



Imię i nazwisko autora rozprawy: Magdalena Brygała
Dyscyplina naukowa: Ekonomia i finanse

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: Modele oceny ryzyka upadłości konsumenckiej

Tytuł rozprawy w języku angielskim: Models for assessing the risk of consumer bankruptcy

Promotor
<i>podpis</i>
dr hab. inż. Tomasz Korol, prof. PG
Promotor pomocniczy
<i>podpis</i>
dr Piotr Paradowski

Gdańsk, rok 2025



The author of the PhD dissertation: Magdalena Brygała
Scientific discipline: Economics and finance

DOCTORAL DISSERTATION

Title of PhD dissertation: Models for assessing the risk of consumer bankruptcy

Title of PhD dissertation (in Polish): Modele oceny ryzyka upadłości konsumenckiej

Supervisor
<i>signature</i>
dr hab. inż. Tomasz Korol, prof. PG
Auxiliary supervisor
<i>signature</i>
dr Piotr Paradowski

Gdańsk, year 2025



OŚWIADCZENIE

Autor rozprawy doktorskiej: Magdalena Brygała

Ja, niżej podpisana, oświadczam, iż jestem świadoma, że zgodnie z przepisem art. 27 ust. 1 i 2 ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (tj. Dz.U. z 2021 poz. 1062), uczelnia może korzystać z mojej rozprawy doktorskiej zatytułowanej:

Modele oceny ryzyka upadłości konsumenckiej
do prowadzenia badań naukowych lub w celach dydaktycznych.¹

Świadoma odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym i nauce (Dz.U.2021.478 tj.), a także odpowiedzialności cywilnoprawnej oświadczam, że przedkładana rozprawa doktorska została napisana przeze mnie samodzielnie.

Oświadczam, że treść rozprawy opracowana została na podstawie wyników badań prowadzonych pod kierunkiem i w ścisłej współpracy z promotorem dr hab. inż. Tomaszem Korolem, prof. PG, promotorem pomocniczym dr Piotrem Paradowskim.

Niniejsza rozprawa doktorska nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem stopnia doktora.

Wszystkie informacje umieszczone w ww. rozprawie uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami, zgodnie z przepisem art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy doktorskiej z załączoną wersją elektroniczną.

Gdańsk, dnia

.....
podpis doktoranta

Ja, niżej podpisana, wyrażam zgodę na umieszczenie ww. rozprawy doktorskiej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej.

Gdańsk, dnia

.....
podpis doktoranta

¹ Art. 27. 1. Instytucje oświatowe oraz podmioty, o których mowa w art. 7 ust. 1 pkt 1, 2 i 4–8 ustawy z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce, mogą na potrzeby zilustrowania treści przekazywanych w celach dydaktycznych lub w celu prowadzenia działalności naukowej korzystać z rozpowszechnionych utworów w oryginale i w tłumaczeniu oraz zwielokrotniać w tym celu rozpowszechnione drobne twory lub fragmenty większych utworów.

2. W przypadku publicznego udostępniania utworów w taki sposób, aby każdy mógł mieć do nich dostęp w miejscu i czasie przez siebie wybranym korzystanie, o którym mowa w ust. 1, jest dozwolone wyłącznie dla ograniczonego kręgu osób uczących się, nauczających lub prowadzących badania naukowe, zidentyfikowanych przez podmioty wymienione w ust. 1.



STATEMENT

The author of the doctoral dissertation: Magdalena Brygała

I, the undersigned, declare that I am aware that in accordance with the provisions of Art. 27 (1) and (2) of the Act of 4th February 1994 on Copyright and Related Rights (Journal of Laws of 2021, item 1062), the university may use my doctoral dissertation entitled:
Models for assessing the risk of consumer bankruptcy
for scientific or didactic purposes.¹

Gdańsk,

.....
signature of the PhD student

Aware of criminal liability for violations of the Act of 4th February 1994 on Copyright and Related Rights and disciplinary actions set out in the Law on Higher Education and Science (Journal of Laws 2021, item 478), as well as civil liability, I declare, that the submitted doctoral dissertation is my own work.

I declare, that the submitted doctoral dissertation is my own work performed under and in cooperation with the supervision of dr hab. inż. Tomasz Korol, prof. PG, the auxiliary supervision of dr Piotr Paradowski.

This submitted doctoral dissertation has never before been the basis of an official procedure associated with the awarding of a PhD degree.

All the information contained in the above thesis which is derived from written and electronic sources is documented in a list of relevant literature in accordance with Art. 34 of the Copyright and Related Rights Act.

I confirm that this doctoral dissertation is identical to the attached electronic version.

Gdańsk,

.....
signature of the PhD student

I, the undersigned, agree to include an electronic version of the above doctoral dissertation in the open, institutional, digital repository of Gdańsk University of Technology.

Gdańsk,

.....
signature of the PhD student

¹ Art 27. 1. Educational institutions and entities referred to in art. 7 sec. 1 points 1, 2 and 4–8 of the Act of 20 July 2018 – Law on Higher Education and Science, may use the disseminated works in the original and in translation for the purposes of illustrating the content provided for didactic purposes or in order to conduct research activities, and to reproduce for this purpose disseminated minor works or fragments of larger works.

2. If the works are made available to the public in such a way that everyone can have access to them at the place and time selected by them, as referred to in para. 1, is allowed only for a limited group of people learning, teaching or conducting research, identified by the entities listed in paragraph 1.

OPIS ROZPRAWY DOKTORSKIEJ

Autor rozprawy doktorskiej: Magdalena Brygała

Tytuł rozprawy doktorskiej w języku polskim: Modele oceny ryzyka upadłości konsumenckiej

Tytuł rozprawy w języku angielskim: Models for assessing the risk of consumer bankruptcy

Język rozprawy doktorskiej: polski

Promotor rozprawy doktorskiej: dr hab. inż. Tomasz Korol, prof. PG

Promotor pomocniczy rozprawy doktorskiej: dr Piotr Paradowski

Data obrony: <dzień, miesiąc, rok>

Słowa kluczowe rozprawy doktorskiej w języku polskim: upadłość konsumencka, uczenie maszynowe, sztuczne sieci neuronowe, SHAP, LIME

Słowa kluczowe rozprawy doktorskiej w języku angielskim: consumer bankruptcy, machine learning, artificial neural networks, SHAP, LIME

Streszczenie rozprawy w języku polskim: Upadłość konsumencka jest istotnym zjawiskiem w gospodarce, dlatego wczesne wykrycie ryzyka jej wystąpienia pozwala chronić zarówno kredytodawców, jak i konsumentów przed jej negatywnymi skutkami. W obszarze prognozowania ryzyka upadłości konsumenckiej wciąż istnieje luka badawcza, wynikająca z ograniczonej liczby badań poświęconych tej problematyce. Celem niniejszej rozprawy doktorskiej jest opracowanie modeli prognozowania ryzyka upadłości konsumenckiej na przykładzie Stanów Zjednoczonych. W przeprowadzonym badaniu porównano skuteczność dziesięciu popularnych algorytmów indywidualnych uczenia maszynowego oraz dziesięciu klasyfikatorów zespołowych łączących różne klasyfikatory. Modele oszacowano przy użyciu trzech zestawów zmiennych pochodzących z the Survey of Consumer Finances w Stanach Zjednoczonych. Zidentyfikowano również mikroekonomiczne czynniki wpływające na ryzyko upadłości konsumenckiej przy zastosowaniu metod takich jak analiza istotności cech (ang. feature importance), technika SHapley Additive exPlanations (SHAP) oraz Local Interpretable Model-Agnostic Explanations (LIME). Ponadto podjęto próbę opracowania nowych wskaźników integrujących różne rodzaje informacji, zarówno demograficzne, jak i finansowe, w celu oceny ryzyka upadłości konsumenckiej. Spośród algorytmów indywidualnych najwyższą skuteczność osiągnęły modele Light Gradient Boosting Machine, Categorical Boosting oraz Extreme Gradient Boosting. Metody zespołowe łączące różne klasyfikatory wykazały się również wysoką skutecznością w porównaniu do wszystkich oszacowanych modeli.

Streszczenie rozprawy w języku angielskim: Consumer bankruptcy is a significant phenomenon in the economy; therefore, early detection of the risk of its occurrence helps protect both creditors and consumers from its negative effects. In the area of forecasting consumer bankruptcy risk, a research gap still exists due to the limited number of studies dedicated to this issue. The aim of this doctoral dissertation is to



develop models for predicting consumer bankruptcy risk, using the United States as a case study. The study compared the effectiveness of ten popular individual machine learning algorithms and ten ensemble methods combining various classifiers. The models were estimated using three sets of variables derived from the Survey of Consumer Finances in the United States. Microeconomic factors influencing consumer bankruptcy risk were also identified through methods such as feature importance analysis, SHapley Additive exPlanations (SHAP), and Local Interpretable Model-Agnostic Explanations (LIME). Furthermore, an attempt was made to develop new indicators that integrate different types of information, both demographic and financial, in order to assess consumer bankruptcy risk. Among the individual algorithms, the highest effectiveness was achieved by Light Gradient Boosting Machine, Categorical Boosting, and Extreme Gradient Boosting models. Ensemble methods combining various classifiers also demonstrated high effectiveness compared to all the estimated models.

DESCRIPTION OF DOCTORAL DISSERTATION

The Author of the PhD dissertation: Magdalena Brygala

Title of PhD dissertation: Models for assessing the risk of consumer bankruptcy

Title of PhD dissertation in Polish: Modele oceny ryzyka upadłości konsumenckiej

Language of PhD dissertation: Polish

Supervision: dr hab. inż. Tomasz Korol, prof. PG

Auxiliary supervision: dr Piotr Paradowski

Date of doctoral defense: <day, month, year>

Keywords of PhD dissertation in Polish: upadłość konsumencka, uczenie maszynowe, sztuczne sieci neuronowe, SHAP, LIME

Keywords of PhD dissertation in English: consumer bankruptcy, machine learning, artificial neural networks, SHAP, LIME

Summary of PhD dissertation in Polish: Upadłość konsumencka jest istotnym zjawiskiem w gospodarce, dlatego wczesne wykrycie ryzyka jej wystąpienia pozwala chronić zarówno kredytodawców, jak i konsumentów przed jej negatywnymi skutkami. W obszarze prognozowania ryzyka upadłości konsumenckiej wciąż istnieje luka badawcza, wynikająca z ograniczonej liczby badań poświęconych tej problematyce. Celem niniejszej rozprawy doktorskiej jest opracowanie modeli prognozowania ryzyka upadłości konsumenckiej na przykładzie Stanów Zjednoczonych. W przeprowadzonym badaniu porównano skuteczność dziesięciu popularnych algorytmów indywidualnych uczenia maszynowego oraz dziesięciu klasyfikatorów zespołowych łączących różne klasyfikatory. Modele oszacowano przy użyciu trzech zestawów zmiennych pochodzących z the Survey of Consumer Finances w Stanach Zjednoczonych. Zidentyfikowano również mikroekonomiczne czynniki wpływające na ryzyko upadłości konsumenckiej przy zastosowaniu metod takich jak analiza istotności cech (ang. feature importance), technika SHapley Additive exPlanations (SHAP) oraz Local Interpretable Model-Agnostic Explanations (LIME). Ponadto podjęto próbę opracowania nowych wskaźników integrujących różne rodzaje informacji, zarówno demograficzne, jak i finansowe, w celu oceny ryzyka upadłości konsumenckiej. Spośród algorytmów indywidualnych najwyższą skuteczność osiągnęły modele Light Gradient Boosting Machine, Categorical Boosting oraz Extreme Gradient Boosting. Metody zespołowe łączące różne klasyfikatory wykazały się również wysoką skutecznością w porównaniu do wszystkich oszacowanych modeli.

Summary of PhD dissertation in English: Consumer bankruptcy is a significant phenomenon in the economy; therefore, early detection of the risk of its occurrence helps protect both creditors and consumers



from its negative effects. In the area of forecasting consumer bankruptcy risk, a research gap still exists due to the limited number of studies dedicated to this issue. The aim of this doctoral dissertation is to develop models for predicting consumer bankruptcy risk, using the United States as a case study. The study compared the effectiveness of ten popular individual machine learning algorithms and ten ensemble methods combining various classifiers. The models were estimated using three sets of variables derived from the Survey of Consumer Finances in the United States. Microeconomic factors influencing consumer bankruptcy risk were also identified through methods such as feature importance analysis, SHapley Additive exPlanations (SHAP), and Local Interpretable Model-Agnostic Explanations (LIME). Furthermore, an attempt was made to develop new indicators that integrate different types of information, both demographic and financial, in order to assess consumer bankruptcy risk. Among the individual algorithms, the highest effectiveness was achieved by Light Gradient Boosting Machine, Categorical Boosting, and Extreme Gradient Boosting models. Ensemble methods combining various classifiers also demonstrated high effectiveness compared to all the estimated models.

Spis treści

Wstęp	12
1. Aspekty ekonomiczne i prawne upadłości konsumenckiej	17
1.1. Pojęcie oraz charakterystyka upadłości konsumenckiej	17
1.2. Upadłość konsumencka w Stanach Zjednoczonych	22
1.3. Upadłość konsumencka w wybranych krajach Europy	27
1.3.1. Polska	27
1.3.2. Anglia i Walia	36
1.3.3. Niemcy	40
1.3.4. Irlandia Północna	42
1.4. Przegląd przyczyn upadłości konsumenckiej	44
2. Metodologia badań nad prognozowaniem ryzyka upadłości konsumenckiej	49
2.1. Przygotowanie danych do analizy i modelowania.....	49
2.2. Klasyfikacja modeli prognozowania ryzyka upadłości konsumenckiej	55
2.3. Charakterystyka wybranych metod prognozowania ryzyka upadłości konsumenckiej	64
2.3.1. Regresja logistyczna	64
2.3.2. Maszyna wektorów nośnych.....	65
2.3.3. Drzewo decyzyjne.....	66
2.3.4. Las losowy	67
2.3.5. Adaptive Boosting	68
2.3.6. Gradient Boosting Classifier.....	69
2.3.7. Extreme Gradient Boosting.....	70
2.3.8. Light Gradient Boosting Machine	71
2.3.9. Categorical Boosting.....	72
2.3.10. Sieci neuronowe.....	73
2.4. Ocena skuteczności i interpretacja modeli.....	74
2.4.1. Miary skuteczności modeli	74
2.4.2. Interpretowalność modeli.....	78

2.4.3. Zalety i wady poszczególnych metod prognozowania ryzyka upadłości konsumenckiej	80
2.5. Przegląd zmiennych wykorzystywanych w prognozowaniu ryzyka upadłości konsumenckiej	85
2.6. Przegląd modeli prognozowania ryzyka upadłości konsumenckiej	91
3. Modele prognozowania ryzyka upadłości konsumenckiej w Stanach Zjednoczonych	96
3.1. Założenia do przeprowadzonych badań	96
3.2. Charakterystyka próby badawczej	103
3.3. Modele prognozowania ryzyka upadłości konsumenckiej oszacowane dla pierwszego zestawu zmiennych	105
3.3.1. Regresja logistyczna	105
3.3.2. Maszyna wektorów nośnych	107
3.3.3. Drzewo decyzyjne	113
3.3.4. Las losowy	121
3.3.5. Adaptive Boosting	126
3.3.6. Gradient Boosting Classifier	132
3.3.7. Extreme Gradient Boosting	138
3.3.8. Light Gradient Boosting Machine	144
3.3.9. Categorical Boosting	150
3.3.10. Sieci neuronowe	156
3.3.11. Metody agregacji klasyfikatorów	162
3.4. Modele prognozowania ryzyka upadłości konsumenckiej oszacowane dla drugiego zestawu zmiennych	165
3.4.1. Regresja logistyczna	165
3.4.2. Maszyna wektorów nośnych	168
3.4.3. Drzewo decyzyjne	174
3.4.4. Las losowy	180
3.4.5. Adaptive Boosting	186
3.4.6. Gradient Boosting Classifier	193
3.4.7. Extreme Gradient Boosting	200
3.4.8. Light Gradient Boosting Machine	207

3.4.9. Categorical Boosting.....	214
3.4.10. Sieci neuronowe.....	221
3.4.11. Metody agregacji klasyfikatorów	227
3.5. Analiza porównawcza skuteczności modeli prognozowania ryzyka upadłości konsumenckiej dla pierwszego i drugiego zestawu zmiennych	229
3.6. Analiza istotności cech w modelach prognozowania ryzyka upadłości konsumenckiej	238
Zakończenie	244
Rekomendacje dla przyszłych badań	251
Ograniczenia badawcze	252
Bibliografia	253
Spis rysunków.....	272
Spis wykresów	273
Spis tabel.....	282

Wstęp

Upadłość konsumencka jest istotnym zjawiskiem w gospodarce, a wczesne wykrycie ryzyka jej wystąpienia ma na celu ochronę zarówno kredytodawców, jak i samych konsumentów przed jej negatywnymi skutkami. Wciąż stanowi istotne wyzwanie dla banków oraz innych instytucji kredytowych w wielu krajach na całym świecie. W 2023 roku w Stanach Zjednoczonych ogłoszono 433,7 tys. upadłości konsumenckich, co stanowiło 0,13% populacji, a w Polsce 21 tys. upadłości, co stanowiło 0,06% populacji. W tym samym okresie w Anglii i Walii odnotowano 7,7 tys. upadłości, co stanowiło 0,01% populacji, natomiast w Niemczech 66,9 tys. upadłości, co stanowiło 0,08% upadłości. Zjawisko to, mimo iż różni się w poszczególnych krajach w zależności od obowiązujących regulacji prawnych, uwarunkowań ekonomicznych oraz długości okresu jego funkcjonowania, pozostaje istotnym zagadnieniem o globalnym charakterze. Wczesna identyfikacja konsumentów z wysokim ryzykiem upadłości zmniejsza straty wierzycieli, ponieważ zadłużenie osób ogłaszających upadłość rośnie liniowo wraz ze zbliżającym się momentem ogłoszenia upadłości (Xiong i in., 2013). Skuteczne przewidywanie upadłości konsumenckiej pozwala na podjęcie działań, które mogą zapobiec jej wystąpieniu lub zminimalizować negatywne konsekwencje pogarszającej się sytuacji finansowej konsumentów. Jest to szczególnie istotne w kontekście zmian mikroekonomicznych i makroekonomicznych wpływających na gospodarstwa domowe. Z tego względu kluczowe jest opracowanie skutecznych metod wczesnego wykrywania ryzyka upadłości konsumenckiej. Skala oraz negatywne konsekwencje ekonomiczne i społeczne upadłości konsumenckiej wymagają poszukiwania nowych metod prognozowania ryzyka oraz identyfikacji czynników, które to ryzyko zwiększają.

Niewiele badań zostało opracowanych w zakresie przewidywania ryzyka upadłości konsumenckiej (Syed Nor i in., 2024, Korol, 2024a; Korol, 2024b; Brygała i Korol, 2024; Korol, 2022; Brygała, 2022; Korol i Fotiadis, 2022; Sahiq i in., 2022; Korol, 2021; Syed Nor i in., 2019). Ograniczona liczba badań empirycznych wynika m.in. z ograniczonego dostępu do danych (Fisher, 2019). Ze względu na trudności związane z pozyskaniem wiarygodnych danych dotyczących upadłości konsumenckiej w Polsce, autorka zdecydowała się na wykorzystanie danych pochodzących ze Stanów Zjednoczonych. Należy jednak podkreślić, że opracowane i zastosowane w niniejszym badaniu modele mogą być również wykorzystane na innych zbiorach danych. Ponadto przegląd literatury dotyczącej prognozowania ryzyka upadłości konsumenckiej wykazał następujące ograniczenia.

Po pierwsze, pomimo rosnącej popularności metod boosting, które wykazują wysoką skuteczność, brakuje badań porównujących te metody z klasycznymi algorytmami, takimi jak

regresja logistyczna, maszyna wektorów nośnych oraz drzewo decyzyjne. Dotychczasowe badania nad prognozowaniem upadłości konsumenckiej wykorzystywały różne algorytmy, w tym regresję logistyczną, analizę dyskryminacyjną, drzewo decyzyjne, sieci neuronowe, logikę rozmytą oraz algorytmy genetyczne (Syed Nor i in., 2024, Korol, 2024a; Korol, 2024b; Korol, 2022; Brygała, 2022; Korol, 2021; Korol i Fotiadis, 2022; Sahiq i in., 2022; Syed Nor i in., 2019). Zgodnie z wiedzą autorki, tylko jedno badanie porównało cztery algorytmy boosting z maszynami wektorów nośnych oraz lasami losowymi (Brygała i Korol, 2024). W ramach niniejszej rozprawy porównano modele boosting z klasycznymi metodami, uwzględniając regresję logistyczną, maszynę wektorów nośnych, drzewo decyzyjne, las losowy, Adaptive Boosting, Gradient Boosting Classifier, Extreme Gradient Boosting, Light Gradient Boosting Machine, Categorical Boosting oraz sieci neuronowe.

Po drugie, brak jest badań porównujących pojedyncze klasyfikatory z metodami zespołowymi opartymi na łączeniu klasyfikatorów. Badania tego rodzaju mogłyby dostarczyć cennych informacji na temat skuteczności różnych podejść do prognozowania ryzyka upadłości konsumenckiej. W rozprawie doktorskiej oszacowano klasyfikatory zespołowe bazujące na pojedynczych klasyfikatorach, wykorzystując metody: uśredniania, głosowania oraz stacking. Zgodnie z wiedzą autorki, tylko w dwóch badaniach (Korol, 2024; Korol i Fotiadis, 2022) zastosowano techniki łączenia klasyfikatorów.

Po trzecie, niewiele badań uwzględnia wskaźniki łączące zmienne demograficzne z finansowymi, a dostępne badania nie dotyczą Stanów Zjednoczonych, co stanowi istotną lukę w literaturze. Stany Zjednoczone były jednym z pierwszych krajów, które wprowadziły przepisy dotyczące upadłości konsumenckiej. Zgodnie z wiedzą autorki, dotychczas takie wskaźniki zostały opracowane jedynie dla Polski oraz Tajwanu (Korol, 2024a; Korol, 2024b; Korol, 2021). W związku z tym w rozprawie doktorskiej opracowano nowe wskaźniki integrujące zmienne demograficzne i finansowe na przykładzie Stanów Zjednoczonych.

Po czwarte, zgodnie z wiedzą autorki w dostępnych badaniach, w których zastosowano modele inne niż regresja logistyczna oprócz badania przeprowadzonego przez Brygałę i Korolę (2024), nie uwzględniono metod interpretacji modeli, co ogranicza pełne zrozumienie funkcjonowania tych modeli. W związku z tym przeprowadzone badania, umożliwiły również zidentyfikowanie czynników mających wpływ na ryzyko upadłości konsumenckiej wykorzystując w prognozowaniu upadłości konsumenckiej bardziej zaawansowane metody niż regresja logistyczna, co jest istotne w kontekście zrozumienia, kto decyduje się na ogłoszenie upadłości konsumenckiej. Identyfikacja tych czynników została dokonana na podstawie wyników opracowanych modeli predykcyjnych, przy użyciu takich metod jak analiza istotności

cech (ang. feature importance), techniki SHapley Additive exPlanations (SHAP) oraz Local Interpretable Model-Agnostic Explanations (LIME). Wzrost zaawansowania algorytmów powoduje, że często modele uczenia maszynowego są uważane za „czarne skrzynki” ze względu na ich złożoność i ukryte mechanizmy (Carmona i in., 2022), dlatego też w rozprawie doktorskiej zaprezentowano najbardziej popularne metody interpretacji modeli. Istotne jest zrozumienie, w jaki sposób poszczególne cechy wpływają na działanie modelu. Umożliwia to jego lepszą interpretację oraz dostarcza cennych informacji wspierających budowę modelu.

W związku z powyższym, głównym celem rozprawy doktorskiej jest opracowanie modeli prognozowania ryzyka upadłości konsumenckiej na przykładzie Stanów Zjednoczonych. W przeprowadzonym badaniu porównano skuteczność dziesięciu algorytmów indywidualnych oraz dziesięciu algorytmów zespołowych, wykorzystując trzy zestawy zmiennych z the Survey of Consumer Finances w Stanach Zjednoczonych. Tak sformułowany cel główny doprowadził do wyznaczenia celów szczegółowych:

1. Przegląd literatury międzynarodowej na temat modeli oraz zmiennych wykorzystywanych do prognozowania ryzyka upadłości konsumenckiej.
2. Oszacowanie i weryfikacja skuteczności modeli indywidualnych prognozowania ryzyka upadłości konsumenckiej, w tym zarówno modelu regresji logistycznej, jak i innych modeli uczenia maszynowego (drzewo decyzyjne, las losowy, maszyna wektorów nośnych, Adaptive Boosting, Gradient Boosting Classifier, Extreme Gradient Boosting, Light Gradient Boosting Machine, Categorical Boosting oraz sieci neuronowe).
3. Oszacowanie i weryfikacja skuteczności klasyfikatorów zespołowych z wykorzystaniem metod: uśredniania, głosowania oraz stacking.
4. Porównanie skuteczności klasyfikatorów indywidualnych oraz zespołowych w prognozowaniu ryzyka upadłości konsumenckiej.
5. Ocena skuteczności modeli prognozowania ryzyka upadłości konsumenckiej przy wykorzystaniu różnych miar oceny skuteczności, takich jak: całkowita skuteczność, błąd I typu, błąd II typu, F1, krzywa ROC z wyliczonym wskaźnikiem AUC oraz wskaźnik Giniego.
6. Identyfikacja czynników mikroekonomicznych wpływających na ryzyko upadłości konsumenckiej przy wykorzystaniu metod interpretacji modeli, takich jak analiza istotności cech, technika SHAP oraz LIME.
7. Próba opracowania nowego rodzaju wskaźników integrujących różne rodzaje informacji (demograficzne i finansowe) w celu oceny ryzyka upadłości konsumenckiej.

Cele szczegółowe doprowadziły do sformułowania sześciu pytań badawczych, które opracowano na podstawie przeglądu literatury oraz zidentyfikowanych luk badawczych:

PB1: Jakie są najpopularniejsze algorytmy wykorzystywane w przewidywaniu ryzyka upadłości konsumenckiej w literaturze międzynarodowej?

PB2: Jakie są najpopularniejsze zmienne wykorzystywane w przewidywaniu ryzyka upadłości konsumenckiej w literaturze międzynarodowej?

PB3: Które algorytmy wykazują najwyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej?

PB4: Czy wykorzystanie klasyfikatorów zespołowych zwiększa skuteczność prognozowania ryzyka upadłości konsumenckiej?

PB5: Jakie zmienne mają największy wpływ na ryzyko upadłości konsumenckiej?

PB6: Czy wykorzystanie wskaźników integrujących zmienne demograficzne i finansowe zwiększa skuteczność modeli prognozujących ryzyko upadłości konsumenckiej?

Sprecyzowanie problemu naukowego, wyznaczenie celu głównego i celów szczegółowych umożliwiło sformułowanie następujących hipotez badawczych:

H1: Modele typu boosting, w tym Light Gradient Boosting Machine, Extreme Gradient Boosting oraz Categorical Boosting, wykazują wyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej w porównaniu z popularnymi algorytmami indywidualnymi, takimi jak regresja logistyczna, maszyna wektorów nośnych oraz drzewo decyzyjne.

H2: Zastosowanie nowego rodzaju wskaźników, uwzględniających zmienne demograficzne oraz zmienne finansowe, zwiększa skuteczność modeli prognozowania ryzyka upadłości konsumenckiej.

H3: Klasyfikatory zespołowe oparte na łączeniu wyników modeli indywidualnych, charakteryzują się wyższą zdolnością do poprawnego przewidywania upadłości konsumenckiej niż klasyfikatory indywidualne.

Niniejsza rozprawa doktorska składa się z trzech rozdziałów. Struktura pracy oraz zawartość poszczególnych rozdziałów zostały dostosowane do realizacji przyjętych celów badawczych oraz weryfikacji postawionych hipotez.

W rozdziale pierwszym przedstawiono ekonomiczne i prawne aspekty zjawiska upadłości konsumenckiej. Obejmuje również analizę systemów upadłości konsumenckiej funkcjonujących w Stanach Zjednoczonych oraz wybranych państwach europejskich. Ponadto przedstawiono przegląd najczęstszych przyczyn upadłości konsumenckiej.

W rozdziale drugim zaprezentowano metodologię badań dotyczącą prognozowania ryzyka upadłości konsumenckiej. Przedstawiono w nim szczegółowy opis podejścia

badawczego, obejmujący etapy przygotowania danych oraz klasyfikację modeli prognostycznych. W dalszej części rozdziału scharakteryzowano wybrane metody wykorzystywane do prognozowania upadłości konsumenckiej, zarówno podstawowe techniki uczenia maszynowego, takie jak regresja logistyczna, jak i bardziej zaawansowane algorytmy, w tym metody ensemble oraz sieci neuronowe. Szczególną uwagę poświęcono zagadnieniom związanym z oceną skuteczności oraz interpretacją modeli. Omówiono stosowane miary skuteczności predykcyjnej, kwestie interpretowalności oraz zalety i wady poszczególnych metod predykcyjnych. Rozdział kończy przegląd zmiennych wykorzystywanych w modelowaniu tego rodzaju ryzyka oraz zestawienie wybranych modeli prognozowania upadłości konsumenckiej opisanych w literaturze przedmiotu.

W rozdziale trzecim przedstawiono wyniki badań empirycznych. W pierwszej kolejności omówiono założenia do przeprowadzonych badań oraz charakterystykę próby badawczej. Następnie zaprezentowano wyniki oszacowania dziesięciu modeli indywidualnych oraz dziesięciu modeli łączących klasyfikatory indywidualne, wykorzystując trzy różne zestawy zmiennych. Porównano skuteczność modeli z zastosowaniem szeregu miar oceny jakości predykcji. Ponadto, przy użyciu metod interpretacji modeli, zidentyfikowano mikroekonomiczne czynniki wpływające na ryzyko upadłości konsumenckiej.

Przegląd badań poświęconych prognozowaniu upadłości konsumenckiej wskazuje na rosnącą istotność, popularność oraz aktualność tej tematyki. Poszukiwanie nowych algorytmów predykcyjnych, zmiennych wpływających na ryzyko upadłości oraz nowych wskaźników poprawiających skuteczność modeli jest kluczowe, biorąc pod uwagę zmieniającą się sytuację makroekonomiczną i mikroekonomiczną gospodarstw domowych, jak również wpływ upadłości konsumenckiej na kredytobiorców, konsumentów, ich rodziny, społeczności lokalne oraz całą gospodarkę. Ponadto wykorzystanie metod interpretacji przy budowie modeli umożliwia zrozumienie modelu, przy jednoczesnym korzystaniu z zaawansowanych algorytmów.

1. Aspekty ekonomiczne i prawne upadłości konsumenckiej

1.1. Pojęcie oraz charakterystyka upadłości konsumenckiej

Upadłość konsumencka została wprowadzona w Stanach Zjednoczonych już w 1898 roku a w Europie po raz pierwszy w Danii w 1984 roku (Cukiernik i Teluk, 2007). Kolejne kraje w Europie, które postanowiły wprowadzić upadłość konsumencką, to: Wielka Brytania (1990), Francja (1989), Finlandia (1993), Austria (1994), Szwecja (1994), Niemcy (1999) i Polska (2008) (Szymańska, 2013; Niemi-Kiesiläinen, 1997). Upadłość konsumencka, wprowadzona w Stanach Zjednoczonych, miała istotny wpływ na prawo upadłościowe w Europie. Wraz z wprowadzaniem instytucji upadłości konsumenckiej do ustawodawstw różnych państw wypracowywano odpowiednią terminologię opisującą to zjawisko.

Termin „upadłość konsumencka” został wprowadzony do polskiego języka poprzez tłumaczenie z języka angielskiego terminu „consumer bankruptcy” lub z niemieckiego „Verbraucherkonkurs” (Tereszkiewicz, 2009). Jest to nieformalne wyrażenie, które nie ma odzwierciedlenia w ustawach ani innych aktach normatywnych. Niemniej jednak wielokrotnie było używane w literaturze przedmiotu oraz w tytułach projektów aktów prawnych podczas prac legislacyjnych. Pomimo, że w ustawie z dnia 28 lutego 2003 r. – Prawo upadłościowe (Dz.U. 2022 poz. 1520, t.j.) nie występuje formalnie termin „upadłość konsumencka”, lecz stosuje się określenie „postępowanie upadłościowe wobec osób fizycznych nieprowadzących działalności gospodarczej”, w praktyce oraz w języku prawniczo-ekonomicznym jest on powszechnie używany dla określenia upadłości osoby fizycznej nieprowadzącej działalności gospodarczej (Tereszkiewicz, 2009). Warto jednak zauważyć, że przymiotnik „konsumencka” w odniesieniu do upadłości jest uważany za nieprecyzyjny oraz rozbieżny w porównaniu z definicjami w różnych obszarach np. w prawie i ekonomii (Tereszkiewicz, 2009). Zgodnie z ustawą z dnia 23 kwietnia 1964 r. Kodeksu cywilnego, konsument jest osobą fizyczną, dokonującą z przedsiębiorcą czynności prawnej niezwiązanej bezpośrednio z jej działalnością gospodarczą lub zawodową (art. 221 k.c.). Ponadto, w niektórych systemach prawnych termin „upadłość konsumencka” odnosi się także do postępowania upadłościowego stosowanego wobec osób prowadzących działalność gospodarczą (o określonym zakresie) oraz działalność zarobkową jak np. wolne zawody (Tereszkiewicz, 2009).

Termin „consumer bankruptcy” nie został zaakceptowany w językach europejskich i prawie europejskim. Języki skandynawskie używają sformułowania „sanering” lub „rearrangement of debts”, w Niemczech najczęściej używa się słowa “Verbraucherinsolvenz”, a we Francji “règlement” and “redressement” (Niemi-Kiesiläinen, 1997). Zarówno w języku

polskim jak i angielskim, w odniesieniu do tego samego pojęcia są stosowane różne terminy. Różnorodność terminologiczna dotyczy nie tylko aspektów prawnych, lecz jest szczególnie widoczna w badaniach nad prognozowaniem upadłości konsumenckiej, gdzie autorzy posługują się różnymi określeniami, takimi jak upadłość osobista (ang. personal bankruptcy – np. Zhu, 2011; Syed Nor i in., 2019; Sahiq i in., 2022; Korol, 2024b; Brygała i Korol, 2024), upadłość konsumencka (ang. consumer bankruptcy – np. Brygała, 2022; Korol, 2024a; Korol, 2024b), ryzyko niewypłacalności (ang. insolvency risk – np. Korol, 2024b) czy trudności finansowe (ang. distress – np. Syed Nor i in., 2019). Podobne zróżnicowanie terminologiczne występuje również w niemieckim systemie prawnym, gdzie dla określenia upadłości konsumenckiej stosuje się następujące terminy: upadłość konsumencka (niem. Verbraucherinsolvenz), upadłość prywatna (niem. Privatinsolvenz) oraz „mała upadłość” (niem. Kleininsolvenz) (Tim, 2018). Ponadto, pojęcie upadłość często jest używane zamiennie z terminem bankructwa (Świecka, 2008). Z ekonomicznego punktu widzenia osoba jest uznawana za bankruta, jeżeli nie reguluje swoich zobowiązań, a majątek nie wystarcza na ich pokrycie, natomiast z perspektywy prawniczej upadłość konsumencka następuje po ogłoszeniu upadłości przez sąd (Świecka, 2008). Ze względu na powyższe, a w szczególności na powszechne użycie terminów „upadłość konsumencka” oraz „bankructwo konsumenckie” w odniesieniu do podstępowania upadłościowego osób fizycznych nieprowadzących działalności gospodarczej, w niniejszej rozprawie doktorskiej oba pojęcia będą stosowane zamiennie w odniesieniu do tego rodzaju postępowania.

Upadłość gospodarstw domowych jest postępowaniem prawnym, obejmującym zarówno procedury sądowe jak i pozasądowe, mające na celu ustalenie przyczyn niewypłacalności, możliwość uzgodnienia ugody, opracowania planu spłaty oraz w ostateczności umorzenia części lub całości długów (Świecka, 2009). Istotą upadłości konsumenckiej jest oddłużenie konsumenta, który spełnia wszystkie wymogi prawne. Upadłość konsumencka umożliwia dłużnikowi reorganizację długu poprzez zawarcie układu z wierzycielami, określenie nowego planu spłaty długów i ich likwidację. Zapewnia to dłużnikowi szansę na wyjście ze spirali długów i rozpoczęcie nowego życia bez długów. Mechanizm upadłości konsumenckiej powinien skutecznie przeciwdziałać społecznemu wykluczeniu, które może mieć miejsce, gdy konsument nie jest w stanie uregulować swoich zobowiązań. Plan spłaty ma nie tylko wymiar ekonomiczny, ale również edukacyjny. Jego celem jest nie tylko umożliwienie dłużnikowi spłaty długów, ale także zaoferowanie mu możliwości rehabilitacji, a także zmotywowanie do odpowiedzialnego zarządzania finansami, aby unikać ponownej niewypłacalności w przyszłości. Prawo upadłościowe zapewniając nowy

start dla dłużnika, stanowi formę ochrony. Konsumentów poprzez brak informacji, ograniczoną racjonalność, brak planowania finansów z uwzględnieniem możliwych zagrożeń oraz błędną ocenę zdolności kredytowej, mogą doprowadzić do problemów ze spłatą zobowiązań. Ramsay (2007) zauważył, że istnieją zarówno dowody ekonomiczne, jak i psychologiczne sugerujące, że konsumenci niedoszacowują przyszłego ryzyka związanego z korzystaniem z kredytów. Idea, w której dłużnik będzie ponosił konsekwencje nadmiernego zadłużenia do końca życia, nie jest akceptowalna w społeczeństwie opartym na kredytach, które promuje oraz zachęca do korzystania z kredytów (Huls, 1997). W związku z tym, upadłość jako rozwiązanie dla różnych sytuacji dłużników, może być postrzegana jako mechanizm równoważący interesy wierzycieli i dłużników (Ramsay, 2007). Można wyróżnić następujące cele prawa upadłościowego (White, 2006):

- zachęcanie do podejmowania skutecznych decyzji, zarówno inwestycyjnych przed upadłością jak i po niej,
- unikanie współzawodnictwa między wierzycielami o pierwszeństwo w odzyskaniu zobowiązań,
- dokonanie skutecznego wyboru pomiędzy likwidacją a reorganizacją w przypadku upadłości dłużników,
- ochrona konsumentów przed pogorszeniem sytuacji dłużnika na przykład w przypadku choroby, utraty pracy.

Poszczególne państwa w różnym zakresie i formie implementowały instytucję upadłości konsumenckiej, co wpływa na sposób realizacji ogólnych celów prawa upadłościowego. W związku z tym, w literaturze przedmiotu wyróżnia się różne modele prawne upadłości konsumenckiej, w zależności od przyjętych kryteriów klasyfikacyjnych. Jednym z przykładów takiego ujęcia klasyfikacyjnego jest podział zaproponowany przez Odorzyńską-Kondek (2011), obejmujący model konserwatywny, model umiarkowany oraz model liberalny. Pomiędzy tymi modelami istnieją różnice zarówno w warunkach, które trzeba spełnić, jak i w wymaganiach dotyczących spłaty długu. W modelu konserwatywnym nie ma możliwości całkowitego umorzenia długu konsumenta, a głównym celem jest ochrona interesów wierzycieli. Model ten został przyjęty w ustawodawstwie Czech, Węgier i Włoch. Model umiarkowany opiera się na restrykcyjnych warunkach, a postępowanie jest inicjowane na wniosek dłużnika. Model ten reprezentowany jest przez kraje takie jak Niemcy, Austria, Francja, Hiszpania i Polska. Trzeci model liberalny charakteryzuje się znaczną ochroną interesów dłużnika, a nie wierzycieli. Ważnym elementem jest umożliwienie dłużnikowi

nowego startu. Model ten występuje w krajach takich jak Stany Zjednoczone, Wielka Brytania i Holandia.

W literaturze przedmiotu przedstawione są również inne modele prawne: angloamerykański model „fresh start” i model europejsko-kontynentalny „earned fresh start” (Szpringer, 2008). Model angloamerykański koncentruje się na umożliwieniu dłużnikowi powrotu do społeczeństwa i skutecznego zarządzania finansami. Jest uznawany za najbardziej liberalny model upadłości konsumenckiej, który w pierwszej kolejności chroni interesy dłużnika. Natomiast model europejsko-kontynentalny koncentruje się na edukacji i rehabilitacji dłużnika, zakładając, że umorzenie długów może nastąpić dopiero po pomyślnej realizacji przez dłużnika planu spłaty (Wolska-Bagińska, 2018). Dostęp do procedury upadłości konsumenckiej w modelu europejsko-kontynentalnym jest bardziej utrudniony i ograniczony niż w modelu angloamerykańskim.

Amerykańskie regulacje są krytykowane w Europie z powodu nadmiernego liberalizmu regulacji i szacuje się, że prawo amerykańskie opiera się w zbyt małym stopniu na wymogach moralnych (Szpringer, 2008). Amerykańskie prawo upadłościowe jest uważane za najbardziej łagodne prawo na świecie. Europejskie prawo dotyczące oddłużania, ma wspólny cel (Szpringer, 2008):

- rehabilitację dłużnika,
- edukację konsumentką,
- utrzymanie morale spłaty zadłużenia.

Europejskie regulacje zwracają dużą uwagę na edukację dłużników poprzez poradnictwo co powinno prowadzić do podnoszenia wiedzy ekonomicznej dłużników, zmiany ich stylu życia, w celu wyeliminowania podobnej sytuacji w przyszłości oraz aby dłużnik mógł uregulować jak największą część zaległych zobowiązań (Szpringer, 2008). W Europie prawo upadłościowe ewoluowało z czasem, ponieważ wcześniej brakowało przepisów umożliwiających oddłużenie konsumenta. W ciągu ostatnich lat nastąpiło wiele zmian w prawie upadłościowym zarówno w Europie jak i w Stanach Zjednoczonych. W Europie istnieje tendencja do łagodzenia prawa upadłościowego np. Polska, Niemcy, Francja. Natomiast w Stanach Zjednoczonych, które posiadały bardzo liberalne przepisy upadłościowe wprowadzona nowelizacja z roku 2005 zaostrzyła przepisy, co z kolei spowodowało zmniejszenie liczby ogłaszanych upadłości konsumenckich. 29 maja 2000 r. poprzez wprowadzenie rozporządzenia nr 1346/2000 Rady Unii Europejskiej nastąpiła częściowa harmonizacja prawa upadłości konsumenckiej pomiędzy krajami Unii Europejskiej i ma zastosowanie do wszystkich postępowań upadłościowych,

zarówno jak dłużnikiem jest osoba fizyczna, osoba prawna, przedsiębiorca lub osoba nieprowadząca działalności gospodarczej (Odorzyńska-Kondek, 2011).

Choć ramy prawne różnią się między państwami, etapy prowadzące do ogłoszenia upadłości są do siebie zbliżone i odzwierciedlają podobne problemy finansowe dłużników. Niewypłacalność konsumenta stanowi przesłankę prawną do ogłoszenia upadłości konsumenckiej (Świecka, 2009). Problem nadmiernego zadłużenia gospodarstw domowych jest widoczny na całym świecie. Niewypłacalność konsumentów wynika zarówno z narastającego zadłużenia, jak i konsumpcyjnego nastawienia społeczeństwa (Wolska-Bagińska, 2018). W konsekwencji może prowadzić do upadłości konsumenckiej. Zadłużenie stanowi naturalny etap w rozwoju każdego gospodarstwa domowego i może powstać w instytucjach bankowych (Banki komercyjne, Banki spółdzielcze, Banki oszczędnościowe), parabankowych (Spółdzielcze Kasy Oszczędnościowo-Kredytowe, Pośrednicy kredytowi) i pozabankowych (Instytucje świadczący usługi masowe, Instytucje pozarządowe, Kasy Zapomogowo-Pożyczkowe, Lombardy, Osoby fizyczne) (Świecka, 2009). Największe zapotrzebowanie na pozyskanie środków finansowych zazwyczaj występuje we wczesnych okresach cyklu życia gospodarstwa domowego (Świecka i Koziński, 2014). Na podstawie literatury przedmiotu oraz badań własnych Świecka (2009) zdefiniowała niewypłacalność gospodarstwa domowego jako „trwałą utratę możliwości obsługi zobowiązań przez dłużnika, objawiającą się utratą płynności” oraz „stan, w którym gospodarstwo domowe nie ma możliwości spłaty zobowiązań i zaprzestało spłaty wszelkich zobowiązań”. Z punktu widzenia prawnego niewypłacalność jest przesłanką do ogłoszenia upadłości, a z punktu widzenia ekonomicznego, niewypłacalne jest gospodarstwo domowe, które nie jest w stanie regulować zobowiązań, a posiadany majątek nie wystarcza na pokrycie długów (Świecka, 2009). Upadłość konsumencka jest prawnym stanem niewypłacalności, który ma miejsce poprzez drogę sądową. Niemniej jednak, nie każdy konsument, będący w sytuacji niewypłacalności musi decydować się na złożenie wniosku o upadłość konsumencką. Wpływ na tę decyzję może mieć m.in. posiadany majątek (np. nieruchomości), sytuacja finansowa oraz wsparcie ze strony rodziny.

Niewypłacalność konsumentów jest uważana za zjawisko stopniowalne. W związku z tym, Świecka (2009) zwraca uwagę, iż zasadnym jest wprowadzenie pojęcia „zagrożenia niewypłacalnością konsumentów”. Upadłość konsumencka powinna stanowić ostateczność dla konsumenta i wykluczać sytuacje nadużyć. Według Odorzyńskiej-Kondek (2011), niewypłacalność ma wpływ zarówno na stan psychiczny, funkcjonowanie zawodowe, życie rodzinne, jak i możliwości rozwoju oraz planowanie przyszłości dłużnika, a w konsekwencji

także na gospodarkę. Świecka (2008) wskazuje na następujące etapy prowadzące do niewypłacalności gospodarstwa domowego:

- utrwalenie się negatywnej sytuacji finansowej gospodarstwa domowego, która może być przejściowa,
- pogłębienie się negatywnej sytuacji finansowej gospodarstwa domowego poprzez brak reakcji na złą sytuację finansową lub pozyskiwanie kolejnych zobowiązań w celu poprawy sytuacji finansowej,
- pojawienie się problemów z wypłacalnością gospodarstwa domowego,
- bankructwo gospodarstwa domowego.

Etap pierwszy może stanowić jedynie etap przejściowy, pod warunkiem, że kolejne decyzje finansowe nie będą pogłębiać negatywnej sytuacji finansowej. Pierwsze etapy są odwracalne, gdy zostaną podjęte odpowiednie środki. Kluczowe znaczenie ma tutaj właściwa edukacja finansowa konsumentów i wsparcie. Brak wiedzy i wsparcia może skłaniać do korzystania z droższych produktów finansowych, na przykład w parabankach, lub wykorzystania dostępnych środków finansowych na posiadanych kartach kredytowych czy debetach w koncie osobistym. Taka praktyka w konsekwencji może pogłębić negatywną sytuację finansową i doprowadzić do niewypłacalności lub upadłości konsumenckiej.

1.2. Upadłość konsumencka w Stanach Zjednoczonych


Głównym celem prawa upadłościowego w Stanach Zjednoczonych jest zapewnienie dłużnikom nowego startu (United States Courts, 2023). Prawo to jest skierowane do uczciwych dłużników, którzy nie radzą sobie ze swoim zadłużeniem, dając im nową szansę w życiu, która nie będzie ograniczana ani wyznaczana przez sytuację, która doprowadziła do niewypłacalności.

W Stanach Zjednoczonych konsumenci mogą wybrać jedną z dwóch procedur upadłościowych, określonych w Kodeksie Upadłościowym Stanów Zjednoczonych (ang. U.S. Bankruptcy Code): rozdział 7 i rozdział 13. Wybór ten zależy od wielkości majątku dłużnika oraz wysokości jego dochodów. Procedury upadłościowe różnią się pod względem czasu spłaty zobowiązań, kosztów, które trzeba ponieść, oraz możliwości zatrzymania majątku. Niemniej jednak, obie procedury kończą się spłatą długów. Różnica między rozdziałem 7 a rozdziałem 13 polega na tym, że w przypadku rozdziału 13 dłużnik częściowo spłaca dług w ciągu 3-5 lat i ma prawo zatrzymać swoje aktywa. W przypadku rozdziału 7, częściowa spłata zobowiązań nie jest wymagana. Upadłość zgodnie z rozdziałem 7 jest często nazywana bankructwem likwidacyjnym. Aktywa masy upadłościowej dłużnika są przejmowane, zamieniane na

gotówkę, a następnie rozdzielane wśród wierzycieli. Ponad 95% dłużników, którzy złożyli wnioski o upadłość konsumencką w ramach rozdziału 7, otrzymuje umorzenie większości długów, zazwyczaj w ciągu czterech do sześciu miesięcy od złożenia wniosku (Foohey i in., 2018). Długi nieobjęte umorzeniem obejmują np. alimenty, pożyczki zaciągnięte lub gwarantowane przez jednostkę rządową, długi za umyślne szkody wyrządzone przez dłużnika wobec innego podmiotu lub majątku innego podmiotu, długi z tytułu śmierci lub obrażeń ciała spowodowanych jazdą przez dłużnika pojazdem mechanicznym, gdy dłużnik był pod wpływem alkoholu lub innych środków odurzających (United States Courts, 2023). Większość dłużników ubiegających się o upadłość konsumencką w ramach rozdziału 7 nie posiada majątku możliwego do likwidacji, dlatego absolutorium jest udzielane dłużnikowi zazwyczaj po około czterech miesiącach od daty złożenia wniosku (United States Courts, 2023). Rozdział 13 jest przeznaczony dla dłużników posiadających źródło dochodu, ale w praktyce jest wykorzystywany przez osoby, które nie chcą utracić aktywów (Fisher, 2019). Rozdział 13 umożliwia dłużnikowi zachowanie aktywów, takich jak np. dom oraz pozwala przedstawić plan spłaty wierzycielom w okresie zazwyczaj od 3 do 5 lat. Dłużnik nie przekazuje żadnych aktywów, w zamian proponując wieloletni plan spłaty części zaległego długu (Fisher, 2019). Ponadto rozdział 13 jest skierowany do konsumentów, którzy nie spełniają warunków, aby ubiegać się o rozdział 7. W przeciwieństwie do rozdziału 7, dłużnicy w ramach rozdziału 13 nie otrzymują zwolnienia z długów do czasu, aż nie zrealizują planu spłaty. Postępowanie ugodowe (rozdział 13) trwa kilka lat, zaś postępowanie likwidacyjne (rozdział 7) można uzyskać w ciągu kilku miesięcy. Plan spłaty jest możliwy, jeżeli wierzyciele otrzymają co najmniej tyle, ile otrzymaliby, gdyby aktywa dłużnika były likwidowane na mocy rozdziału 7 (United States Courts, 2023).

W 2024 roku wśród osób ogłaszających upadłość konsumencką, 60% konsumentów było procesowanych w ramach rozdziału 7, podczas gdy 40% postępowań dotyczyło rozdziału 13 (wykres 1). W 2023 roku udział postępowań upadłościowych procesowanych w ramach rozdziału 7 wyniósł 58%. Najniższy udział upadłości konsumenckich rozpatrywanych w ramach rozdziału 7 od 2001 roku odnotowano w latach 2006, 2022 oraz 2023. W latach 2020-2021 udział postępowań upadłościowych procesowanych w ramach rozdziału 7 wzrósł do 70%, co może mieć związek z pandemią COVID-19.

Wykres 1. Upadłość konsumencka w Stanach Zjednoczonych w podziale na rodzaj procedury upadłościowej



Źródło: opracowanie własne na podstawie danych z United States Courts, pozyskanych 02.02.2025 z <https://www.uscourts.gov/statistics-reports/caseload-statistics-data-tables>.

Ogłoszenie upadłości konsumenckiej stanowi jedno z rozwiązań problemów finansowych konsumentów. Jednakże, aby to stało się realne, konieczne jest złożenie odpowiedniego wniosku i zmierzenie się z potencjalnymi barierami. Uchwalenie ustawy o zapobieganiu nadużyciom finansowym i ochronie konsumentów z 2005 r. (BAPCPA) sprawiło, że proces wnioskowania o upadłość stał się bardziej skomplikowany, kosztowny i czasochłonny (Sommer, 2005). Wprowadzenie tej ustawy wynikało z obaw związanych z możliwością nadużyć wśród osób starających się o upadłość konsumencką. Wszelkie przypadki nadużyć mogą uniemożliwić ubieganie się o upadłość konsumencką zgodnie z postanowieniami rozdziału 7. Prawo dążyło do ograniczenia możliwości składania wniosków o upadłość konsumencką według rozdziału 7 przez gospodarstwa domowe o wyższych dochodach, dlatego też wprowadzono weryfikację dochodu (tzw. „the means test”). Jeżeli dochód dłużników z poprzednich sześciu miesięcy przed złożeniem wniosku, skorygowany o wielkość rodziny, jest większy niż mediana dochodu stanu to dłużnicy objęci testem mogą złożyć wniosek o upadłość konsumencką zgodnie z rozdziałem 13, który po wprowadzeniu BAPCPA wymagał wyższej spłaty (Parra, 2022; Gross i in., 2021). BAPCPA wydłużyło również okres, po jakim istnieje możliwość ponownego złożenia wniosku o upadłość konsumencką, z sześciu lat do ośmiu lat w przypadku rozdziału 7 oraz z sześciu miesięcy do dwóch lat w przypadku rozdziału 13 (Gross i in., 2021). Przed uchwaleniem ustawy BAPCPA 71% wniosków było składanych w ramach rozdziału 7 (Fisher, 2019). Decyzja czy upadłość będzie procesowana z planem spłaty (rozdział 13) czy bez (rozdział 7) była po stronie dłużnika.

Tylko około jedna trzecia dłużników, którzy złożyli wniosek o upadłość zgodnie z rozdziałem 13, była w stanie zrealizować swoje plany spłaty w taki sposób, aby pozostała część długu została umorzona; pozostałe dwie trzecie spraw było konwertowanych do rozdziału 7 lub po prostu odrzucanych (Foohey, 2019).

System prawny w Stanach Zjednoczonych przewiduje katalog przesłanek, których wystąpienie może skutkować oddaleniem wniosku o upadłość konsumencką. Sąd może odmówić udzielenia upadłości konsumenckiej, gdy dłużnik (United States Courts, 2025):

- nie prowadził lub nie przedstawił odpowiednich ksiąg lub dokumentacji finansowej,
- nie wyjaśnił w zadowalający sposób utraty swoich aktywów,
- popełnił przestępstwo upadłościowe np. składając fałszywe oświadczenia,
- nie wykonał zgodnego z prawem postanowienia sądu upadłościowego,
- nielegalnie przeniósł, zniszczył lub ukrył majątek,
- nie ukończył kursu dotyczącego zarządzania finansami.


Osoby składające wniosek o upadłość są obecnie zobowiązane do udziału w dwóch kursach edukacyjnych: kursie doradztwa kredytowego przed złożeniem wniosku oraz kursie zarządzania finansami przed umorzeniem długów (Gross i in., 2021). Istotne jest, aby kursy zostały zrealizowane we właściwym czasie, ponieważ jest to wymagane przy składaniu wniosku o upadłość. Kurs doradczy przed złożeniem wniosku o upadłość obejmuje ocenę sytuacji finansowej dłużnika, omówienie alternatyw dla upadłości konsumenckiej oraz indywidualny plan budżetu. Koszt kursu ponosi dłużnik, chyba że nie jest w stanie uiścić opłaty, wówczas może zostać z niej zwolniony. Edukacja dłużników po złożeniu wniosku obejmuje informacje dotyczące tworzenia budżetu, zarządzania finansami oraz rozsądnego korzystania z kredytu. Ze względu na skomplikowane formalności i możliwe wyjątki od umorzenia długów, dłużnicy powinni skorzystać z pomocy radcy prawnego przed złożeniem wniosku o upadłość konsumencką. Choć nie jest to obowiązkowe, to jednak rekomendowane.

Istnieje również możliwość, że dłużnik zawrze porozumienie z wierzycielem w sprawie zobowiązania zabezpieczonego. Dłużnik zobowiązuje się do uiszczenia w całości lub części zobowiązania, zatrzymując jednocześnie określony majątek zabezpieczony, na przykład samochód. W zamian wierzyciel zobowiązuje się nie zabierać mienia, o ile dłużnik kontynuuje spłatę długu.

Na wykresie 2 przedstawiono liczbę upadłości konsumenckich w Stanach Zjednoczonych w latach 2001-2024, a także procentowy udział gospodarstw domowych, które złożyły wniosek o upadłość konsumencką oraz procentowy udział ogólnej liczby ludności,

która złożyła taki wniosek. Gospodarstwo domowe obejmuje wszystkich mieszkańców danej jednostki mieszkaniowej. W ciągu ostatnich trzech lat średnio rocznie 434 tysiące konsumentów składało wnioski o upadłość konsumencką. Na wykresie można również zaobserwować zmniejszenie liczby upadłości konsumenckich od 2006 roku, czyli po uchwaleniu ustawy o zapobieganiu nadużyciom finansowym i ochronie konsumentów z 2005 roku.


Wykres 2. Upadłości konsumenckie w Stanach Zjednoczonych w latach 2001-2024



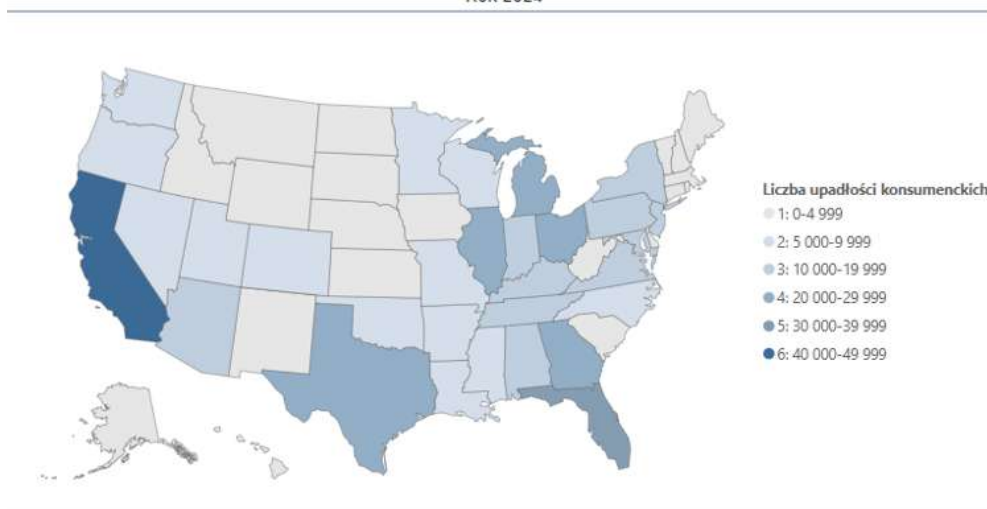
Źródło: opracowanie własne na podstawie danych z United States Courts, pozyskanych 02.02.2025 z <https://www.uscourts.gov/statistics-reports/caseload-statistics-data-tables> oraz Statista (2025), pozyskanych 02.03.2025 z <https://www.statista.com/statistics/>.

Na rysunku 1 autorka rozprawy opracowała mapę ilustrującą liczbę upadłości konsumenckich w poszczególnych stanach. Intensywność koloru odzwierciedla liczbę upadłości, gdzie im kolor jest intensywniejszy, tym większa liczba upadłości. W 2022 roku najwięcej upadłości konsumenckich ogłoszono w następujących stanach: Kalifornia, Floryda, Georgia, Illinois oraz Teksas. Natomiast w 2024 roku były to: Kalifornia, Floryda, Texas, Georgia i Illinois. W obu przypadkach występują te same stany, różniące się jedynie kolejnością.

Rok 2022



Rok 2024



Rysunek 1. Liczba upadłości konsumenckich w poszczególnych stanach w Stanach Zjednoczonych w latach 2022 i 2024

Źródło: opracowanie własne na podstawie danych z United States Courts, pozyskanych 02.02.2025 z <https://www.uscourts.gov/statistics-reports/caseload-statistics-data-tables>.

1.3. Upadłość konsumencka w wybranych krajach Europy

1.3.1. Polska

Pojęcie upadłości konsumenckiej zostało wprowadzone w Polsce dopiero dnia 5 grudnia 2008 r. (ustawa zaczęła obowiązywać od 31 marca 2009 r.), gdy Sejm uchwalił nowelizację ustawy z 28 lutego 2003 r. — Prawo upadłościowe i naprawcze. Nowelizacja wprowadziła do ustawy „Postępowanie upadłościowe wobec osób fizycznych nieprowadzących działalności gospodarczej”, regulując upadłość konsumencką jako odrębne postępowanie. Rosnące zadłużenie konsumentów przyczyniło się do pojawienia się tej instytucji w polskim systemie

prawnym (Szymańska, 2013). Z racji tego, że koszty postępowania upadłościowego były pokrywane z majątku dłużnika, wielu dłużników z powodów finansowych nie mogła sobie pozwolić na złożenie wniosku o upadłość konsumencką (Porzycki, 2019). Umorzenie długu było możliwe jedynie w sytuacji niewypłacalności dłużnika, która wynikała z wyjątkowych okoliczności, na które dłużnik nie miał wpływu. W szczególności w ustawie uwzględniono sytuacje, gdy dłużnik zaciągnął zobowiązania będąc już osobą niewypłacalną lub doszło do rozwiązania stosunku pracy dłużnika z jego winy lub za jego zgodą.

31 grudnia 2014 weszła w życie nowelizacja ustawy z dnia 29 sierpnia 2014 r. całkowicie zmieniająca prawo upadłościowe konsumentów. W ramach reformy zidentyfikowano oraz usunięto następujące trudności, które wpływały na dostępność upadłości konsumenckiej (Porzycki, 2019):

1. Nastąpiła zmiana dotycząca finansowania kosztów postępowania. Przed nowelizacją ustawy dłużnik był zobowiązany do pokrycia kosztów. Wprowadzono tymczasowe finansowanie przez państwo postępowań upadłościowych konsumentów bez aktywów. Koszty powinny być następnie odzyskane, o ile to możliwe, z masy upadłościowej lub w ramach planu spłaty. Jednak w wielu przypadkach państwo ostatecznie pokrywa koszty postępowania, ponieważ dłużnik nie był w stanie spłacić tych kosztów. Dodatkowo zwrócono również uwagę na wysokie koszty postępowania oraz wprowadzono zmiany również w tym aspekcie. Zniesiono publikowanie oficjalnych ogłoszeń w gazetach ze względu na nadmierne koszty oraz wprowadzono limity wynagrodzeń syndyka masy upadłościowej.
2. Wprowadzono łagodniejsze kryteria wykluczające dłużnika z oddłużenia. Po reformie wprowadzonej w 2014 r. stosuje się kryterium niewypłacalności, która została spowodowana umyślnie lub rażąco niedbale. Przed reformą zaś obowiązywało kryterium, gdzie niewypłacalność wynikała z nadzwyczajnych okoliczności pozostających poza kontrolą dłużnika.
3. W przepisach wprowadzono możliwość indywidualnego podejścia do sytuacji dłużnika z przyczyn humanitarnych lub słusznych, nawet jeżeli nastąpiło pewne naruszenie przez dłużnika i w związku z tym wniosek powinien zostać odrzucony.

Ponadto, nowelizacja ustawy wprowadziła również możliwość zawarcia porozumienia pomiędzy dłużnikiem i wierzycielami, w tym np. z zatrzymaniem niektórych aktywów (np. mieszkania) w zamian za dłuższy plan spłaty. Jednakże, w praktyce ta możliwość nie znalazła szerokiego zastosowania (Porzycki, 2019). Przeprowadzona analiza akt wszczętych postępowań w 2015 roku (Fiedorowicz i Popłonyk, 2016) wykazała, że Skarb Państwa pokrył

koszty postępowania upadłościowego w całości w 16% spraw, w części w 20% spraw, a w 64% przypadków nie zaistniała potrzeba pokrycia kosztów. W 52% sprawach sąd umorzył zobowiązania dłużnika bez ustanowienia planu spłaty (Fiedorowicz i Popłonyk, 2016).

Kolejna reforma prawa upadłościowego konsumentów została uchwalona 15 maja 2015 r. i weszła w życie 1 stycznia 2016 r. Ustawa ta nie wprowadziła istotnych zmian w prawie upadłościowym konsumentów, z wyjątkiem dostosowania do zmienionej struktury ogólnych postępowań upadłościowych. Reforma wprowadziła standardową formę wniosku o ogłoszenie upadłości konsumenckiej, co stanowi ułatwienie zarówno dla dłużników, jak i sądów upadłościowych (Porzycki, 2019). Zasady dla byłych przedsiębiorców, którzy w ciągu roku zaprzestali działalności, również zostały wprowadzone. Skrócono okres, po którym były przedsiębiorca może wnioskować o upadłość konsumencką (Wiśniewska, 2018).

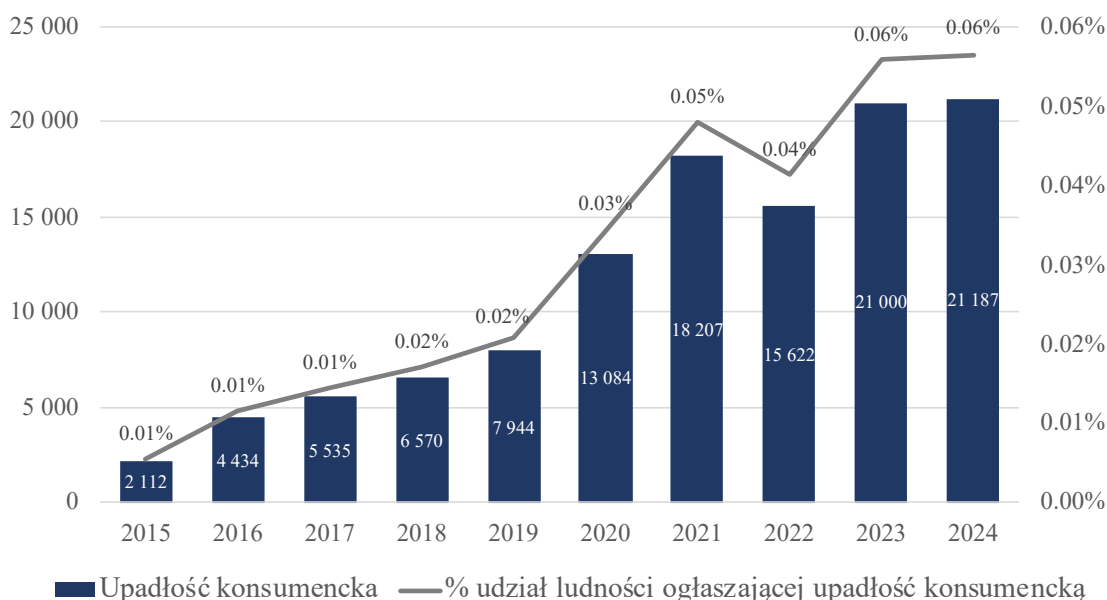
Kolejne istotne zmiany zostały wprowadzone w ramach Ustawy z dnia 30 sierpnia 2019 roku. Ta ustawa, która weszła w życie z dniem 24 marca 2020 r., przyniosła szereg liberalizacji w zakresie upadłości konsumenckiej, modyfikując dotychczasowe przepisy. Zniesiona została konieczność, aby sąd badał przyczyny niewypłacalności. Wcześniej, gdy niewypłacalność wynikała z celowych działań dłużnika lub rażącego niedbalstwa, wnioski były odrzucane. Ponadto, wprowadzono uproszczone postępowanie upadłościowe, które nie powinno trwać dłużej niż 6-8 miesięcy. W ramach tego postępowania sąd jest zaangażowany w sposób ograniczony, zajmując się ustaleniem planu spłaty, rozpatrywaniem ewentualnych skarg oraz ogłoszeniem upadłości. Jeżeli sytuacja konsumenta jest zbyt skomplikowana na postępowanie uproszczone, postępowanie jest prowadzone w trybie zwykłym, trwając co najmniej rok lub dwa lata. W nowelizacji ustawy wprowadzono również zmianę dotyczącą zaspokojenia potrzeb mieszkaniowych dłużnika. Po zmianie dłużnik otrzymuje przeciętny czynsz najmu lokalu mieszkalnego od dwunastu do dwudziestu czterech miesięcy, a nie dwunastu miesięcy tak jak to było w poprzedniej ustawie.

W przypadku dłużników, którzy spowodowali niewypłacalność w wyniku rażącego niedbalstwa, wprowadzono plan spłaty w okresie 3-7 lat. W innych przypadkach czas obowiązywania planu spłaty pozostał na tym samym poziomie, maksymalnie 3 lata, z możliwością skrócenia tego okresu do 1-2 lat. Dodatkowo wprowadzono nową możliwość dla dłużników, którzy nie są w stanie realizować planu spłaty. W takim przypadku może zostać udzielone zawieszono absolutorium na okres 5 lat, w trakcie którego każdy wierzyciel może złożyć wniosek o przyjęcie planu płatności, jeżeli zostanie wykazane, że niezdolność do wykonania planu spłaty nie występuje. Kolejną zmianą w prawie upadłościowym było wprowadzenie informatyzacji postępowań co nastąpiło 1 grudnia 2021 roku. Zmiana

umożliwiła konsumentom składanie wniosków o upadłość konsumencką przez system teleinformatyczny. Wszystkie postępowania upadłościowe oraz restrukturyzacyjne zostały przeniesione do systemu teleinformatycznego Krajowy Rejestr Zadłużonych.

W Polsce w pierwszych latach istnienia prawa upadłościowego, zjawisko to było marginalne. W latach 2009-2014 ogłoszono jedynie 121 upadłości konsumenckich. Jednak po liberalizacji przepisów w grudniu 2014 roku nabrało ogromnego znaczenia. W latach 2015-2024 ogłoszono 115 695 upadłości konsumenckich. W 2024 roku z upadłości konsumenckiej skorzystało 21 187 osób, tj. o 1003% więcej niż w 2015 roku. Zmiana prawa upadłościowego spowodowała istotną zmianę w liczbie ogłaszanych upadłości konsumenckich. Na wykresie 3 przedstawiono liczbę upadłości konsumenckich w Polsce w latach 2015-2024, a także procentowy udział ludności ogłaszającej upadłość konsumencką.

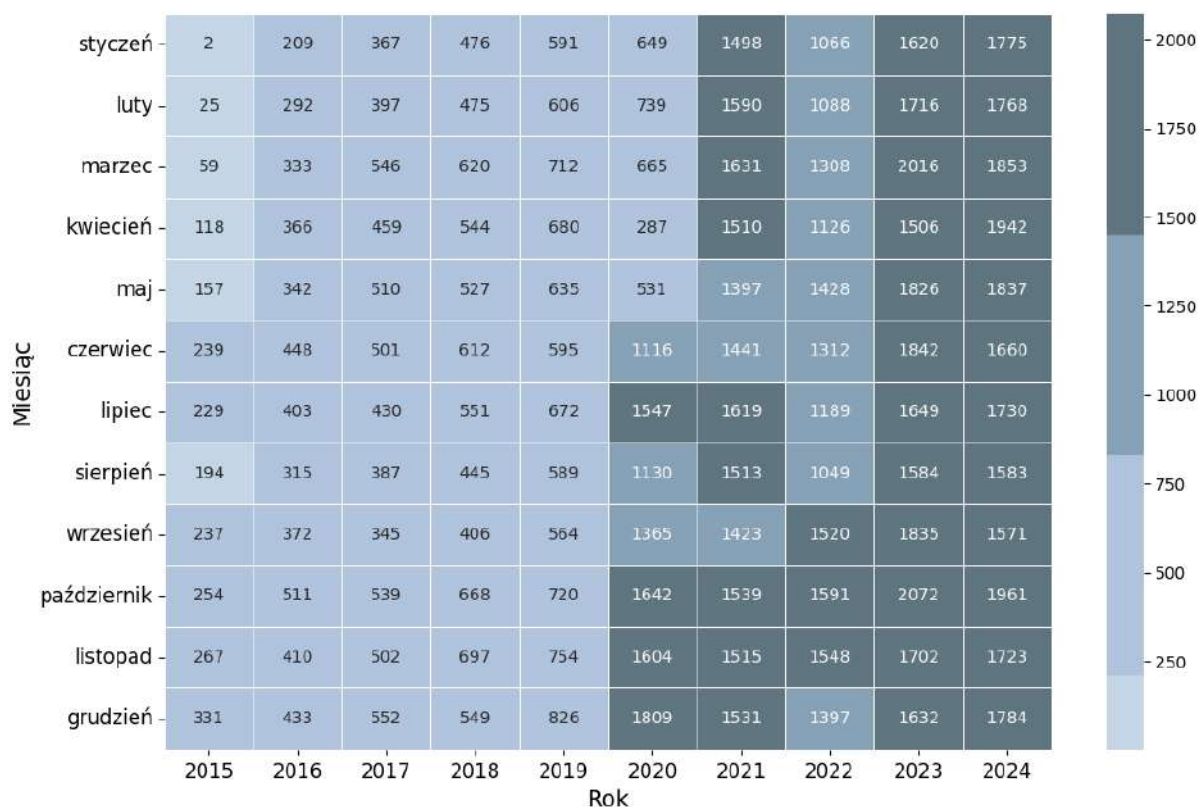
Wykres 3. Upadłości konsumenckie w Polsce w latach 2015-2024



Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/> oraz Głównego Urzędu Statystycznego (2025), pozyskanych 02.02.2025 z <https://stat.gov.pl/>.

Autorka rozprawy doktorskiej opracowała dane dotyczące liczby upadłości konsumenckich w podziale na poszczególne miesiące, które zaprezentowano na rysunku 2. W roku 2020, pomiędzy styczniem a majem, ogłaszano średnio 574 upadłości konsumenckie miesięcznie. Zauważalny jest wpływ pandemii COVID-19 na zmniejszenie liczby upadłości konsumenckich w pierwszych miesiącach pandemii. Dla porównania, w roku 2019 średnia ta wynosiła 662 upadłości miesięcznie. Od czerwca do grudnia 2020 roku ogłaszano średnio 1459 upadłości miesięcznie. Wzrost ten utrzymał się w kolejnych latach: w 2021 roku odnotowano

1517 upadłości konsumenckich, w 2022 roku – 1302, w 2023 roku – 1750, a w 2024 roku - 1766.




Rysunek 2. Miesięczna liczba upadłości konsumenckich w Polsce w latach 2015-2024

Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/>.


Największą grupę konsumentów ogłaszających upadłość konsumencką stanowią osoby w przedziale wiekowym 40-49 (w 2024 roku 26,87%, a w 2018 roku 23,09%) oraz w wieku od 30 do 39 lat (w 2024 roku 23,76%, a w 2018 roku 20,74%) (wykres 4). Wysoki udział mają również konsumenci w wieku od 50 do 59 lat oraz od 60 do 69 lat, jednak w przypadku tych grup wiekowych obserwuje się spadek udziału. Dłużnicy w wieku od 70 do 79 lat stanowili w 2024 roku 7,26% konsumentów, a w 2018 roku 8,83% konsumentów ogłosiło upadłość konsumencką. Zauważalny jest również wzrost udziału konsumentów w przedziale wiekowym do 29 lat (w 2024 7,6% a w 2018 5,04%). Ponadto, do roku 2020 decyzję o ogłoszeniu upadłości konsumenckiej częściej podejmowały kobiety niż mężczyźni. Od roku 2021 zaobserwowano zmianę tego trendu (wykres 5).

Wykres 4. Struktura wieku konsumentów ogłaszających upadłość konsumencką w Polsce w latach 2015-2024



Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/>.

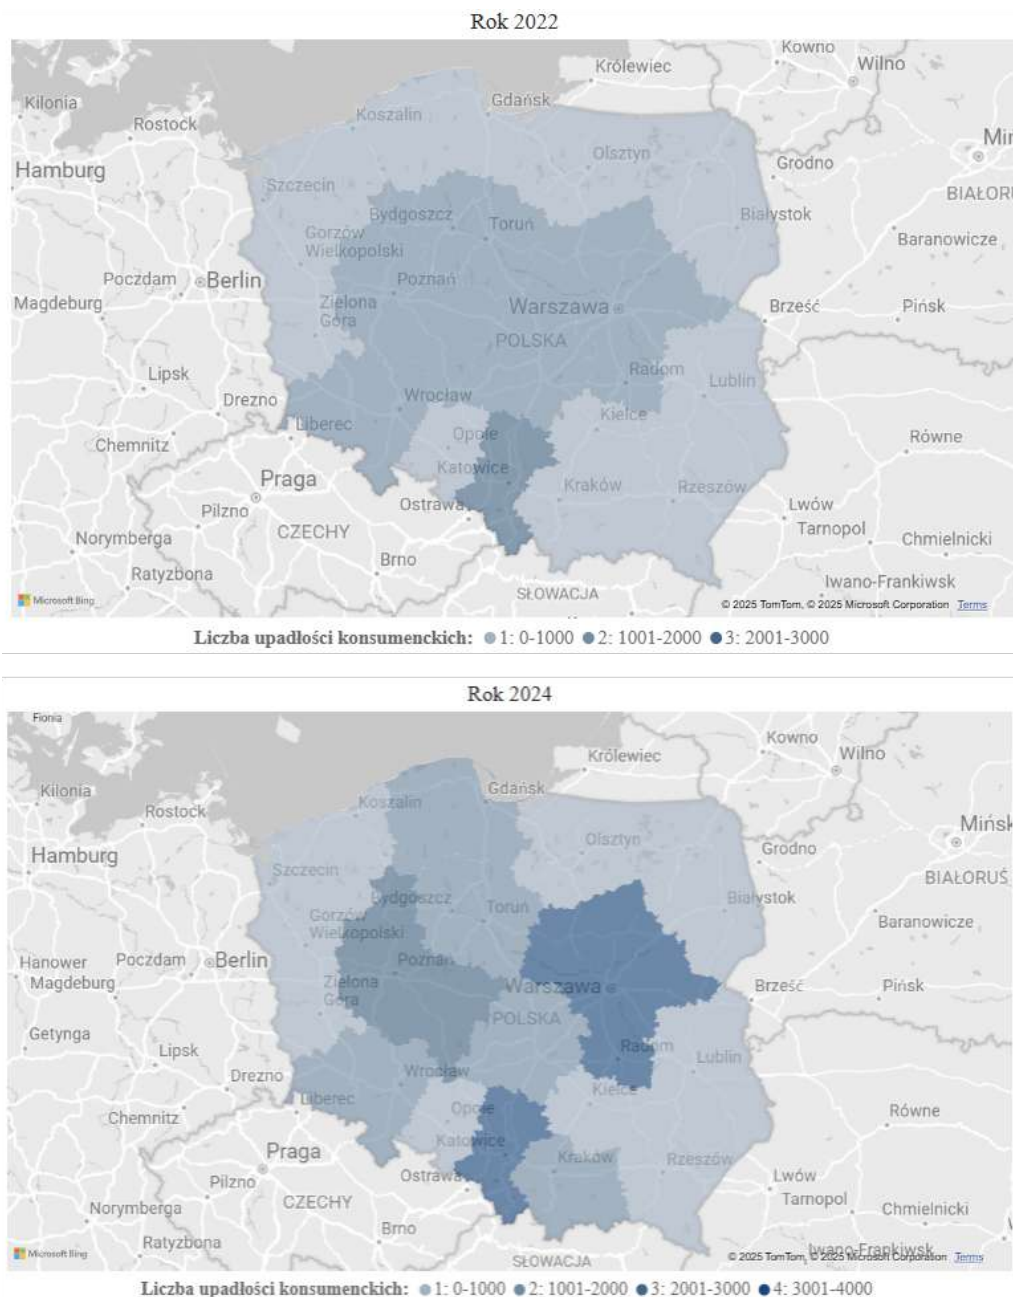
Wykres 5. Upadłość konsumencka w Polsce w latach 2015-2024 ze względu na płeć



Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/>.

Na rysunku 3 znajduje się mapa ilustrująca liczbę upadłości konsumenckich w poszczególnych województwach w latach 2022 i 2024. Intensywność koloru odpowiada liczbie upadłości, gdzie im kolor jest intensywniejszy, tym większa liczba upadłości. W 2022 roku najwięcej upadłości ogłoszono w województwie: śląskim (18,21%), mazowieckim (11,64%) oraz kujawsko-pomorskim (10,09%). Natomiast w przeliczeniu na 100 000 mieszkańców najwięcej postępowań upadłościowych miało miejsce w województwie kujawsko-pomorskim (78), śląskim (65) oraz podlaskim (49). W 2024 roku najwyższy odsetek upadłości odnotowano w województwie: śląskim (15,66%), mazowieckim (15,49%) oraz wielkopolskim (10,44%). W

przeliczeniu na 100 000 mieszkańców, najwięcej upadłości konsumenckich ogłoszono w województwach: śląskim (77), województwie kujawsko-pomorskim (76) oraz województwie lubuskim (71). W latach 2015-2024 najwięcej upadłości konsumenckich było ogłaszanych w województwie śląskim (tj. 16,05%) oraz województwie mazowieckim (tj. 15,52%). Do roku 2019 najwięcej przypadków upadłości konsumenckich wystąpiło w województwie mazowieckim (tj. 20,68%), a od roku 2020 najwięcej zarejestrowano w województwie śląskim (tj. 17,36%).



Rysunek 3. Liczba upadłości konsumenckich w poszczególnych województwach w Polsce w latach 2022 oraz 2024

Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/>.

Na rysunku 4 przedstawiono liczbę upadłości na 100 000 mieszkańców w latach 2015-2024 z podziałem na województwa. Intensywność koloru odzwierciedla liczbę upadłości, gdzie im kolor jest intensywniejszy, tym większa liczba upadłości.




Rysunek 4. Liczba upadłości konsumenckich na 100 000 mieszkańców w województwach Polski w latach 2015-2024

Źródło: opracowanie własne na podstawie danych z Centralnego Ośrodka Informacji Gospodarczej, pozyskanych 02.02.2025 z <http://www.coig.com.pl/>.

W pierwszych latach obowiązywania prawa upadłościowego skierowanego dla konsumentów w Polsce niewiele wniosków o upadłość kończyło się ogłoszeniem upadłości konsumenckiej. Zmiana w prawie upadłościowym spowodowała znaczne zmiany w tym zakresie (wykres 6).


Wykres 6. Udział ogłoszonych upadłości konsumenckich w stosunku do liczby wniosków o upadłość konsumencką w Polsce w latach 2009-2024



Źródło: opracowanie własne na podstawie danych z Ministerstwa Sprawiedliwości, pozyskanych 03.03.2025 z <https://isws.ms.gov.pl/>.

W 2024 roku 87,90% wniosków zostało zakończonych ogłoszeniem upadłości konsumenckiej, podczas gdy w 2009 roku tylko 1,02%. Na wykresie 7 został przedstawiony czas trwania postępowania upadłościowego w miesiącach w latach 2009-2024.

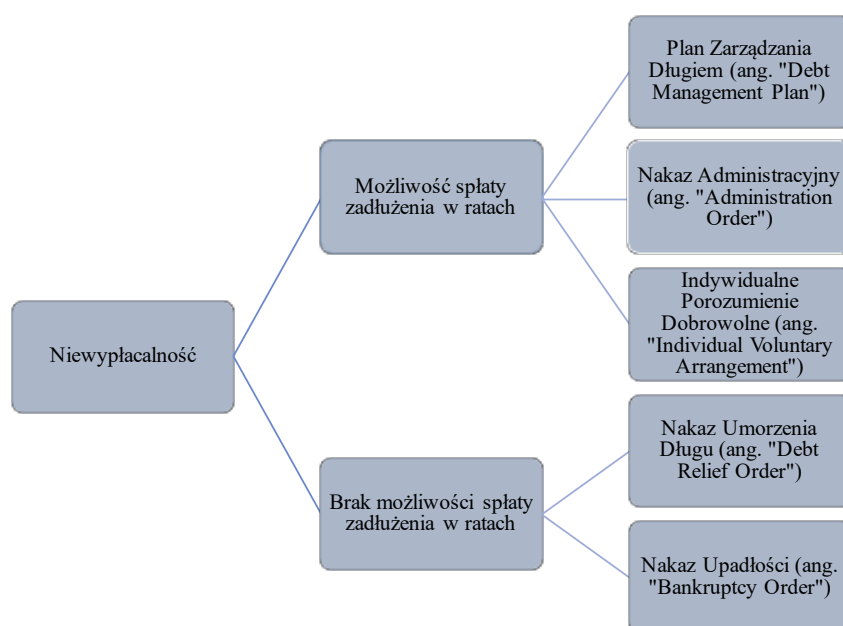
Wykres 7. Średni czas trwania postępowania upadłościowego w Polsce w miesiącach w latach 2009-2024



Źródło: opracowanie własne na podstawie danych z Ministerstwa Sprawiedliwości, pozyskanych 03.03.2025 z <https://isws.ms.gov.pl/>.

1.3.2. Anglia i Walia

W Anglii oraz Walii upadłość konsumencka jest uregulowana przez Ustawę o niewypłacalności z 1986 roku. Wnioskowanie o upadłość konsumencką może nastąpić na wniosek dłużnika lub wierzyciela. Dłużnik, który decyduje się ubiegać o upadłość konsumencką, zobowiązany jest złożyć do sądu oświadczenie, w którym wskazuje na swoją niezdolność do spłacania długów. Od 6 kwietnia 2016 roku wnioski składane przez dłużników są sporządzane wyłącznie online (GOV.UK, 2023). Przed złożeniem wniosku, dłużnik powinien zweryfikować inne możliwości, które są uzależnione od posiadanych środków i aktywów oraz pomogą konsumentowi poradzić sobie z długiem (rysunek 5). Dłużnik ma możliwość skontaktować się z doradcą ds. długów, aby bezpłatnie uzyskać pomoc w wyborze najlepszego sposobu radzenia sobie z nadmiernym zadłużeniem. Osoby, którzy są w stanie spłacać zadłużenie w ratach mogą skorzystać z: Planu Zarządzania Długiem (ang. Debt Management Plan), Nakazu Administracyjnego (ang. Administration Order) oraz Indywidualnego Porozumienia Dobrowolnego (ang. Individual Voluntary Arrangement) (GOV.UK, 2023). Ponadto istnieje możliwość uzyskania tymczasowej ochrony przed wierzycielami poprzez program rządowy (ang. Breathing Space), który przewiduje zawieszenie działań windykacyjnych oraz naliczania odsetek na 60 dni, umożliwiając osobie zadłużonej skorzystanie z porady dotyczącej długu i opracowanie planu wyjścia z trudnej sytuacji finansowej.



Rysunek 5. Dostępne opcje postępowania w przypadku niewypłacalności w Anglii i Walii

Źródło: opracowanie własne na podstawie GOV.UK (2023).

Plan Zarządzania Długiem (ang. „Debt Management Plan”) to umowa zawierana pomiędzy dłużnikiem a wierzycielami, dotycząca spłaty wszystkich długów. Może być opracowana samodzielnie lub za opłatą przez autoryzowaną firmę zajmującą się zarządzaniem długiem. Umowa zobowiązuje dłużnika do regularnej miesięcznej spłaty ustalonej kwoty, która jest wynegocjowana w umowie i dostosowana do jego zdolności finansowej, eliminując konieczność sprzedaży aktywów. W razie zmiany sytuacji finansowej dłużnika istnieje możliwość modyfikacji umowy. Plan Zarządzania Długiem może być stosowany wyłącznie do spłaty niezabezpieczonych długów.

Nakaz Administracyjny (ang. „Administration Order”) jest dostępne dla dłużników, którzy otrzymali wyrok sądu dotyczący długów poniżej 5000 GBP i nie są w stanie uregulować zobowiązań w całości. Procedura polega na regularnych comiesięcznych wpłatach dłużnika do lokalnego sądu, który następnie dzieli te środki pomiędzy wierzycieli. Sąd podejmuje decyzję dotyczącą wysokości raty miesięcznej, okresu trwania układu oraz tego, czy dług ma być spłacony w pełni, czy tylko częściowo.

Indywidualne Porozumienie Dobrowolne (ang. „Individual Voluntary Arrangement”) to ugoda zawierana między dłużnikiem a wierzycielami w celu spłaty całości lub części długów. W ramach tej umowy dłużnik dokonuje regularnych płatności syndykowi masy upadłościowej, który następnie dzieli te środki pomiędzy wierzycieli. Warunkiem skorzystania z Indywidualnego Porozumienia Dobrowolnego jest uzyskanie zgody przynajmniej 75% wierzycieli, którzy posiadają długi. W przypadku nieterminowych płatności umowa może zostać rozwiązana.

Rządowy program tymczasowej ochrony przed wierzycielami (ang. Breathing Space) zapewnia dłużnikom okres względnego zwolnienia od presji egzekucyjnej. W trakcie tego programu dłużnik otrzymuje poradę dotyczącą swoich długów oraz tworzy plan spłaty. Ochrona może trwać do 60 dni, jednak nie zwalnia to dłużnika z obowiązku spłaty zadłużenia. Program ten uniemożliwia wierzycielom podejmowanie działań egzekucyjnych względem dłużnika, kontaktowanie się w sprawie długów objętych programem oraz naliczanie odsetek czy opłat do istniejącego długu. Istnieje możliwość przedłużenia ochrony, jeżeli dłużnik otrzymuje leczenie związane ze zdrowiem psychicznym.


Dłużnicy, którym brakuje środków finansowych i aktywów do spłaty długów mogą skorzystać z opcji złożenia wniosku o Nakaz Umorzenia Długu (ang. „Debt Relief Order”) jako alternatywy do ogłoszenia upadłości (GOV.UK, 2023). Rozwiązanie to zostało wprowadzone 6 kwietnia 2009 r. i jest dostępne dla osób, których zadłużenie nie przekracza 30 000 GBP. Ponadto, miesięczna nadwyżka dochodu zazwyczaj nie powinna przekraczać 75 GBP, wartość

posiadanych aktywów nie może być wyższa niż 2000 GBP, a dłużnicy nie mogą być właścicielami nieruchomości. Proces zazwyczaj trwa 12 miesięcy, po których długi są umarzane. W tym okresie dłużnik przestaje płacić raty wraz z odsetkami za swoje zobowiązania i musi przestrzegać określonych zasad. Warto zauważyć, że Nakaz Umorzenia Długów nie obejmuje czynszów, rachunków oraz niektórych długów, takich jak pożyczki studenckie czy grzywny sądowe. W trakcie obowiązywania dłużnik nie może np. pożyczać więcej niż 500 GBP bez poinformowania pożyczkodawcy o istniejącym Nakazie Umorzenia Długu, pełnić funkcji dyrektora firmy czy zarządzać firmą, nie informując innych osób, z którymi prowadzi firmę. Jeśli sytuacja finansowa dłużnika ulegnie zmianie, Nakaz Umorzenia długu może zostać anulowany lub okres jego obowiązywania przedłużony, pod warunkiem przestrzegania określonych ograniczeń. Wniosek musi zostać złożony za pośrednictwem autoryzowanego doradcy ds. długów (ang. „authorised debt adviser”). Istnieje możliwość uzyskania zwolnienia z długów. Z reguły proces ten trwa 12 miesięcy, po czym długi zostają umorzone. Dłużnik nie jest zobowiązany do dokonywania spłat w zamian za długi ani nie ma obowiązku sprzedaży swoich aktywów. Wierzyciele kontaktują się z dłużnikiem w sprawie płatności, jeżeli są one uwzględnione w Nakazie Umorzenia Długu. Oprócz przestrzegania restrykcji, dłużnik musi również dokonywać płatności. Po skorzystaniu z Nakazu Umorzenia Długów, dane dłużnika pozostają w raporcie kredytowym przez 6 lat.

W przypadku braku możliwości spłaty zadłużenia w ratach, konsumenci mogą złożyć wniosek o ogłoszenie upadłości konsumenckiej. Koszt związany z wnioskowaniem o upadłość konsumencką wynosi 680 GBP i należy go ponieść przed złożeniem wniosku o upadłość (GOV.UK, 2023). Urzędnik podejmuje decyzję, czy dłużnik powinien być objęty postępowaniem w ramach upadłości konsumenckiej. Dłużnik otrzymuje zwolnienie z długów maksymalnie w ciągu roku od ogłoszenia upadłości. Okres ten został skrócony z trzech lat. Celem reformy nie było stworzenie zbyt liberalnego prawa upadłościowego, lecz skrócenie procesu oddłużeniowego.


W Anglii i Walii w latach 2010-2024 odnotowano zmniejszenie liczby ogłaszanych upadłości konsumenckich (wykres 8). W 2010 roku 59 171 konsumentów ogłosiło upadłość konsumencką, natomiast w 2024 roku tylko 7 612 konsumentów. W tym samym okresie zauważalny był wzrost liczby Indywidualnych Porozumień Dobrowolnych z 50 693 w 2010 roku do 67 099 w 2022 roku. Do 2022 roku liczba Nakazów Umorzenia Długu pozostawała natomiast na zbliżonym poziomie. W latach 2023 oraz 2024 odnotowano jednak wzrost (wykres 9).

Wykres 8. Upadłości konsumenckie w Anglii i Walii w latach 2010-2024



Źródło: opracowanie własne na podstawie danych z GOV.UK, pozyskanych 03.02.2025 z <https://www.gov.uk/government/statistics/individual-insolvencies-december-2024> oraz United Kingdom Office for National Statistics, pozyskanych 03.02.2025 z <https://www.ons.gov.uk/>.

Wykres 9. Udział upadłości konsumenckiej, Indywidualnego Porozumienia Dobrowolnego oraz Nakazu Umorzenia Długu w łącznej liczbie indywidualnych postępowań upadłościowych w Anglii i Walii w latach 2010-2024



Źródło: opracowanie własne na podstawie danych z GOV.UK, pozyskanych 03.02.2025 z <https://www.gov.uk/government/statistics/individual-insolvencies-december-2024>.

1.3.3. Niemcy

W Niemczech, przepisy dotyczące upadłości konsumenckiej zostały wprowadzone w ramach Ordynacji o niewypłacalności (Insolvenzordnung, w skrócie InsO) w 1999 roku. Głównym celem upadłości konsumenckiej jest zaspokojenie wierzycieli, jednocześnie dając dłużnikowi możliwość wyjścia z sytuacji niewypłacalności. Reforma prawa upadłościowego w 1999 roku wprowadziła możliwość umorzenia długów w przypadku utrzymania dobrego zachowania przez okres 6 lat. Kolejna nowelizacja miała miejsce 1 grudnia 2001 r., wprowadziła uproszczenia w postaci jednolitych formularzy oraz dostępność informacji w Internecie, co zwiększa przejrzystość oraz umożliwia kontrolę ze strony pozostałych wierzycieli (Szpringer i Szpringer, 2004). Ustawa o upadłości konsumenckiej obejmuje osoby fizyczne, wolne zawody oraz drobnych przedsiębiorców. Procedura upadłości konsumenckiej jest kierowana do niewypłacalnych konsumentów. Stopniowo, poprzez kolejne nowelizacje, grupa osób fizycznych objętych upadłością konsumencką została rozszerzona. Początkowo obejmowała ona jedynie osoby nieprowadzące jednoosobowej działalności gospodarczej, a następnie została poszerzona o małe firmy oraz osoby samodzielnie wykonujące zawód (w przypadku tych grup jest dostępna wyłącznie procedura sądowa, bez procedury pozasądowej) (Szpringer i Szpringer, 2004). System upadłości konsumenckiej w Niemczech od 1999 roku ma strukturę zawierającą cztery kroki (Heuer, 2020):

- obowiązkowa próba pozasądowego uregulowania długu, podczas, której dłużnik wspierany przez doradcę ds. zadłużenia lub prawnika przedstawia propozycję spłaty (wymaga zgody wszystkich wierzycieli),
- po złożeniu wniosku o upadłość próba uregulowania długu w sądzie (nie wszyscy wierzyciele muszą się zgodzić),
- uproszczone postępowanie upadłościowe, w którym aktywa dłużnika są likwidowane i rozdzielane,
- postępowanie o umorzenie długu, w którym zazwyczaj przez 6 lat dochody są przez syndyka rozdzielane.


Jeżeli większość wierzycieli zaakceptuje plan spłaty, a suma ich roszczeń przekroczy 50% całkowitej kwoty zadłużenia, sąd może zatwierdzić plan (Hetes-Gavra i in., 2016). Istnieją jednak sytuacje wyjątkowe, w których wierzyciel, zgłaszając sprzeciw, nie otrzymał uczciwej części w porównaniu do innych wierzycieli lub wprowadzenie planu spłaty będzie skutkowało niekorzystną sytuacją ekonomiczną wierzyciela w porównaniu z postępowaniem upadłościowym (Hetes-Gavra i in., 2016). Od 2014 roku istnieje możliwość umorzenia długu

nawet po upływie trzech lat, jeśli pożyczkobiorca ureguluje co najmniej 35% swojego zadłużenia (Hetes-Gavra i in., 2016). Możliwość ta została wprowadzona w celu motywowania dłużników do spłaty zobowiązań oraz ochrony interesów wierzycieli. Sąd na każdym etapie postępowania może zarządzić zakaz sprzedaży składników majątkowych czy też ze względu na złą sytuację dłużnika przejść do etapu oddłużenia konsumenta (Szpringer i Szpringer, 2004).

Wprowadzenie pozasądowych negocjacji między dłużnikiem a wierzycielami miało na celu minimalizację spraw, które trafiają do sądów. Niestety, takie oczekiwania nie spełniły się, a liczba zakończonych spraw pozasądowych pozostaje niewielka. Celem wprowadzenia pozasądowych negocjacji było proporcjonalne zaspokojenie roszczeń wierzycieli poprzez podział majątku dłużnika, samodzielność finansową dłużnika oraz możliwość rehabilitacji przez dłużnika (Szpringer i Szpringer, 2004). Autorzy wskazują również elementy, które mogą się przyczyniać do tak małej liczby zakończonych spraw: brak zdefiniowanych podmiotów, które powinny merytorycznie wspierać dłużnika, brak jednolitego zakresu danych w planie sanacyjnym co może powodować niekompletność w obszarze zobowiązań oraz składników majątkowych. W październiku 2020 r. wprowadzono nowe przepisy, które skróciły procedurę upadłości konsumenckiej z sześciu lat do trzech lat (Destatis, 2025c). Umożliwiło to szybszy start finansowy konsumentom po zakończeniu postępowania.

W Niemczech w latach 2010-2020 zaobserwowano spadek liczby upadłości konsumenckich. W 2010 roku upadłość konsumencką ogłosiło 108 798 konsumentów, natomiast w 2020 roku - 41 753. W 2024 roku liczba ta wzrosła do 71 207 (wykres 10). Znaczny wzrost liczby upadłości konsumenckich nastąpił od początku 2021 roku, co było związane z wejściem w życie skróconej procedury upadłościowej w październiku 2020 roku.

Wykres 10. Upadłości konsumenckie w Niemczech w latach 2010-2024



Źródło: opracowanie własne na podstawie danych z Destatis, pozyskanych 02.02.2025 ze stron <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Einkommen-Konsum->


Lebensbedingungen/Vermoege-Schulden/Tabellen/verbraucherinsolvenzen-jahren.html oraz <https://www.destatis.de/EN/Themes/Society-Environment/Population/Current-Population/Tables/population-by-territory-and-average-age-basis-2022.html>.

1.3.4. Irlandia Północna

W Irlandii Północnej upadłość konsumencka jest uregulowana przez ustawę Insolvency (Northern Ireland) Order 1989, która stanowi podstawę prawną dla postępowań upadłościowych wobec osób fizycznych (Hrycaj i Michalska, 2018). Tak jak w przypadku prawa upadłościowego w Anglii i Walii, w Irlandii Północnej jest kilka alternatyw dla upadłości konsumenckiej. Oprócz nieformalnych porozumień z wierzycielami istnieje Indywidualne Dobrowolne Porozumienie (ang. Individual Voluntary Arrangements), w którym doradca pomaga negocjować warunki spłaty zadłużenia. Jest to umowa z wierzycielami o spłacie w całości lub części zadłużenia. Płatności są regulowane do autoryzowanego specjalisty ds. długów, a następnie są dzielone pomiędzy wierzycieli zgodnie z umową. Występuje również uproszczona procedura w postaci Nakazu Umorzenia Długu (ang. Debt Relief Order) dla konsumentów, których długi nie są wyższe niż 20 000 GBP. Nakaz Umorzenia Długu jest formalnym procesem dla niewypłacalnych konsumentów, którzy nie posiadają aktywów oraz posiadają niski dochód. Procedura ta jest skierowana do konsumentów bez dostępu do innych opcji i bez perspektyw na poprawę sytuacji. Kolejną alternatywą jest Nakaz Administracyjny, w którym spłata długów jest dystrybuowana przez sąd.

W Irlandii Północnej zaobserwowano systematyczny spadek liczby upadłości konsumenckich w latach 2010-2024. Najwięcej upadłości ogłoszono w latach 2013 i 2014, natomiast najmniej w roku 2024. Na wykresie 11 przedstawiono zarówno liczbę upadłości konsumenckich w Irlandii Północnej w latach 2010-2024, jak i procentowy udział ludności ogłaszającej upadłość konsumencką.


Wykres 11. Upadłości konsumenckie w Irlandii Północnej w latach 2010-2024



Źródło: opracowanie własne na podstawie danych z GOV.UK, pozyskanych 03.02.2025 z <https://www.gov.uk/government/statistics/individual-insolvencies-december-2024> oraz NISRA.GOV.UK, pozyskanych 03.02.2025 z <https://www.nisra.gov.uk/publications/2022-based-population-projections-northern-ireland-statistical-bulletin-charts>.

Na wykresie 12 przedstawiono udział upadłości konsumenckich, Indywidualnych Porozumień Dobrowolnych oraz Nakazów Umorzenia Długu w łącznej liczbie indywidualnych postępowań upadłościowych w Irlandii Północnej w latach 2010-2024. W analizowanym okresie obserwuje się spadek udziału upadłości konsumenckich oraz wyraźny wzrost znaczenia Indywidualnych Porozumień Dobrowolnych w strukturze postępowań upadłościowych.

Wykres 12. Udział upadłości konsumenckiej, Indywidualnego Porozumienia Dobrowolnego oraz Nakazu Umorzenia Długu w łącznej liczbie indywidualnych postępowań upadłościowych w Irlandii Północnej w latach 2010-2024



Źródło: opracowanie własne na podstawie danych z GOV.UK, pozyskanych 03.02.2025 z <https://www.gov.uk/government/statistics/individual-insolvencies-december-2024>.

Procedura upadłości konsumenckiej w Irlandii Północnej zazwyczaj trwa rok i pod koniec tego okresu większość długów zostaje spłacona. Majątek niebędący niezbędnym do codziennego funkcjonowania (w tym posiadane nieruchomości i inne składniki mienia) oraz nadwyżka dochodu mogą być wykorzystywane do spłacenia wierzycieli. Po zakończeniu postępowania upadłościowego większość zadłużenia ulega umorzeniu. W niektórych sytuacjach dłużnik może zostać zobowiązany do zawarcia umowy o dokonywanie wpłat z dochodu, na podstawie której przez okres 3 lat zobowiązuje się do regularnych spłat na rzecz wierzycieli. Pod koniec upadłości większość długów jest anulowana. Wniosek o upadłość konsumencką może zostać złożony przez przynajmniej jednego wierzyciela, dłużnika lub osobę objętą indywidualnym układem dobrowolnym. W przeciwieństwie do Anglii i Walii, w Irlandii Północnej nie ma możliwości złożenia wniosku o upadłość konsumencką online. Koszt związany z wnioskowaniem o upadłość konsumencką wynosi 683 GBP i składa się z opłaty dla syndyka, opłaty sądowej i notarialnej. Wierzyciele mogą zawnioskować o upadłość, jeżeli dłużnik ma zadłużenie powyżej 5000 GBP niezabezpieczonego długu.

1.4. Przegląd przyczyn upadłości konsumenckiej

Przyczyny upadłości konsumenckiej oraz ich klasyfikacja są zbliżone, niezależnie od kraju. Choć procedury prawne mogą się różnić w zależności od systemu prawnego danego państwa, to ogólny schemat prowadzący do niewypłacalności pozostaje zbliżony. W różnych

krajach dłużnicy zmagają się z podobnymi wyzwaniami, a mechanizmy prawne mają na celu uporządkowanie sytuacji finansowej i w wielu przypadkach umożliwienie nowego startu. Mimo lokalnych różnic w regulacjach, podstawowe czynniki, które prowadzą do niewypłacalności oraz sposoby ich klasyfikacji wykazują uniwersalność.

Przyczyny niewypłacalności konsumentów mogą być zarówno niezależne od konsumenta np. bezrobocie, rozwód, choroba, jak i zależne, np. złe zarządzanie finansami gospodarstwa domowego, przeszacowanie swoich możliwości finansowych i kredytowych, oraz zbyt duże pragnienie posiadania dobrobytu materialnego i finansowanie go kredytami (Huls, 1997). Przyczyny te mogą mieć charakter społeczny, polityczno-gospodarczy, strukturalny czy technologiczny (Wolska-Bagińska, 2018). Wolska-Bagińska (2018) zwróciła również uwagę na takie determinanty, jak nadmierna koncentracja w kreowaniu potrzeb, co w konsekwencji prowadzi do zwiększenia poziomu zadłużenia poprzez nowe zobowiązania kredytowe czy też nieracjonalne korzystanie z karty kredytowej. Świecka (2008) dokonała klasyfikacji kryteriów podziału przyczyn bankructw gospodarstw domowych na:


- kryterium klasyczne (przyczyny egzogeniczne i endogeniczne),
- kryterium miejsca (przyczyny makroekonomiczne i mikroekonomiczne),
- kryterium czasu (przyczyny krótkookresowe i długookresowe),
- kryterium zależności (przyczyny niezależne i zależne od gospodarstw domowych),
- kryterium obiektywności (przyczyny obiektywne i subiektywne),
- kryterium ekonomiczne (przyczyny ekonomiczne i pozaekonomiczne).

Jednak jednym z głównych kryteriów, które klasyfikuje przyczyny bankructwa gospodarstwa domowego, jest podział na czynniki mikroekonomiczne oraz makroekonomiczne (Świecka, 2008). Czynniki makroekonomiczne uwzględniają stopy procentowe, kursy wymiany walut, tempo wzrostu PKB, stopę bezrobocia, stopę inflacji oraz rynek nieruchomości (Korol, 2021a; Bauchet i Evans, 2019; Dawsey, 2014). Wzrost stóp procentowych w przypadku kredytów lub kart kredytowych zwiększa miesięczne obciążenie gospodarstw domowych (Ellis, 1998). Ponadto Gross i Souleles (2002) wskazują, że wyższe bezrobocie i niższe ceny nieruchomości wiążą się z większą liczbą upadłości. Wynika to z faktu, że rosnące bezrobocie sprawia, że pożyczkobiorcy nie są w stanie spłacić swoich zobowiązań. Inny istotny czynnik to kurs wymiany walut, który może bezpośrednio wpływać na gospodarstwo domowe poprzez kredyty w obcej walucie lub pośrednio poprzez wzrost cen importowanych towarów, takich jak gaz.

Do czynników mikroekonomicznych należą przyczyny wynikające z błędów związanych z zarządzaniem budżetem domowym (nadmierna konsumpcja kosztem oszczędzania), niewystarczająca wiedza z zakresu finansów i bankowości prowadząca do nadmiernego zadłużenia oraz korzystania z droższych produktów finansowych, błędne decyzje finansowe, a także sytuacje takie jak utrata pracy, choroba czy śmierć członka gospodarstwa domowego (Świecka, 2008). Ponadto, Świecka (2008) w czynnikach pozaekonomicznych wyróżniła czynniki geograficzne, demograficzne, społeczno-ekonomiczne oraz behawioralne. Korol natomiast (2021a) podzielił przyczyny upadłości konsumenckiej na dwie główne grupy:

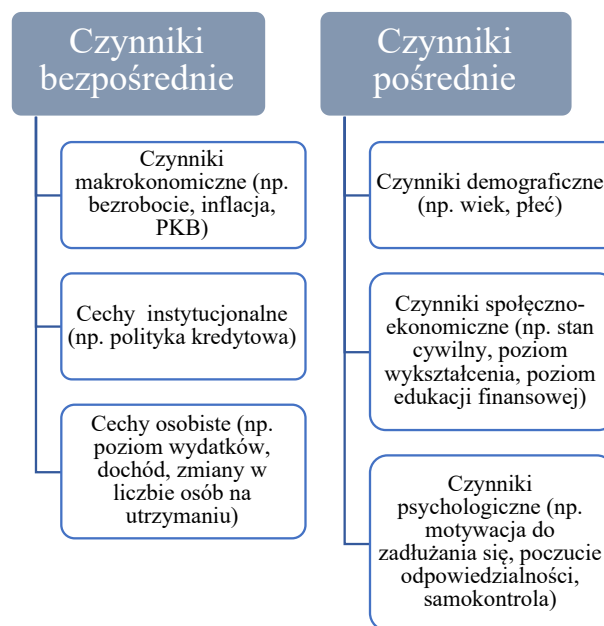
- egzogeniczne, wpływające na gospodarstwa domowe w danym państwie (np. poziom bezrobocia, inflacja, stopy procentowe, kurs walut, PKB),
- endogeniczne, które są kształtowane przez same gospodarstwa domowe:
 - mikroekonomiczne (poziom wykształcenia, stan cywilny, płeć, poziom dochodów, długość zatrudnienia, zadłużenie),
 - społeczne (stan zdrowia, świadomość finansowa, wyznanie religijne, samokontrola).

W tym podziale, czynniki społeczne nakładają się na czynniki mikroekonomiczne oraz makroekonomiczne ze względu na istniejące między nimi zależności. Podział został przedstawiony na rysunku 6.



Rysunek 6. Podział przyczyn upadłości konsumenckiej
Źródło: opracowanie własne na podstawie Korol (2021).

Jureviciene i in. (2016) dokonali podziału przyczyn niewypłacalności, która mogą prowadzić do upadłości na czynniki bezpośrednie oraz pośrednie. Wśród czynników bezpośrednich są: czynniki makroekonomiczne (np. bezrobocie, inflacja, PKB), cechy instytucjonalne takie jak polityka kredytowa oraz cechy osobiste (np. poziom wydatków, dochód, zmiany w liczbie osób na utrzymaniu). Wśród czynników pośrednich prowadzących do niewypłacalności oraz upadłości są czynniki demograficzne (np. wiek, płeć), czynniki społeczno-ekonomiczne (np. stan cywilny, poziom wykształcenia, poziom edukacji finansowej) oraz czynniki psychologiczne (np. motywacja do zadłużania, samokontrola). Podział ten został przedstawiony na rysunku 7.



Rysunek 7. Klasyfikacja czynników ryzyka niewypłacalności w kontekście upadłości konsumentkiej

Źródło: opracowanie własne na podstawie Jureviciene i in. (2016).

Świecka (2008) analizując przyczyny upadłości, zwróciła również uwagę na zależności między poziomem zadłużenia a dochodem, co może być zobrazowane zarówno przy użyciu teorii cyklu życia, jak i teorii permanentnego dochodu. Teoria cyklu życia, zaproponowana przez Franco Modiglianiego, Richarda Bromberga i Alberta Ando, jest zbliżona do teorii permanentnego dochodu Milтона Friedmana (Begg i in., 2007). Możliwa jest również adaptacja tych teorii do określenia niezdolności do spłaty zadłużenia (Świecka, 2008). Według teorii cyklu życia Modiglianiego, ludzie starają się utrzymać stały poziom konsumpcji przez całe życie. W początkowych latach cyklu życia, gdy dochody są niskie, gospodarstwa domowe zaciągają pożyczki, a następnie starają się spłacić zobowiązania i oszczędzić na późniejsze lata (Begg i in., 2007). Motywacją do oszczędzania jest gromadzenie zasobów na późniejsze

wydatki, zwłaszcza na emeryturę (Jappelli i Modigliani, 1998). Świecka (2008) zauważyła, że w teorii cyklu życia stopa oszczędzania kształtuje się pod wpływem czynników demograficznych, takich jak wiek oraz pragnienia utrzymania stabilnego poziomu konsumpcji przez całe życie. Dochód i konsumpcja podlegają zarówno losowym wstrząsom, jak i systematycznym zmianom wynikającym z cyklu życia obejmującego fazy przedpracującą, pracującą oraz emerytalną (Modigliani, 1993). Dlatego hipoteza ta pozwala badać konsekwencje zarówno losowych wstrząsów, jak i systematycznych zmian cyklu życia w kontekście oszczędzania i akumulacji bogactwa (Modigliani, 1993). Wałęga (2010) zauważył, że w początkowym okresie gospodarstwa domowe mogą wydawać więcej niż mają dochodów bieżących ze względu na koszty związane z edukacją czy zakupem nieruchomości. Jednak dostępność kredytów pozwala im unikać znacznego ograniczenia konsumpcji.

Friedman argumentował stworzenie pojęcia dochodu permanentnego, twierdząc, że poziom konsumpcji zależy nie od bieżącego dochodu rozporządzalnego, lecz od dochodu permanentnego (Begg i in., 2007). Teoria dochodu permanentnego miała swoje źródło w dwóch kluczowych elementach: zmienności dochodów jednostek w czasie oraz niechęci konsumentów do fluktuacji w poziomie konsumpcji (Begg i in., 2007). Decydując o poziomie konsumpcji, konsumenci w dużej mierze opierają się na perspektywach dochodowych w długim okresie (Samuelson i Nordhaus, 2003). Świecka (2008) zwróciła uwagę, że zadłużenie gospodarstw domowych nie jest uzależnione od wysokości bieżącego dochodu, lecz od tempa wzrostu dochodu, co ulega zmianom w cyklu życia. Zgodnie z modelem, gospodarstwa domowe zaciągają kredyty, aby zrównoważyć różnicę pomiędzy dochodem permanentnym a dochodem bieżącym (Wałęga, 2010). Im większa jest ta różnica, tym więcej gospodarstwo domowe decyduje się na zaciąganie kredytów (Park i Rodrigues, 2000). Jednak wzrost aktualnego dochodu, przy stałym poziomie dochodu permanentnego, zmniejsza skłonność gospodarstw domowych do sięgania po kredyty (Wałęga, 2010).

2. Metodologia badań nad prognozowaniem ryzyka upadłości konsumentkiej

2.1. Przygotowanie danych do analizy i modelowania

Tworzenie modeli predykcyjnych to proces wieloetapowy. Zazwyczaj obejmuje następujące etapy: zdefiniowanie problemu biznesowego wraz z określeniem kryteriów sukcesu, zebranie danych, przygotowanie danych (analiza eksploracyjna, przetwarzanie danych, wybór i inżynieria zmiennych), budowę modelu (nauka, ocena i interpretacja modelu), wdrożenie modelu oraz monitorowanie jego działania (Wujek i in., 2016; Baier i in., 2019; Halibas i in., 2019; Mai i in., 2019; Zhu i in., 2023; Mumuni i Mumuni, 2024; Databricks, 2024).

Po zdefiniowaniu problemu biznesowego oraz kryteriów sukcesu modelu następuje proces przygotowania danych. Dane surowe (ang. raw data), które nie zostały poddane żadnej obróbce, analizie czy transformacji mogą być niekompletne, zawierać szumy oraz wartości odstające. Wykorzystanie ich w procesie modelowania może prowadzić do niższej skuteczności oraz niestabilności modeli. Może również skutkować błędną interpretacją modeli ze względu na przypisywanie zbyt dużej wagi wybranym zmiennym. Ponadto, niektóre algorytmy uczenia maszynowego nie są wystarczająco zaawansowane, aby wydobyć niezbędne informacje z surowych danych (Halibas i in., 2019). Zanim dane surowe zostaną wykorzystane do budowy modeli predykcyjnych, powinny przejść proces wstępnej obróbki danych (ang. data preprocessing).

Kolejnym ważnym etapem jest wstępna analiza danych, na przykład poprzez wykorzystanie eksploracyjnej analizy danych (EDA). Pozwala to zrozumieć problem biznesowy oraz zależności istniejące w zbiorze danych. Wykorzystuje statystykę opisową oraz wizualizację danych, aby lepiej poznać dane (Camizuli i Carranza, 2018). Umożliwia opisanie kluczowych cech każdej zmiennej (np. wartości minimalnej, maksymalnej, średniej oraz odchylenia standardowego), przedstawienie rozkładu wartości, sprawdzenie zależności między zmiennymi, identyfikację brakujących danych oraz wartości odstających. Wyniki EDA są następnie wykorzystywane we wstępnym przetwarzaniu danych, które stanowi kolejny krok w procesie modelowania.

Wstępne przetwarzanie danych jest uważane za jeden z najważniejszych kroków w uczeniu maszynowym (García i in., 2015). Jest to etap, który zajmuje znaczną część czasu w procesie uczenia maszynowego. Przetwarzanie danych obejmuje kilka procesów, między innymi: czyszczenie danych, normalizację, transformację, ekstrakcję zmiennych oraz ich

selekcję (Kotsiantis i in., 2006). Efektem końcowym przetwarzania danych jest ostateczny zestaw treningowy (Kotsiantis i in., 2006). W związku z tym jest to metoda, która przetwarza surowe dane tak, aby doprowadzić je do etapu, w którym będą użyteczne i przyczynią się do osiągnięcia jak najwyższej skuteczności modelu.

Podczas etapu przygotowywania danych warto również zwrócić uwagę na brakujące dane oraz wartości odstające. Istnieje wiele metod wykorzystywanych w radzeniu sobie z brakującymi danymi, na przykład usunięcie brakujących wierszy lub zmiennych z dużym udziałem brakujących wartości, zastąpienie brakujących danych stałą (np. zerem, średnią, medianą), imputacja metodą k-NN (ang. k-NN imputation), wielokrotna imputacja (ang. multiple imputation), sieci generatywne GAN lub zakodowanie jako osobna kategoria (Nkambule i in., 2024). W metodzie K-najbliższych sąsiadów (k-NN) brakujące wartości są zastępowane na podstawie wartości obserwacji znajdujących się najbliżej w przestrzeni cech (Nishanth i Ravi, 2013). Wielokrotna imputacja polega na estymacji dowolnej zmiennej na podstawie dostępnych danych z pozostałych zmiennych (Wayman, 2003). Uzyskane predykcje – imputacje zastępują brakujące dane. Natomiast imputacja danych za pomocą sieci generatywnych GAN polega na uzupełnieniu brakujących danych przez wygenerowanie realistycznych próbek na podstawie wzorców wyuczonych z dostępnych danych przez współdziałające sieci: generatora i dyskryminatora (Nkambule i in., 2024).

Wśród najpopularniejszych metod radzących sobie z wartościami odstającymi są: usunięcie rekordów z wartościami odstającymi, winsoryzacja, transformacja danych (np. logarytmiczna). Winsoryzacja polega na zastąpieniu skrajnych wartości danymi z najbliższego otoczenia, co pozwala ograniczyć wpływ wartości odstających na model, bez ich usuwania oraz bez konieczności stosowania skomplikowanych procedur przetwarzania (Sharma i Chatterjee, 2021). Większość algorytmów nie wykazuje odporności na wartości odstające w danych, dlatego powinny być one odpowiednio przetworzone, aby nie zniekształcały wyników modelu (Arora i Saurabh, 2022). Przykładem algorytmu wrażliwego na wartości odstające jest regresja logistyczna (Arora i Saurabh, 2022). Wartości odstające mogą występować w surowych danych lub powstawać na etapie tworzenia zmiennych. Son i in. (2019) zaobserwowali w swoich badaniach, że prawie każda wartość odstająca wynikała z dzielenia przez zero, co może występować podczas obliczania wskaźników finansowych.

Normalizacja i standaryzacja to powszechnie stosowane techniki wstępnego przetwarzania danych, które nadają zmiennym wspólną skalę, nie tracąc przy tym informacji. Normalizacja to transformacja, która skaluje cechy w dół, ponieważ mogą występować duże różnice pomiędzy wartościami maksymalnymi a minimalnymi w obrębie zmiennej (Kotsiantis

i in. 2006). Normalizacja powoduje, że wartości są przekształcane do mniejszych wartości. Jest ona istotnym elementem w przypadku algorytmów, takich jak sieci neuronowe oraz k-najbliższych sąsiadów (Kotsiantis i in. 2006). Stosuje się ją, aby uniknąć dominacji zmiennych o większych zakresach numerycznych nad wartościami o mniejszych zakresach. Dane mogą być znormalizowane poprzez skalowanie ich do przedziału $[0,1]$ lub $[-1,1]$ (Chen i in., 2011). Natomiast w przypadku standaryzacji przekształcone wartości zmiennej mają średnią równą 0 i odchylenie standardowe równe 1 (Chen i in., 2023).

Konwersja danych kategorycznych na format numeryczny jest kluczowa dla większości algorytmów w uczeniu maszynowym. Wśród popularnych technik stosowanych do kodowania zmiennych kategorycznych są: One-Hot Encoding, Ordinal Encoding, Label Encoding, Target Encoding oraz Embedding. One-Hot Encoding tworzy nowe zmienne binarne dla każdej unikalnej wartości. Jest to najczęściej wykorzystywana metoda do radzenia sobie ze zmiennymi kategorycznymi. Ordinal Encoding przypisuje każdej kategorii unikalną liczbę, zakładając porządek między wartościami. W tym przypadku nowa kolumna nie jest dodawana do danych (Potdar i in., 2017). Technika ta jest warta rozważenia w szczególności, gdy występuje porządek pomiędzy kategoriami. Podobną techniką jest Label Encoding, która również przypisuje każdej kategorii unikalną liczbę jednak nie zakłada porządku pomiędzy wartościami. Target Encoding koduje kategorie na podstawie średniej wartości zmiennej docelowej (targetu) dla każdej z kategorii (Dahouda i Joe, 2021). W tej technice jest wykorzystana bayesowska metoda kodowania (Dahouda i Joe, 2021). Kolejną techniką jest wykorzystanie embeddingu, który reprezentuje kategorie jako wektory w przestrzeni o niższym wymiarze. Dahouda i Joe (2021) zwrócili uwagę, że zastosowanie techniki embeddingu zużywa mniej pamięci, generuje mniej cech niż One-Hot Encoding oraz prowadzi do wyższej skuteczności modelu w porównaniu do metody One-Hot Encoding.

Przewidywanie rzadkich zdarzeń, takich jak upadłość i niewypłacalność konsumentów, wiąże się z posiadaniem niezrównoważonych danych. Dlatego konieczne jest zwrócenie uwagi na przygotowanie danych, aby posiadanie niezrównoważonych danych nie skutkowało błędnymi przewidywaniami. Wśród najczęściej stosowanych technik równoważenia klas są: oversampling (zwiększenie liczby przykładów w klasie mniejszościowej), undersampling (zmniejszenie liczby przykładów w klasie większościowej), class weighting (przypisanie większej wagi dla przykładów klasy mniejszościowej), algorytmy radzące sobie z niezbilansowanymi danymi (np. Balanced Random Forest, BalancedBaggingClassifier), metody hybrydowe łączące undersampling z oversamplingiem oraz metody zespołowe (np. EasyEnsemble, BalanceCascade). Konsekwencją niezrównoważonych danych może być niska

predykcja klasy mniejszościowej, ponieważ model może zignorować tę klasę i sklasyfikować osoby niewypłacalne jako osoby, które nie posiadają problemów ze spłatą zobowiązań (Akosa, 2017). Veganzones i Séverin (2018) przedstawili wyniki pokazujące, że nierównoważone dane, w których klasa mniejszościowa stanowi 20% lub mniej, znacząco obniżają skuteczność modeli predykcyjnych. Zhou (2013) wskazał, że metoda próbkowania przy tworzeniu modeli predykcyjnych zależy głównie od wielkości klasy mniejszościowej w zbiorze treningowym. Posiadając zbiór danych zawierający setki rekordów w klasie mniejszościowej, metoda undersamplingu jest bardziej efektywna niż metoda oversamplingu, ponieważ wydajność jest podobna, a czas wymagany na zastosowanie metody oversamplingu jest dłuższy (Zhou, 2013). García i in. (2012) zauważyli, że wyniki sugerują, iż zarówno metody oversamplingu, jak i undersamplingu wykazują podobną wydajność dla danych o niskim poziomie nierównowagi. Z kolei Veganzones i Séverin (2018) wskazali, że metoda oversamplingu jest optymalną strategią, ponieważ zapewnia lepszą i bardziej stabilną wydajność w różnych scenariuszach. Przeciwstawia się to metodzie undersamplingu, która, z wyjątkiem zbiorów danych o mniejszych proporcjach nierównowagi i większych zbiorach treningowych, nie jest optymalna (Veganzones i Séverin, 2018). W przypadku znacznie niezrównoważonych danych brak zastosowania metod bilansujących sprawia, że model staje się praktycznie bezużyteczny, ponieważ jest nieskuteczny w przewidywaniu upadłości.

W celu wiarygodnej oceny skuteczności modeli predykcyjnych stosuje się metody podziału danych. Wybór odpowiedniej metody jest kluczowy, w szczególności w przypadku małych i średnich zbiorów danych z niezrównoważonym rozkładem klas, tak jak to często ma miejsce w przypadku oceny ryzyka kredytowego oraz prognozowania upadłości (García i in., 2015). Część zbioru danych jest wykorzystana do nauki modelu, a pozostała część od początku podziału danych jest izolowana do czasu oceny skuteczności modelu. Im większy zbiór uczący, tym lepszy może być klasyfikator, a im większy zbiór testowy, tym dokładniejsza może być ocena skuteczności modelu (García i in., 2015). Metoda podziału danych powinna być dostosowana do posiadanych danych, ponieważ ma to wpływ na poprawność wyników oceny skuteczności modelu (García i in., 2015). Wśród najczęściej spotykanych metod podziału danych jest podział zbioru danych na zbiór uczący i testowy. Model powinien być testowany na danych, które nie były w żaden sposób przekształcone ani używane w procesie jego trenowania, aby wynik na danych testowych odzwierciedlał umiejętności modelu do generalizacji. Model uczony i testowany na jednej próbie może być zbyt dopasowany do posiadanych danych i całkowicie nie sprawdzać się na nowych danych. Dlatego istotne jest, aby niektóre kroki wstępnego przetwarzania danych (np. skalowanie, normalizacja) wykonać

po podziale danych na dane uczące i testowe. Kolejną powszechnie stosowaną praktyką jest podział danych na trzy zbiory: uczący, walidacyjny i testowy (Shin i in., 2005). Zbiór walidacyjny wykorzystywany jest do regulacji hiperparametrów oraz oceny modelu podczas trenowania modelu, aby między innymi zapobiec nadmiernemu dopasowaniu. Zbiór testowy wykorzystywany jest do ostatecznej oceny modelu na danych, których wcześniej model nie widział. Podział danych na trzy zbiory wymaga, aby zbiór danych nie był zbyt mały. Kolejną metodą jest wykorzystanie K-Fold Cross-Validation. Jest to technika wykorzystywana w ocenie modeli uczenia maszynowego. Polega na podziale danych na k podzbiorów, z których każdy przynajmniej raz jest wykorzystywany jako zbiór testowy. W tym samym czasie inne podzbiory są trenowane. W efekcie końcowym model jest testowany na różnych podzbiorach danych niż by był, gdybyśmy podzielili dane na próbę uczącą i testującą. Na koniec wydajność modelu jest oszacowana na podstawie wszystkich prognoz dla zbiorów testowych (García i in., 2015). Technika ta umożliwia maksymalne wykorzystanie posiadanej próby do nauki i walidacji. Podobną techniką do K-Fold Cross-Validation jest Leave-One-Out (LOO). W przypadku tej metody za każdym razem jeden przypadek jest pomijany, a wszystkie inne są włączone do etapu trenowania (García i in., 2015). Metoda ta jest bardziej kosztowna obliczeniowo, w szczególności w przypadku dużych zbiorów danych.

Ustalając podział danych, istotne jest również, w zależności od wybranej metody i strategii, wzięcie pod uwagę różnych proporcji podziału danych np.: 50/50, 80/20, 70/30, a w przypadku podziału zbioru danych na trzy grupy np.: 50/25/25, 60/20/20. Wybór optymalnej konfiguracji ma na celu maksymalizację skuteczności modeli przy jednoczesnej minimalizacji czasu ich budowy. Veganzones i Séverin (2018) zauważyli, że rozmiar zbioru uczącego staje się mniej istotny w miarę powiększania się zbioru danych. Jednak warto pamiętać o tym, że w przypadku małych zbiorów danych podział próby na 50% uczącą i 50% testową może znacząco ograniczyć liczbę obserwacji dostępnych do trenowania modelu (Schonlau i Zou, 2020). W związku z tym, że często posiadane zbiory danych nie są duże, istotne jest znalezienie optymalnego poziomu podziału danych na zbiór uczący i testowy (García i in., 2015).

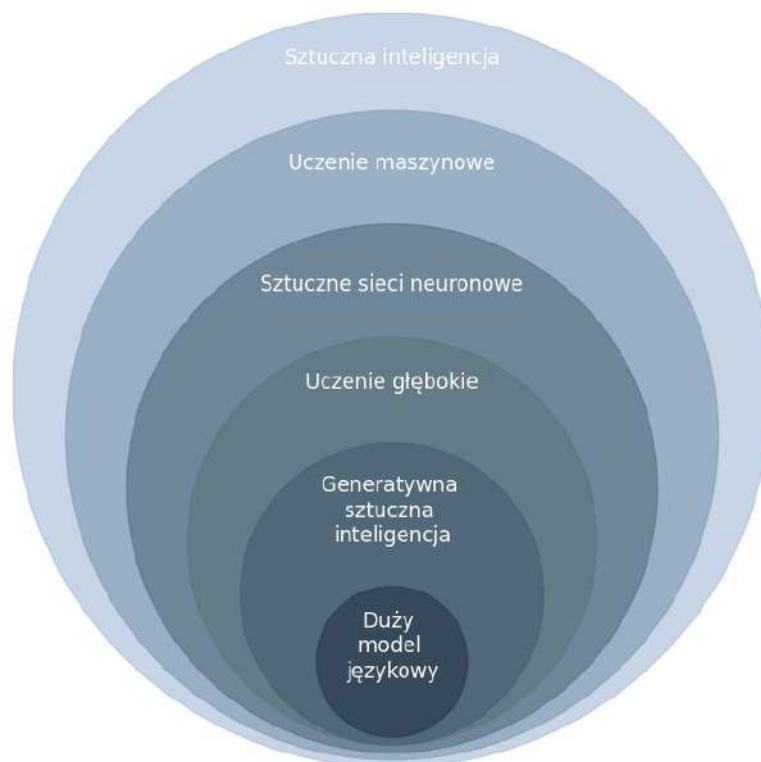
Kolejnym ważnym etapem przygotowującym zbiór danych do etapu tworzenia modelu prognostycznego jest selekcja zmiennych. Polega na wykluczeniu ze zbioru danych zmiennych, które dostarczają niewiele lub żadnych informacji predykcyjnych (Wang i in., 2014). Kotsiantis i in. (2006) scharakteryzowali zmienne jako istotne (mają wpływ na model i nie można zastąpić ich innymi zmiennymi), nieistotne (brak wpływu na model) oraz redundantne (gdy występuje inna zmienna dostarczająca tej samej informacji). Zmniejszanie nieistotnych i redundantnych cech ma na celu zmniejszenie wymiarowości danych oraz zwiększenie skuteczności modeli

przy zachowaniu efektywności obliczeniowej. Wybierane są zmienne, które mają wpływ na zmienną objaśnianą i nie prowadzą do nadmiernego dopasowania modelu (Halibas i in., 2019). Wyeliminowanie zmiennych nieistotnych skraca czas trenowania modelu oraz cyklicznego przeliczania modelu. Ułatwia to wdrożenie modelu oraz jego utrzymanie. Większa liczba zmiennych w modelu może prowadzić do zwiększonej złożoności, co z kolei utrudnia interpretację wyników. Istnieje wiele metod, które można zastosować przy wyborze zmiennych do modelu, np. metody oparte na filtrach (ang. filter methods), metody oparte na wrapperach (ang. wrapper methods) oraz metody oparte na osadzeniach (ang. embedded methods) (Chandrashekar i Sahin, 2014). Metody oparte na filtrach stosują techniki rankingowe jako najważniejsze kryterium wyboru zmiennej (Chandrashekar i Sahin, 2014) i nie wykorzystują algorytmów uczenia maszynowego. Przykładem metody opartej na filtrach jest współczynnik korelacji Pearsona, miara informacji wzajemnej (ang. Mutual Information - MI), wartość informacyjna (ang. Information Value - IV) oraz test t-Studenta (ang. t-test). Współczynnik korelacji mierzy siłę i kierunek związku między dwiema zmiennymi, oceniając ich współzależność (Tsai, 2009). MI wykorzystuje się do oceny siły i rodzaju relacji pomiędzy zmiennymi a zmienną zależną i jest szczególnie pomocna na początku procesu budowy modelu, gdy nie mamy jeszcze wybranego algorytmu (Premalatha i in., 2023). Zaletą tej metody jest łatwość w użyciu oraz interpretacji, odporność na przeuczenie, efektywność obliczeniowa i odporność na wartości odstające (Premalatha i in., 2023). IV mierzy moc predykcyjną zmiennych, im wyższa wartość, tym zmienna ma większą moc predykcyjną (Wang i Brorsson, 2023). Metodę t-Test stosuje się, aby sprawdzić, czy istnieje istotna różnica między średnimi dwóch grup (Tsai, 2009). Metody oparte na wrapperach wykorzystują algorytm uczenia maszynowego. Przykładem jest selekcja w przód (ang. forward selection), selekcja w tył (ang. backward elimination) oraz wykorzystanie algorytmu genetycznego (ang. genetic algorithm) (Chandrashekar i Sahin, 2014). Selekcja w przód polega na stopniowym dodawaniu zmiennych do modelu na podstawie ich największego wpływu na jakość modelu, natomiast selekcja w tył jest procesem odwrotnym. Model jest początkowo budowany na wszystkich zmiennych, a następnie eliminowane są te zmienne, które mają najmniejszy wpływ na jakość modelu. Algorytm genetyczny jest techniką ewolucyjną, która umożliwia wybór optymalnego zestawu zmiennych dla danego algorytmu (Zelenkov i in., 2017). W metodach opartych na osadzeniach selekcja zmiennych jest częścią procesu uczenia modelu (Chandrashekar i Sahin, 2014). Przykładem jest regresja lasso i modele oparte na drzewach decyzyjnych, np. lasy losowe, gradient boosting.

Jedną z metod wykorzystywanych do redukcji wymiarowości danych jest analiza głównych składowych (ang. Principal Component Analysis – PCA). Główną ideą PCA jest redukcja wymiarowości zbioru danych, w którym istnieje wiele powiązanych ze sobą zmiennych (Tsai, 2009). Na podstawie posiadanego zbioru danych jest tworzony nowy zestaw nieskorelowanych oraz uporządkowanych zmiennych, zwanych głównymi składowymi (Tsai, 2009). Składowe są obliczane w taki sposób, aby pierwsza składowa miała największą możliwą wariancję, a kolejne składowe miały największą możliwą wariancję spośród pozostałych (Salekshahrezaee i in., 2023). W przypadku PCA istotne jest, aby zwrócić uwagę na standaryzację zbioru danych oraz usunięcie wartości odstających. Odpowiednie przygotowanie danych stanowi fundament dla budowy modeli predykcyjnych opartych na różnych algorytmach.

2.2. Klasyfikacja modeli prognozowania ryzyka upadłości konsumenckiej

W literaturze przedmiotu, modele sztucznej inteligencji dzielą się na: uczenie maszynowe (ang. machine learning), sztuczne sieci neuronowe (ang. artificial neural network) oraz uczenie głębokie (ang. deep learning) (Janiesch i in. 2021). Podział ten często wzbogaca się również o generatywną sztuczną inteligencję (ang. Generative AI) oraz duże modele językowe (ang. Large Language Models) (Hadid i in. 2024). Powyższa klasyfikacja metod sztucznej inteligencji została przedstawiona na rysunku 8.



Rysunek 8. Klasyfikacja metod z zakresu sztucznej inteligencji

Źródło: opracowanie własne na podstawie Janiesch i in. 2021, Hadid i in. 2024.

Sztuczna inteligencja (ang. Artificial Intelligence - AI) to dziedzina zajmująca się tworzeniem maszyn i systemów, które potrafią realizować zadania wymagające zazwyczaj ludzkiej inteligencji. AI posiada zdolność wykrywania ukrytych wzorców, co wymaga analizy dużych zbiorów danych i badania ich zachowania w różnych warunkach (Letkovský i in., 2024). Termin ten odnosi się do zdolności maszyn do realizacji zadań, które normalnie wymagają ludzkiego umysłu, takich jak rozpoznawanie mowy, interpretowanie języka naturalnego i podejmowanie decyzji (Soori i in., 2023). Sztuczna inteligencja jest szeroką dziedziną, która łączy elementy logiki, statystyki, psychologii poznawczej, teorii decyzji, neuronauki, językoznawstwa, cybernetyki oraz inżynierii komputerowej (Howard, 2019). AI obejmuje zarówno uczenie maszynowe, jak i symboliczną sztuczną inteligencję (Król-Nowak i Kotarba, 2022). W przypadku uczenia maszynowego algorytm, po dostarczeniu danych, sam wyszukuje zestaw reguł. Natomiast w symbolicznej sztucznej inteligencji, to programista opracowuje reguły, jak np. w symulatorach gier w szachy (Król-Nowak i Kotarba, 2022).

W związku z dynamicznym rozwojem sztucznej inteligencji i jej coraz szerszym zastosowaniem, pojawia się konieczność wprowadzenia odpowiednich regulacji prawnych mających na celu ochronę m. in. konsumentów przed nadużyciami oraz dyskryminacją. W Stanach Zjednoczonych zarządzanie AI przyjmuje zdecentralizowaną formę, która jest oparta na regulacjach sektorowych, dobrowolnych zobowiązaniach firm prywatnych oraz wytycznych Białego Domu i federalnych agencji, co odróżnia to podejście od kompleksowych, jednolitych ram prawnych zawartych w unijnym AI Act (Davtyan, 2025). Pomimo, że nie ma ogólnych ram prawnych regulujących kwestię sztucznej inteligencji, w niektórych aktach prawnych pojawiają się rozporządzenia wykonawcze związane z AI (DePaula i in., 2025). Podczas gdy w Stanach Zjednoczonych działania legislacyjne w zakresie AI koncentrują się przede wszystkim na edukacji, badaniach oraz doradztwie, Unia Europejska przyjęła bardziej kompleksowe przepisy nakładające obowiązki i zakazy dotyczące wykorzystania sztucznej inteligencji (Lauser i Hackstandt, 2025). 12 lipca 2024 roku w Dzienniku Urzędowym Komisji Europejskiej zostało opublikowane Rozporządzenie o sztucznej inteligencji - AI Act (Ministerstwo Cyfryzacji, 2024). Celem AI Act jest zagwarantowanie bezpiecznego i etycznego stosowania technologii sztucznej inteligencji (Ministerstwo Cyfryzacji, 2024), poprzez zapewnienie ram prawnych, które zwiększą bezpieczeństwo użytkowników i zaufanie do systemów sztucznej inteligencji. AI Act klasyfikuje systemy sztucznej inteligencji według poziomu ryzyka, co determinuje obowiązki i ograniczenia związane z ich stosowaniem. Wyróżnia się następujące poziomy ryzyka: nieakceptowalne (zakazane praktyki), wysokie

ryzyko (systemy dozwolone, ale wymagają spełnienia warunków) oraz niskie i średnie ryzyko. Ponadto, AI Act wprowadza regulacje dotyczące systemów sztucznej inteligencji ogólnego przeznaczenia. Przykładami systemów zakazanych AI, zgodnie z AI Act, są m.in.: wykorzystywanie technik podprogowych lub manipulacyjnych, wykorzystywanie słabości osób wynikających z wieku, niepełnosprawności czy szczególnej sytuacji społecznej lub ekonomicznej, scoring społeczny, rozpoznawanie emocji w miejscu pracy lub kształcenia. Przykłady systemów wysokiego ryzyka, zgodnie z AI Act, które wymagają spełnienia określonych wymogów, obejmują np. systemy AI wykorzystywane do oceny zdolności kredytowej, systemy AI przeznaczone do zdalnej identyfikacji biometrycznej, systemy AI wykorzystywane przy ocenie ryzyka i ustalaniu cen w odniesieniu do osób fizycznych w przypadku ubezpieczenia na życie i ubezpieczenia zdrowotnego. Pełne stosowanie przepisów AI Act rozpocznie się 2 sierpnia 2026 roku. Rozporządzenie dotyczy zarówno użytkowników, jak i dostawców, dystrybutorów i importerów rozwiązań AI.

Uczenie maszynowe (ang. Machine Learning - ML) jest poddziedziną AI, która umożliwia komputerom uczenie się na podstawie danych. Do najpopularniejszych modeli ML należy uczenie nadzorowane (ang. supervised learning), nienadzorowane (ang. unsupervised learning), półnadzorowane (ang. semi-supervised learning) oraz uczenie przez wzmocnienie (ang. reinforcement learning). Uczenie nadzorowane wykorzystuje zbiór treningowy do znajdowania wzorców i dokonywania prognoz. Algorytm uczy się rozpoznawać wzorce i relacje w danych na podstawie zbioru zawierającego zarówno dane wejściowe, jak i poprawnie przypisane etykiety lub wartości. Dzięki temu algorytm może później przewidywać wyniki dla nowych, nieznanych danych. Uczenie nienadzorowane polega na tym, że algorytm pracuje z danymi bez etykiet, a następnie samodzielnie odkrywa ich ukrytą strukturę. Algorytmy nienadzorowane rozpoznają wzorce, wykorzystując dostępne zmienne, identyfikują wewnętrzne grupy i przypisują etykiety poszczególnym punktom danych (Consoli i in., 2021). Przykładem jest segmentacja, gdzie klienci są grupowani na podstawie wspólnych cech. Uczenie półnadzorowane łączy dużą ilość danych bez etykiet z mniejszą ilością danych oznaczonych, co poprawia dokładność klasyfikacji ML i zmniejsza koszty związane z przygotowaniem zbioru danych (Chapelle i in., 2006). Uczenie przez wzmocnienie polega na tworzeniu własnych danych treningowych przez eksperymentowanie i optymalizację wyników podczas dążenia do celu (Howard, 2019).

Algorytmy uczenia maszynowego, dzięki analizie wcześniejszych obliczeń i identyfikacji wzorców w dużych zbiorach danych, umożliwiają podejmowanie wiarygodnych decyzji i są skutecznie wykorzystywane w takich dziedzinach jak wykrywanie oszustw, ocena kredytowa,

analiza ofert, rozpoznawanie mowy i obrazów oraz przetwarzanie języka naturalnego (NPL) (Janiesch i in., 2021). Techniki uczenia maszynowego analizują wzorce w obserwacjach tej samej klasyfikacji i wykrywają cechy, które odróżniają obserwacje różnych grup (Barboza i in. 2017). Wyróżniają się elastycznością i bardzo dobrze radzą sobie z przetwarzaniem dużych zbiorów danych (Brenes i in., 2022). Techniki uczenia maszynowego identyfikują cechy różniące obserwacje między grupami (Barboza i in., 2017). Są wykorzystywane w wielu dziedzinach, takich jak ekonomia, medycyna i inżynieria. Zastosowanie uczenia maszynowego do prognozowania finansowego jest nadal stosunkowo nowym obszarem, ale wartym eksploracji. Przewaga skuteczności bardziej zaawansowanych metod uczenia maszynowego nad klasycznymi algorytmami, takimi jak regresja logistyczna, została potwierdzona w wielu badaniach dotyczących zarówno upadłości przedsiębiorstw, jak i niespłaconych kredytów (Son i in., 2019; Garcia, 2022; Machado i Karray, 2022). Modele uczenia maszynowego i głębokiego uczenia odniosły duży sukces w zastosowaniu w obszarze finansów, z wieloma badaniami skupiającymi się na ich wykorzystaniu do przewidywania upadłości. Zarówno bardziej zaawansowane metody uczenia maszynowego, jak i techniki uczenia głębokiego przewyższają klasyczne metody statystyczne, szczególnie w sytuacjach, gdy liczba zmiennych jest duża, związki między nimi są złożone, zmienne ulegają zmianom w czasie, a istotniejsze jest zrozumienie korelacji między zmiennymi niż szukanie przyczyn (Syam i Sharma, 2018; Shiri i in., 2023). Wśród zalet stosowania uczenia maszynowego i sztucznej inteligencji są ich dynamizm, który pozwala na uruchamianie procesów w tle i podejmowanie decyzji w czasie rzeczywistym (Syam i Sharma, 2018). Aby przezwyciężyć ograniczenia klasycznych metod statystycznych, rozwinięto badania wykorzystujące metody rozpoznawania wzorców w uczeniu maszynowym (Son i in., 2019).

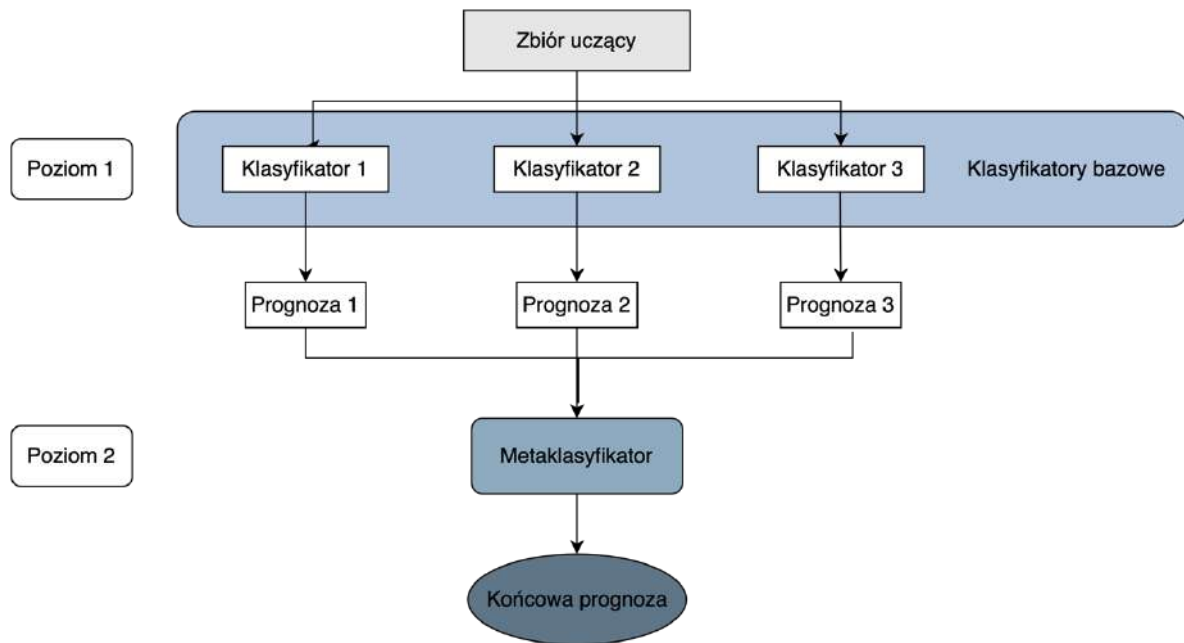
W ramach uczenia maszynowego oprócz klasycznych modeli uczenia maszynowego takich jak wielowymiarowa analiza dyskryminacyjna oraz regresja logistyczna, wyróżnia się metody zespołowe (ang. ensemble methods) (Qu i in., 2019), które polegają na łączeniu wielu modeli bazowych w celu uzyskania bardziej stabilnych i dokładnych predykcji w porównaniu do pojedynczego klasyfikatora. Do najpopularniejszych metod uczenia zespołowego zalicza się bagging, boosting, stacking oraz łączenie wyników klasyfikatorów indywidualnych poprzez metody oparte na głosowaniu (ang. hard voting) i uśrednianiu (ang. soft voting). Ponadto, w literaturze przedmiotu można znaleźć podział metod zespołowych na homogeniczne oraz heterogeniczne (Wang i in., 2025). Metody homogeniczne bazują na połączeniu wielu modeli tego samego typu, najczęściej wytrenowanych na różnych próbach danych (np. bagging), natomiast heterogeniczne łączą modele oparte na różnych algorytmach uczenia maszynowego,

a do ich integracji wykorzystuje się m.in. głosowanie, uśrednianie czy stacking. Klasyfikatory zespołowe budują złożony model składający się z pojedynczych modeli, który może przewyższać klasyfikatory indywidualne poprzez integrację wyników predykcyjnych wszystkich klasyfikatorów (Gu i in., 2021). Metody zespołowe mogą przyczynić się do obniżenia liczby błędnych klasyfikacji w porównaniu do pojedynczych modeli oraz ich połączenie zwiększa odporność algorytmu zespołowego na problemy wynikające ze specyfiki konkretnego zbioru danych (Moreno-Seco i in., 2006).

Bagging jest to technika uczenia maszynowego mająca na celu poprawę dokładności i stabilności algorytmów. Przykładem algorytmu bagging są lasy losowe (Breiman, 2001). Każdy model bazowy jest trenowany niezależnie i równoległe, wykorzystując próbkowanie do tworzenia wielu podzbiorów danych treningowych. Celem baggingu jest redukcja nadmiernego dopasowania modelu do danych treningowych (Barboza i in. 2017).

Kolejną techniką jest boosting, który koncentruje się na tworzeniu silnego modelu poprzez łączenie kilku słabszych modeli. W przeciwieństwie do metod zespołowych takich jak: bagging, głosowanie, uśrednianie, gdzie modele są trenowane równoległe, w metodzie boosting modele są trenowane sekwencyjnie, gdzie każdy kolejny model stara poprawić błędy popełnione przez poprzedni model. Przykładami algorytmu boosting są AdaBoost, XGBoost i LightGBM. Al Daoud (2019) zauważył, że badania wykazały, iż algorytmy gradient boosting są skutecznie stosowane i stanowią bardzo istotną strategię. Carmona i in. (2022) również zaznaczyli, że najnowsze badania wskazują, iż gradient boosting może zniwelować słabe strony tradycyjnych modeli i dostarczyć skutecznego modelu do przewidywania niepowodzeń biznesowych.

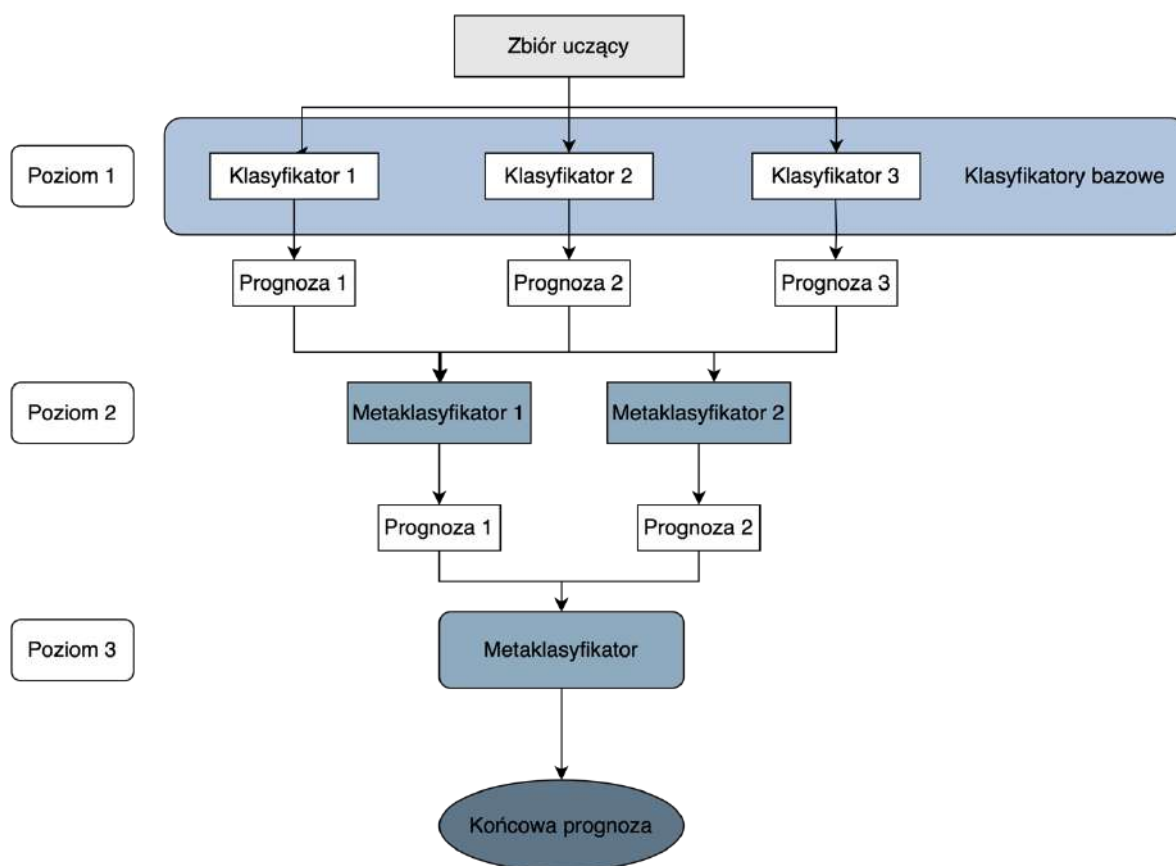
Kolejnym przykładem uczenia zespołowego jest stacking. Jest to technika uczenia maszynowego, której celem jest połączenie wielu modeli w celu poprawy wydajności predykcyjnej poprzez łączenie różnych typów modeli. W podejściu tym, zamiast agregowania wyników klasyfikatorów indywidualnych (klasyfikatorów bazowych) za pomocą technik takich jak głosowanie czy uśrednianie, wykorzystuje się osobny klasyfikator indywidualny (meta-klasyfikator), który przyjmuje prognozy innych klasyfikatorów indywidualnych jako dane wejściowe i dokonuje ostatecznej predykcji. Jest to podejście kombinacyjne, w których klasyfikatory bazowe stanowią pierwszy poziom, a meta-klasyfikator drugi poziom (Pisula, 2017). Przykładowa struktura metody stacking została przedstawiona na rysunku 9.



Rysunek 9. Przykładowa struktura metody stacking

Źródło: opracowanie własne na podstawie Shafieian i Zulkernine (2023).

Klasyczny stacking opiera się na jednym poziomie modeli bazowych, których predykcje są następnie łączone przez metaklasyfikator, aby uzyskać ostateczną prognozę. Metoda ta może być rozszerzona do bardziej złożonej architektury – tzw. wielowarstwowego stackingu (ang. multi-layer stacking), w którym stosuje się kilka poziomów metaklasyfikatorów. W podejściu wielowarstwowym pierwsza warstwa zawiera klasyfikatory bazowe, tak jak w przypadku klasycznego stackingu, z których każdy generuje prognozy na podstawie danych wejściowych. Następnie predykcje z modeli bazowych stają się danymi wejściowymi dla modeli w kolejnej warstwie – pierwszej warstwie metaklasyfikatorów. Każdy z tych modeli przetwarza otrzymane prognozy, generuje dane wyjściowe i przekazuje je do kolejnego etapu. Proces ten może być powtarzany przez kilka warstw, aż do ostatniej, gdzie końcowy metaklasyfikator agreguje predykcje z poprzedniej warstwy, tworząc końcową decyzję modelu zespołowego. Przykładowa struktura wielowarstwowego stackingu została przedstawiona na rysunku 10.

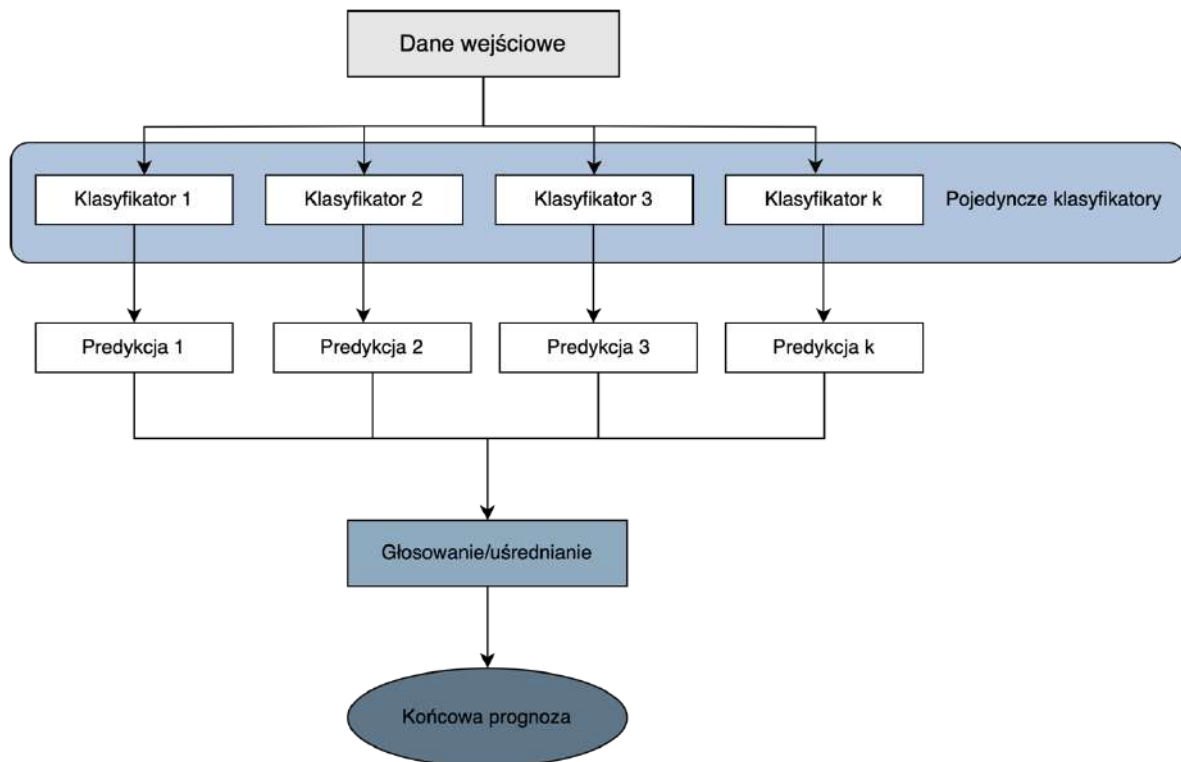


Rysunek 10. Przykładowa struktura metody wielowarstwowego stackingu (ang. multi-layer stacking)

Źródło: opracowanie własne na podstawie Shafieian i Zulkernine (2023).

Kolejną techniką należącą do metod zespołowych jest metoda oparta na głosowaniu (ang. hard voting). Polega ona na łączeniu prognoz generowanych przez wiele modeli indywidualnych. W przypadku klasyfikacji wybierana jest klasa, która uzyskała największą liczbę głosów spośród wszystkich klasyfikatorów indywidualnych. Podobną techniką do głosowania (ang. hard voting) jest metoda uśredniania (ang. soft voting), która różni się sposobem podejmowania decyzji końcowej. Polega ona na tym, że każdy klasyfikator indywidualny zwraca wartość prawdopodobieństwa dla każdej klasy. Następnie prawdopodobieństwa te są sumowane (lub uśredniane) dla każdej klasy, a ostateczna decyzja opiera się na klasie z najwyższym prawdopodobieństwem. W tej metodzie często stosuje się również wagi, które pozwalają uwzględnić jakość poszczególnych modeli nadając wyższą wagę modelom, które mają wyższą skuteczność. Metoda uśredniania może osiągać lepsze wyniki niż metoda głosowania, ponieważ bierze pod uwagę poziom pewności każdego klasyfikatora w decyzji końcowej (Nalić i in., 2020). Metody oparte na głosowaniu i uśrednianiu mają cechy wspólne z metodą bagging, ponieważ polegają na łączeniu wyników wielu algorytmów w celu uzyskania ostatecznej

predykcji. Przykładowa struktura metod bazujących na głosowaniu oraz uśrednianiu zostały przedstawione na rysunku 11.



Rysunek 11. Przykładowa struktura metody głosowania oraz uśredniania

Źródło: opracowanie własne na podstawie Gu i in. (2021) oraz Uddin i in. (2023).

Sztuczne sieci neuronowe (ang. Artificial Neural Networks - ANN) są podzbiorem uczenia maszynowego. Pod pojęciem sztucznych sieci neuronowych rozumie się technikę informatyczną, naśladującą działanie układu nerwowego żywych organizmów (Pociecha 2018). Przypominają one przetwarzanie neuronowe w ludzkim mózgu. ANN składają się z połączonych sztucznych neuronów, ułożonych w warstwy: warstwę wejściową, jedną lub więcej warstw ukrytych oraz warstwę wyjściową. Neurony działają niezależnie i równolegle (Witkowska i in., 2003). Przechowują informacje oraz uczą się istotnych wzorców poprzez wzmacnianie swoich połączeń (Witkowska i in., 2003). Warstwa wejściowa zawiera neurony wejściowe, które przyjmują dane i przekazują je do pierwszej warstwy ukrytej, gdzie odbywają się początkowe obliczenia (Brenes i in., 2022). Warstwy ukryte i wyjściowe zbudowane są natomiast ze sztucznych neuronów (Brenes i in., 2022). Warstwa wyjściowa generuje wynik obliczeń sieci (Korol i Fotiadis, 2022). Sieci neuronowe składają się z węzłów (neuronów) połączonych ze sobą, gdzie wejścia są mnożone przez wagi i przetwarzane za pomocą funkcji matematycznych, które określają aktywację i wyjście neuronu (Barboza i in. 2023). Brenes i in. (2022) zwrócili uwagę na to, że liczba neuronów w warstwie ukrytej nie powinna być

większa niż liczba neuronów wejściowych, ponieważ sieć ze zbyt dużą liczbą połączeń może nadmiernie zapamiętywać dane treningowe, co może prowadzić do problemów z generalizacją. Nie ma uniwersalnej zasady ustalającej optymalną liczbę neuronów w warstwie ukrytej przed przystąpieniem do budowy sieci, co często wymaga eksperymentowania oraz dostosowywania liczby neuronów do badanego zjawiska oraz posiadanych danych (Zhang i in., 1999). Sieci jednokierunkowe mogą być jednowarstwowe (z pojedynczą warstwą neuronów wyjściowych i bez neuronów ukrytych) oraz wielowarstwowe (zawierające co najmniej jedną warstwę ukrytą) (Korol, 2021).

Uczenie głębokie (ang. Deep Learning - DL) jest podzbiorem sieci neuronowych. Głębokie sieci neuronowe zazwyczaj składają się z więcej niż jednej warstwy ukrytej, zorganizowanej w głęboko zagnieżdżonych architekturach sieci (Janiesch i in., 2021). Zawierają zazwyczaj zaawansowane neurony, w przeciwieństwie do prostych sztucznych sieci neuronowych (ANN) (Janiesch i in., 2021). Wśród najpopularniejszych modeli są sieci rekurencyjne (ang. Recurrent Neural Network - RNN) oraz konwolucyjne sieci neuronowe (ang. Convolutional Neural Network - CNN) (Qu i in. 2019). Sieć rekurencyjna wykorzystuje sprzężenie zwrotne tzn. sygnał, który pojawia się na wyjściu, przechodzi ponownie na etap sygnału wejściowego, aż do ustabilizowania sygnałów wyjściowych. Jest zaprojektowana szczególnie dla sekwencyjnych struktur danych, takich jak szeregi czasowe, sekwencje zdarzeń i język naturalny (Janiesch i in. 2021). Przykładami rekurencyjnych sieci neuronowych są prosta rekurencyjna sieć neuronowa (RNN), Long short-term memory (LSTM) oraz Gated Recurrent Unit (GRU) (Shiri i in. 2023). Konwolucyjne sieci neuronowe bardzo dobrze sprawdzają się w przetwarzaniu obrazów oraz rozpoznawaniu mowy (Janiesch i in. 2021). Jest to dobrze znana architektura uczenia, inspirowana naturalnym mechanizmem percepcji wzrokowej żywych stworzeń (Gu i in. 2018). Ich architektura obejmuje kilka etapów, które pozwalają na hierarchiczne uczenie się funkcji dopasowanych do specyfiki zadania modelowania (Janiesch i in. 2021). Zastosowanie CNN w analizach finansowych było rzadkie, ponieważ CNN są bardziej odpowiednie do analizy obrazów, a mniej do przetwarzania danych numerycznych (Hosaka, 2019). Hosaka (2019) wykorzystał jednak CNN w prognozowaniu bankructwa firm, przekształcając wskaźniki finansowe na obraz w odcieniach szarości, który następnie był trenowany oraz testowany przez CNN.

Generatywna sztuczna inteligencja (ang. Generative AI - GenAI) jest podzbiorem uczenia głębokiego. Jest to rodzaj technologii sztucznej inteligencji, która potrafi generować treści, takie jak tekst, obrazy, dźwięk i wideo, na podstawie tego, czego nauczyła się z danych wejściowych. Generatywna sztuczna inteligencja otworzyła nowe możliwości w różnych

dziedzinach. Wykorzystanie GenAI może przyczynić się do poprawy skuteczności i produktywności poprzez automatyzację wielu zadań, które wcześniej były realizowane przez ludzi, takie jak tworzenie treści, obsługa klienta czy generowanie kodu (Feuerriegel i in., 2024). Może mieć istotny wpływ na koszty oraz otworzyć nowe możliwości rozwoju firm (Eloundou i in. 2023). Wśród przykładów dotychczas opracowanych modeli generatywnych są Auto-Encoder, Generative Adversarial Network (GAN), Restricted Boltzmann Machine (RBM), Deep Belief Network (DBN) oraz Self-Organizing Map (SOM) (Shiri i in., 2023).

Ostatnim podzbiorem jest **duży model językowy** (ang. Large Language Model - LLM), który jest podkategorią generatywnej sztucznej inteligencji (Corchado i in., 2023). Jest wykorzystywany między innymi do generowania tekstu przypominającego ludzki język na podstawie wzorców nauczonych z ogromnych ilości danych tekstowych podczas procesu treningowego. ChatGPT jest obecnie jednym z najbardziej znanych przykładów technologii wykorzystujących LLM. Duże modele językowe mogą być również wartościowym narzędziem w rozwoju modeli uczenia maszynowego poprzez pomoc w tworzeniu kodu, generowaniu danych syntetycznych oraz etykietowaniu danych (Eloundou i in., 2023).

2.3. Charakterystyka wybranych metod prognozowania ryzyka upadłości konsumenckiej

2.3.1. Regresja logistyczna

Regresja logistyczna jest klasyczną metodą uczenia maszynowego, która może być wykorzystana do prognozowania upadłości konsumentów. Jest to metoda statystyczna służąca do przewidywania prawdopodobieństwa zajścia określonego zdarzenia kategoriycznego w oparciu o jedną lub więcej zmiennych niezależnych (Islam i in., 2024). Badania wykazały, że modele regresji logistycznej mogą być stosowane do przewidywania upadłości i niespłacania kredytów (Olson i in., 2012; Zhu i in., 2019; Korol, 2021). Modele regresji logistycznej przedstawiają związek pomiędzy binarną zmienną zależną a zmiennymi niezależnymi. Wynikiem funkcji regresji logistycznej jest prawdopodobieństwo zdarzenia. Wartości zmiennej zależnej wskazują na wystąpienie lub też brak wystąpienia zdarzenia, które prognozujemy. W przypadku prognozowania ryzyka upadłości konsumentów tym zdarzeniem będzie przynależność konsumenta do grupy bankrutów lub niebankrutów. Równanie regresji logistycznej można zapisać jako iloraz szans:

$$\frac{\pi}{1-\pi} = \exp(\alpha + \beta_1 X_1 + \dots + \beta_M X_M),$$

co można również przedstawić w następującej postaci (Peng i in., 2002):

$$\text{logit}(Y) = \ln\left(\frac{\pi}{1-\pi}\right) = \alpha + \beta_1 X_1 + \dots + \beta_M X_M,$$

gdzie π jest prawdopodobieństwem zdarzenia, α to punkt przecięcia z osią Y, β to współczynniki regresji i X to zmienne objaśniające. Logit jest więc logarytmem ilorazu szans pojawienia się pewnego zjawiska, np. bankructwa i niebankructwa (Pociecha, 2013). Gdy prawdopodobieństwo obu zdarzeń jest jednakowe, tzn. $p=0,5$, to logit wynosi 0, dla $p>0,5$ logit jest dodatni, a dla $p<0,5$ logit jest ujemny (Pociecha, 2013). Współczynniki modelu są szacowane na podstawie maksymalnego prawdopodobieństwa ze zbioru danych. Do interpretacji modelu logitowego wykorzystywany jest iloraz szans (ang. Odds ratio). Iloraz szans stanowi stosunek prawdopodobieństwa wystąpienia pewnego zdarzenia do prawdopodobieństwa niewystąpienia tego zdarzenia (Ptak-Chmielewska, 2012). Ponadto, wyznaczone w procesie trenowania wagi umożliwiają ocenę istotności poszczególnych cech.


2.3.2. Maszyna wektorów nośnych

Maszyna wektorów nośnych (ang. Support Vector Machine - SVM) to algorytm uczenia maszynowego wykorzystywany zarówno do problemów regresji, jak i klasyfikacji. Algorytm został po raz pierwszy zaproponowany przez Vapnika jako klasę nadzorowanych modeli uczenia maszynowego i był dalej rozwijany wraz z jego zespołem (Boser i in., 1992). Celem SVM jest znalezienie hiperpłaszczyzny, która może podzielić przestrzeń n-wymiarową na klasy. Hiperpłaszczyzna to granica klasyfikacji między dwiema klasami z największym marginesem. Zapewnia separację pomiędzy klasami decyzyjnymi (Min i Lee, 2005). Wektory nośne to punkty danych, które są najbliższej hiperpłaszczyzny i tworzą tę hiperpłaszczyznę. Jest to algorytm wykorzystujący płaszczyzny decyzyjne do wyznaczania granic, które separują obiekty przypisane do różnych klas (Ptak-Chmielewska, 2021). SVM wykorzystuje model liniowy do tworzenia nieliniowych granic decyzyjnych (Min i Lee, 2005). W SVM przyjęcie granicy decyzyjnej z jak najszerzym marginesem między klasami sprzyja zdolności generalizacji model i mniejszej podatności na przeuczenie (Raschka i Mirjalili, 2021). Siłą SVM jest to, że mimo znacznego nakładania się różnych klas danych, znajduje granicę decyzyjną. Model SVM jest wtedy gotowy do klasyfikacji nowych punktów danych po stronie hiperpłaszczyzny, do której powinny być przypisane. Jednak SVM jest bardziej czasochłonny, ma wysoką złożoność algorytmu i wymaga dużej pojemności pamięci (Jabeur i in., 2021). Zhao i in. (2024) zwrócili uwagę na to, że jednymi z najbardziej istotnych zalet SVM są ich zdolność do efektywnego przetwarzania danych o wysokiej wymiarowości oraz umiejętność radzenia sobie z nieliniowymi zależnościami. SVM umożliwia interpretację geometryczną modelu, szczególnie w przypadku danych, które są liniowo separowalne (Shrivastav i Ramudu, 2020).

SVM znajduje zastosowanie, szczególnie wtedy, gdy dane charakteryzują się dużą liczbą zmiennych przy ograniczonej liczbie obserwacji (Shrivastav i Ramudu, 2020).

2.3.3. Drzewo decyzyjne

Kolejną metodą jest drzewo decyzyjne (ang. Decision Tree), zwane również drzewem klasyfikacyjnym (Breimann i in., 1984). Drzewa decyzyjne są jedną z metod wykorzystywanych do przewidywania upadłości (Pompe i Feelders, 1997; Brown i Mues, 2012; Olson i in., 2012; Syed Nor i in., 2019). Jest to metoda predykcyjna powszechnie stosowana w dziedzinie uczenia maszynowego. Model drzewa decyzyjnego zawiera zestaw reguł podziału dużej heterogenicznej grupy na mniejsze, bardziej jednorodne grupy, które są powiązane z określoną zmienną docelową (Syed Nor i in., 2019). Drzewo decyzyjne składa się z korzenia, węzłów, gałęzi oraz liści (rysunek 12). Korzeń jest to jeden z węzłów w strukturze drzewa decyzyjnego, który został wyróżniony. Gałęzie prowadzące pomiędzy węzłami stanowią warianty lub wartości, które odpowiadają atrybutom w węzłach. Liście to z kolei poszczególne podjęte decyzje. Drzewa rosną od góry do dołu, tzn. od korzenia, w którym rozpoczyna się proces podziału danych, aż do liści reprezentujących końcowe decyzje.



Rysunek 12. Przykładowa struktura drzewa decyzyjnego


Źródło: opracowanie własne na podstawie Papana i Spyridou (2020).

Drzewo decyzyjne klasyfikuje elementy danych, sprawdzając odpowiedzi na pytania dotyczące cech. Każde pytanie jest zawarte w węźle, który stanowi poszczególne atrybuty, a każdy węzeł wewnętrzny wskazuje jeden węzeł podrzędny dla każdej możliwej odpowiedzi na swoje pytanie, co tworzy hierarchię podobną do drzewa. Drzewa decyzyjne pozwalają na graficzne przedstawienie decyzji i ich możliwych konsekwencji. Każdy węzeł gałęzi reprezentuje wybór między wieloma alternatywami, a każdy węzeł liścia reprezentuje klasyfikację lub decyzję. Drzewa decyzyjne charakteryzują się hierarchiczną strukturą. Metoda

ta polega na podejmowaniu decyzji dotyczących podziału danego zbioru na podzbiory, co tworzy węzeł. W przypadku braku takiego podziału dane zawarte są w jednej klasie, tworząc tzw. liść. Ta procedura jest powtarzana rekursywnie, dopóki nie będzie możliwe utworzenie węzła, a każda gałąź kończy się liściem. W przypadku drzewa klasyfikacyjnego wyróżniona cecha y jest cechą nominalną, a w przypadku drzew regresyjnych zmienną ciągłą (Pociecha, 2018). Nie ma ograniczeń dotyczących zmiennych zależnych i niezależnych tzn. mogą być zarówno zmienne kategoryczne, jak i liczbowe. Dostępnych jest wiele algorytmów drzewa decyzyjnego, np.: ID3, C4.5, CART, CHAID, QUEST, GUIDE, CRUISE i CTREE (Singh i Gupta, 2014). Jednym z najpopularniejszych algorytmów stosowanych w drzewach decyzyjnych jest CART (ang. Classification and Regression Trees). Drzewa klasyfikacyjne i regresyjne CART mogą być wykorzystywane zarówno do wyboru predyktorów, jak i modeli predykcyjnych (Chen, 2011; Brezigar-Masten i Masten, 2012; Korol, 2013; Podhorska i in., 2020). Algorytm ten wykorzystuje indeks Giniego jako uogólnienie wariancji dwumianowej (Loh, 2011). Algorytm CART w porównaniu do np. algorytmu CHAID i C4.5 nie jest tak podatny na wartości odstające i radzi sobie z nimi (Singh i Gupta, 2014). Słabą stroną algorytmu CART jest to, że niewielka zmiana w próbie uczącej, taka jak np. wyeliminowanie kilku obserwacji, może spowodować zmiany w złożoności drzewa decyzyjnego, wyborze zmiennych oraz ich wartości (Singh i Gupta, 2014).

2.3.4. Las losowy

Jednym ze sposobów poprawy wydajności drzew decyzyjnych jest uwzględnienie jedynie podzbioru obserwacji i budowa wielu drzew decyzyjnych za pomocą algorytmu lasów losowych (ang. random forest). Metoda ta została zaproponowana przez Breimanna (2001). Jest to technika uczenia maszynowego, należąca do grupy metod zespołowych (ang. ensemble methods), a dokładniej do metod typu bagging. Lasy losowe składają się z wielu podzbiorów danych, z których każdy służy do wygenerowania oddzielnego drzewa klasyfikacyjnego (Barboza i in., 2017). Ostateczna decyzja modelu opiera się na agregacji odpowiedzi z poszczególnych drzew (Wu i in., 2016, Schonlau i Zou, 2020). Każde drzewo jest trenowane na innej próbce bootstrap, która powstała poprzez wylosowanie ze zwracaniem N obserwacji ze zbioru uczącego o N elementach. Obserwacje są klasyfikowane przez wiele drzew, a preferowaną klasę określa większość głosów, czyli klasę, na którą wskazała największa liczba drzew w lesie. Tradycyjnie algorytmy lasów losowych są zbudowane na algorytmie CART (Barboza i in., 2017). Przykładową strukturę lasu losowego przedstawiono na rysunku 13.



Rysunek 13. Przykładowa struktura lasu losowego

Źródło: opracowanie własne na podstawie Zhang (2017).

Lasy losowe mogą być używane zarówno jako narzędzie predykcyjne, jak i do wyboru istotnych predyktorów (Probst i in., 2019). Umożliwiają one przygotowanie rankingu cech ze względu na ich istotność. Dla wszystkich cech modelu wyliczana jest punktacja, która reprezentuje istotność każdej cechy. Im wyższy wynik, tym większy wpływ zmiennej na model predykcyjny. W lasach losowych, algorytm losowo wybiera podzbiór zmiennych, spośród wszystkich dostępnych (Kim i in., 2022). Kluczowymi aspektami podczas estymacji modelu lasu losowego są: dobór optymalnej liczby drzew oraz liczby atrybutów, które będą wykorzystywane do wzrostu każdego drzewa (Brown i Mues, 2012). Lasy losowe stanowią wydajny algorytm predykcyjny w przypadku dużych baz danych. Ich wydajność jest silnie uzależniona od wyboru parametrów, takich jak: liczba drzew, maksymalna głębokość drzewa, minimalna liczba próbek w liściu, minimalna liczba próbek do podziału oraz maksymalna liczba zmiennych branych pod uwagę przy podziale.


2.3.5. Adaptive Boosting

AdaBoost (Adaptive Boosting) jest jednym z algorytmów uczenia maszynowego zaproponowanych przez Freunda i Schapire'a (1997). Był pierwszym praktycznym algorytmem boosting (Tunio i in., 2021). Może być stosowany w połączeniu z innymi algorytmami uczenia, aby stworzyć bardziej skuteczny model (Heo i Yang, 2014). Metoda polega na dopasowywaniu sekwencji słabych klasyfikatorów, które są modelami tylko nieznacznie lepszymi od losowego zgadywania, do wielu zmodyfikowanych wersji danych (Barboza i in., 2023). Wykorzystując słabe klasyfikatory, AdaBoost tworzy silniejszy algorytm, wzmacniając działanie klasyfikatorów (Heo i Yang, 2014). Dzięki temu algorytm koncentruje się na najtrudniejszych przykładach ze zbioru uczącego (Alfaro i in., 2008). W algorytmie AdaBoost podejście jest sekwencyjne, a kolejne klasyfikatory są wzajemnie powiązane. W zbiorze przypisywane są wagi, tak aby każdy słaby klasyfikator skupiał się na przykładach błędnie sklasyfikowanych przez poprzednie klasyfikatory (Sun, 2023). Waga błędnie sklasyfikowanych próbek jest

zwiększana, natomiast waga próbek poprawnie sklasyfikowanych jest zmniejszana (Aly i in., 2022). Wagi po każdej iteracji są normalizowane (Alfaro i in., 2008). Gdy wynikowy klasyfikator osiąga wyższą dokładność niż reguła domyślna, oznacza to, że metoda klasyfikacji zidentyfikowała wzorce lub struktury w danych, które pozwalają jej działać skuteczniej (Alfaro i in., 2008). W AdaBoost każdy klasyfikator uzyskuje wynik oparty na wykorzystanym zbiorze treningowym i wnosi swój głos do ostatecznej decyzji przy klasyfikacji nowej obserwacji (Aly i in., 2022). Indywidualne prognozy są następnie łączone z odpowiednimi wagami, tworząc końcową prognozę (Tunio i in., 2021). Uwzględnienie zbyt dużej liczby pojedynczych klasyfikatorów będzie prowadziło do wzrostu błędu generalizacji końcowego klasyfikatora, który można ograniczyć między innymi poprzez zwiększenie rozmiaru zbioru danych treningowych (Alfaro i in., 2008).

2.3.6. Gradient Boosting Classifier

Gradient Boosting Classifier (GBC) jest klasyfikatorem opartym na metodzie boosting, która należy do technik uczenia maszynowego. GradientBoostingClassifier z biblioteki scikit-learn jest przykładem implementacji bazowego algorytmu gradient boosting. Model jest budowany iteracyjnie, a w kolejnych iteracjach algorytm koryguje błędy poprzednich predykcji, stosując odpowiednie wagi (Kozina i in., 2023). Może być stosowany zarówno do klasyfikacji binarnej, jak i wieloklasowej. Poprawia przewidywaną skuteczność poprzez kolejne optymalizacje drzew decyzyjnych. Gradient Boosting może być skłonny do przeuczenia, jeżeli złożoność modelu nie będzie kontrolowana. Jest również algorytmem kosztownym obliczeniowo. Według dokumentacji scikit-learn (2025), w przypadku Gradient Boosting Classifier przy każdym podziale zmienne są losowo przetasowywane. W przypadku małych zbiorów danych Gradient Boosting Classifier może się sprawdzać, ponieważ nie stosuje grupowania zmiennych, co umożliwia dokładniejsze wyznaczanie punktów podziału i lepsze dostosowanie modelu (scikit-learn, 2025). W algorytmie Gradient Boosting Classifier podczas budowy każdego drzewa, w każdym węźle obserwacje są sortowane dla każdej zmiennej, aby efektywnie znaleźć najlepszy punkt podziału (scikit-learn, 2025). Na rysunku 14 przedstawiono przykładową strukturę algorytmu Gradient Boosting Classifier.




Rysunek 14. Przykładowa struktura algorytmu Gradient Boosting Classifier

Źródło: opracowanie własne.

2.3.7. Extreme Gradient Boosting

Extreme Gradient Boosting (XGBoost) to metoda stosowana w regresji oraz klasyfikacji, będąca implementacją algorytmu wzmacniania gradientowego, opracowaną przez Chen i Guestrina (2016). Jest to metoda uczenia maszynowego, należąca do grupy metod zespołowych, a konkretnie technik typu boosting. XGBoost rozpoczyna od stworzenia pierwszego słabego drzewa o niskiej wydajności, a następnie buduje kolejne drzewo na podstawie wyników poprzedniego, próbując przewidzieć to, czego poprzednie drzewo nie było w stanie przewidzieć. Algorytm kontynuuje budowę kolejnych drzew, z których każde koryguje błędy poprzedniego, aż do osiągnięcia warunku zatrzymania, takiego jak określona liczba drzew do zbudowania. XGBoost wykorzystuje algorytm wzrostu drzewa poziomami (ang. level-wise), w którym na kolejnym poziomie drzewa wybierany jest najlepszy węzeł do podziału, co skutkuje symetrycznymi drzewami, które rosną poziomo (Park i in., 2021) (rysunek 15). XGBoost rozwija podejście zastosowane w algorytmie Gradient Boosting, stosując funkcję celu składającą się z funkcji straty oraz regularyzacji, co pozwala poprawić jakość klasyfikacji (Aly i in., 2022).



Rysunek 15. Przykładowa struktura algorytmu XGBoost

Źródło: opracowanie własne na podstawie Park i in. (2021).


Model można zapisać w następujący sposób (Nguyen i in., 2023):

$$Z = F(x_i) = f_t(x_i)$$

gdzie x_i oznacza zmienne niezależne a $f_t(x_i)$ reprezentuje funkcję wyjściową każdego drzewa. XGBoost w każdej iteracji przegląda dane treningowe kilkukrotnie, co z jednej strony umożliwia znalezienie dokładnych warunków podziału, ale z drugiej strony wymaga dużo pamięci (Qian i in., 2022). Wpływa to na czas obliczeń i może prowadzić do nadmiernego dopasowania (Qian i in., 2022). Algorytm XGBoost akceptuje jako dane wejściowe zarówno zmienne ciągłe, jak i dyskretne, ale zmienna wyjściowa musi być dyskretna (Mo i in., 2019).

2.3.8. Light Gradient Boosting Machine

Light Gradient Boosting Machine (LightGBM) to algorytm zaproponowany przez Ke i in. (2017). Wykorzystuje algorytm wzmacniania gradientowego, podobnie jak XGBoost oraz Catboost. Jest to tak jak XGBoost metoda uczenia maszynowego, należąca do grupy metod zespołowych, a konkretnie technik typu boosting. Drzewa decyzyjne w algorytmie LightGBM są rozwijane liść po liściu, zamiast sprawdzania wszystkich poprzednich liści dla każdego nowego liścia, jak ma to miejsce w XGBoost (Al Daoud, 2019). Aby poprawić moc obliczeniową oraz zwiększyć dokładność algorytmu, LightGBM wykorzystuje algorytm histogramowy do łączenia wzajemnie wykluczających się cech (Wang i in., 2022). Zmniejsza to liczbę cech, które muszą być oceniane w każdej iteracji algorytmu gradient boosting, a tym samym skraca czas treningu modelu (Amirshahi i Lahmiri, 2024). Ponadto wykorzystywana jest strategia wzrostu drzewa na podstawie liści (ang. leaf-wise) z ograniczeniem głębokości drzewa, aby zapobiegać nadmiernemu dopasowaniu (Wang i in., 2022). Metoda rozrostu drzewa na podstawie liści wybiera liść, który najbardziej obniży wartość funkcji straty i go dzieli (Park i in., 2021). Dzięki takiemu podziałowi drzewo rośnie pionowo (rysunek 16). Mimo, że XGBoost i LightGBM są przykładami algorytmów wzmacniania gradientowego opartych na drzewach, różnią się sposobem rozbudowy drzew dla słabych klasyfikatorów (Park i in., 2021). Metoda rozrostu drzewa na podstawie liści zazwyczaj osiąga niższą wartość funkcji straty niż metoda rozrostu drzewa poziomami, ale jest bardziej podatna na przeuczenie (Park i in., 2021).




Rysunek 16. Przykładowa struktura algorytmu LightGBM

Źródło: opracowanie własne na podstawie Park i in. (2021).

LightGBM wykorzystuje technikę Gradient-based One-Side Sampling (GOSS) oraz Exclusive Feature Bundling (EFB) (Nguyen i in., 2023). GOSS jest wykorzystywane do podziału optymalnego węzła, natomiast EFB grupuje ekskluzywne zmienne, co wpływa na czas uczenia modelu (Nguyen i in., 2023). Zgodnie z tą metodą drzewo rośnie pionowo (Park i in., 2021).

2.3.9. Categorical Boosting

Categorical Boosting (CatBoost) należy do algorytmów wzmacniania gradientowego. Jest to nowy algorytm gradientowy zaproponowany przez Prokhorenkovą i in. (2018). CatBoost, podobnie jak inne implementacje wzmacniania gradientowego, konstruuje każde nowe drzewo, aby przybliżyć gradienty obecnego modelu (Dorogush i in., 2018). Jest to metoda uczenia maszynowego, należąca do grupy metod zespołowych, a konkretnie technik typu boosting. Celem CatBoost jest minimalizacja funkcji straty modelu poprzez dodawanie słabych klasyfikatorów za pomocą procedury podobnej do gradientowego spadku (Papík i in., 2021). Algorytm wykorzystuje binarne drzewa decyzyjne jako podstawowe predyktory (Ibrahim i in., 2020). Każde kolejne budowane drzewo koryguje błędy popełnione przez poprzednie drzewa. Algorytm powtarza proces budowy drzew, aż zbuduje model o zadowalającej jakości (Catboost, 2024) (rysunek 17).



Rysunek 17. Przykładowa struktura algorytmu CatBoost

Źródło: opracowanie własne na podstawie CatBoost (2024).

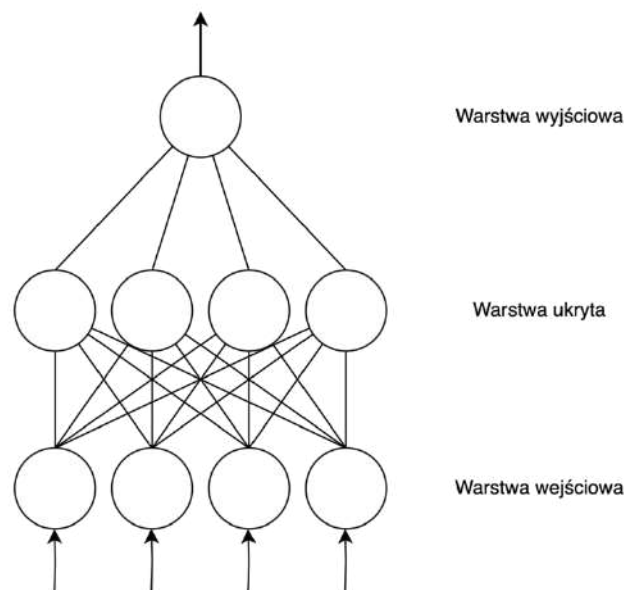
CatBoost opiera się na modelach typu GBDT bazujących na drzewach decyzyjnych (Paul i in., 2024). Model można zapisać w postaci poniższego równania (Lu i Hu, 2024):

$$F(x) = \sum_{m=1}^M T(x; \Theta_m)$$

gdzie M reprezentuje liczbę drzew, Θ_m to liczba m parametrów drzew decyzyjnych. Catboost daje możliwość przetwarzania cech kategorycznych bez konieczności ich wcześniejszego kodowania. Dzięki temu model jest mniej wrażliwy na kolejność danych kategorycznych (Amirshahi i Lahmiri, 2024). Ponadto, CatBoost tworząc symetryczne drzewa decyzyjne, aby zapobiec przeuczeniu wynikającemu z błędnego przypisywania etykiet zmiennym kategorycznym (Aly i in., 2022). Wykonuje losowe permutacje danych, aby uniknąć zależności wynikających z ich kolejności, co mogłoby prowadzić do błędnego wyboru podziałów w drzewie decyzyjnym i tym samym nieprawidłowego przypisania danych do liści (Aly i in., 2022). Catboost został zaprojektowany, aby przeciwdziałać problemowi przeuczenia, który jest powszechnie obserwowany w algorytmach opartych na gradientowym boostingu (Enkhtuya, i Kang, 2023).

2.3.10. Sieci neuronowe

Wśród najpopularniejszych sztucznych sieci neuronowych (ang. Artificial Neural Network – ANN) znajduje się sieć jednokierunkowa wielowarstwowa - perceptron wielowarstwowy (ang. Multilayer Perceptron - MLP). Składa się z jednej warstwy wejściowej, jednej lub kilku warstw ukrytych oraz warstwy wyjściowej (rysunek 18). Warstwa wejściowa perceptronu zawiera wyłącznie neurony wejściowe, które służą wyłącznie do odbioru danych i przekazania ich do pierwszej warstwy ukrytej, gdzie są dokonywane obliczenia (Brenes i in., 2022). Natomiast warstwy ukryte oraz wyjściowe składają się ze sztucznych neuronów (Brenes i in., 2022). Neurony w sieci neuronowej są ze sobą połączone, a każdemu połączeniu przypisana jest określona waga (Tsai i in., 2014). MLP to sieć jednokierunkowa (feed-forward), w której nie występują sprzężenia zwrotne, i która efektywnie radzi sobie z klasyfikacją oraz rozróżnianiem zbiorów danych o słabo zdefiniowanej strukturze klas (Pełka, 2009). MLP jest rodzajem sztucznej sieci neuronowej, która służy jako podstawowa architektura do głębokiego uczenia (Shiri i in., 2023).



Rysunek 18. Przykładowa struktura algorytmu sztucznej sieci neuronowej

Źródło: opracowanie własne na podstawie Zhang i in. (1999).

Fernández-Gómez i in. (2016) zwrócili uwagę, że zbyt duża liczba neuronów ukrytych może przyczynić się do zwiększenia ryzyka przeuczenia modelu. Pełka (2009) zauważył, że perceptron wielowarstwowy ma niższą skuteczność, gdy jednocześnie występują zmienne zakłócające oraz obserwacje odstające. W związku z relacją między liczebnością próby a liczbą uwzględnionych zmiennych, wskazane jest wykorzystanie technik redukcji wymiarowości w celu zwiększenia skuteczności modelu (Brenes i in., 2022).

2.4. Ocena skuteczności i interpretacja modeli

2.4.1. Miary skuteczności modeli

Do oceny skuteczności modeli wykorzystuje się wiele metryk, takich jak całkowita skuteczność, błąd I typu, błąd II typu, precyzja, czułość, swoistość, F1, krzywa ROC, AUC oraz wskaźnik Giniego (García i in., 2015; Barboza i in., 2017; Papana i Spyridou, 2020; Shetty i in., 2022; Nguyen i in., 2023; Brygała i Korol, 2024). Niektóre z powyższych miar można oszacować na podstawie macierzy błędów (ang. confusion matrix), która służy do porównania rzeczywistej klasyfikacji z przewidywaną (rysunek 19). Celem większości metryk oceny wydajności modeli klasyfikacyjnych jest oszacowanie, jak dobrze model potrafi przewidzieć poprawną klasę na nowych danych (García i in., 2015).

Prawdziwa wartość	0	Prawdziwie negatywna (TN)	Falŝywie pozytywna (FP)
	1	Falŝywie negatywna (FN)	Prawdziwie pozytywna (TP)
		0	1
		Prognozowana wartość	

Rysunek 19. Macierz błędów dla wyniku binarnego

Źródło: opracowanie własne.

W tabeli 1 przedstawiono wybrane miary skuteczności modeli. Całkowita skuteczność (ang. accuracy) jest jednym z najczęściej stosowanych wskaźników oceny modeli (García i in., 2015) i pokazuje ogólną skuteczność modelu. Błąd I typu oznacza nieprawidłową klasyfikację konsumentów z upadłością jako konsumentów bez upadłości, podczas gdy błąd II typu wskazuje na nieprawidłową klasyfikację konsumentów bez upadłości jako konsumentów z upadłością (Begley i in., 1996). Błędy I i II typu są powszechnie stosowane w kontekście testowania hipotez, jednak znalazły również zastosowanie jako wskaźniki oceny skuteczności modeli predykcyjnych. Na podstawie macierzy pomyłek, oprócz błędów I i II typu, można również oszacować następujące metryki: precyzję (ang. precision), czułość (ang. recall), swoistość (ang. specificity) oraz miarę F1.

Precyzja jest miarą, która określa dokładność prognozowanych pozytywnych wyników, tzn. prawdziwie zaklasyfikowanych bankrutów wśród wszystkich zaklasyfikowanych konsumentów jako bankrutów. Wskazuje więc, jaki odsetek spośród wszystkich przewidywanych np. jako pozytywne przypadki, rzeczywiście należy do klasy pozytywnej (Chen i in., 2023). Czułość określa siłę modelu w prognozowaniu wyników pozytywnych tzn. prawdziwie zaklasyfikowanych bankrutów wśród wszystkich bankrutów. Można czułość również oszacować jako: 1 - błąd I typu (Barboza i in., 2017). Czułość definiuje się jako stosunek poprawnie przewidzianych przypadków pozytywnych do łącznej liczby rzeczywistych przypadków pozytywnych (Dasilas i Rigani, 2024). Swoistość natomiast określa

zdolność modelu do prognozowania wyników negatywnych, tzn. prawdziwie zaklasyfikowanych konsumentów jako niebankrutow wśród wszystkich konsumentów, którzy nie są bankrutami. Można ją również oszacować jako: 1 - błąd II typu (Barboza i in., 2017). Swoistość definiujemy jako stosunek poprawnie przewidzianych przypadków negatywnych do łącznej liczby rzeczywistych przypadków negatywnych (Dasilas i Rigani, 2024). Gdy błąd I typu jest niski, czułość ma wartości bliskie 1, natomiast gdy błąd II typu jest niski, swoistość ma wartości bliskie 1 (Barboza i in., 2017). Precyzja, podobnie jak dokładność i czułość, powinna przyjmować wartość jak najbliższą 1 (Bruce i in., 2021). F1 natomiast jest średnią harmoniczną wskaźnika czułości i precyzji (Lombardo i in., 2022). Precyzja, czułość oraz F1 są często liczone dla poszczególnych klas, na przykład w raporcie klasyfikacji generowanym przez bibliotekę scikit-learn (sklearn) w języku Python.

Tabela 1. Miary skuteczności modeli

Miara	Sposób obliczenia
Całkowita skuteczność (ang. accuracy)	$\frac{TP + TN}{FN + TP + TN + FP}$
Wskaźnik błędu klasyfikacji (ang. misclassification)	$1 - \text{całkowita skuteczność}$
Precyzja (ang. precision) – klasa 1 (bankruci)	$\frac{TP}{TP + FP}$
Precyzja (ang. precision) – klasa 0 (niebankruci)	$\frac{TN}{TN + FN}$
Czułość (ang. recall) – klasa 1 (bankruci)	$\frac{TP}{TP + FN}$
Czułość (ang. recall) – klasa 0 (niebankruci)	$\frac{TN}{TN + FP}$
Swoistość (ang. specificity)	$\frac{TN}{TN + FP}$
F1 – klasa 1 (bankruci)	$2x \frac{\text{precyzja (bankruci)} \times \text{czułość (bankruci)}}{\text{precyzja (bankruci)} + \text{czułość (bankruci)}}$
F1 – klasa 0 (niebankruci)	$2x \frac{\text{precyzja (niebankruci)} \times \text{czułość (niebankruci)}}{\text{precyzja (niebankruci)} + \text{czułość (niebankruci)}}$
Błąd I typu	$\frac{FN}{TP + FN}$
Błąd II typu	$\frac{FP}{TN + FP}$
Wskaźnik Giniego	$2 \times AUC-1$

Źródło: opracowanie własne na podstawie: Hand i Till (2001), Chen i in. (2011), Chen i in. (2023), Noh (2023).

Barboza i in. (2017) zauważyli, że w przypadku prognozowania upadłości należy analizować skuteczność modeli zarówno za pomocą całkowitej skuteczności, jak i błędów I typu, błędów II typu oraz ich potencjalnych skutków. Bazowanie wyłącznie na ogólnej skuteczności w przypadku danych niezbilansowanych może prowadzić do zniekształcenia wyników i znikomej klasyfikacji mniejszej grupy, np. bankrutów, w porównaniu do większej grupy niebankrutów. Błąd typu I to sytuacja, w której konsument nie jest klasyfikowany jako potencjalny bankrut, pomimo problemów ze spłatą zobowiązań, co prowadzi do upadłości. Udzielenie kredytu osobie, która będzie miała problemy ze spłatą zobowiązań i w konsekwencji ogłosi upadłość, może prowadzić do strat, na przykład ze strony banku, z powodu niemożności odzyskania pożyczki. W przypadku prognozowania upadłości istotne jest skupienie się na wysokiej czułości, ponieważ konsekwencją mogą być straty dla pożyczkodawców (Barboza i in., 2017). Błąd typu II to utrata potencjalnego klienta i zysku dla banku lub innej instytucji pożyczkowej w związku z udzieleniem kredytu osobie, która nie miałaby problemów ze spłatą zobowiązań i nie ogłosiłaby bankructwa. W związku z tym nie można zapominać o swoistości, która ma związek z potencjalnym zyskiem. W konsekwencji błąd I typu uważany jest za droższy niż błąd II typu (West, 2000). Koszty błędnej klasyfikacji powinny być również brane pod uwagę w zależności od przedmiotu badań, ponieważ koszty błędnej klasyfikacji w medycynie będą postrzegane inaczej niż na przykład w bankowości. Minimalizacja zarówno błędów I typu, jak i błędów II typu gwarantuje instytucji pożyczkowej niskie ryzyko niewypłacalności kredytobiorców oraz maksymalizację udzielanych pożyczek z powodu upadłości konsumentów. Antunes i in. (2017) zwrócili również uwagę, że idealna sytuacja byłaby w przypadku, gdyby całkowita skuteczność oraz F1 były jak najbliżej 1 a błędy I i II typu jak najbliżej 0.

Kolejną popularną metryką wykorzystywaną do oceny skuteczności modeli jest krzywa ROC. Przedstawia poprawność klasyfikacji pozytywnej i negatywnej dla różnych punktów odcięcia. Jest to wykres przedstawiający zależność pomiędzy współczynnikiem czułości a współczynnikiem swoistości. Można spodziewać się lepszych wyników prognozowania, jeśli krzywa znajduje się bliżej lewego górnego rogu wykresu (Shetty i in., 2022). Obszar pod krzywą ROC (AUC – Area Under Curve) jest odpowiedni do oceny wydajności metody w zestawach danych z niezbalansowanymi klasami, ponieważ jest odporny na koszty błędnej klasyfikacji i nierównomierny rozkład, a wyższa wartość AUC wskazuje na lepszą wydajność klasyfikatora (Zelenkov i Volodarskiy, 2021). AUC mierzy prawdopodobieństwo tego, że model sklasyfikuje losowo wybrany pozytywny przykład wyżej niż losowo wybrany negatywny (Liang i in., 2016). Barboza i in. (2017) zauważyli, że aby model był na

akceptowalnym poziomie, AUC powinno być wyższe niż 0,5, a im wartość ta jest wyższa, tym moc predykcyjna modelu jest silniejsza. Miara AUC jest ściśle powiązana ze wskaźnikiem Giniego (Hand i Till, 2001). Wskaźnik Giniego mierzy zdolność modelu do rozróżniania klas. W przypadku modelu losowego wskaźnik Giniego będzie równy lub bliski zeru (Bemš, 2015). Natomiast, wskaźnik Giniego osiąga wartość 1, gdy model idealnie rozróżnia klasy pozytywne i negatywne. Im wyższy wskaźnik Giniego, tym lepsza zdolność modelu do rozróżniania przypadków. Pisula (2013) zwrócił uwagę, że wskaźnik Giniego poniżej 0,35 może świadczyć o niewystarczającej skuteczności modelu predykcyjnego, co może prowadzić do nieprawidłowej klasyfikacji. Nikolic (2013), zauważył, że wskaźnik Giniego umożliwia porównanie zdolności dyskryminacyjnej modelu z wynikami innych badań (Nikolic, 2013).

Poza tradycyjnym podejściem wykorzystującym macierz pomyłek, jedną z metod oceny skuteczności modelu predykcyjnego jest analiza decylowa. Polega ona na podziale zbioru danych na dziesięć równolicznych grup (decyli) posegregowanych według wartości prognozowanego prawdopodobieństwa zdarzenia wygenerowanego przez model. Pozwala to na precyzyjne określenie skuteczności modelu w każdej z tych grup. Ułatwia to również klasyfikację konsumentów według poziomu ryzyka i wdrożenie bardziej zróżnicowanego podejścia.

Powyższe wskaźniki umożliwiają dokładną analizę wyników predykcyjnych, uwzględniając skuteczność zarówno wśród konsumentów, którzy ogłosili upadłość, jak i tych, którzy jej nie ogłosili. Pozwalają na ocenę modelu zarówno dla zbilansowanego, jak i niezbilansowanego zbioru danych. W związku z tym istotne jest dostosowanie wyboru miar skuteczności modelu do posiadanych danych oraz wykorzystanych algorytmów.

2.4.2. Interpretowalność modeli

Wraz z upływem lat modele stają się coraz bardziej złożone oraz zaawansowane. Ponadto nowe możliwości technologiczne pozwalają na głębszą analizę oraz uzyskiwanie coraz bardziej precyzyjnych wyników. Aby budować zaufanie do sztucznej inteligencji wykorzystywanej w procesie podejmowania decyzji, istotne jest dostarczanie zrozumiałych i interpretowalnych wyjaśnień finansowych (Černevičienė i Kabašinskas, 2024). Potrzeba zrozumiałej sztucznej inteligencji (ang. Explainable Artificial Intelligence - XAI) staje się coraz bardziej kluczowa. XAI umożliwia badanie, wyjaśnianie i zrozumienie złożonych systemów (Černevičienė i Kabašinskas, 2024). Wśród najczęściej używanych metod interpretacji modeli znajdują się: istotność cech (ang. feature importance), SHapley Additive exPlanation oraz metody oparte na regułach (Černevičienė i Kabašinskas, 2024).

Wzrost zaawansowania algorytmów powoduje, że często modele uczenia maszynowego są uważane za czarne skrzynki ze względu na ich złożoność i ukryte mechanizmy (Carmona i in., 2022). Termin „czarna skrzynka” odnosi się do modeli, gdzie znamy dane wejściowe i wyjściowe, ale możemy powiedzieć niewiele o tym, co dzieje się w środku (Gramegna i Giudici, 2021). Brotcke (2022) zauważył, że mniejsza przejrzystość i możliwości wyjaśnienia modeli uczenia maszynowego w porównaniu do tradycyjnych modeli regresji mogą prowadzić do dyskusji na temat zgodności modeli z regulacjami dotyczącymi uczciwego udzielania kredytów. Bardziej skomplikowane modele, często cechują się wyższą dokładnością predykcyjną, ale często są trudniejsze do zrozumienia i interpretacji. Niemniej jednak, w ostatnich latach badacze zaproponowali rozwiązania mające na celu zwiększenie interpretowalności modeli uczenia maszynowego. Możliwość interpretacji modeli predykcyjnych jest kluczowym elementem, aby świadomie i skutecznie korzystać z zaawansowanych algorytmów. Jednak interpretacja powinna być rzetelna i zrozumiała, aby można było wykorzystywać uczenie maszynowe skutecznie (Ribeiro i in., 2016).

Powszechnie wykorzystywanym podejściem, umożliwiającym ocenę istotności zmiennych jest analiza ważności cech (ang. feature importance). Modele zespołowe bazujące na drzewach umożliwiają relatywnie prostą ocenę istotności zmiennych (Son i in., 2019). Dla każdego drzewa oblicza się wpływ danej zmiennej na poprawę dokładności predykcji, uwzględniając liczbę przypisanych obserwacji, a następnie wyniki te są uśredniane dla całego modelu (Son i in., 2019).

Kolejnym podejściem wykorzystywanym do interpretacji modeli uczenia maszynowego jest metoda SHapley Additive exPlanation (SHAP) (Bussmann i in., 2020), która często stosowana jest do interpretowania złożonych modeli (Bussmann i in., 2020; Jabeur i in., 2021). Metoda ta opiera się na teorii gier i służy do wyjaśniania wyników dowolnego modelu uczenia maszynowego. Została zaproponowana przez Lundberga i Lee (2017). Wartość SHAP jest obliczana w celu uzyskania interpretowalnych wyników predykcji i pokazuje kluczowe czynniki wpływające na wyniki predykcyjne, dostarczając cennych informacji do identyfikacji potencjalnych upadłości. Aby uczynić model interpretowalnym, SHAP wykorzystuje addytywną metodę przypisania cech, a wynik modelu jest definiowany jako liniowa suma zmiennych wejściowych (Mangalathu i in., 2020). Tworzony jest model liniowy, a współczynniki odzwierciedlają istotność poszczególnych zmiennych (Černeckienė i Kabašinskas, 2024). Biorąc pod uwagę, że modele uczenia maszynowego są uważane za „czarne skrzynki”, zestawienie SHAP pomaga wyjaśnić predykcje. SHAP jest stosowany do interpretacji każdego parametru w skali globalnej i indywidualnej. Każdy punkt na wykresie

reprezentuje osobę, a zbiór punktów tworzy wartość SHAP danej cechy. Oś pozioma pokazuje dodatnią i negatywną korelację między zmiennymi charakterystycznymi a wynikami, podczas gdy oś pionowa przedstawia ranking wartości bezwzględnych atrybutów (Zhang i in., 2023). Innym istotnym aspektem jest kolor danej obserwacji: niebieski reprezentuje niższą wartość, a czerwony wyższą wartość. Wyższa wartość SHAP oznacza np. większe prawdopodobieństwo bankructwa. Metoda SHAP jest uważana za pośrednią metodę generowania wyjaśnień modelu, ponieważ skupia się na indywidualnej interpretacji danej cechy, nie uwzględniając zależności między nimi (Černevičienė i Kabašinskas, 2024). Kluczowe jest uwzględnienie tego przy silnych korelacjach między zmiennymi, ponieważ w konsekwencji może to prowadzić do sprzecznych wyników (Černevičienė i Kabašinskas, 2024).

Inną popularną techniką interpretacji modeli uczenia maszynowego jest algorytm Local Interpretable Model-Agnostic Explanations (LIME) zaproponowany przez Ribeiro i in. (2016). LIME wykorzystuje interpretowalny model, aby wytłumaczyć poszczególne predykcje (Ribeiro i in., 2016). Algorytm można wykorzystać do interpretacji dowolnego modelu zarówno algorytmów uczenia maszynowego jak i uczenia głębokiego (Chou, 2019). Aby wyjaśnić działanie bardziej złożonych algorytmów, LIME wykorzystuje modele interpretowalne, takie jak regresja logistyczna czy drzewa decyzyjne (Chen i in. 2024). LIME dostosowuje lokalny model, korzystając z podobnych danych do obserwacji, która jest wyjaśniana (Gramegna i Giudici, 2021).

Przedstawione metody SHAP i LIME umożliwiają interpretacje na poziomie pojedynczych obserwacji dając lokalne wyjaśnienia, jednak różnią się zastosowanymi algorytmami (Gramegna i Giudici, 2021). Chen i in. (2024) zauważyli spadek stabilności interpretacji generowanych przez te metody wraz ze wzrostem nierównowagi pomiędzy klasami, co stanowi istotny aspekt wymagający uwagi. Natomiast istotność cech oraz SHAP umożliwiają interpretację globalną modelu, wskazując, które zmienne mają największy wpływ na jego ogólne działanie.

2.4.3. Zalety i wady poszczególnych metod prognozowania ryzyka upadłości konsumenckiej

Wybór odpowiedniej metody prognozowania jest kluczowy i ma istotny wpływ na trafność predykcji, przejrzystość wyników oraz możliwość zastosowania modelu w praktyce. Algorytm powinien być dostosowany do konkretnego problemu badawczego oraz charakterystyki posiadanych danych. Metody statystyczne, pomimo dużego zainteresowania, mają pewne ograniczenia, co skłoniło badaczy do poszukiwania nowych algorytmów lepiej dostosowanych do złożoności obecnych danych. Skuteczność klasycznych metod

statystycznych zależy od spełnienia założeń takich jak liniowość, normalność oraz niezależność zmiennych predykcyjnych (Zgang i in., 1999). Alaka i in. (2018) zauważyli, że regresja logistyczna i analiza dyskryminacyjna są wrażliwe na współliniowość. Ponadto regresja logistyczna wykazuje wysoką wrażliwość na wartości odstające (Alaka i in., 2018) oraz brakujące dane (Hassan i in., 2017). Z tego powodu wzrosło zainteresowanie innymi technikami sztucznej inteligencji (Korol, 2019). Jak zauważył Begum (2021), do zalet regresji logistycznej należy niskie zapotrzebowanie na zasoby obliczeniowe oraz ograniczona podatność na przeuczenie modelu. Dodatkowo, regresja logistyczna jest łatwa w interpretacji, co stanowi ważną zaletę tej metody.

Podobnie drzewa decyzyjne wyróżniają się przejrzystością i łatwością w interpretacji. Ponadto, drzewa decyzyjne mają zdolność automatycznego pomijania nieistotnych zmiennych oraz radzenia sobie z klasyfikacją danych niepełnych (Pociecha, 2018). Jednym z problemów związanych z drzewem decyzyjnym, które mogą się pojawić, jest nadmierne dopasowanie. Rozwiązaniem tego problemu jest odpowiednie przycinanie drzewa na etapie jego tworzenia lub przycinanie już istniejącego drzewa (Podhorska i in., 2020). Podczas przygotowywania drzewa decyzyjnego może dojść do przetrenowania modelu, tzn. efektem będzie uzyskanie małego błędu na próbie uczącej i dużego błędu na próbie testującej. Model zostanie nadmiernie dopasowany do danych uczących. Można wyeliminować taką sytuację poprzez np. ograniczenie głębokości drzewa, ustalenie minimalnej liczby próbek w liściu, ustaleniu minimalnej liczby próbek do podziału i przycinanie drzewa.

W przypadku lasów losowych zamiast pojedynczego drzewa buduje się wiele drzew decyzyjnych, a ich wyniki są łączone. Dzięki temu końcowa prognoza jest bardziej stabilna i dokładna niż prognoza oparta na jednym drzewie. Lasy losowe często zapewniają lepsze wyniki klasyfikacji niż drzewa decyzyjne, jednak kosztem trudniejszej interpretacji działania modelu.

Min i Lee (2005) zwrócili uwagę, że maszyny wektorów nośnych mogą stanowić alternatywę, łącząc zalety tradycyjnych modeli statystycznych z nowoczesnymi, niezależnymi od rozkładu i odpornymi bardziej zaawansowanymi metodami uczenia maszynowego. Pociecha (2018) podkreśla również, że SVM jest z jednej strony algorytmem bardzo wydajnym i odpornym na przetrenowanie, ale z drugiej strony charakteryzuje się stosunkowo powolnym uczeniem.

Wciąż rośnie zainteresowanie również bardziej zaawansowanymi algorytmami uczenia maszynowego (Lee i in., 2005; Barboza i in., 2017; Shi i Li, 2019; Son i in., 2019; Aly i in., 2022; Papík i Papíková, 2023; Lu i Hu, 2024). Jednym z takich algorytmów jest AdaBoost, który zyskał popularność ze względu na swoją prostotę i skuteczność. AdaBoost nie wymaga

dużego zbioru danych treningowych, w przeciwieństwie do innych metod wykorzystujących techniki boostingu i baggingu (Tsai i in., 2014). Jest uznawany za algorytm prosty w użyciu, dokładny, stabilny oraz mniej podatny na przeuczenie w porównaniu z innymi algorytmami uczenia zespołowego (Sun, 2023). Jeszcze lepsze rezultaty w wielu zastosowaniach zapewnia XGBoost, który łączy wysoką dokładność z szybkością działania w większą odpornością na nadmierne dopasowanie. Daoud (2019) zauważył, że technika zastosowana w XGBoost sprawia, że model jest szybszy i bardziej stabilny podczas dopasowywania modelu. Podobnie jak w przypadku LightGBM, istnieje wiele hiperparametrów, które można modyfikować, aby zmaksymalizować moc modelu i zapobiec jego nadmiernemu dopasowaniu. Wśród parametrów wykorzystywanych do eliminacji nadmiernego dopasowania modelu są między innymi: maksymalna głębokość drzew, liczba drzew, procentowy wybór obserwacji i zmiennych służących do budowy pojedynczego drzewa oraz regularyzacja. XGBoost działa wyłącznie na wartościach numerycznych, podobnie jak lasy losowe, w przeciwieństwie do nowszych algorytmów, takich jak CatBoost i LightGBM (Jabeur i in., 2021). W związku z tym przed użyciem danych kategorycznych konieczne jest zastosowanie metod kodowania, takich jak kodowanie One-Hot Encoding i Label Encoding (Jabeur i in., 2023). Zaletą algorytmu LightGBM jest jego wysoka dokładność, szybkość trenowania modelu, niskie zużycie pamięci oraz zdolność do pracy z dużymi zestawami danych (Ke i in., 2017; Al Daoud, 2019). Ke i in. (2017) zauważyli, że LightGBM, oprócz skrócenia czasu treningu o ponad 20 razy w porównaniu do Gradient Boosting Decision Tree (GBDT), osiąga niemal taką samą dokładność. Jednak posiadanie dużego zestawu danych wpływa na czas treningu modelu. W związku z tym wybór między krótszym czasem treningu a dokładnością modelu nie jest tak oczywisty, zwłaszcza gdy różnice w dokładności nie są znaczące przy krótszym czasie treningu modelu. W badaniach przeprowadzonych przez Al Daoud (2019), LightGBM okazał się szybszy i bardziej dokładny niż CatBoost i XGBoost. Jedną z zalet CatBoost jest zdolność tego algorytmu do pracy ze zmiennymi kategorycznymi. Algorytm radzi sobie bez stosowania wstępnego przetwarzania zmiennych kategorycznych (Aly i in., 2022). Wykorzystuje podejście rankingowe, w którym różne wartości zmiennej są klasyfikowane według związku ze zmienną zależną, a każda wartość jest konwertowana na wartość numeryczną (Lu i Hu, 2024). CatBoost wykorzystuje także adaptacyjne przetwarzanie cech oraz przetwarzanie oparte na symetrycznym podziale drzew (Lu i Hu, 2024). Symetryczny podział drzew przekłada się na szybszy podział i klasyfikację danych, co wpływa na efektywność obliczeniową modelu, skracając czas trenowania (Lu i Hu, 2024). Dorogush i in. (2018) zauważyli, że CatBoost, zaraz po LightGBM, jest najszybszą metodą, podczas gdy XGBoost jest znacznie wolniejszy od obu

tych algorytmów, co jest istotne w przypadku dużych zbiorów danych. Hancock i Khoshgoftaar (2020) zwrócili uwagę, że CatBoost wykazuje wrażliwość na hiperparametry i podkreślili wagę dostosowywania tych parametrów. Z kolei Aly i in. (2022) zauważyli, że algorytm CatBoost charakteryzuje się wysoką skutecznością przy zastosowaniu domyślnych hiperparametrów. Lu i Hu (2024) również podkreślili, że CatBoost dobrze radzi sobie z dużymi zbiorami danych, zapewniając wysoką dokładność predykcji oraz dużą efektywność obliczeniową na etapie trenowania modelu.

Kolejną popularną metodą wykorzystywaną w modelach prognostycznych są sieci neuronowe. Zaletą sieci neuronowych jest to, że nie wymagają spełnienia takich założeń, jak liniowość, rozkład normalny czy niezależność zmiennych (Gavurova i in., 2022). W badaniu przeprowadzonym przez Zhang i in. (1999) sieci neuronowe przewyższyły skutecznością regresję logistyczną, co potwierdzono także w innych badaniach (Lee i in., 2005; Son i in., 2019). Becerra-Vicario i in. (2020) porównali skuteczność regresji logistycznej i głębokiej rekurencyjnej konwolucyjnej sieci neuronowej (ang. Deep Recurrent Convolutional Neural Network), gdzie bardziej zaawansowana metoda wykazała się wyższą skutecznością. Z kolei Fernández-Gámez i in. (2016) porównali dwa algorytmy sieci neuronowych: MLP (ang. Multilayer Perceptron) oraz PNN (ang. Probabilistic Neural Network), przy czym MLP osiągnął wyższą skuteczność. Shanker i in. zwrócili uwagę, że w modelach opartych na głębokim uczeniu wykorzystanie standaryzacji na etapie przygotowywania danych poprawia skuteczność modelu, jednak korzyści wynikające ze standaryzacji maleją wraz ze wzrostem sieci lub ze wzrostem wielkości próby.

Barboza i in. (2017) porównali tradycyjne modele, takie jak analiza dyskryminacyjna, regresja logistyczna oraz sztuczne sieci neuronowe, z nowoczesnymi modelami uczenia maszynowego, takimi jak bagging, boosting i lasy losowe. Bardziej zaawansowane modele uczenia maszynowego wykazały wyższą zdolność predykcyjną niż metody tradycyjne. Autorzy wykorzystali surowe dane zawierające silnie skorelowane zmienne, wartości odstające oraz brakujące dane. Hossain i in. (2022) porównali skuteczność sieci neuronowych, lasów losowych, SVM, XGBoost i LightGBM. Przy zastosowaniu metody SMOTE najwyższą skuteczność osiągnęły sieci neuronowe, a następnie SVM, a najniższą LightGBM (Hossain i in., 2022). W próbie, gdzie metoda SMOTE nie została zastosowana, najwyższą skuteczność wykazały sieci neuronowe, a następnie algorytm XGBoost, przy czym najniższą skuteczność zanotowano dla SVM (Hossain i in., 2022). Różnice między algorytmami były niewielkie, podobnie jak między innymi miarami skuteczności (F1, czułość i precyzja). W badaniu przeprowadzonym przez Shetty i in. (2022), porównano skuteczność trzech algorytmów:

głębokich sieci neuronowych, XGBoost i SVM, uzyskując bardzo zbliżoną skuteczność modeli dla wszystkich trzech algorytmów. Korol (2019) w swoim badaniu porównał skuteczność 4 modeli: MLNN (ang. Multilayer Neural Network), RNN (ang. Recurrent Neural Network), zbiory rozmyte (ang. Fuzzy Sets) i drzewa decyzyjne. Zbiory rozmyte oraz RNN wykazały najwyższą skuteczność i najniższe błędy I i II typu. Altman i in. (2020) porównali skuteczność pięciu algorytmów: drzewa decyzyjnego, gradient boosting, regresji logistycznej, sieci neuronowych oraz SVM w przewidywaniu upadłości małych i średnich przedsiębiorstw. Najwyższą skuteczność osiągnęły regresja logistyczna oraz sieci neuronowe. W badaniu Smith i Alvarez (2022) algorytm XGBoost przewyższył regresję logistyczną w przewidywaniu upadłości. Hosaka (2019) wykazał, że konwolucyjne sieci neuronowe (ang. Convolutional Neural Network) przewyższają skutecznością inne algorytmy, w tym drzewo decyzyjne, analizę dyskryminacyjną, SVM, wielowarstwowe perceptrony (MLP) oraz AdaBoost.

Coraz częściej stosowane są również algorytmy zespołowe, łączące dwa lub więcej algorytmów w celu prognozowania upadłości. Xie i in. (2013) porównali skuteczność regresji logistycznej (LR), SVM, BPNN (ang. Back-Propagation Neural Network) oraz dwóch modeli zespołowych LR-BPNN i LR-SVM. Spośród pojedynczych algorytmów najwyższą skuteczność osiągnął model sieci neuronowych, a następnie SVM. Regresja logistyczna wykazała najniższą skuteczność. Połączenie regresji logistycznej z sieciami neuronowymi oraz regresji logistycznej z SVM zwiększyło skuteczność modeli zarówno w całkowitej skuteczności, jak i w zmniejszaniu błędów I i II typu. Lin i McClean (2001) przeanalizowali skuteczność algorytmów uczenia maszynowego oraz metod hybrydowych, łączących techniki statystyczne z metodami uczenia maszynowego. Sieci neuronowe oraz drzewa decyzyjne wykazały wyższą skuteczność niż analiza dyskryminacyjna i regresja logistyczna, a zastosowanie metod hybrydowych dodatkowo podniosło skuteczność prognoz. Wiele pojedynczych sieci neuronowych można połączyć w model zespołowy, który może osiągać lepsze rezultaty niż pojedynczy klasyfikator (Nanni i Lumini, 2009). Tsai i Wu (2008) porównali wydajność pojedynczego algorytmu sieci neuronowych oraz zespołowego algorytmu sieci neuronowych w prognozowaniu upadłości i ocenie kredytowej. Wyniki sugerują, że najlepszy pojedynczy algorytm sieci neuronowej jest bardziej skuteczny niż wiele połączonych algorytmów, podczas gdy udział błędnych predykcji w poszczególnych klasach był na podobnym poziomie (Tsai i Wu, 2008). Autorzy zwrócili uwagę, że na takie wyniki może mieć wpływ zbyt mała populacja oraz większa stabilność pojedynczego klasyfikatora w przypadku klasyfikacji binarnej. W przeprowadzonym badaniu autorzy wykorzystali wyłącznie

sieci neuronowe, bez uwzględniania w zespołowym algorytmie innych metod takich jak metody statystyczne, bagging czy boosting.

Nie istnieje jednoznacznie najlepsza inteligentna technika w modelach prognostycznych (Wang i in., 2014). Na skuteczność algorytmów wpływają również inne aspekty, takie jak struktura i przygotowanie danych, inżynieria i selekcja zmiennych, wybór metody bilansującej dane, wybór algorytmu i jego hiperparametrów. Każdy etap budowy modelu może wpływać na jego końcową skuteczność, co podkreśla znaczenie dostosowania metod do specyfiki posiadanych danych.

2.5. Przegląd zmiennych wykorzystywanych w prognozowaniu ryzyka upadłości konsumenckiej

W literaturze poświęconej upadłości konsumenckiej, wśród mikroekonomicznych aspektów do najczęściej występujących czynników należą wiek, stan cywilny, dochód, wykształcenie, posiadanie nieruchomości, posiadanie dzieci, źródło dochodu oraz rodzaj i liczba posiadanych zobowiązań wraz z ich udziałem do dochodu czy miesięcznej płatności rat (Zywicki, 2004; Fisher, 2005; Dawsey, 2014; Syed Nor i in., 2019). W tabeli 2 został przedstawione zmienne, które najczęściej występują w literaturze przedmiotu dotyczącej upadłości konsumenckiej.

Tabela 2. Zmienne najczęściej wykorzystywane w analizowanej literaturze przedmiotu

Zmienna	Publikacje
Wiek	Stavins, 2000; Caputo, 2008; Zhu, 2011; Nor i in., 2019; Fisher, 2019; Bauchet i Evans, 2019; Brygała, 2022; Sahiq i in., 2022; Korol, 2024;
Stan cywilny	Domowitz i Sartain, 1999; Stavins, 2000; Zhu, 2011; Caputo, 2008; Dawsey, 2014; Bauchet i Evans, 2019; Fisher, 2019; Brygała, 2022; Sahiq i in., 2022; Korol, 2024;
Dochód	Stavins, 2000; Caputo, 2008; Zhu, 2011; Nor i in., 2019; Bauchet i Evans, 2019; Fisher, 2019; Sahiq i in., 2022; Korol, 2024; Brygała i Korol, 2024;
Wykształcenie	Stavins, 2000; Caputo, 2008; Bauchet i Evans, 2019; Fisher, 2019; Brygała, 2022; Sahiq i in., 2022; Korol, 2024; Brygała i Korol, 2024;
Posiadanie nieruchomości	Domowitz i Sartain, 1999; Stavins, 2000; Zhu, 2011; Fisher, 2019; Sahiq i in., 2022; Brygała, 2022; Brygała i Korol, 2024;
Liczba dzieci	Caputo, 2008; Zhu, 2011; Nor i in., 2019; Bauchet i Evans, 2019; Brygała, 2022; Brygała i Korol, 2024;
Źródło dochodu	Stavins, 2000; Zhu, 2011; Nor i in., 2019; Bauchet i Evans, 2019; Fisher, 2019; Brygała, 2022;
Zadłużenie	Zhu, 2011; Nor i in., 2019; Bauchet i Evans, 2019; Sahiq i in., 2022; Korol, 2024;
Grupa etniczna	Caputo, 2008; Nor i in., 2019; Bauchet i Evans, 2019; Fisher, 2019; Sahiq i in., 2022;

Wiek jest silnym determinantem złożenia wniosku o ogłoszenie upadłości i zmienia się w zależności od grupy wiekowej. Bauchet i Evans (2019) doszli do wniosku, że wiek zwiększa prawdopodobieństwo złożenia wniosku o ogłoszenie upadłości. Zwrócili również uwagę, że związek między wiekiem a ogłoszeniem upadłości był nieliniowy, więc prawdopodobieństwo wzrosło w tempie malejącym wraz z wiekiem. Najwyższe prawdopodobieństwo złożenia wniosku o ogłoszenie upadłości konsumenckiej można zaobserwować w grupie wiekowej 45–54 oraz 55–64 w porównaniu z osobami poniżej 35 lat (Brygała, 2022). Fay i in. (2002) zwrócili uwagę na to, że każdy kolejny rok nauki dla głowy gospodarstwa domowego oraz wzrost wieku skutkuje większym spadkiem prawdopodobieństwa upadłości.

W literaturze poświęconej upadłości konsumenckiej zwracano również uwagę na związek między stanem cywilnym a upadłością (Fay i in., 2002; Agarwal i in., 2011; Fisher, 2019). Zmiana stanu cywilnego może prowadzić do pogorszenia sytuacji finansowej konsumentów, na przykład ze względu na śmierć małżonka lub rozwód. Ponadto Fisher i Lyons (2006) zauważyli, że rozwód znacząco zwiększa prawdopodobieństwo upadłości. Według Moorman i Garasky (2008), bycie w związku małżeńskim może zwiększać ryzyko upadłości konsumenckiej. Z kolei Bauchet i Evans (2019) doszli do innego wniosku, twierdząc, że bycie w związku małżeńskim zmniejsza prawdopodobieństwo złożenia wniosku o upadłość konsumencką.

Kolejną determinantą analizowaną w kontekście upadłości konsumenckiej jest dochód. Choć czynnik dochodowy często pojawia się w literaturze przedmiotu dotyczącej upadłości konsumentów (Fay i in., 2002; Zhu, 2011), badania przeprowadzone przez Bauchet i Evans (2019) pokazują, że dochód nie był zmienną istotną statystycznie. Z kolei Fay i in. (2002) stwierdzili, że zarówno wzrost, jak i spadek dochodu wpływają na decyzję o ogłoszeniu upadłości konsumenckiej, przy czym spadek dochodu ma silniejszy efekt w kolejnym roku. Wynika to z faktu, że spadek dochodu wpływa zarówno na poziom dochodu, jak i na zmienną dotyczącą jego zmniejszenia (Fay i in., 2002). Fisher (2005) uznał, że koncentracja na dochodzie z pracy jako czynnika wpływającym na upadłość konsumencką jest uzasadniona, ponieważ dochód z pracy stanowi główne źródło dochodu dla większości gospodarstw domowych. Niemniej jednak, autor zauważa, że takie podejście ignoruje inne składniki dochodu, które wydają się równie istotne przy podejmowaniu decyzji o upadłości konsumenckiej. Fisher (2005) stwierdza również, że wzrost świadczeń dla bezrobotnych zmniejsza prawdopodobieństwo upadłości. Bauchet i Evans (2019) zwrócili uwagę również na to, że samozatrudnienie nie było zmienną istotną statystycznie.

Fisher (2019) zwrócił uwagę, że niższy poziom wykształcenia zwiększa prawdopodobieństwo ogłoszenia upadłości konsumenckiej. Podobne wnioski przedstawił Sahiq i in. (2022), wskazując, że poziom wykształcenia obok takich czynników jak sektor zatrudnienia, grupa etniczna czy rodzaj zatrudnienia ma istotny wpływ a zwiększone prawdopodobieństwo ogłoszenia upadłości konsumenckiej. Natomiast, w badaniach przeprowadzonych przez Bauchet i Evans (2019) wykazano, że poziom wykształcenia był istotnie statystycznie powiązany z ogłoszeniem upadłości, przy czym różnica była niewielka. Osoby ogłaszające upadłość miały średnio o pół roku krótszy okres edukacji niż pozostali (Bauchet i Evans, 2019).

Posiadanie domu zmniejsza prawdopodobieństwo złożenia wniosku o upadłość konsumencką i jest istotnym predyktorem tego zjawiska (Stavins, 2000; Fisher, 2005; Agarwal i in., 2011; Syed Nor i in., 2019; Brygała, 2022). Przyczyną może być obawa przed utratą nieruchomości, co prowadzi do poszukiwania innych alternatyw, które pomogą poradzić sobie z nadmiernym zadłużeniem. Ponadto, Domowitz i Sartain (1999) zwrócili uwagę, że posiadanie nieruchomości na własność odgrywa istotną rolę nie tylko w kontekście decyzji o ogłoszeniu upadłości, ale również w wyborze alternatywy upadłościowej.

Ogłoszenie upadłości może być również związane z posiadanym zadłużeniem na kartach kredytowych, zadłużeniem medycznym, zadłużeniem hipotecznym oraz kredytami samochodowymi (Domowitz i Sartain, 1999; Gross i Souleles, 2002; Zhu, 2011; Bauchet i Evans, 2019; Syed Nor i in., 2019). Ponadto, liczba posiadanych kredytów zwiększa prawdopodobieństwo upadłości (Dawsey, 2014). Domowitz i Sartain (1999) wskazali, że do kluczowych przyczyn upadłości konsumentów należą: dług medyczny oraz wykorzystany limit karty kredytowej. Zobowiązania medyczne sprawiają, że gospodarstwa domowe są bardziej wrażliwe na wzrost innych źródeł niezabezpieczonego długu (Domowitz i Sartain, 1999). Zadłużenie na kartach kredytowych jest uważane za silny determinant upadłości (Domowitz i Sartain, 1999; Zhu, 2011), ale na ogłoszenie upadłości wpływa również udział poszczególnych zobowiązań. Posiadanie karty kredytowej ma istotny wpływ na wzrost wydatków i nadmierne zadłużanie się (Zalega, 2014). Dostępny limit na karcie kredytowej daje możliwość realizacji potrzeb kredytowych w każdej chwili w ramach dostępnego limitu, pomimo że ten typ zadłużenia nie jest najtańszą opcją kredytową, jeżeli zobowiązanie nie jest regulowane w całości w okresie bezodsetkowym. Podobne możliwości daje limit odnawialny w rachunku czy też limit kredytowy, dzięki któremu można odroczyć transakcje i przelewy. Udostępnianie konsumentom limitów do wykorzystania w każdej chwili może prowadzić do nieracjonalnego korzystanie z tych produktów. Zhu (2011) zauważył również, że stosunek kredytów

hipotecznych, kredytów samochodowych oraz zadłużeń na karcie kredytowej do rocznych dochodów gospodarstwa domowego ma wpływ na złożenie wniosku o upadłość konsumencką. Posiadanie wyższego udziału zadłużenia z tytułu kart kredytowych do ogólnego zadłużenia zmniejsza prawdopodobieństwo złożenia wniosku o ogłoszenie upadłości (Brygała, 2022). Kolejnym kluczowym czynnikiem determinującym ogłaszanie upadłości konsumenckiej jest udział zadłużenia hipotecznego w aktywach. Wyższy wskaźnik tego zadłużenia przyczynia się do zwiększenia prawdopodobieństwa ogłoszenia upadłości konsumenckiej (Brygała, 2022). Qi i Yang (2009) analizowali straty wynikające z niewywiązania się z zobowiązań i doszli do wniosku, że stosunek kredytów hipotecznych do wartości nieruchomości stanowi istotny czynnik.

Alfaro i Gallardo (2012) zauważyli, że rodzaj produktu kredytowego odgrywa istotną rolę w kontekście upadłości konsumenckiej. Skiba i Tobacman (2019) zwrócili uwagę na to, że posiadanie pożyczek krótkoterminowych wpływa na decyzje o ogłoszeniu upadłości. Podobne wnioski w swoich badaniach potwierdzili Martin i Tong (2009) oraz Brygała (2022), wskazując, że posiadanie tego typu pożyczek przyczynia się do złożenia wniosku o upadłość, zgodnie z pogarszającą się sytuacją finansową gospodarstw domowych. Pożyczki krótkoterminowe mogą negatywnie wpływać na sytuację finansową konsumentów z powodu wysokich kosztów. Skiba i Tobacman (2019) podkreślają, że tego rodzaju pożyczki charakteryzują się jednymi z najwyższych stóp procentowych wśród różnych produktów kredytowych. Decyzja konsumentów o sięgnięciu po pożyczki krótkoterminowe, mimo ich wysokich kosztów, może wynikać z różnych czynników, takich jak niemożność uzyskania kredytu w banku, otrzymanie odmowy kredytu czy nawet obawy przed odrzuceniem wniosku. Takie sytuacje skłaniają niektórych do poszukiwania alternatywnych źródeł finansowania. Parabanki nie podlegają rejestracji oraz regulacjom takim jak banki co powoduje, że ich działalność jest obciążona wysokim ryzykiem (Gostomski i Michałowski, 2015). Udzielają pożyczek konsumentom o gorszym standingu finansowym (Gostomski i Michałowski, 2015). Zachowania związane ze spłatą długów lub konsekwencje, takie jak posiadanie zbyt wielu kredytów i nieodpowiednie zarządzanie budżetem domowym (np. opóźnione płatności), mogą stanowić wczesne sygnały ostrzegawcze o potencjalnej nadchodzącej upadłości (Himmelstein i in., 2005; Moorman i Garasky, 2008).

Warto zwrócić uwagę na czynniki związane z podejściem do wydawania pieniędzy, oszczędzania, zaciągania pożyczek, korzystania z kart kredytowych w ramach codziennych wydatków, kompulsywnych zakupów i oczekiwań dotyczących przyszłych zarobków, ponieważ są one uważane za związane z decyzjami o zadłużeniu i upadłości konsumentów

(Roberts i Jones, 2001; Korol, 2021). Niewłaściwe nawyki konsumpcyjne mogą prowadzić do zaciągania kredytów, nadmiernego korzystania z kart kredytowych i w konsekwencji do zobowiązań, które są zbyt duże do utrzymania płynności finansowej. Zachowanie konsumenta w kontekście spłaty długu może wpływać na ograniczenia kredytowe zarówno ze strony kredytodawcy, jak i wynikać z obaw konsumenta przed odmową udzielenia pożyczki. Zalega (2014) zauważył, że błędy i ignorancja konsumentów w zakresie zarządzania finansami w gospodarstwie domowym są jednymi z przyczyn niewypłacalności i upadłości konsumentów. Zachowania związane ze spłatą długu, takie jak opóźnienia, stanowią jedno z determinantów upadłości (Moorman i Garasky, 2008; Himmelstein i in., 2005). Posiadanie ograniczeń kredytowych jest również silnym determinantem złożenia wniosku o upadłość. Odmowa udzielenia pożyczki lub obawa przed złożeniem wniosku o pożyczkę (która nie zawsze jest uzasadniona i może wynikać z braku wiedzy finansowej) może pogłębić problemy finansowe gospodarstwa domowego i prowadzić do ogłoszenia upadłości konsumenckiej. Gospodarstwa domowe z ograniczeniami kredytowymi (osoby, które otrzymały odmowę kredytu w ciągu ostatniego roku, a także ci, którzy nie składali wniosków o kredyt z obawy przed odmową), oraz konsumenci z opóźnieniami w spłacie zobowiązań przekraczającymi 60 dni w ciągu ostatniego roku, mają wyższe ryzyko ogłoszenia upadłości (Brygała, 2022). Czas trwania opóźnień również może być kluczowy. Niemniej jednak nie każdy konsument, który ma opóźnienia, zdecyduje się złożyć wniosek o upadłość. Niektóre badania dotyczące upadłości konsumenckiej, analizujące modele upadłości konsumentów, nie uwzględniają opóźnień w spłacie jako jednego z determinantów prowadzących do upadłości. Tylko kilka badań przeanalizowało wpływ zachowania konsumentów pod kątem spłaty zobowiązań jako jednego z predyktorów upadłości konsumentów.

Wśród zmiennych wykorzystywanych w predykcji upadłości konsumenckiej znajdują również zastosowanie wskaźniki łączące różne rodzaje informacji w ocenie sytuacji finansowej gospodarstw domowych (Korol, 2024a; Korol, 2024b). Tego typu zestaw wskaźników, wykorzystywanych do oceny kondycji gospodarstw domowych, znajduje już odzwierciedlenie m.in. w analizie finansowej stosowanej w zarządzaniu finansami przedsiębiorstw (Korol, 2024b). Wśród wskaźników używanych w predykcji upadłości konsumenckiej można znaleźć zarówno te oparte wyłącznie na zmiennych finansowych (np. stosunek dochodu do zadłużenia, stosunek zadłużenia hipotecznego do aktywów, stosunek miesięcznych odsetek do miesięcznego dochodu, stosunek miesięcznego dochodu do zadłużenia na kartach kredytowych, stosunek zadłużenia na kartach kredytowych do dochodu), jak i wskaźniki oparte na zmiennych demograficznych (np. stosunek poziomu wykształcenia do wieku, stosunek

poziomu wykształcenia do liczby dzieci), a także tzw. wskaźniki mieszane, łączące zmienne demograficzne z finansowymi (np. stosunek poziomu wykształcenia do zadłużenia skorygowanego o dochód), stosunek wieku do zadłużenia skorygowanego o dochód) (Domowitz i Sartain, 1999; Korol i Fotiadis, 2022; Brygała, 2022; Korol, 2024a; Korol, 2024b; Brygała i Korol, 2024).

2.6. Przegląd modeli prognozowania ryzyka upadłości konsumenckiej

Wiele badań empirycznych zostało przeprowadzonych na temat przewidywania ryzyka upadłości przedsiębiorstw i niespłacanych kredytów (Barboza i in., 2023; Barboza i in., 2017; Garcia, 2022; Kovacova i in., 2019; Kovacova i Kliestikova, 2017; Letza i in., 2003; Wang i in., 2022), ale niewiele badań dotyczy upadłości konsumenckiej (Syed Nor i in., 2019; Korol, 2021; Korol i Fotiadis, 2022; Brygała, 2022; Sahiq i in., 2022; Korol, 2024a; Korol, 2024b; Brygała i Korol, 2024). Wynika to między innymi z czynników takich jak ograniczony dostęp do danych związanych z upadłością konsumencką. Choć istnieją badania analizujące czynniki wpływające na ryzyko upadłości konsumenckiej (Domowitz i Sartain, 1999; Fisher, 2019; Bauchet i Evans, 2019), to nie koncentrują się na predykcji konsumentów zagrożonych upadłością, lecz na identyfikacji ogólnych determinant tego zjawiska. Liczba badań dotyczących prognozowania upadłości konsumenckiej jest wciąż stosunkowo niewielka, jednak obserwuje się wyraźny wzrost zainteresowania tym zagadnieniem w literaturze przedmiotu. Rosnące znaczenie zjawiska upadłości konsumenckiej w ekonomii wynika między innymi ze zmieniającej się sytuacji makroekonomicznej i mikroekonomicznej gospodarstw domowych oraz z coraz wyraźniejszego wpływu tej instytucji na kredytobiorców, konsumentów, ich rodziny, społeczności lokalne i całą gospodarkę. Porównanie modeli prognozowania upadłości konsumenckiej przedstawiono w Tabeli 3.

Tabela 3. Przegląd modeli prognozowania upadłości konsumenckiej

Autorzy	Zbiór danych	Metoda	Skuteczność	Błąd I typu	Błąd II typu
Syed Nor i in. (2019)	Niezbilansowany zbiór danych	Drzewo decyzyjne	83.29%	-	-
	Zbilansowany zbiór danych – undersampling		70.90%	-	-
Korol (2021)	Zbilansowany zbiór danych - undersampling (Polska)	Regresja logistyczna	92.70%	6.20%	8.40%
		Analiza dyskryminacyjna	89.60%	8.20%	12.60%
		Drzewo decyzyjne	85.60%	15.80%	13%
	Zbilansowany zbiór danych - undersampling (Tajwan)	Regresja logistyczna	90.10%	10.60%	9.20%
		Analiza dyskryminacyjna	87.70%	13.80%	10.80%
		Drzewo decyzyjne	83.70%	17.40%	15.20%

Autorzy	Zbiór danych	Metoda	Skuteczność	Błąd I typu	Błąd II typu
Korol i Fotiadis (2022)	Zbilansowany zbiór danych - undersampling (Polska)	Logika rozmyta	93.90%	4.80%	7.40%
		Sztuczne sieci neuronowe	92.90%	5.80%	8.40%
		Algorytm genetyczny	92.30%	5.80%	9.60%
	Zbilansowany zbiór danych - undersampling (Tajwan)	Logika rozmyta	90.60%	7.80%	11%
		Sztuczne sieci neuronowe	89.30%	8.80%	12.60%
		Algorytm genetyczny	89.30%	8.80%	12.60%
Brygała (2022)	Niezbilansowany zbiór danych	Regresja logistyczna	95.98%	99.71%	0%
	Niezbilansowany zbiór danych - adjusting cut-off point		68.99%	31.18%	31.00%
	Zbilansowany zbiór danych – undersampling		69.85%	29.41%	30.88%
Sahiq i in. (2022)	Niezbilansowany zbiór danych	Regresja logistyczna	84.82%	-	-
	Zbilansowany zbiór danych - SMOTE		73.43%	-	-
Brygała i Korol (2024)	Zbilansowany zbiór danych – undersampling	SVM	70.76%	25.67%	32.65%
		Las losowy	73.11%	22.46%	31.12%
		AdaBoost	70.76%	27.81%	30.61%
		XGBoost	73.63%	24.60%	27.04%
		LightGBM	74.93%	21.93%	28.06%
		CatBoost	74.15%	22.99%	28.57%
Korol (2024a)	Zbilansowany zbiór danych - undersampling (Polska)	Logika rozmyta	94.20%	4.40%	7.20%
		System wczesnego ostrzegania	95.60%	3.00%	5.80%
	Zbilansowany zbiór danych - undersampling (Tajwan)	Logika rozmyta	90.60%	7.80%	11.00%
		System wczesnego ostrzegania	91.80%	6.80%	9.60%
Syed Nor i in. (2024)	Niezbilansowany zbiór danych	Regresja logistyczna	83,17%	-	-
	Zbilansowany zbiór danych – undersampling		71,14%	-	-
Korol (2024b)	Zbilansowany zbiór danych – undersamplin (Polska)	Perceptron wielowarstwowy	79,10%	26,20%	15,60%
			91,50%	9,60%	7,40%
			84,70%	19,80%	10,80%
		Rekurencyjna sieć neuronowa	78,20%	15,80%	15,80%
			93,10%	6,20%	7,60%
			88,90%	12,40%	9,80%
		Samoorganizująca się mapa cech	73,40%	30,80%	22,40%
			88,90%	9,20%	13%
			81,20%	22,40%	15,20%

Źródło: opracowanie własne na podstawie wyników analizy literatury przedmiotu.

Jedno z badań dotyczących prognozowania upadłości konsumenckiej zostało przeprowadzone przez Syed Nor i in. (2019). Autorzy analizowali skuteczność drzewa decyzyjnego w przewidywaniu upadłości konsumenckiej w Malezji, zarówno dla konsumentów, którzy mieli problem ze spłatą swoich zobowiązań oraz dla tych, którzy uregulowali swoje zobowiązania. Modele drzewa decyzyjnego oszacowano na zbiorze danych niezrównoważonych oraz po jego zrównoważeniu metodą undersampling. W przypadku niezrównoważonych danych model osiągnął wyższą dokładność (83,29%), jednak czułość dla klasy mniejszościowej wyosiła jedynie 6,62%, a specyficzność dla klasy większościowej – 99%. Po zrównoważeniu zbioru dokładność spadła do 70,90%, ale czułość dla klasy mniejszościowej wzrosła do 81,23%, a specyficzność dla klasy większościowej spadła do 60,57%. Czułość to prawdopodobieństwo, że model poprawnie przewidzi upadłość (Syed Nor i in., 2019). Pomimo wyższej dokładności, model dla niezrównoważonych danych nie jest skuteczny ze względu na duży błąd predykcji klasy mniejszościowej. Bardziej skuteczny model został przedstawiony dla zrównoważonej próby. Zbiór danych pochodził z autoryzowanej agencji zarządzania długiem w Malezji (Syed Nor i in., 2019).

Korol (2021) zastosował drzewo decyzyjne, regresję logistyczną i analizę dyskryminacyjną do przewidywania upadłości konsumenckiej na zbilansowanym zbiorze danych. Wyniki pokazują, że najwyższą całkowitą skuteczność dla gospodarstw domowych w Europie osiągnęła regresja logistyczna (92,70%), następnie analiza dyskryminacyjna (89,60%) i drzewo decyzyjne (85,60%). Dla gospodarstw domowych w Azji Wschodniej, najwyższą całkowitą skuteczność również osiągnęła regresja logistyczna (90,10%), następnie analiza dyskryminacyjna (87,70%) i drzewo decyzyjne (83,70%). Dla tej samej populacji Korol i Fotiadis (2022) porównali zbiory rozmyte, sztuczne sieci neuronowe oraz algorytmy genetyczne w prognozowaniu ryzyka upadłości konsumenckiej na zrównoważonym zbiorze danych. Zbiór danych został również zbilansowany metodą undersampling. Zbiory rozmyte przewyższyły sztuczne sieci neuronowe i algorytmy genetyczne. Dla gospodarstw domowych na Tajwanie zbiory rozmyte charakteryzują się 90,60% poprawnych klasyfikacji, natomiast dla europejskich konsumentów wartość ta wynosi 93,90%. Sztuczne sieci neuronowe i algorytmy genetyczne uzyskały całkowitą skuteczność wynoszącą 89,30% dla gospodarstw domowych na Tajwanie i 92,90% dla gospodarstw domowych w Polsce.

Inne badanie wykazało, że predykcyjna skuteczność modelu regresji logistycznej opartego na zrównoważonym zbiorze danych jest wyższa w porównaniu do modelu opartego na niezrównoważonym zbiorze danych (Brygała, 2022). W badaniu zastosowano dwie metody

radzenia sobie z niezrównoważonymi danymi: undersampling oraz dostosowanie optymalnej wartości progowej (cut-off). Badanie opiera się na zbiorze danych z the Survey of Consumer Finances ze Stanów Zjednoczonych. Całkowita skuteczność modelu predykcyjnego na niezrównoważonym zbiorze danych wyniosła 95,98%, z błędem typu I wynoszącym 99,71% i błędem typu II wynoszącym 0%. Całkowita skuteczność modelu predykcyjnego na zrównoważonym zbiorze danych (technika undersampling) wyniosła 69,85%, z błędem typu I wynoszącym 29,41% i błędem typu II wynoszącym 30,88%. Po dostosowaniu punktu odcięcia do niezrównoważonego zbioru danych jako jednej z metod radzenia sobie z nimi (Mihalovič, 2016), całkowita skuteczność modelu osiągnęła 68,99%, z błędem typu I wynoszącym 31,18% i błędem typu II wynoszącym 31%.

Sahiq i in. (2022) również badali użyteczność regresji logistycznej w prognozowaniu upadłości konsumenckiej i porównywali zbilansowane oraz niezbilansowane zbiory danych. Zbiór danych został zbilansowany techniką SMOTE. Całkowita skuteczność modelu predykcyjnego na niezrównoważonym zbiorze danych wyniosła 84,82%, z czułością (dla klasy większościowej) wynoszącą 100% i swoistością (dla klasy mniejszościowej) wynoszącą 0%. Całkowita skuteczność modelu predykcyjnego na zrównoważonym zbiorze danych wyniosła 73,43%, z czułością (dla klasy większościowej) wynoszącą 69,50% i swoistością (dla klasy mniejszościowej) wynoszącą 77,35%. Badanie opiera się na zbiorze danych z programu zarządzania długiem, który został przeprowadzony w Malezji.

Brygała i Korol (2024) w swoim badaniu analizowali skuteczność algorytmów SVM, lasu losowego, AdaBoost, XGBoost, LightGBM oraz Catboost na zbilansowanym zbiorze danych przy użyciu metody undersamplingu. Najwyższą skuteczność osiągnęły algorytmy LightGBM, XGBoost oraz CatBoost, natomiast najniższą SVM i AdaBoost. Najwyższą wartość AUC osiągnęły algorytmy lasu losowego, LightGBM oraz CatBoost, natomiast najniższą SVM i AdaBoost. Najniższy błąd I typu miały algorytmy LightGBM, lasu losowego i CatBoost, natomiast najwyższy AdaBoost i SVM. Najniższy błąd II typu osiągnęły algorytmy XGBoost, LightGBM i CatBoost, natomiast najwyższy SVM i lasu losowego.

W kolejnym badaniu Korol (2024a) zaproponował system wczesnego ostrzegania w celu prognozowania ryzyka upadłości konsumenckiej, składający się z trzech modeli, które na koniec zostały połączone w jeden system wczesnego ostrzegania. Zaproponowane rozwiązanie wykorzystuje zarówno dane mikroekonomiczne jak i makroekonomiczne. W pierwszym modelu uwzględniono zmienne demograficzne i finansowe konsumentów, w drugim zmienne makroekonomiczne przewidujące zmianę w liczbie niespłaconych kredytów, a w trzecim

zmienne mające na celu prognozę kursu waluty (stosunek waluty badanego kraju do USD). Systemy wczesnego ostrzegania osiągnęły wyższą skuteczność niż pojedyncze modele.

Syed Nor i in. (2024) w swoim badaniu analizowali skuteczność regresji logistycznej w przewidywaniu upadłości konsumenckiej w Malezji dla konsumentów, którzy mieli problem ze spłatą swoich zobowiązań, oraz dla tych, którzy je uregulowali, zarówno na niezrównoważonym, jak i zrównoważonym zbiorze danych. W artykule zastosowano technikę losowego undersamplingu. Całkowita skuteczność modelu predykcyjnego dla próby walidacyjnej na danych niezbilansowanych wynosiła 83,17%, wskaźnik błędu klasyfikacji - 16,82%, swoistość - 8,38% a czułość - 98,49%. W przypadku zbilansowanego zbioru danych całkowita skuteczność wynosiła 71,14%, wskaźnik błędu klasyfikacji - 28,86%, swoistość - 78,43%, a czułość - 63,84%.

Korol (2024b) w swoim badaniu opracował dziewięć modeli prognozowania upadłości konsumenckiej w Polsce z wykorzystaniem trzech typów sztucznych sieci neuronowych: perceptronu wielowarstwowego, rekurencyjnej sieci neuronowej oraz samoorganizującej się mapy cech. W badaniu zastosowano trzy zestawy zmiennych. Pierwszy zawierał pojedyncze zmienne demograficzne oraz finansowe. Drugi obejmował wskaźniki opracowane na podstawie danych demograficznych i finansowych. W trzecim zestawie wykorzystano zmienne z dwóch poprzednich zbiorów. Najwyższą skuteczność w przypadku pierwszego zestawu zmiennych osiągnął perceptron wielowarstwowy, natomiast w drugim i trzecim rekurencyjne sieci neuronowe. Najniższa skuteczność dla wszystkich trzech zestawów zmiennych odnotowano w przypadku samoorganizujących się map cech.

3. Modele prognozowania ryzyka upadłości konsumenckiej w Stanach Zjednoczonych

3.1. Założenia do przeprowadzonych badań

W ramach niniejszego badania we wstępie pracy sformułowano cele szczegółowe, pytania badawcze oraz hipotezy. Jeden z celów szczegółowych dotyczący przeglądu literatury międzynarodowej na temat modeli oraz zmiennych wykorzystywanych do prognozowania ryzyka upadłości konsumenckiej został zrealizowany w poprzednim rozdziale. Niniejszy rozdział koncentruje się na realizacji kolejnych celów szczegółowych, tj.:

- Oszacowanie i weryfikacja skuteczności modeli indywidualnych prognozowania ryzyka upadłości konsumenckiej, w tym zarówno modelu regresji logistycznej, jak i innych modeli uczenia maszynowego (drzewo decyzyjne, las losowy, maszyny wektorów nośnych, Adaptive Boosting, Gradient Boosting Classifier, Extreme Gradient Boosting, Light Gradient Boosting Machine, Categorical Boosting oraz sieci neuronowe).
- Oszacowanie i weryfikacja skuteczności klasyfikatorów zespołowych z wykorzystaniem metod: uśredniania, głosowania oraz stacking.
- Porównanie skuteczności klasyfikatorów indywidualnych oraz zespołowych w prognozowaniu ryzyka upadłości konsumenckiej.
- Ocena skuteczności modeli prognozowania ryzyka upadłości konsumenckiej przy wykorzystaniu różnych miar oceny skuteczności, takich jak: całkowita skuteczność, błąd I typu, błąd II typu, F1, krzywa ROC z wyliczonym wskaźnikiem AUC oraz wskaźnik Giniego.
- Identyfikacja czynników mikroekonomicznych wpływających na ryzyko upadłości konsumenckiej przy wykorzystaniu metod interpretacji modeli, takich jak analiza istotności cech, technika SHAP oraz LIME.
- Próba opracowania nowego rodzaju wskaźników integrujących różne rodzaje informacji (demograficzne i finansowe) w celu oceny ryzyka upadłości konsumenckiej.

Realizacja powyższych celów pozwoli na odpowiedź na pytania badawcze oraz weryfikację hipotez. W poprzednim rozdziale udzielono odpowiedzi na dwa pytania badawcze dotyczące najpopularniejszych algorytmów i zmiennych wykorzystywanych w prognozowaniu upadłości konsumenckiej, natomiast w niniejszym rozdziale skoncentrowano się na odpowiedzi na następujące pytania badawcze:

PB3: Które algorytmy wykazują najwyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej?

PB4: Czy wykorzystanie klasyfikatorów zespołowych zwiększa skuteczność prognozowania ryzyka upadłości konsumenckiej?

PB5: Jakie zmienne mają największy wpływ na ryzyko upadłości konsumenckiej?

PB6: Czy wykorzystanie wskaźników integrujących zmienne demograficzne i finansowe zwiększa skuteczność modeli prognozujących ryzyko upadłości konsumenckiej?


Wyznaczenie celu głównego, celów szczegółowych oraz pytań badawczych umożliwi również weryfikację sformułowanych następujących hipotez badawczych:

H1: Modele typu boosting, w tym Light Gradient Boosting Machine, Extreme Gradient Boosting oraz Categorical Boosting, wykazują wyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej w porównaniu z popularnymi algorytmami indywidualnymi, takimi jak regresja logistyczna, maszyna wektorów nośnych oraz drzewo decyzyjne.

H2: Zastosowanie nowego rodzaju wskaźników, uwzględniających zmienne demograficzne oraz zmienne finansowe, zwiększa skuteczność modeli prognozowania ryzyka upadłości konsumenckiej.

H3: Klasyfikatory zespołowe oparte na łączeniu wyników modeli indywidualnych, charakteryzują się wyższą zdolnością do poprawnego przewidywania upadłości konsumenckiej niż klasyfikatory indywidualne.

W niniejszym rozdziale przedstawiono wyniki badań dotyczących opracowania modeli prognozowania ryzyka upadłości konsumenckiej. Kluczowe etapy budowy modeli w ramach niniejszego badania obejmują (rysunek 21): zrozumienie danych (zebranie i wstępna analiza danych), przygotowanie danych (wstępne przetwarzanie), modelowanie (selekcja zmiennych, budowa modeli wraz z dostosowaniem hiperparametrów, ocena skuteczności i interpretacja modeli), a także dokumentację całego procesu.



Rysunek 21. Kluczowe etapy budowy oszacowanych modeli

Źródło: opracowanie własne.

Badanie opiera się na danych pochodzących z 42 495 ankiet przeprowadzonych w latach 2001-2022 w ramach the Survey of Consumer Finances (SCF), które realizowane są cyklicznie co trzy lata. SCF to badanie prowadzone w Stanach Zjednoczonych, które obejmuje różnorodne cechy gospodarstw domowych, w tym aspekty demograficzne, behawioralne i finansowe. Braki danych uzupełniono za pomocą techniki wielokrotnej imputacji. Zbiór danych zawiera zmienną zależną, której wartość 1 przypisano gospodarstwom domowym, które w ciągu ostatnich pięciu lat przed przeprowadzeniem ankiety złożyły wniosek o upadłość, natomiast wartość 0 - pozostałym. Przed selekcją zmiennych zbiór danych zawierał 353 zmienne opisujące konsumentów posiadających jakiegokolwiek zadłużenie.

Zestaw danych jest silnie niezrównoważony, z przewagą konsumentów, którzy nie zdecydowali się na upadłość (klasa negatywna). Przed zastosowaniem undersamplingu w zbiorze znajdowało się 23 180 konsumentów bez upadłości oraz 1005 konsumentów, którzy złożyli wniosek o upadłość, co daje proporcję upadłości do liczby wszystkich konsumentów na poziomie 4,34%. W związku z tym zastosowano metodę undersamplingu, aby zrównoważyć liczbę konsumentów, którzy złożyli wniosek o upadłość, i tych, którzy tego nie zrobili. Ostatecznie uzyskano zbiór danych obejmujący 1005 konsumentów, którzy złożyli wniosek o upadłość, oraz 1005 konsumentów, którzy tego nie zrobili, co daje łącznie 2010 obserwacji. Dane zostały następnie podzielone na zbiór uczący i testowy, aby uniknąć przeuczenia modeli oraz błędów w ocenie ich skuteczności. Zbiór danych został podzielony w proporcji 80% do 20%, co oznacza odpowiednio 1608 konsumentów w zbiorze treningowym i 397 w zbiorze testowym. Taki podział zapewnił najwyższą efektywność procesu uczenia. Dzięki zastosowanym technikom uzyskano zrównoważony zbiór danych.

Przewidywanie rzadkich zdarzeń, takich jak upadłości, bywa trudne z powodu potencjalnych błędów w szacowaniu prawdopodobieństw. Bez zastosowania metod radzenia sobie z niezrównoważonym zestawem danych, klasa mniejszościowa może być ignorowana w procesie przewidywania. Badacze zaproponowali kilka metod radzenia sobie z tym wyzwaniem, zarówno na poziomie algorytmu, jak i danych (Yen i Lee, 2009). W niniejszym badaniu zastosowano metodę undersamplingu, aby zrównoważyć liczbę konsumentów. Jest to metoda powszechnie stosowana w obszarze przewidywania upadłości (Syed Nor i in., 2019; Korol, 2021). Modele były oceniane dla różnych proporcji między próbą uczącą a testową, aby z jednej strony zmaksymalizować proces uczenia, ale z drugiej strony zapewnić wiarygodność testowania. Poprzednie badania (Khare i Sait, 2018; Schonlau i Zou, 2020) wykazały, że użycie większej próby treningowej, może prowadzić do wyższej efektywności modelu i umożliwić zoptymalizowanie wielkości próby treningowej. Jest to szczególnie istotne w sytuacji, gdy nie

dysponujemy bardzo dużym zbiorem danych, co zostało potwierdzone w niniejszym badaniu. Ważne jest dostosowanie podziału próby, uwzględniając problem badawczy, proporcje między klasą mniejszościową i większościową oraz wielkość zbioru danych.

W etapach przetwarzania wstępnego oraz budowy modeli wykorzystano pakiety dostępne w języku Python. Ponadto dane zostały przetworzone za pomocą StandardScaler. Jest to technika służąca do standaryzacji cech poprzez usunięcie średniej i skalowanie do wariancji jednostkowej (Le i in., 2018). Przy budowie modeli przeprowadzono selekcję cech, wykorzystując model lasu losowego do oceny ich ważności oraz macierz korelacji do eliminacji zmiennych silnie skorelowanych ze sobą. Ostatecznie, ze zbioru danych zawierającego 353 zmienne wyselekcjonowano 20 zmiennych, które posłużyły do opracowania 25 zmiennych oraz trzech zestawów zmiennych. W procesie budowy zestawów zmiennych wykorzystano następujące zmienne, zaprezentowane w tabeli 4.

Tabela 4. Opis zmiennych wykorzystanych do budowy modeli

Zmienna	Opis
AGE (X1)	Wiek: poniżej 35 lat, 35-44 lat, 45-54 lat, 55-64 lat, 65-74 lat, 75 i więcej lat
AGE_CONSPAY_INC_MO (X2)	Wskaźnik relacji wieku w stosunku do udziału całkowitych miesięcznych spłat zadłużenia konsumenckiego do miesięcznego dochodu
AGE_REVPAY_TPAY (X3)	Wskaźnik relacji wieku w stosunku do udziału całkowitych miesięcznych spłat zobowiązań odnawialnych do sumy wszystkich miesięcznych płatności związanych z zadłużeniami
CONSPAY_INC_MO (X4)	Udział całkowitych miesięcznych spłat zadłużenia konsumpcyjnego (niezwiązanego z hipoteką ani zadłużeniem odnawialnym) w stosunku do miesięcznego dochodu
CONSPAY_TPAY (X5)	Udział całkowitych miesięcznych spłat zadłużenia konsumpcyjnego, które nie obejmuje kredytów hipotecznych ani zadłużenia odnawialnego, w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami
EDU (X6)	Poziom wykształcenia: brak wykształcenia średniego, wykształcenie średnie, szkoła policealna lub dyplom zawodowy, licencjat lub wyższy stopień naukowy
EDU_AGE (X7)	Wskaźnik relacji poziomu wykształcenia w stosunku do wieku
EDU_DEBT_INCOME (X8)	Wskaźnik relacji poziomu wykształcenia w stosunku do udziału zadłużenia do dochodu
EDU_KIDS (X9)	Wskaźnik relacji poziomu wykształcenia w stosunku do liczby dzieci
EDU_MORTPAY_INC_MO (X10)	Wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu
FOODHOME_INCOME (X11)	Udział rocznych wydatków na żywność w stosunku do rocznego dochodu
HOUSE (X12)	Posiadanie nieruchomości
INCOME_ASSET (X13)	Udział dochodu w stosunku do całkowitych aktywów
KIDS (X14)	Liczba dzieci
LATE60 (X15)	Opóźnienia w spłacie zobowiązań powyżej 60 dni
MORTHEL_ASSET (X16)	Udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów

Zmienna	Opis
MORTPAY_INC_MO (X17)	Udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu
NETWORTH_INCOME (X18)	Udział wartości netto majątku (różnica między aktywami a długiem) do dochodu
NFIN_DEBT (X19)	Udział całkowitych aktywów niefinansowych w stosunku do długu
REVPAY_INC_MO (X20)	Udział całkowitych miesięcznych spłat zobowiązań odnawialnych (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu
REVPAY_TPAY (X21)	Udział całkowitych miesięcznych spłat zobowiązań odnawialnych w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami
SAVED (X22)	Posiadanie wydatków mniejszych niż dochody
SAVING_DEBT (X23)	Udział oszczędności w stosunku do długu
SAVING_INC_MO (X24)	Udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu
TURNDOWN (X25)	Odmowa udzielenia kredytu

Źródło: opracowanie własne.

W niniejszym badaniu modele oszacowano dla trzech zestawów zmiennych (tabela 5):

Tabela 5. Grupy zmiennych wykorzystane do budowy modeli

Lp.	I zestaw zmiennych	II zestaw zmiennych	III zestaw zmiennych
1	TURNDOWN (X25)	TURNDOWN (X25)	TURNDOWN (X25)
2	LATE60 (X15)	LATE60 (X15)	LATE60 (X15)
3	NETWORTH INCOME (X18)	NETWORTH INCOME (X18)	NETWORTH INCOME (X18)
4	INCOME ASSET (X13)	INCOME ASSET (X13)	INCOME ASSET (X13)
5	KIDS (X14)	HOUSE (X12)	KIDS (X14)
6	EDU (X6)	MORTHEL ASSET (X16)	EDU (X6)
7	HOUSE (X12)	FOODHOME INCOME (X11)	HOUSE (X12)
8	MORTHEL ASSET (X16)	SAVED (X22)	MORTHEL ASSET (X16)
9	FOODHOME INCOME (X11)	SAVING DEBT (X23)	FOODHOME INCOME (X11)
10	NFIN DEBT (X19)	CONSPAY INC MO (X4)	NFIN DEBT (X19)
11	SAVED (X22)	MORTPAY_INC_MO (X17)	SAVED (X22)
12	SAVING DEBT (X23)	REVPAY_INC_MO (X20)	SAVING DEBT (X23)
13	CONSPAY_INC_MO (X4)	SAVING_INC_MO (X24)	CONSPAY_INC_MO (X4)
14	MORTPAY_INC_MO (X17)	CONSPAY_PAY (X5)	MORTPAY_INC_MO (X17)
15	REVPAY_INC_MO (X20)	REVPAY_TPAY (X21)	REVPAY_INC_MO (X20)
16	SAVING_INC_MO (X24)	EDU_AGE (X7)	SAVING_INC_MO (X24)
17	CONSPAY_TPAY (X5)	EDU_DEBT_INCOME (X8)	CONSPAY_TPAY (X5)
18	REVPAY_TPAY (X21)	EDU_KIDS (X9)	REVPAY_TPAY (X21)
19		EDU_MORTPAY_INC_MO (X10)	AGE (X1)
20		AGE_CONSPAY_INC_MO (X2)	
21		AGE_REVPAY_TPAY (X3)	

Źródło: opracowanie własne.

Pierwszy wariant zawiera 18 wyselekcjonowanych zmiennych wejściowych do modeli. Zmienne niezależne, takie jak wiek, płeć, stan cywilny i rasa, nie zostały uwzględnione w budowie modeli opartych na tym zestawie. Zastosowanie tych zmiennych mogłoby prowadzić do dyskryminacji konsumentów ze względu na Equal Credit Opportunity Act w Stanach Zjednoczonych (Brotcke, 2022). W Stanach Zjednoczonych pożyczkodawcom nie wolno dyskryminować konsumentów ze względu na takie cechy, jak rasa, kolor skóry, religia, pochodzenie narodowe, płeć, stan cywilny czy wiek (CFPB, 2022). Regulacje te mają na celu ochronę konsumentów poprzez eliminację niesprawiedliwych i dyskryminacyjnych praktyk (Brotcke, 2022). Kredytodawcy mogą brać pod uwagę różnorodne informacje przy ocenie wnioskodawców, o ile nie prowadzi to do dyskryminacji na podstawie zakazanych kryteriów (Federal Reserve, 2021). Kredytodawca nie może między innymi uwzględniać żadnych zakazanych cech, takich jak wiek (o ile wnioskodawca jest wystarczająco dorosły, by zawrzeć ważną umowę) ani wykorzystywać informacji o macierzyństwie, wychowywaniu dzieci ani statystyk w celu oceny czy dochody wnioskodawcy mogą zostać przerwane lub zmniejszone (Federal Reserve, 2021). Istnieją jednak pewne wyjątki i jednym z nich jest możliwość uwzględnienia wieku w systemie oceny kredytowej, pod warunkiem, że nie działa to na niekorzyść wnioskodawców w wieku 62 lat lub starszych (CFPB, 2022). Pożyczkodawcy mogą powiązać wiek z innymi informacjami, w celu oceny zdolności kredytowej konsumenta (CFPB, 2022). Ponadto, kredytodawca może uwzględnić zatrudnienie oraz planowany czas przejścia na emeryturę, aby ocenić, czy dochód będzie wystarczający przez cały okres spłaty kredytu również w trakcie emerytury (Consumer Finance, 2022). Przepisy chronią konsumentów, zakazując niesprawiedliwych i dyskryminacyjnych praktyk (Brotcke, 2022). Zabraniając jednak jawnej i celowej dyskryminacji przy użyciu bezpośrednich i bliskich wskaźników zawierających zakazane zmienne, w związku z czym pracownicy sektora bankowego powszechnie wiedzą, że wiek, płeć, etniczność i pochodzenie narodowe powinno być wykluczone z zestawu zmiennych używanych do opracowywania polityk oceny ryzyka kredytowego oraz modeli scoringowych i ustalania cen (Brotcke, 2022). Brotcke (2022) zauważył również, że uczenie maszynowe w porównaniu do tradycyjnych modeli regresyjnych, mogą ograniczyć ryzyko dyskryminacji poprzez redukcję uznaniowych i subiektywnych decyzji.

W drugim zestawie, oprócz zmiennych uwzględnionych w pierwszym zestawie, wykorzystano również wskaźniki łączące różne rodzaje informacji w ocenie sytuacji finansowej gospodarstw domowych. Ponadto na etapie selekcji, po dodaniu nowych wskaźników usunięto zmienne silnie skorelowane. W procesie tworzenia wskaźników

uwzględniono zmienną wiek. Wiek może być powiązany z etapem życia, poziomem dochodów, skłonnością do zadłużenia oraz oszczędzania, a także integrować cechy demograficzne z aspektami finansowymi. Ponadto stanowi istotny czynnik wpływający na prawdopodobieństwo upadłości i jest powszechnie stosowaną zmienną w badaniach dotyczących przewidywania upadłości (Syed Nor i in.,2019; Brygała 2022; Korol 2024). Bauchet i Evans (2019) zwrócili uwagę na nieliniową zależność między upadłością a wiekiem - prawdopodobieństwo upadłości rośnie wraz z wiekiem, ale w coraz mniejszym tempie. Łącznie drugi zestaw zmiennych obejmuje 21 wyselekcjonowanych cech, w tym sześć nowych wskaźników, wykorzystujących zarówno wskaźniki zaproponowane w literaturze przedmiotu (Korol, 2024a; Korol, 2024b; Korol, 2021) jak i nowe, opracowane na potrzeby niniejszego badania.

Aby zweryfikować, czy poprawa skuteczności drugiego zestawu zmiennych nie wynikała wyłącznie z uwzględnienia zmiennej wiek w nowych wskaźnikach, oszacowano dodatkowe modele dla trzeciego zestawu zmiennych, który obejmował zmienne z pierwszego zestawu oraz dodatkowo zmienną wiek. Łącznie trzeci zestaw zmiennych obejmuje 19 wyselekcjonowanych zmiennych.

Autorka wykorzystała dziesięć indywidualnych algorytmów do prognozowania upadłości konsumenckiej: regresję logistyczną, maszynę wektorów nośnych, drzewo decyzyjne, las losowy, AdaBoost, Gradient Boosting Classifier, XGBoost, LightGBM, CatBoost oraz sieci neuronowe dla trzech wyselekcjonowanych zbiorów zmiennych. Ponadto oszacowano dziesięć klasyfikatorów zespołowych bazujących na pojedynczych klasyfikatorach wykorzystujących metody: uśredniania, głosowania oraz stacking.


Dostrajanie hiperparametrów przeprowadzono za pomocą walidacji krzyżowej. Celem tego procesu było wybranie optymalnych hiperparametrów, ponieważ ich dobór ma istotny wpływ na dokładność oraz wydajność modeli. Wśród najpopularniejszych metod wykorzystywanych do doboru hiperparametrów znajdują się: GridSearchCV, RandomizedSearchCV oraz Optuna – narzędzia dostępne w języku Python. W niniejszym badaniu porównano czas działania i skuteczność metod w celu wyboru najbardziej optymalnego narzędzia zarówno pod względem skuteczności wyników, jak i efektywności obliczeniowej. Jest to szczególnie istotne w przypadku analiz obejmujących duże zbiory danych lub wymagających budowy wielu modeli, gdzie czas i zasoby obliczeniowe odgrywają również istotną rolę. W przypadku algorytmu XGBoost czas dostrajania hiperparametrów za pomocą GridSearchCV wyniósł 5 godzin 55 minut i 53 sekundy, przy 3-krotnej walidacji krzyżowej oraz 19683 testowanych kombinacji hiperparametrów, co łącznie dało 59049 trenowań. Dla RandomizedSearchCV czas dostrajania wyniósł 1 minutę i 8 sekund, przy 3-krotnej walidacji

krzyżowej oraz 50 kombinacjach hiperparametrów, co łącznie dało 150 trenowań modelu. Dla obu metod (GridSearchCV oraz RandomizedSearchCV) wskazane zostały dokładnie te same zestawy hiperparametrów wraz z wartościami, które zostały poddane testom. Technika Optuna wykorzystywała znacznie szerszy zakres wartości dla tych samych hiperparametrów. Dla metody Optuna czas dostrajania hiperparametrów wynosił 1 minutę, przy 50 próbach optymalizacji i 3-krotnej walidacji krzyżowej. Porównując wyniki uzyskane przez modele, zauważono, że były one na podobnym poziomie. Wskaźnik F1 dla GridSearchCV wynosił 0,7351, dla RandomizedSearchCV 0,7333, a dla Optuna 0,7316. Różnice między wynikami odpowiadały jednej błędnej predykcji konsumenta. W niniejszych badaniach, biorąc pod uwagę czas, dostrajanie hiperparametrów przeprowadzono z wykorzystaniem metod Optuna oraz RandomizedSearchCV.

3.2. Charakterystyka próby badawczej

Badani konsumenci różnią się między sobą pod względem cech demograficznych, takich jak wiek czy wykształcenie, a także pod względem posiadanego majątku czy też zobowiązań. W dalszej części tego podrozdziału przedstawiono charakterystykę próby z uwzględnieniem wybranych zmiennych demograficznych oraz finansowych. W próbie badawczej najliczniejszą grupę stanowili konsumenci w wieku 35-44 lat, stanowiący 26,72% spośród wszystkich badanych (537 osób) oraz w wieku 45-54 lat, stanowiący 24,48% spośród badanych (492 osoby). Na wykresie 13 przedstawiono rozkład wieku wraz z odpowiadającą liczbą przypadków, z podziałem na zmienną celu.


Wykres 13. Udział procentowy kategorii wiekowych wraz z odpowiadającą liczbą przypadków względem upadłości konsumenckiej



Źródło: opracowanie na podstawie wyników badań własnych.

Natomiast najliczniejszą grupą pod względem wykształcenia stanowili konsumenci ze średnim wykształceniem, stanowiący 32,54% spośród wszystkich konsumentów (654 osoby) oraz konsumenci z ukończoną szkołą policealną lub dyplomem zawodowym, stanowiący 30,50% wśród badanych osób (613 osób). Na wykresie 14 przedstawiono rozkład poziomów edukacji wraz z odpowiadającą liczbą przypadków, z podziałem na zmienną celu.

Wykres 14. Udział procentowy poziomu wykształcenia wraz z odpowiadającą liczbą przypadków względem upadłości konsumenckiej



Źródło: opracowanie na podstawie wyników badań własnych.

Wśród gospodarstw domowych, które złożyły wniosek o upadłość konsumencką, 39,90% miało opóźnienia w spłacie zobowiązań przekraczające 30 dni, a 21,99% opóźnienia powyżej 60 dni. W przypadku konsumentów, którzy nie składali wniosku o upadłość konsumencką, wartości te były istotnie niższe i wynosiły odpowiednio 22,09% oraz 7,56%. Odmowę udzielenia kredytu otrzymało 43,18% konsumentów ubiegających się o upadłość oraz 18,01% spośród tych, którzy nie złożyli wniosku. Ponadto 38,01% konsumentów, którzy wnioskowali o upadłość, nie ubiegało się o kredyt z obawy przed odmową, podczas gdy w grupie osób, które nie składały takiego wniosku, odsetek ten wynosił 16,92%. Łącznie 60,70% konsumentów wnioskujących o upadłość doświadczyło odmowy udzielenia kredytu lub nie wnioskowało o niego z obawy przed odrzuceniem, w porównaniu do 27,46% konsumentów, którzy nie złożyli wniosku o upadłość. Analiza związku między upadłością a posiadaniem nieruchomości wskazuje, że 51,84% konsumentów, którzy złożyli wniosek o upadłość, była

właścicielami mieszkań lub domów. Wśród osób, które nie zdecydowały się na upadłość, odsetek ten wynosił 67,36%. Pod względem wykształcenia 19% konsumentów, którzy złożyli wniosek o upadłość, posiadało wykształcenie wyższe, a 11,74% miało wykształcenie niższe niż średnie. Wśród osób, które nie składały wniosku o upadłość, 34,63% posiadało wykształcenie wyższe, a 8,56% nie ukończyło szkoły średniej. Odsetek konsumentów z wydatkami niższymi niż dochody wynosił 56,02% wśród osób, które nie wnioskowały o upadłość, oraz 43,48% wśród tych, którzy złożyli taki wniosek.


W kolejnych dwóch podrozdziałach zaprezentowano wyniki modeli prognozowania ryzyka upadłości konsumenckiej oszacowanych dla dwóch pierwszych zestawów zmiennych, wraz z interpretacją globalną i lokalną, przy czym lokalna interpretacja została wykonana dla tych samych dwóch konsumentów we wszystkich oszacowanych modelach. Wyniki modeli opartych na trzecim zestawie zmiennych zostały uwzględnione zarówno w omówieniu wyników indywidualnych modeli oszacowanych na podstawie drugiego zestawu, jak i w analizie porównawczej wszystkich modeli.

3.3. Modele prognozowania ryzyka upadłości konsumenckiej oszacowane dla pierwszego zestawu zmiennych

3.3.1. Regresja logistyczna

W niniejszym podrozdziale przedstawiono wyniki badań nad modelem prognozowania ryzyka upadłości konsumenckiej z wykorzystaniem regresji logistycznej. Model został oszacowany dla pierwszego zestawu zmiennych. Całkowita skuteczność modelu regresji logistycznej wynosi 68,78% dla próby uczącej oraz 71,89% dla próby testowej. Błąd I typu wynosi 32,91%, a błąd II typu wynosi 29,56% dla próby uczącej. Dla próby testowej błąd pierwszego typu wynosi 33,01%, a błąd drugiego typu wynosi 22,80%. Miara F1 dla próby uczącej wynosi 0,70 dla klasy 0 i 0,68 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,73 dla klasy 0 i 0,71 dla klasy 1. Miara Giniego wynosi 0,50 dla próby uczącej i 0,55 dla próby testowej. AUC wynosi 0,75 dla próby uczącej i 0,77 dla próby testowej. Na wykresie 15 przedstawiono krzywą ROC (Receiver Operating Characteristic), ilustrującą zdolność modelu do rozróżniania klas. Na osi pionowej (True Positive Rate) przedstawiono odsetek poprawnie sklasyfikowanych przypadków, natomiast na osi poziomej (False Positive Rate) odsetek fałszywie pozytywnych klasyfikacji. Wyższa wartość na osi Y wskazuje większą liczbę trafnych klasyfikacji pozytywnych (True Positives) w porównaniu z liczbą błędnie zaklasyfikowanych jako negatywne (False Negatives) (Shetty i in., 2022). Im bliżej lewego górnego rogu wykresu znajduje się krzywa, tym wyższa jest skuteczność predykcyjna modelu.

Wykres 15. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem regresji logistycznej



Źródło: opracowanie na podstawie wyników badań własnych.

Współczynniki regresji oraz błędy standardowe dla modelu regresji logistycznej przedstawiono w tabeli 6. Wśród predyktorów upadłości znajdują się: odmowa udzielenia kredytu (X25), posiadanie nieruchomości (X12), opóźnienia w spłacie zobowiązań (X15), relacja miesięcznej płatności kredytu hipotecznego (X17), miesięcznej spłaty zadłużenia konsumpcyjnego (X4), miesięcznej spłaty zadłużenia odnawialnego (X20) oraz środków z kont oszczędnościowych (X24) do miesięcznego dochodu, udział miesięcznych spłat zadłużenia konsumpcyjnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X5), udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X16), poziom wykształcenia (X6) oraz posiadanie wydatków mniejszych niż dochody (X22).

Tabela 6. Wyniki modelu regresji logistycznej opracowane dla pierwszego zestawu zmiennych


Zmienna	Coef	S.E.
const	-0.0199	0.056
KIDS (X14)	0.0844	0.057
SAVED (X22)	-0.1464*	0.057
LATE60 (X15)	0.2762***	0.061
TURNDOWN (X25)	0.4611***	0.057
EDU (X6)	-0.2409***	0.057
HOUSE (X12)	-0.3662***	0.09
MORTHEL_ASSET (X16)	0.2912**	0.092
MORTPAY_INC_MO (X17)	0.3369*	0.135
CONSPAY_INC_MO (X4)	-0.2452*	0.108
REVPAY_INC_MO (X20)	-0.2698*	0.079
CONSPAY_TPAY (X5)	0.2192*	0.097
REVPAY_TPAY (X21)	0.0389	0.082
INCOME_ASSET (X13)	0.0275	0.063
NETWORTH_INCOME (X18)	-0.1731	0.126
SAVING_INC_MO (X24)	-0.2059*	0.086
SAVING_DEBT (X23)	0.2179	0.192
NFIN_DEBT (X19)	-0.0272	0.073
FOODHOME_INCOME (X11)	0.0561	0.091
* p < 0.05, ** p < 0.01, *** p < 0.001. N = 1608		

Źródło: opracowanie na podstawie wyników badań własnych.

3.3.2. Maszyna wektorów nośnych

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM dla pierwszego zestawu zmiennych. Całkowita skuteczność modelu wynosi 73,20% dla próby uczącej oraz 72,89% dla próby testowej. Błąd I typu wynosi 22,99%, a błąd II typu 30,54% dla próby uczącej, natomiast dla próby testowej odpowiadające wartości to 26,79% dla błędu I typu i 27,46% dla błędu II typu. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0 i 0,76 dla klasy 1, natomiast dla próby testowej wartości te wynoszą odpowiednio 0,72 dla klasy 0 i 0,74 dla klasy 1. Miara Giniego wynosi 0,61 dla próby uczącej i 0,54 dla próby testowej. AUC wynosi 0,81 dla próby uczącej i 0,77 dla próby testowej. Na wykresie 16 przedstawiono krzywą ROC.


Wykres 16. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 17 przedstawiono istotność cech wyznaczoną przez model SVM. Wśród najistotniejszych zmiennych znajdują się: odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15) oraz udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X13).

Wykres 17. Istotność cech w modelu SVM




Źródło: opracowanie na podstawie wyników badań własnych.

W celu oceny wpływu poszczególnych cech na decyzje podejmowane przez model SVM, poniżej przedstawiono interpretację modelu z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Obliczenie wartości SHAP dla algorytmów opartych na drzewach jest szybsze w porównaniu do modeli, które nie są oparte na drzewach, takie jak np. SVM, ponieważ w przypadku modeli opartych na drzewach wykorzystywana jest ich wewnętrzna struktura (Chen i in., 2023). Dla algorytmu SVM czas generowania wartości SHAP, niezbędnych do stworzenia interpretacji, wyniósł 23 minuty. Czas ten był zdecydowanie dłuższy niż w przypadku algorytmów opartych na drzewach. Przeliczenie wartości LIME, potrzebnych do wygenerowania interpretacji, zajęło zaledwie sekundę.

Na wykresie 18 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu. Każdy punkt odpowiada jednej próbie w zbiorze danych, a jego pozycja na osi poziomej zależy od wartości SHAP dla danej cechy. Gdy punkty są zlokalizowane po prawej stronie, oznacza to, że cech pozytywnie wpływa na klasyfikację tzn. zwiększa prawdopodobieństwo upadłości. Jeżeli punkt jest przesunięty w lewo, oznacza to, że cecha negatywnie wpływa na wynik, tzn. zmniejsza prawdopodobieństwo upadłości. Kolejnym

istotnym aspektem jest kolor danej obserwacji - niebieski oznacza niższą wartość, a czerwony wyższą wartość cechy.

Wykres 18. Podsumowanie wartości SHAP dla modelu SVM




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 19 cechy zostały uszeregowane według ich średnich wartości bezwzględnych SHAP. Wśród najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumenckiej, znajdują się: odmowa udzielenia kredytu (X25), posiadanie wydatków mniejszych niż dochody (X22), opóźnienia w spłacie zobowiązań (X15), posiadanie nieruchomości (X12) oraz udział całkowitego zadłużenia konsumpcyjnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X5).


Ponadto wartości SHAP mogą być wykorzystywane do tworzenia wyjaśnień dla każdej obserwacji w zbiorze danych. Na wykresach 20 oraz 21 przedstawiono wyjaśnienia indywidualne dla dwóch przykładowych predykcji. Najistotniejszymi cechami wpływającymi na predykcję pierwszego konsumenta (wykres 20) są: opóźnienia w spłacie zobowiązań (X15), posiadanie wydatków większych niż dochody (X22) oraz udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X13). Wartości tych trzech cech wpłynęły na zwiększenie ryzyka upadłości konsumenckiej. Model dokonał prawidłowej predykcji, prognozując wysokie ryzyko upadłości konsumenckiej.

Wykres 19. Średni wpływ cech na wynik modelu SVM według wartości SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 20. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

W przypadku drugiego konsumenta (wykres 21) najważniejszymi cechami wpływającymi na predykcję są: odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15), posiadanie nieruchomości (X12) oraz posiadanie wydatków mniejszych niż dochody (X22). Wartości tych cech wpłynęły na zmniejszenie ryzyka upadłości u tego konsumenta. Model dokonał prawidłowej predykcji, prognozując niskie ryzyko upadłości konsumentki.

Wykres 21. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 22 i 23 przedstawiono interpretację LIME dla dwóch konsumentów. Wykres 22 ilustruje konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), natomiast wykres 23 dotyczy drugiego konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). W dalszej części rozprawy doktorskiej pierwszy i drugi konsument to ci sami konsumenci we wszystkich interpretacjach lokalnych. Model przewiduje 79% prawdopodobieństwo bankructwa dla pierwszego konsumenta i 79% prawdopodobieństwo braku bankructwa dla drugiego. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań oraz inne czynniki finansowe. Opóźnienia w spłacie zobowiązań (X15) zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko


upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25) oraz brak opóźnień w spłacie zobowiązań (X15) co zmniejszyło ryzyko upadłości.

Wykres 22. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 23. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.3. Drzewo decyzyjne

W niniejszym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu drzewa decyzyjnego. Model został

oszacowany na pierwszym zestawie zmiennych. Całkowita skuteczność modelu wynosi 73,20% dla próby uczącej oraz 73,38% dla próby testowej. Błąd I typu wynosi 24,62%, a błąd II typu wynosi 28,94% dla próby uczącej. Dla próby testowej błąd I typu wynosi 24,40%, a błąd II typu 29,02%. Miara F1 dla próby uczącej wynosi 0,73 dla klasy 0 i 0,74 dla klasy 1, natomiast dla próby testowej wartości te wynoszą 0,72 dla klasy 0 i 0,75 dla klasy 1. Miara Giniego wynosi 0,59 dla próby uczącej i 0,57 dla próby testowej. AUC wynosi 0,79 zarówno dla próby uczącej, jak i testowej. Na wykresie 24 przedstawiono krzywą ROC dla modelu drzewa decyzyjnego.


Wykres 24. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu drzewa decyzyjnego



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 25 przedstawiono istotność cech wyznaczoną przez model drzewa decyzyjnego. Wśród najistotniejszych cech wskazanych przez model znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział miesięcznej spłaty zadłużenia odnawialnego do miesięcznego dochodu (X20), opóźnienia w spłacie zobowiązań (X15) oraz udział całkowitych aktywów niefinansowych w stosunku do długu (X19).


Wykres 25. Istotność cech w modelu drzewa decyzyjnego



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretację wyników z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP, podobnie jak w przypadku poprzedniego algorytmu, wykonano zarówno interpretację globalną, jak i interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Dla algorytmu drzewa decyzyjnego czas generowania wartości SHAP, potrzebnych do wygenerowania interpretacji, wyniósł mniej niż sekundę. Taki sam czas osiągnięto dla przeliczenia wartości LIME potrzebnych do interpretacji modelu. Na wykresie 26 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 26. Podsumowanie metody SHAP dla modelu drzewa decyzyjnego



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 27 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które były istotne z punktu widzenia prognozowania upadłości konsumentów, znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), udział całkowitych aktywów niefinansowych w stosunku do długu (X19) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 27. Średni wpływ cech na wynik modelu drzewa decyzyjnego według wartości SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 28 oraz 29 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji, tych samych, które zostały również zaprezentowane w ramach innych algorytmów. W przypadku pierwszego konsumenta (wykres 28) najistotniejszymi cechami wpływającymi na prognozowanie upadłości konsumenckiej są: opóźnienia w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne na podstawie wartości nieruchomości) w stosunku do całkowitych aktywów (X16). Wartości wszystkich trzech cech zwiększyły ryzyko upadłości konsumenckiej. Model poprawnie przewidział upadłość konsumencką, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.


Wykres 28. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Największy wpływ na predykcję drugiego konsumenta (wykres 29) miały następujące cechy: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz opóźnienia w spłacie zobowiązań (X15). Wartości tych trzech cech wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej. Model poprawnie zaklasyfikował tego konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej, prognozując wartość 0, która była zgodna z rzeczywistym wynikiem.

Wykres 29. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 30 i 31 została przedstawiona interpretacja LIME dla dwóch konsumentów. Wykres 30 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość). Na wykresie 31 przedstawiono natomiast drugi przykład konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 100%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 91%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), poziom wykształcenia (X6) oraz udział całkowitych aktywów niefinansowych w stosunku do długu (X19). Cechy te zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), udział całkowitych aktywów


niefinansowych w stosunku do długu (X19), poziom wykształcenia (X6) oraz opóźnienia w spłacie zobowiązań (X15). Cechy te wpłynęły na niskie ryzyko upadłości u tego konsumenta.

Wykres 30. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 31. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.4. Las losowy

W niniejszym podrozdziale omówiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu lasu losowego. Całkowita skuteczność modelu dla pierwszego zestawu zmiennych wynosi 74,07% dla próby uczącej oraz 73,88% dla próby testowej. Błąd I typu wynosi 22,74%, a błąd II typu 29,06% dla próby uczącej, natomiast dla próby testowej są to odpowiednio 24,40% i 27,98%. Miara F1 dla próby uczącej wynosi 0,73 dla klasy 0 i 0,75 dla klasy 1, a dla próby testowej odpowiadające wartości to 0,73 i 0,75. Miara Giniego wynosi 0,59 dla próby uczącej i 0,58 dla próby testowej. AUC wynosi 0,82 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 32 przedstawiono krzywą ROC dla algorytmu lasu losowego.


Wykres 32. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem lasu losowego



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 33 przedstawiono istotność cech wyznaczoną przez model lasu losowego. Wśród najistotniejszych cech znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), udział dochodu w stosunku do całkowitych aktywów (X13), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział całkowitych aktywów niefinansowych do długu (X19).

Wykres 33. Istotność cech w modelu lasu losowego




Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretację z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP wykonano interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Dla algorytmu lasu losowych czas generowania wartości SHAP, potrzebnych do wygenerowania interpretacji, wynosił 43 sekundy. Obliczenie wartości LIME zajęło mniej niż sekundę. Na wykresie 34 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu na podstawie wartości SHAP.


Na wykresie 35 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Kluczowe cechy w przewidywaniu upadłości konsumentów to: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), udział miesięcznej spłaty zadłużenia odnawialnego w stosunku do miesięcznego dochodu (X20) oraz opóźnienia w spłacie zobowiązań (X15).

Wykres 34. Podsumowanie SHAP dla modelu lasu losowego



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 35. Średni wpływ cech na wynik modelu lasu losowego według wartości SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Ponadto na wykresach 36 i 37 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. W przypadku pierwszego konsumenta (wykres 36) największy wpływ na predykcję modelu miały następujące cechy: opóźnienia w spłacie zobowiązań (X15), odmowa udzielenia

kredytu (X25) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17). Opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) zwiększyły prawdopodobieństwo upadłości konsumenckiej. Konsument wnioskował o upadłość konsumencką i został poprawnie zaklasyfikowany przez model.


Wykres 36. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Największy wpływ na predykcję drugiego konsumenta (wykres 37) miały następujące cechy: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz udział dochodu w stosunku do całkowitych aktywów (X13). Wartości tych cech zmniejszyły ryzyko upadłości konsumenckiej u tego konsumenta. Konsument nie wnioskował o upadłość konsumencką i został poprawnie zaklasyfikowany przez model.


Wykres 37. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 38 i 39 przedstawiono interpretację wyników modelu za pomocą metody LIME dla dwóch konsumentów. Wykres 38 obrazuje przypadek konsumenta, dla którego model przewidział wynik klasy 1 (upadłość). Z kolei wykres 39 przedstawia drugiego konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 66%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 81%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24). Cechy te zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) co wpłynęło na niskie ryzyko upadłości.

Wykres 38. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 39. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.5. Adaptive Boosting

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu AdaBoost. Model został oszacowany na pierwszym zestawie zmiennych. Całkowita skuteczność modelu wynosi 74,75% dla próby uczącej oraz 73,88% dla próby testowej. Błąd I typu wynosi 24,87%, a błąd II typu 25,62% dla

próby uczącej. Dla próby testowej błąd I wynosi 26,32%, a błąd II typu 25,91%. Miara F1 dla próby uczącej wynosi 0,75 dla klasy 0 i 0,75 dla klasy 1, natomiast dla próby testowej wartości te wynoszą odpowiednio 0,73 dla klasy 0 i 0,75 dla klasy 1. Miara Giniego wynosi 0,67 dla próby uczącej i 0,58 dla próby testowej. AUC wynosi 0,84 dla próby uczącej oraz 0,79 dla próby testowej. Na wykresie 40 przedstawiono krzywą ROC.

Wykres 40. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu AdaBoost




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 41 przedstawiono istotność cech wyznaczoną przez model AdaBoost. Wśród kluczowych cech znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), odmowa udzielenia kredytu (X25) oraz opóźnienia w spłacie zobowiązań (X15).

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Dla algorytmu AdaBoost czas generowania wartości SHAP, potrzebnych do stworzenia interpretacji, wynosił 30 minut, natomiast obliczenie wartości LIME zajęło dwie sekundy. Na wykresie 42


przedstawiono wpływ poszczególnych cech na wynik predykcji modelu z wykorzystaniem metody SHAP.

Wykres 41. Istotność cech w modelu AdaBoost



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 42. Podsumowanie wartości SHAP dla modelu AdaBoost




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 43 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najistotniejszych cech w przewidywaniu upadłości konsumentów znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku

do dochodu (X18), odmowa udzielenia kredytu (X25), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20).

Wykres 43. Średni wpływ cech na wynik modelu AdaBoost według wartości SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Ponadto, na wykresach 44 oraz 45 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Dla pierwszego konsumenta (wykres 44) największy wpływ na predykcję miały cechy: opóźnienia w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17). Zarówno opóźnienia w spłacie zobowiązań (X15), jak i wysokość udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) przyczyniły się zwiększenia ryzyka upadłości konsumenckiej. Model poprawnie przewidział upadłość konsumentką, prognozując wartość 1, co było zgodne z rzeczywistym wynikiem.

W przypadku drugiego konsumenta (wykres 45) wśród najistotniejszych cech wpływających na predykcję upadłości konsumenckiej znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), edukacja (X6) oraz opóźnienia w spłacie zobowiązań (X15). Model poprawnie zaklasyfikował konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.


Wykres 44. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresie 46 i 47 przedstawiono interpretacje wyników metody LIME dla dwóch konsumentów. Wykres 46 ilustruje konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), natomiast wykres 47 dotyczy drugiego konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 71%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 85%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) co zmniejszyło ryzyko upadłości.

Wykres 45. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 46. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 47. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.6. Gradient Boosting Classifier

W niniejszym podrozdziale omówiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu Gradient Boosting Classifier. Całkowita skuteczność modelu dla pierwszego zestawu zmiennych wynosi 75,44% dla próby uczącej oraz 74,13% dla próby testowej. Błąd I typu wynosi 23,12%, a błąd II typu 25,99% dla próby uczącej. Dla próby testowej błąd I typu wynosi 25,84%, a błąd II typu 25,91%. Miara F1 dla próby uczącej wynosi 0,75 dla klasy 0 i 0,76 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,73 dla klasy 0 i 0,75 dla klasy 1. Miara Giniego wynosi 0,65 dla próby uczącej i 0,58 dla próby testowej. AUC wynosi 0,83 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 48 przedstawiono krzywą ROC.


Na wykresie 49 przedstawiono istotność cech wyznaczoną przez model Gradient Boosting Classifier. Do najistotniejszych cech należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), udział miesięcznej spłaty zadłużenia odnawialnego w stosunku do miesięcznego dochodu (X20) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24).

Wykres 48. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu Gradient Boosting Classifier



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 49. Istotność cech w modelu Gradient Boosting Classifier




Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje przy użyciu dwóch metod: SHAP oraz LIME. Tak jak w przypadku poprzednich algorytmów, dla metody SHAP przygotowano interpretację

globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne tych samych konsumentów. Czas generowania wartości SHAP, potrzebnych do wygenerowania interpretacji w algorytmie Gradient Boosting Classifier, wyniósł 6 sekund, podczas gdy dla wartości LIME czas ten był krótszy niż sekunda. Na wykresie 50 przedstawiono wpływ poszczególnych zmiennych na wynik predykcji modelu z wykorzystaniem metody SHAP.


Wykres 50. Podsumowanie wartości SHAP dla modelu Gradient Boosting Classifier



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 51 uszeregowano cechy według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które miały największy wpływ na przewidywanie upadłości konsumenckiej, znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20).

Wykres 51. Średni wpływ cech na wynik modelu Gradient Boosting Classifier według wartości SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wśród najistotniejszych cech mających wpływ na predykcję pierwszego konsumenta (wykres 52) są opóźnienia w spłacie zobowiązań (X15), udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) oraz udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18). Wartości tych cech zwiększyły prawdopodobieństwo upadłości konsumenckiej. Model poprawnie przewidział upadłość konsumentką, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.

Wśród najważniejszych cech mających wpływ na predykcję drugiego konsumenta (wykres 53) znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), poziom wykształcenia (X6) oraz odmowa udzielenia kredytu (X25). Wartości tych cech wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej. Model prawidłowo zaklasyfikował konsumenta jako osobę o niskim ryzyku upadłości, prognozując wartość 0, która była zgodna z rzeczywistym wynikiem.


Wykres 52. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresie 54 i 55 została przedstawiona interpretacja przygotowana z wykorzystaniem metody LIME dla dwóch konsumentów. Na wykresie 54 została zilustrowana interpretacja konsumenta, dla którego model przewidział wynik klasy 1 (upadłość). Na wykresie 55 został przedstawiony drugi przykład konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 78%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 82%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25) oraz brak opóźnień w spłacie zobowiązań (X15).

Wykres 53. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 54. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 55. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.7. Extreme Gradient Boosting

W kolejnym podrozdziale przedstawiono wyniki badań dotyczące modelu prognozowania upadłości konsumenckiej z zastosowaniem algorytmu XGBoost. Całkowita skuteczność modelu XGBoost oszacowanego na pierwszym zestawie zmiennych wynosi 74,32% dla próby uczącej oraz 75,12% dla próby testowej. Błąd I typu wynosi 24,87%, a błąd II typu wynosi 26,48% dla próby uczącej. Dla próby testowej błąd I typu wynosi 25,36%, a błąd II typu 24,35%. Miara F1 dla próby uczącej wynosi 0,74 dla klasy 0 i 0,76 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,74 dla klasy 0 i 0,74 dla klasy 1. Miara Giniego wynosi 0,62 dla próby uczącej i 0,58 dla próby testowej. AUC wynosi 0,81 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 56 przedstawiono krzywą ROC.


Na wykresie 57 przedstawiono istotność cech wyznaczoną przez model XGBoost. Do najistotniejszych cech należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), posiadanie wydatków mniejszych niż dochody (X22) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24).

Wykres 56. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu XGBoost



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 57. Istotność cech w modelu XGBoost

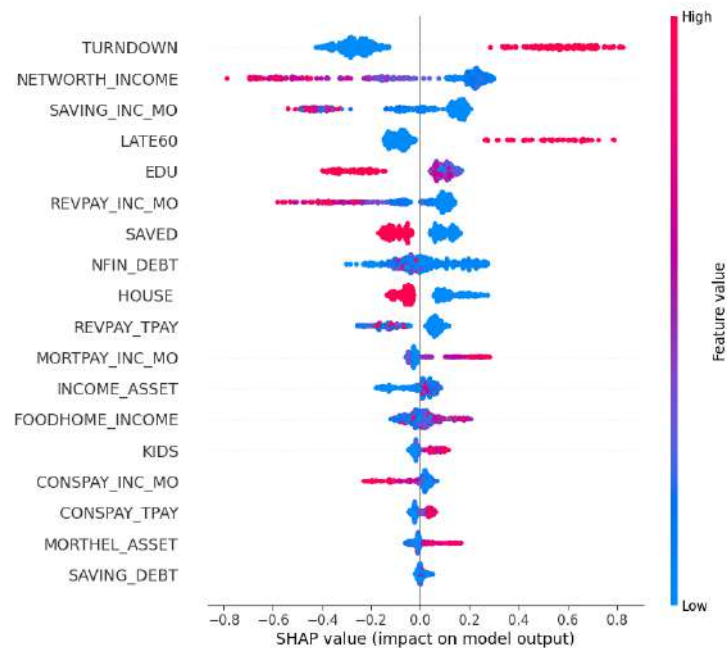


Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretację modelu z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP wykonano interpretację globalną oraz interpretacje

indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Dla algorytmu XGBoost czas generowania wartości SHAP, niezbędnych do przygotowania interpretacji modelu, wynosił 7 sekund. Dla wartości LIME, ponownie jak w przypadku poprzednich algorytmów, czas ten wynosił mniej niż sekundę. Na wykresie 57 przedstawiono wpływ poszczególnych zmiennych na wynik predykcji modelu.


Wykres 58. Podsumowanie wartości SHAP dla modelu XGBoost



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 59 cechy zostały uporządkowane według ich średnich bezwzględnych wartości SHAP. Do najistotniejszych cech należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), opóźnienia w spłacie zobowiązań (X15) oraz poziom wykształcenia (X6).

Wykres 59. Średni wpływ cech na wynik modelu XGBoost według wartości SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 60 oraz 61 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Najważniejszymi cechami, które wpłynęły na predykcję pierwszego konsumenta (wykres 60), są opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17). Obie te zmienne przyczyniły się do zwiększenia prawdopodobieństwa upadłości konsumenckiej. Konsument został prawidłowo zaklasyfikowany przez model jako osoba z wysokim ryzykiem upadłości konsumenckiej.

Najważniejszymi cechami wpływającymi na predykcję drugiego konsumenta (wykres 61) są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), poziom wykształcenia (X6) oraz odmowa udzielenia kredytu (X25). Te cechy wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej tego konsumenta.


Wykres 60. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresie 62 i 63 zostały przedstawione interpretacje przygotowane metodą LIME dla dwóch konsumentów. Wykres 62 pokazuje konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), natomiast wykres 63 konsumenta, dla którego model przewidział wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 71%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 86%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), które zmniejszyły ryzyko upadłości.

Wykres 61. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 62. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 63. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.8. Light Gradient Boosting Machine

W niniejszym podrozdziale omówiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu LightGBM. Model został oszacowany na podstawie pierwszego zestawu zmiennych. Całkowita skuteczność modelu wynosi 77,24% dla próby uczącej oraz 76,12% dla próby testowej. Błąd I typu wynosi 20,48%, a błąd II typu wynosi 25% dla próby uczącej. Dla próby testowej błąd I typu wynosi 22,97%, a błąd II typu wynosi 24,87%. Miara F1 dla próby uczącej wynosi 0,77 dla klasy 0, a 0,78 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,75 dla klasy 0 i 0,77 dla klasy 1. Miara Giniego wynosi 0,69 dla próby uczącej i 0,60 dla próby testowej. AUC wynosi 0,85 dla próby uczącej i 0,80 dla próby testowej. Na wykresie 64 przedstawiono krzywą ROC.


Na wykresie 65 przedstawiono istotność cech wyznaczoną przez model LightGBM. Wśród najistotniejszych cech znajdują się: udział całkowitych aktywów niefinansowych w stosunku do długu (X19), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20), udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24).

Wykres 64. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu LightGBM



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 65. Istotność cech w modelu LightGBM




Źródło: opracowanie na podstawie wyników badań własnych.

Interpretacja modelu z wykorzystaniem dwóch metod: SHAP oraz LIME przedstawiona jest poniżej. Dla metody SHAP, podobnie jak w przypadku poprzednich algorytmów,

wykonano interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Czas generowania wartości SHAP dla algorytmu LightGBM, niezbędnych do przygotowania interpretacji modelu, wyniósł mniej niż sekundę, a czas obliczeń dla wartości LIME był na podobnym poziomie. Na wykresie 66 przedstawiono wpływ poszczególnych zmiennych na wynik predykcji modelu z wykorzystaniem metody SHAP.


Wykres 66. Podsumowanie wartości SHAP dla modelu LightGBM



Źródło: opracowanie na podstawie wyników badań własnych.

Ponadto zmienne zostały uszeregowane według ich średnich bezwzględnych wartości SHAP (wykres 67). Wśród najistotniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumentów, znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), poziom wykształcenia (X6), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 67. Średni wpływ cech wejściowych na wynik modelu LightGBM według wartości SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Wyjaśnienia indywidualne dla dwóch predykcji przedstawiono na wykresach 68 oraz 69. Najistotniejszymi czynnikami wpływającymi na predykcję pierwszego konsumenta są cechy: opóźnienia w spłacie zobowiązań (X15), udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20). Cechy te zwiększyły prawdopodobieństwo upadłości konsumentki. Model poprawnie przewidział upadłość konsumentką, prognozując wartość 1, co było zgodne z rzeczywistym wynikiem.

Wykres 68. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

U drugiego konsumenta (wykres 69) najistotniejszymi czynnikami wpływającymi na predykcję są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), poziom wykształcenia (X6) oraz odmowa udzielenia kredytu (X25). Wartości tych cech zmniejszyły prawdopodobieństwo upadłości konsumenckiej tego konsumenta. Model poprawnie zaklasyfikował konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.

Poniżej przedstawiono interpretację modelu z wykorzystaniem metody LIME dla dwóch konsumentów (wykresy 70 i 71). Pierwszy wykres ilustruje konsumenta, dla którego model przewidział upadłość (klasa 1), a drugi przedstawia konsumenta, dla którego model przewidział brak upadłości (klasa 0). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 79%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 87%. Największy wpływ na przewidywanie pierwszego konsumenta miały udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), posiadanie wydatków mniejszych niż dochody (X22), udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów (X16) oraz


udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), które zwiększyły prawdopodobieństwo upadłości, natomiast udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11) oraz brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), posiadanie nieruchomości (X12), posiadanie wydatków mniejszych niż dochody (X22) oraz poziom wykształcenia (X6), które zmniejszyły ryzyko upadłości.

Wykres 69. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 70. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 71. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.9. Categorical Boosting

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu CatBoost. Całkowita skuteczność modelu CatBoost dla pierwszego zestawu zmiennych wynosi 75,93% dla próby uczącej oraz 75,87% dla próby testowej. Błąd I typu wynosi 22,11%, a błąd II typu 25,99% dla próby

uczącej. Dla próby testowej błąd I typu wynosi 24,40%, a błąd II typu 23,83%. Miara F1 wynosi 0,76 dla klasy 0 i 0,76 dla klasy 1 w próbie uczącej, a 0,75 dla klasy 0 i 0,77 dla klasy 1 w próbie testowej. Miara Giniego wynosi 0,69 dla próby uczącej i 0,59 dla testowej. AUC wynosi 0,84 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 72 przedstawiono krzywą ROC.


Wykres 72. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem Catboost



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 73 przedstawiono istotność cech wyznaczoną przez model Catboost. Wśród najistotniejszych cech znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział całkowitego zadłużenia odnawialnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X21).

Wykres 73. Istotność cech w modelu Catboost




Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej, jak w przypadku poprzednich algorytmów, przedstawiono interpretacje modelu za pomocą dwóch metod: SHAP oraz LIME. Dla metody SHAP zaprezentowano interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Czas wygenerowania wartości SHAP, potrzebnych do przygotowania interpretacji modelu CatBoost, wyniósł 7 sekund, natomiast dla wartości LIME czas ten, jak w przypadku poprzednich algorytmów, był krótszy niż sekunda. Na wykresie 74 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP i zaprezentowane na wykresie 75. Najistotniejsze z nich w przewidywaniu upadłości konsumentki to: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), opóźnienia w spłacie zobowiązań (X15) oraz poziom wykształcenia (X6).

Wykres 74. Podsumowanie SHAP dla modelu CatBoost



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 75. Średni wpływ cech na wynik modelu CatBoost według wartości SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 76 i 77 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Najistotniejszymi cechami, które wpłynęły na predykcję pierwszego konsumenta (wykres 76) są: opóźnienia w spłacie zobowiązań (X15), odmowa udzielenia kredytu (X25) oraz udział

całkowitego zadłużenia odnawialnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X21). Opóźnienia w spłacie zobowiązań (X15) oraz wysokość udziału zadłużenia odnawialnego (X21) wpłynęły na zwiększenie prawdopodobieństwa upadłości konsumenckiej, podczas gdy brak odmowy udzielenia kredytu (X25) zmniejszył to ryzyko. Model poprawnie zaklasyfikował konsumenta, prognozując wartość 1, co odpowiadało rzeczywistemu wynikowi.


Wykres 76. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Dla drugiego konsumenta (wykres 77) najistotniejszymi cechami są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz poziom wykształcenia (X6). Zmienne te zmniejszyły ryzyko upadłości konsumenckiej. Model poprawnie zaklasyfikował konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.


Wykres 77. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody SHAP



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 78 i 79 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 78 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 79 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 76%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 81%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miał brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) oraz poziom wykształcenia (X6).

Wykres 78. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 79. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody LIME




Źródło: opracowanie na podstawie wyników badań własnych.

3.3.10. Sieci neuronowe

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu sieci neuronowych. Całkowita skuteczność modelu dla pierwszego zestawu zmiennych wynosi 73,57% dla próby uczącej i 73,13% dla próby testowej. Błąd I typu wynosi 23,87%, a błąd II typu 28,94% w próbie uczącej.

Dla próby testowej wartości te wynoszą odpowiednio 27,27% oraz 26,42%. Miara F1 w próbie uczącej wynosi 0,73 dla klasy 0 i 0,74 dla klasy 1, natomiast w próbie testowej odpowiadające wartości to 0,72 dla klasy 0 i 0,74 dla klasy 1. Miara Giniego osiąga 0,60 dla próby uczącej i 0,55 dla próby testowej. Wartość AUC wynosi 0,80 dla próby uczącej i 0,78 dla próby testowej. Na wykresie 80 przedstawiono krzywą ROC.

Wykres 80. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem sieci neuronowych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 81 przedstawiono istotność cech wyznaczoną przez model sieci neuronowych. Wśród najistotniejszych cech znajdują się: udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20), posiadanie wydatków mniejszych niż dochody (X22) oraz udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18).

Poniżej, podobnie jak w przypadku poprzednich algorytmów, przedstawiono interpretacje modelu za pomocą dwóch metod: SHAP oraz LIME. W metodzie SHAP zaprezentowano zarówno interpretację globalną, jak i indywidualne analizy dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. W przypadku metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Czas wygenerowania wartości SHAP, niezbędnych do przygotowania interpretacji modelu sieci neuronowych, wyniósł 2 minuty i 21 sekundy. Natomiast dla wartości LIME, podobnie jak w


przypadku wcześniejszych algorytmów, czas ten był krótszy niż sekunda. Na wykresie 82 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.

Wykres 81. Istotność cech w modelu sieci neuronowych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 82. Podsumowanie wartości SHAP dla modelu sieci neuronowych




Źródło: opracowanie na podstawie wyników badań własnych.

Cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP i zaprezentowane na wykresie 83. Do najistotniejszych czynników wpływających a przewidywanie upadłości konsumenckiej należą: odmowa udzielenia kredytu (X25), poziom

wykształcenia (X6), udział całkowitego zadłużenia konsumpcyjnego (z wyłączeniem kredytów hipotecznych oraz zadłużenia odnawialnego) w stosunku do sumy wszystkich miesięcznych płatności związanych z zobowiązaniami (X5), posiadanie nieruchomości (X12) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 83. Średni wpływ cech na wynik modelu sieci neuronowych według wartości SHAP



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 84 i 85 przedstawiono indywidualne wyjaśnienia dla dwóch predykcji. Najistotniejsze cechy wpływające na predykcję konsumenta (wykres 84) to: opóźnienia w spłacie zobowiązań (X15), udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) oraz liczba dzieci (X14). Czynniki te zwiększyły ryzyko upadłości konsumentki u tego konsumenta. Model poprawnie zaklasyfikował konsumenta, prognozując wartość 1, co było zgodne z rzeczywistym wynikiem.

Wykres 84. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Dla drugiego konsumenta (wykres 85) kluczowe cechy to: poziom wykształcenia, odmowa udzielenia kredytu (X25) oraz udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18). Czynniki te przyczyniły się do obniżenia ryzyka upadłości konsumenckiej. Model poprawnie zaklasyfikował konsumenta jako osobę o niskim ryzyku upadłości.

Na wykresach 86 i 87 przedstawiono interpretację metodą LIME dla dwóch konsumentów. Wykres 86 dotyczy konsumenta, dla którego model przewidział upadłość (klasa 1), natomiast wykres 87 odnosi się do konsumenta, dla którego prognozowano brak upadłości (klasa 0). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 79%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 85%. Największy wpływ na przewidywanie pierwszego konsumenta miały udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) oraz opóźnienia w spłacie zobowiązań (X15), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak opóźnień w spłacie zobowiązań (X15), brak odmowy udzielenia kredytu (X25), poziom


wykształcenia (X6) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), które zmniejszyły ryzyko upadłości.

Wykres 85. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody SHAP




Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 86. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 87. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody LIME



Źródło: opracowanie na podstawie wyników badań własnych.

3.3.11. Metody agregacji klasyfikatorów

Aby poprawić skuteczność predykcji modeli klasyfikacyjnych, w literaturze przedmiotu zaproponowano różnorodne podejścia łączenia skuteczności modeli takie jak na przykład: głosowanie większościowe, ważone głosowanie większościowe, uśrednianie, ważone uśrednianie, metoda stacking (Kim i in., 2013). Dla pierwszego zestawu zmiennych zostały przygotowane modele z uwzględnieniem uśredniania, głosowania oraz stacking.

Wykorzystując metodę uśredniania, nie udało się osiągnąć wyższej skuteczności niż w przypadku najlepszych pojedynczych algorytmów. Zweryfikowano skuteczność modeli w różnych kombinacjach dla algorytmów: regresji logistycznej, maszyny wektorów nośnych, AdaBoost, drzewa decyzyjnego, lasu losowego, Gradient Boosting Classifier, LightGBM, XGBoost, CatBoost oraz sieci neuronowych. Przy połączeniu algorytmu LightGBM i CatBoost (z zastosowanymi wagami 0,5) całkowita skuteczność wynosi 76,31% dla próby testowej i 74,88% dla próby uczącej. Błąd I typu wynosi 21,86% dla próby uczącej i 23,92% dla próby testowej. Błąd II typu wynosi 25,49% dla próby uczącej i 26,42% dla próby testowej. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0 i 0,77 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,74 dla klasy 0 i 0,76 dla klasy 1. Miara Giniego wynosi 0,70 dla próby uczącej i 0,60 dla próby testowej. AUC wynosi 0,85 dla próby uczącej i 0,80 dla próby testowej. Przy modyfikacji wag do poziomu 0,7 dla modelu LightGBM i 0,3 dla algorytmu CatBoost, całkowita skuteczność wynosi 76,87% dla próby uczącej i 75,12% dla próby

testowej. Zmniejszył się również błąd I typu, który wynosi 21,48% dla próby uczącej i 21,97% dla próby testowej. Błąd II typu wynosi 24,75% dla próby uczącej i 26,94% dla próby testowej. Miara Giniego oraz AUC mają te same wartości, co w przypadku zastosowania wag 0,5. Podobną skuteczność udało się osiągnąć przy połączeniu modeli LightGBM i XGBoost (z wagami 0,8/0,2), LightGBM, XGBoost i Catboost (0,6/0,1/0,3) oraz CatBoost i XGBoost (0,85/0,15).

Została również porównana skuteczność modeli z zastosowaniem głosowania większościowego. Zweryfikowano skuteczność modeli w różnych kombinacjach: regresji logistycznej, maszyny wektorów nośnych, AdaBoost, drzewa decyzyjnego, lasu losowego, Gradient Boosting Classifier, LightGBM, XGBoost, CatBoost oraz sieci neuronowych. Porównując wyłącznie całkowitą skuteczność modeli, modele z wykorzystaniem głosowania wykazały się niższą skutecznością niż pojedynczy algorytm z najwyższym wynikiem (LightGBM). Łącząc trzy często wykorzystywane algorytmy w prognozowaniu upadłości: regresję logistyczną, drzewo decyzyjne oraz SVM, osiągnięto całkowitą skuteczność wynoszącą 73,01% na próbie uczącej oraz 73,63% na próbie testowej. Błąd I typu wynosi 25,63%, a błąd II typu wynosi 28,33% dla próby uczącej. Dla próby testowej błąd I typu wynosi 28,71%, a błąd II typu wynosi 23,83%. Powyższe wyniki zostały osiągnięte przy założeniu, że przynajmniej dwa modele musiały zagłosować na klasę 1, aby przypisać tę klasę ostatecznie. Modyfikacja tego warunku na jeden model powoduje spadek całkowitej skuteczności (71,21% dla próby uczącej, 72,89% natomiast dla próby testowej), jednak znacznie wzrósł błąd II typu (44,58% dla próby uczącej i 41,45% dla próby testowej), a błąd I typu uległ obniżeniu (12,69% dla próby uczącej i 13,88% dla próby testowej). W przypadku modyfikacji warunku na trzy modele przypisujące klasę 1 wystąpiła sytuacja odwrotna. Znacznie wzrósł błąd I typu (42,21% dla próby uczącej oraz 41,63% dla próby testowej), przy jednoczesnym spadku błędów II typu (16,13% dla próby uczącej i 13,99% dla próby testowej). Całkowita skuteczność modelu niewiele spadła (70,96% dla próby uczącej i 71,64% dla próby testowej).

Dodanie modelu Adaboost przyczyniło się do wzrostu całkowitej skuteczności, która wyniosła 74,38% dla próby uczącej i 75,62% dla próby testowej. Błąd I typu wynosi 18,59%, a błąd II typu wynosi 32,51% dla próby uczącej. Dla próby testowej, błąd I typu wynosi 21,53%, a błąd II typu 27,46%. Zastąpienie AdaBoost modelem LightGBM spowodowało ponowny wzrost całkowitej skuteczności do 74,38% dla próby uczącej i 75,62% dla próby testowej. Błąd I typu obniżył się do 18,59% dla próby uczącej i 21,53% dla próby testowej, natomiast błąd II typu wyniósł 32,51% dla próby uczącej i 27,46% dla próby testowej. Powyższe wyniki zostały

osiągnięte przy uwzględnieniu warunku, że przynajmniej dwa modele musiały przypisać klasę 1.

W przypadku połączenia algorytmu LightGBM z algorytmem CatBoost poprzez głosowanie większościowe, całkowita skuteczność wynosi 76,12% dla próby uczącej oraz 75,62% dla próby testowej. Dla próby testowej całkowita skuteczność osiągnięta poprzez połączenie modelu LightGBM z CatBoost jest o 0,50 p.p. niższa niż w przypadku modelu LightGBM i o 0,25 p.p. niższa niż w przypadku modelu CatBoost. Błąd I typu wynosi 17,84% dla próby uczącej i 21,05% dla próby testowej, natomiast błąd II typu wynosi 29,80% dla próby uczącej i 27,98% dla próby testowej. Powyższe wyniki zostały osiągnięte przy założeniu, że przynajmniej dwa modele musiały zagłosować na klasę 1, aby przypisać tę klasę ostatecznie. Błąd I typu w połączonym algorytmie LightGBM z CatBoost jest niższy o 1,91 p.p. niż w przypadku pojedynczego algorytmu LightGBM, natomiast błąd II typu jest wyższy o 3,11 p.p. niż w przypadku pojedynczego algorytmu LightGBM dla próby testowej. Jednak porównując do innych pojedynczych algorytmów, całkowita skuteczność osiągnięta poprzez połączenie modelu LightGBM z CatBoost jest najwyższa.

Łącząc modele LightGBM, CatBoost i XGBoost poprzez głosowanie, uzyskano całkowitą skuteczność na poziomie 76,24% dla próby uczącej oraz 75,62% dla próby testowej. Dla próby uczącej błąd I typu wynosi 21,98%, a błąd II typu 25,49%. Dla próby testowej błąd I typu wynosi 23,92%, a błąd II typu 24,87%. Model osiągnął nieznacznie wyższą skuteczność niż XGBoost, lecz nieco niższą niż LightGBM i Catboost.

Przygotowano również dwa modele z wykorzystaniem metody stacking. W przypadku pierwszego modelu jako modele bazowe zostały wykorzystane algorytmy: CatBoost, XGboost oraz Gradient Boosting Classifier. Każdy z tych modeli wygenerował prognozy w postaci prawdopodobieństw, które następnie są wykorzystywane przez model nadrzędny LightGBM do finalnej predykcji. Całkowita skuteczność modelu dla próby testowej wyniosła 75,62%. Błąd I typu dla próby testowej wyniósł 22,01% a błąd II typu 26,94%. Największy wpływ na wynik modelu miały kolejno prawdopodobieństwa wygenerowane przez modele: CatBoost, Gradient Boosting Classifier oraz XGBoost.

Drugi model wykorzystujący metodę stacking oparto na modelach bazowych z wykorzystaniem algorytmów: LightGBM, CatBoost, las losowy, Gradient Boosting Classifier oraz AdaBoost. Prawdopodobieństwa uzyskane z tych modeli zostały następnie przekazane do modelu nadrzędnego XGBoost. Całkowita skuteczność modelu dla próby testowej wyniosła 75,52%, przy błędzie I typu równym 24,40% i błędzie II typu 24,35%. Model ten również znalazł się wśród najlepszych pod względem skuteczności w porównaniu do innych

oszacowanych modeli. Prawdopodobieństwa uzyskane z modeli, w kolejności: LightGBM, CatBoost, Adaboost, las losowy oraz Gradient Boosting Classifier, miały największy wpływ na wyniki modelu.


Zastosowanie metod agregujących pojedyncze klasyfikatory pozwoliło na porównanie skuteczności prognozowania ryzyka upadłości konsumenckiej z wynikami uzyskanymi przy użyciu poszczególnych algorytmów. W kolejnym podrozdziale przedstawiono analogiczne modele oszacowane dla drugiego zestawu zmiennych, co umożliwia porównanie ich efektywności.

3.4. Modele prognozowania ryzyka upadłości konsumenckiej oszacowane dla drugiego zestawu zmiennych

3.4.1. Regresja logistyczna

W niniejszym podrozdziale przedstawiono wyniki badań nad modelem prognozowania ryzyka upadłości konsumenckiej z wykorzystaniem regresji logistycznej. Model został oszacowany dla drugiego zestawu zmiennych zawierającego wskaźniki integrujące różne rodzaje informacji w ocenie sytuacji finansowej konsumentów. Całkowita skuteczność modelu regresji logistycznej wynosi 68,59% dla próby uczącej i 71,39% dla próby testowej. Błąd I typu wynosi 32,16%, a błąd II typu wynosi 30,67% dla próby uczącej. Dla próby testowej błąd pierwszego typu wynosi 32,06%, a błąd drugiego typu 24,87%. Miara F1 dla próby uczącej wynosi 0,69 dla klasy 0 i 0,68 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,72 dla klasy 0 i 0,71 dla klasy 1. Miara Giniego wynosi 0,51 dla próby uczącej i 0,55 dla próby testowej. AUC wynosi 0,76 dla próby uczącej i 0,77 dla próby testowej. Na wykresie 88 przedstawiono krzywą ROC.

Wykres 88. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem regresji logistycznej, opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Współczynniki regresji i błędy standardowe dla regresji logistycznej zostały przedstawione w tabeli 7. Wśród predyktorów upadłości znajdują się: odmowa udzielenia kredytu (X25), posiadanie nieruchomości (X12), wskaźnik relacji poziomu wykształcenia do wieku (X7), udział miesięcznej płatności kredytu hipotecznego w miesięcznym dochodzie, udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone nieruchomościami) do całkowitych aktywów (X16), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20), udział środków z kont oszczędnościowych w miesięcznym dochodzie (X24) oraz wskaźnik relacji wieku w stosunku do udziału miesięcznych spłat zadłużenia konsumpcyjnego do miesięcznego dochodu (X2).

Tabela 7. Wyniki modelu regresji logistycznej opracowane dla drugiego zestawu zmiennych

Zmienna	Coef	S.E.
const	-0.0239	0.056
SAVED	-0.1341	0.058
LATE60	0.2804***	0.061
TURNDOWN	0.4793***	0.058
HOUSE	-0.4198***	0.093
EDU_KIDS	0.0566	0.061
EDU_AGE	-0.3841***	0.063
EDU_DEBT_INCOME	-0.1627	0.198
EDU_MORTPAY_INC_MO	-0.0174	0.067
AGE_CONSPAY_INC_MO	0.1359*	0.078
AGE_REVPAY_TPAY	0.0993	0.082
MORTHEL_ASSET	0.3051**	0.095
MORTPAY_INC_MO	0.3362*	0.138
CONSPAY_INC_MO	-0.2044	0.11
REVPAY_INC_MO	-0.2697*	0.08
CONSPAY_TPAY	0.1892	0.099
REVPAY_TPAY	0.0343	0.083
INCOME_ASSET	0.0287	0.061
NETWORTH_INCOME	-0.2809*	0.138
SAVING_INC_MO	-0.2083*	0.086
SAVING_DEBT	0.2947	0.213
FOODHOME_INCOME	0.0575	0.091
* p < 0.05, ** p < 0.01, *** p < 0.001. N = 1608		

Źródło: opracowanie na podstawie wyników badań własnych.


Dla modelu regresji logistycznej dodanie wskaźników łączących zmienne demograficzne i finansowe spowodowało spadek całkowitej skuteczności modelu dla próby testowej z 71,89% do 71,39%, co oznacza spadek o 0,50 p.p. Spadek skuteczności dla próby uczącej wyniósł 0,19 p.p. Skuteczność modelu zawierającego zmienną wiek (trzeci zestaw zmiennych) była na poziomie porównywalnym ze skutecznością modelu opartego na drugim zestawie zmiennych. Uwzględnienie wskaźników demograficznych i finansowych oraz dodanie zmiennej wiek nie przyczyniło się do poprawy skuteczności modelu prognozującego upadłość konsumencką. Jest to jeden z dwóch modeli, w których dodanie wskaźników spowodowało niewielki spadek całkowitej skuteczności.

3.4.2. Maszyna wektorów nośnych

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM. Model został oszacowany dla drugiego zestawu zmiennych, który łączy zmienne demograficzne i finansowe. Całkowita skuteczność modelu dla pierwszego zestawu zmiennych wynosi 73,26% dla próby uczącej oraz 73,13% dla próby testowej. Błąd I typu wynosi 23,62%, a błąd II typu wynosi 29,80% dla próby uczącej. Dla próby testowej błąd I typu wynosi 22,97%, a błąd II typu 31,09%. Miara F1 dla próby uczącej wynosi 0,73 dla klasy 0 i 0,72 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,71 dla klasy 0 i 0,75 dla klasy 1. Miara Giniego wynosi 0,60 dla próby uczącej i 0,58 dla próby testowej. AUC wynosi 0,80 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 89 przedstawiono krzywą ROC.


Na wykresie 90 przedstawiono istotność cech wyznaczoną przez model SVM. Wśród najistotniejszych cech wskazanych przez model znajdują się: odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15) oraz udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów (X16).

Wykres 89. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 90. Istotność cech w modelu SVM opracowana dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne tych samych konsumentów. Na wykresie 91 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Na wykresie 92 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumenckiej, znajdują się: odmowa udzielenia kredytu (X25), posiadanie nieruchomości (X12), opóźnienia w spłacie zobowiązań (X15), wskaźnik relacji poziomu wykształcenia do wieku (X7) oraz posiadanie wydatków mniejszych niż dochody (X22).

Wykres 91. Podsumowanie wartości SHAP dla modelu SVM opracowane dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 92. Średni wpływ cech na wynik modelu SVM według wartości SHAP opracowany dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 93 oraz 94 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Najistotniejszymi cechami wpływającymi na predykcję pierwszego konsumenta (wykres 93) są opóźnienia w spłacie zobowiązań (X15) oraz udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne na podstawie wartości nieruchomości) w stosunku do całkowitych aktywów (X16). Wartości tych cech wpłynęły na zwiększenie ryzyka upadłości konsumenckiej, co spowodowało prawidłową predykcję modelu, który prognozował upadłość konsumencką.


W przypadku ostatniego konsumenta (wykres 94), wśród najważniejszych cech wpływających na predykcję są odmowa udzielenia kredytu (X25), posiadanie nieruchomości (X12), opóźnienia w spłacie zobowiązań (X15) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7). Wartości tych cech wpłynęły na zmniejszenie ryzyka upadłości u tego konsumenta. Model dokonał prawidłowej predykcji prognozując niskie ryzyko upadłości konsumenckiej.

Wykres 93. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

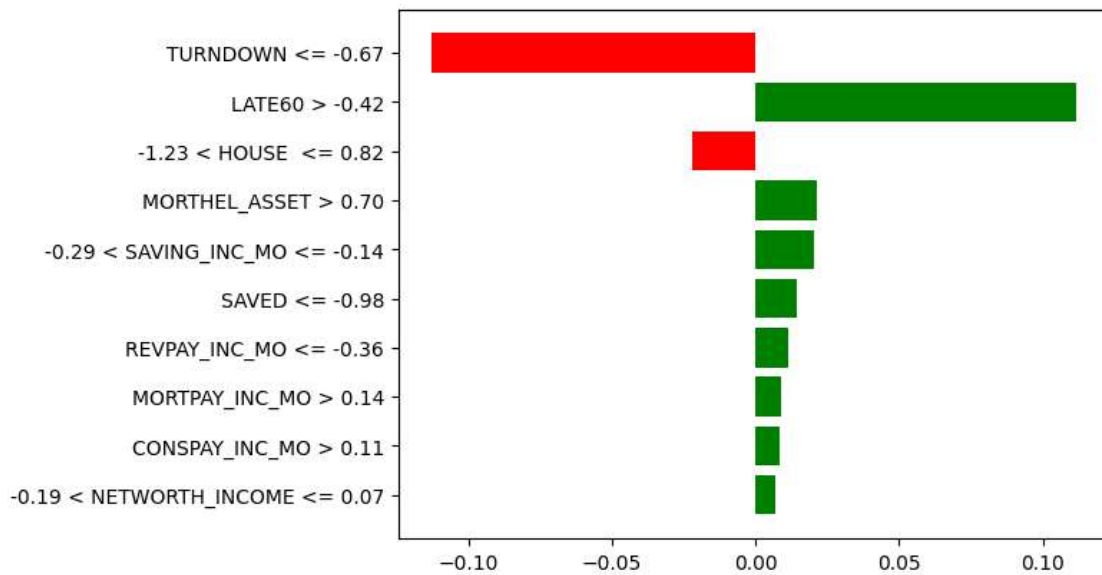
Wykres 94. Interpretacja wyniku modelu SVM dla drugiego konsumenta z użyciem metody SHAP opracowana na podstawie drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 95 i 96 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 95 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 96 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument ma 84% prawdopodobieństwo upadłości, a drugi 82% prawdopodobieństwo braku upadłości. Największy wpływ na przewidywanie upadłości pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), które zwiększyły prawdopodobieństwo upadłości, podczas gdy brak odmowy udzielenia kredytu (X25) obniżył to ryzyko. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak opóźnień w spłacie zobowiązań (X15) oraz brak odmowy udzielenia kredytu (X25), które wpłynęły na niskie ryzyko upadłości.

Wykres 95. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody LIME, opracowana na podstawie drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 96. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody LIME dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Dla modelu SVM wyniki osiągnięte na próbie testowej przy użyciu drugiego zestawu zmiennych były o 0,25 p.p. wyższe niż wyniki dla pierwszego zestawu zmiennych. Całkowita skuteczność modelu dla próby testowej wzrosła z 72,89% do 73,13%. Wzrost skuteczności dla próby uczącej był minimalny i wyniósł 0,06 p.p. Drugi zestaw zmiennych, oprócz nowych wskaźników, zawiera także nową zmienną wiek. Dodanie samej zmiennej wiek do pierwszego

zestawu zmiennych (trzeci zestaw zmiennych) spowodowało również wzrost całkowitej skuteczności o 0,25 p.p. W przypadku modelu SVM dodanie zmiennych przyniosło najniższy wzrost w porównaniu do innych algorytmów oprócz modelu regresji logistycznej oraz drzewa decyzyjnego, gdzie zaobserwowano spadek całkowitej skuteczności.

3.4.3. Drzewo decyzyjne

W niniejszym podrozdziale przedstawiono wyniki badań nad modelem prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu drzewa decyzyjnego. Model został oszacowany na drugim zestawie zmiennych, zawierającym wskaźniki zbudowane na zmiennych demograficznych oraz finansowych. Całkowita skuteczność modelu drzewa decyzyjnego wynosi 73,20% dla próby uczącej oraz 72,64% dla próby testowej. Błąd I typu wynosi 24,87%, a błąd II typu 28,69% dla próby uczącej. Dla próby testowej błąd I typu wynosi 25,84%, a błąd II typu 29,02%. Miara F1 dla próby uczącej wynosi 0,73 dla klasy 0 i 0,74 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,71 dla klasy 0 i 0,74 dla klasy 1. Miara Giniego wynosi 0,60 dla próby uczącej i 0,52 dla próby testowej. Miara AUC wynosi 0,80 dla próby uczącej i 0,76 dla próby testowej. Na wykresie 97 przedstawiono krzywą ROC dla modelu drzewa decyzyjnego.


Wykres 97. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem drzewa decyzyjnego opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 98 przedstawiono istotność cech wyznaczoną przez model drzewa decyzyjnego. Istotność cech określa wpływ poszczególnych cech na decyzje podejmowane przez model. Wśród najistotniejszych cech wskazanych przez model znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w dochodzie (X18), wskaźnik relacji poziomu wykształcenia do wieku (X7), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 98. Istotność cech w modelu drzewa decyzyjnego opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 99 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.

Wykres 99. Podsumowanie wartości SHAP dla modelu drzewa decyzyjnego opracowane dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 100 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumentów, znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w dochodzie (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), wskaźnik relacji poziomu wykształcenia do wieku (X7) oraz wskaźnik relacji wieku do udziału całkowitego zadłużenia odnawialnego do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X3).


Ponadto wartości SHAP mogą być również wykorzystywane do tworzenia wyjaśnień dla każdej obserwacji w zbiorze danych. Na wykresie 101 i 102 przedstawiono wyjaśnienia indywidualne dla trzech predykcji. Największy wpływ na predykcję pierwszego konsumenta (wykres 100) miały następujące cechy: udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15) oraz udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11). Wartości tych cech zwiększyły ryzyko upadłości konsumentki. Model poprawnie przewidział upadłość konsumentki, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.

Wykres 100. Średni wpływ cech wejściowych na wynik modelu drzewa decyzyjnego według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 101. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Największy wpływ na predykcję drugiego konsumenta (wykres 102) miały następujące cechy: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz opóźnienia w spłacie zobowiązań (X15). Wartości tych trzech cech wpłynęły na zmniejszenie prawdopodobieństwa upadłości konsumenckiej. Model poprawnie zaklasyfikował tego konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.


Wykres 102. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 103 i 104 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 103 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 104 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 56%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 97%. Największy wpływ na przewidywanie pierwszego konsumenta miał udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18).

Wykres 103. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zbioru zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 104. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zbioru zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Porównując wyniki osiągnięte przez model drzewa decyzyjnego zbudowanego na pierwszym zestawie zmiennych z modelem zbudowanym na drugim zestawie zmiennych, po dodaniu wskaźników łączących zmienne demograficzne i finansowe, całkowita skuteczność modelu dla próby testowej spadła z 73,38% do 72,64%, co oznacza spadek o 0,75 p.p. Skuteczność modelu dla próby uczącej pozostała na tym samym poziomie. Dodanie wyłącznie

zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność modelu jedynie o 0,25 p.p. Model drzewa decyzyjnego jest jednym z dwóch algorytmów, w których dodanie nowych wskaźników spowodowało spadek całkowitej skuteczności. Dodanie samej zmiennej wiek (X1) spowodowało jedynie marginalny wzrost skuteczności.

3.4.4. Las losowy

W niniejszym podrozdziale przedstawiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu lasu losowego dla drugiego zestawu zmiennych, wykorzystujących wskaźniki, które łączą różne rodzaje informacji w ocenie sytuacji finansowej gospodarstw domowych. Całkowita skuteczność modelu wynosi 76,74% dla próby uczącej oraz 76,62% dla próby testowej. Błąd I typu wynosi 20,35%, a błąd II typu 26,11% dla próby uczącej. Dla próby testowej błąd I typu wynosi 21,53%, a błąd II typu 25,39%. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0 oraz 0,77 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,75 i 0,78. Miara Giniego wynosi 0,70 dla próby uczącej i 0,61 dla próby testowej. AUC wynosi 0,85 dla próby uczącej, a 0,81 dla próby testowej. Na wykresie 105 przedstawiono krzywą ROC dla algorytmu lasu losowego.


Wykres 105. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem lasu losowego opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 106 zaprezentowano istotność cech określoną przez model oparty na lasach losowych. Do najważniejszych cech należą: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia do wieku (X7) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20).


Wykres 106. Istotność cech w modelu lasu losowego opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 107 zaprezentowano wpływ poszczególnych cech na wynik predykcji modelu w oparciu o wartości SHAP.

Wykres 107. Podsumowanie wartości SHAP dla modelu lasu losowego opracowane dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 108 cechy zostały uporządkowane na podstawie ich średnich bezwzględnych wartości SHAP. Do najważniejszych czynników wpływających na przewidywanie upadłości konsumenckiej należą: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24).


Dodatkowo, na wykresach 109 oraz 110 zaprezentowano wyjaśnienia indywidualne dla dwóch predykcji. W przypadku pierwszego konsumenta (wykres 109) największy wpływ na wynik predykcji modelu miały następujące cechy: opóźnienia w spłacie zobowiązań (X15) oraz wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10). Cechy te zwiększyły ryzyko upadłości tego konsumenta. Model poprawnie przewidział upadłość konsumencką, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.

Wykres 108. Średni wpływ cech na wynik modelu lasu losowego według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 109. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta przy użyciu metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Największy wpływ na predykcję drugiego konsumenta (wykres 110) mają następujące cechy: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10) oraz brak odmowy udzielenia kredytu (X25). Wartości tych cech zmniejszają ryzyko upadłości konsumenckiej u tego konsumenta. Konsument nie wnioskował o upadłość konsumencką i został poprawnie zaklasyfikowany przez model.

Wykres 110. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 111 i 112 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 111 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 112 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument ma 85% prawdopodobieństwo upadłości, a drugi 85% prawdopodobieństwo braku upadłości. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24) oraz udział


zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X16), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) oraz brak opóźnień w spłacie zobowiązań (X15), które zmniejszyły ryzyko upadłości.

Wykres 111. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 112. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Porównując wyniki osiągnięte przez model zbudowany na pierwszym zestawie zmiennych do modelu zbudowanego na drugim zestawie zmiennych, po dodaniu wskaźników łączących zmienne demograficzne i finansowe, całkowita skuteczność modelu dla próby testowej wzrosła z 73,88% do 76,62%, co oznacza wzrost o 2,74 p.p. Wzrost skuteczności dla próby uczącej był na podobnym poziomie i wyniósł 2,67 p.p. Dodanie wyłącznie zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność modelu o 1,49 p.p. W przypadku modelu lasu losowego zarówno dodanie zmiennej wiek (X1), jak i uwzględnienie wskaźników opartych na zmiennych demograficznych i finansowych przyczyniły się do poprawy skuteczności modelu. Najwyższą skuteczność osiągnął model zawierający wskaźniki oparte na kombinacji zmiennych demograficznych z finansowymi (76,62%), następnie model zawierający zmienną wiek (75,37%), a najniższą skuteczność uzyskał pierwszy zestaw zmiennych (73,88%).

3.4.5. Adaptive Boosting

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania ryzyka upadłości konsumenckiej z wykorzystaniem algorytmu AdaBoost. Model został oszacowany dla drugiego zestawu zmiennych, zawierających wskaźniki, które łączą różne rodzaje informacji w ocenie sytuacji finansowej gospodarstw domowych. Całkowita skuteczność modelu AdaBoost wynosi 76,24% dla próby uczącej i 75,12% dla próby testowej. Błąd I typu wynosi 23,99%, a błąd II typu 23,52% dla próby uczącej. Dla próby testowej błąd I typu wynosi 24,40%, a błąd II typu 25,39%. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0 i 0,76 dla klasy 1, natomiast dla próby testowej wynosi odpowiednio 0,74 dla klasy 0 i 0,76 dla klasy 1. Miara Giniego wynosi 0,70 dla próby uczącej i 0,57 dla próby testowej. AUC wynosi 0,85 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 113 przedstawiono krzywą ROC.


Na wykresie 114 przedstawiono istotność cech wyznaczoną przez model AdaBoost. Wśród najistotniejszych cech znajdują się: wskaźnik relacji wieku w stosunku do udziału miesięcznych spłat zadłużenia konsumpcyjnego do miesięcznego dochodu (X2), udział środków z kont oszczędnościowych do miesięcznego dochodu (X24), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) i udział dochodu w stosunku do całkowitych aktywów (X13).

Wykres 113. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem algorytmu AdaBoost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 114. Istotność cech w modelu AdaBoost opracowana dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono

interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 115 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 115. Podsumowanie wartości SHAP dla modelu AdaBoost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 116 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najistotniejszych cech, które miały kluczowy wpływ na przewidywanie upadłości konsumentów, znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), udział całkowitego zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 116. Średni wpływ cech na wynik modelu AdaBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 117 oraz 118 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Dla pierwszego konsumenta (wykres 117) najistotniejszymi cechami mającymi wpływ na predykcję są: opóźnienia w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7). Opóźnienia w spłacie zobowiązań (X15) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) wpłynęły na zwiększenie ryzyka upadłości konsumenckiej. Model poprawnie przewidział upadłość konsumencką, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.


Wykres 117. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

W przypadku drugiego konsumenta (wykres 118), najistotniejszymi cechami wpływającymi na przewidywanie upadłości konsumenckiej są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), odmowa udzielenia kredytu (X25) oraz opóźnienia w spłacie zobowiązań (X15). Cechy te wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej. Model poprawnie zaklasyfikował konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.


Wykres 118. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 119 i 120 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 119 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 120 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 63%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 76%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zmniejszyło ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) oraz brak opóźnień w spłacie zobowiązań (X15).

Wykres 119. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 120. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Porównując wyniki modeli zbudowanych na pierwszym i drugim zestawie zmiennych, po dodaniu wskaźników, całkowita skuteczność modelu dla próby testowej wzrosła z 73,88% do 75,12%, co oznacza wzrost o 1,24 p.p. Wzrost skuteczności dla próby uczącej był na podobnym poziomie i wyniósł 1,49 p.p. Dodanie wyłącznie zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność modelu o 1,49 p.p. W

przypadku modelu AdaBoost zarówno dodanie zmiennej wiek (X1), jak i uwzględnienie wskaźników przyczyniły się do poprawy skuteczności modelu. Najwyższą skuteczność osiągnął model zawierający zmienną wiek (75,37%), następnie model ze wskaźnikami (75,12%), a najniższą skuteczność uzyskał model oparty na pierwszym zestawie zmiennych (73,88%).

3.4.6. Gradient Boosting Classifier

W niniejszym podrozdziale omówiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu Gradient Boosting Classifier. Model został oszacowany na drugim zestawie zmiennych zawierającym wskaźniki. Całkowita skuteczność modelu wynosi 76,68% dla próby uczącej i 76,37% dla próby testowej. Błąd I typu wynosi 20,60%, a błąd II typu 25,99% dla próby uczącej. Dla próby testowej błąd I typu wynosi 21,53%, a błąd II typu 25,91%. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0, a 0,77 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,75 dla klasy 0 i 0,78 dla klasy 1. Miara Giniego wynosi 0,70 dla próby uczącej i 0,61 dla próby testowej. AUC wynosi 0,85 dla próby uczącej i 0,81 dla próby testowej. Na wykresie 121 przedstawiono krzywą ROC.


Wykres 121. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem modelu Gradient Boosting Classifier opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 122 przedstawiono istotność cech wyznaczoną przez model Gradient Boosting Classifier. Wśród najistotniejszych cech znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7).


Wykres 122. Istotność cech w modelu Gradient Boosting Classifier opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 123 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 123. Podsumowanie SHAP dla modelu Gradient Boosting Classifier opracowane dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 124 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumenckiej są: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 124. Średni wpływ cech na wynik modelu Gradient Boosting Classifier według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 125 oraz 126 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. W przypadku pierwszego konsumenta (wykres 125), wśród najistotniejszych cech mających wpływ na predykcję są: opóźnienia w spłacie zobowiązań (X15), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów (X16), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu. Wartości tych cech zwiększyły prawdopodobieństwo upadłości konsumenckiej. Konsument został prawidłowo zaklasyfikowany przez model.


Wykres 125. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wśród najważniejszych cech mających wpływ na predykcję drugiego konsumenta (wykres 126) znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz udział dochodu w stosunku do całkowitych aktywów (X13). Wartości tych cech zmniejszyły ryzyko upadłości konsumenckiej. Model prawidłowo zaklasyfikował konsumenta jako osobę, która ma niskie ryzyko upadłości.

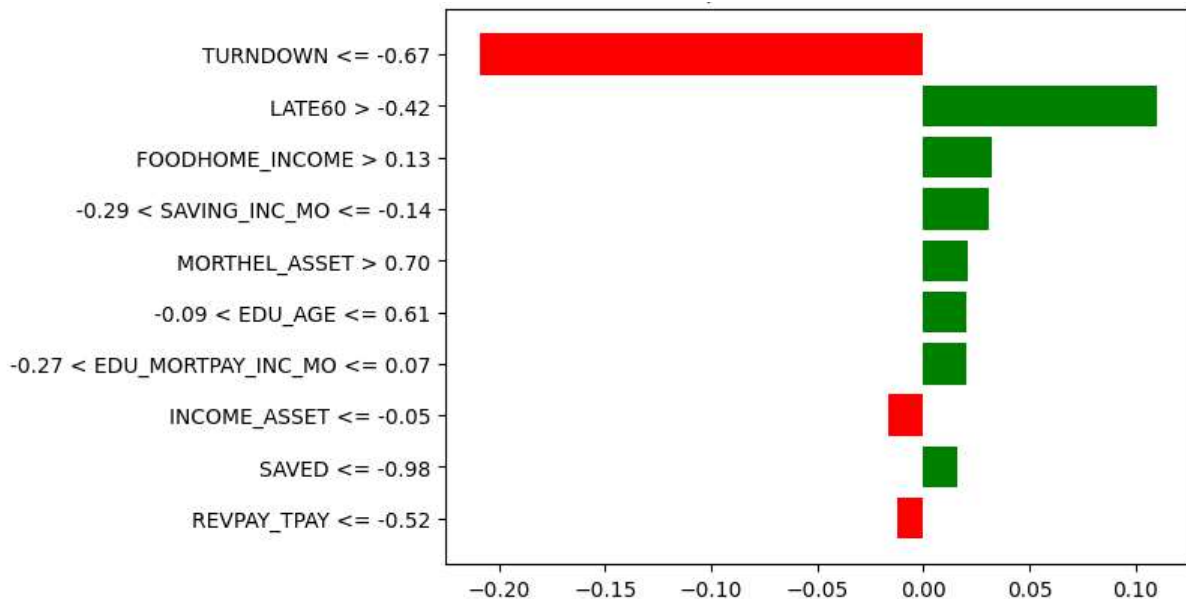
Wykres 126. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 127 i 128 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 127 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 128 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 72%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 80%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15). Opóźnienia w spłacie zobowiązań (X15) zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zmniejszyło ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7).

Wykres 127. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 128. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Dla modelu Gradient Boosting Classifier dodanie wskaźników spowodowało wzrost całkowitej skuteczności modelu dla próby testowej z 74,13% do 76,37%, co oznacza wzrost o 2,24 p.p. Wzrost skuteczności dla próby uczącej wyniósł 1,24 p.p. Dodanie wyłącznie zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność pierwszego modelu o 1 p.p. dla próby testowej. W przypadku modelu Gradient Boosting

Classifier zarówno uwzględnienie wskaźników oraz dodanie zmiennej wiek (X1) przyczyniło się do poprawy skuteczności modelu prognozującego upadłość konsumencką. Najwyższą skuteczność osiągnął model zawierający wskaźniki (76,37%), następnie model zawierający zmienną wiek (75,12%), a najniższą skuteczność uzyskał model zbudowany na pierwszym zestawie zmiennych (74,13%).

3.4.7. Extreme Gradient Boosting

W kolejnym podrozdziale przedstawiono wyniki badań dotyczące modelu prognozowania ryzyka upadłości konsumenckiej z zastosowaniem algorytmu XGBoost. Model został oszacowany dla drugiego zestawu zmiennych zawierającego wskaźnik bazujące na kombinacji zmiennych demograficznych i finansowych. Całkowita skuteczność modelu XGBoost wynosi 76,80% dla próby uczącej oraz 76,62% dla próby testowej. Błąd I typu wynosi 20,98%, a błąd II typu wynosi 25,37% dla próby uczącej. Dla próby testowej błąd I typu wynosi 22,01%, a błąd II typu wynosi 24,87%. Miara F1 dla próby uczącej wynosi 0,76 dla klasy 0 i 0,77 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,76 dla klasy 0 i 0,78 dla klasy 1. Miara Giniego wynosi 0,70 dla próby uczącej i 0,61 dla próby testowej. AUC wynosi 0,85 dla próby uczącej i 0,80 dla próby testowej. Na wykresie 129 przedstawiono krzywą ROC.


Wykres 129. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu XGBoost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 130 przedstawiono istotność cech wyznaczoną przez model XGBoost. Wśród najistotniejszych cech znajdują się: odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), posiadanie wydatków mniejszych niż dochody (X22) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7).


Wykres 130. Istotność cech w modelu XGBoost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 131 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 131. Podsumowanie wartości SHAP dla modelu XGBoost opracowane dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 132 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Do najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumentów należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział środków z kont oszczędnościowych do miesięcznego dochodu (X24), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz opóźnienia w spłacie zobowiązań (X15).


Wykres 132. Średni wpływ cech na wynik modelu XGBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 133 oraz 134 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. W przypadku pierwszego konsumenta (wykres 133), najważniejszymi cechami wpływającymi na predykcję są: opóźnienia w spłacie zobowiązań (X15), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), udział całkowitego zadłużenia odnawialnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X21) oraz posiadanie wydatków mniejszych niż dochody (X22). Cechy te wpłynęły na zwiększenie ryzyka upadłości konsumenckiej. Model poprawnie przewidział wysokie ryzyko upadłości konsumenckiej, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.


Wykres 133. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Najważniejszymi cechami wpływającymi na predykcję drugiego konsumenta (wykres 134) są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10) oraz odmowa udzielenia kredytu (X25). Cechy te wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej tego konsumenta. Model zaklasyfikował konsumenta jako osobę z niskim ryzykiem upadłości konsumenckiej.


Wykres 134. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 135 i 136 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 135 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 136 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 80%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 91%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zadziałało na jego korzyść, zmniejszając ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18).

Wykres 135. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 136. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Dla modelu XGBoost, wykorzystując wskaźniki łączące zmienne demograficzne i finansowe, całkowita skuteczność modelu dla próby testowej wzrosła z 75,12% do 76,62%, co oznacza wzrost o 1,49 p.p w porównaniu do pierwszego zestawu zmiennych. Wzrost skuteczności dla próby uczącej wyniósł 2,49 p.p. Dodanie wyłącznie zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło całkowitą skuteczność


pierwszego modelu tylko o 0,25 p.p. Uwzględnienie wskaźników opartych na zmiennych demograficznych i finansowych przyczyniło się do poprawy skuteczności modelu. Najwyższą skuteczność osiągnął model zawierający wskaźniki (76,62%), następnie model zawierający zmienną wiek (75,37%), a najniższy wynik model zbudowany na pierwszym zestawie zmiennych (75,12%).

3.4.8. Light Gradient Boosting Machine

W niniejszym podrozdziale omówiono model prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu LightGBM. Model został oszacowany dla drugiego zestawu zmiennych, obejmującego wskaźniki łączące różne rodzaje informacji w ocenie sytuacji finansowej gospodarstw domowych. Całkowita skuteczność modelu dla pierwszego zestawu zmiennych wynosi 77,80% w próbie uczącej i 77,11% w próbie testowej. Spośród wszystkich modeli przygotowanych w drugim zestawie zmiennych, ten model osiągnął najwyższą skuteczność. Błąd I typu wynosi 19,10%, a błąd II typu 25,25% w próbie uczącej. Dla próby testowej błąd I typu wynosi 20,10%, a błąd II typu 25,91%. Miara F1 dla próby uczącej wynosi 0,77 dla klasy 0 oraz 0,78 dla klasy 1, natomiast dla próby testowej odpowiadające wartości to 0,76 dla klasy 0 i 0,78 dla klasy 1. Miara Giniego wynosi 0,72 dla próby uczącej i 0,61 dla próby testowej. AUC wynosi 0,86 dla próby uczącej i 0,80 dla próby testowej. Na wykresie 137 przedstawiono krzywą ROC.


Na wykresie 138 przedstawiono istotność cech wyznaczoną przez model LightGBM. Do najistotniejszych cech należą: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20).

Wykres 137. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem modelu LightGBM opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 138. Istotność cech w modelu LightGBM opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Podobnie jak w przypadku wcześniejszych modeli, dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 139 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 139. Podsumowanie wartości SHAP dla modelu LightGBM opracowane dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 140 cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP. Wśród najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumentów są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24).


Wykres 140. Średni wpływ cech na wynik modelu LightGBM według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 141 oraz 142 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. U pierwszego konsumenta (wykres 141) najistotniejszymi czynnikami wpływającymi na predykcję były cechy: opóźnienia w spłacie zobowiązań (X15) oraz wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10). Cechy te zwiększyły ryzyko upadłości konsumenckiej. Model poprawnie przewidział upadłość konsumencką, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.


Wykres 141. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

U drugiego konsumenta (wykres 142) wśród najistotniejszych czynników wpływających na predykcję są: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10), odmowa udzielenia kredytu (X25) oraz udział dochodu w stosunku do całkowitych aktywów (X13). Wartości tych cech u tego konsumenta zmniejszyły prawdopodobieństwo upadłości konsumenckiej. Model poprawnie zaklasyfikował tego konsumenta jako osobę wykazującą niskie ryzyko upadłości konsumenckiej.

Wykres 142. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 143 i 144 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 143 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 144 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 56%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 61%. Największy wpływ na przewidywanie pierwszego konsumenta miały udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7), wskaźnik relacji poziomu wykształcenia do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10) oraz udział zadłużenia związanego z nieruchomościami do całkowitych aktywów (X16), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zmniejszyło ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały udział wartości netto majątku (różnica między aktywami


a długiem) do dochodu (X18), brak odmowy udzielenia kredytu (X25), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10).

Wykres 143. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 144. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Porównując wyniki osiągnięte przez model zbudowany na pierwszym zestawie zmiennych do modelu zbudowanego na drugim zestawie zmiennych, po dodaniu wskaźników,


całkowita skuteczność modelu LightGBM dla próby testowej wzrosła z 76,12% do 77,11%, co oznacza wzrost o 1 p.p. Wzrost skuteczności dla próby uczącej był na podobnym poziomie i wyniósł 0,56 p.p. Dodanie wyłącznie zmiennej wiek do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność modelu tylko o 0,25 p.p. W przypadku modelu LightGBM uwzględnienie wskaźników przyczyniło się do poprawy skuteczności modelu. Dodanie zmiennej wiek (X1) miało marginalny wpływ na model. Najwyższą skuteczność osiągnął model zawierający wskaźniki oparte na kombinacji zmiennych demograficznych z finansowymi (77,11%), następnie model zawierający zmienną wiek (76,37%), a najniższą skuteczność uzyskał model zbudowany na pierwszym zestawie zmiennych (76,12%).

3.4.9. Categorical Boosting

W kolejnym podrozdziale przedstawione zostały wyniki badań nad modelem prognozowania ryzyka upadłości konsumenckiej z wykorzystaniem algorytmu CatBoost. Model został oszacowany na drugim zestawie zmiennych zawierającym wskaźniki łączące różne typy zmiennych. Całkowita skuteczność modelu CatBoost wynosi 77,24% dla próby uczącej oraz 77,11% dla próby testowej. Błąd I typu wynosi 21,73%, a błąd II typu 23,77% dla próby uczącej, natomiast dla próby testowej odpowiadające wartości to 21,53% i 24,87%. Miara F1 dla próby uczącej wynosi 0,77 dla obu klas (0 i 1), natomiast dla próby testowej miara F1 dla klasy 0 wynosi 0,76 i 0,77 dla klasy 1. Miara Giniego wynosi 0,70 dla próby uczącej i 0,61 dla próby testowej. AUC wynosi 0,87 dla próby uczącej i 0,80 dla próby testowej. Na wykresie 145 przedstawiono krzywą ROC.


Na wykresie 146 przedstawiono istotność cech wyznaczoną przez model Catboost. Wśród najistotniejszych cech znajdują się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz opóźnienia w spłacie zobowiązań (X15).

Wykres 145. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu Catboost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 146. Istotność cech w modelu Catboost opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej przedstawiono interpretacje z wykorzystaniem dwóch metod: SHAP oraz LIME. Dla metody SHAP przeprowadzono interpretację globalną oraz interpretacje indywidualne dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. Dla metody LIME zaprezentowano interpretacje indywidualne dla tych samych konsumentów. Na wykresie 147 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.


Wykres 147. Podsumowanie wartości SHAP dla modelu CatBoost opracowane dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Ponadto, cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP (wykres 148). Do najważniejszych cech, które odegrały kluczową rolę w przewidywaniu upadłości konsumenckiej należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), udział środków z kont oszczędnościowych do miesięcznego dochodu (X24) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7).


Wykres 148. Średni wpływ cech na wynik modelu CatBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 149 oraz 150 przedstawiono wyjaśnienia indywidualne dla dwóch predykcji. Najistotniejszymi cechami, które wpłynęły na predykcję pierwszego konsumenta (wykres 149) są: opóźnienia w spłacie zobowiązań (X15), udział dochodu w stosunku do całkowitych aktywów (X13) oraz udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów (X16). Opóźnienia w spłacie zobowiązań (X15) oraz udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów (X16) wpłynęły na zwiększenie prawdopodobieństwa upadłości konsumenckiej, natomiast udział dochodu w stosunku do całkowitych aktywów (X13) wpłynęła na zmniejszenie ryzyka upadłości konsumenckiej. Model poprawnie przewidział wysokie ryzyko upadłości konsumenckiej, prognozując wartość 1, która była zgodna z rzeczywistym wynikiem.


Wykres 149. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

W przypadku drugiego konsumenta (wykres 150), do cech, które miały największy wpływ na predykcję należą: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10). Wartości tych cech wpłynęły na zmniejszenie ryzyka upadłości konsumenckiej. Model poprawnie zaklasyfikował konsumenta jako osobę wykazującą niskie ryzyko upadłości konsumenckiej.


Wykres 150. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Na wykresach 151 i 152 zaprezentowano interpretacje metodą LIME dla dwóch konsumentów. Wykres 151 przedstawia konsumenta, dla którego model przewidział wynik klasy 1 (upadłość), a wykres 152 pokazuje konsumenta, dla którego przewidziano wynik klasy 0 (brak upadłości). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 66%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 79%. Największy wpływ na przewidywanie pierwszego konsumenta miały opóźnienia w spłacie zobowiązań (X15), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zmniejszyło ryzyko upadłości. W przypadku drugiego konsumenta największy wpływ na predykcję miały brak odmowy udzielenia kredytu (X25), brak opóźnień w spłacie zobowiązań (X15) oraz udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18).

Wykres 151. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 152. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Dla modelu CatBoost dodanie wskaźników łączących zmienne demograficzne i finansowe spowodowało wzrost całkowitej skuteczności modelu dla próby testowej z 75,87% do 76,87%, co oznacza wzrost o 1 p.p. Wzrost skuteczności dla próby uczącej był na podobnym poziomie i wyniósł 1,31 p.p. Dodanie wyłącznie zmiennej wiek (X1) do pierwszego zestawu

zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność pierwszego modelu o 0,75 p.p. W przypadku modelu CatBoost zarówno uwzględnienie wskaźników oraz dodanie zmiennej wiek (X1) przyczyniło się do poprawy skuteczności modelu prognozującego upadłość konsumentką. Najwyższą skuteczność osiągnął model zawierający wskaźniki (76,87%), następnie model zawierający zmienną wiek (76,62%), a najniższą skuteczność uzyskał model zbudowany na pierwszym zestawie zmiennych (75,87%).

3.4.10. Sieci neuronowe

W kolejnym podrozdziale przedstawiono wyniki badań nad modelem prognozowania ryzyka upadłości konsumentkiej z wykorzystaniem algorytmu sieci neuronowych. Model został oszacowany dla drugiego zestawu zmiennych zawierającego wskaźniki bazujące na zmiennych demograficznych i finansowych. Całkowita skuteczność modelu wynosi 74,38% dla próby uczącej i 74,13% dla próby testowej. Błąd I typu wynosi 22,24%, a błąd II typu 28,94% w próby uczącej. Dla próby testowej wartości te wynoszą odpowiednio 24,40% oraz 27,46%. Miara F1 w próby uczącej wynosi 0,74 dla klasy 0 i 0,75 dla klasy 1, natomiast w próby testowej odpowiadające wartości to 0,73 dla klasy 0 i 0,75 dla klasy 1. Miara Giniego osiąga 0,63 dla próby uczącej i 0,57 dla próby testowej. Wartość AUC wynosi 0,81 dla próby uczącej i 0,79 dla próby testowej. Na wykresie 153 przedstawiono krzywą ROC.


Wykres 153. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem sieci neuronowych opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 154 przedstawiono istotność cech wyznaczoną przez model sieci neuronowych. Wśród najistotniejszych cech znajdują się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20) i posiadanie wydatków mniejszych niż dochody (X22).


Wykres 154. Istotność cech w modelu sieci neuronowych opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Poniżej, podobnie jak w przypadku poprzednich algorytmów, przedstawiono interpretacje modelu za pomocą dwóch metod: SHAP oraz LIME. W metodzie SHAP zaprezentowano zarówno interpretację globalną, jak i indywidualne analizy dla dwóch konsumentów: wnioskującego o upadłość oraz niewnioskującego o upadłość. W przypadku metody LIME przedstawiono interpretacje indywidualne dla tych samych konsumentów. Na wykresie 155 przedstawiono wpływ poszczególnych cech na wynik predykcji modelu.

Wykres 155. Podsumowanie wartości SHAP dla modelu sieci neuronowych opracowane dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Cechy zostały uszeregowane według ich średnich bezwzględnych wartości SHAP i zaprezentowane na wykresie 156. Do najistotniejszych czynników wpływających na przewidywanie upadłości konsumenckiej należą: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20).


Na wykresach 157 i 158 przedstawiono indywidualne wyjaśnienia dla dwóch predykcji. Do najistotniejszych cech wpływających na predykcję pierwszego konsumenta (wykres 157) należą: opóźnienia w spłacie zobowiązań (X15), udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu oraz udział całkowitego zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X17). Czynniki te zwiększyły ryzyko upadłości konsumenckiej. Model poprawnie zaklasyfikował konsumenta, prognozując wartość 1, co było zgodne z rzeczywistym wynikiem.

Wykres 156. Średni wpływ cech na wynik modelu sieci neuronowych według wartości SHAP opracowany dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.


Wykres 157. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody SHAP opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Dla drugiego konsumenta (wykres 158) kluczowe cechy to: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), odmowa udzielenia kredytu (X25) oraz opóźnienia w spłacie zobowiązań (X15). Model poprawnie zaklasyfikował konsumenta jako osobę o niskim ryzyku upadłości.

Wykres 158. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody SHAP opracowana dla drugiego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresach 159 i 160 przedstawiono interpretację metodą LIME dla dwóch konsumentów. Wykres 159 dotyczy konsumenta, dla którego model przewidział upadłość (klasa 1), natomiast wykres 160 odnosi się do konsumenta, dla którego prognozowano brak upadłości (klasa 0). Model ocenił, że pierwszy konsument zbankrutuje z prawdopodobieństwem 80%, natomiast drugi konsument nie zbankrutuje z prawdopodobieństwem 90%. Największy wpływ na predycję pierwszego konsumenta mają opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17), które zwiększyły prawdopodobieństwo upadłości, natomiast brak odmowy udzielenia kredytu (X25) u tego konsumenta zmniejszyło ryzyko upadłości. W przypadku drugiego konsumenta największy


wpływ na predykcję miały brak opóźnień w spłacie zobowiązań (X15), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), brak odmowy udzielenia kredytu (X25) oraz wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7).

Wykres 159. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Wykres 160. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Dla modelu sieci neuronowych dodanie wskaźników łączących zmienne demograficzne i finansowe spowodowało wzrost całkowitej skuteczności modelu dla próby testowej z 73,13%

do 74,13%, co oznacza wzrost o 1 p.p. Wzrost skuteczności dla próby uczącej był na podobnym poziomie i wyniósł 0,81 p.p. Dodanie wyłącznie zmiennej wiek (X1) do pierwszego zestawu zmiennych (trzeci zestaw zmiennych) zwiększyło skuteczność modelu o 2,74 p.p. Skuteczność modelu sieci neuronowych dla trzeciego zestawu zmiennych była wyższa nie tylko w porównaniu do pierwszego zestawu zmiennych ale również drugiego zestawu zmiennych. Najwyższą skuteczność osiągnął model zawierający zmienną wiek (75,87%), następnie model zawierający wskaźniki (74,13%), a najniższą skuteczność uzyskał model zbudowany na pierwszym zestawie zmiennych (73,13%).

3.4.11. Metody agregacji klasyfikatorów

Modele zespołowe zostały oszacowane z uwzględnieniem metody uśredniania, głosowania oraz stacking. Powyższe metody przetestowano w różnych kombinacjach. Poniżej zaprezentowano wybrane modele.

Wykorzystując uśrednianie, przy połączeniu algorytmu LightGBM i CatBoost (z zastosowanymi wagami 0,5), całkowita skuteczność wynosi 77,24% dla próby uczącej oraz 77,36% dla próby testowej. Osiągnięta skuteczność jest o 0,25 p.p. wyższa niż skuteczność modelu LightGBM dla próby testowej. Błąd I typu wynosi 21,48%, a błąd II typu 24,01% dla próby uczącej. Natomiast dla próby testowej, błąd I typu wynosi 21,05%, a błąd II typu 24,35%. Miara F1 dla próby uczącej wynosi 0,77 dla oby klas (0 i 1), natomiast dla próby testowej wartość tej miary wynosi 0,76 dla klasy 0 oraz 0,78 dla klasy 1. Miara Giniego wynosi 0,73 dla próby uczącej oraz 0,61 dla próby testowej. Wartość miary AUC wynosi odpowiednio 0,87 dla próby uczącej i 0,81 dla próby testowej.

Przy modyfikacji wag do poziomu 0,7 dla modelu LightGBM i 0,3 dla algorytmu CatBoost, całkowita skuteczność wynosi 77,80% dla próby uczącej i 77,36% dla próby testowej. Osiągnięta skuteczność jest o 0,25 p.p. wyższa niż skuteczność modelu LightGBM dla próby testowej. Dla próby uczącej błąd I typu wynosi 20,73%, a błąd drugiego typu 23,65%. Dla próby testowej błąd I typu wynosi 21,05%, a błąd drugiego typu 24,35%. Miary Giniego oraz AUC nie uległy zmianie w porównaniu do uśredniania z wykorzystaniem wag 0,5.

Taką samą skuteczność udało się osiągnąć przy połączeniu modeli LightGBM, XGBoost oraz CatBoost (wykorzystując wagi 0,6/0,1/0,3). Osiągnięta skuteczność jest o 0,25 p.p. wyższa niż skuteczność modelu LightGBM dla próby testowej. Całkowita skuteczność modelu dla próby uczącej wyniosła 77,67%, a dla próby testowej 77,36. Błędy I i II typu były podobnym poziomie, co w przypadku modelu łączącego LightGBM i CatBoost (wagi 0,5) oraz LightGBM i CatBoost (wagi 0,7/0,3). Pozostałe miary różniły się nieznacznie.

Podobne wyniki osiągnięto przy połączeniu algorytmów CatBoost i XGBoost (z wagami 0,85/0,15). Całkowita skuteczność modelu dla próby uczącej wynosi 77,24%, a dla próby testowej wynosi 77,36%. Osiągnięta skuteczność jest o 0,25 p.p. wyższa niż skuteczność modelu LightGBM dla próby testowej. Dla próby uczącej błąd I typu wynosi 21,98%, a błąd II typu 23,52%. Dla próby testowej błąd I typu wynosi 21,05%, a błąd II typu 24,35%. Miara F1, Giniego oraz AUC są na tym samym poziomie co miary osiągnięte przez połączenie modeli LightGBM oraz CatBoost.

Najwyższa skuteczność modelu została osiągnięta przez połączenie modeli LightGBM oraz XGBoost (z wagami 0,8 i 0,2). Dla próby testowej całkowita skuteczność wynosi 77,61% i jest o 0,50 p.p. wyższa niż dla pojedynczego algorytmu LightGBM. Dla próby uczącej całkowita skuteczność wynosi 77,11%. Błąd I typu wynosi 20,10%, a błąd II typu 25,62% dla próby uczącej, natomiast dla próby testowej błąd I typu wynosi 20,57%, a błąd II typu 24,35%. Pozostałe miary były na zbliżonym lub takim samym poziomie jak w przypadku innych modeli wykorzystujących uśrednianie.

Analizując skuteczność modeli z wykorzystaniem głosowania większościowego najwyższą skuteczność osiągnięto przy połączeniu LightGBM oraz CatBoost. Powyższe wyniki zostały osiągnięte przy założeniu, że przynajmniej jeden model musiał zagłosować na klasę 1, aby ostatecznie przypisać tę klasę. Całkowita skuteczność dla próby testowej wynosi 77,61% i jest o 0,5 p.p. wyższa niż w przypadku pojedynczego algorytmu LightGBM. Dla próby uczącej całkowita skuteczność również wynosi 77,74% i była o 0,06 p.p. niższa niż w przypadku modelu LightGBM. Błąd I typu dla próby uczącej wynosi 15,95%, a dla próby testowej 17,70%. Jest to wynik lepszy niż w przypadku modelu LightGBM (próba ucząca – 19,10%, próba testowa – 20,10%). Porównując błąd II typu, dla próby uczącej wynosi 0,28, a dla próby testowej 0,27. Jest wynik wyższy niż w przypadku modelu LightGBM (próba ucząca - 0,25, próba testowa - 0,26).

Przygotowano również dwa modele z wykorzystaniem metody stacking. W przypadku pierwszego modelu jako modele bazowe zostały wykorzystane algorytmy: CatBoost, XGboost, las losowy oraz Gradient Boosting Classifier. Każdy z tych modeli wygenerował prognozy w postaci prawdopodobieństw, które następnie są wykorzystywane przez model nadrzędny LightGBM do finalnej predykcji. Model ten osiągnął najwyższą skuteczność ze wszystkich oszacowanych modeli, która wynosi 78,11%. Błąd I typu dla próby testowej wynosi 19,62% a błąd II typu 24,35%. Model ten osiągnął również najwyższy wskaźnik Giniego, AUC, F1 dla klasy 0 i 1 wśród wszystkich modeli. Największy wpływ na wynik modelu miały kolejno

prawdopodobieństwa wygenerowane przez modele: XGBoost, las losowy, Gradient Boosting Classifier oraz CatBoost.

Kolejny model wykorzystujący metodę stacking oparty jest na modelach bazowych z wykorzystaniem algorytmów: LightGBM, CatBoost, las losowy, Gradient Boosting Classifier oraz AdaBoost. Prawdopodobieństwa z tych modeli zostały wykorzystane przez model nadrzędny XGBoost. Całkowita skuteczność modelu dla próby testowej wyniosła 76,87%. Błąd I typu wyniósł 19,62%, a błąd II typu 26,94%. Wskaźnik Giniego i AUC tak jak w przypadku poprzedniego modelu były najwyższe wśród wszystkich modeli. Prawdopodobieństwa uzyskane z modeli, w kolejności: LightGBM, CatBoost, Adaboost, Gradient Boosting Classifier oraz las losowy, miały największy wpływ na wyniki modelu.

3.5. Analiza porównawcza skuteczności modeli prognozowania ryzyka upadłości konsumenckiej dla pierwszego i drugiego zestawu zmiennych

W niniejszym podrozdziale przeprowadzono analizę porównawczą skuteczności modeli prognozowania ryzyka upadłości konsumenckiej opracowanych na podstawie dwóch zestawów zmiennych. Celem analizy jest porównanie miar skuteczności modeli. Porównanie to pozwala zidentyfikować podejścia z najwyższą skutecznością oraz ocenić wpływ doboru zmiennych na wyniki prognoz.

Najwyższą skuteczność wśród modeli indywidualnych dla pierwszego zestawu zmiennych na próbie testowej osiągnął model LightGBM, a następnie CatBoost, XGBoost, Gradient Boosting Classifier, las losowy oraz AdaBoost. Najniższą skuteczność odnotowano w przypadku regresji logistycznej, SVM oraz sieci neuronowych. Najmniejszy błąd I typu uzyskano w modelach LightGBM i CatBoost, natomiast najniższy błąd II typu osiągnęły LightGBM, CatBoost, Gradient Boosting Classifier, XGBoost i AdaBoost. Błąd I typu oznacza nieprawidłową klasyfikację konsumentów z upadłością jako konsumentów bez upadłości, natomiast błąd II typu to błędnie zaklasyfikowanie konsumentów bez upadłości jako konsumentów z upadłością. Wśród modeli indywidualnych najwyższą miarę Giniego, która mierzy zdolność modelu do rozróżniania klas uzyskał LightGBM, następnie CatBoost oraz las losowy, natomiast najniższą SVM, sieci neuronowe oraz regresja logistyczna. Najwyższy wskaźnik AUC osiągnął LightGBM, a najniższy regresja logistyczna oraz SVM. Miary skuteczności modeli indywidualnych dla pierwszego zestawu zmiennych przedstawiono w tabeli 8 (próba ucząca) oraz tabeli 9 (próba testowa).

Tabela 8. Skuteczność modeli indywidualnych opracowana dla pierwszego zestawu zmiennych – próba ucząca

Algorytm	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
Regresja Logistyczna	68.78%	32.91%	29.56%	0,70	0,68
SVM	73.20%	22.99%	30.54%	0,76	0,76
Drzewo decyzyjne	73.20%	24.62%	28.94%	0,73	0,74
Las Losowy	74.07%	22.74%	29.06%	0,73	0,75
AdaBoost	74.75%	24.87%	25.62%	0,75	0,75
XGBoost	74.32%	24.87%	26.48%	0,74	0,76
LightGBM	77.24%	20.48%	25.00%	0,77	0,78
CatBoost	75.93%	22.11%	25.99%	0,76	0,76
Gradient Boosting Classifier	75.44%	23.12%	25.99%	0,75	0,76
Sieci Neuronowe	73.57%	23.87%	28.94%	0,73	0,74

Źródło: opracowanie na podstawie wyników badań własnych.

Tabela 9. Skuteczność modeli indywidualnych opracowana dla pierwszego zestawu zmiennych – próba testowa

Algorytm	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
Regresja Logistyczna	71.89%	33.01%	22.80%	0,73	0,71
SVM	72.89%	26.79%	27.46%	0,72	0,74
Drzewo decyzyjne	73.38%	24.40%	29.02%	0,72	0,75
Las Losowy	73.88%	24.40%	27.98%	0,73	0,75
AdaBoost	73.88%	26.32%	25.91%	0,73	0,75
Gradient Boosting Classifier	74.13%	25.84%	25.91%	0,73	0,75
XGBoost	75.12%	25.36%	24.35%	0,74	0,74
LightGBM	76.12%	22.97%	24.87%	0,75	0,77
CatBoost	75.87%	24.40%	23.83%	0,75	0,77
Sieci Neuronowe	73.13%	27.27%	26.42%	0,72	0,74

Źródło: opracowanie na podstawie wyników badań własnych.

W pierwszym zestawie zmiennych zaproponowane modele zespołowe nie osiągnęły wyższej skuteczności niż najlepsze modele indywidualne (LightGBM i CatBoost), jednak wykazały się wysoką skutecznością w porównaniu do reszty modeli. Wśród modeli, które osiągnęły najwyższą skuteczność, oprócz LightGBM oraz CatBoost, kolejne miejsca zajęło sześć modeli zespołowych (dwa wykorzystujące metodę uśredniania, dwa wykorzystujące metodę głosowania oraz dwa wykorzystujące metodę stacking). Analizując miarę Giniego i AUC wśród modeli zespołowych wykorzystujących metodę uśredniania oraz stacking, cztery z siedmiu modeli osiągnęły taki sam wskaźnik Giniego jak model LightGBM, a sześć modeli

osiągnęło identyczny wskaźnik AUC jak model LightGBM. Najslabszą skuteczność wśród modeli zespołowych osiągnął model łączący regresję logistyczną, SVM oraz drzewo decyzyjne. Warto jednak zauważyć, że jego skuteczność nieznacznie przewyższała skuteczność tych samych modeli indywidualnych. W tabeli 10 przedstawiono opis modeli zespołowych wraz z wykorzystanymi algorytmami oraz wagami w przypadku modeli stosujących metodę uśredniania. Natomiast miary skuteczności dla pierwszego zestawu zmiennych przedstawiono w tabeli 11 (próba ucząca) oraz tabeli 12 (próba testowa).

Tabela 10. Opis modeli zespołowych opracowany dla pierwszego i drugiego zestawu zmiennych

Numer modelu zespołowego	Metoda	Wykorzystane algorytmy	Wagi
M1	głosowanie	LR, SVM, DT	
M2	głosowanie	LR, SVM, DT, AdaBoost	
M3	głosowanie	LR, SVM, DT, LightGBM	
M4	głosowanie	LightGBM, CatBoost, XGBoost	
M5	uśrednianie	LightGBM, CatBoost	0,7/0,3
M6	uśrednianie	LightGBM, XGBoost	0,8/0,2
M7	uśrednianie	LightGBM, XGBoost, CatBoost	0,6/0,1/0,3
M8	uśrednianie	CatBoost, XGBoost	0,85/0,15
M9	stacking	LightGBM	
M10	stacking	XGBoost	

Źródło: opracowanie własne.

Tabela 11. Skuteczność modeli zespołowych opracowana dla pierwszego zestawu zmiennych – próba ucząca

Numer modelu zespołowego	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
M1	73.01%	25.63%	28.33%	0,73	0,73
M2	73.45%	19.85%	33.13%	0,72	0,75
M3	74.38%	18.59%	32.51%	0,73	0,76
M4	76.24%	21.98%	25.49%	0,76	0,76
M5	76.87%	21.48%	24.75%	0,77	0,77
M6	76.55%	21.61%	25.25%	0,76	0,77
M7	76.37%	21.73%	25.49%	0,76	0,77
M8	75.81%	22.49%	25.86%	0,76	0,76
M9	77.80%	16.96%	27.34%	0,77	0,79
M10	74.32%	24.87%	26.48%	0,75	0,76

Źródło: opracowanie na podstawie wyników badań własnych.

Tabela 12. Skuteczność modeli zespołowych opracowana dla pierwszego zestawu zmiennych – próba testowa

Numer modelu zespołowego	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
M1	73.63%	28.71%	23.83%	0,73	0,74
M2	74.38%	22.97%	28.50%	0,73	0,76
M3	75.62%	21.53%	27.46%	0,74	0,77
M4	75.62%	23.92%	24.87%	0,75	0,76
M5	75.12%	22.97%	26.94%	0,74	0,76
M6	75.37%	22.97%	26.42%	0,74	0,76
M7	74.88%	22.97%	27.46%	0,73	0,76
M8	75.62%	24.88%	23.83%	0,75	0,76
M9	75.62%	22.01%	26.94%	0,74	0,77
M10	75.62%	24.40%	24.35%	0,75	0,76

Źródło: opracowanie na podstawie wyników badań własnych.

Dodanie wskaźników łączących zmienne demograficzne i finansowe (drugi zestaw zmiennych) zwiększyło skuteczność modeli dla próby testowej średnio o 0,97 p.p., a dla trzech najlepszych algorytmów (LightGBM, CatBoost i XGBoost) o 1,16 p.p. Warto jednak zauważyć, że już samo dodanie do pierwszego zestawu zmiennych zmiennej wiek (trzeci zestaw zmiennych) nieznacznie zwiększyło skuteczność modeli indywidualnych w 90% modeli predykcyjnych. Wśród modeli indywidualnych jedynie w przypadku regresji logistycznej całkowita skuteczność trzeciego zestawu zmiennych była niższa niż w przypadku pierwszego zestawu zmiennych, jednak różnica była niewielka. Błędy I typu i II typu były również na zbliżonym poziomie i wynosiły odpowiednio 33% i 23%. Największy wzrost skuteczności odnotowano w przypadku sieci neuronowych (o 2,74 p.p.), a następnie w Adaboost (1,49 p.p.) oraz w lasach losowych (1,49 p.p.). Średnia skuteczność modeli po dodaniu zmiennej wiek zwiększyła się o 0,80 p.p., a dla trzech najlepszych algorytmów o 0,41 p.p. Natomiast dodanie wskaźników spowodowało kolejny wzrost skuteczności w 50% modeli indywidualnych w porównaniu do dodania samej zmiennej wiek. Dotyczyło to następujących modeli: lasu losowego, XGBoost, LightGBM, CatBoost, Gradient Boosting Tree. Wyniki sugerują, że wyższa skuteczność drugiego zestawu zmiennych może wynikać z dodatkowych informacji uchwyconych przez nowe wskaźniki, a nie wyłącznie z samej zmiennej wiek. Korol (2024) zaproponował wykorzystanie innowacyjnych wskaźników integrujących różne rodzaje informacji w ocenie sytuacji finansowej konsumentów przy budowie modeli prognozujących upadłość konsumencką. Wyższa skuteczność modeli zawierających wskaźniki łączące zmienne

demograficzne oraz finansowe w niniejszym badaniu jest spójna z wynikami osiągniętymi przez autora.

Najwyższą skuteczność wśród wszystkich oszacowanych modeli w drugim zestawie zmiennych osiągnęło sześć modeli zespołowych (model wykorzystujący metodę stacking, cztery modele bazujące na uśrednianiu oraz model wykorzystujący głosowanie), następnie model LightGBM, drugi model z metodą stacking oraz CatBoost. Wśród modeli indywidualnych, oprócz algorytmów LightGBM oraz Catboost, najwyższą skuteczność na próbie testowej osiągnęły las losowy, XGBoost oraz Gradient Boosting Classifier. Najniższą skuteczność odnotowały regresja logistyczna, drzewo decyzyjne oraz SVM. Wśród modeli zespołowych, najwyższą skuteczność osiągnęły model LightGBM wykorzystujący metodę stacking, następnie modele bazujące na uśrednianiu z zastosowaniem wag. Model łączący LightGBM, CatBoost oraz XGBoost przy zastosowaniu głosowania, był równie skuteczny jak modele bazujące na uśrednianiu i nieznacznie skuteczniejszy niż sam LightGBM. Najniższą skuteczność na próbie testowej osiągnęły regresja logistyczna, drzewo decyzyjne oraz SVM. Najniższy błąd I typu został osiągnięty przez model zespołowy 9, model zespołowy 10, model zespołowy 2 oraz LightGBM. Następnie najniższy błąd I typu odnotowano w sześciu modelach zespołowych. Wśród algorytmów pojedynczych, oprócz modelu LightGBM, najniższy błąd I typu wystąpił w modelach CatBoost, las losowy, Gradient Boosting Classifier oraz XGBoost. Najwyższy błąd I typu osiągnęły regresja logistyczna, drzewo decyzyjne oraz model zespołowy 1. Najniższy błąd II typu uzyskano w siedmiu modelach zespołowych, a następnie w modelach CatBoost, XGBoost, regresji logistycznej, lasach losowych i AdaBoost. Najwyższy wskaźnik Giniego osiągnęły modele wykorzystujące metodę stacking, a następnie LightGBM, CatBoost, XGBoost, Gradient Boosting Classifier, las losowy oraz wszystkie modele zespołowe bazujące na uśrednianiu z wykorzystaniem wag. Analizując miarę AUC, najwyższy wskaźnik uzyskały las losowy, Gradient Boosting Classifier, wszystkie modele bazujące na uśrednianiu z wykorzystaniem wag, modele stacking, a następnie LightGBM, CatBoost, XGBoost oraz drzewo decyzyjne. Miary skuteczności modeli indywidualnych dla drugiego zestawu zmiennych dla próby uczącej przedstawiono w tabeli 13, a dla próby testowej w tabeli 14. Miary skuteczności modeli zespołowych dla drugiego zestawu zmiennych na próbie uczącej znajdują się w tabeli 15, a na próbie testowej w tabeli 16.

Tabela 13. Skuteczność modeli indywidualnych opracowana dla drugiego zestawu zmiennych – próba ucząca

Algorytm	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
Regresja Logistyczna	68.59%	32.16%	30.67%	0,69	0,68
SVM	73.26%	23.62%	29.80%	0,73	0,72
Drzewo decyzyjne	73.20%	24.87%	28.69%	0,73	0,74
Las Losowy	76.74%	20.35%	26.11%	0,76	0,77
AdaBoost	76.24%	23.99%	23.52%	0,76	0,76
Gradient Boosting Classifier	76.68%	20.60%	25.99%	0,76	0,77
XGBoost	76.80%	20.98%	25.37%	0,76	0,77
LightGBM	77.80%	19.10%	25.25%	0,77	0,78
CatBoost	77.24%	21.73%	23.77%	0,77	0,77
Sieci Neuronowe	74.38%	22.24%	28.94%	0,74	0,75

Źródło: opracowanie na podstawie wyników badań własnych.

Tabela 14. Skuteczność modeli indywidualnych opracowana dla drugiego zestawu zmiennych – próba testowa

Algorytm	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
Regresja Logistyczna	71.39%	32.06%	24.87%	0,72	0,71
SVM	73.13%	22.97%	31.09%	0,71	0,75
Drzewo decyzyjne	72.64%	25.84%	29.02%	0,71	0,74
Las Losowy	76.62%	21.53%	25.39%	0,75	0,78
AdaBoost	75.12%	24.40%	25.39%	0,74	0,76
Gradient Boosting Classifier	76.37%	21.53%	25.91%	0,75	0,78
XGBoost	76.62%	22.01%	24.87%	0,76	0,78
LightGBM	77.11%	20.10%	25.91%	0,76	0,78
CatBoost	76.87%	21.53%	24.87%	0,76	0,78
Sieci Neuronowe	74.13%	24.40%	27.46%	0,73	0,75

Źródło: opracowanie na podstawie wyników badań własnych.

Tabela 15. Skuteczność modeli zespołowych opracowana dla drugiego zestawu zmiennych – próba ucząca

Numer modelu zespołowego	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
M1	71.89%	27.64%	28.57%	0,72	0,72
M2	73.88%	20.35%	31.77%	0,73	0,75
M3	74.81%	18.09%	32.14%	0,73	0,76
M4	77.67%	20.48%	24.14%	0,77	0,78
M5	77.80%	20.73%	23.65%	0,78	0,78
M6	77.11%	20.10%	25.62%	0,77	0,78
M7	77.67%	20.73%	23.89%	0,77	0,78
M8	77.24%	21.98%	23.52%	0,77	0,77
M9	78.67%	17.34%	25.25%	0,78	0,79
M10	76.80%	20.98%	25.37%	0,76	0,78

Źródło: opracowanie na podstawie wyników badań własnych.

Tabela 16. Skuteczność modeli zespołowych opracowana dla drugiego zestawu zmiennych – próba testowa

Numer modelu zespołowego	Całkowita skuteczność	Błąd I typu	Błąd II typu	F1 klasa 0	F1 klasa 1
M1	74.88%	25.84%	24.35%	0,74	0,75
M2	76.87%	19.62%	26.94%	0,75	0,78
M3	76.87%	20.57%	25.91%	0,75	0,78
M4	77.36%	21.05%	24.35%	0,76	0,78
M5	77.36%	21.05%	24.35%	0,76	0,78
M6	77.61%	20.57%	24.35%	0,76	0,79
M7	77.36%	21.05%	24.35%	0,76	0,78
M8	77.36%	21.05%	24.35%	0,76	0,78
M9	78.11%	19.62%	24.35%	0,77	0,79
M10	77.36%	20.57%	24.87%	0,76	0,78

Źródło: opracowanie na podstawie wyników badań własnych.

Al Daoud (2019) porównał trzy algorytmy: XGBoost, CatBoost i LightGBM, pod kątem dokładności oraz czasu pracy procesora. Okazało się, że LightGBM jest zarówno szybszy od pozostałych metod, jak i bardziej dokładny. Ze względu na to, że w przeprowadzonym badaniu zbiór danych nie był duży, czas obliczeń nie stanowił istotnego kryterium przy wyborze modelu. Niemniej jednak, LightGBM wykazał się wysoką skutecznością w porównaniu do innych testowanych modeli indywidualnych. De Castro Vieira i in. (2019) porównali SVM, bagging, AdaBoost, drzewa decyzyjne, regresję logistyczną oraz analizę dyskryminacyjną w

prognozowaniu niespłacanych kredytów hipotecznych. Algorytmy oparte na boostingu, baggingu oraz lasach losowych przewyższyły inne metody. SVM okazało się jedną z najsłabszych metod, w porównaniu do lasów losowych, baggingu, AdaBoost i drzew decyzyjnych. W niniejszym badaniu najniższą skuteczność spośród zastosowanych metod osiągnęły regresja logistyczna, a następnie SVM, drzewo decyzyjne oraz sieci neuronowe. Ponadto, Coşer i in. (2019) porównali lasy losowe, regresję logistyczną, LightGBM i XGBoost w prognozowaniu niespłacalności kredytów. Najwyższe wyniki uzyskano dla lasu losowego. W przypadku niniejszego badania, w pierwszym zestawie zmiennych algorytmy LightGBM i XGBoost przewyższyły skutecznością model lasu losowego. W przypadku drugiego zestawu zmiennych, algorytm LightGBM okazał się bardziej skuteczny od modelu lasu losowego, podczas gdy model XGBoost osiągnął taką samą skuteczność.

Barboza i in. (2017) wykazali, że modele uczenia maszynowego takie jak bagging i boosting, przewyższają tradycyjne metody (np. analizę dyskryminacyjną, regresję logistyczną i sztuczne sieci neuronowe) pod względem zdolności predykcyjnej, co znajduje potwierdzenie w wynikach niniejszego badania. Podobnie jak w badaniu Barbozy i in. (2017), w niniejszym badaniu regresja logistyczna, SVM oraz sieci neuronowych osiągnęły niższą skuteczność niż modele LightGBM, XGBoost, CatBoost, las losowy, Gradient Boosting Classifier oraz AdaBoost. Ponadto, Wang i in. (2022) porównali skuteczność algorytmu k-najbliższych sąsiadów, drzewa decyzyjnego, lasów losowych oraz LightGBM. Model LightGBM uzyskał lepsze wyniki według kilku miar oceny modeli w porównaniu z pozostałymi metodami. Wyższą skuteczność modelu LightGBM względem drzewa decyzyjnego oraz lasu losowego potwierdziły również wyniki niniejszego badania. Kovacova i Klietkova (2017) wskazali natomiast, że techniki takie jak bagging, boosting i lasy losowe przewyższają klasyczne metody, takie jak analiza dyskryminacyjna, regresja logistyczna oraz sieci neuronowe.

Lasy losowe są bardziej skuteczne niż modele logitowe i drzewa decyzyjne, co zostało potwierdzone w wielu badaniach dotyczących zarówno upadłości przedsiębiorstw (Chen, 2011; Barboza i in., 2017), jak i niewypłacalności kredytowej (Zhu i in., 2019). Gürtler i Zöllner (2022) zauważyli, że lasy losowe przewyższają nie tylko regresję logistyczną, ale także zaawansowane algorytmy uczenia maszynowego. Ren i Weiss (2021), stwierdzili, że las losowy osiąga lepsze wyniki niż regresja logistyczna i drzewa decyzyjne, przy czym spośród tych trzech metod to regresja logistyczna charakteryzuje się najniższą skutecznością. Wyniki te są zgodne z badaniami przedstawionymi w niniejszej pracy. W modelach budowanych na trzech zestawach zmiennych lasy losowe przewyższyły zarówno modele regresji logistycznej, jak i drzewa decyzyjne pod względem skuteczności.

W badaniu Zhang i in. (1999) sieci neuronowe wykazały wyższą skuteczność niż regresja logistyczna, co zostało potwierdzone także w kolejnych badaniach (Lee i in., 2005; Son i in., 2019). Podobne zależności zaobserwowano w niniejszym badaniu. Sieci neuronowe przewyższyły skutecznością regresję logistyczną, która osiągnęła najniższą skuteczność spośród wszystkich oszacowanych algorytmów.

W badaniach przeprowadzonych przez Hossain i in. (2022) w próbie, gdzie nie zastosowano metody SMOTE, najwyższą skuteczność uzyskały sieci neuronowe, a następnie XGBoost, podczas gdy SVM odnotowało najniższą skuteczność. W niniejszym badaniu podobnie jak u Hossaina i in. (2022), algorytm SVM osiągnął jedną z najniższych skuteczności dla wszystkich trzech zestawów zmiennych. Shetty i in. (2022) porównali skuteczność głębokich sieci neuronowych, XGBoost i SVM, uzyskując bardzo zbliżone wyniki dla wszystkich trzech algorytmów. Altman i in. (2020) ocenili pięć algorytmów: drzewo decyzyjne, gradient boosting, regresję logistyczną, sieci neuronowych oraz SVM. Najwyższą skuteczność uzyskały regresja logistyczna oraz sieci neuronowe. Natomiast w badaniu Smitha i Alvareza (2022) algorytm XGBoost przewyższył regresję logistyczną. Z kolei Hosaka (2019) wykazał, że konwolucyjne sieci neuronowe (ang. Convolutional Neural Network) przewyższają skutecznością inne algorytmy, w tym drzewa decyzyjne, analizę dyskryminacyjną, SVM, wielowarstwowe perceptrony (MLP) oraz AdaBoost.

Coraz częściej stosowane są również algorytmy zespołowe, łączące dwa lub więcej modeli w celu zwiększania skuteczności prognozowania upadłości. W badaniach przeprowadzonych przez Xie i in. (2013) połączenie regresji logistycznej z sieciami neuronowymi oraz z SVM poprawiło zarówno całkowitą skuteczność modeli, jak i zmniejszyło błędy I i II typu. Lin i McClean (2001) również przeanalizowali skuteczność metod uczenia maszynowego oraz podejść hybrydowych. Ich badanie wykazało, że zastosowanie metod hybrydowych dodatkowo zwiększa skuteczność prognoz. Amirshahi i Lahmiri (2024) porównali pojedyncze algorytmy XGBoost, LightGBM oraz Catboost z modelami zespołowymi opartymi na tych trzech algorytmach. Modele zespołowe wykazały wyższą skuteczność niż pojedyncze algorytmy. W badaniu zastosowano uśrednianie z wagami, co pozwoliło na zwiększenie precyzji prognoz. W badaniu przeprowadzonym przez Korola (2024a) model składający się z trzech połączonych modeli osiągnął wyższą skuteczność niż indywidualne modele. W niniejszym badaniu, w modelach oszacowanych na drugim zestawie zmiennych skuteczność modeli zespołowych jest nieznacznie wyższa niż skuteczność osiągnięta przez pojedyncze modele. Analizując pierwszy zestaw zmiennych, modele

zespołowe należały do najskuteczniejszych, jednak ich skuteczność była nieco niższa niż modeli LightGBM oraz CatBoost.

3.6. Analiza istotności cech w modelach prognozowania ryzyka upadłości konsumenckiej

Po przeanalizowaniu skuteczności poszczególnych modeli w niniejszym podrozdziale dokonano analizy istotności cech w modelach prognozowania ryzyka upadłości konsumenckiej. Wykorzystane metody interpretacji modeli pozwoliły zidentyfikować cechy mające wpływ na ryzyko upadłości konsumenckiej.

Ograniczenia kredytowe stanowią istotny czynnik determinujący ogłoszenie upadłości. W przypadku pierwszego zestawu zmiennych, w siedmiu modelach były one najważniejszym czynnikiem, a w ośmiu znalazły się wśród trzech najistotniejszych cech. Odmowa udzielenia kredytu może prowadzić do decyzji finansowych pogarszających sytuację gospodarstwa domowego, takich jak zaciągnięcie pożyczki o wysokim oprocentowaniu. Dodatkowo, odmowa udzielenia kredytu lub strach przed ubieganiem się o niego, który nie zawsze jest uzasadniony i często wynikający z braku wiedzy finansowej, mogą pogłębiać problemy finansowe gospodarstwa domowego, prowadząc do upadłości konsumenckiej. Posiadanie odmowy udzielenia kredytu zwiększa ryzyko upadłości konsumenckiej, co w niniejszym badaniu potwierdzono we wszystkich modelach predykcyjnych.

W większości modeli udział wartości netto majątku w stosunku do dochodu znajduje się wśród trzech najistotniejszych cech. Im wyższy wskaźnik, tym mniejsze ryzyko upadłości konsumenckiej, co czyni go kluczowym czynnikiem prognozowania ryzyka upadłości konsumenckiej.

Opóźnienia w spłacie zobowiązań to istotny czynnik zwiększający ryzyko upadłości. W przypadku pierwszego zestawu zmiennych, w siedmiu modelach znalazły się wśród pięciu najważniejszych czynników. Należy jednak zauważyć, że nie każdy konsument, który opóźnia płatności, zdecyduje się na ogłoszenie upadłości. Kluczowe znaczenie może mieć czas trwania opóźnień. Wiele badań dotyczących upadłości nie uwzględnia opóźnień w spłacie jako czynnika prowadzącego do upadłości, a jedynie nieliczne analizują zachowania konsumentów w zakresie spłaty zadłużenia jako determinantę upadłości. Wyniki niniejszego badania potwierdzają, że zachowania związane ze spłatą długu, takie jak opóźnienia w spłacie zobowiązań w ostatnim okresie, mogą być jednym z czynników upadłości (Moorman i Garasky, 2008; Himmelstein i in., 2005). Ponadto, zaległości w spłacie zobowiązań mogą prowadzić do ograniczeń kredytowych, zarówno na skutek decyzji kredytodawcy, jak i obaw konsumenta przed odmową kredytu. Posiadanie opóźnień w spłacie zobowiązań zwiększa

ryzyko upadłości konsumenckiej, co zostało potwierdzone we wszystkich modelach predykcyjnych.

Alfaro i Gallardo (2012) zwrócili uwagę, że poziom wykształcenia jest czynnikiem determinującym niewypłacalność hipoteczną, podczas gdy zaleganie z płatnościami zobowiązań jest związane z wiekiem oraz liczbą osób w gospodarstwie domowym. Wyniki niniejszego badania, zarówno na podstawie analizy SHAP, jak i regresji logistycznej wskazują, że wyższy poziom wykształcenia wiąże się z mniejszym ryzykiem upadłości. Zmienna poziom wykształcenia, znalazła się w 9 modelach predykcyjnych wśród 10 najistotniejszych cech. Ponadto niniejsze badania potwierdzają, że im więcej dzieci w gospodarstwie domowym, tym wyższe ryzyko upadłości. Jednak, analizując sam model regresji logistycznej, liczba dzieci nie okazała się istotna statystycznie. Podobne wnioski przedstawili Moorman i Garasky (2008), którzy wykazali, że wielkość rodziny nie ma istotnego związku z decyzją o ogłoszeniu upadłości. Liczba dzieci znalazła się wśród dziesięciu najistotniejszych cech tylko w jednym modelu. Wśród zmiennych demograficznych wiek jest również istotnym predyktorem. Bauchet i Evans (2019) zauważyli nieliniową zależność między bankructwem a wiekiem, wskazując, że prawdopodobieństwo upadłości rośnie z wiekiem, ale w malejącym tempie. Niniejsze badanie również potwierdza istotność zmiennej wiek. Cecha ta, pojawiła się w 4 modelach wśród 3 najistotniejszych cech oraz w 8 modelach wśród 10 najistotniejszych. Im wyższy wiek konsumenta, tym wyższe ryzyko upadłości konsumenckiej. Ponadto, analizując wskaźnik łączący wiek z poziomem edukacji, cecha ta znalazła się w 7 modelach wśród 3 najistotniejszych oraz we wszystkich modelach wśród 10 najistotniejszych. Im wyższy udział poziomu wykształcenia w stosunku do wieku, tym mniejsze ryzyko upadłości konsumenckiej.

Istotnym czynnikiem wpływającym na upadłość konsumencką jest struktura zobowiązań. Im wyższy udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu, tym większe ryzyko upadłości konsumenckiej. Z kolei, im większy udział całkowitego zadłużenia konsumpcyjnego (niezwiązanego z hipoteką ani zadłużeniem odnawialnym) w stosunku do miesięcznego dochodu, tym mniejsze ryzyko upadłości konsumenckiej. Analizując udział całkowitego zadłużenia konsumpcyjnego w stosunku do wszystkich miesięcznych płatności związanych z zadłużeniami, wyższy udział zwiększa ryzyko upadłości konsumpcyjnej. Karty kredytowe są uznawane za silny czynnik determinujący upadłość konsumencką (Zhu, 2011; Gross i Souleles, 2002), jednak analizując wyłącznie udział poszczególnych zobowiązań, zauważono, że wyższy udział całkowitego zadłużenia odnawialnego w stosunku do miesięcznego dochodu wiąże się z mniejszym ryzykiem upadłości. Zhu (2011) zwrócił również uwagę, że stosunek kredytów hipotecznych,

kredytów samochodowych oraz zadłużeń na karcie kredytowej do rocznych dochodów gospodarstwa domowego ma wpływ na decyzję o złożeniu wniosku o upadłość konsumencką.


Kolejnym silnym predyktorem upadłości konsumenckiej jest wskaźnik zadłużenia mieszkaniowego w stosunku do całkowitych aktywów. Wyniki wskazują, że im wyższy udział zadłużenia związanego z nieruchomościami (kredyty hipoteczne, pożyczki hipoteczne, kredyty odnawialne zabezpieczone wartością nieruchomości) w stosunku do całkowitych aktywów tym wyższe ryzyko upadłości. Qi i Yang (2009) oraz Bian i in. (2018) zauważyli związek między niewypłacalnością lub ryzykiem kredytowym a wskaźnikiem wartości kredytu hipotecznego w stosunku do wartości nieruchomości.

Oprócz struktury zobowiązań, istotnym aspektem jest również podejście do oszczędzania. Niniejsze badania wykazały, że posiadanie wydatków mniejszych niż dochody zmniejsza ryzyko upadłości konsumenckiej. Ponadto, im wyższy udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu, tym mniejsze ryzyko upadłości konsumenckiej. Zmienna udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu w pięciu modelach okazała się jedną z pięciu najistotniejszych cech, a w dziewięciu modelach była wśród 10 najistotniejszych cech. Z kolei zmienna posiadanie wydatków mniejszych niż dochody nie była tak istotna w zaprezentowanych modelach, jak zmienna udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu.

Wyniki oszacowanych modeli wskazują również, że posiadanie nieruchomości zmniejsza prawdopodobieństwo ogłoszenia upadłości, co zgadza się z badaniami m.in. Syed Nor i in. (2019) oraz Fishera (2005). Posiadanie nieruchomości jest uważane za jeden z najważniejszych predyktorów upadłości. W oszacowanych modelach tylko wśród 4 modeli zmienna ta znalazła się wśród dziesięciu najistotniejszych cech. Warto jednak zwrócić uwagę, że w niniejszym badaniu zmienna posiadanie nieruchomości jest powiązana z dwoma innymi zmiennymi: udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów oraz udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu. Innym silnym determinantem upadłości jest wskaźnik długu mieszkaniowego do aktywów – wyższy wskaźnik zwiększa prawdopodobieństwo upadłości konsumenckiej. Qi i Yang (2009) analizowali straty przy niewypłacalności i wskazali, że wskaźnik wartości kredytu w stosunku do wartości nieruchomości jest istotnym czynnikiem. W niniejszym badaniu analizowano wskaźnik zadłużenia związanego z nieruchomościami w stosunku do aktywów, a wyniki również potwierdzają znaczenie tej zmiennej. Zmienna ta w przypadku 5 modeli była wśród 10 najistotniejszych cech.

Na wykresie 161 przedstawiono dziesięć najistotniejszych cech dla modeli oszacowanych na podstawie pierwszego zestawu zmiennych. Cechy uszeregowano według istotności, zaczynając od tej, która miała największy wpływ na model. Cecha zajmująca pierwsze miejsce otrzymała wartość 1, a dziesiąta wartość 10. Jeśli dana cecha nie znalazła się wśród dziesięciu najważniejszych cech w modelu, przypisano jej wartość 0. Wśród czterech najistotniejszych cech pod względem istotności cech znalazły się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), opóźnienia w spłacie zobowiązań (X15) oraz udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20). Natomiast w grupie dziesięciu najistotniejszych cech, które pojawiły się w co najmniej pięciu modelach, znalazły się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), opóźnienia w spłacie zobowiązań (X15), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), poziom wykształcenia (X6), udział rocznych wydatków na żywność w stosunku do rocznego dochodu (X11), udział całkowitego zadłużenia odnawialnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X21), udział całkowitych aktywów niefinansowych w stosunku do długu (X19) oraz udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X16). Wśród najrzadziej występujących cech znalazły się: liczba dzieci (X14), udział oszczędności w stosunku do długu (X23) oraz udział dochodu w stosunku do całkowitych aktywów (X13).

Wykres 161. Rozkład istotności cech w modelach oszacowanych dla pierwszego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 162 przedstawiono dziesięć najistotniejszych cech dla modeli oszacowanych na podstawie drugiego zestawu zmiennych. Cechy zostały uszeregowane od najistotniejszej do najmniej istotnej. W przypadku, gdy cecha nie znalazła się wśród dziesięciu najistotniejszych w modelu, przypisano jej wartość 0. Wśród trzech najważniejszych cech pod względem istotności cech znalazły się: wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz odmowa udzielenia kredytu (X25). Spośród dziesięciu najistotniejszych cech, które wystąpiły w co najmniej pięciu modelach, znalazły się: udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18), udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20), wskaźnik relacji poziomu wykształcenia w stosunku do wieku (X7), odmowa udzielenia kredytu (X25), udział środków z kont oszczędnościowych w stosunku do miesięcznego dochodu (X24), opóźnienia w spłacie zobowiązań (X15), udział całkowitego zadłużenia odnawialnego w stosunku do sumy wszystkich miesięcznych płatności związanych z zadłużeniami (X21), udział rocznych wydatków na żywność w stosunku do

rocznego dochodu (X11) oraz wskaźnik relacji poziomu wykształcenia w stosunku do udziału miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X10).

Wykres 162. Rozkład istotności cech w modelach oszacowanych dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

Zakończenie

Wykorzystanie zaawansowanych modeli uczenia maszynowego w prognozowaniu finansowym wciąż pozostaje stosunkowo nowym obszarem badawczym. Ponadto wciąż istnieje luka badawcza w zakresie przewidywania ryzyka upadłości konsumenckiej, wynikająca z niewystarczającej liczby badań poświęconych tej tematyce. Niniejsze badanie jest jednym z pierwszych, w którym zastosowano nowoczesne algorytmy uczenia maszynowego typu gradient boosting, takie jak XGBoost, LightGBM, czy CatBoost, do prognozowania upadłości konsumenckiej, wykraczając tym samym poza tradycyjne podejścia oparte na regresji logistycznej, drzewach decyzyjnych czy sieciach neuronowych. Ponieważ modele te są często postrzegane jako tzw. „czarne skrzynki”, w badaniu zastosowano techniki umożliwiające interpretację i wyjaśnienie prognoz modelu. Większa interpretowalność modeli umożliwia zastosowanie bardziej złożonych algorytmów, które choć mogą charakteryzować się wyższą skutecznością, ale do tej pory były rzadko wykorzystywane ze względu na małą przejrzystość i trudność w interpretacji. W efekcie można łączyć wysoką skuteczność z możliwością wyjaśnienia prognoz modelu.

Jak zostało wskazane we wstępie niniejszej rozprawy doktorskiej, głównym celem pracy jest opracowanie modeli prognozowania ryzyka upadłości konsumenckiej na przykładzie Stanów Zjednoczonych. Realizacja tego celu została potwierdzona przez wyniki badań empirycznych zaprezentowane w rozdziale trzecim. W ramach badania porównano skuteczność dziesięciu algorytmów indywidualnych oraz dziesięciu algorytmów zespołowych, opracowując trzy zestawy zmiennych na podstawie uzyskanych cech konsumentów z the Survey of Consumer Finances w Stanach Zjednoczonych. Osiągnięcie celu głównego wymagało uprzedniego zrealizowania celów szczegółowych:

1. Przegląd literatury międzynarodowej na temat modeli oraz zmiennych wykorzystywanych do prognozowania ryzyka upadłości konsumenckiej.
2. Oszacowanie i weryfikacja skuteczności modeli indywidualnych prognozowania ryzyka upadłości konsumenckiej, w tym zarówno modelu regresji logistycznej, jak i innych modeli uczenia maszynowego (drzewo decyzyjne, las losowy, maszyny wektorów nośnych, Adaptive Boosting, Gradient Boosting Classifier, Extreme Gradient Boosting, Light Gradient Boosting Machine, Categorical Boosting oraz sieci neuronowe).
3. Oszacowanie i weryfikacja skuteczności klasyfikatorów zespołowych z wykorzystaniem metod: uśredniania, głosowania oraz stacking.

4. Porównanie skuteczności klasyfikatorów indywidualnych oraz zespołowych w prognozowaniu ryzyka upadłości konsumenckiej.
5. Ocena skuteczności modeli prognozowania ryzyka upadłości konsumenckiej przy wykorzystaniu różnych miar oceny skuteczności, takich jak: całkowita skuteczność, błąd I typu, błąd II typu, F1, krzywa ROC z wyliczonym wskaźnikiem AUC oraz wskaźnik Giniego.
6. Identyfikacja czynników mikroekonomicznych wpływających na ryzyko upadłości konsumenckiej przy wykorzystaniu metod interpretacji modeli, takich jak analiza istotności cech, technika SHAP oraz LIME.
7. Próba opracowania nowego rodzaju wskaźników integrujących różne rodzaje informacji (demograficzne i finansowe) w celu oceny ryzyka upadłości konsumenckiej.

Pierwszy cel szczegółowy został osiągnięty poprzez przegląd literatury dotyczącej modeli oraz zmiennych wykorzystywanych w prognozowaniu upadłości konsumenckiej, który został przedstawiony w rozdziale drugim. Przeprowadzona analiza umożliwiła wyodrębnienie najczęściej wykorzystywanych zmiennych oraz modeli w prognozowaniu ryzyka upadłości konsumenckiej.

Drugi cel szczegółowy został zrealizowany poprzez opracowanie indywidualnych modeli prognozowania ryzyka upadłości konsumenckiej. Zostały oszacowane jedne z najbardziej popularnych algorytmów służących do prognozowania ryzyka upadłości konsumenckiej. Uwzględniono zarówno prostsze metody, takie jak regresja logistyczna, drzewa decyzyjne, lasy losowe czy maszyny wektorów nośnych, jak i bardziej zaawansowane techniki, w tym AdaBoost, Gradient Boosting Classifier, XGBoost, LightGBM, CatBoost oraz sieci neuronowe.

Realizacja trzeciego celu szczegółowego została osiągnięta poprzez oszacowanie dziesięciu algorytmów zespołowych, uwzględniających metody uśredniania, głosowania oraz stacking. W ramach metody głosowania przedstawiono wyniki czterech modeli, w których zastosowano różne kombinacje algorytmów o zróżnicowanym poziomie złożoności – od prostszych, takich jak regresja logistyczna, maszyny wektorów nośnych i drzewa decyzyjne, po bardziej zaawansowane, w tym AdaBoost, XGBoost, LightGBM oraz CatBoost. Zbudowano również cztery modele z wykorzystaniem uśredniania, w których zastosowano metody LightGBM, CatBoost oraz XGBoost, przy użyciu różnych wag. W ostatnich dwóch modelach zastosowano metodę stackingu. W pierwszym z nich modelami bazowymi były CatBoost, XGBoost, las losowy oraz Gradient Boosting Classifier, natomiast rolę metamodelu

pełnił LightGBM. W drugim z nich modelami bazowymi były LightGBM, CatBoost, las losowy, Gradient Boosting Classifier oraz AdaBoost, a rolę metamodelu pełnił XGBoost.

Czwarty cel szczegółowy został zrealizowany poprzez porównanie skuteczności klasyfikatorów indywidualnych z klasyfikatorami zespołowymi wykorzystującymi metody głosowania, uśredniania oraz stackingu. Takie podejście pozwoliło ocenić, w jakim stopniu agregacja modeli może poprawić skuteczność prognozowania ryzyka upadłości konsumenckiej w porównaniu z pojedynczymi algorytmami, a także wskazać najbardziej skuteczne metody agregacji.

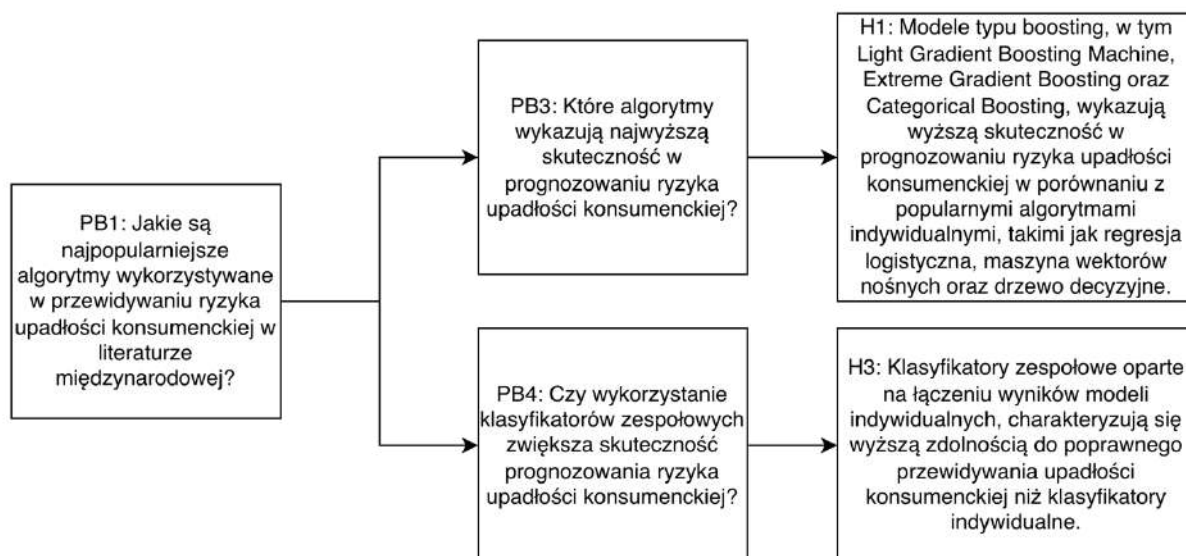
W ramach realizacji piątego celu szczegółowego oceniono skuteczność oszacowanych modeli z wykorzystaniem następujących miar: całkowitej skuteczności, błędu I typu, błędu II typu, miary F1, krzywej ROC wraz z wartością AUC oraz wskaźnika Giniego. Zastosowanie różnych metryk umożliwiło wieloaspektowe porównanie modeli pod kątem ich precyzji, zdolności wykrywania przypadków upadłości konsumenckiej oraz ogólnej jakości klasyfikacji. Ocena skuteczności modeli na podstawie jednej metryki byłaby niewystarczająca, dlatego w rozprawie doktorskiej wykorzystano zestaw wskaźników uwzględniających zarówno ogólną skuteczność, jak i specyfikę popełnianych błędów klasyfikacyjnych. Ponadto poszczególne metryki uzupełniają się wzajemnie, umożliwiając kompleksową ocenę działania modeli z różnych perspektyw.

Szósty cel szczegółowy został zrealizowany poprzez identyfikację czynników mikroekonomicznych wpływających na ryzyko upadłości konsumenckiej przy wykorzystaniu metod interpretacji modeli, takich jak analiza istotności cech, technika SHAP oraz LIME. Analiza istotności cech dostarcza globalnych informacji o wpływie poszczególnych zmiennych na działanie całego modelu, pozwalając zidentyfikować najważniejsze czynniki decydujące o ryzyku upadłości konsumenckiej. SHAP umożliwia zarówno lokalną, jak i globalną interpretację, dostarczając wgląd we wpływ cech na poszczególne predykcje oraz na ogólne działanie modelu. Natomiast Lime pozwala na wyjaśnianie decyzji modeli uczenia maszynowego na poziomie indywidualnym, skupiając się na lokalnej interpretacji pojedynczych przypadków.

Realizacja siódmego celu szczegółowego została zrealizowana poprzez opracowanie nowego rodzaju wskaźników integrujących różne rodzaje informacji – zarówno demograficzne jak i finansowe. Celem ich konstrukcji było zwiększenie wartości informacyjnej zmiennych wejściowych oraz poprawa skuteczności modeli predykcyjnych. Zaproponowane wskaźniki umożliwiają uchwycenie złożonych zależności pomiędzy zmiennymi, które w analizie indywidualnej mogą mieć ograniczoną wartość predykcyjną. Cechują się większą

uniwersalnością, co umożliwia ich zastosowanie w różnych kontekstach społeczno-gospodarczych, w tym także w analizach prowadzonych w innych państwach. Dzięki temu stanowią potencjalne narzędzie, wspierające proces oceny ryzyka upadłości konsumenckiej niezależnie od specyfiki lokalnych systemów prawnych oraz danych źródłowych.

Na podstawie powyższych celów szczegółowych sformułowano pytania badawcze. W pierwszej kolejności poniżej przedstawiono te dotyczące algorytmów prognozowania ryzyka upadłości konsumenckiej. Na rysunku 22 zobrazowano strukturę pytań badawczych oraz hipotez związanych z tym obszarem.



Rysunek 22. Struktura pytań badawczych i hipotez dotyczących algorytmów prognozowania ryzyka upadłości konsumenckiej

Źródło: opracowanie własne.

Celem pierwszego pytania badawczego (PB1) jest identyfikacja i uporządkowanie najczęściej stosowanych algorytmów w badaniach naukowych dotyczących prognozowania upadłości konsumenckiej. Pozwoliło to na opracowanie przeglądu literatury oraz stworzenie podstaw do wyboru odpowiednich metod analizy w dalszej części pracy. Trzecie pytanie badawcze (PB3) koncentruje się na określeniu, które algorytmy w przeprowadzonym badaniu wykazują najwyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej. Jak wykazano w przeprowadzonych badaniach, spośród algorytmów indywidualnych najwyższą skuteczność dla pierwszego zestawu zmiennych osiągnęły modele boostingowe, takie jak LightGBM, Catboost oraz XGBoost. W przypadku drugiego zestawu zmiennych wśród najskuteczniejszych algorytmów również znalazły się LightGBM, CatBoost, XGBoost oraz las losowy. Z kolei najniższą skuteczność, zarówno dla pierwszego, jak i drugiego zestawu

zmiennych, odnotowano w przypadku regresji logistycznej, maszyny wektorów nośnych, sieci neuronowych oraz drzewa decyzyjnego.

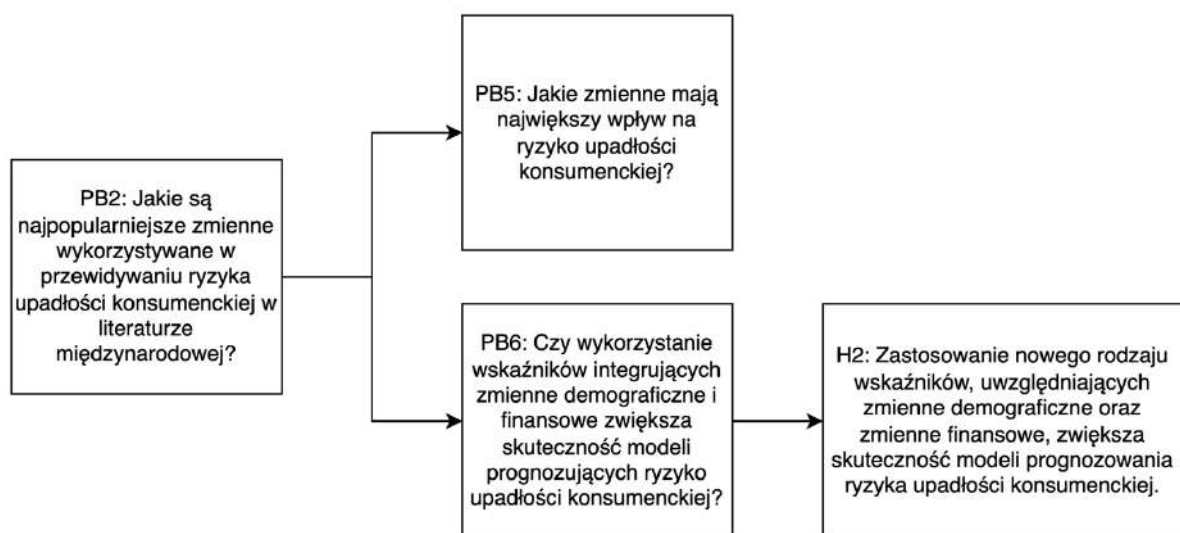
Pierwsza hipoteza badawcza (H1), powiązana z powyższym pytaniem badawczym, ma na celu sprawdzenie czy modele typu boosting, w tym Light Gradient Boosting Machine, Extreme Gradient Boosting oraz Categorical Boosting, wykazują wyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej w porównaniu z popularnymi algorytmami indywidualnymi, takimi jak regresja logistyczna, maszyna wektorów nośnych oraz drzewo decyzyjne. Hipoteza ta została potwierdzona, ponieważ wyniki wskazują na istotną przewagę tych algorytmów w prognozowaniu upadłości konsumenckiej. Otrzymane rezultaty pokazują, że metody te charakteryzują się wyższą dokładnością i lepszą zdolnością klasyfikacyjną w porównaniu z innymi rozważanymi algorytmami indywidualnymi, co potwierdza ich zastosowanie jako efektywnego narzędzia w badanym obszarze.

Czwarte pytanie badawcze (PB4) dotyczy oceny czy zastosowanie klasyfikatorów zespołowych opartych na łączeniu wyników klasyfikatorów indywidualnych zwiększa skuteczność prognozowania upadłości konsumenckiej. Wyniki przeprowadzonych badań wskazują, że w pierwszym zestawie zmiennych żaden z klasyfikatorów zespołowych nie przewyższył pod względem skuteczności indywidualnych algorytmów LightGBM i CatBoost. Jednocześnie 60% klasyfikatorów zespołowych uzyskało wyższe wyniki niż indywidualny algorytm XGBoost, który wśród algorytmów indywidualnych osiągnął trzecią najwyższą skuteczność. Wśród tych klasyfikatorów zespołowych znalazły się dwa algorytmy oparte na metodzie głosowania, dwa wykorzystujące uśrednianie oraz dwa stosujące stacking. W drugim zestawie zmiennych aż 70% klasyfikatorów zespołowych osiągnęła wyższą skuteczność niż LightGBM, który był najlepszym klasyfikatorem indywidualnym. Najwyższą całkowitą skuteczność wykazał klasyfikator zespołowy oparty na metodzie stacking z wykorzystaniem LightGBM jako metamodelu. Wśród kolejnych najsukuteczniejszych modeli znalazły się cztery oparte na uśrednianiu, jeden na głosowaniu oraz stacking z metamodeliem XGBoost.

Hipoteza trzecia (H3), zakładająca, że klasyfikatory zespołowe oparte na metodach łączenia wyników klasyfikatorów indywidualnych charakteryzują się wyższą zdolnością do poprawnego przewidywania upadłości konsumenckiej niż klasyfikatory indywidualne, nie została potwierdzona na podstawie przeprowadzonych badań. Analiza wyników wykazała, że w pierwszym zestawie zmiennych żaden z klasyfikatorów zespołowych nie osiągnął lepszych rezultatów niż najlepsze algorytmy indywidualne, takie jak LightGBM i CatBoost. Chociaż w drugim zestawie zmiennych większość klasyfikatorów zespołowych przewyższyła

skutecznością najlepszy klasyfikator indywidualny, wyniki nie były wystarczająco jednoznaczne, aby potwierdzić hipotezę. Wyniki badań wskazują, że metody zespołowe łączące różne klasyfikatory zasługują na dalszą analizę i weryfikację, ponieważ na innych zbiorach danych lub przy zastosowaniu odmiennych zestawów zmiennych ich skuteczność może ulec zmianie. Pomimo, iż hipoteza nie została jednoznacznie potwierdzona, większość klasyfikatorów zespołowych wykazała bardzo wysoką skuteczność w porównaniu do wszystkich oszacowanych algorytmów. W szczególności najwyższą skuteczność osiągnęły metody oparte na metodzie stacking oraz na uśrednianiu z wagami.

Na rysunku 23 przedstawiono strukturę pytań badawczych oraz hipotez dotyczących zmiennych wykorzystanych w budowie modeli prognozowania ryzyka upadłości konsumenckiej.



Rysunek 23. Struktura pytań badawczych i hipotez dotyczących zmiennych wykorzystanych w budowie modeli prognozowania ryzyka upadłości konsumenckiej.

Źródło: opracowanie własne.

Na podstawie zaprezentowanej struktury trzech pytań badawczych oraz jednej hipotezy dotyczącej zmiennych predykcyjnych upadłości konsumenckiej poniżej przedstawiono szczegółową analizę każdego z pytań. Drugie pytanie badawcze (PB2) koncentruje się na identyfikacji najczęściej wykorzystywanych zmiennych w prognozowaniu upadłości konsumenckiej w literaturze międzynarodowej. Wyniki przeprowadzonej analizy stanowią podstawę do dalszych etapów badania, w tym budowy własnego zbioru zmiennych oraz oceny ich skuteczności w modelach predykcyjnych.

Kolejne piąte pytanie badawcze (PB5) dotyczy oceny, które zmienne mają największy wpływ na prognozowanie ryzyka upadłości konsumenckiej. Aby na nie odpowiedzieć, zastosowano techniki interpretacji modeli, umożliwiające określenie znaczenia poszczególnych

cech w kontekście dokładności predykcyjnej upadłości konsumenckiej. Zidentyfikowano cechy o kluczowym znaczeniu oraz zweryfikowano ich zgodność z ustaleniami wcześniejszych badań w odniesieniu do tych, które były już wcześniej wykorzystywane. W pierwszym zestawie zmiennych, wśród trzech najistotniejszych pod względem istotności cech znalazły się: odmowa udzielenia kredytu (X25), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz opóźnienia w spłacie zobowiązań (X15). Dodatkowo istotny był udział miesięcznej spłaty zadłużenia odnawialnego (z wyłączeniem kredytów hipotecznych) w stosunku do miesięcznego dochodu (X20). W drugim zestawie zmiennych, wśród trzech najważniejszych pod względem istotności cech znalazły się: wskaźnik relacji poziomu wykształcenia do wieku (X7), udział wartości netto majątku (różnica między aktywami a długiem) w stosunku do dochodu (X18) oraz odmowa udzielenia kredytu (X25). Analizując zmienne w modelu LightGBM, który osiągnął najwyższą skuteczność wśród modeli indywidualnych, stwierdzono, że wcześniejsza odmowa udzielenia kredytu (X25), opóźnienia w spłacie zobowiązań (X15), wyższy udział miesięcznej płatności kredytu hipotecznego w stosunku do miesięcznego dochodu (X17) oraz wyższy udział zadłużenia związanego z nieruchomościami w stosunku do całkowitych aktywów (X16) zwiększają ryzyko upadłości konsumenckiej. Natomiast wyższy udział wartości netto majątku (różnica między aktywami a długiem) do dochodu (X18), wyższy poziom wykształcenia (X6), posiadanie wydatków mniejszych niż dochody (X22) oraz posiadanie nieruchomości zmniejszają ryzyko upadłości konsumenckiej (X12).

Szóste pytanie badawcze (PB6) dotyczy oceny czy wykorzystanie wskaźników integrujących zmienne demograficzne i finansowe zwiększa skuteczność modeli prognozowania ryzyka upadłości konsumenckiej. Aby na nie odpowiedzieć, przygotowano drugi zestaw zmiennych zawierający właśnie takie wskaźniki.

Hipoteza badawcza (H2) ma na celu sprawdzenie czy zastosowanie nowego rodzaju wskaźników integrujących zmienne demograficzne i finansowe zwiększa skuteczność prognozowania ryzyka upadłości konsumenckiej. Hipoteza druga (H2) została potwierdzona, ponieważ dodanie wskaźników łączących zmienne demograficzne i finansowe (drugi zestaw zmiennych) zwiększyło skuteczność modeli prognozujących upadłość konsumencką.

Realizacja celów badawczych oraz weryfikacja przedstawionych hipotez przyczyniły się do wypełnienia luk badawczych wskazanych we wstępie niniejszej pracy. Niemniej jednak, zagadnienie prognozowania ryzyka upadłości konsumenckiej nadal stwarza przestrzeń do dalszych badań, szczególnie w kontekście wykorzystania odmiennych zbiorów danych, nowych zmiennych i wskaźników, a także innych algorytmów czy metod wstępnego

przetwarzania danych, selekcji zmiennych oraz bilansowania danych. Ze względu na ograniczoną liczbę badań dotyczących prognozowania upadłości konsumenckiej oraz wykorzystanie jedynie pojedynczych zbiorów danych z wybranych państw (np. Polski, Malezji, Tajwanu, USA), konieczne jest dalsze rozwijanie tego obszaru w oparciu o szersze i bardziej zróżnicowane dane empiryczne. Wczesne wykrywanie konsumentów o wysokim ryzyku upadłości pozwala z jednej strony podjąć działania zapobiegawcze, a z drugiej, gdy takie działania nie przyniosą efektu, identyfikować tych konsumentów w celu ograniczenia negatywnych skutków pogarszającej się sytuacji finansowej prowadzącej do upadłości konsumenckiej.

Rekomendacje dla przyszłych badań

Przeprowadzone badania empiryczne wskazują szereg obszarów, które mogą stanowić przedmiot dalszych analiz w zakresie prognozowania ryzyka upadłości konsumenckiej. Niewątpliwie interesującym kierunkiem dalszych badań jest zastosowanie bardziej zaawansowanych algorytmów uczenia maszynowego, w tym metod uczenia głębokiego oraz technik opartych na hierarchicznym łączeniu modeli (stacking), uzupełnionych o narzędzia interpretacji, które pozwalają zrozumieć działanie modeli zarówno na poziomie globalnym, jak i jednostkowym. Takie podejście umożliwia połączenie wysokiej skuteczności predykcji z przejrzystością podejmowanych decyzji.

Kolejnym istotnym obszarem badawczym jest identyfikacja nowych zmiennych i wskaźników, które mogą zwiększyć skuteczność i stabilność modeli prognozujących ryzyko upadłości konsumenckiej. Takie wskaźniki integrują różne informacje co zwiększa uniwersalność i trafność modeli prognozujących ryzyko upadłości konsumenckiej, umożliwiając ich zastosowanie w różnych populacjach i warunkach ekonomicznych. W dalszych badaniach warto również rozwijać podejścia uwzględniające zmienne makroekonomiczne, takie jak na przykład stopy procentowe, kursy walutowe, tempo wzrostu PKB, stopę bezrobocia oraz poziom inflacji. Choć są one już obecne w wybranych publikacjach, ich szersze zastosowanie może przyczynić się do lepszego odwzorowania dynamiki zmian gospodarczych, a tym samym do zwiększenia skuteczności i adaptacyjności modeli.

Nie mniej istotnym aspektem jest porównanie różnych technik selekcji zmiennych oraz metod przygotowywania danych, które mogą istotnie wpłynąć na jakość i skuteczność modeli prognozujących ryzyko upadłości konsumenckiej. Wstępne przetwarzanie danych stanowi jeden z kluczowych etapów w tworzeniu modeli prognostycznych, ponieważ obejmuje

działania mające na celu między innymi oczyszczenie, transformację i standaryzację danych, a także redukcję wymiarowości zbioru. Odpowiedni dobór metod przetwarzania może prowadzić do zwiększenia stabilności i dokładności prognoz, natomiast selekcja zmiennych pozwala wyeliminować cechy o niskiej wartości informacyjnej. Dlatego tak istotne jest dopasowanie metod przygotowania danych do specyfiki zbioru oraz zastosowanych algorytmów.

Równie ważny jest dobór optymalnych metod bilansowania danych. Jest kluczowy dla efektywnego wykorzystania modeli, gdy dane są silnie nie zrównoważone, co jest powszechne w problematyce prognozowania ryzyka upadłości konsumenckiej. Ma to na celu zminimalizowanie ryzyka błędnych prognoz spowodowanych nie zrównoważonym zbiorem danych.

Ograniczenia badawcze

Niniejsze badanie, podobnie jak wiele innych, nie jest pozbawione ograniczeń. Jednym z nich jest uwzględnienie wyłącznie danych pochodzących ze Stanów Zjednoczonych. Badania koncentrujące się na jednym kraju mogą, w zależności od tematyki, być trudniejsze do uogólnienia na szerszą populację. W przypadku zjawiska upadłości konsumenckiej, mimo że różni się w zależności od obowiązujących regulacji prawnych i uwarunkowań ekonomicznych, posiada wiele cech wspólnych, co czyni je istotnym problemem o wymiarze globalnym. Dotychczasowe badania pokazują, że wiele kluczowych predyktorów upadłości konsumenckiej powtarza się niezależnie od kraju, co potwierdza ich uniwersalność. W związku z tym autorka ma nadzieję, że w przyszłości rozszerzy zakres badań o dane pochodzące z innych państw.

Kolejnym ograniczeniem jest posiadanie danych obejmujących różne lata. Dysponowanie większą liczbą przypadków upadłości konsumenckiej umożliwiłoby prognozowanie tego zjawiska na podstawie danych z krótszego przedziału czasowego. Ponadto większa dostępność danych pozwoliłaby na uwzględnienie zmian zachodzących w czasie, takich jak trendy ekonomiczne, zmiany legislacyjne czy cykle koniunkturalne, które mogą wpływać na poziom zadłużenia i ryzyko upadłości konsumenckiej.

Ponadto kolejnym ograniczeniem niniejszego badania jest wykorzystanie wyłącznie danych mikroekonomicznych. Uwzględnienie przy budowie modeli prognozujących upadłość konsumencką zmiennych makroekonomicznych umożliwiłoby dokładniejsze uchwycenie dynamiki procesów gospodarczych. W związku z tym autorka wyraża nadzieję, że w przyszłych badaniach rozszerzy zakres badań o uwzględnienie zmiennych makroekonomicznych.

Bibliografia

1. Agarwal, S., Chomsisengphet, S., & Liu, C. (2011). Consumer bankruptcy and default: The role of individual social capital. *Journal of Economic Psychology*, 32(4), 632-650.
2. Akosa, Josephine. 2017. Predictive accuracy: A misleading performance measure for highly imbalanced data. Paper presented at SAS Global Forum, Orlando, FL, USA, April 2–5; vol. 12.
3. Al Daoud, E. (2019). Comparison between XGBoost, LightGBM and CatBoost using a home credit dataset. *International Journal of Computer and Information Engineering*, 13(1), 6-10.
4. Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O., & Bilal, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*, 94, 164-184.
5. Alfaro, E., García, N., Gámez, M., & Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45(1), 110-122.
6. Alfaro, R., & Gallardo, N. (2012). The determinants of household debt default. *Economic Analysis Review*, 27(1), 27-54.
7. Altman, E. I., Iwanicz-Drozdowska, M., Laitinen, E. K., & Suvas, A. (2020). A race for long horizon bankruptcy prediction. *Applied Economics*, 52(37), 4092-4111.
8. Aly, S., Alfonse, M., & Salem, A. B. M. (2022). Intelligent model for enhancing the bankruptcy prediction with imbalanced data using oversampling and CatBoost. *International Journal of Intelligent Computing and Information Sciences*, 22(3), 92-108.
9. Amirshahi, B., & Lahmiri, S. (2024). Bankruptcy prediction using optimal ensemble models under balanced and imbalanced data. *Expert Systems*, 41(8), e13599.
10. Antunes, F., Ribeiro, B., & Pereira, F. (2017). Probabilistic modeling and visualization for bankruptcy prediction. *Applied Soft Computing*, 60, 831-843.
11. Arora, P., & Saurabh, S. (2022). Predicting distress: A post insolvency and bankruptcy code 2016 analysis. *Journal of Economics and Finance*, 46(3), 604-622.
12. Baier, L., Jöhren, F., & Seebacher, S. (2019, June). Challenges in the Deployment and Operation of Machine Learning in Practice. In *ECIS* (Vol. 1).
13. Barboza, F., Basso, L. F. C., & Kimura, H. (2023). New metrics and approaches for predicting bankruptcy. *Communications in Statistics-Simulation and Computation*, 52(6), 2615-2632.

14. Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417.
15. Bauchet, J., & Evans, D. (2019). Personal bankruptcy determinants among US households during the peak of the Great Recession. *Journal of Family and Economic Issues*, 40(4), 577-591.
16. Becerra-Vicario, R., Alaminos, D., Aranda, E., & Fernández-Gámez, M. A. (2020). Deep recurrent convolutional neural network for bankruptcy prediction: A case of the restaurant industry. *Sustainability*, 12(12), 5180.
17. Begg, D. K., Fischer, S., & Dornbusch, R. (2007). *Mikroekonomia. Polskie Wydawnictwo Ekonomiczne*.
18. Begley, J., Ming, J., & Watts, S. (1996). Bankruptcy classification errors in the 1980s: An empirical analysis of Altman's and Ohlson's models. *Review of Accounting Studies*, 1, 267-284.
19. Begum, S. (2021). A detailed study for bankruptcy prediction by machine learning technique. In *Intelligent Sustainable Systems: Selected Papers of WorldS4 2021, Volume 2* (pp. 201-213). Singapore: Springer Nature Singapore.
20. Bemš, J., Starý, O., Macaš, M., Žegklitz, J., & Pošík, P. (2015). Innovative default prediction approach. *Expert Systems with Applications*, 42(17-18), 6277-6285.
21. Ben Jabeur, S., Stef, N., & Carmona, P. (2023). Bankruptcy prediction using the XGBoost algorithm and variable importance feature engineering. *Computational Economics*, 61(2), 715-741.
22. Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152).
23. Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
24. Breiman, L., Friedman, J.H. and Olshen, R.A., 1984. Charles J Stone, Classification and Regression Trees. Statistics/Probability Series, The Wadsworth.
25. Brenes, R. F., Johannssen, A., & Chukhrova, N. (2022). An intelligent bankruptcy prediction model using a multilayer perceptron. *Intelligent Systems with Applications*, 16, 200136.
26. Brezigar-Masten, A., & Masten, I. (2012). CART-based selection of bankruptcy predictors for the logit model. *Expert systems with applications*, 39(11), 10153-10159.
27. Brotcke, L. (2022). Time to assess bias in machine learning models for credit decisions. *Journal of Risk and Financial Management*, 15(4), 165.

28. Brown, I., & Mues, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert systems with applications*, 39(3), 3446-3453.
29. Bruce, P. C., Bruce, A., & Gedeck, P. (2021). Statystyka praktyczna w data science: 50 kluczowych zagadnień w językach R i Python. *Helion*.
30. Brygała, M. (2022). Consumer bankruptcy prediction using balanced and imbalanced data. *Risks*, 10(2), 24.
31. Brygała, M., & Korol, T. (2024). Personal bankruptcy prediction using machine learning techniques. *Economics and Business Review*, 10(2), 118-142.
32. Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2020). Explainable AI in fintech risk management. *Frontiers in Artificial Intelligence*, 3, 26.
33. Camizuli, E., & Carranza, E. J. (2018). Exploratory data analysis (EDA). *The encyclopedia of archaeological sciences*, 1-7.
34. Caputo, R. K. (2008). Marital status and other correlates of personal bankruptcy, 1986–2004. *Marriage & Family Review*, 44(1), 5-32.
35. Carmona, P., Dwekat, A., & Mardawi, Z. (2022). No more black boxes! Explaining the predictions of a machine learning XGBoost classifier algorithm in business failure. *Research in International Business and Finance*, 61, 101649.
36. Catboost. (2024). Catboost enables fast gradient boosting on decision trees using GPUs. Pozyskano 10 października 2024, ze strony <https://catboost.ai/news/catboost-enables-fast-gradient-boosting-on-decision-trees-using-gpus>.
37. Centralny Ośrodek Informacji Gospodarczej. (2025) Pozyskano 2 lutego 2025, ze strony <http://www.coig.com.pl/>.
38. Černevičienė, J., & Kabašinskas, A. (2024). Explainable artificial intelligence (XAI) in finance: a systematic literature review. *Artificial Intelligence Review*, 57(8), 216.
39. Chandrashekar, G., & Sahin, F. (2014). A survey on feature selection methods. *Computers & electrical engineering*, 40(1), 16-28.
40. Learning, S. S. (2006). Semi-supervised learning. CSZ2006. html, 5(2), 1.
41. Chen, H. L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S. J., & Liu, D. Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24(8), 1348-1359.
42. Chen, M.Y. (2011), “Predicting corporate financial distress based on integration of decision tree classification and logistic regression”, *Expert Systems with Applications*, 38(9), pp. 11261-11272.

43. Chen, T. K., Liao, H. H., Chen, G. D., Kang, W. H., & Lin, Y. C. (2023). Bankruptcy prediction using machine learning models with the text-based communicative value of annual reports. *Expert Systems with Applications*, 233, 120714.
44. Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. *In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
45. Chen, Y., Calabrese, R., & Martin-Barragan, B. (2024). Interpretable machine learning for imbalanced credit scoring datasets. *European Journal of Operational Research*, 312(1), 357-372.
46. Chou, T. N. (2019, July). An explainable hybrid model for bankruptcy prediction based on the decision tree and deep neural network. *In 2019 IEEE 2nd international conference on knowledge innovation and invention (ICKII)* (pp. 122-125). IEEE.
47. Consoli, S., Reforgiato Recupero, D., & Saisana, M. (2021). *Data science for economics and finance: Methodologies and applications* (p. 355). Springer Nature.
48. Corchado, J. M., López, S., Garcia, R., & Chamoso, P. (2023). Generative artificial intelligence: fundamentals. *ADCAIJ: advances in distributed computing and artificial intelligence journal*, 12(1), e31704-e31704.
49. Cukiernik, T., & Teluk, T. (2007). Najlepsze praktyki upadłości konsumenckiej. *Raport Instytutu Globalizacji, czerwiec*.
50. Dahouda, M. K., & Joe, I. (2021). A deep-learned embedding technique for categorical features encoding. *IEEE Access*, 9, 114381-114391.
51. Dasilas, A., & Rigani, A. (2024). Machine learning techniques in bankruptcy prediction: A systematic literature review. *Expert systems with applications*, 255, 124761.
52. Databricks. (2024), pozyskano 10.10.2024, ze strony <https://www.databricks.com/glossary/mlops>.
53. Davtyan, T. (2025). The us approach to ai regulation: federal laws, policies, and strategies explained. *Journal of Law, Technology, & the Internet*, 16(2), 223.
54. Dawsey, A. E. (2014). Externalities among creditors and personal bankruptcy. *Journal of Financial Economic Policy*, 6(1), 2-24.
55. De Castro Vieira, J.R., Barboza, F., Sobreiro, V.A. & Kimura, H. (2019). Machine learning models for credit analysis improvements: Predicting low-income families' default. *Applied Soft Computing*, 83, 105640.

56. DePaula, N., Gao, L., Mellouli, S., Luna-Reyes, L. F., & Harrison, T. M. (2025, May). The evolving AI regulation space: A preliminary analysis of US state legislations addressing AI, 2024. *In Conference on Digital Government Research* (Vol. 1).
57. Destatis. (2025a). Verbraucherinsolvenzen nach Jahren. Pozyskano 2 lutego 2025, ze strony <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Einkommen-Konsum-Lebensbedingungen/Vermoeigen-Schulden/Tabellen/verbraucherinsolvenzen-jahren.html>.
58. Destatis. (2025b). Population by territory and average age. Pozyskano 2 lutego 2025, ze strony <https://www.destatis.de/EN/Themes/Society-Environment/Population/Current-Population/Tables/population-by-territory-and-average-age-basis-2022.html>.
59. Destatis. (2025c). Pozyskano 5 marca 2025, ze strony https://www.destatis.de/DE/Presse/Pressemitteilungen/2023/03/PD23_109_52411.html.
60. Devi, S. S., & Radhika, Y. (2018). A survey on machine learning and statistical techniques in bankruptcy prediction. *International Journal of Machine Learning and Computing*, 8(2), 133-139.
61. Domowitz, I., & Sartain, R. L. (1999). Determinants of the consumer bankruptcy decision. *The Journal of Finance*, 54(1), 403-420.
62. Dorogush, A. V., Ershov, V., & Gulin, A. (2018). CatBoost: gradient boosting with categorical features support. *arXiv preprint arXiv:1810.11363*.
63. Ellis, D. (1998). The effect of consumer interest rate deregulation on credit card volumes, charge-offs, and the personal bankruptcy rate. *Federal Deposit Insurance Company, Bank Trends*, (98-05).
64. Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). Gpts are gpts: An early look at the labor market impact potential of large language models. *arXiv preprint arXiv:2303.10130*.
65. Enkhtuya, T., & Kang, D. K. (2023). Bankruptcy prediction with explainable artificial intelligence for early-stage business models. *Int. J. Internet Broadcast. Commun*, 15, 58-65.
66. Fay, S., Hurst, E., & White, M. J. (2002). The household bankruptcy decision. *American Economic Review*, 92(3), 706-718.
67. Federal Reserve. (2025). Pozyskano 3 stycznia 2025, ze strony https://www.federalreserve.gov/boarddocs/supmanual/cch/fair_lend_reg_b.pdf/.
68. Fernández-Gámez, M. A., García-Lagos, F., & Sánchez-Serrano, J. R. (2016). Integrating corporate governance and financial variables for the identification of qualified audit opinions with neural networks. *Neural Computing and Applications*, 27, 1427-1444.

69. Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative ai. *Business & Information Systems Engineering*, 66(1), 111-126.
70. Fiedorowicz, E., & Popłonyk, D. (2016). Wybrane zagadnienia upadłości konsumenckiej – analiza empiryczna. *Instytut Wymiaru Sprawiedliwości, Warsaw*.
71. Fisher, J. D. (2005). The effect of unemployment benefits, welfare benefits, and other income on personal bankruptcy. *Contemporary Economic Policy*, 23(4), 483-492.
72. Fisher, J. D. (2019). Who files for personal bankruptcy in the United States? *Journal of Consumer Affairs*, 53(4), 2003-2026.
73. Fisher, J. D., & Lyons, A. C. (2006). Till debt do us part: A model of divorce and personal bankruptcy. *Review of Economics of the Household*, 4, 35-52.
74. Foohey, P. (2019). Fines, Fees, and Filing Bankruptcy. *NCL Rev.*, 98, 419.
75. Foohey, P., Lawless, R. M., Porter, K., & Thorne, D. (2018). Life in the Sweatbox. *Notre Dame L. Rev.*, 94, 219.
76. Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
77. Garcia, J. (2022). Bankruptcy prediction using synthetic sampling. *Machine Learning with Applications*, 100343.
78. García, V., Marqués, A. I., & Sánchez, J. S. (2015). An insight into the experimental design for credit risk and corporate bankruptcy prediction systems. *Journal of Intelligent Information Systems*, 44, 159-189.
79. García, V., Sánchez, J.S., & Mollineda, R.A. (2012). On the effectiveness of preprocessing methods when dealing with different levels of class imbalance. *Knowledge-Based Systems*, 25(1), 13-21.
80. Gavurova, B., Jencova, S., Bacik, R., Miskufova, M., & Letkovsky, S. (2022). Artificial intelligence in predicting the bankruptcy of non-financial corporations. *Oeconomia Copernicana*, 13(4), 1215-1251.
81. Główny Urząd Statystyczny. (2025). Pozyskano 2 lutego 2025, ze strony <https://stat.gov.pl/>.
82. Gostomski, E., & Michałowski, T. (2015). Próby uregulowania sektora parabankowego na świecie. *Acta Universitatis Lodzianensis. Folia Oeconomica*, 6(317), 131-143.
83. GOV.UK. (2025). Individual insolvencies, December 2024. Pozyskano 2 lutego 2025, ze strony <https://www.gov.uk/government/statistics/individual-insolvencies-december-2024>.
84. GOV.UK. (2023). Pozyskano 2 listopada 2023 ze strony <https://www.gov.uk/bankruptcy>.

85. Gramegna, A., & Giudici, P. (2021). SHAP and LIME: an evaluation of discriminative power in credit risk. *Frontiers in Artificial Intelligence*, 4, 752558.
86. Gross, D. B., & Souleles, N. S. (2002). An empirical analysis of personal bankruptcy and delinquency. *The Review of Financial Studies*, 15(1), 319-347.
87. Gross, T., Kluender, R., Liu, F., Notowidigdo, M. J., & Wang, J. (2021). The economic consequences of bankruptcy reform. *American Economic Review*, 111(7), 2309-2341.
88. Gu, J., Na, J., Park, J., & Kim, H. (2021). Predicting success of outbound telemarketing in insurance policy loans using an explainable multiple-filter convolutional neural network. *Applied Sciences*, 11(15), 7147.
89. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
90. Gürtler, M., & Zöllner, M. (2022). Heterogeneities among credit risk parameter distributions: the modality defines the best estimation method. *OR Spectrum*, 1-37.
91. Hadid, A., Chakraborty, T., & Busby, D. (2024). When geoscience meets generative AI and large language models: Foundations, trends, and future challenges. *Expert Systems*, e13654.
92. Halibas, A. S., Matthew, A. C., Pillai, I. G., Reazol, J. H., Delvo, E. G., & Reazol, L. B. (2019, January). Determining the intervening effects of exploratory data analysis and feature engineering in telecoms customer churn modelling. In *2019 4th MEC International Conference on Big Data and Smart City (ICBDSC)* (pp. 1-7). IEEE.
93. Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: an interdisciplinary review. *Journal of big data*, 7(1), 94.
94. Hand, D. J., & Till, R. J. (2001). A simple generalisation of the area under the ROC curve for multiple class classification problems. *Machine learning*, 45, 171-186.
95. Heo, J., & Yang, J. Y. (2014). AdaBoost based bankruptcy forecasting of Korean construction companies. *Applied soft computing*, 24, 494-499.
96. Hetes-Gavra, R., Avram, A., & Avram, C. D. (2016). The models of personal bankruptcy in Western Europe. *Series Economic Sciences*, 16(1), 554-550.
97. Heuer, J. O. (2020). Hurdles to debt relief for “no income no assets” debtors in Germany: A case study of failed consumer bankruptcy law reforms. *International Insolvency Review*, 29, S44-S76.
98. Himmelstein, D. U., Warren, E., Thorne, D., & Woolhandler, S. (2005). Illness and injury as contributors to bankruptcy. *Health Affairs*, 24(1), 570.

99. Hosaka, T. (2019). Bankruptcy prediction using imaged financial ratios and convolutional neural networks. *Expert systems with applications*, 117, 287-299.
100. Hossain, T., Ferdous, T., Bahadur, E. H., Masum, A. K. M., & YasirArafat, A. (2022, February). Data mining for predicting and finding factors of bankruptcy. In *2022 International Conference on Innovations in Science, Engineering and Technology (ICISSET)* (pp. 504-509). IEEE.
101. Howard, J. (2019). Artificial intelligence: Implications for the future of work. *American journal of industrial medicine*, 62(11), 917-926.
102. Hrycaj, A., & Michalska, A. I. SYSTEM PRAWA UPADŁOŚCIOWEGO W UNII EUROPEJSKIEJ. *PRAWO W DZIAŁANIU*, 7.
103. Huls, N. (1997). Overindebtedness and overlegalization: Consumer bankruptcy as a field for alternative dispute resolution. *Journal of Consumer Policy*, 20(2), 143-159.
104. Ibrahim, A. A., Ridwan, R. L., Muhammed, M. M., Abdulaziz, R. O., & Saheed, G. A. (2020). Comparison of the CatBoost classifier with other machine learning methods. *International Journal of Advanced Computer Science and Applications*, 11(11).
105. Islam, J., Saha, S., Hasan, M., Mahmud, A., & Jannat, M. (2024, April). Cognitive modelling of bankruptcy risk: A comparative analysis of machine learning models to predict the bankruptcy. In *2024 12th International Symposium on Digital Forensics and Security (ISDFS)* (pp. 1-6). IEEE.
106. Jabeur, S. B., Gharib, C., Mefteh-Wali, S., & Arfi, W. B. (2021). CatBoost model and artificial intelligence techniques for corporate failure prediction. *Technological Forecasting and Social Change*, 166, 120658.
107. Jabeur, S. B., Mefteh-Wali, S., & Viviani, J. L. (2021). Forecasting gold price with the XGBoost algorithm and SHAP interaction values. *Annals of Operations Research*, 334, 679–699.
108. Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
109. Jappelli, T., & Modigliani, F. (1998). The age-saving profile and the life-cycle hypothesis. *Long-run Growth and Short-run Stabilization: Essays in Memory of Albert Ando*.
110. Jureviciene, D., Taujanskaite, K., & Sukacevskyte, V. (2016). Indirect factors affecting personal solvency: empirical analysis of Lithuanian consumer credit market. *European Scientific Journal*, 12(1).

111. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30.
112. Khare, N., & Sait, S. Y. (2018). Credit card fraud detection using machine learning models and collating machine learning models. *International Journal of Pure and Applied Mathematics*, 118(20), 825-838.
113. Kim, H., Cho, H., & Ryu, D. (2022). Corporate bankruptcy prediction using machine learning methodologies with a focus on sequential data. *Computational Economics*, 59(3), 1231-1249.
114. Kim, N. R., Shin, K. S., & Ahn, H. (2013). Impact of Ensemble Member Size on Confidence-based Selection in Bankruptcy Prediction. *Journal of Intelligence and Information Systems*, 19(2), 55-71.
115. Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.
116. Korol, T. (2019). Dynamic bankruptcy prediction models for European enterprises. *Journal of Risk and Financial Management*, 12(4), 185.
117. Korol, T. (2021a). Evaluation of the Macro-and Micro-Economic Factors Affecting the Financial Energy of Households. *Energies*, 14(12), 3512.
118. Korol, T. (2021b). Examining statistical methods in forecasting financial energy of households in Poland and Taiwan. *Energies*, 14(7), 1821.
119. Korol, T. (2024a). Multi-factor fuzzy sets decision system forecasting consumer insolvency risk. *Decision*, 51(3), 279-302.
120. Korol, T. (2024b). Artificial Neural Networks in Forecasting the Consumer Bankruptcy Risk with Innovative Ratios. *Contemporary Economics*, 18(4), 391-407.
121. Korol, T. (Ed.). (2021). *Systemy ostrzegania przedsiębiorstw przed ryzykiem upadłości*. Wolters Kluwer Polska.
122. Korol, T., & Fotiadis, A. (2022). Implementing artificial intelligence in forecasting the risk of personal bankruptcies in Poland and Taiwan. *Oeconomia Copernicana*, 13, 407-438.
123. Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). Data preprocessing for supervised learning. *International journal of computer science*, 1(2), 111-117.
124. Kovacova, M., & Kliestikova, J. (2017). Modelling bankruptcy prediction models in Slovak companies. In *SHS Web of Conferences* (Vol. 39, p. 01013). EDP Sciences.

125. Kovacova, M., Kliestik, T., Valaskova, K., Durana, P., & Juhaszova, Z. (2019). Systematic review of variables applied in bankruptcy prediction models of Visegrad group countries. *Oeconomia Copernicana*, 10(4), 743–772.
126. Kozina, A., Kuźmiński, Ł., Nadolny, M., Miałkowska, K., Tutak, P., Janus, J., ... & Król, R. (2023). The default of leasing contracts prediction using machine learning. *Procedia Computer Science*, 225, 424-433.
127. Król-Nowak, A., & Kotarba, K. (2022). Podstawy uczenia maszynowego. *Wydawnictwo AGH, Kraków*, 9-13.
128. Lauser, S., & Hackstadt, A. (2025). Code of justice: Comparing US and EU regulation of AI use in criminal sentencing.
129. Lee, K., Booth, D., & Alam, P. (2005). A comparison of supervised and unsupervised neural networks in predicting bankruptcy of Korean firms. *Expert Systems with Applications*, 29(1), 1-16.
130. Letkovský, S., Jenčová, S., & Vašaničová, P. (2024). Is Artificial Intelligence Really More Accurate in Predicting Bankruptcy? *International Journal of Financial Studies*, 12(1), 8.
131. Letza, S. R., Kalupa, Ł., & Kowalski, T. (2003). Predicting corporate failure: How useful are multi-discriminant analysis models? *Economics and Business Review*, 3(2), 5–11.
132. Liang, D., Lu, C. C., Tsai, C. F., & Shih, G. A. (2016). Financial ratios and corporate governance indicators in bankruptcy prediction: A comprehensive study. *European journal of operational research*, 252(2), 561-572.
133. Lin, F. Y., & McClean, S. (2001). A data mining approach to the prediction of corporate failure. *Knowledge-based systems*, 14(3-4), 189-195.
134. Loh, W.Y., 2011. Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1), pp.14-23.
135. Lombardo, G., Pellegrino, M., Adosoglou, G., Cagnoni, S., Pardalos, P. M., & Poggi, A. (2022). Machine learning for bankruptcy prediction in the American stock market: dataset and benchmarks. *Future Internet*, 14(8), 244.
136. Lu, H., & Hu, X. (2024). Enhancing Financial Risk Prediction for Listed Companies: A Catboost-Based Ensemble Learning Approach. *Journal of the Knowledge Economy*, 15(2), 9824-9840.
137. Lundberg, S. M., & Lee, S. I. (2017). Consistent feature attribution for tree ensembles. *arXiv preprint arXiv:1706.06060*.
138. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.

139. Machado, M. R., & Karray, S. (2022). Assessing credit risk of commercial customers using hybrid machine learning algorithms. *Expert Systems with Applications*, 200, 116889.
140. Mai, F., Tian, S., Lee, C., & Ma, L. (2019). Deep learning models for bankruptcy prediction using textual disclosures. *European journal of operational research*, 274(2), 743-758.
141. Mangalathu, S., Hwang, S. H., & Jeon, J. S. (2020). Failure mode and effects analysis of RC members based on machine-learning-based SHapley Additive exPlanations (SHAP) approach. *Engineering Structures*, 219, 110927.
142. Martin, N., & Tong, K. I. (2009). Double down-and-out: The connection between payday loans and bankruptcy. *Sw. L. Rev.*, 39, 785.
143. Min, J. H., & Lee, Y. C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert systems with applications*, 28(4), 603-614.
144. Ministerstwo Cyfryzacji. (2024). Europejski AI Act – opublikowany. Pozyskano 25 kwietnia 2025 z <https://www.gov.pl/web/cyfryzacja/europejski-ai-act-opublikowany>.
145. Ministerstwo Sprawiedliwości. (2025). Pozyskano 3 marca 2025, ze strony <https://isws.ms.gov.pl/pl/baza-statystyczna/opracowania-wieloletnie/>.
146. Mo, H., Sun, H., Liu, J., & Wei, S. (2019). Developing window behavior models for residential buildings using XGBoost algorithm. *Energy and Buildings*, 205, 109564.
147. Modigliani, F. (1993). Recent declines in the savings rate: a life cycle perspective. *In World saving, prosperity and growth* (pp. 249-286). London: Palgrave Macmillan UK.
148. Moorman, D. C., & Garasky, S. (2008). Consumer debt repayment behavior as a precursor to bankruptcy. *Journal of Family and Economic Issues*, 29, 219-233.
149. Moreno-Seco, F., Inesta, J. M., De León, P. J. P., & Micó, L. (2006). Comparison of classifier fusion methods for classification in pattern recognition tasks. In *Structural, Syntactic, and Statistical Pattern Recognition: Joint IAPR International Workshops, SSPR 2006 and SPR 2006, Hong Kong, China, August 17-19, 2006. Proceedings* (pp. 705-713). Springer Berlin Heidelberg.
150. Mumuni, A., & Mumuni, F. (2024). Automated data processing and feature engineering for deep learning and big data applications: a survey. *Journal of Information and Intelligence*.
151. Nalić, J., Martinović, G., & Žagar, D. (2020). New hybrid data mining model for credit scoring based on feature selection algorithm and ensemble classifiers. *Advanced Engineering Informatics*, 45, 101130.

152. Nanni, L., & Lumini, A. (2009). An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring. *Expert systems with applications*, 36(2), 3028-3033.
153. Nguyen, H. H., Viviani, J. L., & Ben Jabeur, S. (2023). Bankruptcy prediction using machine learning and Shapley additive explanations. *Review of Quantitative Finance and Accounting*, 1-42.
154. Niemi-Kiesiläinen, J. (1997). Changing directions in consumer bankruptcy law and practice in Europe and USA. *Journal of Consumer Policy*, 20(2), 133-142.
155. Nikolic, N., Zarkic-Joksimovic, N., Stojanovski, D., & Joksimovic, I. (2013). The application of brute force logistic regression to corporate credit scoring models: Evidence from Serbian financial statements. *Expert Systems with Applications*, 40(15), 5932-5944.
156. Nishanth, K. J., & Ravi, V. (2013). A computational intelligence based online data imputation method: An application for banking. *Journal of Information Processing Systems*, 9(4), 633-650.
157. NISRA.GOV.UK. (2025). Pozyskano 3 lutego 2025, ze strony <https://www.nisra.gov.uk/publications/2022-based-population-projections-northern-ireland-statistical-bulletin-charts>.
158. Nkambule, D. S., Twala, B., & Pretorius, J. H. C. (2024). Effective Machine Learning Techniques for Dealing with Poor Credit Data. *Risks*, 12(11), 172.
159. Noh, S. H. (2023). Comparing the performance of corporate bankruptcy prediction models based on imbalanced financial data. *Sustainability*, 15(6), 4794.
160. Odorzyńska-Kondek, J. (2011). Upadłość konsumencka w świetle wybranych przepisów prawnych. *Handel Wewnętrzny*, (1), 5-13.
161. Olson, D.L., Delen, D. and Meng, Y., 2012. Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, 52(2), pp.464-473.
162. Papan, A., & Spyridou, A. (2020). Bankruptcy prediction: the case of the Greek market. *Forecasting*, 2(4), 505-525.
163. Papík, M., & Papíková, L. (2023). Impacts of crisis on SME bankruptcy prediction models' performance. *Expert Systems with Applications*, 214, 119072.
164. Papík, M., Papíková, L., Kajanová, J., & Bečka, M. (2021, November). CatBoost: The case of bankruptcy prediction. In *International Conference on Business and Technology* (pp. 3-17). Cham: Springer International Publishing.
165. Park, M. S., Son, H., Hyun, C., & Hwang, H. J. (2021). Explainability of machine learning models for bankruptcy prediction. *Ieee Access*, 9, 124887-124899.

166. Park, S., & Rodrigues, A. P. (2000). Is aggregate consumer borrowing consistent with the permanent income hypothesis? *The Manchester School*, 68(3), 301-320.
167. Parra, C. (2022). How Does Consumer Bankruptcy Protection Impact Household Outcomes? *Available at SSRN 2808851*.
168. Paul, S., Das, P., Kashem, A., & Islam, N. (2024). Sustainable of rice husk ash concrete compressive strength prediction utilizing artificial intelligence techniques. *Asian Journal of Civil Engineering*, 25(2), 1349-1364.
169. Pełka, M. (2009). Sieci neuronowe dla danych symbolicznych: perceptron wielowarstwowy. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu. Taksonomia*, 16(47 Klasyfikacja i analiza danych-teoria i zastosowania), 223-230.
170. Peng, C.Y.J., Lee, K.L., & Ingersoll, G.M. (2002). An introduction to logistic regression analysis and reporting. *The Journal of Educational Research*, 96(1), 3-14.
171. Pisula, T. (2013). Metodyczne aspekty zastosowania modeli skoringowych do oceny zdolności kredytowej z wykorzystaniem metod ilościowych. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, (323), 265-288.
172. Pisula, T. (2017). Zastosowanie ensemble klasyfikatorów do oceny ryzyka upadłości przedsiębiorstw na przykładzie firm sektora produkcyjnego działających na Podkarpaciu. *Zarządzanie i Finanse*, (3), 279-293.
173. Pocięcha, J. (2013). Wybrane metody klasyfikacyjne oraz ich efektywność w prognozowaniu upadłości firm. *Studia Ekonomiczne*, 152, 119-139.
174. Pocięcha, J. (2018). Współczesne zmiany narzędzi badań statystycznych. *Zeszyty Naukowe Uniwersytetu Ekonomicznego w Krakowie*, 976(4), 123-143.
175. Podhorska, I., Vrbka, J., Lazaroiu, G., & Kovacova, M. (2020). Innovations in financial management: Recursive prediction model based on decision trees.
176. Pompe, P.P. & Feelders, A.J. (1997). Using machine learning, neural networks, and statistics to predict corporate bankruptcy. *Computer-Aided Civil and Infrastructure Engineering*, 12(4), 267-276.
177. Porzycki, M. (2019). Bankruptcy of natural persons: the polish experience.
178. Potdar, K., Pardawala, T. S., & Pai, C. D. (2017). A comparative study of categorical variable encoding techniques for neural network classifiers. *International journal of computer applications*, 175(4), 7-9.
179. Premalatha, G., Priyanka, R., & Chaitya, K. (2023, February). Feature selection for predicting bankruptcy: Comparative analysis. In 2023 Fifth International Conference on Electrical, Computer and Communication Technologies (ICECCT) (pp. 1-5). IEEE.

180. Probst, P., Wright, M.N., & Boulesteix, A.L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: data mining and knowledge discovery*, 9(3), e1301.
181. Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in neural information processing systems*, 31.
182. Ptak-Chmielewska, A. (2012). Wykorzystanie modeli przeżycia i analizy dyskryminacyjnej do oceny ryzyka upadłości przedsiębiorstw. *Ekonometria*, (38), 157-172.
183. Ptak-Chmielewska, A. (2021). Bankruptcy prediction of small-and medium-sized enterprises in Poland based on the LDA and SVM methods. *Statistics in Transition. New Series*, 22(1), 179-195.
184. Qi, M., & Yang, X. (2009). Loss given default of high loan-to-value residential mortgages. *Journal of Banking & Finance*, 33(5), 788-799.
185. Qian, H., Wang, B., Yuan, M., Gao, S., & Song, Y. (2022). Financial distress prediction using a corrected feature selection measure and gradient boosted decision tree. *Expert Systems with Applications*, 190, 116202.
186. Qu, Y., Quan, P., Lei, M., & Shi, Y. (2019). Review of bankruptcy prediction using machine learning and deep learning techniques. *Procedia Computer Science*, 162, 895-899.
187. Ramsay, I. (2007). Comparative consumer bankruptcy. *U. Ill. L. Rev.*, 241.
188. Raschka, S., & Mirjalili, V. (2021). *Python, machine learning i deep learning: Biblioteki scikit-learn i TensorFlow 2* (tłum. K. Sawka). Helion.
189. Ren, Y., & Weiss, G.M. (2021). A Comparison of Important Features for Predicting Polish and Chinese Corporate Bankruptcies. In *Advances in Data Science and Information Engineering*, Proceedings from ICDATA 2020 and IKE 2020, Springer International Publishing, 187-198.
190. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016, August). "Why should i trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 1135-1144).
191. Roberts, J. A., & Jones, E. (2001). Money attitudes, credit card use, and compulsive buying among American college students. *Journal of consumer affairs*, 35(2), 213-240.
192. Sahiq, A. N. M., Ismail, S., Nor, S. H. S., Ul-Saufie, A. Z., & Yaacob, W. F. W. (2022, September). Application of logistic regression model on imbalanced data in personal bankruptcy prediction. 2022 3rd International Conference on Artificial Intelligence and Data Sciences (AiDAS) (pp. 120–125). IEEE.

193. Salekshahrezaee, Z., Leevy, J. L., & Khoshgoftaar, T. M. (2023). The effect of feature extraction and data sampling on credit card fraud detection. *Journal of Big Data*, 10(1), 6.
194. Samuelson, P. A., & Nordhaus, W. D. (2003). *Ekonomia 1*, Wyd. Naukowe PWN, Warszawa.
195. Schonlau, M., & Zou, R.Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3-29.
196. Scikit-learn. (2025a). *Gradient boosting*. Pozyskano 25 maja 2025, ze strony <https://scikit-learn.org/stable/modules/ensemble.html#gradient-boosting>.
197. Scikit-learn. (2025b). *Gradient Boosting Classifier*. Pozyskano 5 maja 2025, ze strony <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html>.
198. Shafieian, S., & Zulkernine, M. (2023). Multi-layer stacking ensemble learners for low footprint network intrusion detection. *Complex & Intelligent Systems*, 9(4), 3787-3799.
199. Shanker, M., Hu, M. Y., & Hung, M. S. (1996). Effect of data standardization on neural network training. *Omega*, 24(4), 385-397.
200. Sharma, S., & Chatterjee, S. (2021). Winsorization for robust bayesian neural networks. *Entropy*, 23(11), 1546.
201. Shetty, S., Musa, M., & Brédart, X. (2022). Bankruptcy prediction using machine learning techniques. *Journal of Risk and Financial Management*, 15(1), 35.
202. Shi, Y., & Li, X. (2019). An overview of bankruptcy prediction models for corporate firms: A systematic literature review. *Intangible Capital*, 15(2), 114-127.
203. Shin, K. S., Lee, T. S., & Kim, H. J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert systems with applications*, 28(1), 127-135.
204. Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. A. (2023). A Comprehensive Overview and Comparative Analysis on Deep Learning Models. CNN, RNN, LSTM, GRU.
205. Shrivastav, S. K., & Ramudu, P. J. (2020). Bankruptcy prediction and stress quantification using support vector machine: Evidence from Indian banks. *Risks*, 8(2), 52.
206. Singh, S., & Gupta, P. (2014). Comparative study ID3, cart and C4. 5 decision tree algorithm: a survey. *International Journal of Advanced Information Science and Technology (IJAIST)*, 27(27), 97-103.
207. Skiba, P. M., & Tobacman, J. (2019). Do payday loans cause bankruptcy? *The Journal of Law and Economics*, 62(3), 485-519.
208. Smith, M., & Alvarez, F. (2022). Predicting firm-level bankruptcy in the Spanish economy using extreme gradient boosting. *Computational Economics*, 59(1), 263-295.

209. Sommer, H. J. (2005). Trying to Make Sense Out of Nonsense: Representing Consumers Under the Bankruptcy Abuse Prevention and Consumer Protection Act of 2005. *Am. Bankr. LJ*, 79, 191.
210. Son, H., Hyun, C., Phan, D., & Hwang, H. J. (2019). Data analytic approach for bankruptcy prediction. *Expert Systems with Applications*, 138, 112816.
211. Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 3, 54-70.
212. Statista. (2025). Pozyskano 2 lutego 2025, ze strony <https://www.statista.com/statistics/>.
213. Stavins, J. (2000). Credit card borrowing, delinquency, and personal bankruptcy. *New England Economic Review*, 15-30.
214. Sun, C. (2023). Company Bankruptcy Prediction with Machine Learning Techniques. In *Advances in Artificial Intelligence, Big Data and Algorithms* (pp. 425-437). IOS Press.
215. Świecka, B. (2008). *Bankructwa gospodarstw domowych: Perspektywa ekonomiczna i społeczna*.
216. Świecka, B. (2009). Niewypłacalność gospodarstw domowych: przyczyny, skutki, przeciwdziałanie. *Centrum Doradztwa i Informacji Difin*.
217. Świecka, B., & Koziński, M. (2014). Rola perspektywy czasowej w zadłużeniu gospodarstw domowych. Ujęcie behawioralne. *Zeszyty Naukowe Uniwersytetu Szczecińskiego, Problemy zarządzania, finansów i marketingu*, 34, 217-230.
218. Syam, N., & Sharma, A. (2018). Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial marketing management*, 69, 135-146.
219. Syed Nor, S. H., Ismail, S., & Wah, Y. B. (2024). Personal Bankruptcy Prediction Using Logistic Regression Model. *Information Management and Business Review*, 16(3S (I) a), 366-378.
220. Syed Nor, S.H., Ismail, S., & Yap, B.W. (2019). Personal bankruptcy prediction using decision tree model. *Journal of Economics, Finance and Administrative Science*, 24(47), 157-170.
221. Szpringer, W. (2008) Upadłość konsumencka (inspiracje z rozwiązań światowych), *CBEK*, Wrocław, http://bibliotekacyfrowa.pl/Content/23655/Regulacja_upadlosci.pdf (dostęp: 25 października 2023r.).
222. Szpringer, W., & Szpringer, Z. (2004). Regulacja kredytu konsumenckiego i upadłości konsumenckiej (inspiracje dla Polski w świetle rozwiązań niektórych krajów UE oraz projektu noweli do dyrektywy UE o kredycie konsumenckim). *Bank i Kredyt*, (9), 31-41.

223. Szymańska, A. (2013). Upadłość konsumencka w wybranych krajach Unii Europejskiej a kryzys gospodarczy. *Problemy Zarządzania*, (1/2013 (40) t. 1), 54-67.
224. Tereszkievicz, P. (2009). Upadłość konsumencka w wybranych systemach prawnych. *Instytut Wymiaru Sprawiedliwości, Warszawa*.
225. Tim, A. (2018). Upadłość konsumencka w prawie polskim i niemieckim a praktyka forum shopping. *Internetowy Kwartalnik Antymonopolowy i Regulacyjny (iKAR)*, 7(6), 53-66.
226. Tsai, C. F. (2009). Feature selection in bankruptcy prediction. *Knowledge-Based Systems*, 22(2), 120-127.
227. Tsai, C. F., & Wu, J. W. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert systems with applications*, 34(4), 2639-2649.
228. Tsai, C. F., Hsu, Y. F., & Yen, D. C. (2014). A comparative study of classifier ensembles for bankruptcy prediction. *Applied Soft Computing*, 24, 977-984.
229. Tunio, F. H., Ding, Y., Agha, A. N., Agha, K., & Panhwar, H. U. R. Z. (2021). Financial distress prediction using adaboost and bagging in Pakistan stock exchange. *The Journal of Asian Finance, Economics and Business*, 8(1), 665-673.
230. Uddin, N., Ahamed, M. K. U., Uddin, M. A., Islam, M. M., Talukder, M. A., & Aryal, S. (2023). An ensemble machine learning based bank loan approval predictions system with a smart application. *International Journal of Cognitive Computing in Engineering*, 4, 327-339.
231. Ul Hassan, E., Zainuddin, Z., & Nordin, S. (2017). A review of financial distress prediction models: logistic regression and multivariate discriminant analysis. *Indian-Pacific Journal of Accounting and Finance*, 1(3), 13-23.
232. United Kingdom Office for National Statistics. (2025). Pozyskano 2 lutego 2025, ze strony <https://www.ons.gov.uk/>.
233. United States Courts. (2023). Pozyskano 2 listopada 2023, ze strony <https://www.uscourts.gov/services-forms/bankruptcy/>.
234. United States Courts. (2025). *Caseload statistics data tables*. Pozyskano 2 lutego 2025, ze strony <https://www.uscourts.gov/statistics-reports/caseload-statistics-data-tables>.
235. Veganzones, D., & Séverin, E. (2018). An investigation of bankruptcy prediction in imbalanced datasets. *Decision Support Systems*, 112, 111-124.
236. Wałęga, G. (2010). Determinanty zadłużenia gospodarstw domowych w Polsce w świetle wybranych teorii konsumpcji. Otoczenie ekonomiczne a zachowania podmiotów rynkowych, *Polskie Towarzystwo Ekonomiczne, Kraków*.
237. Wang, D. N., Li, L., & Zhao, D. (2022). Corporate finance risk prediction based on LightGBM. *Information Sciences*, 602, 259-268.

238. Wang, G., Ma, J., & Yang, S. (2014). An improved boosting based on feature selection for corporate bankruptcy prediction. *Expert Systems with Applications*, 41(5), 2353-2361.
239. Wang, X., & Brorsson, M. (2023, December). Augmenting Bankruptcy Prediction Using Reported Behavior of Corporate Restructuring. In BenchCouncil International Symposium on Intelligent Computers, Algorithms, and Applications (pp. 102-121). Singapore: Springer Nature Singapore.
240. Wang, Z., Hong, Y., Huang, L., Zheng, M., Yuan, H., & Zeng, R. (2025). A comprehensive review and future research directions of ensemble learning models for predicting building energy consumption. *Energy and Buildings*, 115589.
241. Wayman, J. C. (2003, April). Multiple imputation for missing data: What is it and how can I use it. In *Annual Meeting of the American Educational Research Association, Chicago, IL* (Vol. 2, p. 16).
242. West, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, 27(11-12), 1131-1152.
243. White, M. (2006). Bankruptcy and consumer behavior: Theory and US evidence (Vol. 7). ch.
244. Wiśniewska, D. (2018). New Consumer Bankruptcy in Poland—a New Start not only for the Consumer? *Bezpieczny Bank*, 73(4), 80-109.
245. Witkowska, D., Kaminski, W., & Staniec, I. (2003). The Loan Granting Procedure: Artificial Neural Networks, Discriminant Analysis, K-Means Method. In *Modeling and Control of Economic Systems 2001* (pp. 383-387). Elsevier Science Ltd.
246. Wolska-Bagińska, A. (2018). Ekonomiczno-prawne aspekty upadłości konsumenckiej. *Andrzej Marian Świątkowski Specyficzne pojmowanie badań i metod empirycznych w prawie pracy* | 9 *Andrzej Szymański Gdy bezprawie było prawem. Kilka przykładów dyskryminacji ludzi wierzących w Polsce Ludowej* | 39, 145.
247. Wu, D.J., Feng, T., Naehrig, M., & Lauter, K.E. (2015). Privately Evaluating Decision Trees and Random Forests. *Proc. Priv. Enhancing Technol.*, 2016(4), pp.335-355.
248. Wujek, B., Hall, P., & Günes, F. (2016). Best practices for machine learning applications. *SAS Institute Inc*, 3.
249. Xie, G., Zhao, Y., Jiang, M., & Zhang, N. (2013). A novel ensemble learning approach for corporate financial distress forecasting in fashion and textiles supply chains. *Mathematical Problems in Engineering*, 2013(1), 493931.
250. Yen, S. J., & Lee, Y. S. (2009). Cluster-based under-sampling approaches for imbalanced data distributions. *Expert Systems with Applications*, 36(3), 5718-5727.

251. Zalega, T. (2014). Upadłość konsumencka a zadłużanie się miejskich gospodarstw domowych w Polsce w okresie kryzysu. Nierówności społeczne a wzrost gospodarczy, (38), 152-168.
252. Zelenkov, Y., & Volodarskiy, N. (2021). Bankruptcy prediction on the base of the unbalanced data using multi-objective selection of classifiers. *Expert Systems with Applications*, 185, 115559.
253. Zelenkov, Y., Fedorova, E., & Chekrizov, D. (2017). Two-step classification method based on genetic algorithm for bankruptcy forecasting. *Expert Systems with Applications*, 88, 393-401.
254. Zhang, G., Hu, M. Y., Patuwo, B. E., & Indro, D. C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European journal of operational research*, 116(1), 16-32.
255. Zhang, L., Wang, J., & Liu, Z. (2023). What should lenders be more concerned about? Developing a profit-driven loan default prediction model. *Expert Systems with Applications*, 213, 118938.
256. Zhang, W. (2017). Machine learning approaches to predicting company bankruptcy. *Journal of Financial Risk Management*, 6(04), 364.
257. Zhao, J., Ouenniche, J., & De Smedt, J. (2024). Survey, classification and critical analysis of the literature on corporate bankruptcy and financial distress prediction. *Machine Learning with Applications*, 100527.
258. Zhou, L. (2013). Performance of corporate bankruptcy prediction models on imbalanced dataset: The effect of sampling methods. *Knowledge-Based Systems*, 41, 16-25.
259. Zhu, J. J., Yang, M., & Ren, Z. J. (2023). Machine learning in environmental research: common pitfalls and best practices. *Environmental Science & Technology*, 57(46), 17671-17689.
260. Zhu, L., Qiu, D., Ergu, D., Ying, C. and Liu, K. (2019), "A study on predicting loan default based on the random forest algorithm", *Procedia Computer Science*, 162, pp. 503-513
261. Zhu, N. (2011). Household consumption and personal bankruptcy. *The Journal of Legal Studies*, 40(1), 1-37.
262. Zywicki, T. J. (2004). An economic analysis of the consumer bankruptcy crisis. *Nw. UL Rev.*, 99, 1463.

Spis rysunków

Rysunek 1. Liczba upadłości konsumenckich w poszczególnych stanach w Stanach Zjednoczonych w latach 2022 i 2024	27
Rysunek 2. Miesięczna liczba upadłości konsumenckich w Polsce w latach 2015-2024	31
Rysunek 3. Liczba upadłości konsumenckich w poszczególnych województwach w Polsce w latach 2022 oraz 2024	33
Rysunek 4. Liczba upadłości konsumenckich na 100 000 mieszkańców w województwach Polski w latach 2015-2024	34
Rysunek 5. Dostępne opcje postępowania w przypadku niewypłacalności w Anglii i Walii	36
Rysunek 6. Podział przyczyn upadłości konsumenckiej	46
Rysunek 7. Klasyfikacja czynników ryzyka niewypłacalności w kontekście upadłości konsumenckiej	47
Rysunek 8. Klasyfikacja metod z zakresu sztucznej inteligencji.....	55
Rysunek 9. Przykładowa struktura metody stacking	60
Rysunek 10. Przykładowa struktura metody wielowarstwowego stackingu (ang. multi-layer stacking)	61
Rysunek 11. Przykładowa struktura metody głosowania oraz uśredniania	62
Rysunek 12. Przykładowa struktura drzewa decyzyjnego.....	66
Rysunek 13. Przykładowa struktura lasu losowego.....	68
Rysunek 14. Przykładowa struktura algorytmu Gradient Boosting Classifier	70
Rysunek 15. Przykładowa struktura algorytmu XGBoost	70
Rysunek 16. Przykładowa struktura algorytmu LightGBM	72
Rysunek 17. Przykładowa struktura algorytmu CatBoost	72
Rysunek 18. Przykładowa struktura algorytmu sztucznej sieci neuronowej	74
Rysunek 19. Macierz błędów dla wyniku binarnego.....	75
Rysunek 20. Wizualizacja częstotliwości wykorzystywanych zmiennych oraz komponentów wskaźników w wybranej literaturze przedmiotu	86
Rysunek 21. Kluczowe etapy budowy oszacowanych modeli	97
Rysunek 22. Struktura pytań badawczych i hipotez dotyczących algorytmów prognozowania ryzyka upadłości konsumenckiej	247
Rysunek 23. Struktura pytań badawczych i hipotez dotyczących zmiennych wykorzystanych w budowie modeli prognozowania ryzyka upadłości konsumenckiej.....	249

Spis wykresów

Wykres 1. Upadłość konsumencka w Stanach Zjednoczonych w podziale na rodzaj procedury upadłościowej	24
Wykres 2. Upadłości konsumenckie w Stanach Zjednoczonych w latach 2001-2024.....	26
Wykres 3. Upadłości konsumenckie w Polsce w latach 2015-2024.....	30
Wykres 4. Struktura wieku konsumentów ogłaszających upadłość konsumencką w Polsce w latach 2015-2024.....	32
Wykres 5. Upadłość konsumencka w Polsce w latach 2015-2024 ze względu na płeć.....	32
Wykres 6. Udział ogłoszonych upadłości konsumenckich w stosunku do liczby wniosków o upadłość konsumencką w Polsce w latach 2009-2024	35
Wykres 7. Średni czas trwania postępowania upadłościowego w Polsce w miesiącach w latach 2009-2024	35
Wykres 8. Upadłości konsumenckie w Anglii i Walii w latach 2010-2024.....	39
Wykres 9. Udział upadłości konsumenckiej, Indywidualnego Porozumienia Dobrowolnego oraz Nakazu Umorzenia Długu w łącznej liczbie indywidualnych postępowań upadłościowych w Anglii i Walii w latach 2010-2024.....	39
Wykres 10. Upadłości konsumenckie w Niemczech w latach 2010-2024	41
Wykres 11. Upadłości konsumenckie w Irlandii Północnej w latach 2010-2024	43
Wykres 12. Udział upadłości konsumenckiej, Indywidualnego Porozumienia Dobrowolnego oraz Nakazu Umorzenia Długu w łącznej liczbie indywidualnych postępowań upadłościowych w Irlandii Północnej w latach 2010-2024	43
Wykres 13. Udział procentowy kategorii wiekowych wraz z odpowiadającą liczbą przypadków względem upadłości konsumenckiej.....	103
Wykres 14. Udział procentowy poziomu wykształcenia wraz z odpowiadającą liczbą przypadków względem upadłości konsumenckiej.....	104
Wykres 15. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem regresji logistycznej.....	106
Wykres 16. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM.....	108
Wykres 17. Istotność cech w modelu SVM.....	109
Wykres 18. Podsumowanie wartości SHAP dla modelu SVM	110
Wykres 19. Średni wpływ cech na wynik modelu SVM według wartości SHAP.....	111

Wykres 20. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody SHAP	111
Wykres 21. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody SHAP	112
Wykres 22. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody LIME	113
Wykres 23. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody LIME	113
Wykres 24. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu drzewa decyzyjnego	114
Wykres 25. Istotność cech w modelu drzewa decyzyjnego	115
Wykres 26. Podsumowanie metody SHAP dla modelu drzewa decyzyjnego	116
Wykres 27. Średni wpływ cech na wynik modelu drzewa decyzyjnego według wartości SHAP	117
Wykres 28. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody SHAP	118
Wykres 29. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody SHAP	119
Wykres 30. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody LIME	120
Wykres 31. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody LIME	120
Wykres 32. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem lasu losowego	121
Wykres 33. Istotność cech w modelu lasu losowego	122
Wykres 34. Podsumowanie SHAP dla modelu lasu losowego	123
Wykres 35. Średni wpływ cech na wynik modelu lasu losowego według wartości SHAP ..	123
Wykres 36. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody SHAP	124
Wykres 37. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody SHAP	125
Wykres 38. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody LIME	126

Wykres 39. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody LIME	126
Wykres 40. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu AdaBoost.....	127
Wykres 41. Istotność cech w modelu AdaBoost.....	128
Wykres 42. Podsumowanie wartości SHAP dla modelu AdaBoost	128
Wykres 43. Średni wpływ cech na wynik modelu AdaBoost według wartości SHAP	129
Wykres 44. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP	130
Wykres 45. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody SHAP	131
Wykres 46. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody LIME	131
Wykres 47. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody LIME	132
Wykres 48. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu Gradient Boosting Classifier	133
Wykres 49. Istotność cech w modelu Gradient Boosting Classifier.....	133
Wykres 50. Podsumowanie wartości SHAP dla modelu Gradient Boosting Classifier	134
Wykres 51. Średni wpływ cech na wynik modelu Gradient Boosting Classifier według wartości SHAP	135
Wykres 52. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody SHAP	136
Wykres 53. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody SHAP	137
Wykres 54. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody LIME	137
Wykres 55. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody LIME	138
Wykres 56. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu XGBoost.....	139
Wykres 57. Istotność cech w modelu XGBoost	139
Wykres 58. Podsumowanie wartości SHAP dla modelu XGBoost	140
Wykres 59. Średni wpływ cech na wynik modelu XGBoost według wartości SHAP	141

Wykres 60. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP	142
Wykres 61. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody SHAP	143
Wykres 62. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody LIME	143
Wykres 63. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody LIME	144
Wykres 64. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem modelu LightGBM	145
Wykres 65. Istotność cech w modelu LightGBM.....	145
Wykres 66. Podsumowanie wartości SHAP dla modelu LightGBM	146
Wykres 67. Średni wpływ cech wejściowych na wynik modelu LightGBM według wartości SHAP	147
Wykres 68. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody SHAP	148
Wykres 69. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody SHAP	149
Wykres 70. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody LIME	150
Wykres 71. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody LIME	150
Wykres 72. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem Catboost.....	151
Wykres 73. Istotność cech w modelu Catboost	152
Wykres 74. Podsumowanie SHAP dla modelu CatBoost.....	153
Wykres 75. Średni wpływ cech na wynik modelu CatBoost według wartości SHAP	153
Wykres 76. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody SHAP	154
Wykres 77. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody SHAP	155
Wykres 78. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody LIME	156

Wykres 79. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody LIME	156
Wykres 80. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem sieci neuronowych	157
Wykres 81. Istotność cech w modelu sieci neuronowych	158
Wykres 82. Podsumowanie wartości SHAP dla modelu sieci neuronowych	158
Wykres 83. Średni wpływ cech na wynik modelu sieci neuronowych według wartości SHAP	159
Wykres 84. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody SHAP	160
Wykres 85. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody SHAP	161
Wykres 86. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody LIME	161
Wykres 87. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody LIME	162
Wykres 88. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem regresji logistycznej, opracowana dla drugiego zestawu zmiennych	166
Wykres 89. Krzywa ROC dla modelu prognozowania upadłości konsumenckiej z wykorzystaniem algorytmu SVM opracowana dla drugiego zestawu zmiennych	168
Wykres 90. Istotność cech w modelu SVM opracowana dla drugiego zestawu zmiennych	169
Wykres 91. Podsumowanie wartości SHAP dla modelu SVM opracowane dla drugiego zestawu zmiennych	170
Wykres 92. Średni wpływ cech na wynik modelu SVM według wartości SHAP opracowany dla drugiego zestawu zmiennych	170
Wykres 93. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	171
Wykres 94. Interpretacja wyniku modelu SVM dla drugiego konsumenta z użyciem metody SHAP opracowana na podstawie drugiego zestawu zmiennych	172
Wykres 95. Interpretacja wyniku modelu SVM dla pierwszego konsumenta z wykorzystaniem metody LIME, opracowana na podstawie drugiego zestawu zmiennych	173
Wykres 96. Interpretacja wyniku modelu SVM dla drugiego konsumenta z wykorzystaniem metody LIME dla drugiego zestawu zmiennych	173

Wykres 97. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem drzewa decyzyjnego opracowana dla drugiego zestawu zmiennych.....	174
Wykres 98. Istotność cech w modelu drzewa decyzyjnego opracowana dla drugiego zestawu zmiennych.....	175
Wykres 99. Podsumowanie wartości SHAP dla modelu drzewa decyzyjnego opracowane dla drugiego zestawu zmiennych.....	176
Wykres 100. Średni wpływ cech wejściowych na wynik modelu drzewa decyzyjnego według wartości SHAP opracowany dla drugiego zestawu zmiennych.....	177
Wykres 101. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych.....	177
Wykres 102. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych.....	178
Wykres 103. Interpretacja wyniku modelu drzewa decyzyjnego dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zbioru zmiennych.....	179
Wykres 104. Interpretacja wyniku modelu drzewa decyzyjnego dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zbioru zmiennych.....	179
Wykres 105. Krzywa ROC dla modelu prognozowania upadłości konsumentek z wykorzystaniem lasu losowego opracowana dla drugiego zestawu zmiennych.....	180
Wykres 106. Istotność cech w modelu lasu losowego opracowana dla drugiego zestawu zmiennych.....	181
Wykres 107. Podsumowanie wartości SHAP dla modelu lasu losowego opracowane dla drugiego zestawu zmiennych.....	182
Wykres 108. Średni wpływ cech na wynik modelu lasu losowego według wartości SHAP opracowany dla drugiego zestawu zmiennych.....	183
Wykres 109. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta przy użyciu metody SHAP opracowana dla drugiego zestawu zmiennych.....	183
Wykres 110. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych.....	184
Wykres 111. Interpretacja wyniku modelu lasu losowego dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	185
Wykres 112. Interpretacja wyniku modelu lasu losowego dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	185
Wykres 113. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem algorytmu AdaBoost opracowana dla drugiego zestawu zmiennych.....	187

Wykres 114. Istotność cech w modelu AdaBoost opracowana dla drugiego zestawu zmiennych	187
Wykres 115. Podsumowanie wartości SHAP dla modelu AdaBoost opracowana dla drugiego zestawu zmiennych	188
Wykres 116. Średni wpływ cech na wynik modelu AdaBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych	189
Wykres 117. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	190
Wykres 118. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	191
Wykres 119. Interpretacja wyniku modelu AdaBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	192
Wykres 120. Interpretacja wyniku modelu AdaBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	192
Wykres 121. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem modelu Gradient Boosting Classifier opracowana dla drugiego zestawu zmiennych.....	193
Wykres 122. Istotność cech w modelu Gradient Boosting Classifier opracowana dla drugiego zestawu zmiennych	194
Wykres 123. Podsumowanie SHAP dla modelu Gradient Boosting Classifier opracowane dla drugiego zestawu zmiennych.....	195
Wykres 124. Średni wpływ cech na wynik modelu Gradient Boosting Classifier według wartości SHAP opracowany dla drugiego zestawu zmiennych.....	196
Wykres 125. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych.....	197
Wykres 126. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych.....	198
Wykres 127. Interpretacja wyniku modelu Gradient Boosting Classifier dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych	199
Wykres 128. Interpretacja wyniku modelu Gradient Boosting Classifier dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych	199

Wykres 129. Krzywa ROC dla modelu prognozowania upadłości konsumentek z wykorzystaniem modelu XGBoost opracowana dla drugiego zestawu zmiennych	200
Wykres 130. Istotność cech w modelu XGBoost opracowana dla drugiego zestawu zmiennych	201
Wykres 131. Podsumowanie wartości SHAP dla modelu XGBoost opracowane dla drugiego zestawu zmiennych	202
Wykres 132. Średni wpływ cech na wynik modelu XGBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych	203
Wykres 133. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	204
Wykres 134. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	205
Wykres 135. Interpretacja wyniku modelu XGBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	206
Wykres 136. Interpretacja wyniku modelu XGBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	206
Wykres 137. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem modelu LightGBM opracowana dla drugiego zestawu zmiennych.....	208
Wykres 138. Istotność cech w modelu LightGBM opracowana dla drugiego zestawu zmiennych	208
Wykres 139. Podsumowanie wartości SHAP dla modelu LightGBM opracowane dla drugiego zestawu zmiennych	209
Wykres 140. Średni wpływ cech na wynik modelu LightGBM według wartości SHAP opracowany dla drugiego zestawu zmiennych	210
Wykres 141. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	211
Wykres 142. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	212
Wykres 143. Interpretacja wyniku modelu LightGBM dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	213
Wykres 144. Interpretacja wyniku modelu LightGBM dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	213
Wykres 145. Krzywa ROC dla modelu prognozowania upadłości konsumentek z wykorzystaniem algorytmu Catboost opracowana dla drugiego zestawu zmiennych.....	215

Wykres 146. Istotność cech w modelu Catboost opracowana dla drugiego zestawu zmiennych	215
Wykres 147. Podsumowanie wartości SHAP dla modelu CatBoost opracowane dla drugiego zestawu zmiennych	216
Wykres 148. Średni wpływ cech na wynik modelu CatBoost według wartości SHAP opracowany dla drugiego zestawu zmiennych	217
Wykres 149. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	218
Wykres 150. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z użyciem metody SHAP opracowana dla drugiego zestawu zmiennych	219
Wykres 151. Interpretacja wyniku modelu CatBoost dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	220
Wykres 152. Interpretacja wyniku modelu CatBoost dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	220
Wykres 153. Krzywa ROC dla modelu prognozowania upadłości konsumentów z wykorzystaniem sieci neuronowych opracowana dla drugiego zestawu zmiennych	221
Wykres 154. Istotność cech w modelu sieci neuronowych opracowana dla drugiego zestawu zmiennych.....	222
Wykres 155. Podsumowanie wartości SHAP dla modelu sieci neuronowych opracowane dla drugiego zestawu zmiennych.....	223
Wykres 156. Średni wpływ cech na wynik modelu sieci neuronowych według wartości SHAP opracowany dla drugiego zestawu zmiennych	224
Wykres 157. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody SHAP opracowana dla drugiego zestawu zmiennych.....	224
Wykres 158. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody SHAP opracowana dla drugiego zestawu zmiennych.....	225
Wykres 159. Interpretacja wyniku modelu sieci neuronowych dla pierwszego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	226
Wykres 160. Interpretacja wyniku modelu sieci neuronowych dla drugiego konsumenta z wykorzystaniem metody LIME opracowana dla drugiego zestawu zmiennych.....	226
Wykres 161. Rozkład istotności cech w modelach oszacowanych dla pierwszego zestawu zmiennych.....	242
Wykres 162. Rozkład istotności cech w modelach oszacowanych dla drugiego zestawu zmiennych.....	243

Spis tabel

Tabela 1. Miary skuteczności modeli	76
Tabela 2. Zmienne najczęściej wykorzystywane w analizowanej literaturze przedmiotu.....	85
Tabela 3. Przegląd modeli prognozowania upadłości konsumenckiej	91
Tabela 4. Opis zmiennych wykorzystanych do budowy modeli	99
Tabela 5. Grupy zmiennych wykorzystane do budowy modeli.....	100
Tabela 6. Wyniki modelu regresji logistycznej opracowane dla pierwszego zestawu zmiennych	107
Tabela 7. Wyniki modelu regresji logistycznej opracowane dla drugiego zestawu zmiennych	167
Tabela 8. Skuteczność modeli indywidualnych opracowana dla pierwszego zestawu zmiennych – próba ucząca	230
Tabela 9. Skuteczność modeli indywidualnych opracowana dla pierwszego zestawu zmiennych – próba testowa.....	230
Tabela 10. Opis modeli zespołowych opracowany dla pierwszego i drugiego zestawu zmiennych.....	231
Tabela 11. Skuteczność modeli zespołowych opracowana dla pierwszego zestawu zmiennych – próba ucząca.....	231
Tabela 12. Skuteczność modeli zespołowych opracowana dla pierwszego zestawu zmiennych – próba testowa	232
Tabela 13. Skuteczność modeli indywidualnych opracowana dla drugiego zestawu zmiennych – próba ucząca.....	234
Tabela 14. Skuteczność modeli indywidualnych opracowana dla drugiego zestawu zmiennych – próba testowa	234
Tabela 15. Skuteczność modeli zespołowych opracowana dla drugiego zestawu zmiennych – próba ucząca.....	235
Tabela 16. Skuteczność modeli zespołowych opracowana dla drugiego zestawu zmiennych – próba testowa	235