



WYDZIAŁ ZARZĄDZANIA
I EKONOMII

**AUTOREFERAT
ROZPRAWY DOKTORSKIEJ**

**Modele oceny ryzyka upadłości
konsumenckiej**

Magdalena Brygała

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

Promotor pomocniczy: dr Piotr Paradowski

Gdańsk, 2026

Spis treści

1. Uzasadnienie wyboru tematu.....	3
2. Cele rozprawy, pytania badawcze i hipotezy badawcze.....	6
3. Struktura rozprawy doktorskiej	8
4. Metodyka przeprowadzonych badań	9
4.1. Założenia do przeprowadzonych badań	9
4.2. Charakterystyka próby badawczej.....	15
5. Kluczowe wyniki badań	18
5.1. Analiza porównawcza skuteczności modeli prognozowania ryzyka upadłości konsumenckiej.....	18
5.2. Analiza istotności cech w modelach prognozowania ryzyka upadłości konsumenckiej 27	
6. Podsumowanie.....	33
Rekomendacje dla przyszłych badań	40
Ograniczenia badawcze.....	41
Bibliografia.....	42

1. Uzasadnienie wyboru tematu

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; 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; 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, 2024a; 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.

2. Cele rozprawy, pytania badawcze i hipotezy badawcze

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.

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 umożliwi zrozumienie modelu, przy jednoczesnym korzystaniu z zaawansowanych algorytmów.

3. Struktura rozprawy doktorskiej

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.

4. Metodyka przeprowadzonych badań

4.1. Założenia do przeprowadzonych badań

Kluczowe etapy budowy modeli w ramach niniejszego badania obejmują (rysunek 1): 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 1. 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 1.

Tabela 1. 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
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 2).

Tabela 2. 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 (Consumer Financial Protection Bureau [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, 2025). 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, 2025). 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 (CFPB, 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 2024a). 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

dotatkowe 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 wyniósł 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 wyniósł 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.

4.2. 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 1 przedstawiono rozkład wieku wraz z odpowiadającą liczbą przypadków, z podziałem na zmienną celu.

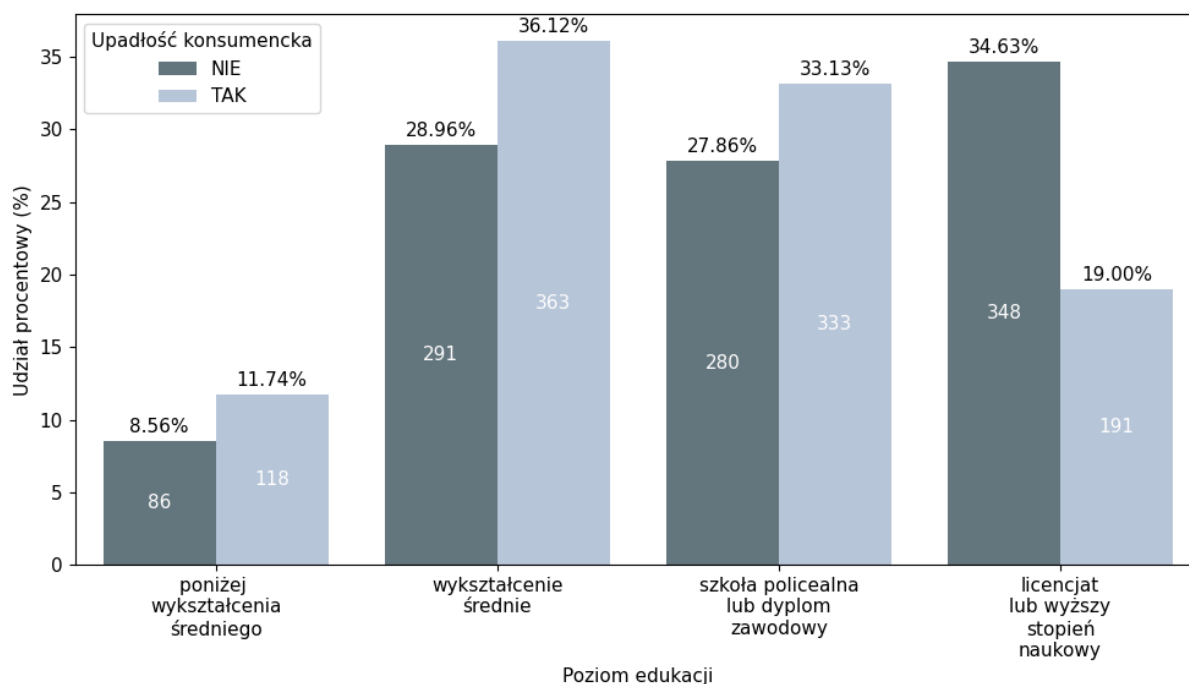
Wykres 1. Udział procentowy kategorii wiekowych wraz z odpowiadającą liczbą przypadków względem upadłości konsumenckiej



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 2 przedstawiono rozkład poziomów edukacji wraz z odpowiadającą liczbą przypadków, z podziałem na zmienną celu.

Wykres 2. 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.

5. Kluczowe wyniki badań

5.1. Analiza porównawcza skuteczności modeli prognozowania ryzyka upadłości konsumenckiej

Przeprowadzono analizę porównawczą skuteczności modeli prognozowania ryzyka upadłości konsumenckiej opracowanych na podstawie dwóch zestawów zmiennych. Celem analizy było porównanie miar skuteczności modeli. Porównanie to pozwoliło 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 3 (próba ucząca) oraz tabeli 4 (próba testowa).

Tabela 3. 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 4. 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 pozostałych 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. Najniższą 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 5 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 6 (próba ucząca) oraz tabeli 7 (próba testowa).

Tabela 5. 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 6. 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 7. 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 (2024b) 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 8, a dla próby testowej w tabeli 9. Miary skuteczności modeli zespołowych dla drugiego zestawu zmiennych na próbie uczącej znajdują się w tabeli 10, a na próbie testowej w tabeli 16.

Tabela 8. 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 9. 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 10. 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 11. 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 Klietikova (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.

5.2. Analiza istotności cech w modelach prognozowania ryzyka upadłości konsumenckiej

Po przeanalizowaniu skuteczności poszczególnych modeli przeprowadzono ocenę 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 zaciąganie 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 3 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 3. Rozkład istotności cech w modelach oszacowanych dla pierwszego zestawu zmiennych




Źródło: opracowanie na podstawie wyników badań własnych.

Na wykresie 4 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 4. Rozkład istotności cech w modelach oszacowanych dla drugiego zestawu zmiennych



Źródło: opracowanie na podstawie wyników badań własnych.

6. Podsumowanie

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.

Przeprowadzone badania umożliwiły osiągnięcie głównego celu rozprawy, polegającego na opracowaniu modeli prognozowania ryzyka upadłości konsumenckiej na przykładzie Stanów Zjednoczonych. Osiągnięcie tego celu potwierdzają wyniki badań empirycznych. 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.

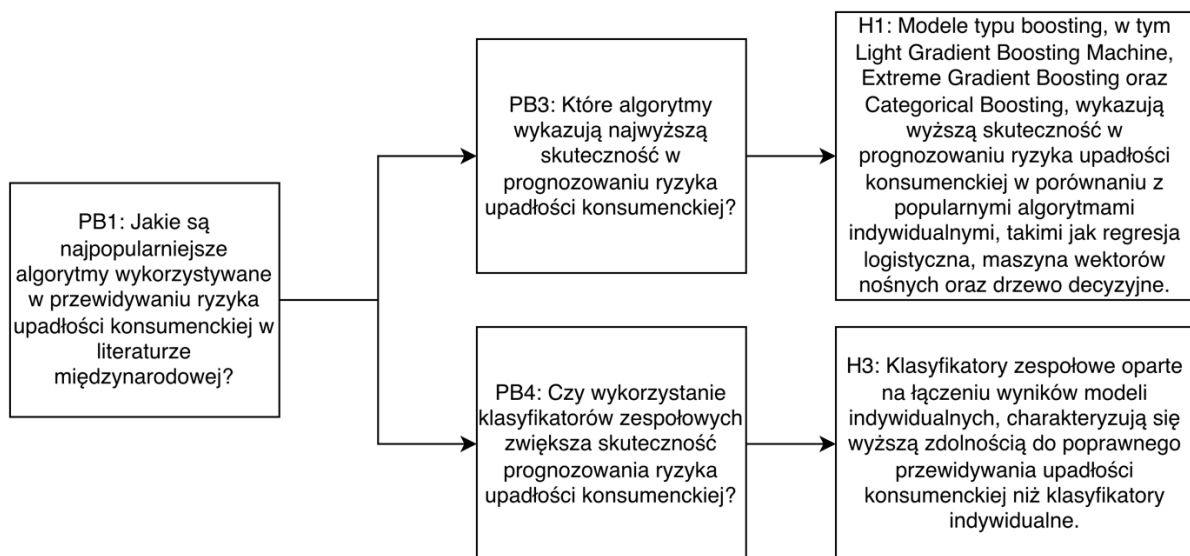
W ramach realizacji piątego celu szczegółowego oceniono skuteczność oszacowanych modeli z wykorzystaniem następujących miar: całkowitej skuteczności, błędu I typu, błędu II typu, miary F1, krzywej ROC wraz z wartością AUC oraz wskaźnika Giniego. Zastosowanie różnych metryk umożliwiło wieloaspektowe porównanie 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 2 zobrazowano strukturę pytań badawczych oraz hipotez związanych z tym obszarem.



Rysunek 2. 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.

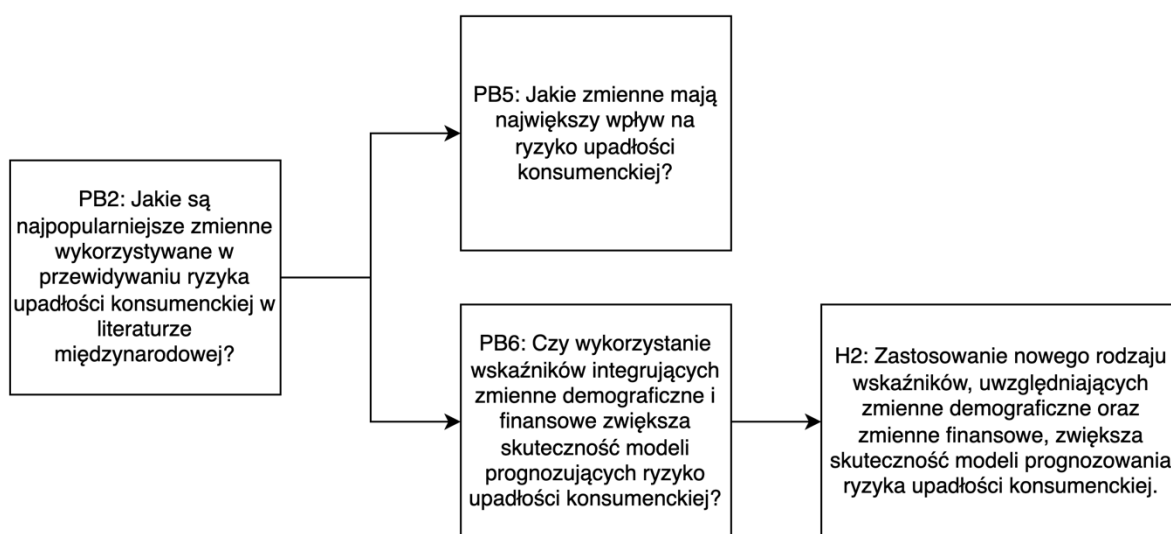
Pierwsza hipoteza badawcza (H1), powiązana z powyższym pytaniem badawczym, ma na celu sprawdzenie czy modele typu boosting, w tym Light Gradient Boosting Machine, Extreme Gradient Boosting oraz Categorical Boosting, wykazują wyższą skuteczność w prognozowaniu ryzyka upadłości konsumenckiej w porównaniu 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 najskuteczniejszych modeli znalazły się cztery oparte na uśrednianiu, jeden na głosowaniu oraz stacking z metamodelem 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. Choć 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 3 przedstawiono strukturę pytań badawczych oraz hipotez dotyczących zmiennych wykorzystanych w budowie modeli prognozowania ryzyka upadłości konsumenckiej.



Rysunek 3. 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. 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 redukcje 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. 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.
2. Alfaro, R., & Gallardo, N. (2012). The determinants of household debt default. *Economic Analysis Review*, 27(1), 27-54.
3. 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.
4. Amirshahi, B., & Lahmiri, S. (2024). Bankruptcy prediction using optimal ensemble models under balanced and imbalanced data. *Expert Systems*, 41(8), e13599.
5. Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417.
6. 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.
7. Bian, X., Lin, Z., & Liu, Y. (2018). House price, loan-to-value ratio and credit risk. *Journal of Banking & Finance*, 92, 1-12.
8. Brotcke, L. (2022). Time to assess bias in machine learning models for credit decisions. *Journal of Risk and Financial Management*, 15(4), 165.
9. Brygała, M. (2022). Consumer bankruptcy prediction using balanced and imbalanced data. *Risks*, 10(2), 24.
10. Brygała, M., & Korol, T. (2024). Personal bankruptcy prediction using machine learning techniques. *Economics and Business Review*, 10(2), 118-142.
11. 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.
12. 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.
13. Consumer Financial Protection Bureau (2022). Pozyskano 19 października 2022, ze strony at: <https://www.consumerfinance.gov/ask-cfpb/is-a-lender-allowed-to-consider-my-age-or-where-my-income-comes-from-when-deciding-whether-to-give-me-a-loan-en-1181/>.

14. Coşer, A., Maer-Matei, M. M., & Albu, C. (2019). PREDICTIVE MODELS FOR LOAN DEFAULT RISK ASSESSMENT. *Economic Computation & Economic Cybernetics Studies & Research*, 53(2).
15. 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.
16. Federal Reserve. (2025). Pozyskano 3 stycznia 2025, ze strony https://www.federalreserve.gov/boarddocs/supmanual/cch/fair_lend_reg_b.pdf/.
17. Fisher, J. D. (2005). The effect of unemployment benefits, welfare benefits, and other income on personal bankruptcy. *Contemporary Economic Policy*, 23(4), 483-492.
18. Fisher, J. D. (2019). Who files for personal bankruptcy in the United States? *Journal of Consumer Affairs*, 53(4), 2003-2026.
19. Gross, D. B., & Souleles, N. S. (2002). An empirical analysis of personal bankruptcy and delinquency. *The Review of Financial Studies*, 15(1), 319-347.
20. Gürtler, M., & Zöllner, M. (2022). Heterogeneities among credit risk parameter distributions: the modality defines the best estimation method. *OR Spectrum*, 1-37.
21. Himmelstein, D. U., Warren, E., Thorne, D., & Woolhandler, S. (2005). Illness and injury as contributors to bankruptcy. *Health Affairs*, 24(1), 570.
22. Hosaka, T. (2019). Bankruptcy prediction using imaged financial ratios and convolutional neural networks. *Expert systems with applications*, 117, 287-299.
23. 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.
24. 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.
25. Korol, T. (2021). Examining statistical methods in forecasting financial energy of households in Poland and Taiwan. *Energies*, 14(7), 1821.
26. Korol, T. (2024a). Multi-factor fuzzy sets decision system forecasting consumer insolvency risk. *Decision*, 51(3), 279-302.
27. Korol, T. (2024b). Artificial Neural Networks in Forecasting the Consumer Bankruptcy Risk with Innovative Ratios. *Contemporary Economics*, 18(4), 391-407.

28. Korol, T., & Fotiadis, A. (2022). Implementing artificial intelligence in forecasting the risk of personal bankruptcies in Poland and Taiwan. *Oeconomia Copernicana*, 13, 407-438.
29. Kovacova, M., & Kliestikova, J. (2017). Modelling bankruptcy prediction models in Slovak companies. In *SHS Web of Conferences* (Vol. 39, p. 01013). EDP Sciences.
30. Le, T., Hoang Son, L., Vo, M. T., Lee, M. Y., & Baik, S. W. (2018). A cluster-based boosting algorithm for bankruptcy prediction in a highly imbalanced dataset. *Symmetry*, 10(7), 250.
31. 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.
32. Lin, F. Y., & McClean, S. (2001). A data mining approach to the prediction of corporate failure. *Knowledge-based systems*, 14(3-4), 189-195.
33. Moorman, D. C., & Garasky, S. (2008). Consumer debt repayment behavior as a precursor to bankruptcy. *Journal of Family and Economic Issues*, 29, 219-233.
34. Qi, M., & Yang, X. (2009). Loss given default of high loan-to-value residential mortgages. *Journal of Banking & Finance*, 33(5), 788-799.
35. 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.
36. 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.
37. Schonlau, M., & Zou, R.Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3-29.
38. Shetty, S., Musa, M., & Brédart, X. (2022). Bankruptcy prediction using machine learning techniques. *Journal of Risk and Financial Management*, 15(1), 35.
39. Smith, M., & Alvarez, F. (2022). Predicting firm-level bankruptcy in the Spanish economy using extreme gradient boosting. *Computational Economics*, 59(1), 263-295.
40. Son, H., Hyun, C., Phan, D., & Hwang, H. J. (2019). Data analytic approach for bankruptcy prediction. *Expert Systems with Applications*, 138, 112816.

41. 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.
42. 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.
43. Wang, D. N., Li, L., & Zhao, D. (2022). Corporate finance risk prediction based on LightGBM. *Information Sciences*, 602, 259-268.
44. 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.
45. Xiong, T., Wang, S., Mayers, A., & Monga, E. (2013). Personal bankruptcy prediction by mining credit card data. *Expert systems with applications*, 40(2), 665-676.
46. Yen, S. J., & Lee, Y. S. (2009). Cluster-based under-sampling approaches for imbalanced data distributions. *Expert Systems with Applications*, 36(3), 5718-5727.
47. 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.
48. 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.
49. Zhu, N. (2011). Household consumption and personal bankruptcy. *The Journal of Legal Studies*, 40(1), 1-37.