POLITECHNIKA ŚLĄSKA W GLIWICACH
WYDZIAŁ INŻYNIERII BIOMEDYCZNEJ

Metody komputerowego wspomagania diagnostyki osób z zaburzeniami odżywiania wykorzystujące analizę potencjalnych obszarów trudności

— ROZPRAWA DOKTORSKA—

AUTOR
mgr inż. Agnieszka Różańska

PROMOTOR
Prof. dr hab. inż. Dominik Spinczyk

Zabrze 2026

Podziękowania

Składam serdeczne podziękowania Prof. dr hab. inż. Dominikowi Spinczykowi za podjęcie się opieki naukowej nad niniejszą pracą, cenne uwagi merytoryczne oraz wsparcie na każdym etapie przewodu doktorskiego.

Dziękuję moim Rodzicom oraz Narzeczonemu za wsparcie na każdym etapie powstawania tej pracy.

Spis treści

Streszczenie 1

Abstract 3

1. Wstęp 5
1.1 Definicja zaburzeń odżywiania 6
1.1.1 Historia i rozwój pojęcia zaburzeń odżywiania oraz anoreksji . 7
1.1.2 Definicja, klasyfikacja i ogólna charakterystyka zaburzeń odżywiania 8
1.1.3 Epidemiologia zaburzeń odżywiania 8
1.1.4 Anoreksja - kryteria diagnostyczne i leczenie 10
1.2 Wprowadzenie do eksploracji tekstów 11
1.3 Cel i zakres badań własnych 12
1.4 Układ pracy 14

2. Przegląd stanu wiedzy 17
2.1 Znaczenie analizowanych aspektów funkcjonowania psychicznego i społecznego 17
2.2 Proces analizy danych w eksploracji tekstu 20
2.2.1 Określenie celu, zakresu i kosztu analizy 21
2.2.2 Budowa i przekształcenie korpusu 21
2.2.3 Reprezentacja dokumentów tekstowych 22
2.2.4 Wybór metody analizy i przetwarzania danych 25
2.3 Zastosowanie algorytmów uczenia maszynowego 32
2.4 Metody wykorzystywane do analizy wypowiedzi pisemnych 37

3. Materiał badawczy i metodyka badań 41
3.1 Materiał badawczy 42
3.1.1 Główny zbiór danych 42
3.1.2 Dodatkowe zbiory danych 44
3.2 Metody badań 45
3.2.1 Etap I - Eksploracja tekstu - wykrycie analizowanych obszarów trudności 47
3.2.2 Etap II - Analiza statystyczna 56
3.2.3 Etap III - Wykorzystanie algorytmów uczenia maszynowego . . 57

4. Rezultaty 69
4.1 Detekcja obszarów trudności w wypowiedziach osób cierpiących na anoreksję 69
4.2 Analiza porównawcza wartości przynależności notatek do obszarów trudności u osób chorych na anoreksję i zdrowych 94
4.3 Przegląd rezultatów użytych metod uczenia maszynowego 103
4.3.1 Modelowanie szans wystąpienia anoreksji 103
4.3.2 Analiza struktury danych za pomocą drzew klasyfikacyjnych . 107
4.3.3 Wykorzystanie algorytmu lasu losowego do klasyfikacji notatek do klas zdrowy/chory 118
4.3.4 Podsumowanie dotychczasowych wyników 120
4.3.5 Wykorzystanie algorytmu sieci neuronowej do klasyfikacji notatek do klas zdrowy/chory 121
4.3.6 Kompleksowa analiza porównawcza modeli predykcyjnych . . . 127
4.4 Zastosowanie metody wykrywania obszarów trudności w innych dziedzinach - wyniki dla otyłości, nadwagi i nowotworów głowy i szyi . . . 130

5. Podsumowanie i dyskusja 133

Bibliografia 156

A. Dodatek - lista publikacji współautorskich 157

Spis rysunków

2.1 Etapy eksploracji tekstu (grafika własna). 21

2.2 Przykład drzewa decyzyjnego (grafika własna). 29

2.3 Architektura wielowarstwowego perceptronu MLP, gdzie $Z_1, Z_2 ... Z_n$ to zmienne wejściowe, cechy (grafika własna) 31

3.1 Schemat metodyki badawczej (grafika własna). 46

3.2 Uproszczony schemat zastosowanych operacji (grafika własna). 53

4.1 Graficzna prezentacja wyników dla obszaru „Obraz ciała" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 73

4.2 Graficzna prezentacja wyników dla obszaru „Emocje" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 78

4.3 Graficzna prezentacja wyników dla obszaru „Samoocena" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 81

4.4 Graficzna prezentacja wyników dla obszaru „Funkcjonowanie ciała" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 83

4.5 Graficzna prezentacja wyników dla obszaru „Autoagresja" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 85

4.6 Graficzna prezentacja wyników dla obszaru „Ból" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). . 88

4.7 Graficzna prezentacja wyników dla obszaru „Akceptacja otoczenia" dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c). 90

4.8 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Obraz ciała w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 95

4.9 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Obraz ciała w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 95

4.10 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Emocje w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 96

4.11 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Emocje w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 96

4.12 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Samoocena w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 97

4.13 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Samoocena w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 98

4.14 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Funkcjonowanie ciała w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 98

4.15 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Funkcjonowanie ciała w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 99

4.16 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Autoagresja" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 100

4.17 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Ból" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 100

4.18 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Akceptacja otoczenia w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 101
4.19 Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Akceptacja otoczenia w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup. 101
4.20 Wykres leśny uzyskany dla regresji logistycznej przedstawiający iloraz szans dla wybranych predyktorów 107
4.21 Wykres ważności zmiennych 108
4.22 Wygenerowany optymalny model drzewa decyzyjnego 110
4.23 Wykres kafelkowy przedstawiający klastry wraz z regułami decyzyjnymi (powierzchnia kafelka jest proporcjonalna do liczby obserwacji) 113
4.24 Wykres radarowy przedstawiający mediany wartości analizowanych zmiennych dotyczących obszarów trudności w grupie osób chorych (Anoreksja=1) i zdrowych (Anoreksja=0) oraz w wyodrębnionych klastrach (ID=5 i ID=7) 115
4.25 Wykres krzywych ROC dla pięciu wybranych modeli wygenerowane dla zbioru testowego 126
4.26 Porównanie krzywych ROC dla czterech analizowanych klasyfikatorów 127

Spis tabel

2.1 Przebieg tworzenia macierzy TF. 23

3.1 Wybrane notatki 43
3.2 Charakterystyka antropometryczna badanych grup 44
3.3 Przykładowe wypowiedzi pisemne osób, u których zdiagnozowano raka górnego odcinka przewodu pokarmowego lub głowy i szyi 44
3.4 Przykładowe wypowiedzi pisemne osób z nadwagą lub otyłością przed i po udziale w programie dietetycznym. 45
3.5 Przykłady notatek oryginalnych i notatek po przeprowadzonych operacjach. 47
3.6 Zestawienie liczby słów dla każdego z słowników dla poszczególnych tematów (obszarów trudności). 48
3.7 Przykładowe terminy 49
3.8 Zestawienie wszystkich zmiennych wraz z przypisanymi im rolami i skalami. 57
3.9 Macierz błędów 62

4.1 Zbiorcze wyniki dla wszystkich obszarów trudności. 93
4.2 Statystyki opisowe i wyniki testu U Manna-Whitneya dla stopnia przynależności notatek do obszarów trudności 102
4.3 Macierz korelacji Spearmana dla badanych zmiennych ($N = 201$). . . . 104
4.4 Ocena parametrów modelu regresji logistycznej dla zmiennej zależnej: czy osoba jest chora na anoreksję 106
4.5 Kombinacje parametrów dla wszystkich wygenerowanych modeli drzew 109
4.6 Reguły Decyzyjne - Profil notatki osoby chorej (Wynik = 1) 112
4.7 Macierz pomyłek wyrażona w procentach. 117
4.8 Obliczone pozostałe miary oceny modelu dla wybranego drzewa decyzyjnego - część 1. 117
4.9 Obliczone pozostałe miary oceny modelu dla wybranego drzewa decyzyjnego - część 2. 117
4.10 Wartości przyjętych parametrów dla modelu lasu losowego 118
4.11 Macierz pomyłek wyrażona w procentach. 120
4.12 Obliczone pozostałe miary oceny modelu dla wygenerowanego modelu lasu losowego - część 1. 120
4.13 Obliczone pozostałe miary oceny modelu dla wygenerowanego modelu lasu losowego - część 2. 120
4.14 Podsumowanie wybranych sieci wraz z informacjami o strukturze warstw 122

4.15 Macierz pomyłek dla analizowanych klasyfikatorów wyrażona w procentach. 123
4.16 Miary oceny jakości klasyfikacji analizowanych sieci. 125
4.17 Wartość pola pod krzywą ROC (AUC) dla zbioru testowego dla wybranych pięciu analizowanych sieci. 126
4.18 Zbiorcze porównanie zdolności dyskryminacyjnej badanych klasyfikatorów wraz z 95% przedziałami ufności 128
4.19 Wyniki testu DeLonga dla prób zależnych oceniającego istotność różnic pomiędzy polami pod krzywymi ROC 128
4.20 Wyłonione najważniejsze predyktory przy wykorzystaniu modelu regresji logistycznej 129
4.21 Zmiany w negatywnym i pozytywnym obrazie ciała, emocjach oraz samoocenie po udziale w programie dietetycznym wśród uczestników z nadwagą i otyłością (wartości procentowe). 131

Spis skrótów i oznaczeń

AANN	Autoasocjacyjna sieć neuronowa (ang.: *Autoassociative Neural Network*)
ANN	Sztuczne sieci neuronowe (ang.: *Artificial Neural Networks*)
ACC	Skuteczność / Dokładność (ang.: Accuracy)
AIC	Kryterium Informacyjne Akaikego (ang.: Akaike Information Criterion)
AN	Anoreksja, jadłowstręt psychiczny (łac.: Anorexia Nervosa, ang. Anorexia)
ARFID	Zaburzenie polegające na unikaniu lub ograniczaniu przyjmowania pokarmów (ang.: Avoidant/Restrictive Food Intake Disorder)
AUC	Wartość pola pod krzywą ROC (ang.: Area Under the Curve)
B	Współczynnik regresji
BED	Zaburzenie z napadami objadania się (ang.: Binge Eating Disorder)
BERTopic	Model do modelowania tematów w tekście oparty na pakiecie BERT
BM25	Jeden z rodzajów reprezentacji wektorowej
BMI	Wskaźnik masy ciała (ang.: Body Mass Index)
C4.5	Algorytm indukcji drzew decyzyjnych C4.5
CBT	Terapia poznawczo-behawioralna (ang.: Cognitive Behavioral Therapy)
CI	Przedział ufności (ang.: Confidence Interval)
CNN	Splotowe sieci neuronowe (ang.: Convolutional Neural Networks)
CRT	Drzewa klasyfikacyjne i regresyjne (ang.: Classification and Regression Trees)
DNN	Głęboka sieć neuronowa (ang.: Deep Neural Network)
DSM-5	System klasyfikacji zaburzeń psychicznych Amerykańskiego Towarzystwa Psychiatrycznego (ang.: Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition)
ED	Zaburzenia odżywiania (ang.: Eating Disorders)
EDBase	Leksykon terminów związanych ogólnie z tematem zaburzeń odżywiania (ang.: Eating Disorders Databases)

EKG	Elektrokardiogram
ElasticNet	Metoda regularyzacji łącząca kary L_1 (Lasso) oraz L_2 (Ridge)
EMLP	Rozszerzony wielowarstwowy perceptron (ang.: Enhanced Multilayer Perceptron)
EPV	Liczba zdarzeń przypadających na jedną zmienną objaśniającą (ang.: Events Per Variable)
ErrorRate	Współczynnik błędnych klasyfikacji (ang.: Error Rate lub Misclassification Rate)
F	Miara F1 (ang.: F1-score / F-measure)
F_N	Miara F negatywna
F_P	Miara F pozytywna
FBT	Terapia rodzinna (ang.: Family-Based Therapy)
FDR	Współczynnik fałszywych odkryć (ang.: False Discovery Rate)
FN	Liczba wyników fałszywie ujemnych (ang.: False Negatives)
FNR	Współczynnik fałszywie negatywnych wyników (ang.: False Negative Rate)
FOR	Współczynnik fałszywych pominięć (ang.: False Omission Rate)
FP	Liczba wyników fałszywie dodatnich (ang.: False Positives)
FPR	Współczynnik fałszywie pozytywnych wyników (ang.: False Positive Rate)
HerBERT	Przykład modelu językowego opartego na transformatorach
ICD-11	Międzynarodowa Klasyfikacja Chorób i Problemów Zdrowotnych (ang.: International Classification of Diseases, 11th Revision)
ID3	Algorytm indukcji drzew decyzyjnych (ang.: Iterative Dichotomiser 3)
IDF	Odwrotna częstość występowania terminu w dokumentach (ang.: Inverse Document Frequency)
kNN	Algorytm k najbliższych sąsiadów (ang.: k Nearest Neighbors)
KDD	Proces odkrywania wiedzy w bazach danych (ang.: Knowledge Discovery in Databases)
***L*1**	Kara regularyzacyjna typu Lasso
***L*2**	Kara regularyzacyjna typu Ridge
LASSO	Metoda regularyzacji i selekcji cech (ang.: Least Absolute Shrinkage and Selection Operator)
LDA	Ukryta alokacja Dirichleta (ang.: Latent Dirichlet Allocation)

LIWC	Słownik służący do wykrywania emocji i sentymentu stosowany w Text Miningu (ang.: Linguistic Inquiry and Word Count)
LLM	Duży model językowy (ang.: Large Language Model)
LSA	Ukryta analiza semantyczna (ang.: Latent Semantic Analysis)
M	Średnia arytmetyczna (ang.: Mean)
MANTRA	Jeden z modeli terapeutycznych dla pacjentów z anoreksją
MCC	Współczynnik korelacji Matthewsa (ang.: Matthews Correlation Coefficient)
Me	Mediana, wartość środkowa (ang.: Median)
MLP	Wielowarstwowy perceptron (ang.: Multilayer Perceptron)
MR T2	Obrazowanie T2-zależne w rezonansie magnetycznym
MRI	Obrazowanie rezonansu magnetycznego (ang.: Magnetic Resonance Imaging)
NAWL	Standaryzowana polska baza słów określająca ich ładunek emocjonalny (Nencki Affective Word List)
NLP	Przetwarzanie języka naturalnego (ang.: Natural Language Processing)
NPV	Wartość predykcyjna ujemna (ang.: Negative Predictive Value)
OOB	Mechanizm estymacji błędu oparty na próbach pozawęzłowych (ang.: Out-of-Bag)
OR	Iloraz szans (ang.: Odds Ratio)
p	Poziom istotności statystycznej (ang.: p-value)
PPV	Precyzja, wartość predykcyjna dodatnia (ang.: Positive Predictive Value)
RBF	Sieć / Funkcja z Radialnymi Funkcjami Bazowymi (ang.: Radial Basis Function)
RNN	Rekurencyjne sieci neuronowe (ang.: Recurrent Neural Networks)
ROC	Krzywa charakterystyki (ang.: Receiver Operating Characteristic)
SCOFF	Kwestionariusz przesiewowy zaburzeń odżywiania (ang.: Sick Control One stone Fat Food)
SD	Odchylenie standardowe (ang.: Standard Deviation)
SE	Błąd standardowy estymacji (ang.: Standard Error)
SentiWordNet	Słownik służący do wykrywania emocji i sentymentu stosowany w Text Miningu
SMR	Standaryzowany wskaźnik śmiertelności (ang.: Standardized Mortality Ratio)

SOS	Suma kwadratów błędów (ang.: Sum of Squares)
SVD	Rozkład według wartości osobliwych (ang.: Singular Value Decomposition)
SVM	Maszyny wektorów nośnych (ang.: Support Vector Machines)
TF	Częstość występowania terminu w dokumencie (ang.: Term Frequency)
TF-IDF	Ważona reprezentacja częstości terminu w dokumencie i w korpusie
TM	Analiza i eksploracja tekstu (ang.: Text Mining)
TN	Liczba wyników prawdziwie ujemnych (ang.: True Negatives)
TNR	Swoistość (ang.: True Negative Rate)
TP	Liczba wyników prawdziwie dodatnich (ang.: True Positives)
TPR	Czułość (ang.: True Positive Rate)
$\boldsymbol{U}$	Wartość statystyki testu U Manna-Whitneya
VIF	Współczynnik współliniowości (ang.: Variance Inflation Factor)
$\boldsymbol{W}$	Statystyka testu Walda
WHO	Światowa Organizacja Zdrowia (ang.: World Health Organization)
Youden's J	Indeks Youdena (ang.: Youden's J statistic)
$\boldsymbol{Z}$	Skorygowana wartość statystyki standaryzowanej (dla testów nieparametrycznych)

Streszczenie

Metody eksploracji tekstu (text mining) oraz przetwarzanie języka naturalnego (NLP) stwarzają nowe możliwości obiektywizacji analizy danych narracyjnych w psychologii i psychiatrii. Szczególnym wyzwaniem analitycznym są zaburzenia odżywiania w tym anoreksja, charakteryzująca się zniekształconym obrazem postrzegania ciała i destrukcyjnymi zachowaniami zagrażającymi życiu.

W rozprawie doktorskiej postawiono i pozytywnie zweryfikowano tezę: „*Metody eksploracji danych tekstowych łączące polskojęzyczne słowniki dziedzinowe z procedurą ukrytej analizy semantycznej (LSA) opartej na dekompozycji według wartości osobliwych (SVD) pozwalają na automatyczne rozpoznawanie obecności i wydźwięku wybranych tematów psychologicznych w wypowiedziach osób z anoreksją i osób zdrowych. Uzyskane w ten sposób wyniki umożliwiają, przy wykorzystaniu algorytmów uczenia maszynowego, identyfikację istotnych statystycznie predyktorów, wyodrębnienie interpretowalnych reguł decyzyjnych oraz klasyfikację i odróżnienie wypowiedzi osób zmagających się z anoreksją od grupy osób zdrowych.*" Głównym celem była analiza pisemnych wypowiedzi osób chorych na anoreksję oraz zdrowych w celu identyfikacji i oceny nasilenia siedmiu tematów, które nazwano dalej obszarami trudności: obrazu ciała, emocji, samooceny, autoagresji, funkcjonowania ciała, akceptacji otoczenia oraz bólu. Cel ten osiągnięto łącząc metody eksploracji tekstu z algorytmami uczenia maszynowego. Celem utylitarnym było opracowanie autorskiej koncepcji psychologicznego narzędzia wspomagającego proces diagnostyczny, natomiast cel dydaktyczny polegał na upowszechnieniu wiedzy na temat kluczowych obszarów trudności (tematów) przejawiających się w wypowiedziach pisemnych osób chorych na anoreksję.

Materiał badawczy stanowiło 201 pisemnych wypowiedzi o obrazie ciała (115 od osób chorych na anoreksję i 86 od osób zdrowych), pozyskanych we współpracy z Samodzielnym Publicznym Szpitalem Klinicznym Nr 1 Śląskiego Uniwersytetu Medycznego. Metodyka obejmowała trzy etapy. Pierwszy dotyczył eksploracji tekstu i wykorzystania podejścia słownikowego w celu wykrycia i określenia stopnia poruszenia siedmiu analizowanych obszarów trudności. Dane poddano preprocesingowi (czyszczenie tekstu, lematyzacja, zastosowanie „stop listy"). Opracowano autorskie słowniki dziedzinowe z uwzględnieniem polaryzacji wykorzystując bazę NAWL i walidację przez zespół psychologów pod kierownictwem szefa Centralnej Pracowni Psychologii Klinicznej Samodzielnego Publicznego Szpitala Klinicznego nr 1 SUM. Zastosowano analizę semantyczną LSA (opartą na dekompozycji SVD) oraz miarę podobieństwa kosinusowego do wzbogacenia słowników i kategoryzacji wypowiedzi. Skuteczność metody zweryfikowano poprzez porównanie uzyskanych rezultatów z oceną ekspercką zespołu psychologów. Dodatkowo transferowalność podejścia sprawdzono na próbach pacjentów onkologicznych oraz osób z nadwagą i otyłością. Etap drugi objął analizę statystyczną. Na

podstawie wyników uzyskanych w pierwszym etapie sporządzono histogramy wartości poruszenia danych tematów w notatkach osób chorych i zdrowych. Zbadano różnice między notatkami reprezentującymi te grupy za pomocą testu U Manna-Whitneya z uwzględnieniem poprawki na ciągłość oraz korekty Bonferroniego dla wielokrotnych porównań. Etap trzeci polegał na wykorzystaniu algorytmów uczenia maszynowego w tym: regresji logistycznej, drzew decyzyjnych, lasów losowych oraz sztucznych sieci neuronowych (MLP i RBF).

Zgodność metody słownikowej opartej na LSA/SVD z oceną ekspercką była najwyższa w przypadku autoagresji (99%) oraz bólu (99%). Wysoki poziom zbieżności odnotowano również dla samooceny (86%), emocji (83%) oraz funkcjonowania ciała (83%). Najniższą skuteczność wykazano dla tematów obrazu ciała (75%) i akceptacji otoczenia (69%).W modelu regresji logistycznej istotnymi predyktorami okazały się: samoocena w kontekście negatywnym (B = 3,384; OR = 29,485; p < 0,001), która wiąże się z wysokim współwystępowaniem anoreksji oraz obraz ciała w kontekście pozytywnym (B = -2,13; OR = 0,119; p = 0,001), która wiąże się z niskim współwystępowaniem anoreksji. Analiza reguł decyzyjnych drzewa decyzyjnego pozwoliła zidentyfikować dwa odmienne wzorce (profile) narracyjne w tekstach osób chorych: dominujący profil klasyczny (z przewagą negatywnych wartości w tematach: samooceny, emocji, obrazu ciała oraz akceptacji otoczenia i emocji), spójny z wynikami regresji logistycznej oraz mniejszościowy profil atypowy o przewadze określeń pozytywnych w tematach: emocji, akceptacji otoczenia oraz obrazu ciała. W ujęciu punktowym wartość wskaźnika AUC rosła wraz ze złożonością algorytmów: od 0,745 dla regresji logistycznej, przez drzewo decyzyjne (0,773) i las losowy (0,792), do 0,848 dla sieci neuronowej. Przeprowadzony test DeLonga wykazał jednak brak istotności statystycznej tych różnic (p > 0,05), co wskazuje, że do skutecznego rozróżniania notatek wystarczające są podstawowe zależności liniowe, a potwierdzenie przewagi modeli złożonych wymaga dalszych badań na większej próbie. W notatkach osób z nadwagą i otyłością uchwycono tematy: obrazu ciała, emocji oraz samooceny, mierząc dynamikę ich zmian. W notatkach pacjentów onkologicznych uzyskano wysoką zgodność detekcji z oceną ekspercką w obszarach: akceptacji otoczenia (82%), samooceny (80%) i obrazu ciała (78%).

Uzyskane wyniki potwierdzają postawioną tezę oraz realizację celów pracy. Oryginalność podejścia polega na integracji metod eksploracji tekstu (autorskie słowniki dziedzinowe, LSA, SVD) z algorytmami uczenia maszynowego w analizie tekstów. Kluczowym wkładem było opracowanie polskojęzycznych słowników domenowych obejmujących siedem tematów (m.in. obraz ciała, emocje, samoocenę i autoagresję). Opracowane podejście może wspierać psychologów w codziennej pracy jako element systemów komputerowego wspomagania diagnostyki psychologicznej.

Słowa kluczowe: zaburzenia odżywiania, anoreksja, komputerowe wspomaganie diagnostyki psychologicznej, eksploracja tekstu, przetwarzanie języka naturalnego (NLP), utajona analiza semantyczna (LSA), drzewa decyzyjne, lasy losowe, sieci neuronowe, uczenie maszynowe.

Abstract

Text mining methods and natural language processing (NLP) open up new possibilities for the objective analysis of narrative data in psychology and psychiatry. Eating disorders, including anorexia, which are characterised by a distorted perception of one's own body and destructive, life-threatening behaviours, present a particular analytical challenge.

The dssertation put forward and successfully verified the following thesis: " *Methods of text data mining combining Polish-language subject-specific dictionaries with the Latent Semantic Analysis (LSA) procedure, based on Singular Value Decomposition (SVD), enable the automatic identification of the presence and connotations of selected psychological themes in the utterances of people with anorexia and healthy individuals. The results obtained in this way make it possible, using machine learning algorithms, to identify statistically significant predictors, derive interpretable decision rules, and classify and distinguish the statements of people struggling with anorexia from those of a group of healthy individuals.*" The main objective was to analyse written statements from people with anorexia and healthy individuals in order to identify and assess the severity of seven themes, hereinafter referred to as areas of difficulty: body image, emotions, self-esteem, autoaggression, bodily functioning, acceptance of one's surroundings, and pain. This objective was achieved by combining text mining with machine learning algorithms. The practical aim was to develop an original concept for a psychological tool to support the diagnostic process, whilst the educational aim was to disseminate knowledge about the key areas of difficulty (themes) evident in the written statements of people with anorexia.

The research data consisted of 201 written statements on body image (115 from people with anorexia and 86 from healthy individuals), obtained in cooperation with the Independent Public Clinical Hospital No. 1 of the Medical University of Silesia. The methodology comprised three stages. The first stage involved text exploration and the use of a lexical approach to identify and determine the extent to which the seven areas of difficulty under analysis were addressed. The data underwent pre-processing (text cleaning, lemmatisation, application of a 'stop list'). Proprietary domain-specific dictionaries were developed, taking polarisation into account, using the NAWL corpus and validated by a team of psychologists led by the head of the Central Clinical Psychology Unit at the 1st Clinical Hospital of the Medical University of Silesia. LSA semantic analysis (based on SVD decomposition) and the cosine similarity measure were applied to enrich the dictionaries and categorise utterances. The effectiveness of the method was verified by comparing the results obtained with the expert assessment of the team of psychologists. In addition, the transferability of the approach was tested on samples of cancer patients and people who were overweight or obese. The second

stage involved statistical analysis. Based on the results obtained in the first stage, histograms were plotted showing the frequency of specific themes mentioned in the notes of sick and healthy individuals. Differences between the scores representing these groups were tested using the Mann-Whitney U test, with a continuity correction and a Bonferroni correction for multiple comparisons.The third stage involved the use of machine learning algorithms, including logistic regression, decision trees, random forests and artificial neural networks (MLP and RBF).

The agreement between the LSA/SVD-based dictionary method and expert assessment was highest for autoaggression (99%) and pain (99%). A high level of agreement was also observed for self-esteem (86%), emotions (83%), and bodily functioning (83%). The lowest accuracy was observed for the themes of body image (75%) and acceptance of one's surroundings (69%). In the logistic regression model, the following proved to be significant predictors: self-esteem in a negative context (B = 3.384; OR = 29.485; $p < 0.001$), which is associated with a high prevalence of anorexia, and body image in a positive context (B = -2.13; OR = 0.119; p = 0.001), which is associated with a low prevalence of anorexia. An analysis of the decision rules of the decision tree enabled the identification of two distinct narrative patterns (profiles) in the texts of sick people: a dominant classical profile (with a predominance of negative values in the themes of self-esteem, emotions, body image, and acceptance of one's surroundings and emotions), consistent with the results of logistic regression, and a minority atypical profile characterised by a predominance of positive terms in the areas of emotions, acceptance of one's surroundings and one's own body. In terms of scores, the AUC value increased with the complexity of the algorithms: from 0.745 for logistic regression, through the decision tree (0.773) and random forest (0.792), to 0.848 for the neural network. However, the DeLong test revealed that these differences were not statistically significant ($p > 0.05$), suggesting that basic linear relationships are sufficient for effectively distinguishing between notes, whilst confirmation of the superiority of complex models requires further research on a larger sample. The notes of overweight and obese individuals captured the themes of body image, emotions and self-esteem, measuring the dynamics of their changes. In the notes of cancer patients, a high degree of agreement was achieved between the model's detection and expert assessment in the areas of acceptance of one's surroundings (82%), self-esteem (80%) and body image (78%).

The results obtained confirm the research hypothesis and demonstrate that the objectives of the study have been achieved. The originality of the approach lies in the integration of text mining methods (customised domain-specific dictionaries, LSA, SVD) with machine learning algorithms in text analysis. A key contribution was the development of Polish-language domain-specific dictionaries covering seven topics (including body image, emotions, self-esteem and autoaggression). The approach developed can support psychologists in their day-to-day work as part of computer-assisted psychological diagnosis systems.

Keywords: eating disorders, anorexia, computer-aided psychological diagnostics, text mining, natural language processing (NLP), latent semantic analysis (LSA), decision trees, random forests, neural networks, machine learning.

1. Wstęp

Ciągle obserwowany jest trend, który polega na gwałtownym wzroście wytwarzanych i przechowywanych danych. We współczesnym świecie popularne stało się pojęcie „big data", które według definicji oznacza dużą ilość danych o dużej objętości, różnorodności, złożoności i formie. Jak wskazują Gandomi i Haider [1], szacuje się, że nawet do 95% zbiorów danych ma charakter niestrukturyzowany, co oznacza, że nie posiadają z góry określonej formy umożliwiającej łatwą analizę ilościową. Przykładami niestrukturyzowanego tekstu są wszelkiego rodzaju notatki, wpisy, zapiski, artykuły, raporty, posty itd. Pomimo braku formalnej struktury, dane te stanowią bogate źródło wiedzy. Efektywne przetwarzanie i analizowanie tych danych stanowi wyzwanie dnia codziennego. Skuteczne i szybkie znajdowanie właściwych informacji z danych w tej formie ma kluczowe znaczenie dla wspierania najlepszych decyzji. Ciągle poszukuje się nowych możliwości przetwarzania i analizowania tych danych, zarówno na niższym, jak i wyższym poziomie. Analiza na niższym poziomie ma charakter bardziej techniczny i językowy, czyli koncentruje się m.in. na wstępnym przetwarzaniu pojedynczych rekordów danych. Zatem związana jest z oczyszczeniem i opisaniem struktury językowej, bez interpretacji znaczenia. Analiza na wyższym poziomie koncentruje się na warstwie semantycznej, czyli polega na wykrywaniu ogólnych trendów, wzorców oraz ukrytych zależności. Na tym poziomie tekst nie jest już tylko zbiorem słów, ale nośnikiem znaczeń, relacji i informacji. W przypadku występowania rozległych i ogromnych zasobów danych tekstowych coraz większego znaczenia nabierają metody umożliwiające automatyczne ich przetwarzanie oraz interpretację. Są nimi metody automatycznej analizy języka naturalnego, w tym eksploracja tekstu. Jest to zbiór metod służących do automatycznej analizy, przetwarzania i wydobywania informacji z danych tekstowych. Obecnie coraz częściej wykracza się poza klasyczne techniki eksploracji tekstu poprzez łączenie ich z metodami uczenia maszynowego. Po odpowiednim przekształceniu tekstu do reprezentacji numerycznej, takie dane mogą zostać wykorzystane w szerokiej gamie modeli obliczeniowych. Połączenie to umożliwia jednocześnie przetworzenie, analizę i wydobycie z tekstu istotnych informacji, a następnie utworzenie modeli predykcyjnych, klasyfikacyjnych i eksploracyjnych. Połączenie metod eksploracji tekstu z algorytmami uczenia maszynowego otwiera możliwość efektywnego przetwarzania i modelowania danych jakościowych na skalę wcześniej niedostępną. Dzięki temu zwiększa się potencjał tworzenia narzędzi, które usprawniają analizę dokumentacji i przyspieszają pracę. Wśród możliwych do zastosowania algorytmów znajdują się drzewa decyzyjne, lasy losowe i sieci neuronowe.

Współczesna medycyna generuje olbrzymie zbiory danych klinicznych, diagnostycznych i tekstowych, które stanowią cenne, choć trudne do przetworzenia źródło wiedzy. Zatem i tutaj występuje wyzwanie efektywnej analizy i interpretacji ogromnych ilości danych pochodzących z różnorodnych źródeł takich jak: wywiady lekarskie, kwestio-

nariusze, obserwacje pacjentów, opisy i wyniki badań oraz dokumentacja kliniczna. Właściwe wykorzystanie metod analizy danych, w tym eksploracji tekstu, stwarza liczne możliwości pogłębienia wiedzy o stanach zdrowia i choroby. Narzędzia analityczne mogą przyczynić się do podniesienia jakości świadczonych usług medycznych, usprawnienia pracy personelu oraz rozwoju działalności naukowo-badawczej [2].

Zaburzenia odżywiania stanowią szeroką grupę zaburzeń psychicznych. Jednym z najcięższych z nich pod względem przebiegu choroby jest anoreksja, która cechuje się szczególnie wysokim wskaźnikiem śmiertelności na tle innych zaburzeń psychicznych [3, 4]. Szczególnie niepokojące jest to, że rośnie odsetek młodych ludzi zmagających się z zaburzeniami odżywiania. Zatem można stwierdzić, że stanowią poważne choroby współczesnego świata. Polski system ochrony zdrowia psychiatrycznego od lat zmaga się z przeciążeniem wynikającym z niedoboru specjalistów i rosnącej liczby pacjentów. Psycholodzy i lekarze mają ograniczony czas na analizę dokumentacji oraz czas, który mogą poświęcić pacjentowi. W takich realiach efektywne wykorzystanie danych medycznych staje się nie tylko potrzebą, ale koniecznością. Dziedziny psychologii i psychiatrii szczególnie intensywnie opierają się na narracyjnym opisie doświadczeń pacjenta. Z tego powodu eksploracja tekstu wydaje się być obiecującym narzędziem umożliwiającym obiektywną analizę takich danych. Uważa się, że automatyczne metody analizy tekstu mogą dostarczyć cennych informacji.

W niniejszej pracy podjęto próbę analizy notatek osób zdrowych oraz cierpiących na zaburzenia odżywiania, w tym na anoreksję, aby sprawdzić potencjał zastosowania technik przetwarzania języka naturalnego (ang.: Natural Language Processing, NLP) i eksploracji tekstu (ang.: text mining, TM) w celu wydobycia wiedzy z nieustrukturyzowanych treści medycznych i psychologicznych. Wytypowano siedem obszarów trudności, które z punktu widzenia diagnostyki i leczenia są ważne dla osób cierpiących na zaburzenia odżywiania, w tym anoreksję. Uzyskane informacje, dzięki zastosowaniu metod eksploracji tekstu posłużyły jako dane wejściowe w algorytmach uczenia maszynowego. Wykorzystano model regresji logistycznej w celu zamodelowania szans współwystępowania anoreksji, identyfikując statystycznie istotne predyktory. W celu dalszej eksploracji danych zastosowano algorytm drzewa decyzyjnego, który pozwolił na wyznaczenie kluczowych reguł decyzyjnych, najważniejszych klastrów oraz profili notatek osób cierpiących na anoreksję. Las losowy i sieci neuronowe posłużyły w zadaniu klasyfikacyjnym, które polegało na odróżnieniu notatek osób chorych od zdrowych.

1.1 Definicja zaburzeń odżywiania

Zaburzenia odżywiania (ang.: eating disorder, ED) zaliczamy do poważnych zaburzeń psychicznych. Wśród cech, które charakteryzują ED można wyróżnić trzy najważniejsze: trwałe nieprawidłowości w zachowaniach związanych z przyjmowaniem pokarmu, zaburzenia postrzegania obrazu ciała oraz funkcjonowania psychicznego. Grupa tych chorób jest bardzo zróżnicowana, a do najczęstszych należą anoreksja (jadłowstręt psychiczny, łac.: Anorexia Nervosa, ang. Anorexia, AN) oraz bulimia [5]. W poniższych podrozdziałach omówiono zaburzenia odżywiania, a zwłaszcza jadłowstręt psychiczny.

1.1.1 Historia i rozwój pojęcia zaburzeń odżywiania oraz anoreksji

Zaburzenia odżywiania, które obejmują nieprawidłowe relacje z jedzeniem oraz zaburzone nawyki żywieniowe nie są zjawiskiem nowym. Zachowania takie były obserwowane w różnych kulturach i epokach. Towarzyszą ludziom już od wielu stuleci. Jednak w zależności od epoki przyjmowały różne formy i interpretacje. Dobrowolne głodzenie się lub skrajne posty były obserwowane już w średniowieczu. Zachowania te miały podłoże religijne lub ascetyczne i interpretowane były jako przejawy świętości tzn. „Anorexia mirabilis". W renesansie odnotowano coraz więcej opisów kobiet, które umyślnie odmawiały pożywienia, wyniszczając swój organizm jako akt pobożności. Potocznie nazywane były „świętymi anorektyczkami" (ang.: „holy anorexics"). Przykładami takich kobiet jest Katarzyna z Sieny (1347-1380) oraz święta Teresa z Ávili, która łączyła post z symboliką mistycznych doznań [6]. Minęło wiele czasu, zanim anoreksję zaczęto postrzegać w medycynie jako zaburzenie psychiczne. Za pierwszy naukowy, medyczny opis klinicznego stanu, który nawiązuje do tego co obecnie określamy jako anoreksję uważa się pracę angielskiego lekarza Richarda Mortona, który w 1689 roku opisał przypadki jadłowstrętu psychicznego w kontekście stanu chorobowego. Opisał przypadek młodej kobiety, która cierpiała na brak apetytu, a w konsekwencji doprowadziło to do osłabienia organizmu i utraty masy ciała. Za pierwszą próbę powiązania zaburzeń odżywiania z funkcjonowaniem układu nerwowego uważa się obserwacje Roberta Whytt'a, który również zwrócił uwagę na inne problemy zdrowotne pojawiające się u osób, które przejawiają zachowania przypominające anoreksję [6]. Za podstawę współczesnego rozumienia anoreksji jako zaburzenia psychicznego, a nie jedynie skutku chorób somatycznych uważa się prace dwóch lekarzy: Ernesta Charles Lasègue i sir Williama Withey'a Gulla. Pierwszy z nich zwrócił uwagę na psychologiczne aspekty choroby, opisując „odmowę jedzenia, która może trwać nieokreślony czas" oraz podkreślając, że pacjentki często nie odczuwają potrzeby powrotu do zdrowia i są „zadowolone ze swojego stanu". Ostrzegał innych przed lekceważeniem ciągłej odmowy jedzenia jako zwykłego kaprysu. Uważał, że leczenie nie będzie przynosiło efektów, dopóki lekarz nie zrozumie psychologicznych czynników odrzucenia jedzenia przez pacjentów [6]. Drugi ze wspomnianych lekarzy w 1873 roku po raz pierwszy szczegółowo opisał i użył nazwy „anorexia nervosa". Podał charakterystyczne cechy choroby takie jak: skrajne wyniszczenie, brak miesiączki itd. W. W. Gul podkreślał, że anoreksja charakteryzuje się nie tylko utratą masy ciała, ale także szeregiem objawów somatycznych i psychicznych. Zwracał uwagę na konieczność odpowiedniego podejścia terapeutycznego. Uważa się, że jego prace o anoreksji stanowią przełom w historii psychiatrii i medycyny [7]. Wraz z upływającym czasem pojawiały się różne teorie dotyczące przyczyn anoreksji. W XX wieku trwały spory, czy jest to choroba o podłożu psychicznym, czy somatycznym. Jean-Martin Charcot używał określenia „anorexia hysterica" i zalecał izolację jako formę leczenia. W drugiej połowie XX wieku Hilde Bruch podkreśliła rolę patologicznego lęku przed otyłością i zaburzenia obrazu własnego ciała [6]. Jak widać minęło wiele lat, przeprowadzono wiele badań i obserwacji zanim to, co współcześnie rozumiemy jako zaburzenia odżywiania lub konkretną chorobę jaką jest anoreksja zaczęto postrzegać jako zaburzenie psychiczne, a nie tylko jako zjawisko religijne lub moralne.

1.1.2 Definicja, klasyfikacja i ogólna charakterystyka zaburzeń odżywiania

Zaburzenia odżywiania stanowią zróżnicowaną grupę chorób psychicznych, które charakteryzują się nieprawidłowymi, a wręcz patologicznymi i utrwalonymi wzorcami zachowań żywieniowych, które prowadzą do znacznych konsekwencji zdrowotnych, psychologicznych i społecznych. Punktem wspólnym jest dysfunkcyjna postawa wobec jedzenia, ciała oraz emocji, która często związana jest z samokontrolą oraz samooceną [8]. Obsesyjna potrzeba utraty masy ciała, duży lęk przed przytyciem oraz nadmierna koncentracja na szczupłej sylwetce są tylko niektórymi zachowaniami towarzyszącymi osobom cierpiącym na różne formy ED. Biorąc pod uwagę klasyfikację DSM-5[1] oraz ICD-11[2] zaburzenia odżywiania są uznawane jako osobna kategoria diagnostyczna. W jej skład wchodzą tradycyjne zaburzenia takie jak anoreksja i bulimia jak i nowsze rozpoznania m.in. zaburzenie z napadami objadania się (ang.: Binge Eating Disorder, BED) lub unikanie przyjmowania pokarmu (ang.: Avoidant/Restrictive Food Intake Disorder, ARFID) [9, 10, 11, 12].

Choć wszystkie te choroby mają pewne wspólne cechy to można wskazać pewne różnice pomiędzy poszczególnymi zaburzeniami. Anoreksja charakteryzuje się ograniczaniem przyjmowania pożywienia, które jest motywowane silnym lękiem przed przytyciem oraz poważnym zniekształceniem obrazu własnego ciała. U osób chorujących na bulimię odnotowuje się okresy objadania się i występowanie zachowań kompensacyjnych, takich jak wywoływanie wymiotów oraz nadużywanie środków przeczyszczających, przy czym masa ciała zwykle pozostaje w normie. W przypadku BED również występują napady objadania się, ale nie obserwuje się zachowań kompensacyjnych. Chorym często towarzyszy poczucie winy i wstydu [13, 14]. ARFID charakteryzuje się unikaniem jedzenia z powodów sensorycznych lub lękowych [12].

Wszystkie te zaburzenia mają charakter biopsychospołeczny. Oznacza to, że postęp tych chorób jest wynikiem wpływu czynników biologicznych, psychologicznych i środowiskowych. Zatem mówiąc inaczej etiologia ED jest wieloczynnikowa. Wśród czynników biologicznych można wyróżnić predyspozycje genetyczne, zaburzenia osobowości (np. cechy obsesyjno-kompulsyjne), neurobiologię, wpływ hormonów czy traumy. Autorzy Jane Morris i Stephen Anderson piszą o wysokiej dziedziczność anoreksji z przedziału 28-74% [15]. Wśród psychologicznych czynników można wymienić zachowania takie jak: perfekcjonizm, niska samoocena, zaburzenia emocjonalne, poznawcze, a także lękowe i depresyjne. Istotny wpływ mają także czynniki społeczne, takie jak: wpływ mediów, presja kulturowa, relacje rodzinne czy wszechobecne promowanie norm dotyczących wyglądu [15, 16, 17, 18]. Współczesne badania wyraźnie podkreślają, że wyżej wymienione czynniki działają synergicznie, a to niestety zwiększa ryzyko rozwoju ED.

1.1.3 Epidemiologia zaburzeń odżywiania

Zaburzenia odżywiania są uznawane za poważne zagrożenie dla zdrowia publicznego. Choroby te istotnie wpływają na zdrowie fizyczne jak i psychiczne. Występują

[1] System klasyfikacji zaburzeń psychicznych autorstwa Amerykańskiego Towarzystwa Psychiatrycznego.

[2] Wersja globalnego standardu kodowania chorób i stanów zdrowotnych autorstwa Światowej Organizacji Zdrowia (WHO).

na całym świecie, jednak największe natężenie przypadków odnotowuje się w krajach wysoko rozwiniętych, zwłaszcza w kulturze zachodniej. W latach 2000 - 2018 odnotowano, że rozpowszechnienie ED na świecie wzrosło z 3,5% do 7,8% [19], co stanowi istotny sygnał alarmowy dla zdrowia publicznego. Jest to dynamiczny wzrost, który nie tylko podkreśla skalę problemu, ale również wskazuje na konieczność wzmożonych działań profilaktycznych, diagnostycznych i terapeutycznych.
Mimo że schorzenia te mogą rozwinąć się w każdym wieku, to według badań najczęściej rozpoczynają się w wieku nastoletnim lub wczesnej dorosłości [20, 21]. Według raportu Deloitte Access Economics z roku 2020, szacuje się, że 8,6% kobiet i 4,07% mężczyzn w Stanach Zjednoczonych doświadcza zaburzeń odżywiania w ciągu życia [22]. Według danych 22% dzieci i młodzieży na całym świecie wykazało symptomy zaburzeń odżywiania [23]. Kobiety chorują częściej, choć zauważalne jest stopniowe zwiększanie się udziału mężczyzn wśród osób zmagających się z ED, a tym samym zróżnicowanie ze względu na płeć stopniowo zmniejsza się [24, 25]. Według badań globalny poziom rozpowszechnienia ED u kobiet jest z przedziału 2,58-8,40%, podczas gdy u mężczyzn jest on z zakresu 0,74-2,20% [26]. Rozpowszechnienie występowania anoreksji w populacji kobiet w krajach zachodnich to ok. 1%, a u mężczyzn 0,5% [15]. Według [27] na przestrzeni ostatnich trzydziestu lat odsetek występowania anoreksji i bulimii wzrósł w 8 z 10 krajów Europy Wschodniej. Rozpowszechnienie BED w populacji ogólnej wynosi od 2 do 5%. Wskaźnik ten rośnie aż do 30% w grupie pacjentów z nadwagą lub otyłością. BED znacznie częściej dotyczy kobiet [8]. Według badań okazuje się, że ARFID występuje równie często jak inne zaburzenia odżywiania. Jego udział wynosi 12,0% w populacji klinicznej i 2,84% w pozaklinicznej. Wykazano, że jest to zaburzenie niezależne od wieku, a w odróżnieniu od innych zaburzeń odżywiania, większość badań wskazuje na nieznaczną przewagę chłopców/mężczyzn [28]. W minionych latach odnotowuje się wzrost zachorowań na ED wśród chłopców, młodych mężczyzn oraz osób starszych obu płci [29]. Wskazuje to na rozszerzanie się grup ryzyka. Rozpatrując wszystkie zaburzenia odżywiania, anoreksja ma najwyższy wskaźnik śmiertelności (ang.: standardized mortality ratio, SMR), który jest równy 5 [30]. Oznacza to, że osoby zmagające się z tą chorobą umierają pięciokrotnie częściej niż ich rówieśnicy w populacji ogólnej, co tylko podkreśla wyjątkowo wysokie ryzyko zgonu związane z tym zaburzeniem odżywiania. Analiza przeprowadzona przez Arcelusa i wsp. wskazuje, że odsetek zgonów na AN jest znacznie wyższy niż w przypadku innych zaburzeń psychicznych takich jak np. schizofrenia czy choroba afektywna dwubiegunowa [3]. Warto podkreślić, że śmiertelność z powodu anoreksji jest bardzo wysoka. U osób z wieloletnim przebiegiem anoreksji, trwającym około dwóch dekad, odsetek zgonów może sięgać około 20% [31].
Rozpowszechnienie jadłowstrętu psychicznego wśród polskich uczennic, które nie ukończyły 18 lat, szacuje się na poziomie 0,8-1,8% [5]. U 6,5% przebadanych kobiet z regionu kujawsko-pomorskiego zaobserwowano postawy i zachowania charakterystyczne dla wczesnych stadiów anoreksji [32]. Bardzo niepokojące wydają się badania przeprowadzone przez Andrzeja Wojtyłę i wsp. na próbie uczniów ze szkół średnich. Analiza wykazała, że 40% respondentów wykazało obawy i strach przed otyłością, 29% uczniów deklarowało chęć redukcji masy ciała, a aż 33% próbowało schudnąć, stosując nawet drastyczne metody, przy czym co dziesiąty uczeń prowokował wymioty [33, 34]. Warto dodać, że pandemia COVID-19 również wpłynęła na rozwój ED. Izolacja społeczna i stres z nią związany przyczyniły się do wzrostu liczby osób chorych na zaburzenia

odżywiania [35].
Obecnie pojawiają się badania, które alarmują o dynamicznym wzroście zachorowań na zaburzenia odżywiania w krajach, w których jak dotąd uważano, że nie występują te choroby, czyli przykładowo w krajach arabskich i zachodniej Azji [36, 37].

Dane epidemiologiczne wskazują, że zaburzenia odżywiania stale są poważnym wyzwaniem dla systemów ochrony zdrowia. Dodatkowo bardzo niepokojące są sygnały o niedoszacowaniach w wykrywaniu osób chorych, a w konsekwencji o braku leczenia części chorych. Morris i Anderson podkreślają, że co druga osoba, która spełnia kryteria, nie korzysta z leczenia [15].

1.1.4 Anoreksja - kryteria diagnostyczne i leczenie

Osoby cierpiące na anoreksję przede wszystkim kojarzą się z bardzo szczupłą, a wręcz wychudzoną sylwetką. Jednakże niekoniecznie taka osoba musi cierpieć na AN. Istnieje wiele innych chorób, których skutkiem jest znaczna utrata masy ciała. Dlatego też, aby poprawnie zdiagnozować jadłowstręt psychiczny należy przeprowadzić szczegółową ocenę kliniczną pacjenta. Zarówno ICD-11 oraz DSM-5 definiują kryteria niezbędne do rozpoznania zaburzenia [30, 31, 38]. Według ICD-11 pierwszym i podstawowym kryterium diagnostycznym jest wyraźnie niska, a tym samym niepoprawna masa ciała biorąc pod uwagę wzrost czy też wiek. Stosowanym wskaźnikiem jest wartość BMI (wskaźnika masy ciała, ang.: Body Mass Index). Wartością graniczną u osób dorosłych jest wartość poniżej 18,5 kg/m^2. U dzieci i młodzieży wartością alarmującą jest wartość BMI poniżej piątego percentyla. Warto zaznaczyć, że również szybka utrata masy ciała może zastąpić kryterium niskiej wagi [30]. DSM-5 w przeciwieństwie do ICD-11 nie określa konkretnej wartości progu BMI. Następną przesłanką jest długotrwałe ograniczanie kalorii w celu utrzymania nienaturalnie niskiej masy ciała. Kolejnym symptomem jest zniekształcone i zaburzone postrzeganie obrazu własnego ciała, któremu często towarzyszą przesadne, obsesyjne i patologiczne myśli i zachowania kompensacyjne. Osoby chore często stosują głodówki, wywołują wymioty, uprawiają wyczerpujące ćwiczenia lub stosują różne środki farmakologiczne w tym: przeczyszczające lub zmniejszające apetyt. Innym kryterium rozpoznania jest silny lęk i strach przed przytyciem.

Leczenie zaburzeń odżywiania, w tym anoreksji stanowi wyzwanie dla systemu opieki zdrowotnej. Wymaga indywidualnie dostosowanego podejścia oraz współpracy wielu specjalistów, a także wsparcia ze strony najbliższego otoczenia pacjenta. Na początku trzeba ocenić stan pacjenta. Mając na uwadze fakt, że osoby cierpiące na AN swoim zachowaniem i podejmowanymi działaniami systematycznie i skutecznie wyniszczają swój organizm, narażając się na poważne, wielonarządowe powikłania np. kardiologiczne lub zagrażające życiu niedożywienie, często pierwszym podejmowanym krokiem jest hospitalizacja, która ma na celu ratowanie życia. Następnie kluczowa jest psychoterapia [39]. Ważne jest również nawiązanie i zbudowanie relacji terapeutycznej już na samym początku procesu leczenia, ponieważ pacjenci z AN często wykazują brak motywacji, ambiwalentną postawę wobec leczenia lub wręcz zaprzeczają istnieniu choroby [38]. Obecnie według badań największą skuteczność ma terapia rodzinna (ang.: Family-Based Treatment, FBT), stosuje się również terapię poznawczo-behawioralną (ang.: cognitive behavioral therapy, CBT). Pomocne w czasie terapii są dzienniczki samoobserwacji, w których zapisywane są myśli i emocje, co jest kluczowym elementem

terapii poznawczo-behawioralnej [5, 39]. Istotnym uzupełnieniem dzienniczków samooceny są wywiady, obejmujące zarówno notatki przygotowywane przez specjalistów jak i zapisy tworzone przez pacjentów czy osoby należące do grup podwyższonego ryzyka. Tego typu materiały stanowią wartościowe źródło informacji, które można poddać analizie z wykorzystaniem metod eksploracji tekstu. Przetwarzanie treści umożliwia identyfikację charakterystycznych słów i fraz mogących świadczyć o tendencjach do zaburzeń odżywiania lub ich występowaniu, np. sygnalizujących obawy przed przyrostem masy ciała czy zniekształcone postrzeganie własnej sylwetki. Włączenie takich technik do badań przesiewowych sprzyja wczesnemu rozpoznaniu ryzyka oraz planowaniu adekwatnych działań terapeutycznych. Nie ulega wątpliwości, że najlepsze efekty uzyskuje się w przypadku wczesnej diagnozy i skutecznej interwencji. Warto zwrócić uwagę, że pomimo postępu, leczenie dorosłych z przewlekłą postacią anoreksji wciąż jest dużym wyzwaniem. Obecnie trwają badania nad poszukiwaniem nowych rozwiązań terapeutycznych [38].

1.2 Wprowadzenie do eksploracji tekstów

Eksploracja danych obejmuje różne ich typy - zarówno strukturalne (np. tabele, wartości liczbowe), jak i niestrukturalne (np. teksty, dokumenty). Z tego powodu w ramach procesu eksploracji wyróżnia się dwie główne specjalizacje: data mining (analizę danych) oraz text mining (analizę, eksplorację tekstu, TM). Oba podejścia stanowią integralne elementy procesu wyszukiwania wiedzy w bazach danych (ang.: Knowledge Discovery in Databases, KDD). Podstawowa różnica między nimi wynika z rodzaju danych, na których operują: data mining koncentruje się na danych ustrukturyzowanych, natomiast text mining na danych nieustrukturyzowanych, wymagających zastosowania metod przetwarzania języka naturalnego (ang.: Natural Language Processing, NLP). Nie ulega wątpliwości, że dane tekstowe, które swoje źródła mają w Internecie, literaturze, wszelkiego rodzaju raportach, czy dokumentacji np. medycznej stanowią znaczącą część generowanych i przechowywanych danych. Dlatego TM jest kluczowym narzędziem w analizie danych.

Historia eksploracji tekstu sięga lat 50. XX wieku. Lata 50. to początek ery komputerów. W tym czasie rozwijały się pierwsze koncepcje automatycznego przetwarzania informacji. Za jeden z pierwszych przełomowych momentów uważa się prace H. P. Luhn'a z 1958 roku. Autor zaproponował automatyczne tworzenie streszczeń poprzez analizę znaczenia wykorzystanych słów (wagi terminów) w tekście źródłowym. Wprowadzenie przez H. P. Luhn'a koncepcji „ważności słów" (ang.: frequency-based weighting) stało się fundamentem dla późniejszych metod oceny ważności użytych terminów (np. TF-IDF) [40]. Od końca lat dziewięćdziesiątych XX wieku pojęcie „text mining methods" stopniowo zyskiwało na popularności [41]. W 1999 Margaret Marti Hearst zwróciła uwagę na istotne rozróżnienie między wyszukiwaniem informacji, a eksploracją danych tekstowych. Stwierdzono, że celem TM jest nie tylko lokalizowanie dokumentów, lecz przede wszystkim wydobywanie wiedzy z ich treści [42, 43].

Eksploracja tekstu bazuje na podejściu silnie interdyscyplinarnym, wynika to z faktu, że głównym celem TM jest wydobywanie informacji z nieustrukturyzowanych danych tekstowych, a to wymaga zastosowania narzędzi, algorytmów, metod i teorii z różnych obszarów nauki [41]. Ponieważ w eksploracji tekstu wykorzystuje się dane w postaci

tekstowej, to kluczową rolę odgrywa przetwarzanie języka naturalnego, które obejmuje tokenizację, lematyzację oraz analizę składniową i semantyczną. Eksploracja tekstu bazuje na wykorzystaniu zaawansowanych algorytmów przetwarzania danych oraz technik uczenia maszynowego, które umożliwiają m.in. kategoryzację, klasteryzację czy grupowanie dużych zbiorów danych. Lingwistyka komputerowa, dostarczająca narzędzi do analizy morfologicznej i semantycznej języka. Zrozumienie znaczenia tekstu jest konieczne dla skutecznej analizy sentymentu oraz wykrywania intencji [44]. Wykorzystanie statystyki i matematyki jest również istotne. Metody takie jak TF-IDF, analiza częstości, redukcja wymiarowości czy zastosowanie modeli probabilistycznych pozwala na efektywne wydobywanie wzorców oraz zależności w tekstach [45].

Eksploracja tekstu znajduje zastosowanie w wielu obszarach. Pozwala na generowanie streszczeń, identyfikację wiadomości o określonej tematyce, klasyfikację dokumentów, tworzenie automatycznych odpowiedzi na pytania, identyfikację powiązań pomiędzy informacjami oraz pozyskiwanie informacji z dokumentów. W naukach społecznych służy do analizy opinii publicznej oraz monitorowania trendów w mediach społecznościowych. W medycynie wspomaga analizę dokumentacji klinicznej i wspiera pracę badaczy oraz lekarzy poprzez automatyczne wydobywanie wiedzy z dużych zbiorów tekstów medycznych [46]. W sektorze biznesowym TM wykorzystuje się go do analizy opinii klientów, wykrywania ryzyka oraz obserwacji działań konkurencji.

Podsumowując, w erze Big Data większość danych ma formę tekstową. Eksploracja tekstu umożliwia przekształcenie niestrukturyzowanego tekstu w dane strukturalne, które mogą być analizowane ilościowo. Współczesna definicja TM mówi, że jest to proces polegający na automatycznym wydobywaniu informacji z niestrukturyzowanych danych, czyli z tekstów. Proces ten następuje poprzez identyfikację wzorców, zależności i informacji, przy wykorzystaniu techniki przetwarzania języka naturalnego, metod statystycznych, czy też uczenia maszynowego [47, 48].

1.3 Cel i zakres badań własnych

W niniejszej pracy podjęto się próby przeanalizowania notatek osób zmagających się z anoreksją wykorzystując metody eksploracji tekstu, w tym: metodę słownikową, ukrytą analizę semantyczną z wykorzystaniem dekompozycji według wartości osobliwych oraz algorytmy uczenia maszynowego takie jak regresja logistyczna, drzewa decyzyjne, las losowy oraz sieci neuronowe.

Dobór odpowiednich metod eksploracji tekstu jest ważnym elementem w pracach badawczych, zyskując szczególne znaczenie, gdy przedmiotem analizy są notatki osób chorych na zaburzenia odżywiania. Ze względu na fakt, iż analizowany zbiór danych obejmuje notatki osób zmagających się z anoreksją, podjęcie się tego zagadnienia ma szczególne znaczenie i wymaga wyjątkowej ostrożności. Wysoka precyzja oraz interpretowalność zastosowanych metod stają się kluczowe dla zapewnienia rzetelności i wiarygodności wyników. Metoda słownikowa została wybrana przez fakt, iż w analizie notatek osób chorych na anoreksję występuje charakterystyczny język. Często wypowiedzi tych osób zawierają odniesienia do obrazu ciała, emocji, terminologię kompensacyjną, a czasami wręcz autoagresję. Zaletą metody słownikowej jest to że jest interpretowalna, ale również wysoko dopasowana do analizowanej domeny. Zastosowanie ukrytej analizy semantycznej w połączeniu z dekompozycją według wartości osobliwych umożliwia

redukcję wymiarowości oraz uchwycenie ukrytych zależności semantycznych.

Celem naukowym jest opracowanie i empiryczna weryfikacja metod eksploracji tekstu, ze szczególnym uwzględnieniem metody słownikowej pod kątem, automatycznego określenia czy w notatkach narracyjnych osób chorych na anoreksję oraz zdrowych zostały poruszone analizowane tematy, które później nazwano obszarami trudności, w jednym z trzech kontekstów: pozytywnym, negatywnym lub mieszanym (pozytywno-negatywnym). Z przeprowadzonego przeglądu literatury wyłoniono obszary o kluczowym znaczeniu z perspektywy psychologów pracujących z osobami chorującymi na anoreksję. W pracy przeanalizowano następujące tematy: obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia oraz ból. Proponowana koncepcja opierała się na opracowaniu dla każdego analizowanego obszaru tematycznego precyzyjnego słownika domenowego, obejmującego zestaw terminów i synonimów, którego poprawność została zweryfikowana przez zespół psychologów pod nadzorem kierownikiem Centralnej Pracowni Psychologii Klinicznej Samodzielnego Publicznego Szpitala Klinicznego numer 1 imienia Profesora Stanisława Szyszko Śląskiego Uniwersytetu Medycznego w Katowicach. Dodatkowym celem badawczym było wykorzystanie algorytmów uczenia maszynowego w celu pogłębionej analizy i predykcji. Regresja logistyczna pozwoliła na zidentyfikowanie predyktorów, które w sposób statystycznie istotny różnicuje szansę współwystępowania anoreksji. Algorytmy drzew decyzyjnych cieszą się uznaniem pod względem przejrzystości reguł decyzyjnych, co ma kluczowe znaczenie w obszarze medycyny, gdzie interpretacja i wyjaśnienie wyników muszą być jasne i zrozumiałe. Zatem model ten pozwoli na głębszą eksplorację danych i wyników, uzyskując informacje o regułach decyzyjnych, najważniejszych klastrach oraz profilach notatek osób chorych. Następnie zastosowano dwa algorytmy w postaci: lasu losowego oraz sieci neuronowych, których głównym celem było zadanie klasyfikacyjne - odróżnienie notatek autorstwa osób chorych na anoreksję od zdrowych.

Celem utylitarnym jest opracowanie koncepcji narzędzia wspomagającego psychologiczną diagnostykę stanu osoby, które analizuje notatkę pod kątem obecności siedmiu obszarów trudności. Dodatkowo określającego polaryzację danego tematu (pozytywny, negatywny lub mieszany). Kontekst jest uwzględniany dla wszystkich obszarów z wyłączeniem autoagresji oraz bólu.

Celem dydaktycznym jest upowszechnienie wiedzy o najczęstszych obszarach trudności/tematach przejawiających się w wypowiedziach osób z zaburzeniami odżywiania ze szczególnym ukierunkowaniem na anoreksję.

Zakres badań obejmuje zastosowanie metody słownikowej, opartej na specjalistycznych słownikach słów kluczowych reprezentujących poszczególne obszary trudności. Metoda ta polega na identyfikacji tematów w analizowanych tekstach, które zostały odpowiednio przekształcone zgodnie z zasadami stosowanymi w eksploracji tekstu. Korpus danych przygotowano w postaci macierzy częstości, która następnie została poddana redukcji wymiarowości z wykorzystaniem rozkładu według wartości osobliwych oraz analizy ukrytej semantyki w celu uchwycenia zależności semantycznych między terminami. W kolejnym etapie wygenerowano modele: regresji logistycznej, drzew decyzyjnych, lasów losowych oraz sieci neuronowych.

Mając na uwadze powyższy cel i zakres badań, sformułowano następującą tezę pracy:

> *Metody eksploracji danych tekstowych łączące polskojęzyczne słowniki dziedzinowe z procedurą ukrytej analizy semantycznej (LSA) opartej na dekompozycji według wartości osobliwych (SVD) pozwalają na automatyczne rozpoznawanie obecności i wydźwięku wybranych tematów psychologicznych w wypowiedziach osób z anoreksją i osób zdrowych.*
>
> *Uzyskane w ten sposób wyniki umożliwiają przy wykorzystaniu algorytmów uczenia maszynowego identyfikację istotnych statystycznie predyktorów, wyodrębnienie interpretowalnych reguł decyzyjnych oraz klasyfikację i odróżnienie wypowiedzi osób zmagających się z anoreksją od grupy osób zdrowych.*

Udowodnienie postawionej tezy wymagało przeprowadzenia pełnego procesu badawczo-rozwojowego począwszy od dokonania przeglądu literatury dziedzinowej, przez opracowanie metodyki, zaimplementowanie metod, aż po analizę i opracowanie wyników.

1.4 Układ pracy

Układ rozprawy bezpośrednio odzwierciedla kolejne etapy realizacji badań i przedstawia się następująco:

Rozdział 1 Wstęp - stanowi wprowadzenie do pracy. Nakreśla ogólny kontekst badawczy poprzez zdefiniowanie specyfiki zaburzeń odżywiania (Podrozdział 1.1), przybliżenie tematyki eksploracji danych tekstowych (Podrozdział 1.2), określenie celu i zakresu badań oraz sformułowanie tezy rozprawy doktorskiej (Podrozdział 1.3).

Rozdział 2 Przegląd stanu wiedzy - wprowadza w tematykę rozprawy. Usystematyzowano w nim wiedzę o znaczeniu wybranych obszarów trudności (Podrozdział 2.1) oraz przybliżono proces przetwarzania i eksploracji danych tekstowych (Podrozdział 2.2). Następnie przeanalizowano zastosowania uczenia maszynowego w medycynie ze szczególnym uwzględnieniem zaburzeń odżywiania (Podrozdział 2.3) oraz wykorzystanie technik eksploracji tekstu w analizie wypowiedzi pisemnych (Podrozdział 2.4).

Rozdział 3 (Materiał badawczy i metodyka badań) - opisuje zgromadzony materiał (Podrozdział 3.1) oraz zastosowane metody (Podrozdział 3.2). W ramach opracowanej metodyki przedstawiono wykorzystanie technik TM do przetwarzania tekstów, a następnie do identyfikacji i określenia stopnia przynależności obszarów trudności (Podrozdział 3.2.1), procedurę analizy statystycznej opartej na badaniu rozkładów i teście U Manna-Whitneya (Podrozdział 3.2.2). Rozdział zamyka opis wdrożonych algorytmów uczenia maszynowego, w tym: regresji logistycznej, drzew decyzyjnych, lasu losowego oraz sieci neuronowych (Podrozdział 3.2.3).

Rozdział 4 Rezultaty - przedstawia szczegółowe wyniki przeprowadzonych badań oraz ocenę skuteczności zaproponowanych rozwiązań.

Rozdział 5 Podsumowanie i dyskusja - zamyka rozprawę, podsumowując przebieg badań i konfrontując uzyskane wyniki z postawioną tezą. Część ta zawiera również opis ograniczeń zastosowanych metod oraz propozycje dalszych kierunków przyszłych prac.

2. Przegląd stanu wiedzy

Rozdział stanowi przegląd aktualnego stanu wiedzy w obszarach kluczowych dla celów badawczych niniejszej pracy. W pierwszej części omówiono znaczenie wybranych obszarów trudności takich jak: obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia i ból w kontekście ich roli w procesie diagnozowania i leczenia osób cierpiących na zaburzenia odżywiania, a w szczególności na anoreksję. Następnie przybliżono metodykę eksploracji danych tekstowych oraz zastosowanie algorytmów uczenia maszynowego. W ostatniej części rozdziału dokonano przeglądu prac poświęconych wykorzystaniu eksploracji tekstu do analizowania wypowiedzi pisemnych.

2.1 Znaczenie analizowanych aspektów funkcjonowania psychicznego i społecznego

Zaburzenia odżywiania w tym anoreksja, należą do najpoważniejszych i złożonych zaburzeń psychicznych. Przebieg i rokowanie uzależnione są od wielu czynników psychologicznych, emocjonalnych i somatycznych. Współczesne prace naukowe podkreślają, że skuteczność leczenia AN nie powinna ograniczać się tylko do ustabilizowania masy ciała chorej osoby. Bardzo ważna jest równoczesna praca nad problemami, które towarzyszą osobom chorym na anoreksję, czyli z zaburzeniami dotyczącymi obrazu własnego ciała, trudnościami z emocjami, z niskim poczuciem własnej wartości (niską samooceną) oraz skłonnością do autoagresji. Głównym celem terapii powinna być praca z tymi głęboko zakorzenionymi zaburzeniami [49].

Zniekształcony obraz własnego ciała jest jednym z kluczowych zaburzeń towarzyszących osobom z anoreksją. Negatywne postrzeganie ciała stanowi istotny element ich codziennych doświadczeń [50], co sprawia że jest jednym z najbardziej uporczywych i wymagających obszarów trudności obserwowanych u pacjentów z anoreksją. Chorzy postrzegają swoją sylwetkę w sposób skrajnie negatywny. W badaniu Ciwoniuk i wsp. wykazano, że osoby z anoreksją cechują się znacznie silniejszymi zniekształceniami obrazu ciała oraz podwyższonym poziomem depresji i bólu psychicznego w porównaniu z grupą kontrolną [51]. Autorzy podkreślają, że sposób w jaki pacjent postrzega własną sylwetkę oraz jakie emocje mu towarzyszą uznawane są za jeden z kluczowych aspektów obrazu klinicznego choroby. Ich właściwe zrozumienie i podjęcie pracy nad nimi stanowi kluczowy element skutecznej terapii. Znaczenie pracy nad obrazem ciała w procesie leczenia zostało również potwierdzone w wynikach badania Junne i wsp. [52]. Autorzy wskazują, że zaburzenia obrazu ciała są jednym z kluczowych obszarów, które utrudnia leczenie. Im większe zniekształcenie obrazu, tym trudniejszy jest proces zdrowienia [53]. Istotny wkład do zrozumienia znaczenia obrazu ciała wnosi również

analiza przedstawiona w pracy przeglądowej Abdoli i wsp. [54]. Badacze zwracają uwagę, że fałszywy lub nieadekwatny obraz ciała jest silnie powiązany z zaburzeniami odżywiania, a jednocześnie współwystępuje z obniżoną samooceną i trudnościami emocjonalnymi. Takie zaburzenia obrazu ciała potęgują niekorzystne wzorce jedzenia, co sprawia, że stanowią istotny punkt wyjścia w procesie leczenia. Znaczenie obrazu ciała jako ważnego czynnika procesu leczenia zostało potwierdzone również w badaniach Biney i wsp.[55]. Wykazały, że niezadowolenie z ciała jest jednym z najbardziej trwałych objawów anoreksji, utrzymującym się nawet po ustabilizowaniu masy ciała. Aby terapia była efektywna i trwała, konieczna jest praca nad sposobem myślenia o własnym ciele i źródłami zniekształceń obrazu własnego ciała. Bez takiej zmiany ryzyko nawrotu pozostaje realne, nawet jeśli stan fizyczny chwilowo się poprawi.

Emocje stanowią kolejny ważny obszar trudności w anoreksji. Badania i praktyka kliniczna potwierdzają, że zaburzenia odżywiania są ściśle powiązane z intensywnymi i trudnymi do opanowania reakcjami emocjonalnymi. W literaturze podkreśla się, że mogą im towarzyszyć takie reakcje, jak poczucie winy, wstyd, głęboki lęk, złość czy skłonność do hipochondrycznych interpretacji doznań [56]. Czynniki te odgrywają znaczącą rolę w przebiegu choroby i mają istotny wpływ na skuteczność terapii, wpływając na gotowość pacjenta do współpracy i na możliwość utrzymania stabilnych zmian. U osób z anoreksją szczególnie silny lęk ujawnia się w momentach bezpośredniej konfrontacji z własnym wyglądem [55]. W pracy Mioduchowskiej-Zienkiewicz [56] opisano wyniki wskazujące, że znaczna część badanych dziewcząt, bo aż 72% przejawiała zachowania typowe dla zaburzeń odżywiania, takie jak jedzenie w ukryciu, odczuwanie wstydu i silnej niechęci do siebie po epizodach zwiększonego apetytu lub przejadania się. Autorzy podkreślają, że tego rodzaju reakcje emocjonalne odzwierciedlają wysoki poziom wewnętrznego napięcia i znaczne obciążenie psychiczne, które często towarzyszą osobom z zaburzeniami odżywiania i mają istotne znaczenie dla procesu leczenia. Na znaczącą rolę emocji w anoreksji zwraca również uwagę Ciwoniuk, Wayda-Zalewska i Kucharska [51]. Autorki wskazują, że zaburzony obraz własnego ciała generuje nasilony lęk i poczucie winy, a to z kolei wpływa na izolację i unikanie kontaktów społecznych oraz większe cierpienie jakiego doznają ci pacjenci. Podkreślają, że emocje związane z własnym ciałem są jednym z głównych objawów anoreksji i mają duże znaczenie dla skuteczności terapii. Dlatego poprawa stanu fizycznego nie rozwiąże problemu, jeśli negatywne emocje wobec własnego wyglądu nadal będą wywoływać destrukcyjne zachowania. Abdoli i wsp. [54] podkreślają, że kłopoty z regulacją emocji są ważnym czynnikiem zarówno w rozwoju, jak i dalszym trwaniu zaburzeń odżywiania. Wiele pacjentek próbuje radzić sobie z napięciem, lękiem czy wstydem poprzez ograniczanie jedzenia, napady objadania się lub zachowania kompensacyjne. Jednoznacznie wskazuje to, że obszar emocji stanowi ważny temat, który musi być uwzględniony w procesie terapeutycznym.

Obniżona samoocena jest istotnym czynnikiem ryzyka w anoreksji. Ma wpływ zarówno na rozwój choroby, jak i utrzymywanie się objawów. Badania pokazują, że sposób myślenia o sobie, ze szczególnym naciskiem na sposób postrzegania swojego wizerunku stanowi ważny element ogólnej samooceny człowieka i ma znaczący wpływ na poczucie własnej wartości [57]. Jak zauważa Mioduchowska-Zienkiewicz [56] pacjentki z zaburzeniami odżywiania często wykazują krytyczne, a wręcz wrogie nastawienie wobec siebie, które przejawia się poprzez intensywną krytykę, wyrażającą się w skłonności do umniejszania własnej wartości, przesadnego wytykania braków i koncentrowania się

na wadach. Tak silnie negatywne postrzeganie siebie skutkuje wyraźnym obniżeniem samooceny, co znacząco utrudnia proces leczenia. Dlatego praca nad wzmocnieniem poczucia własnej wartości stanowi ważny element terapii - bez niej utrwalają się nieprawidłowe schematy i zachowania, które podtrzymują chorobę. Różnica między postrzeganiem siebie takim, jakim się jest, a obrazem siebie idealnego stanowi istotny wskaźnik poprawy bądź nasilenia objawów [51, 58]. Im większa jest ta różnica, tym silniejsze stają się potrzeby kontrolowania wyglądu, co bezpośrednio sprzyja utrzymywaniu się anoreksji. Badania kliniczne pokazują, że osoby z anoreksją często narzucają sobie nierealistycznie wysokie wymagania dotyczące wyglądu, których nie są w stanie osiągnąć, co w konsekwencji prowadzi do obniżenia samooceny. Zależność tą pokazują analizy przeprowadzone przez Abdoli i wsp. Wykazali oni, że obniżona samoocena jest ściśle powiązana zarówno z zaburzonym postrzeganiem ciała, jak i z trudnościami emocjonalnymi [54]. Zwracają uwagę, że osoby o niskim poczuciu własnej wartości łatwiej ulegają negatywnym emocjom i napięciu związanym z wyglądem, co sprzyja nasilaniu niezdrowych wzorców żywieniowych. Analizowane badania wyraźnie pokazują, że samoocena odgrywa istotną rolę nie tylko jako współwystępujący objaw anoreksji, lecz także jako czynnik wpływający na jej przebieg. Jej obniżenie wzmacnia tendencję do nadmiernej kontroli wyglądu i jedzenia, co sprzyja skrajnym i niebezpiecznym zachowaniom. Dlatego praca nad poczuciem własnej wartości musi stanowić integralną część terapii, ponieważ jej pominięcie utrudnia trwałą poprawę funkcjonowania pacjentki.

Kolejnym kluczowym obszarem trudności z jakim często zmagają się chorzy na zaburzenia odżywiania jest autoagresja [59]. Kobiety z ED wykazują znacznie częstsze niż populacja zdrowa tendencje autodestrukcyjne, przyjmując różne formy od kierowania agresji na własne ciało poprzez zadawanie bólu, samouszkodzenia po głodzenie się, przeczyszczanie czy epizody kompulsywnego objadania [56, 60]. Mioduchowska-Zienkiewicz zwraca uwagę, że omawiany obszar trudności pełni ważną funkcję emocjonalną, ponieważ pomaga choć na chwilę zredukować napięcie i radzić sobie z bolesnymi emocjami. Ryzyko zgonu wśród pacjentów z anoreksją jest ponad pięciokrotnie wyższe niż w populacji ogólnej, a w przybliżeniu co piąty przypadek śmierci jest związany z samobójstwem [3, 61]. Występowanie autoagresji wskazuje na cięższy przebieg zaburzenia i wiąże się z mniej pomyślnym rokowaniem [59, 62]. Jedne z najnowszych badań wskazują, że samouszkodzenia występują u młodych osób z zaburzeniami odżywiania wyjątkowo często, osiągając poziomy świadczące o poważnej skali zjawiska. Dane Lavis i wsp. pokazują, że odsetek ten mieści się w przedziale od 25,4% do 55,2% [62]. Współwystępowanie zachowań autoagresywnych znacząco utrudnia terapię i pogarsza rokowania. W tym ujęciu autoagresja staje się nie tylko objawem choroby, ale poważnym czynnikiem ryzyka.

W obszarze funkcjonowania ciała u osób z anoreksją obserwuje się obecność zachowań kompulsywnych, takich jak prowokowanie wymiotów czy stosowanie środków przeczyszczających. Mioduchowska-Zienkiewicz podkreśla, że działania te zazwyczaj współwystępują z innymi formami autodestrukcji m.in. głodzeniem się, napadami objadania czy urazami fizycznymi i pełnią jednocześnie ważną funkcję regulacji emocjonalnej. Takie działania stają się sposobem radzenia sobie z trudnymi, często przytłaczającymi emocjami [56]. Z tego względu terapia nie może ograniczać się wyłącznie do kontroli i wygaszania tych zachowań, ale powinna również skupiać się na zrozumieniu ich funkcji i budowaniu alternatywnych strategii radzenia sobie.

Funkcjonowanie pacjenta w relacjach społecznych jest kolejnym ważnym elementem wpływającym na skuteczność leczenia zaburzeń odżywiania. To, jak osoba chora odbiera reakcje otoczenia na swoje ciało i zachowania wpływa na jej funkcjonowanie psychiczne. Obraz ciała, jako kluczowy element tożsamości, kształtuje się przede wszystkim poprzez doświadczenia społeczne i podlega ciągłej ocenie ze strony otoczenia [63]. W świecie, w którym wygląd jest nieustannie oceniany i porównywany, brak akceptacji społecznej łatwo prowadzi do wstydu, poczucia odmienności i wycofania, co jest szczególnie nasilone u osób z anoreksją. Badania wskazują, że pacjentki z zaburzeniami odżywiania często doświadczają silnego napięcia, poczucia winy lub lęku związanego z własnym wyglądem i w odpowiedzi na to wycofują się z kontaktów społecznych [51]. Rolę czynników społeczno-emocjonalnych w terapii anoreksji podkreśla się m.in. w analizie zastosowania dedykowanego modelu terapeutycznego MANTRA [49]. Badacze zwracają uwagę, że negatywne interakcje społeczne, brak wspierającego otoczenia oraz trudności w mówieniu o własnych emocjach mogą przyczyniać się do utrzymywania objawów anoreksji. Dlatego kluczowym elementem terapii jest budowanie relacji opartych na zrozumieniu i akceptacji. Oznacza to, że akceptujące otoczenie wspiera pacjenta emocjonalnie, zwiększa jego motywację i ułatwia współpracę terapeutyczną. Natomiast brak wsparcia może umacniać niekorzystne schematy działania i prowadzić do narastania oporu wobec leczenia.

W terapii zaburzeń odżywiania, w tym anoreksji, coraz większą wagę przykłada się do roli zarówno bólu fizycznego, jak i emocjonalnego cierpienia. Ciwoniuk, Wayda-Zalewska i Kucharska zwracają uwagę, że intensywne doświadczenie cierpienia stanowi istotny aspekt choroby i wymaga szczególnej uwagi ze strony specjalistów [51].

Analiza przedstawionych zagadnień jednoznacznie wskazuje, że każdy z nich odgrywa istotną rolę w diagnostyce oraz procesie terapeutycznym osób z zaburzeniami odżywiania, w tym z anoreksią. Wspomniane obszary współwystępują, wzajemnie się wzmacniając i wpływając na dynamikę choroby. Z tego względu istnieje potrzeba stworzenia narzędzia, które w sposób kompleksowy i zintegrowany pozwoliłoby uchwycić obecność tych obszarów trudności w wypowiedziach pacjentów. Takie podejście umożliwiłoby pełniejszą ocenę ich stanu, trafniejszą diagnozę oraz bardziej precyzyjne planowanie interwencji terapeutycznych.

2.2 Proces analizy danych w eksploracji tekstu

Analiza tekstu w TM to złożony i wieloetapowy proces. Jego celem jest przekształcenie nieustrukturyzowanych danych w dane strukturalne i wyciągniecie z nich istotnych informacji. Proces ten nie sprowadza się do pojedynczego algorytmu, lecz obejmuje szereg powiązanych ze sobą etapów, począwszy od precyzyjnego określenia celów badawczych, poprzez przygotowanie i reprezentację korpusu tekstowego, aż po wybór odpowiednich metod analitycznych oraz interpretację i walidację uzyskanych wyników. Każdy z tych kroków buduje się na poprzednim, co zapewnia spójność oraz wysoką jakość metodologiczną prowadzonych analiz. Takie podejście łączy elementy przetwarzania języka naturalnego, statystyki, uczenia maszynowego oraz wiedzy dziedzinowej. Graficznie, każdy etap analizy eksploracji tekstu przedstawiono na rysunku 2.1.



Rysunek 2.1: Etapy eksploracji tekstu (grafika własna).

2.2.1 Określenie celu, zakresu i kosztu analizy

Pierwszym etapem każdego zadania związanego z wykorzystaniem TM jest precyzyjne określenie celu badawczego. Jasne zdefiniowanie problemu analitycznego determinuje nie tylko wybór odpowiednich metod, metryk ale również sposobu reprezentacji danych i możliwych walidacji. W zależności od obszaru badawczego oraz zamierzonych rezultatów, cele analizy mogą być różne, m.in. mogą obejmować: klasyfikację dokumentów, analizę sentymentu, wykrywanie tematów lub ekstrakcję informacji. Kolejnym istotnym aspektem jest określenie zakresu analizy, który obejmuje m.in. jakość dostępnego korpusu, język, specyfikę dziedzinową (np. teksty medyczne, marketingowe, dane z mediów społecznościowych) oraz potencjalne ograniczenia związane z prywatnością czy dostępnością danych. Nie można również pominąć kwestii kosztów i dostępnych zasobów. Tylko rzetelna ocena tych czynników pozwala na realistyczne zaplanowanie projektu i dobór rozwiązań adekwatnych do założonych celów oraz ograniczeń praktycznych.

2.2.2 Budowa i przekształcenie korpusu

Korpus jest to zbiór dokumentów takich jak: artykuły naukowe, literatura, raporty, notatki kliniczne, dokumentacja, wpisy w mediach społecznościowych, czy wypowiedzi pisemne uczestników badań. Utworzony zbiór danych, który podlega dalszej analizie, musi spełniać określone kryteria włączenia i wykluczenia, aby zapewnić reprezentatywność, a także musi być zebrany zgodnie z zasadami etyki. W przypadku niniejszej pracy korpus stanowią pisemne, swobodne wypowiedzi (notatki) badanych osób na temat obrazu własnego ciała, pozyskane we współpracy z Samodzielnym Publicznym Szpitalem Klinicznym Nr 1 im. prof. Stanisława Szyszko Śląskiego Uniwersytetu Medycznego.
Przygotowanie korpusu poprzez wstępne przetwarzanie jest kluczowe dla uzyskania formatu tekstu odpowiedniego do dalszych operacji obliczeniowych. Warto podkreślić, że zarówno jakość zgromadzonego korpusu, jak i dobór metod przetwarzania mają istotny wpływ na efektywność i wiarygodność kolejnych etapów eksploracji tekstu.
Proces ten obejmuje różnorodne operacje, które mogą być stosowane niezależnie lub łączone w zależności od potrzeb analizy [64, 65]. Bywa, że jest to czasochłonny etap. Wśród tych operacji można wyróżnić:

- Redukcję morfologiczną - Ze względu na występowanie różnych form gramatycznych kluczowym wyzwaniem w analizie tekstu jest sprowadzenie wyrazów do wspólnej reprezentacji semantycznej. Jest to szczególnie istotne w przypadku języków o bogatej fleksji, do których zalicza się język polski. Stosuje się w tym celu dwa podstawowe podejścia: lematyzacja oraz stemming. Pierwsza z ich jest bardziej zaawansowana i polega na sprowadzeniu wyrazów do ich formy podstawowej (lematu) [66]. Przykładowo, wyrazy: „czytałem”, „czytać”, „czytający”,

„przeczytana" zostanie zastąpione przez „czytać". Stemming polega na usuwaniu końcówek fleksyjnych i derywacyjnych w celu wyodrębnienia rdzenia słowa. Przykładowo, słowa „pisanie", „pisarz", „napisać" zostaną zredukowane do wspólnego rdzenia „pis". Warto podkreślić, że uzyskane formy dzięki operacji stemmingu nie zawsze odpowiadają poprawnym wyrazom słownikowym [66, 67].

- Filtrowanie i redukcja wymiarowości - Celem tych operacji jest usunięcie terminów niewnoszących wartości merytorycznej. Do tego celu można wykorzystać listy słów odrzuconych tzn. „stop words". Zastosowanie takiej listy prowadzi do usunięcia z tekstów wszystkich słów, które znajdują się na takiej liście. Inną stosowana metodą jest przycinanie (ang.: pruning), polegające na wykluczeniu z dalszych analiz słów występujących rzadko lub nadmiernie często w skali całego korpusu [64].

- Czyszczenie i normalizacja strukturalna - Proces ten może obejmować: korektę pisowni, rozwijanie skrótów, usuwanie znaków: formatujących, interpunkcyjnych, specjalnych lub emotikonów, a także normalizację w postaci ujednolicenia wielkości liter oraz standaryzację znaków diakrytycznych [41, 67].

- Segmentacja (Tokenizacja) - Proces polegający na podzieleniu tekstu na mniejsze jednostki, które nazywamy tokenami. Mogą to być pojedyncze słowa, fragmenty słów, znaki lub symbole [66, 67].

- Tagowanie kategorialne - Proces polegający na automatycznym określaniu kategorii gramatycznych dla poszczególnych jednostek tekstu. Dzięki tej operacji możliwa jest analiza składniowa i semantyczna [68].

2.2.3 Reprezentacja dokumentów tekstowych

W procesie eksploracji tekstu, po przeprowadzeniu operacji przekształcających korpus, kolejnym istotnym krokiem jest wybór metody reprezentacji dokumentów tekstowych. Zasadniczo w TM można wyróżnić dwie reprezentacje: wektorową i grafową.

2.2.3.1 Reprezentacje wektorowe

Reprezentacja wektorowa opiera się na założeniu, że każdy dokument w korpusie można opisać jako punkt w przestrzeni wielowymiarowej, gdzie poszczególne wymiary odpowiadają terminom występującym w zbiorze danych. Podejście to zakłada, że każdy dokument w analizowanym zbiorze tekstów jest opisany jako wektor w przestrzeni cech. Cechami są słowa (terminy), które występują w korpusie [45]. Należy podkreślić, że aby reprezentacja wektorowa dokumentów tekstowych była rzeczywiście użyteczna, konieczne jest wcześniejsze przeprowadzenie odpowiednich operacji wstępnego przetwarzania, opisanych szczegółowo w rozdziale 2.2.2. Proces ten zazwyczaj obejmuje: redukcję form wyrazów (np. zastosowanie stemmingu lub lematyzacji), normalizację (np. usuwanie znaków specjalnych, interpunkcyjnych, sprowadzanie wyrazów do małych liter), wykluczenie wyrazów z stop listy. Podstawą tej reprezentacji jest utworzenie macierzy term-document, gdzie wiersze reprezentują wszystkie terminy, które występują w korpusie, a kolumny poszczególne dokumenty. Wartości pojedynczych komórek w_{ij} określają poziom częstości występowania danego słowa w danym

tekście. Model ten określa się mianem reprezentacji częstotliwościowej (ang. term frequency, TF), a samą strukturę macierzą częstości (równanie 2.1).

$$A = \begin{bmatrix} w_{11} & \cdots & w_{1j} \\ \vdots & \ddots & \vdots \\ w_{i1} & \cdots & w_{ij} \end{bmatrix} \tag{2.1}$$

Przykład macierzy częstości TF.
Załóżmy, że analizie poddano trzy krótkie fragmenty wypowiedzi pacjentek:

- Dokument 1: „Często porównuję swoje ciało do innych kobiet."
- Dokument 2: „Nie akceptuję swojego wyglądu, zwłaszcza sylwetki."
- Dokument 3: „Obsesyjnie myślę o wadze i kształcie ciała."

Po przeprowadzeniu operacji lematyzacji, normalizacji oraz zastosowaniu stop listy unikalnymi słowami są: ciało, kobiet, porównuję, akceptuję, wyglądu, sylwetki, obsesyjnie, myślę, wadze, kształcie. Terminy te będą reprezentować wiersze w macierzy, a kolumny to poszczególne dokumenty. W celu ułatwienia zrozumienia przedstawionej koncepcji przygotowano tabelę ilustrującą omawiane zagadnienie (tabela 2.1), natomiast matematyczny zapis macierzy częstości TF przedstawiono wzorem 2.2.

Tabela 2.1: Przebieg tworzenia macierzy TF.

Termin	**Dokument 1**	**Dokument 2**	**Dokument 3**
ciało	1	0	1
kobiet	1	0	0
porównuję	1	0	0
akceptuję	0	1	0
wyglądu	0	1	0
sylwetki	0	1	0
obsesyjnie	0	0	1
myślę	0	0	1
wadze	0	0	1
kształcie	0	0	1

$$TF = \begin{bmatrix} 1 & 0 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \end{bmatrix} \tag{2.2}$$

Model macierzy TF jest podstawowym wariantem. W literaturze, w zależności od celu badawczego i charakteru korpusu, można znaleźć klika odmian reprezentacji wektorowej [64, 66]. Najprostszy wariant boolowski ogranicza się tylko do binarnej identyfikacji obecności terminu, ignorując jego częstotliwość występowania. Zamiast zwykłego zliczania słów, częściej łączy się ich liczbę w danym tekście (TF) z tym, jak rzadko występują w całym zbiorze (IDF). Przykładem takiej reprezentacji jest reprezentacja mieszana TF-IDF (ang.: Term Frequency-Inverse Document Frequency). Dodatkowo stosuje się tu logarytm, aby słowo powtórzone kilkadziesiąt razy nie zdominowało wyniku. Jeśli natomiast porównujemy teksty o różnej długości, stosuje się model BM25 lub normalizację L_2. W ten sposób sama wielkość dokumentu nie zaburza oceny jego istotności.

Niezależnie od wybranej reprezentacji wektorowej, każda z nich przekształca analizowany korpus w formę numeryczną, umożliwiającą dokonanie dalszych operacji, przykładowo zastosowania metod obliczeniowych, czy też algorytmów uczenia maszynowego.

2.2.3.2 Reprezentacje grafowe

Reprezentacje grafowe stanowią inny sposób modelowania danych tekstowych. Oferują odmienną perspektywę reprezentacji informacji. Przede wszystkim umożliwiają pokazanie relacji pomiędzy słowami, dokumentami lub zdaniami. W literaturze można znaleźć kilka możliwych reprezentacji grafowych [64, 69]:

- **Reprezentacje proste oraz ich rozszerzenia bazujące na pozycji słów** - Najprostszą formę stanowi graf, w którym węzłami są pojedyncze, unikalne słowa, a skierowane krawędzie odzwierciedlają ich współwystępowanie po sobie w tekście. Wersja standardowa wzbogaca ten schemat o dodatkowe etykiety na krawędziach, określające miejsce wystąpienia. Z kolei model n-odległościowy wprowadza dodatkowo informację o relacjach między wyrazami oddalonymi o n pozycji i przypisując krawędziom wartości odpowiadające rzeczywistemu dystansowi.

- **Reprezentacje częstotliwościowe** - Takie grafy zawierają informację o częstotliwości pojawiania się elementów w tekście. Przykładowo węzłom przypisuje się liczbę wystąpień poszczególnych słów, natomiast krawędziom częstotliwość tworzenia przez nie par.

- **Grafy zaawansowane (składniowe i heterogeniczne)** - Te grafy zawierają informację o relacjach gramatycznych podmiot-orzeczenie lub łączą obiekty różnego typu: słowa, autorów, dokumenty.

2.2.3.3 Porównanie reprezentacji

Reprezentacje wektorowe są szeroko stosowane ze względu na prostotę implementacji, dużą dostępność narzędzi, uniwersalność, wysoką skalowalność, która pozwala zastosować je w przypadku dużego korpusu danych, a przede wszystkim ze względu na możliwość późniejszego zastosowania zaawansowanych metod przetwarzania takich

jak: redukcja wymiarowości czy algorytmy uczenia maszynowego [45, 70]. Warto jednak pamiętać o istotnych ograniczeniach tego typu reprezentacji danych. Dochodzi bowiem do utraty informacji o składni i zależnościach pomiędzy słowami, ponieważ tekst jest traktowany jako zbiór niezależnych cech [71]. Alternatywą jest reprezentacja grafowa, która zachowuje informacje o powiązaniach. Dzięki temu można modelować zależności składniowe oraz semantyczne, a przez to interpretacja tych modeli jest łatwiejsza. Relacje są jawne i umożliwiają ich śledzenie. Jednakże złożoność ich budowy i przetwarzania, często wymaga zaawansowanych narzędzi a tym samym algorytmy umożliwiające budowanie grafów bywają bardzo kosztowne obliczeniowo, co znacząco ogranicza ich stosowanie. Wobec powyższego wybór reprezentacji powinien być uzależniony od specyfiki zadania badawczego.

2.2.4 Wybór metody analizy i przetwarzania danych

Wybór odpowiedniej metody analizy danych tekstowych jest kluczowy, ponieważ będzie wpływał zarówno na możliwości wydobycia istotnych informacji, jak i jakość uzyskiwanych wyników. W literaturze dostępne są różne podejścia, które różnią się między sobą założeniami teoretycznymi, tym samym przekładają się na różnice w zakresie zastosowań, interpretowalność wyników i uzyskanych efektów. W praktyce, wybór metody powinien być podyktowany jakością posiadanego korpusu danych, specyfiką analizowanego problemu, tym jakie wyniki chcemy uzyskać oraz dysponowanymi zasobami obliczeniowymi. Kluczowym czynnikiem, który wpływać będzie na wybór metody przetwarzania jest uwzględnienie wymagania dotyczącego przejrzystości i interpretowalności modelu. W praktyce oznacza to konieczność oceny, na ile wyniki uzyskane za pomocą danej techniki są zrozumiałe i możliwe do uzasadnienia zarówno dla badacza, jak i dla odbiorców wyników. Istnieją takie dziedziny, gdzie jest to szczególne istotne np. w zastosowaniach medycznych, klinicznych, prawnych czy edukacyjnych. W tych obszarach zachowanie transparentności procesu decyzyjnego stanowi wymóg formalny lub etyczny [72].

Wśród dostępnych podejść można wyróżnić: metody słownikowe, ukrytą analizę semantyczną, rozkład według wartości osobliwych, drzewa decyzyjne i lasy losowe, sieci neuronowe, metodę wektorów nośnych, metody probabilistyczne, metody oparte na regułach i ekstrakcji informacji. Warto również wspomnieć, że istnieją metody hybrydowe, które polegają na łączeniu różnych podejść. Wymienione metody pełnią różne funkcje w procesie przetwarzania. Przykładowo: metody słownikowe lub rozkład według wartości osobliwych służą do zamiany tekstu na liczby, a drzewa decyzyjne czy sieci neuronowe bazują na przetworzonych danych liczbowych, które wymienione algorytmy wykorzystują do prowadzenia analiz, klasyfikacji czy predykcji.

2.2.4.1 Metody słownikowe

Metody słownikowe (ang.: dictionary-based methods) są klasycznym, intuicyjnym i przejrzystym narzędziem stosowanym w eksploracji tekstu. Technika ta wykorzystuje listę wcześniej zdefiniowanych terminów, które reprezentują określony temat. Proces analizy polega na przeszukiwaniu tekstu pod kątem wystąpień tych terminów i przypisywaniu ich do odpowiednich klas bez udziału człowieka. Słowniki tematyczne umożliwiają szybkie i stosunkowo proste przetwarzanie dużych korpusów danych, gdzie dla

człowieka taka praca byłaby trudna i czasochłonna [73]. Metody te szczególnie znajdują zastosowanie w zadaniach, w których kluczowe jest wychwycenie specyficznych pojęć w dużych korpusach danych (zbiorach dokumentów). Metody bazujące na słownikach mogą wykazać dużą użyteczność w medycynie, ponieważ zakres terminów jest jasno zdefiniowany i ograniczony. Przykładem mogą być specyficzne pojęcia, terminy, jednostki chorobowe, leki, a to umożliwia pełną analizę tekstów naukowych i klinicznych [73, 74]. Poza tym, metody te znajdują zastosowanie w analizie sentymentu, czyli automatycznego rozpoznawania i klasyfikowania emocjonalnego wydźwięku analizowanego tekstu, czy też w badaniach społecznych, gdzie można wychwycić określone tematy. Popularność metod słownikowych wynika z kilku kluczowych zalet. Pierwszą cechą jest ich prostota, przejrzystość i szybkość działania. Implementacja metod jest stosunkowo łatwa, ich działanie jest intuicyjne i umożliwia bardzo szybkie przetwarzanie dużych zbiorów tekstowych [73]. Dzięki zastosowaniu słowników, proces klasyfikacji jest transparentny, ponieważ w każdej chwili można sprawdzić jakie słowa zdecydowały o wyniku analizy. Co ważne, słowniki można w dowolnym momencie modyfikować. Można je rozszerzać, aktualizować i dostosować do zmieniających się wymagań. Pomimo tych zalet metody oparte na słownikach mają kilka istotnych ograniczeń. Pierwszym z nich jest brak uwzględnienia kontekstu i znaczenia słów w odniesieniu do całego zdania, co może prowadzić do niewłaściwej interpretacji wieloznacznych wyrażeń [73]. Kolejną wadą jest brak uwzględnienia negacji, co może wpływać na błędne wyniki. Skuteczność metody jest silnie powiązana z jakością słownika. W zależności od analizowanej tematyki, istnieje konieczność ciągłej aktualizacji słowników. Brak bieżącej aktualizacji słownika może prowadzić do pominięcia istotnych wyrazów lub błędnej klasyfikacji tekstu. Dodatkowo w wielu przypadkach budowa słowników wymaga zaangażowania ekspertów dziedzinowych. Jest to istotne w takich dziedzinach jak medycyna, prawo czy nauki techniczne, gdzie poprawność i aktualność słownika mają kluczowe znaczenie dla wiarygodności wyników. Konieczność zaangażowania ekspertów może wpływać na wydłużony czas budowania takich słowników, ale z drugiej strony wiedza ekspercka pozwala na uwzględnienie subtelnych różnic znaczeniowych i kontekstowych Obecnie najbardziej znanymi słownikami są te, które używane są do wykrywania emocji i sentymentu - np. LIWC lub SentiWordNet. Słowniki specjalistyczne tworzone są na potrzeby konkretnych projektów badawczych, czy badań klinicznych i w przeważającej większości nie są ogólnodostępne. W przypadku zaburzeń odżywiania wciąż brakuje kompleksowego słownika [75]. Obecnie najbardziej znanym i największym leksykonem terminów związanych ogólnie z tematem zaburzeń odżywiania jest EDBase. Natomiast należy zaznaczyć, że został on opracowany na podstawie analizy wpisów z mediów społecznościowych.

2.2.4.2 Ukryta analiza semantyczna

Ukryta analiza semantyczna (ang.: Latent Semantic Analysis, LSA) jest zaawansowaną techniką często stosowaną w eksploracji tekstu [41, 64]. Głównym jej celem jest znalezienie zależności pomiędzy terminami i dokumentami. Metoda ta bazuje na tym, że teksty oraz słowa są reprezentowane jako wektory w wielowymiarowej przestrzeni semantycznej. Ich wzajemne podobieństwo określane jest na podstawie odległości w tej przestrzeni. Zatem LSA umożliwia osadzenie zarówno dokumentów, jak i słów w tej samej przestrzeni semantycznej, gdzie bliskość oznacza silne powiązania znaczeniowe [70]. Istotnym krokiem jest skonstruowanie macierzy term-document, którą można na-

stępnie poddać odpowiednim transformacjom (np. TF-IDF), a następnie dekompozycji wartości osobliwych. Dzięki temu możliwa jest redukcja wymiarowości danych tekstowych, co pozwala na wydobycie ukrytych struktur tematycznych i semantycznych, które nie są bezpośrednio widoczne w oryginalnych danych. W rezultacie otrzymuje się przestrzeń o mniejszych wymiarach, minimalizując utratę informacji, a pozwalającą na analizę semantyczną [76]. LSA bazuje na założeniu, że znaczenie słów wynika z ich współwystępowania w podobnych kontekstach, co jest zgodne z hipotezą dystrybucyjną szeroko stosowaną w lingwistyce. W praktyce metoda ta umożliwia nie tylko kategoryzację i porównywanie dokumentów, ale także automatyczne streszczanie dużych zbiorów tekstów oraz wykrywanie powiązań semantycznych pomiędzy terminami, nawet jeśli nie występują one dosłownie w analizowanych tekstach. Warto podkreślić, że LSA nie bierze pod uwagę kolejności słów w zdaniu, co stanowi jej ograniczenie typowe dla modeli typu „bag of words" [77], jednakże mimo to jest powszechnie wykorzystywana w eksploracji tekstu do analizy danych przedstawianych w postaci listy wyrazów. Metoda LSA bazuje na konstrukcji macierzy term-dokument. Wymiar macierzy zazwyczaj jest bardzo duży dlatego niezbędna jest jej redukcja. Do redukcji wymiarowości stosuje się dekompozycję według wartości osobliwych, która jest szczegółowo omówiona w rozdziale 2.2.4.3. Po zastosowaniu LSA każdy dokument i termin jest reprezentowany w przestrzeni o niższej wymiarowości.

2.2.4.3 Rozkład według wartości osobliwych

Rozkład według wartości osobliwych (ang.: Singular Value Decomposition, SVD) jest jednym z kluczowych narzędzi, które wykorzystywane jest w text minigu. Metoda ta polega na dekompozycji macierzy term-dokument (najczęściej jest to macierz TF lub TF-IDF) na trzy składowe: macierz U (macierz wyrazów), macierz V (macierz dokumentów) i macierz S (macierz diagonalna, określa znaczenie kolejnych składowych). Rozkład SVD przedstawia schematycznie wzór numer 2.3.

$$\begin{bmatrix} X \\ \text{Macierz} \\ \text{częstotliwości} \end{bmatrix} = \begin{bmatrix} U \\ \text{Macierz} \\ \text{wyrazów} \end{bmatrix} \begin{bmatrix} S \\ \text{Macierz} \\ \text{diagonalna} \end{bmatrix} \begin{bmatrix} V^T \\ \text{Transponowana} \\ \text{macierz} \\ \text{dokumentów} \end{bmatrix} \tag{2.3}$$

Procedura redukcji wymiaru z wykorzystaniem SVD obejmuje kilka kluczowych etapów. Proces ten polega na wyznaczeniu i uszeregowaniu wartości osobliwych, a następnie odrzuceniu najmniej znaczących z nich, uznawanych za szum informacyjny. W efekcie tych operacji uzyskuje się nową macierz o zredukowanych wymiarach, która zachowuje najważniejsze informacje semantyczne, choć pewna część szczegółowych danych zostaje utracona. W tak przekształconej macierzy nowe zmienne stanowią liniowe kombinacje pierwotnych terminów, zachowując wzajemną niezależność. Dokumenty po dekompozycji SVD reprezentowane są jako wektory kolumnowe w macierzy V^T. Terminy natomiast odpowiadają wierszom w macierzy będącej iloczynem $U \cdot S$ [41].

Takie podejście umożliwia nie tylko redukcję wymiarowości macierzy, ale również lepsze uchwycenie ukrytych powiązań semantycznych pomiędzy dokumentami i terminami, co jest szczególnie cenne w zadaniach związanych z wyszukiwaniem informacji, klasteryzacją czy analizą tematyczną tekstu. Wykorzystanie SVD pozwala nie tylko na

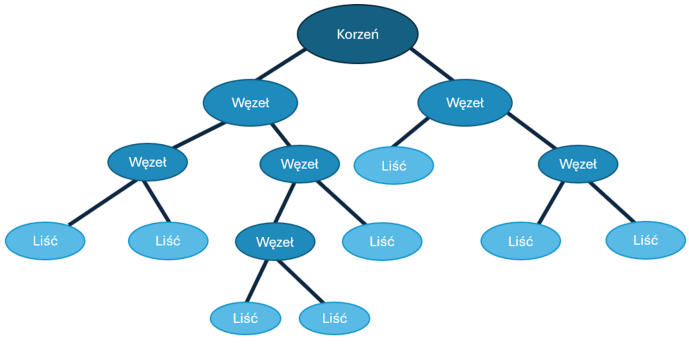
eliminację nieistotnych elementów i zakłóceń w danych, lecz także na skoncentrowanie analizy na tych wymiarach, które są najbardziej wartościowe z punktu widzenia semantyki tekstu [70, 78]. Należy mieć na uwadze, że pomimo wielu korzyści, zastosowanie SVD wiąże się również z pewnymi ograniczeniami. Przede wszystkim, przeprowadzenie dekompozycji na bardzo dużych macierzach wymaga znacznych zasobów obliczeniowych. Dodatkowo, uzyskane wyniki są w dużej mierze zależne od jakości przygotowania danych wejściowych oraz właściwego przeprowadzenia etapów wstępnej obróbki [45]. Rozkład według wartości osobliwych stanowi bazę dla licznych metod, takich jak LSA. Dzięki zastosowaniu SVD można zredukować wymiarowość danych tekstowych bez utraty istotnych informacji semantycznych, co pozwala LSA na odkrywanie głębokich zależności pomiędzy terminami i dokumentami.

2.2.4.4 Drzewa decyzyjne (klasyfikacyjne) i lasy losowe

Drzewa decyzyjne to predykcyjne modele należące do grupy algorytmów nadzorowanego uczenia maszynowego. Ich celem jest przewidzenie wartości zmiennej docelowej (objaśnianej) na podstawie zestawu zmiennych wejściowych (objaśniających), a działanie opiera się na rekurencyjnym podziale zbioru danych na coraz bardziej jednorodne podzbiory pod względem zmiennej objaśnianej [79]. Jest to przykład algorytmu, który dokonuje podziału danych na podstawie ich cech, tworząc strukturę drzewa. Cechą charakterystyczną tego algorytmu jest jej hierarchiczna struktura. Proces konstrukcji drzewa przebiega etapowo, zaczynając od całego zbioru danych i stopniowym dzieleniu go na coraz mniejsze podzbiory. W zależności od rodzaju zmiennej, którą model ma przewidywać, można wyróżnić dwie podstawowe odmiany drzew: klasyfikacyjne i regresyjne. Pierwsze z nich znajdują zastosowanie wtedy, gdy wynik ma charakter kategorialny i celem jest przypisanie obserwacji do jednej z dostępnych klas. W takich modelach kolejne podziały danych mają na celu zwiększenie jednorodności klas. Drzewa regresyjne wykorzystuje się, gdy przewidywana zmienna jest liczbowa. Dużą zaletą tego algorytmu jest łatwość interpretacji wyników, ponieważ znany jest cały proces decyzyjny - znane są wszystkie reguły podziału danych [72].

Drzewo decyzyjne ma budowę warstwową, tworząc jednocześnie strukturę ukierunkowaną, hierarchiczną i acykliczną. W modelu tym można wyróżnić kilka charakterystycznych elementów takich jak: korzeń, gałęzie, węzły i liście. Przykład schematu drzewa decyzyjnego przedstawiono na rysunku 2.2. Wierzchołkiem każdego drzewa decyzyjnego jest korzeń. Jest to punkt startowy modelu, który odpowiada całemu zbioru danych wejściowych. Budowa drzewa następuje od korzenia poprzez dokonanie najbardziej efektywnego podziału danych według przyjętych kryteriów. Po podziale danych tworzone są węzły, które następnie mogą ulegać dalszym podziałom na podstawie wybranej jednej cechy. Wybór cechy ma znaczenie, ponieważ podział ma za zadanie maksymalną redukcję nieczystości w danym węźle. Czyli dąży się do tego, aby dany węzeł był jak najbardziej jednorodny pod względem zmiennej objaśnianej. W zależności od przyjętego algorytmu węzeł ulega podziałowi na dwie (w modelu CRT) lub więcej gałęzi (w np. modelu C4.5) [79]. Gałęzie, czyli krawędzie łączące węzły odzwierciedlają wynik testu na danej cesze, który doprowadził do konkretnego podziału danych. Gałęzie określają trasę w strukturze drzewa jaką pokonuje konkretna obserwacja w trakcie prognozowania. Wierzchołki, które nie podlegają dalszym podziałom nazywa się liśćmi. Te końcowe węzły drzewa zawierają ostateczną decyzję modelu. Liście stanowią finalny punkt ścieżki decyzyjnej. Pierwszym parametrem, dzięki któ-

remu można opisać złożoność wygenerowanego modelu jest głębokość drzewa. Można ją określić w kontekście całego drzewa lub konkretnego wierzchołka. Należy jedynie policzyć sumę wszystkich krawędzi pomiędzy korzeniem a danym wierzchołkiem. Długość najdłuższej takiej ścieżki, która prowadzi od korzenia do liścia jest głębokością (wysokością) całego drzewa [80, 81]. W literaturze w opisach relacji pomiędzy elementami drzewa używane są pojęcia: węzeł rodzicielski i węzeł potomny. Każdy węzeł potomny jest bezpośrednio wyprowadzony z jednego węzła rodzicielskiego.



Rysunek 2.2: Przykład drzewa decyzyjnego (grafika własna).

Drzewa decyzyjne z pewnością można zaliczyć do najbardziej intuicyjnych i łatwo interpretowanych modeli uczenia maszynowego, które znajdują zastosowanie w wielu problemach decyzyjnych. Pozwalają na graficzną wizualizację rezultatów, która może być bardziej przyjazna dla osób nietechnicznych. Model oferuje jednoznacznie zdefiniowane reguły, pokazując zależności miedzy zmiennymi, a tym samym gwarantując transparentność całego procesu decyzyjnego. Zastosowanie tego algorytmu nie wymaga skomplikowanej implementacji, a faza klasyfikacji przebiega przy bardzo niskim koszcie obliczeniowym [82, 83]. Wśród wad tego modelu należy wymienić wysoką podatność na przeuczenie. Bez ograniczenia głębokości czy minimalnej liczby próbek w liściu drzewa mają tendencję do nadmiernego rozrastania się.

Istota działania lasów losowych jako metody zespołowej polega na połączeniu wielu drzew decyzyjnych oraz zastosowaniu kontrolowanej losowości. Pierwszym etapem jest utworzenie wielu modeli drzew decyzyjnych, z których każdy trenowany jest na innej, losowo dobranej próbce danych (technika ta nosi nazwę bootstrap) oraz na losowym zestawie cech. Takie podejście zwiększa zróżnicowanie drzew i zmniejsza ich wzajemną zależność, a ostateczna prognoza całego zespołu powstaje poprzez uśrednienie (lub połączenie) wyników wygenerowanych przez poszczególne modele. Ze względu na fakt, że każde drzewo analizuje inny zestaw cech, to cały model potrafi dostrzec bardziej złożone zależności i relacje między zmiennymi. Ostatnim etapem jest agregacja predykcji. Polega ona na łączeniu wyników z wielu modeli drzew decyzyjnych. W zależności od typu zadania lasy losowe stosują różne strategie. W klasyfikacji wykorzystują głosowanie większościowe, które polega na tym, że każde drzewo wskazuje swoją klasę, a model wybiera tę klasę, którą wskazała największa liczba drzew. Klasę rozumiemy jako wartość, którą próbuje się przewidzieć w modelu. Dzięki agregacji wielu niezależnych drzew lasy losowe charakteryzują się wysoką skutecznością predykcyjną oraz odpornością na przeuczenie, przez co są znacznie dokładniejsze i bardziej stabilne niż

pojedyncze modele [84, 85]. Należy jednak pamiętać, że trenowanie całego zespołu wiąże się z większym zapotrzebowaniem na pamięć operacyjną oraz wyższym kosztem obliczeniowym. Ze względu na fakt, iż ten model zbudowany jest z wielu drzew, jego pełna interpretacja jest znacznie trudniejsza niż pojedynczego drzewa.

2.2.4.5 Sieci neuronowe

Sztuczne sieci neuronowe (ang.: Artificial Neural Networks, ANN) to przykład modeli uczenia maszynowego. Zbudowane są z warstw połączonych ze sobą neuronów, które przetwarzają dane na wzór ludzkiego mózgu [86]. Neurony to jednostki obliczeniowe. Dane wejściowe są przetwarzane przez kolejne warstwy neuronów, które stopniowo uczą się rozpoznawać coraz bardziej złożone zależności i wzorce. Podczas treningu sieć modyfikuje wagi połączeń, aby uzyskać jak najlepsze efekty, czyli takie które najlepiej odpowiadają rzeczywistym wynikom, na podstawie których sieć się uczy. Współcześnie istnieje wiele różnych architektur sieci neuronowych, które różnią się między sobą strukturą połączeń oraz przeznaczeniem. Wśród nich można wyróżnić zarówno tradycyjne sieci jednokierunkowe (np. MLP - Wielowarstwowy Perceptron, ang.: Multilayer Perceptron lub RBF - Sieć z Radialnymi Funkcjami Bazowymi, ang. Radial Basis Function), jak i wysoce wyspecjalizowane głębokie modele (np. sieci konwolucyjne CNN, rekurencyjne RNN czy architektury transformatorowe np. HerBERT). Biorąc pod uwagę analizowany problem badawczy oraz ograniczony zbiór danych (201 obserwacji), w pracy zdecydowano się wykorzystać sztuczne sieci neuronowe o mało skomplikowanej strukturze. Zapobiega to zjawisku przeuczenia i wspiera zdolności generalizacyjne modeli. W pracy przeanalizowano dwie klasyczne architektury sieci jednokierunkowych (MLP oraz RBF), czyli takich w których informacje przepływają w jednym kierunku od warstwy wejściowej przez warstwę lub warstwy ukryte, aż do warstwy wyjściowej.

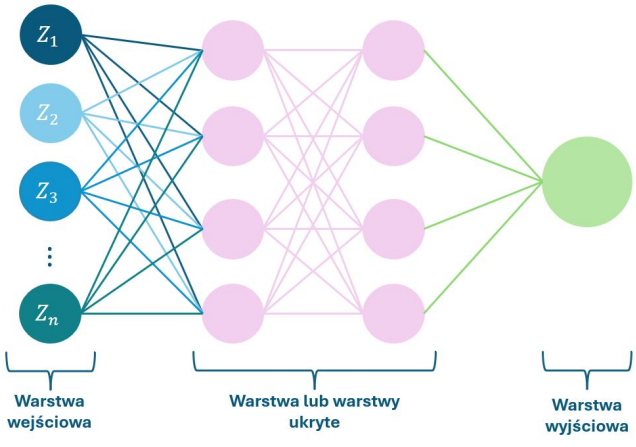
Perceptron Wielowarstwowy (MLP) to wielowarstwowa sieć przetwarzająca sygnały poprzez liniową kombinację wejść i ich dalszą nieliniową aktywację. Schematycznie architektura wielowarstwowego perceptronu została przestawiona na rysunku 2.3.

W każdym neuronie obliczana jest suma ważona sygnałów wejściowych powiększona o przesunięcie (ang.: bias), a następnie nakładana jest nieliniowa funkcja aktywacji f. Sygnał wyjściowy y wyraża się wzorem 2.4 [86, 87].

$$y = f\left(\sum_{i=1}^{n} w_i x_i + b\right) \tag{2.4}$$

gdzie:
i - numer kolejnego sygnału wejściowego,
n - liczba wszystkich sygnałów wejściowych (zmiennych),
x_i - sygnał wejściowy,
w_i - waga połączenia,
b - wartość przesunięcia (bias),
f - funkcja aktywacji (np.liniowa, logistyczna, wykładnicza, Softmax, tangens hiperboliczny).

Trenowanie sieci MLP opiera się na podejściu nadzorowanym z wykorzystaniem algorytmu wstecznej propagacji błędów (ang.: backpropagation), którego zadaniem jest optymalizacja wag sieci poprzez ciągłą minimalizację wybranej funkcji kosztu (np. błąd średniokwadratowy, sumę kwadratów błędów lub entropię) [86, 87].



Rysunek 2.3: Architektura wielowarstwowego perceptronu MLP, gdzie $Z_1, Z_2 ... Z_n$ to zmienne wejściowe, cechy (grafika własna)

Sieć z Radialnymi Funkcjami Bazowymi (RBF) to sieć z pojedynczą warstwą ukrytą, wykorzystującą odległość euklidesową do określania aktywacji centrów radialnych. Sygnał wyjściowy y wyraża się wzorem 2.5 [86].

$$y = \sum_{i=1}^{n} w_i \phi_i(\mathbf{x}) + b \tag{2.5}$$

gdzie:
i - numer kolejnego sygnału wejściowego,
n - liczba wszystkich sygnałów wejściowych (zmiennych),
w_i - waga połączenia,
$\phi_i(\mathbf{x})$ - odpowiedź (aktywacja) i-tego neuronu warstwy ukrytej reprezentowana przez radialną funkcję bazową,
b - wartość przesunięcia (bias).

Wśród zalet można wyróżnić ich wysoką skuteczność w zadaniach klasyfikacyjnych [88]. Jednak często sieci neuronowe wymagają dużego zbioru danych wejściowych, a to skutkuje koniecznością wysokich wymagań obliczeniowych [89]. Największą wadą jest jednak ich ograniczona interpretowalność. Modele te funkcjonują jako „czarne skrzynki". Niezwykle trudno jednoznacznie prześledzić, które elementy danych wejściowych wpłynęły na ostateczną decyzję modelu. To utrudnia interpretację wyników i skutkuje tym, że sieci neuronowe nie są tak transparentne jak np. modele drzew decyzyjnych.

2.2.4.6 Regresja logistyczna

Analiza regresji pozwala na zbadanie zależności zachodzących pomiędzy zmienną objaśnianą Y a zestawem zmiennych objaśniających (predyktorów) $X = (X_1, X_2, \ldots, X_p)$ [90]. Wśród modeli regresyjnych wyróżnia się m.in. regresję liniową oraz logistyczną. Pierwsza z nich wymaga, aby zmienna objaśniana miała charakter ciągły, natomiast regresję logistyczną stosuje się w sytuacjach, gdy zmienna zależna jest jakościowa (najczęściej binarna). Regresja logistyczna modeluje prawdopodobieństwo opisane wzorem 2.6 [91].

$$p(X) = P(Y = 1|X) \tag{2.6}$$

W celu oceny wpływu konkretnych predyktrów na zmienną objaśnianą analizuje się kilk aparametrów takich jak: współczynniki regresji (B) oraz ich błędy standardowe (SE). Do weryfikacji istotności statystycznej zmiennych wykorzystuje się test Walda, przyjmując poziom istotności $p < 0{,}05$. W celu oceny kierunku i siły danych zmmiennych stosuje się parametr o nazwie iloraz szans (OR) wyznaczany wraz z 95% przedziałem ufności (95% CI). Uzyskane na wyjściu modelu prawdopodobieństwo warunkowe $p(X)$ stanowi podstawę zaklasyfikowania obserwacji do odpowiedniej kategorii na podstawie ustalonego progu odcięcia.

2.2.4.7 Metody probabilistyczne

Metody probabilistyczne to kolejna grupa metod, które można używać w analizie tekstu. Ich celem jest identyfikowanie ukrytych tematów występujących w dużych korpusach danych. Jednym z przykładów algorytmów, które możemy zaliczyć do tej grupy jest Latent Dirichlet Allocation (LDA) [92]. Wśród jej zalet można wymienić dobrą interpretowalność wyników i fakt, że dobrze sobie radzi w pracy z dużymi korpusami tekstu. Głównym ograniczeniem stosowania jest konieczność poprawnego określenia liczby tematów oraz parametrów samego modelu, a także trudności w interpretacji wyników w przypadku tekstów bardzo krótkich lub silnie zróżnicowanych dokumentów tekstowych [93].

2.3 Zastosowanie algorytmów uczenia maszynowego

Mimo szybkiego postępu w dziedzinie głębokiego uczenia, regresja logistyczna nie traci na znaczeniu i również znajduje zastosowanie jako narzędzie predykcji w medycynie. W badaniach opublikowanych przez Cartera i wsp. [94] model regresji logistycznej został wykorzystamy do identyfikacji predyktorów sprzyjających nawrotom anoreksji u pacjentek po zakończonej hospitalizacji. Grupa badawcza liczyła 100 osób, a wśród zmiennych uwzględniono zarówno parametry demograficzne i kliniczne oceniane przy przyjęciu pacjentek na oddział (m.in. wiek, wyjściowy i końcowy wskaźnik BMI oraz nasilenie objawów depresyjnych i obsesyjnych, kontrolujących i kompensacyjnych), jak i czynniki związane z samym przebiegiem leczenia (tempo przyrostu masy ciała, dynamika motywacji do wyzdrowienia, a także natężenie symptomów chorobowych wciąż utrzymujących się po zakończeniu leczenia). Autorzy wykazali, że najważniejszymi czynnikami ryzyka nawrotu choroby są: określony podtyp kliniczny anoreksji,

nasilenie tendencji do obsesyjnej kontroli przed leczeniem, a także niski poziom motywacji do wyzdrowienia przy wypisie oraz spadek motywacji w pierwszych czterech tygodniach terapii. Regresja logistyczna posłużyła również do oceny skuteczności kwestionariusza SCOFF, który stosowany jest jako narzędzie przesiewowe w celu wykrycia zaburzeń odżywiania. Zastosowanie regresji logistycznej umożliwiło wyłonienie pytań najlepiej różnicujących osoby chore i zdrowe [95]. W badaniach nad czynnikami ryzyka rozwoju zaburzeń odżywiania wykorzystywano m.in. wielowymiarowe analizy statystyczne, w tym regresję logistyczną [96]. Pozwoliło to autorom na ocenę wpływu różnorodnych cech psychologicznych oraz doświadczeń z okresu rozwoju na prawdopodobieństwo wystąpienia choroby. Spośród analizowanych predyktorów, krytycznymi dla przyszłej diagnozy anoreksji okazały się: negatywna samoocena, doświadczanie presji lub innych trudności w relacjach z rodzicami, a także występowanie problemów z karmieniem i jedzeniem w dzieciństwie. Zmienne te w istotny sposób podnosiły ryzyko zachorowania na jadłowstręt psychiczny w okresie nastoletnim lub wczesnej dorosłości.

Choć w obszarze zaburzeń odżywiania liczba publikacji wykorzystujących ten algorytm jest wciąż ograniczona, to w skali całej medycyny regresja logistyczna stanowi jedno z najczęściej stosowanych narzędzi statystycznych. Nie brakuje artykułów, w których metoda ta znajduje zastosowanie w niemal każdej dziedzinie medycyny. Przykładem może być praca Fox i wsp., którzy wykorzystali regresję logistyczną do oszacowania ryzyka zgonu lub zawału serca u pacjentów z ostrym zespołem wieńcowym [97]. Wieloczynnikowa analiza pozwoliła wyodrębnić z zestawu danych kilka najważniejszych wskaźników o największej sile predykcyjnej, wśród której znalazły się takie zmienne jak: wiek, ciśnienie skurczowe, klasa Killipa, stężenie kreatyniny i nieprawidłowości w EKG [97]. Model regresji logistycznej może być stosowany również do oceny, czy nowe markery poprawiają zdolność prognostyczną znanych modeli klinicznych. Przykładem są badania Lyssenko i wsp., w których szacowano ryzyko zachorowania na cukrzycę typu 2. Autorzy wykorzystali jedno- i wieloczynnikowe modele regresji logistycznej do wyznaczenia ilorazów szans (OR) dla tradycyjnych cech klinicznych oraz 16 wariantów genetycznych [98]. Wykorzystanie regresji pozwoliło na udowodnienie, że uwzględnienie profilu genetycznego pacjentów skutkowało statystycznie istotnym wzrostem predykcji. Chayakova i wsp. wykorzystali model regresji logistycznej do analizy procesów decyzyjnych w medycynie ratunkowej [99]. Autorzy przebadali prawie 10 tysięcy wezwań pogotowia ratunkowego do pacjentów z chorobą niedokrwienną serca. W badaniu zastosowano wieloczynnikowy model regresji logistycznej, aby ustalić jakie czynniki demograficzne i kliniczne niezależnie wpływają na podjęcie przez zespół ratownictwa medycznego decyzji o hospitalizacji pacjenta [99]. Regresja logistyczna znajduje zastosowanie również w analizie barier systemowych ograniczających dostęp pacjentów do nowoczesnych terapii. Kim i wsp. wykorzystali tę metodę do oceny, czy standardowe kryteria wykluczenia w badaniach klinicznych nad rakiem płuca w sposób nieproporcjonalny eliminują przedstawicieli mniejszości rasowych i etnicznych [100]. W analizie zestawiono dane o chorobach współistniejących 4096 pacjentów z wymaganiami formalnymi pochodzącymi z 1134 programów klinicznych. Model regresji logistycznej wykazał, że w porównaniu do pacjentów rasy białej, osoby pochodzenia azjatyckiego były 1,8-krotnie, a pacjenci czarnoskórzy 1,6-krotnie bardziej narażone na dyskwalifikację z udziału w badaniach z powodu występujących u nich schorzeń współistniejących [100]. Ma i wsp. na grupie 551 pacjentów z łuszczycą

wykorzystali model regresji logistycznej do spersonalizowania leczenia łuszczycy [101].

Algorytm drzew decyzyjnych i lasów losowych ze względów na swoje liczne zalety są ważnymi narzędziami stosowanymi w obszarze medycznym. Brizzi i wsp. przeprowadzili analizę kilku metod uczenia maszynowego, w tym drzew decyzyjnych oraz lasów losowych, aby przewidywać efektywność hospitalizacji osób z anoreksją na podstawie danych psychologicznych i fizjologicznych zbieranych przy przyjęciu [102]. Najbardziej efektywnym rozwiązaniem okazał się las losowy osiągając skuteczność na poziomie 77%. Analiza najważniejszych zmiennych ujawniła, że największy wpływ mają zaburzenia obrazu ciała, problemy interpersonalne oraz początkowy poziom BMI. Wyniki te dobrze pokazują potencjał metod opartych na drzewach w obszarze zaburzeń odżywiania. W badaniu Izydorczyk i Wojciechowskiego drzewa decyzyjne posłużyły jako narzędzie do pokazania, że odpowiednio dobrany zestaw zmiennych psychologicznych i fizycznych pozwala skutecznie rozróżnić formy zaburzeń odżywiania [103]. Próba obejmowała grupę 92 zdrowych kobiet oraz 121 pacjentek z rozpoznaniem anoreksji, bulimii lub napadami objadania się. Opracowany model brał pod uwagę takie atrybuty jak: wartość BMI, niezadowolenie z ciała, presja norm społeczno kulturowych, lęk przed przytyciem czy trudności w budowaniu relacji interpersonalnych. Zastosowany algorytm wykazał wysoką precyzję, zwłaszcza przy identyfikowaniu anoreksji i napadów objadania się, co potwierdza użyteczność drzew decyzyjnych jako prostego, a jednocześnie bardzo efektywnego narzędzia do analizy. Wyniki te dobrze pokazują, jak metody drzewiaste pozwalają uchwycić specyficzne wzorce charakterystyczne dla poszczególnych typów ED. Podobne badanie przeprowadzili Vijayalakshmi i Vidhya [104]. Autorzy wykorzystali różne algorytmy drzew decyzyjnych do przewidywania rodzaju zaburzenia występującego u pacjentów. W badaniu wykorzystano dane od 55 osób zbierane na przestrzeni 4 lat. Każda obserwacja była opisana przez zestaw 16 parametrów obejmujących między innymi masę ciała, regularność miesiączki, zachowania żywieniowe, społeczne i psychologiczne. Najwyższą skuteczność osiągnął algorytm ID3 (klasyczny algorytm indukcji drzew decyzyjnych), którego skuteczność klasyfikacji wyniosła 67%, przewyższając zarówno algorytm J48 (ulepszona wersja algorytmu C4.5), jak i Random Tree, które uzyskały odpowiednio 49% i 47%. Uzyskane wyniki należy uznać za stosunkowo niskie. Ograniczona skuteczność mogła wynikać z małej próby lub źle dobranych parametrów drzewa jak i analizowanych atrybutów, którymi zostały opisane dane. W analizie Xie przedstawiono zastosowanie klasyfikacyjnych drzew decyzyjnych do przewidywania ryzyka anoreksji na podstawie wybranych pięciu wskaźników fizjologicznych [105]. Wyniki wykazały, że najwyższe prawdopodobieństwo anoreksji wiązało się z takimi cechami, jak "*twardość wątroby*"oraz "*wyczuwalna śledziona*". Model drzewa decyzyjnego osiągnął najwyższą skuteczność spośród porównywanych algorytmów, gdzie skuteczność osiągnęła wartość 89%, co jest wysokim wynikiem. Jednakże autor ma świadomość ograniczeń jego badań (np. mała liczba próbek) i konieczności dalszych prac nad ulepszaniem modeli predykcyjnych w obszarze zaburzeń odżywiania. Jak pokazali Benítez Andrades i wsp., las losowy może skutecznie wspierać analizę treści publikowanych na Twitterze w kontekście zaburzeń odżywiania [106]. Uzyskane skuteczności mieściły się w zakresie od 73,7% do 80,4%. Najlepszy wynik (80,4%) uzyskano dla podziału tweetów na naukowe i nienaukowe, a niższe wartości dotyczyły klasyfikacji wpisów informacyjnych (73,7%), treści promujących ED (76,7%) oraz identyfikacji tweetów autorstwa osób z ED (79,2%). W badaniu Zeeshan i wsp.

porównano skuteczność kilku popularnych algorytmów klasyfikacyjnych, takich jak: drzewa decyzyjne, las losowy, KNN (model k Nearest Neighbors - prosty model klasyfikacji, który przypisuje etykietę na podstawie *k najbliższych sąsiadów* w przestrzeni cech) oraz Naive Bayes (klasyfikator probabilistyczny oparty na twierdzeniu Bayesa) aby sprawdzić, który najlepiej rozpoznaje stopnie otyłości na podstawie informacji o wadze, wzroście, stylu odżywiania, aktywności i uwarunkowaniach rodzinnych [107]. Pośród analizowanych algorytmów to metody drzewiaste osiągnęły najwyższą skuteczność: 98,33% dla drzewa decyzyjnego i 98,27% dla lasu losowego, potwierdzając ich wysoką użyteczność w zadaniach diagnostycznych. Wyniki te podkreślają przewagę algorytmów drzewiastych nad prostymi wskaźnikami, takimi jak BMI, ponieważ umożliwiają uchwycenie wielowymiarowych wzorców obecnych w danych, dzięki czemu stanowią wartościowe narzędzie w analizie klinicznej otyłości.

Choć zastosowania drzew decyzyjnych i lasów losowych w diagnostyce zaburzeń odżywiania, w tym anoreksji, pozostają stosunkowo nieliczne, to algorytmy te znajdują również zastosowanie w innych obszarach medycyny. Przykładem może być praca Abou-Warda i wsp., którzy wykorzystali model lasu losowego do klasyfikacji pacjentów z zaburzeniami psychicznymi i uzależnieniami [108]. Co istotne, oprócz wysokiej skuteczności klasyfikacji, model pozwolił wyodrębnić najbardziej istotne zmienne z klinicznego punktu widzenia. Mathur i wsp. dokonali przeglądu zastosowań drzew decyzyjnych w predykcji różnych chorób takich jak: cukrzyca, choroby serca, czy diagnostyka nowotworów [109]. Algorytm lasu losowego został również wykorzystany do przewidywania skuteczności chemio-radioterapii u pacjentek z zaawansowanym rakiem szyjki macicy. W badaniu Liu i wsp. wyodrębniono 106 cech radiomicznych z obrazów MR T2-zależnych. Autorzy badali również wpływ i dobór parametrów samego modelu. Najlepszy wariant lasu losowego uzyskał skuteczność na poziomie 0.914, co potwierdza jego wysoki potencjał kliniczny [110]. Ponadto pokazali, że odpowiedni dobór liczby drzew, kryteriów podziału i minimalnej liczby próbek w węźle znacząco wpływa na jakość predykcji.

Analiza literatury wskazuje, że sieci neuronowe są stosowane do różnych celów w obszarze zaburzeń odżywiania, wykazując wysoką skuteczność w zadaniach klasyfikacyjnych i predykcyjnych. Ghosh i wsp. w swojej przeglądowej pracy dokonali kompleksowej analizy zastosowań algorytmów sztucznej inteligencji i uczenia maszynowego w badaniach w obszarze zaburzeń odżywiania [111]. Buscema i wsp. podjęli się próby opracowania narzędzia, które mogłoby być wykorzystywane przez lekarzy niebędących specjalistami psychiatrii w celu wczesnego rozpoznania pacjenta z ED i skierować go na odpowiednie leczenie. W tym celu wykorzystali autoasocjacyjne sztuczne sieci neuronowe (ang.: Autoassociative Neural Network, AANN). Grupę badawczą stanowiły 172 pacjentki, które pogrupowano wg konkretnego rodzaju zaburzeń odżywiania, z którym się zmagają (np. anoreksja, bulimia itd.) Każda pacjentka była opisana przez 124 różne zmienne. Zaproponowany algorytm osiągnął 86,94% skuteczności [111, 112]. W badaniu przeprowadzonym przez zespół Bernardoniego wykorzystano algorytm maszyny wektorów nośnych oraz sieci neuronowe do analizy obrazów MRI mózgu pacjentek z anoreksją (570 osób) oraz osób zdrowych (739 osób). Autorzy artykułu wykazali, że zastosowane modele oparte na wielowymiarowych cechach morfologicznych pozwalają skutecznie odróżnić osobę chorą od zdrowych. Wartość pola

pod krzywą ROC (ang.: Area Under the Curve, AUC) w ich badaniu wahała się od 0,75 - 0,81 [113]. Z kolei Spinczyk i wsp. zastosowali rekurencyjne sieci neuronowe (ang.: Recurrent Neural Networks, RNN) w zadaniu polegającym na automatycznej analizie sentymentu wypowiedzi w języku polskim, pochodzących od kobiet chorych na anoreksję [111, 114]. Opracowany model osiągnął skuteczność na poziomie 72%. Levinson i wsp. wykorzystali płytkie sieci neuronowe do przewidywania wystąpienia objawów chorobowych nawet do 12 godzin przed na podstawie codziennych raportów z życia pacjentów [111, 115]. Feldman zastosował sieci neuronowe do identyfikacji pro-anorektycznych i pro-bulimicznych grafik w mediach społecznościowych [111, 116].

Mimo że zastosowanie sztucznych sieci neuronowych w obszarze zaburzeń odżywiania jest wciąż niszowe m.in. ze względu na wymóg posiadania dużych zbiorów danych, to w innych gałęziach medycyny znajdują szerokie zastosowanie. Abdullahi i Sathasivam połączyli architekturę sztucznej sieci neuronowej typu wielowarstwowy perceptron (MLP) z maszyną wektorów nośnych (SVM) w celu wczesnej diagnostyki medycznej i analizy predykcyjnej w ochronie zdrowia [117]. Zhong i wsp. zaproponowali model głębokiego uczenia (oparty na architekturze Res-MLP), który został wykorzystany do segmentacji guza, klasyfikacji gęstości tkanki gruczołowej oraz do ocenia złośliwość zmian raka piersi na podstawie mammografii [118]. Al-Shayea wykorzystał sieci neuronowe typu feed-forward trenowane algorytmem wstecznej propagacji błędu do wspierania diagnostyki w przypadku ostrego zapalenia nerek oraz w diagnostyce chorób serca, osiągając odpowiednio 99% i 95% poprawnych klasyfikacji [119]. W badaniu opublikowanym przez Abdullaha przedstawiono zmodyfikowaną strukturę sztucznej sieci neuronowej o nazwie EMLP (Enhanced Multilayer Perceptron), która została wykorzystana do wczesnego wykrywania schorzeń układu sercowo-naczyniowego, osiągając skuteczność równą 92% [120]. W celu poprawy diagnostyki stopnia zaawansowania choroby Alzheimera, Kumar i Sasikala, wykorzystując dane pozyskane z obrazów rezonansu magnetycznego, zaproponowali wieloetapowe podejście hybrydowe, łączące głębokie sieci neuronowe z tradycyjnymi klasyfikatorami [121]. W badaniu przeprowadzonym przez Zou i wsp. zaproponowano nowatorskie podejście do prognozowania czasu pobytu pacjenta w szpitalu, wykorzystując zmodyfikowaną głęboką sieć neuronową (ang.: Deep Neural Network, DNN) [122].

Przegląd literatury wyraźnie pokazuje, że algorytmy uczenia maszynowego znajdują szerokie zastosowanie w różnych obszarach medycyny, także w kontekście zaburzeń odżywiania. Modele opisane w analizowanych pracach często osiągają bardzo wysoką skuteczność, co potwierdza zasadność wykorzystywania tych metod w analizie danych medycznych. Jednocześnie należy podkreślić, że jakość predykcji zależy nie tylko od samego algorytmu, lecz również od odpowiedniego doboru jego parametrów oraz właściwego doboru atrybutów opisujących dane wejściowe. Co szczególnie istotne, w przeprowadzonym przeglądzie nie odnaleziono badań, które łączyłyby wykorzystanie technik drzewiastych, regresji liniowej lub sieci neuronowych z analizą treści odnoszących się do specyficznych obszarów trudności doświadczanych przez osoby chorujące na anoreksję i inne zaburzenia odżywiania. Można zatem przypuszczać, że połączenie modeli uczenia maszynowego z kluczowymi obszarami trudności mogłoby stanowić podstawę do stworzenia wartościowego narzędzia wspierającego diagnostykę i planowanie leczenia w obszarze zaburzeń odżywiania.

2.4 Metody wykorzystywane do analizy wypowiedzi pisemnych

Wypowiedzi ludzi dostarczają wielu informacji, a w grupie osób chorujących na zaburzenia odżywiania, w tym na anoreksję, mogą one stanowić ważne źródło danych o przebiegu choroby - niezależnie od tego, czy pochodzą z sieci, forów czy materiałów klinicznych. Odkąd rozwój NLP, metod słownikowych i modelowania tematycznego umożliwił automatyczne wykrywanie konkretnych tematów i wzorców w tekście, notuje się wzrost znaczenia analizy języka jako narzędzia analitycznego. To właśnie język pokazuje, jak choroba wpływa na sposób opisywania doświadczeń związanych z ciałem, emocjami i relacjami z ludźmi. Współczesne badania zwracają uwagę, że metody automatycznej analizy języka mają istotną wartość diagnostyczną. Mogą służyć zarówno do monitorowania zmian w nasileniu objawów i oceny ryzyka w środowisku, jak i do uchwycenia emocji przejawiających się w sposobie pisania [123]. Ta zależność sprawia, że analiza tekstu staje się ważnym źródłem danych o kondycji psychicznej pacjenta. Niniejszy rozdział prezentuje przegląd tych rozwiązań.

W badaniach nad anoreksją szczególną uwagę poświęca się wczesnej identyfikacji charakterystycznych słów, czy tematów związanych z tą chorobą w wypowiedziach osób zagrożonych i cierpiących [123]. Podstawę stosowanych metod stanowią klasyczne modele reprezentacji tekstu (TF-IDF) oraz słowniki psycholingwistyczne, takie jak LIWC, uzupełniane o słowniki dedykowane zaburzeniom odżywiania. Merhbene i wsp. zwracają uwagę na szereg wyzwań i luk badawczych w obszarze wykorzystania metod NLP i eksploracji tekstu w analizie zaburzeń odżywiania. Autorzy podkreślają, że dotychczasowe badania w przeważającej mierze opierają się na materiałach anglojęzycznych. Jedynie około 7% prac uwzględnia inne języki. Dodatkowo aż około 93% analiz opiera się na danych z mediów społecznościowych, podczas gdy zasoby kliniczne pozostają marginalne, mimo że ich charakter znacząco różni się od treści internetowych i mógłby dostarczać bardziej pogłębionych informacji diagnostycznych. Autorzy wskazują także na niewystarczające zaangażowanie specjalistów klinicznych oraz brak jednolitych standardów metodologicznych, co utrudnia porównywanie wyników między badaniami i pokazuje, że dziedzina ta wciąż znajduje się na etapie intensywnego rozwoju. Dotychczasowe prace koncentrują się głównie na wykrywaniu anoreksji jako jednego zaburzenia, podczas gdy rzadziej analizują szczegółowe, klinicznie istotne obszary trudności. Jednocześnie, jak zauważają autorzy, liczba publikacji w ostatnich latach wyraźnie rośnie, co świadczy o rosnącym zainteresowaniu tą tematyką w środowisku naukowym. Chopra i wsp. przeprowadzili analizę postów z Reddita, łącząc klasyczną eksplorację tekstu ze słownikami tematycznymi, modelowaniem tematów (LDA) oraz wsparciem dużych modeli językowych (ang.: Large Language Model, LLM), aby wydobyć najczęściej poruszane wątki [124]. Twórcami wpisów w przeważającej większości były osoby zmagające się z ED (około 70%) oraz ich bliscy. Wyniki wykazały, że najczęściej poruszano temat dotyczący obrazu i masy ciała, emocji (np. poczucia winy), a także relacji społecznych i szerzej rozumianego funkcjonowania zarówno u osób chorujących, jak i ich rodzin. W pracy Cliffe i wsp. [125] wykorzystano narzędzia oparte na regułach i słownikach, aby automatycznie wykrywać w notatkach klinicznych odniesienia do autoagresji i myśli samobójczych u pacjentów z zaburzeniami odżywiania. Autorzy wykazali, że takie narzędzia skutecznie wyłapują istotne informacje, dlatego

nadają się do monitorowania określonych treści w dokumentacji. Dobrym przykładem zastosowania metod słownikowych w analizie wypowiedzi osób z anoreksją jest badanie Ramíreza-Cifuentesa i wsp. [126]. Autorzy przygotowali model, który wykrywa wczesne sygnały AN w postach z Reddita, wykorzystując słownik LIWC oraz zestaw predefiniowanych słowników obejmujących m.in. obraz ciała, jedzenie, restrykcje kaloryczne, objadanie się i zachowania kompensacyjne. Dopełnieniem analizy były tematy wydobyte metodą LDA. Wyniki jednoznacznie wskazały, że podejścia słownikowe połączone z klasycznymi technikami NLP umożliwiają trafne identyfikowanie treści wskazujących na problemy charakterystyczne dla anoreksji. W innym z badań wykorzystano podejście słownikowe do analizy dużego zbioru wypowiedzi użytkowników Reddita [127]. Stworzono listy terminów dotyczących jedzenia, ciała i aktywności fizycznej, a następnie porównano ich częstość występowania w społecznościach pro ED (społeczności, które wspierają i promują zachowania związane z zaburzeniami odżywiania) i pro recovery (społeczności wspierające zdrowienie). Okazało się, że grupy pro ED częściej używały słów związanych z kontrolą wagi i monitorowaniem aktywności, natomiast społeczności recovery (grupy wsparcia) częściej odnosiły się do procesu zdrowienia. Badanie to pokazuje, że metody słownikowe stanowią skuteczny sposób identyfikowania specyficznych obszarów tematycznych w narracjach osób z zaburzeniami odżywiania, a także mogą być wykorzystane do wykrywania różnic w profilu trudności między różnymi grupami użytkowników. Innym przykładem wykorzystania NLP w analizie wypowiedzi osób z anoreksją jest praca Rojewskiej w wsp. [128]. W badaniu zastosowano metody słownikowe oraz klasyczne techniki przetwarzania języka, które umożliwiły automatyczne identyfikowanie treści związanych m.in. z funkcjonowaniem ciała, zachowaniami autoagresywnymi czy postrzeganiem siebie w relacjach społecznych. Uzyskane wyniki potwierdzają, że rozwiązania oparte na analizie języka mogą skutecznie wydobywać istotne klinicznie informacje i stanowią wartościowy element rozwijającego się nurtu badań nad narracjami osób z zaburzeniami odżywiania. Odmienne podejście zastosowali Rujas i wsp. [129]. Ich rozwiązanie nie wykorzystywało z góry zdefiniowanych słowników pod konkretne tematy. Zastosowali modelowanie tematów BERTopic. Ponieważ modelowanie tematów służy odkrywaniu tematów w danych, algorytm sam identyfikował, o czym piszą użytkownicy, bez narzucania z „góry" konkretnej kategorii. Celem było zbudowanie narzędzia, które automatycznie rozpoznaje czy wiadomość z Telegrama pochodzi od osoby z ED oraz szacuje prawdopodobieństwo występowania zaburzeń odżywiania. Wyniki pokazały, że zaproponowane podejście skutecznie przewiduje obecność zaburzeń odżywiania na podstawie krótkich tekstów, wspierając ideę wykorzystania NLP jako narzędzia do wczesnej identyfikacji ryzyka. W literaturze bardzo dużą grupę stanowią prace wykorzystujące NLP w kontekście zaburzeń odżywiania ukierunkowane nie na identyfikację konkretnych obszarów trudności, lecz na wykrywanie wpisów sugerujących bezpośrednie ryzyko. W badaniu Yan i wsp. [130] przeanalizowano posty pochodzące z kilku forów dyskusyjnych z platformy Reddit dotyczących zaburzeń odżywiania. Celem była ocena, czy na podstawie ich treści można automatycznie wykrywać wpisy wskazujące na pilną potrzebę interwencji specjalisty. Autorzy wykorzystali klasyczne techniki NLP oraz różne warianty uczenia maszynowego. Co istotne, tylko 53 etykietowane przykłady wystarczyły, by najlepsze algorytmy uzyskały poziom 4% błędu. Wynik ten potwierdza, że nawet skromny zasób danych uczących pozwala budować narzędzia do wczesnego wychwytywania treści wymagających pilnej reakcji klinicznej. Kolejnym przykładem są

badania opublikowane przez Sarangi i wsp. [131], którzy również wykorzystując różnorodne techniki eksploracji tekstu oraz duże modele językowe (LLM) analizowali posty użytkowników Reddita w celu odróżnienia osób z oznakami anoreksji od grupy kontrolnej. Uzyskane wyniki stanowią istotne uzupełnienie literatury. Wskazują, że NLP może służyć wczesnej detekcji ryzyka, jednak nie dostarczają informacji o poruszanych w wypowiedziach pacjentów obszarach trudności.

Dopełnienie przeglądu literatury stanowią prace nad tworzeniem słowników tematycznych dla obszarów trudności wspólnych dla różnych grup pacjentów. W artykule Różańskiej i wsp. [132] przedstawiono wyniki pracy nad automatycznym wykrywaniem obszarów trudności takich jak: obraz ciała, ból oraz samoocena w narracjach pacjentów żywionych dojelitowo z rakiem głowy i szyi lub rakiem górnego odcinka przewodu pokarmowego. Pacjenci reprezentowali trzy grupy związane ze stadium choroby: stadium I, stadium II lub pacjenci paliatywni. Metodyka zastosowana w badaniu opierała się na klasycznym podejściu wykorzystywanym w analizie tekstu: po etapie wstępnego przetwarzania notatek przygotowano ich reprezentację w postaci wektorowej, a następnie zbudowano macierz częstości. Kolejnym krokiem była redukcja wymiarowości z użyciem SVD w ramach Latent Semantic Analysis, co pozwoliło na wyodrębnienie struktur semantycznych. Dla każdego obszaru trudności zastosowano także odpowiednie słowniki słów kluczowych - w przypadku obrazu ciała i samooceny o polaryzacji pozytywnej i negatywnej, a dla bólu słownik był tylko negatywny. W wynikach „obraz ciała"i „samoocena"uzyskały wysoką zgodność z oceną ekspercką (np. obraz ciała: 82% zgodności w stadium I, 75% w stadium II, 86% w opiece paliatywnej; samoocena: odpowiednio 64%, 87% i 71%), natomiast „ból"okazał się najłatwiejszy do automatycznej identyfikacji (100% zgodności w każdym stadium choroby). Dodatkowo, obecność bólu wiązała się z wyższym średnim poziomem negatywnego obrazu ciała, co potwierdza kliniczną sensowność podejścia słownikowo tematycznego do wykrywania obszarów trudności. W ramach innego artykułu przedstawiono wyniki próby identyfikacji tematów: obraz ciała, akceptacji otoczenia i samooceny również wśród pacjentów onkologicznych. Uzyskano wówczas 78% zgodności dla obrazu ciała, 82% dla akceptacji otoczenia oraz 80% dla samooceny [133].

Z analizy literatury wynika, że poszukuje się różnych rozwiązań nad wykorzystaniem analizy tekstu w diagnostyce i leczeniu różnych chorób w tym zaburzeń odżywiania. Ich wyniki są obiecujące, wykazując dużą zgodność z oceną ekspertów psychologów i psychiatrów dokonaną na podstawie ich metod badawczych. Jednocześnie w literaturze widoczny jest niedobór prac koncentrujących się na identyfikacji konkretnych obszarów trudności charakterystycznych dla osób z AN, takich jak obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia lub ból. Co istotne, praktycznie nie występują badania, które obejmowałyby wszystkie te obszary jednocześnie. Wskazuje to na wyraźną lukę badawczą i potwierdza potrzebę rozwijania metod analizy, pozwalających na bardziej całościowe uchwycenie doświadczeń i trudności osób zmagających się z zaburzeniami odżywiania, w tym również z anoreksją.

3. Materiał badawczy i metodyka badań

W rozdziale opisano materiał badawczy poddany analizie oraz przedstawiono wykorzystaną metodykę badań własnych.

Analizowany zbiór danych składa się z wypowiedzi pisemnych osób zdrowych oraz cierpiących na anoreksję. Charakter badanej problematyki sprawia, że pozyskanie materiału badawczego jest trudne z powodu ograniczonego dostępu do pacjentów. W przypadku zaburzeń odżywiania nie istnieją otwarte, zanonimizowane zbiory danych zawierające tego typu dokumenty. Dostęp do specjalistów takich jak psychologowie i psychoterapeuci, którzy mogliby pośredniczyć w pozyskiwaniu takich materiałów, jest mocno ograniczony. Wynika to zarówno z przeciążenia systemu opieki psychiatrycznej i etycznej ochrony procesu leczenia. Również duży wpływ na to ma fakt, że są to teksty niezwykle osobiste, często o głęboko intymnym charakterze. Lęk przed osądzeniem, wstyd, a także silna w anoreksji potrzeba absolutnej kontroli nad własnym sekretem, budują naturalny opór przed pokazywaniem komukolwiek swoich zapisków. Dlatego też posiadany zbiór danych jest relatywnie niewielki. Wykorzystane w pracy wypowiedzi osób chorych i zdrowych zostały pozyskane z wyspecjalizowanego źródła klinicznego z zachowaniem wymaganych zasad anonimowości.

Choć praca dotyczy analizy tekstów osób cierpiących na anoreksję, w rozdziale tym przedstawiono również dwa dodatkowe tekstowe zbiory danych. Notatki te pochodzą od osób cierpiących na nadwagę lub otyłość oraz zmagające się z nowotworami górnego przewodu pokarmowego lub głowy i szyi. Dane te wykorzystano do sprawdzenia jak zaproponowane metody badań, które pierwotnie były opracowane dla osób cierpiących na anoreksję, poradzą sobie w przypadku innych schorzeń. Grupy te łączy to, że pacjenci w obu przypadkach również mają trudności z akceptacją i postrzeganiem własnego ciała.

Analiza wypowiedzi pacjenta, pozwala na bieżąco monitorować jego stan psychiczny i precyzyjnie wskazać moment, w którym potrzebuje on profesjonalnego wsparcia. Ponadto może to umożliwić psychologom zorientować się, w jakiej fazie akceptacji choroby znajduje się chory oraz z jakim konkretnie problemem (np. ból, niska samoocena, zniekształcony obraz własnego ciała) mierzy się w danym momencie.

W pracy zdecydowano się wykorzystać hybrydowe podejście, które łączy klasyczne metody przetwarzania języka naturalnego, metodę LSA opartą na rozkładzie według

wartości osobliwych (SVD) oraz algorytmy uczenia maszynowego w postaci: regresji logistycznej, drzew decyzyjnych, lasów losowych oraz sieci neuronowych. Zastosowanie takiego podejścia wynika bezpośrednio ze specyfiki analizowanego problemu, charakterystyki posiadanego zbioru danych oraz celu badań.

Tematyka pracy wymaga integracji wiedzy eksperckiej z analizą semantyczną. Zastosowanie reprezentacji worka słów, z których powstała macierz częstotliwości, a następnie metody LSA opartej na SVD pozwala na uchwycenie ukrytych powiązań semantycznych, redukując jednocześnie bardzo dużą wymiarowość tekstów. Kluczowym elementem jest zastosowanie metody słownikowej, która pozwala na wykorzystanie wiedzy eksperckiej. Słowniki reprezentują obszary trudności, które są kluczowe z punktu widzenia diagnostyki i leczenia zaburzeń odżywiania, w tym anoreksji. Zastosowanie takiego podejścia pozwala na wykrycie danego tematu w notatce oraz ilościowe określenie jego natężenia w wypowiedzi (np. pozytywnego i negatywnego obrazu ciała). Uzyskany wynik jest niezbędny do ostatecznego stwierdzenia, czy analizowany obszar został w niej rzeczywiście poruszony.

Niewielki rozmiar próby uniemożliwia efektywne wykorzystanie nowoczesnych modeli językowych opartych na architekturze transformerów (np. HerBERT). Ponieważ jednak w badaniach z pogranicza medycyny i psychologii kluczowe jest zrozumienie procesu decyzyjnego, w pracy przyjęto wieloetapowe podejście analityczne, które łączy metody interpretowalne z bardziej zaawansowanymi modelami, które są „czarnymi skrzynkami". W pierwszym etapie wykorzystano model regresji logistycznej, którego zadaniem było wychwycenie istotnych predyktorów. Następnie zastosowano model drzewa decyzyjnego, który ze względu na przejrzystość i łatwość interpretacyjną pełnił głównie funkcję eksploracyjną. Wykorzystanie tego modelu pozwoliło na wyłonienie reguł decyzyjnych, analizę uzyskanych klastrów oraz wyodrębnienie spośród nich klastrów wysokiego ryzyka. Grupowały one notatki autorstwa osób chorych, umożliwiając tym samym opisanie specyficznych profili tekstowych wypowiedzi i ich łatwiejszą identyfikację. W kolejnych krokach, w celu uzyskania jak najwyższej skuteczności klasyfikacji, wykorzystano dwa klasyfikatory: las losowy oraz sieć neuronową.

3.1 Materiał badawczy

Główny materiał badawczy analizowany w niniejszej pracy stanowią notatki osób chorych na anoreksję oraz osób zdrowych. Ich szczegółowa charakterystyka została przedstawiona w rozdziale 3.1.1. W celu zweryfikowania uniwersalności oraz elastyczności wypracowanej metodyki, podjęto próbę jej aplikacji do analizy tekstów pochodzących od innych grup pacjentów, które zostały opisane w rozdziale 3.1.2.

3.1.1 Główny zbiór danych

Materiał badawczy w postaci polskojęzycznych wypowiedzi pisemnych o rożnej długości pozyskano we współpracy z Samodzielnym Publicznym Szpitalem Klinicznym Nr 1 im. prof. Stanisława Szyszko Śląskiego Uniwersytetu Medycznego w Katowicach. W początkowej fazie badań materiał obejmował 96 dokumentów tekstowych, który zawierał 44 notatki sporządzone przez osoby chore na anoreksję i 52 notatki

napisane przez osoby zdrowe. Uczestników poproszono o pisemną wypowiedź na temat własnego ciała w odpowiedzi na pytanie: *„Jak postrzegasz swoje ciało?”*. Badani mieli pełną swobodę w formułowaniu tekstu i nie narzucano im żadnych dodatkowych kryteriów. W tabeli 3.1 przedstawiono przykłady kilku z nich w pisowni oryginalnej. W toku prac nad rozprawą doktorską zbiór danych został rozszerzony o dodatkowe dane, w tym 71 notatek osób chorych na anoreksję oraz 34 notatki osób zdrowych, sumarycznie tworząc zbiór 201 notatek (115 od osób cierpiących na anoreksję i 86 od osób zdrowych).

Doboru uczestników badania dokonano w oparciu o następujące kryteria:

- Grupa osób chorych:
  - formalne rozpoznanie anoreksji postawione przez lekarza psychiatrę (kody ICD-10: F50.00-F50.08),
  - wiek w przedziale od 12 do 19 lat,
  - czas od momentu postawienia diagnozy nieprzekraczający 3 lat,
  - brak współwystępujących zaburzeń psychicznych.
- Grupa osób zdrowych:
  - wiek w przedziale od 12 do 19 lat,
  - brak zdiagnozowanych zaburzeń psychicznych.

W tabeli 3.2 przedstawiono charakterystykę antropometryczną badanych grup. Zgodnie ze stanowiskiem Komisji Bioetycznej, prowadzone badanie nie stanowiło eksperymentu medycznego, w związku z czym uzyskanie formalnej opinii etycznej nie było konieczne. Od wszystkich osób biorących udział w badaniu pozyskano świadomą zgodę.

Tabela 3.1: Wybrane notatki

Wybrane notatki autorstwa osób chorych na anoreksję	**Wybrane notatki autorstwa osób zdrowych**
Ja mam taki trochę władczy charakter, ma być tak jak ja mówię. I najczęściej, kiedy mi coś nie wychodziło, karałam siebie… Jeśli coś nie działo się po mojej myśli, to wyładowywałam to na swoim ciele. Zawsze. Albo poprzez wymioty, albo poprzez chudnięcie, albo poprzez ranienie się.	Jestem zadowolony z mojego ciała. Jestem wysoki i dość dobrze zbudowany. Mimo lekkiej otyłości jestem z niego zadowolony. Noszę się z nim dumnie.
Moje ciało: zakompleksione obwisła skóra tłuszcz na nogach i brzuchu zaniedbane włosy wypryski na twarzy rozstępy nieidealne sucha i zniszczona skóra brzydki	ładne zgrabne lubię i w ogóle wysportowane szczupłe wysokie proporcjonalne trochę krzywe (szpotawe kolana, nie polecam) minimalnie pryszczate, ale da się przeżyć często boli ale i tak zajebiste

Tabela 3.2: Charakterystyka antropometryczna badanych grup

Parametr	**Grupa kliniczna**	**Grupa kontrolna**
Płeć	100% kobiety	100% kobiety
Wiek [lata] ($M \pm SD$)	$15{,}7 \pm 2{,}0$	$15{,}1 \pm 1{,}9$
Masa ciała [kg] ($M \pm SD$)	$35{,}1 \pm 4{,}7$	$57{,}1 \pm 10{,}1$
Zakres BMI [kg/m^2]	11,3-20,2	16,5-25,8
Średnie BMI [kg/m^2] ($M \pm SD$)	$15{,}1 \pm 2{,}8$	$21{,}5 \pm 3{,}4$

Objaśnienia: M - średnia arytmetyczna; SD - odchylenie standardowe; BMI - wskaźnik masy ciała (ang.: Body Mass Index).

3.1.2 Dodatkowe zbiory danych

Pierwszy dodatkowy zbiór danych obejmował notatki 50 pacjentów (26 kobiet, 24 mężczyzn; w wieku: średnia 57,0 ± 11,2 lat, zakres 25 - 75) hospitalizowanych i żywionych dojelitowo z powodu nowotworu głowy i szyi lub górnego odcinka przewodu pokarmowego. Badanych zakwalifikowano do trzech grup, które związane były z czasem trwania choroby (stadium 1, stadium 2, opieka paliatywna). Zbiór pozyskano w trakcie bezpośrednich wywiadów prowadzonych na oddziale. Uczestnicy odpowiadali na pytanie: „Jak postrzegasz swoje ciało?". W razie potrzeby zadawano pytanie doprecyzowujące. Przykładowe notatki zamieszczono w tabeli 3.3. Badanie przeprowadzono zgodnie z Deklaracją Helsińską, za świadomą zgodą wszystkich uczestników oraz po uzyskaniu akceptacji Komisji Bioetycznej przy Centrum Medycznym Kształcenia Podyplomowego w Warszawie (nr 116/2018 z dnia 14 lipca 2021 r.).

Tabela 3.3: Przykładowe wypowiedzi pisemne osób, u których zdiagnozowano raka górnego odcinka przewodu pokarmowego lub głowy i szyi

Moje ciało wiele przeszło. Jestem chudy i wyniszczony. Bardzo męczą mnie podstawowe czynności. Nie jestem zadowolony z mojego ciała. Skóra jest sucha i przeźroczysta. Mam liczne rany po różnych zabiegach. Kości są bardzo widoczne, dlatego myślę że jestem nieatrakcyjny.
Postrzegam swoje ciało jako delikatne i wrażliwe, a jednocześnie silne i wytrzymałe. Choroba okrutnie trawi moje ciało. Ból i strach mnie nie opuszczają. Akceptuje moje ciało, chociaż boję się, że mnie zawiedzie.
Moje ciało jest dobre. Zawsze podnosi się po chorobie. Jestem pełna nadziei, że tym razem również wyzdrowieję, a lekarze będą w stanie mi pomóc. Obecnie wyglądam źle. Zawsze byłam bardzo zadbana. Włosy i paznokcie zrobione. Pięknie się ubierałam. W szpitalu nie mam siły i ochoty o siebie zadbać. Wyglądam strasznie ponuro i niezdrowo. Wszystko przez chorobę.

Drugi zbiór danych obejmował 45 notatek kobiet, które uczestniczyły w trzymiesięcznym programie dietetycznym, które miały BMI większe lub równe 25,0 kg/m^2 (średnio 30,8±4,3 kg/m^2), w wieku od 18 do 60 lat (średnio 44,9±8,0 lat). Uczestniczki miały odpowiedzieć na pytanie: „Jak postrzegasz swoje ciało?". Wśród nich 23 dokumenty tekstowe pochodziły od osób z nadwagą (BMI w przedziale $25{,}0 - 29{,}9$ kg/m^2, średnio $27{,}3 \pm 1{,}7$ kg/m^2), a 22 od osób z otyłością (BMI $\geq$ 30,0 kg/m^2, średnio

$34{,}1 \pm 3{,}4$ kg/m^2). Średnia zmiana masy ciała uczestniczek po programie wyniosła $-2{,}4 \pm 3{,}3$ kg. Teksty sporządzano przed przystąpieniem do programu i po jego zakończeniu. Badanie zostało przeprowadzone w Katedrze Dietetyki Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie i uzyskało pozytywną opinię Komisji Etyki Instytutu Nauk o Żywieniu Człowieka SGGW (uchwała nr 09/2021). Przykładowe notatki zamieszczono w tabeli 3.4.

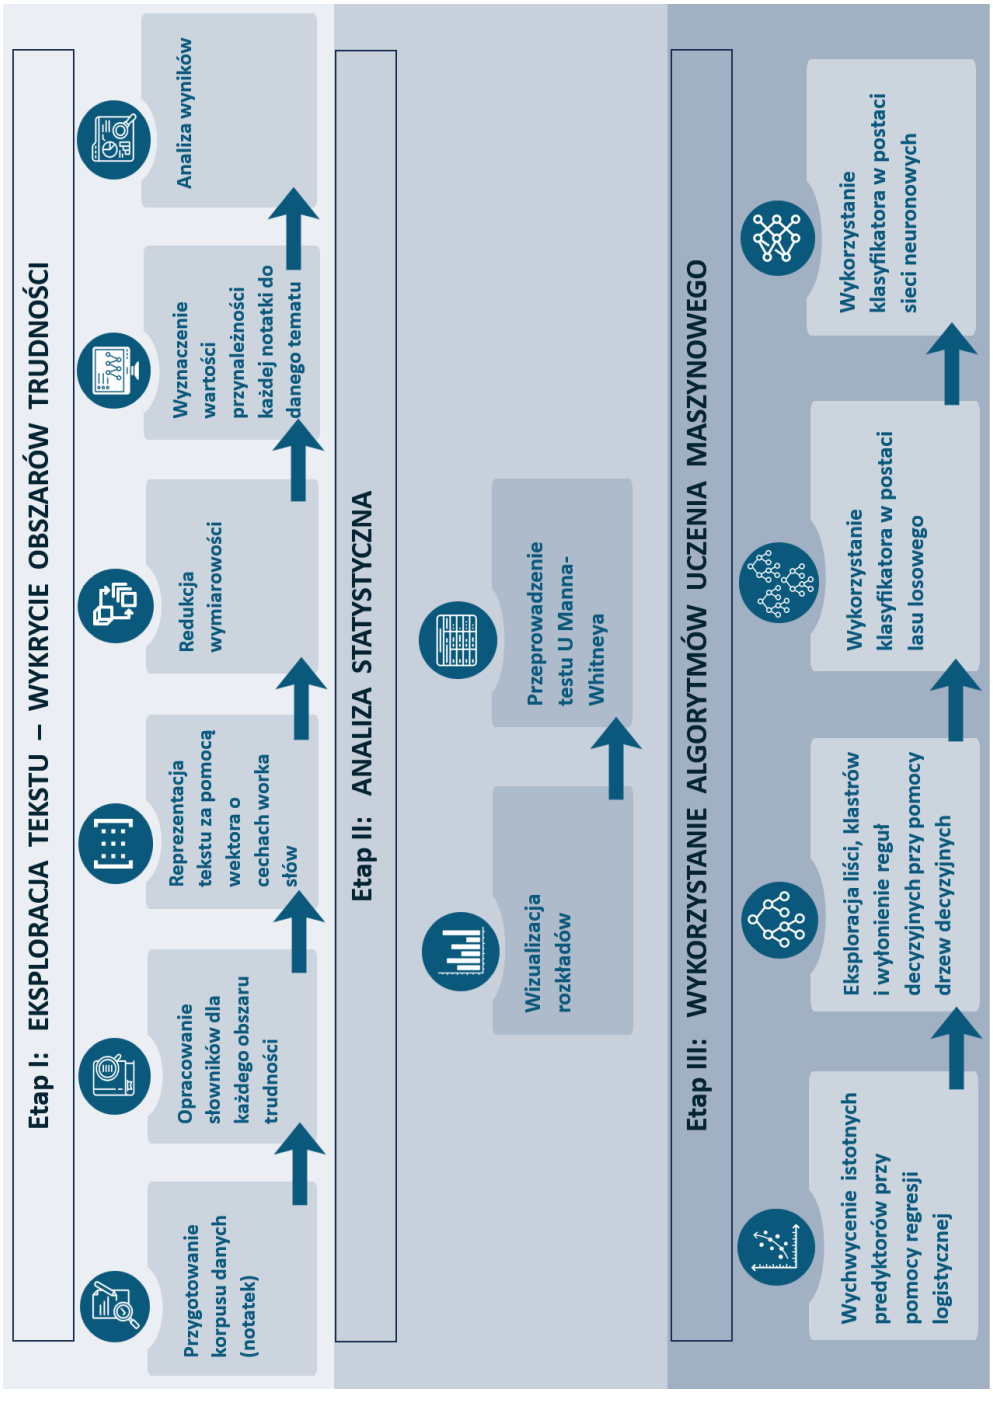
Tabela 3.4: Przykładowe wypowiedzi pisemne osób z nadwagą lub otyłością przed i po udziale w programie dietetycznym.

Przed programem	**Po programie**
Osoby z nadwagą	
Moje ciało wygląda jak napompowana gruszka z nogami jak kolumny	Jeszcze długa droga przede mną do postrzegania siebie w superlatywach, ale jestem na dobrej drodze.
Mam kompleksy, odkąd pamiętam. Wszystkie kobiety w mojej rodzinie są niewysokie i raczej grube. Do tego dochodzi cellulit i rozstępy, które zaczęły się pojawiać w okresie dojrzewania a po ciąży jest tylko gorzej. Nie rozbieram się na plaży, staram się odsłaniać jak najmniej ciała. Okresowo potrafię mieć +/- 10kg (w zależności od tego, czy jestem właśnie w trakcie kolejnej diety czy nie).	Negatywnie. Utrata 10kg w rok (zdrowo, ale wolno!) nie zmieniła tego nic a nic. Zresztą utrata masy ciała nie spowodowała utraty centymetrów, więc nie wiem, gdzie się podziały te kilogramy.
Osoby z otyłością	
BMI na granicy normy nie wiem czy to kwalifikuje ale próbuje, jednak otyłość brzuszna 7 kiedyś 4, nie umiem schudnąć od 10 lat po drugiej ciąży a w okręcie ostatnich 2 lat przytyłam 4 kg złe się z tym czuje, dużo się ruszam treningi, praca biurowa, nie potrafię przejść na redukcje tak aby nie stracić mięśni.	Pozytywnie plus jest jeszcze nad czym pracować w procesie czas to szansa na zmiany
Nie lubię swojego brzucha i boczków, brak mięśni coraz bardziej obwisła skóra	Jest szczuplejsze

3.2 Metody badań

Schemat badań własnych przedstawiono na rysunku 3.1. Metodyka zastosowana w pracy wykorzystuje połączenie metod eksploracji tekstu z algorytmami uczenia maszynowego w tym: regresji logistycznej, drzew decyzyjnych, lasów losowych i sieci neuronowych. Przed implementacją wspomnianych algorytmów wykonano statystykę opisową. Etap I objął identyfikację analizowanych obszarów trudności w tekście wykonaną metodą słownikową. Analizie poddano siedem tematów: obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia oraz ból. Etap II obejmował wykonane analizy statystycznej. Etap III związany był z wykorzystaniem algorytmów uczenia maszynowego w tym: regresji logistycznej, drzew decyzyjnych, lasu losowego oraz sieci neuronowych. Szczegółowe omówienie każdego z etapów znajduje

się w kolejnych podrozdziałach.



Rysunek 3.1: Schemat metodyki badawczej (grafika własna).

3.2.1 Etap I - Eksploracja tekstu - wykrycie analizowanych obszarów trudności

Etap ten związany jest z wykryciem analizowanych obszarów trudności w wykorzystanych notatkach. Cały proces składał się z kilku kroków. Pierwszy krok polegał na odpowiednim przygotowaniu korpusu danych. Proces ten jest kluczowy w dalszej analizie. Obejmował korektę błędów ortograficznych, ujednolicenie zapisu wielkich liter, usunięcie znaków interpunkcyjnych oraz lematyzację słów. Wszystkie operacje, poza korektą błędów, zostały wykonane automatycznie przy użyciu dedykowanego skryptu napisanego w Pythonie. Przykład oryginalnej notatki i notatki po zastosowaniu wyżej wymienionych operacji zostały przedstawione w tabeli. 3.5.

Tabela 3.5: Przykłady notatek oryginalnych i notatek po przeprowadzonych operacjach.

Oryginalna notatka	Notatka po przekształceniu
Moje ciało: zakompleksione obwisła skóra tłuszcz na nogach i brzuchu zniszczone włosy wypryski na twarzy rozstępy nieidealne sucha i zniszczona skóra nieatrakcyjne. Myśląc i mówiąc sobie ”moje ciało”w głowie od razu pojawia mi się obraz samej siebie. Siebie sprzed wakacji. Ważącą 100 kg. Dalej siebie taką widzę. Po schudnięciu nie zauważyłam zmiany w odbiciu w lustrze. Uważam, że dalej wyglądam bardzo podobnie jak w wakacje. Wszyscy mówią mi, że się zmieniłam, a ja wciąż mam wrażenie, że postrzegają mnie jako osobę otyłą. Zresztą ja sama się za taką uważam.	mój ciało zakompleksiony obwisły skóra tłuszcz na noga i brzuch zniszczony włos wyprysk na twarz rozstęp nieidealny suchy i zniszczony skóra nieatrakcyjny myśleć i mówiąc się mój ciało w głowa oda raz pojawiać ja się obraz sam się się sprzed wakacje ważący 100 kg dalej się taka widzieć po schudnięcie nie zauważyć zmiany w odbicie w lustr uważać że dalej wyglądać bardzo podobnie jaka w wakacje wszystek mówić ja że się zmienić a ja wciąż mam wrażenie że postrzegać ja jaka osoba otyły zresztą ja sam się za taka uważać
Ja generalnie mojego ciała nie lubię. To znaczy nie uważam, żeby ono było specjalnie atrakcyjne, specjalnie ładne. Raczej mam poczucie takiego skazania na to ciało, które mam. Zawsze bardziej ceniłam w sobie jakieś takie intelektualne wątki niż ciało. Zawsze uważałam, że to, co związane z ciałem, jest jakieś gorsze, krępujące, jakieś takie niższe.	ja generalnie mój ciało nie lubić ten znaczyć nie uważać żeby on być specjalnie atrakcyjny specjalnie ładny raczy mam poczucie taki skazanie na ten ciało który mam zawsze bardzo cenić w się jakaś taki intelektualny wątek niż ciało zawsze uważać że ten ca związany z ciało być jakaś gorsze krępujący jakaś taki niższy
Ja mam taki trochę władczy charakter, ma być tak jak ja mówię. I najczęściej, kiedy mi coś nie wychodziło, karałam siebie… Jeśli coś nie działo się po mojej myśli, to wyładowywałam to na swoim ciele. Zawsze. Albo poprzez wymioty, albo poprzez chudnięcie, albo poprzez ranienie się.	ja mam taka trocha władczy charakter ma bycie taka jaka ja mówić i często kiedy ja coś nie wychodzić karać się jeśli coś nie działo się po mój myśl ten wyładowywać ten na swoim ciało zawsze alba poprzez wymioty alba poprzez chudnięcie alba poprzez ranienie się
Jestem zadowolony z mojego ciała. Jestem wysoki i dość dobrze zbudowany. Mimo lekkiej otyłości jestem z niego zadowolony. Noszę się z nim dumnie.	być zadowolony z mój ciało być wysoki i dość dobro zbudowany mimo lekki otyłość być z on zadowolony nosić się z nim dumnie
zgrabne powabne wysportowane chude wysokie podoba mi się proporcjnalne minimalnie pryszczate	zgrabny powabny wysportowany chuda wysoki podobać ja się proporcjonalne minimalnie pryszczaty

Analizując notatki po przeprowadzonych przekształceniach, należy podkreślić, że dzięki lematyzacji wyeliminowano problem bogatej fleksji języka polskiego. Zróżnicowane końcówki deklinacyjne zostały zredukowane, poprzez sprowadzenie słów do ich wspólnych form.

Następnie niezbędne było przygotowanie słowników tematycznych. Opracowano je samodzielnie, gdyż nie istnieją gotowe słowniki dla analizowanych tematów. Dla każdego obszaru trudności, z wyjątkiem autoagresji i bólu, zaprojektowano dwa zestawy: słowniki terminów pozytywnych oraz słowniki terminów negatywnych. Dla autoagresji i bólu utworzono tylko po jednym słowniku terminów negatywnych, gdyż te tematy występują tylko w tym kontekście. W celu kategoryzacji czy dane słowo dla danego tematu powinno trafić do pozytywnego lub negatywnego słowika skorzystano z bazy NAWL (ang.: Nencki Affective Word List [134]), która zawiera ocenę czy dane polskie słowo kojarzy się pozytywnie, czy negatywnie. Ponieważ baza ta nie zawiera wszystkich słów, listę uzupełniono o brakujące terminy. Każdy słownik został skonsultowany, zweryfikowany i zaakceptowany przez zespół psychologów pod nadzorem kierownika Centralnej Pracowni Psychologii Klinicznej SP Szpitala Klinicznego nr 1 im. Prof. Stanisława Szyszko SUM. Zadaniem ekspertów było potwierdzenie zarówno czy dane słowo rzeczywiście odnosi się do danego tematu (obszaru trudności) jak i jego polaryzacji. Należy podkreślić, że słowniki tematyczne zostały opracowane w sposób w pełni niezależny od analizowanego korpusu danych, co pozwoliło wyeliminować ryzyko naddopasowania leksyki do specyfiki badanej próby. Liczebność słowników przedstawiono w tabeli 3.6, natomiast przykładowe słowa w tabeli 3.7.

Tabela 3.6: Zestawienie liczby słów dla każdego z słowników dla poszczególnych tematów (obszarów trudności).

Obszar trudności	**Liczba słów w słowniku**	
	negatywnym	**pozytywnym**
Obraz ciała	360	291
Emocje	308	191
Samoocena	190	149
Funkcjonowanie ciała	245	137
Autoagresja	192	—
Ból	59	—
Akceptacja otoczenia	134	142

Tabela 3.7: Przykładowe terminy

Obszar trudności	Przykładowe słowa	
	w słowniku z słowami negatywnymi	**w słowniku z słowami pozytywnymi**
Obraz ciała	brzydki, otyły, gruby, straszny, krzywy, odrażający, nieładny, wystawać, wisieć, obrzydliwość, tłuszcz, brzydota, wstrętny, obwisły	zdrowy, ładny, zgrabny, ideał, piękno, umięśniony, piękny, niesamowity, niezwykły, olśniewający, zachwycający, proporcjonalny
Emocje	beznadziejny, bezsilność, dręczyć, frustracja, gniew, nieszczęśliwy, smutek	akceptacja, boski, duma, podziw, podekscytowany, radość
Samoocena	bezwartościowy, dziwactwo, niezadowalająco, potworność	boski, cudowny, ideał, uwielbiając, zadowalająco
Funkcjonowanie ciała	bezsilność, bolesny, kaleka, niedomaganie, pogarszający, wycieńczony	czynny, energiczny, dziarski, mocny, silny, witalność
Autoagresja	autoagresja, brutalnie, głodzić, karać, kaleczyć, krzywdzić, samookaleczanie	—
Ból	ból, bólowy, dolegliwość, cierpienie, opuchlizna, rana	—
Akceptacja otoczenia	krytyka, kpina, niechęć, konflikt, samotność, wykluczenie	bliskość, lojalność, przyjazny, serdeczny

Kolejne kroki analizy obejmujące reprezentację tekstu za pomocą wektora o cechach worka słów, redukcję wymiarowości oraz wyznaczenie wartości przynależności każdej notatki do danego obszaru trudności zrealizowano w środowisku SAS Enterprise Miner. Jest to profesjonalne narzędzie firmy SAS przeznaczone do eksploracji danych i budowy modeli uczenia maszynowego [135, 136].

Przed przedstawieniem tekstu za pomocą wektora o cechach worka słów, usunięto z tekstu słowa występujące na stop liście. Na potrzeby dalszej analizy wykluczono spójniki oraz przyimki, ponieważ nie wnoszą one istotnej wartości w kontekście badanych tematów.

Następnie, mając tak przygotowane dokumenty tekstowe można było je przedstawić za pomocą wektora o cechach worka słów i dokonać jej redukcji wymiarowości. W pierwszej kolejności dokonano wyboru odpowiedniej reprezentacji dokumentów, umożliwiającej dalszą analizę tekstu. Każdą notatkę opisano za pomocą wektora cech zgodnego z koncepcją worka słów, gdzie każdy element odpowiada liczbie wystąpień danego (i)-tego słowa w j-tej notatce. Pozwoliło to określić częstość występowania poszczególnych słów w tekście (f_{ij}). Podejście, które polega na zliczaniu wystąpień słów ma jednak istotną wadę. Faworyzuje dłuższe teksty oraz wyrazy zbyt powszechne, czyli takie, które nie wnoszą istotnych informacji do interpretacji. W celu uniknięcia wystąpienia tego zjawiska wartości w macierzy przeliczono przy użyciu wag lokalno-globalnych [136, 137]:

$$x_{ij} = L(i,j) \times G(i) \tag{3.1}$$

gdzie $L(i,j) = \log(1 + f_{ij})$ stanowi wagę lokalną. Dzięki temu częste powtórzenia tego samego słowa nie zdominują całej notatki, a waga globalna $G(i)$ (oparta na IDF) ogranicza wpływ powszechnych terminów, które nie wnoszą istotnej informacji.

Pozwoliło to utworzyć ważoną macierz częstości X, której wiersze odpowiadają unikalnym słowom, a kolumny reprezentują kolejne dokumenty. W interpretacji geometrycznej macierz X definiuje m-wymiarową przestrzeń, w której każdy wymiar reprezentuje pojedynczy termin. Ze względu na wysoką wymiarowość macierzy, jej bezpośrednia analiza prowadzi do istotnych błędów. Dlatego standardową praktyką w eksploracji tekstu jest redukcja wymiarowości. Operację tą przeprowadzono z użyciem metody Latent Semantic Analysis (LSA) opartej na dekompozycji według wartości osobliwych (SVD) [70, 137].

Dekompozycja macierzy X (równanie 3.2) polega na jej rozkładzie na iloczyn trzech macierzy składowych, z ograniczeniem do k dominujących wartości osobliwych ($k \ll \min(m,\ n)$, gdzie m oznacza liczbę unikalnych słów, a n liczbę unikalnych dokumentów).

$$X \approx U_k S_k V_k^T \tag{3.2}$$

Po wykonaniu operacji SVD i odrzuceniu najmniej istotnych wartości osobliwych, czyli podczas redukcji wymiaru, stare wymiary reprezentowane przez słowa zostają połączone w nowe wymiary tzn. koncepty (tematy). Zastosowana metoda pozwoliła zmniejszyć wymiarowość macierzy, zachowując jej kluczowe informacje, dzięki czemu uzyskana reprezentacja dokładniej odwzorowywała główne relacje między dokumentami i była bardziej użyteczna na kolejnych etapach analizy. Każdy nowy wymiar to wektor, w którym słowa dostają pewne wagi (wartości).

Kluczowym i najważniejszym krokiem metodyki jest etap związany z wykryciem i wyznaczeniem wartości przynależności każdej notatki do danego obszaru trudności, czyli tematu. To właśnie w tym kroku dochodzi nie tylko do detekcji, ale również wyznaczenia wartości liczbowych stopnia poruszenia analizowanych tematów w tekstach. Uzyskane wyniki w tej fazie nie tylko dostarczają informacji ilościowych, ale również zostaną wykorzystane w dalszych etapach opracowanej metodyki.

Analizą objęto 12 tematów:

- Obraz ciała w kontekście pozytywnym.
- Obraz ciała w kontekście negatywnym.
- Emocje w kontekście pozytywnym.
- Emocje w kontekście negatywnym.
- Samoocena w kontekście pozytywnym.
- Samoocena w kontekście negatywnym.
- Autoagresja.

- Ból.
- Funkcjonowanie ciała w kontekście pozytywnym.
- Funkcjonowanie ciała w kontekście negatywnym.
- Akceptacja otoczenia w kontekście pozytywnym.
- Akceptacja otoczenia w kontekście negatywnym.

Dla każdego obszaru tematycznego p przygotowano słownik pojęć kluczowych. W przestrzeni leksykalnej całego korpusu (obejmującego wszystkie unikalne słowa występujące w dokumentach) dany temat reprezentowany jest jako binarny wektor wskaźnikowy $z^{(p)}$. Wektor ten przyjmuje wartość 1 dla słów kluczowych wskazanych w słowniku eksperckim oraz 0 dla pozostałych terminów występujących w korpusie.

W kolejnym kroku wektor słów kluczowych, który reprezentuje dany obszar trudności (temat) odwzorowano w przestrzeni semantycznej wyznaczonej przez dekompozycję SVD. Dany temat to zbiór słów kluczowych. Zestaw ten traktuje się jak sztuczny dokument, a wektor jego współrzędnych w nowej przestrzeni pojęć, czyli profil tematu $q^{(p)}$ wyznaczono za pomocą standardowej metody rzutowania (fold-in) [78]:

$$q^{(p)} = (z^{(p)})^T U_k S_k^{-1} \tag{3.3}$$

Macierz U_k reprezentuje powiązania wyrazów z wyodrębnionymi tematami, a człon S_k^{-1} standaryzuje składowe, wyrównując ich wpływ na końcowy wynik.

Aby spróbować uwzględnić synonimy oraz słowa bliskoznaczne występujące w notatkach, zbadano pokrewieństwo każdego wyrazu z wyznaczonym profilem tematu $q^{(p)}$. Siłę tego powiązania określono za pomocą standardowego podobieństwa kosinusowego w zredukowanej przestrzeni cech [70, 78]:

$$\mathrm{Sim}(t_i, p) = \frac{u_i \cdot q^{(p)}}{||u_i||||q^{(p)}||} \tag{3.4}$$

gdzie u_i oznacza wektor reprezentujący słowo t_i w przestrzeni SVD.

Wartość $\mathrm{Sim}(t_i, p)$ może przyjąć wynik z zakresu: $\in [-1, 1]$. Im wyższy wynik, tym silniej dane słowo wiąże się z badanym tematem. Zatem oznacza to, że w notatce pojawia się to słowo w tych samych kontekstach co pojęcia ze słownika eksperckiego.

Końcową wagę danego słowa w danym analizowany temacie wyznaczono następująco [136]:

$$w_i^{(p)} = \begin{cases} 1{,}0 & \text{dla słów ze słownika bazowego,} \\ \mathrm{Sim}(t_i, p) & \text{dla słów dołączonych automatycznie } (\mathrm{Sim} \geq C_{\mathrm{term}}), \\ 0 & \text{dla pozostałych słów.} \end{cases} \tag{3.5}$$

Do profilu danego tematu $q^{(p)}$ włączono tylko te wyrazy spoza słownika, których wyznaczony współczynnik powiązania przekroczył ustalony próg odcięcia terminów

C_{term}. Próg odcięcia jest dobierany statystycznie na podstawie wag uzyskanych z dekompozycji SVD (jako średnia powiększona o wielokrotność odchylenia standardowego) [136]. Dzięki temu wyrazy o niskich wagach z SVD są odrzucane jako szum informacyjny [70], a do tematu dołączane są wyłącznie pojęcia o najsilniejszym powiązaniu semantycznym. Przyjmując takie podejście, terminy ze zdefiniowanego słownika zachowują najwyższą wagę 1, natomiast słowa dobrane automatycznie przyjmują wagę proporcjonalną do siły swojego związku z tematem.

Po uzyskaniu wektora wag $w^{(p)}$ możliwe jest określenie stopnia natężenia (wartości przynależności) danego analizowanego tematu w notatce. Zatem stopień poruszenia tematu p w j-tym dokumencie (reprezentowanym przez j-tą kolumnę macierzy cech x_j) obliczany jest jako iloczyn skalarny:

$$W_{\text{raw}}(j,p) = (w^{(p)})^T x_j = \sum_{i=1}^{m} w_i^{(p)} x_{ij} \tag{3.6}$$

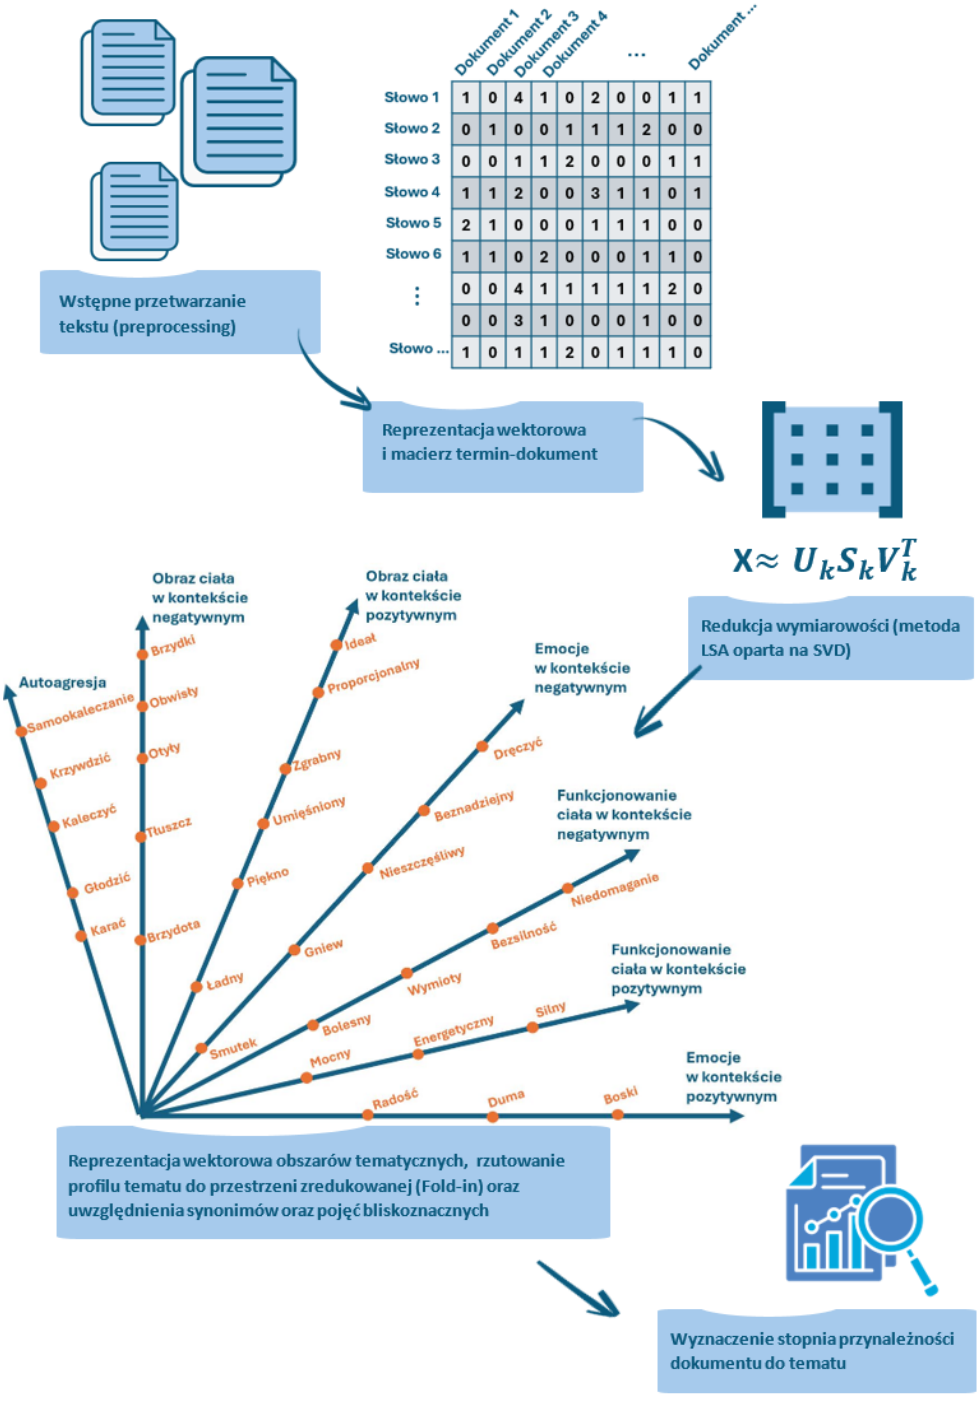
Rozbijając powyższą sumę na składowe wzór prezentuje się następująco:

$$W_{\text{raw}}(j,p) = \sum_{i \in \text{Słownik bazowy}} 1.0 \cdot x_{ij} + \sum_{i \in \text{Słownik słów bliskoznacznych}} \text{Sim}(t_i, p) \cdot x_{ij} \tag{3.7}$$

Wyznaczony wskaźnik $W_{\text{raw}}(j,p)$ stanowi miarę przynależności danego tematu w notatce. Nie przyjmuje on wartości z ograniczonego przedziału $[0,1]$, lecz skalę nieujemną, zależną od liczby i wag pojęć zidentyfikowanych w tekście. Wyższe wartości oznaczają, że w notatce pojawiło się naraz kilka słów kluczowych z słownika lub kilka bliskich odpowiedników, co świadczy, że dany temat był w niej mocno poruszony. Niższe wyniki informują o tym, że w tekście padło mniej słów z utworzonych słowników.

Na potrzeby ostatecznej decyzji czy dany temat został poruszony w danym dokumencie tekstowym, czy po prostu pojawia się jedynie jako marginalny szum konieczne było zastosowanie progu odcięcia dokumentu, który jest dobierany analogicznie jak w przypadku progu odcięcia terminu.

Schematycznie proces ten został przedstawiony na rysunku 3.2.



Rysunek 3.2: Uproszczony schemat zastosowanych operacji (grafika własna).

Zatem w wyniku przeprowadzonej analizy dla każdej notatki otrzymano informacje o:

- Wartości przynależności notatki do tematu obrazu ciała w kontekście negatywnym.
- Wartości przynależności notatki do tematu obrazu ciała w kontekście pozytywnym.
- Wartości przynależności notatki do tematu emocji w kontekście negatywnym.
- Wartości przynależności notatki do tematu emocji w kontekście pozytywnym.
- Wartości przynależności notatki do tematu samooceny w kontekście negatywnym.
- Wartości przynależności notatki do tematu samooceny w kontekście pozytywnym.
- Wartości przynależności notatki do tematu autoagresji.
- Wartości przynależności notatki do tematu ból.
- Wartości przynależności notatki do tematu funkcjonowania ciała w kontekście negatywnym.
- Wartości przynależności notatki do tematu funkcjonowania ciała w kontekście pozytywnym.
- Wartości przynależności notatki do tematu akceptacji otoczenia w kontekście negatywnym.
- Wartości przynależności notatki do tematu akceptacji otoczenia w kontekście pozytywnym.

Na tej podstawie wyróżniono cztery kategorie klasyfikacyjne, stanowiące ostateczny wynik działania metody:

- **Kontekst negatywny** - przypisanie następuje w przypadku przewagi przynależności do kontekstu negatywnego nad pozytywnym, przy czym ich różnica względna przekracza 20%.
- **Kontekst pozytywny** - kwalifikacja ma miejsce przy dominacji wartości kontekstu pozytywnego nad negatywnym z zachowaniem różnicy względnej większej niż 20%.
- **Kontekst mieszany** - występuje w sytuacji zbliżonego natężenia obu kontekstów, gdy różnica względna między miarami przynależności wynosi 20% lub mniej.
- **Brak wykrycia tematu** - dotyczy przypadków, w których wartości przynależności dla obu kontekstów są równe zero.

Sformułowanie powyższych kryteriów podziału nawiązuje do kryteriów przyjętych we wcześniejszych badaniach własnych [138].

Różnicę względną obliczano zgodnie z wzorem przedstawionym w równaniu 3.8.

$$R = \frac{|raw_N - raw_P|}{max(|raw_N|; |raw_P|)} \cdot 100\% \tag{3.8}$$

gdzie:
raw_N - oznacza wartość przynależności notatki do danego tematu w kontekście negatywnym,
raw_P - oznacza wartość przynależności notatki do danego tematu w kontekście pozytywnym.

Ostatnim krokiem była analiza wyników dotycząca obszarów trudności. W poprzednim kroku opisano, że dla każdego obszaru trudności uzyskano dwa wyniki: wartość określającą przynależność notatki do danego tematu w kontekście pozytywnym oraz negatywnym (z wyłączeniem obszaru autoagresji i bólu). Na podstawie tych dwóch wartości obliczono różnicę względną, która stanowiła ostateczny wynik określony w poprzednim kroku. Następnie konieczne było zestawienie tego wyniku z oceną ekspercką. Oceny tej dokonał zespół psychologów pod nadzorem kierownika Centralnej Pracowni Psychologii Klinicznej Samodzielnego Publicznego Szpitala Klinicznego nr 1 SUM. Ocena ekspercka polegała na analizie każdej notatki i przypisaniu jej odpowiedniej flagi. W przypadku obszarów takich jak obraz ciała, emocje, samoocena, funkcjonowanie ciała oraz akceptacja otoczenia zastosowano czterostopniowy system flag:

- Flaga = 0 - oznacza, że dany temat nie został poruszony w notatce.
- Flaga = -1 - oznacza, że dany temat został poruszony w notatce w kontekście negatywnym.
- Flaga = 1 - oznacza, że dany temat został poruszony w notatce w kontekście pozytywnym.
- Flaga = 2 - oznacza, że dany temat został poruszony w notatce w kontekście mieszanym, czyli pozytywno - negatywnym w równym stopniu.

W przypadku obszarów takich jak: autoagresja i ból psycholodzy mogli nadać jedną z dwóch flag: występuje ten temat (flaga = 1) lub nie występuje (flaga = 0).

W ramach walidacji zastosowano zmodyfikowaną procedurę klasyfikacji wyników, stanowiącą rozwinięcie metodyki zaprezentowanej we wcześniejszych badaniach własnych [138]. Ostateczny wynik analizy obszarów trudności zestawiono z flagą ekspercką, co pozwoliło na kwalifikację do jednego z sześciu wariantów walidacyjnych. Każda kategoria określa, czy zaproponowana metoda prawidłowo identyfikuje poruszenie danego obszaru w wypowiedzi, czy też prowadzi do błędnej oceny. W efekcie wyodrębniono następujące typy wyników:

- Wynik zbieżny - pełna zgodność klasyfikacji uzyskanej metodą słownikową ze zbiorczą oceną zespołu ekspertów.

- Błąd I rodzaju (odwrócona polaryzacja) - sytuacja, w której odnotowano przeciwne wyniki polaryzacji (np. metoda słownikowa wykazała kontekst negatywny, a zespół ekspertów pozytywny lub odwrotnie).
- Błąd II rodzaju (przeoczenie) - pominięcie obszaru przez metodę słownikową przy jednoczesnym zidentyfikowaniu go przez zespół ekspertów.
- Błąd III rodzaju (fałszywe wykrycie) - wyznaczenie danego obszaru przez metodę słownikową bez potwierdzenia w ocenie zespołu ekspertów.
- Niezgodność I rodzaju - ocena zespołu ekspertów wskazuje na kontekst mieszany, podczas gdy metoda słownikowa wykazuje dominację jednego z kontekstów (różnica względna pomiędzy wynikami dla kontekstu pozytywnego i negatywnego przekracza 20%).
- Niezgodność II rodzaju - ocena zespołu ekspertów wskazuje na dominację jednego z kontekstów, podczas gdy metoda słownikowa wykazuje kontekst mieszany (różnica względna pomiędzy wynikami przynależności notatki do tematu w kontekście pozytywnym i negatywnym jest mniejsza bądź równa 20%).

3.2.2 Etap II - Analiza statystyczna

W celu zweryfikowania różnic w wartościach przynależności notatek do poszczególnych obszarów trudności w danym kontekście pomiędzy grupą osób chorych na anoreksję jak i zdrowych, uzyskanych w ramach I etapu badań własnych, przeprowadzono analizę statystyczną. W pierwszym kroku dokonano oceny rozkładów analizowanych zmiennych za pomocą histogramów. Wizualna ocena wykresów wykazała, że rozkłady wszystkich analizowanych zmiennych w obu grupach w sposób istotny odbiegają od rozkładu normalnego.

Ze względu na niespełnienie założenia o normalności rozkładów, do porównania dwóch niezależnych grup (osoby chore i zdrowe) zastosowano nieparametryczny test U Manna-Whitneya z poprawką na ciągłość. W rozdziale dotyczącym tej części wyników przedstawiono: wartości median (Me) oraz średnich arytmetycznych (M) dla każdej z grup. Wyniki testu przedstawiono za pomocą wartości takich jak: U - wartość statystyki testu U Manna-Whitneya, skorygowanej wartości statystyki standaryzowanej Z oraz poziomu istotności p. Wyjściowy poziom istotności ustalono na $\alpha = 0,05$. Ze względu na wykonanie wielokrotnych porównań (dla 12 analizowanych zmiennych) i chęć zminimalizowania ryzyka popełnienia błędu I rodzaju, zastosowano korektę Bonferroniego. W związku z tym za poziom istotny statystycznie uznano wartości spełniające warunek $p \leq \alpha_{\text{Bonf}}$, gdzie $\alpha_{\text{Bonf}} = \frac{0,05}{12} \approx 0,0042$.

3.2.3 Etap III - Wykorzystanie algorytmów uczenia maszynowego

W tym etapie wykorzystano algorytmy uczenia maszynowego zawierające: model regresji logistycznej, drzew decyzyjnych, lasu losowego oraz sieci neuronowych. Zmienne w oparciu, o które zostały zbudowane modele zostały przedstawione w tabeli 3.8.

Tabela 3.8: Zestawienie wszystkich zmiennych wraz z przypisanymi im rolami i skalami.

Nazwa zmiennej	**Opis**	**Rola**	**Skala i zakres**
Anoreksja	Zmienna mówiąca, czy notatka pochodzi od osoby zdrowej czy chorej.	Zmienna celu	Binarna: 1 - osoba chora na anoreksję, 0 - osoba zdrowa.
P obraz ciała temat	Wartość przynależności danej notatki do tematu obrazu ciała w kontekście pozytywnym.	Zmienna wejściowa	Interwałowa (wartości ≥ 0)
N obraz ciała temat	Wartość przynależności danej notatki do tematu obrazu ciała w kontekście negatywnym.	Zmienna wejściowa	Interwałowa (jw.)
P emocje temat	Wartość przynależności danej notatki do tematu emocji w kontekście pozytywnym.	Zmienna wejściowa	Interwałowa (jw.)
N emocje temat	Wartość przynależności danej notatki do tematu emocji w kontekście negatywnym.	Zmienna wejściowa	Interwałowa (jw.)
P samoocena temat	Wartość przynależności danej notatki do tematu samooceny w kontekście pozytywnym.	Zmienna wejściowa	Interwałowa (jw.)
N samoocena temat	Wartość przynależności danej notatki do tematu samooceny w kontekście negatywnym.	Zmienna wejściowa	Interwałowa (jw.)
P funkcjonowanie ciała temat	Wartość przynależności danej notatki do tematu funkcjonowania ciała w kontekście pozytywnym.	Zmienna wejściowa	Interwałowa (jw.)
N funkcjonowanie ciała temat	Wartość przynależności danej notatki do tematu funkcjonowania ciała w kontekście negatywnym.	Zmienna wejściowa	Interwałowa (jw.)
P akceptacja otoczenia temat	Wartość przynależności danej notatki do tematu akceptacji otoczenia w kontekście pozytywnym.	Zmienna wejściowa	Interwałowa (jw.)
N akceptacja otoczenia temat	Wartość przynależności danej notatki do tematu akceptacji otoczenia w kontekście negatywnym.	Zmienna wejściowa	Interwałowa (jw.)
Autoagresja temat	Wartość przynależności danej notatki do tematu autoagresji.	Zmienna wejściowa	Interwałowa (jw.)
Ból temat	Wartość przynależności danej notatki do tematu ból.	Zmienna wejściowa	Interwałowa (jw.)

3.2.3.1 *Modelowanie szans współwystępowania anoreksji za pomocą predyktorów regresji logistycznej*

Pierwszy krok III etapu metodyki obejmował modelowanie szansy współwystępowania anoreksji z wykorzystaniem regresji logistycznej z regularyzacją Elastic Net. Zastosowanie tego podejścia pozwoliło na zidentyfikowanie predyktorów, które w sposób statystycznie istotny ($p < 0{,}05$) różnicują szansę wystąpienia anoreksji. Dodatkowo modelowanie umożliwiło określenie kierunku oraz siły wpływu poszczególnych zmiennych niezależnych.

Wybór regresji logistycznej był ściśle związany ze skalą zmiennej celu (zmiennej zależnej), która jest binarna. Przyjęto kodowanie zero-jedynkowe. Wartość 1 określa, że dana osoba jest chora na anoreksję, a 0 że jest zdrowa. Do budowy modelu wykorzystano wszystkie wartości zmiennych, które uzyskano w I etapie analizy, zatem wszystkie wartości przynależności danej notatki do danego tematu w rozpatrywanym kontekście.

Przed przystąpieniem do budowy modelu przeprowadzono wieloetapową weryfikację założeń:

1. **Analiza korelacji predyktorów** - W pierwszym etapie wyznaczono macierz korelacji w celu określenia siły i kierunku powiązań pomiędzy wszystkimi analizowanymi zmiennymi. Ze względu na brak normalności rozkładu zmiennych, zgodnie z wytycznymi literaturowymi [139, 140] wykorzystano test nieparametryczny (korelację rang Spearmana). Krok ten stanowił również wstępną identyfikację potencjalnej współliniowości.

2. **Jednowymiarowa analiza regresji logistycznej (analiza pojedynczego wpływu)** - Oceniono pojedynczy wpływ każdej ze zmiennych na zmienną zależną. Na tej podstawie odrzucono trzy predyktory, których wpływ okazał się statystycznie nieistotny lub bliski zeru. Taka wstępna selekcja cech jest standardowym działaniem mającym na celu eliminację szumu informacyjnego przed budową modelu docelowego.

3. **Analiza adekwatności próby (EPV)** - Wyznaczono wskaźnik EPV (ang.: Events Per Variable), określający liczbę zdarzeń przypadających na jedną wprowadzoną zmienną objaśniającą. Przy pomocy tej miary możliwe jest określenie, czy próba badawcza jest wystarczająco duża w stosunku do liczby zmiennych, które są dostarczane do modelu, a tym samym pozwala ocenić stabilność strukturalną modelu. Miara ta wyraża się wzorem 3.9. Uzyskana wartość EPV została szczegółowo opisana w rozdziale zawierającym wyniki.

$$EPV = \frac{\min(chorzy, zdrowi)}{N} \tag{3.9}$$

gdzie:
chorzy - liczba wszystkich obserwacji dla osób chorych,
zdrowi - liczba wszystkich obserwacji dla osób zdrowych,
N - to liczba wszystkich zmiennych.

Wskaźnik EPV oblicza się jako stosunek liczby obserwacji reprezentującej mniejszą grupę do liczby wszystkich analizowanych zmiennych predykcyjnych w modelu. Dotychczas w literaturze przyjmowało się, że wartość wskaźnika EPV powinna wynosić co najmniej 10, co pozwala na zachowanie stabilności oraz walidacji statystycznej modelu regresji logistycznej [141]. Jednakże współczesne badania kwestionują stosowanie tej granicy i pokazują, że nie we wszystkich sytuacjach konieczne jest użycie tego wskaźnika. Vittinghoff i McCulloch [142] udowodnili, że kryterium to można złagodzić, a modele zachowują stabilność przy mniejszych wartościach EPV. Courvoisier i in. [143] w swoich badaniach podkreślają, że na zachowanie modelu większy wpływ ma struktura danych i korelacja predyktorów niż wartość samego wskaźnika EPV. Według Ogundimu i in. [144], kryterium EPV powinno być elastyczne i uzależnione od charakterystyki posiadanych danych. Wyższe wartości tego wskaźnika stają się kluczowe głównie w sytuacjach, gdy wśród predyktorów znajdują się zmienne binarne o bardzo niskiej częstości występowania, co w przypadku zmiennych wykorzystanych w niniejszej pracy nie miało miejsca. W związku z tym brak spełnienia kryterium EPV co najmniej równego 10 nie wykluczało przeprowadzenia analizy, jednak ze względu na obecność korelacji między predyktorami, których negatywny wpływ na stabilność modelu wykazali Courvoisier i wsp. [143], w badaniach zdecydowano się na zastosowanie metody odpornej na te zjawiska - regresji z regularyzacją Elastic Net.

4. **Analiza współliniowości (multikolinearności)** - W celu dokładnej oceny stopnia współliniowości predyktorów, wykorzystano wskaźnik VIF (ang.: *Variance Inflation Factor*) oraz powiązany z nim współczynnik tolerancji ($Tolerancja = \frac{1}{VIF}$). Jako kryterium braku nadmiernej współliniowości przyjęto powszechnie stosowaną w literaturze granicę $VIF < 4$ (bardziej rygorystyczną) lub dopuszczalną $VIF < 10$. Zgodnie z definicją O'Briena wartości te pokazują, ile razy wzrasta wariancja danego współczynnika regresji przez to, że zmienne objaśniające korelują ze sobą [145]. Niski poziom VIF w tym badaniu gwarantuje, że uzyskane wyniki są stabilne.

Wystąpienie wyraźnych współzależności między analizowanymi zmiennymi oraz potencjalne ograniczenia wynikające z wartości wskaźnika EPV wpłynęły na zrezygnowanie z klasycznych metod regresji krokowej, które w takich warunkach prowadzą do niestabilności ocen parametrów [146]. W celu eliminacji tych ograniczeń zdecydowano się na wdrożenie regresji logistycznej z regularyzacją Elastic Net, łączącej cechy kary L_1 (Lasso) oraz L_2 (Ridge). Celem zastosowania kary L_2 jest pozbycie się problemu ze współliniowością predyktorów poprzez tzw. efekt grupowania [147]. Dzięki temu możliwa jest stabilna estymacja współczynników dla zmiennych silnie skorelowanych. Karę L_1 stosuje się w celu automatycznej selekcji cech poprzez eliminację zmiennych o niskim znaczeniu [147]. Wpływa to na wyraźne ograniczenie ryzyka przeuczenia. W efekcie taki model zyskuje znacznie lepsze właściwości prognostyczne, co ma kluczowe znaczenie przy pracy z mniejszymi zbiorami danych.

Wpływ predyktorów wyłonionych przez algorytm Elastic Net oceniono przy użyciu statystyki testowej Walda, służącej do weryfikacji istotności strukturalnej współczynników regresji (B). Uwzględniono również błędy standardowe (SE) estymacji para-

metrów. Dla zmiennych istotnych statystycznie ($p < 0{,}05$) obliczono Ilorazy Szans (ang.: Odds Ratio, OR) wraz z ich 95% przedziałami ufności (95% CI). Dla większej czytelności wyniki analizy ilorazów szans wraz z przedziałami ufności przedstawiono graficznie na wykresie leśnym.

3.2.3.2 Analiza struktury danych za pomocą drzew klasyfikacyjnych CRT

Kolejnym algorytmem wykorzystanym w zaproponowanej metodyce były drzewa decyzyjne (klasyfikacyjne CRT). Mając na uwadze fakt, że algorytm ten opiera się na sukcesywnym podziale danych na kolejne zbiory, proces decyzyjny jest znany oraz z uwagi na wysoką interpretowalność wyników model ten posłużył przede wszystkim w celach eksploracyjnych. Ich zastosowanie miało na celu wyznaczenie: kluczowych reguł decyzyjnych, najważniejszych klastrów, a ostatecznie profili notatek osób chorych na anoreksję.

Cały proces analizy danych został podzielony na kilka etapów:

1. **Wstępna ocena istotności zmiennych** - Przed przystąpieniem do budowy właściwych, pojedynczych drzew klasyfikacyjnych, przeprowadzono celową eksplorację struktury danych za pomocą algorytmu lasów losowych. Miało to na celu identyfikację tych zmiennych (poruszonych tematów w analizowanych notatkach), które w największym stopniu różnicują teksty autorstwa osób chorych od zdrowych. Zmienne te niosą za sobą największy wkład informacyjny w procesie prawidłowej klasyfikacji notatek. Innymi słowy zmienne te w najlepszy sposób dzielą dane na analizowane grupy. Wynikiem tej części badań był wykres ważności zmiennych.

2. **Dobór parametrów i optymalizacja modeli** - W celu wygenerowania optymalnej struktury pojedynczego drzewa decyzyjnego zbadano wpływ różnych wartości parametrów i ich kombinacji.

   Przeanalizowano wpływ następujących ustawień:

   - maksymalna głębokość (przyjęte wartości: 3, 6, 10, 20),
   - minimalny rozmiar liścia (przyjęte wartości: 1, 3, 5, 8).

   Biorąc pod uwagę wszystkie możliwe kombinacje wygenerowano 16 różnych drzew decyzyjnych. Następnie wykorzystując Kryterium Informacyjne Akaikego (AIC) wybrano optymalny zestaw parametrów. Kryterium to wyraża się wzorem 3.10:

$$AIC = 2k - 2\ln(L) \tag{3.10}$$

   gdzie:
   k - oznacza liczbę estymowanych parametrów modelu.
   L - oznacza maksymalną wartość funkcji wiarygodności (ang.: maximum likelihood function) wyznaczoną dla analizowanego modelu.

3. **Walidacja krzyżowa i wybór modelu końcowego** - Po wyborze optymalnej konfiguracji przeprowadzono procedurę 4-krotnej walidacji krzyżowej. Proces uczenia i walidacji zrealizowano na wyodrębnionym podzbiorze ucząco-walidacyjnym, który stanowił 80% wszystkich danych. Zatem na proces ucząco-walidacyjny przeznaczono 160 obserwacji. Następnie spośród otrzymanych modeli, ponownie wykorzystując Kryterium Informacyjnego Akaikego (AIC) wybrano optymalny model drzewa.

4. **Analiza strukturalna i ekstrakcja reguł decyzyjnych** - Wybrane na podstawie kryterium AIC drzewo klasyfikacyjne zostało poddane szczegółowej analizie. Zweryfikowano liczbę liści (węzłów końcowych) oraz jakie zmienne wystąpiły w modelu drzewa. Wybór zmiennych tworzących model drzewa zestawiono i porównano z wcześniejszym wykresem ważności zmiennych uzyskanym z lasu losowego. Pozwoliło to na ocenę stabilności i spójności wybranych cech. W następnym kroku wyodrębniono i przeanalizowano reguły decyzyjne dla tych liści, które reprezentowały notatki osób chorych. Analizę reguł specjalnie ograniczono jedynie do tej grupy. Dzięki temu możliwe było utworzenie profili notatek dla osób zmagających się z anoreksją.

5. **Wizualizacja i analiza klastrów (wykres kafelkowy i radarowy)** - Następnie w celu pogłębienia analizy, przedstawiono strukturę drzewa w postaci wykresu kafelkowego. Powierzchnia poszczególnych kafelków odpowiadała liczebności zgromadzonych w nich obserwacji, co pozwoliło na czytelną wizualizację wielkości każdego węzła końcowego z podziałem na notatki autorstwa osób zdrowych i chorych. W kolejnym kroku klastry w przestrzeni cech, reprezentujące węzły końcowe drzewa potraktowano jako odrębne klastry o określonej charakterystyce. Dla każdego z tych klastrów, który reprezentował notatki osób chorych, obliczono wartości median we wszystkich analizowanych w badaniu obszarach trudności dla wszystkich przypadków, które wpadły do tego klastra. Warto podkreślić, że mediany również obliczono dla tych obszarów, które nie brały bezpośredniego udziału w podziałach w drzewie. Wyniki te przedstawiono przy użyciu wykresu radarowego. Jeżeli dany klaster był mocno zanieczyszczony - nie występowała w nim znaczna przewaga notatek osób chorych nad zdrowymi to taki klaster był pomijany. W efekcie końcowym pozwoliło to na wyodrębnienie charakterystycznych profili tematycznych wypowiedzi powiązanych z grupą osób chorujących na anoreksję.

6. **Wyznaczenie macierzy błędów i miar dla modelu drzewa** - W ostatnim kroku w celu formalnej i ilościowej oceny jakości predykcyjnej i zdolności generalizacyjnych wybranego modelu wyznaczono macierz błędów (tabela 3.9) oraz na jej podstawie obliczono wskaźniki efektywności klasyfikacji. Do przedstawienia wyników wykorzystano zbiór testowy, który stanowił wydzielone 20% z całego zbioru danych. Wśród 41 analizowanych w nim przypadków znalazły się 23 osoby cierpiące na anoreksję oraz 18 osób zdrowych.

Tabela 3.9: Macierz błędów

	Predykcja: Pozytywna	Predykcja: Negatywna
Rzeczywiste: Pozytywne (notatki osób chorych na anoreksję)	TP (True Positive) Prawdziwie pozytywny: model poprawnie zaklasyfikował notatkę osoby chorej	FN (False Negative) Fałszywie negatywny: model błędnie uznał notatkę osoby chorej za notatkę osoby zdrowej
Rzeczywiste: Negatywne (notatki osób zdrowych)	FP (False Positive) Fałszywie pozytywny: model błędnie uznał notatkę osoby zdrowej za notatkę osoby chorej	TN (True Negative) Prawdziwie negatywny: model poprawnie zaklasyfikował notatkę osoby zdrowej

Wśród obliczonych miar znalazły się: Wśród obliczonych miar znalazły się:

- Swoistość (ang.: Specificity, TNR - True Negative Rate) - wskaźnik ten określa zdolność modelu do poprawnego rozpoznawania notatek autorstwa osób zdrowych. Miara ta dostarcza informacji, jaki odsetek rzeczywistych negatywów został właściwie zidentyfikowany. Wysoka wartość swoistości świadczy o tym, że model rzadko popełnia błąd polegający na błędnym przypisaniu notatki osoby zdrowej do grupy osób chorych. Swoistość wyraża się wzorem:

$$TNR = \frac{TN}{TN + FP} \tag{3.11}$$

- Czułość (ang.: Sensitivity, TPR - True Positive Rate) - miara ta informuje, jak skutecznie model wykrywa notatki autorstwa osób chorych na anoreksję. Określa odsetek poprawnie sklasyfikowanych dokumentów z grupy pozytywnej. Wskaźnik ten wyraża się wzorem:

$$TPR = \frac{TP}{TP + FN} \tag{3.12}$$

- Skuteczność (ang.: Accuracy, ACC) - wskaźnik ten informuje o ogólnym odsetku poprawnych klasyfikacji, uwzględniając zarówno trafnie rozpoznane notatki osób chorych, jak i zdrowych. Miara ta wyraża się wzorem:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \tag{3.13}$$

- Współczynnik błędnych klasyfikacji (ang.: Error Rate lub Misclassification Rate) - wskaźnik ten określa odsetek wszystkich błędnie przypisanych dokumentów, sumując notatki osób chorych błędnie uznane za teksty osób zdrowych oraz notatki osób zdrowych błędnie uznane za teksty osób chorych. Wskaźnik ten wyraża się wzorem:

$$\text{Error Rate} = \frac{FP + FN}{TP + TN + FP + FN} \tag{3.14}$$

- Precyzja (ang.: Precision) - informuje o trafności pozytywnych predykcji modelu. W kontekście oceny jakości klasyfikacji wyróżnia się dodatnią wartość predykcyjną (PPV) oraz ujemną wartość predykcyjną (NPV). PPV określa, jaki odsetek notatek zaklasyfikowanych przez model jako teksty osób chorych rzeczywiście pochodzi od osób z tej grupy. Z kolei NPV informuje, jaki odsetek dokumentów przypisanych do grupy negatywnej faktycznie stanowi notatki osób zdrowych. Miary te wyrażają się wzorami:

$$PPV = \frac{TP}{TP + FP} \tag{3.15}$$

$$NPV = \frac{TN}{TN + FN} \tag{3.16}$$

- Miara F (ang.: F1-score) - harmoniczna miara łącząca precyzję z czułością lub swoistością. Obliczono dwa warianty tej miary: F_P dla klasy pozytywnej oraz F_N dla klasy negatywnej:

$$F_P = 2 \cdot \frac{PPV \cdot TPR}{PPV + TPR} \tag{3.17}$$

$$F_N = 2 \cdot \frac{NPV \cdot TNR}{NPV + TNR} \tag{3.18}$$

- Współczynnik korelacji Matthewsa (ang.: Matthews Correlation Coefficient, MCC) - zrównoważona miara jakości klasyfikacji binarnej, uwzględniająca wszystkie składowe macierzy błędów. Przyjmuje wartości z przedziału od -1 do 1. Wartość 1 oznacza bezbłędną klasyfikację dokumentów, wartość 0 odpowiada skuteczności klasyfikatora losowego, natomiast -1 oznacza całkowitą niezgodność predykcji ze stanem rzeczywistym. Wskaźnik ten wyraża się wzorem:

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \tag{3.19}$$

- Indeks Youdena (Youden's J) - wskaźnik łączący czułość oraz swoistość. Informuje o zdolności modelu do jednoczesnego poprawnego wykrywania notatek osób chorych oraz bezbłędnego identyfikowania tekstów osób zdrowych. Wartość 1 oznacza model idealny, 0 odpowiada poziomowi losowemu, natomiast wartości ujemne wskazują na działanie gorsze od losowej klasyfikacji. Miara ta wyraża się wzorem:

$$J = TNR + TPR - 1 = \frac{TN}{TN + FP} + \frac{TP}{TP + FN} - 1 \tag{3.20}$$

- Współczynnik fałszywie pozytywnych wyników (ang.: False Positive Rate, FPR) - wskazuje odsetek notatek osób zdrowych, które model błędnie zaklasyfikował jako teksty osób chorych na anoreksję. Wysoka wartość tego wskaźnika oznacza nadmierne generowanie fałszywych alarmów przy ana-

lizie tekstów kontrolnych. Wskaźnik ten wyraża się wzorem:

$$FPR = \frac{FP}{FP + TN} \tag{3.21}$$

- Współczynnik fałszywie negatywnych wyników (ang.: False Negative Rate, FNR) - określa odsetek notatek osób chorych, które zostały błędnie zaklasyfikowane jako teksty osób zdrowych. Miara ta obrazuje, w jakim stopniu model przeoczył cechy tekstowe charakterystyczne dla grupy badanej. Wskaźnik ten wyraża się wzorem:

$$FNR = \frac{FN}{FN + TP} \tag{3.22}$$

- Współczynnik fałszywych odkryć (ang.: False Discovery Rate, FDR) - stosowany do oceny wiarygodności wskazań pozytywnych. Określa, jaki odsetek dokumentów przypisanych przez model do klasy pozytywnej (notatki osób chorych) stanowią w rzeczywistości notatki osób zdrowych. Wskaźnik ten wyraża się wzorem:

$$FDR = \frac{FP}{TP + FP} \tag{3.23}$$

- Współczynnik fałszywych pominięć (ang.: False Omission Rate, FOR) - określa odsetek błędów wśród dokumentów zaklasyfikowanych przez model do grupy negatywnej, czyli udział tekstów osób chorych błędnie uznanych za notatki osób zdrowych. Miara ta wyraża się wzorem:

$$FOR = \frac{FN}{TN + FN} \tag{3.24}$$

- Wartość pola pod krzywą ROC (ang.: Area Under the Curve, AUC) - wskaźnik oceniający ogólną zdolność dyskryminacyjną modelu, czyli jego umiejętność odróżniania notatek osób chorych (klasa pozytywna) od notatek osób zdrowych (klasa negatywna) niezależnie od przyjętego progu odcięcia. Przyjmuje wartości z przedziału od 0 do 1. Miara ta wyraża się wzorem:

$$AUC = \int_0^1 TPR(FPR)\, d(FPR) \tag{3.25}$$

3.2.3.3 Wykorzystanie algorytmu lasu losowego do klasyfikacji notatek do klas zdrowy/chory

Kolejnym algorytmem wykorzystanym w pracy był las losowy. Trening modelu przeprowadzono na próbie stanowiącej 80% całego zbioru danych (co stanowi 160 obserwacji). W przypadku algorytmu lasu losowego nie wydzielono osobnej części danych, którą przeznaczono by na proces walidacyjny. Model lasu losowego posiada wbudowany mechanizm estymacji błędu oparty na próbach out-of-bag (OOB). Mechanizm ten opiera się na metodzie baggingu (czyli agregacji bootstrapowej), na której bazuje działanie lasu losowego. Polega na tym, że podczas procesu budowania poszczególnych drzew algorytm losuje ze zwracaniem podpróbę obserwacji ze zbioru treningowego.

W efekcie około 36,8% obserwacji nie trafia do zbioru treningowego danego drzewa. Obserwacje te tworzą próbę, którą nazywa się „out-of-bag" i pełnią rolę analogiczną do tradycyjnego zbioru walidacyjnego. Pozostałe 20% danych posłużyło do całkowicie niezależnej, ostatecznej oceny jakości predykcji na zbiorze testowym.

W celu optymalizacji działania algorytmu oraz zabezpieczenia go przed zjawiskiem przeuczenia, model został skonstruowany w oparciu o określoną strukturę parametrów. Architektura lasu składała się ze 100 drzew decyzyjnych o maksymalnej głębokości równej 10. Dodatkowo określono liczbę predyktorów losowanych w każdym podziale, maksymalną głębokość drzewa oraz maksymalną liczbę węzłów, minimalną liczbę przypadków w węźle oraz minimalną liczbę przypadków w węźle potomnym. Szczegółowe zestawienie wszystkich przyjętych parametrów modelu przedstawiono w tabeli 4.10 w rozdziale z wynikami.

Po wygenerowaniu modelu wyznaczono macierz błędów oraz miary jakości klasyfikacji, które opisano szczegółowo przy omawianiu poprzedniego modelu drzew decyzyjnych.

3.2.3.4 Wykorzystanie algorytmu sieci neuronowej do klasyfikacji notatek do klas zdrowy/chory

Mając na uwadze specyfikę analizowanego problemu oraz stosunkowo małą liczebność dostępnego zbioru danych, zdecydowano się na implementację sztucznych sieci neuronowych o prostej architekturze.

W niniejszej pracy zaimplementowano i poddano analizie dwie klasyczne struktury sieci jednokierunkowych. Wśród nich znalazły się:

- **MLP (Multilayer Perceptron - Perceptron Wielowarstwowy)** - Reprezentuje sieć o strukturze warstwowej. Przetwarzanie informacji w takiej sieci polega na wyznaczaniu kombinacji liniowej sygnałów wejściowych przez neurony, a następnie poddawaniu ich nieliniowej transformacji za pomocą wybranych funkcji aktywacji.
- **RBF (Radial Basis Function - Sieć z Radialnymi Funkcjami Bazowymi)** - Reprezentuje sieć o jednej warstwie ukrytej. Działanie neuronów opiera się na wyznaczaniu miary dystansu euklidesowego do centrów funkcji bazowych.

Głównym celem wykorzystania powyższych architektur było sprawdzenie, czy sieci neuronowe pozwolą na osiągnięcie wyższej skuteczności klasyfikacyjnej w rozróżnianiu notatek osób chorych na anoreksję od zdrowych w porównaniu do wcześniej wygenerowanego modelu lasu losowego.

Zbiór danych podzielono na trzy zbiory danych.

- Zbiór treningowy - składał się z 60% całego zbioru danych. Został wykorzystany do treningu sieci, czyli bezpośrednio w procesie estymacji wag połączeń między neuronami oraz centrów funkcji radialnych.
- Zbiór walidacyjny - składał się z 20% całego zbioru danych. Został wykorzystany do monitorowania błędu generalizacji w trakcie uczenia sieci oraz zapobiegania zjawisku przeuczenia.

- Zbiór testowy - składał się z 20% całego zbioru danych. Został wykorzystany do oceny zdolności predykcyjnych i porównania wytrenowanych modeli sieci.

Dla architektur typu MLP przebadano struktury zawierające jedną warstwę ukrytą, w której liczba neuronów wahała się w przedziale od 5 do 14. W ramach badań w warstwie ukrytej przebadano wpływ takich funkcji jak:

- funkcja liniowa,
- funkcja logistyczna,
- tangens hiperboliczny,
- funkcja wykładnicza.

Dla warstwy wyjściowej, ze względu na fakt, że zmienna celu ma skalę binarną, przebadano wpływ takich funkcji jak:

- funkcja logistyczna,
- Softmax.

Dla struktury sieci RBF przebadano struktury, w których liczba neuronów wahała się w zakresie od 20 do 28. W warstwie tej zastosowano standardową, symetryczną funkcję Gaussa, opisaną równaniem 3.26.

$$G(x) = \exp(-\gamma||x - c||^2) \tag{3.26}$$

gdzie:
c - oznacza środek (centrum) funkcji bazowej,
γ - jest parametrem kontrolującym szerokość funkcji radialnej.

W procesie uczenia wykorzystano dwa niezależne kryteria optymalizacyjne: sumę kwadratów błędów (ang.: Sum of Squares, SOS) oraz entropię. Pierwsza funkcja określona jest wzorem 3.27, a druga 3.28.

$$E_{SOS} = \frac{1}{2}\sum_{i=1}^{N}(y_i - t_i)^2 \tag{3.27}$$

$$E_{CE} = -\sum_{i=1}^{N}[t_i \ln(y_i) + (1 - t_i)\ln(1 - y_i)] \tag{3.28}$$

gdzie:
y_i - wartość wyjściowa wygenerowaną przez model,
t_i - wartość rzeczywista,
N - liczba obserwacji

Ze wszystkich wygenerowanych kombinacji sieci wyłoniono 5 najlepszych modeli biorąc pod uwagę wyniki uzyskane na zbiorze walidacyjnym i testowym. Następnie, dla

każdego z nich wyznaczono macierz błędów oraz miary jakości klasyfikacji, które opisano szczegółowo przy omawianiu poprzedniego modelu drzewa decyzyjnego.

Ostateczna ocena i wybór najlepszego modelu została dokonana w oparciu o analizę krzywych ROC (ang.: Receiver Operating Characteristic). Dla każdego z 5 modeli wykreślono krzywą obrazującą relację pomiędzy czułością a poziomem fałszywych alarmów wyrażoną jako 1 - swoistość. Następnie obliczono wartość pola powierzchni pod tą krzywą (AUC). Model charakteryzujący się najwyższą wartością AUC został wskazany jako najlepszy ze wszystkich wygenerowanych sieci neuronowych.

3.2.3.5 Kompleksowa analiza porównawcza modeli predykcyjnych

W celu kompleksowej analizy i bezpośredniego porównania zdolności dyskryminacyjnej badanych modeli (regresji logistycznej, drzewa decyzyjnego, lasu losowego oraz sieci neuronowej) wykorzystano analizę krzywych ROC oraz pole pod tą krzywą, czyli wartość AUC.

Dla każdego z modeli oszacowano punktową wartość wskaźnika AUC wraz z błędem standardowym (SE) oraz 95% przedziałem ufności (95% CI), wyznaczonymi nieparametryczną metodą DeLonga [148]. Istotność różnic pomiędzy polami zweryfikowano przy użyciu testu DeLonga dla prób zależnych. Przyjęto standardowy poziom istotności statystycznej $\alpha = 0{,}05$.

4. Rezultaty

W rozdziale tym przedstawiono rezultaty od detekcji obszarów trudności przy pomocy metody słownikowej wykorzystującej LSA i SVD aż po wykorzystanie algorytmów uczenia maszynowego. W podrozdziale 4.1 przedstawiono wyniki detekcji obszarów trudności u osób zdrowych i chorych na anoreksję. Następnie, w podrozdziale 4.2, dokonano analizy porównawczej wartości przynależności notatek do tych obszarów, zestawiając grupę osób chorych z osobami zdrowymi. Podrozdział 4.3 zawiera wyniki wykorzystanych metod uczenia maszynowego w tym: regresji logistycznej, drzewa decyzyjnego, lasu losowego i sieci neuronowej. Rozdział ten zamyka podrozdział 4.4, który stanowi próbę wykorzystania zaproponowanej metody słownikowej w innych obszarach medycznych: otyłości, nadwadze oraz nowotworach głowy i szyi.

4.1 Detekcja obszarów trudności w wypowiedziach osób cierpiących na anoreksję

W niniejszym rozdziale przedstawiono wyniki opracowanej metody w identyfikacji poszczególnych tematów w pisemnych wypowiedziach. Wykresy kołowe obrazują rozkład liczbowy przeanalizowanych notatek po weryfikacji eksperckiej wykonanej przez zespół psychologów pod nadzorem kierownika Centralnej Pracowni Psychologii Klinicznej SP Szpitala Klinicznego nr 1 im. prof. Stanisława Szyszko SUM. Poza łączną liczbą rozbieżności uwzględniono szczegółowy podział na błędy I, II i III rodzaju oraz niezgodności I i II rodzaju, których definicje szczegółowo omówiono w rozdziale z metodyką. Wszystkie błędne wyniki zostały zsumowane i przedstawione jako łączny wynik rozbieżny. Zestawienie zawiera również informację o procentowej skuteczności metody, którą podano osobno dla grupy osób chorych, zdrowych oraz zbiorczo dla całej próby badawczej.

Uwaga: Wszystkie cytowane wypowiedzi przytoczono w brzmieniu oryginalnym, bez poprawiania błędów językowych i interpunkcyjnych.

Pierwszym analizowanym obszarem trudności był „Obraz ciała". Na rysunku 4.1 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.1a przedstawia wyniki dla całej grupy badawczej, 4.1b rezultaty dla osób chorujących na anoreksję, natomiast 4.1c dotyczy grupy notatek osób zdrowych.

Ogólna poprawność działania metody słownikowej jest równa 75% (rysunek 4.1a), czyli dla 150 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. Porównując jednak wyniki pomiędzy grupą osób chorych a zdrowych widać zróżnicowanie skuteczności. W grupie osób chorych na anoreksję metoda osiągnęła wysoką poprawność działania na poziomie 81% (z wszystkich 115 notatek 93 były zgodne z oceną ekspercką, a 22 były rozbieżne, rysunek 4.1b). Wśród błędnych wyników pojawiły się wszystkie możliwe i rozważane kategorie. Błąd I rodzaju oznacza odwrócenie polaryzacji względem oceny eksperckiej, błąd II rodzaju polegał na pominięciu (braku wykrycia) analizowanego obszaru przez metodę, a błąd III rodzaju został zdefiniowany jako jego fałszywe wykrycie. W przypadku metody słownikowej widoczna była skłonność do nadinterpretacji treści i wskazywania tematów nieobecnych w opinii zespołu ekspertów. Niezgodność I rodzaju dotyczy sytuacji, w której metoda słownikowa wskazała dominację określonego wydźwięku (pozytywnego lub negatywnego), podczas gdy eksperci zaklasyfikowali wypowiedź jako mieszaną. Z kolei niezgodność II rodzaju polega na przypisaniu przez metodę kontekstu mieszanego w przypadku, gdy ocena ekspercka była jednoznaczna. Wśród notatek osób chorych najczęściej odnotowano niezgodność II rodzaju (7 notatek), niezgodność I rodzaju (5 notatek) oraz błąd I rodzaju (5 notatek). Błąd II i III rodzaju miały charakter incydentalny, stanowiąc odpowiednio 3 i 2 przypadki. W grupie osób zdrowych metoda osiągnęła poprawność działania na poziomie 66% (z wszystkich 86 notatek 57 były zgodne z oceną ekspercką, a 29 były rozbieżne, rysunek 4.1c). W zakresie stwierdzonych rozbieżności dominował błąd III rodzaju, który stanowił ponad 50% wszystkich pomyłek w tej grupie (dotyczył 15 notatek). Błąd I rodzaju pojawił się w 5 notatkach, a niezgodność I rodzaju w 6. Niezgodność II rodzaju miała charakter incydentalny (dotyczyła 3 przypadków), a błąd II rodzaju w ogóle nie wystąpił.

Największą wartość przynależności notatki do tematu obrazu ciała w kontekście negatywnym metoda zidentyfikowała dla wypowiedzi osoby chorej, o następującej treści:

> *„Moje ciało: ogromny nos, niekształtna twarz, głupie kręcone włosy, nudny kolor oczu, brzydka, pulchna twarz, dupa broda, smutny wyraz twarzy, gruby tułów, grube uda, duże stopy - jak u wielkiej stopy. Nieproporcjonalne, brzydkie, bez kształtów, coś strasznego, coś czego nie akceptuję w 100%, nienawidzę go, mój wróg z którym walczę."*

Powyższą wypowiedź eksperci również zakwalifikowali jako przykład negatywnego obrazu ciała. Z kolei najwyższy stopień przynależności do kontekstu pozytywnego metoda zidentyfikowała dla wypowiedzi osoby zdrowej, która o swoim ciele napisała następująco:

> *„zgrabne, powabne, wysportowane, chude, wysokie, podoba mi się, proporcjonalne, minimalnie pryszczate."*

Warto zaznaczyć, że w tej notatce algorytm wykazał także niewielki stopień nacechowania negatywnego. Ostatecznie jednak, po zestawieniu wartości dla obu kontekstów, wypowiedź została sklasyfikowana przez metodę jako pozytywna, co pozostaje w pełnej zgodzie z oceną ekspercką.

Analiza poszczególnych kategorii rozbieżności w całym materiale badawczym ujawnia naturę ograniczeń podejścia słownikowego:

- **Błąd I rodzaju (odwrócona polaryzacja)** - wystąpił w 10 spośród 201 notatek, co stanowi ok. 5% całego zbioru danych. Przypadki te rozłożyły się po równo między obie badane grupy (po 5 wystąpień), co odpowiada 4,3% w grupie osób chorych oraz 6,0% w grupie osób zdrowych.

- **Błąd II rodzaju (przeoczenie tematu)** - pojawił się wyłącznie u osób chorych (3 notatki). Wśród nich przykładem może być poniższa notatka:

  > *„Moje ciało mnie zniewoliło, zabawa, radość czas, emocje… dominują nad moim życiem… wolałabym go nie mieć, żeby znikło, boję się go."*

  Przytoczony fragment wyraża skrajnie negatywny stosunek do własnego ciała. Autorka posługuje się jednak językiem metaforycznym, unikając odniesień anatomicznych. Metoda słownikowa, bazująca na słowach kluczowych, nie była w stanie uchwycić takiego sposobu wyrażenia obrazu ciała, co doprowadziło do pominięcia tego wątku przez metodę.

- **Błąd III rodzaju (fałszywe wykrycie)** - stanowił najczęstszą rozbieżność odnotowaną w ramach tego obszaru trudności. Wystąpił w 17 z 201 notatek (8,5% całego zbioru). W grupie osób chorych zaobserwowano jedynie 2 takie przypadki, podczas gdy w grupie osób zdrowych aż 15 (co stanowi 17,4% tej grupy).

- **Niezgodność I rodzaju** - Wystąpiła w 11 z 201 notatek (5,5% całego zbioru): w 5 notatkach autorstwa osób chorych (4,3%) oraz w 6 u osób zdrowych (7,0%).

  Zjawisko to w grupie osób zdrowych dobrze ilustrują poniższe wypowiedzi:

  > *„Moje ciało jest niemałe, potężne, umięśnione, wysokie, wulgarne, bezlitosne, denerwujące, okrutne. Czasem bywa lubiane."*

  > *„Moje ciało jest zmęczone. Moje ciało wiele przeszło ale wciąż czasem jest piękne. Moje ciało mi się nie podoba, choć staram się je zaakceptować. Moje ciało ma swoje ładne elementy."*

  W pierwszym przytoczonym przykładzie współwystępują określenia opisujące ciało w kontekście pozytywnym (*„umięśnione", „czasem bywa lubiane"*) oraz negatywnym (*„wulgarne", „bezlitosne", „okrutne"*). Zastosowana metoda, w oparciu o profil tematyczny wyznaczony w zredukowanej przestrzeni LSA/SVD, przypisała tej wypowiedzi wyższą wartość przynależności do jednego z analizowanych kontekstów tematycznych. Eksperci zakwalifikowali natomiast tę wypowiedź jako reprezentującą kontekst mieszany. W drugim przypadku zadziałał analogiczny mechanizm: sumaryczna wartość przynależności notatki do tematu w kontekście negatywny była większa niż w pozytywnym, podczas gdy eksperci zaklasyfikowali tę notatkę jako wydźwięk mieszany, dostrzegając w tekście wyraźną ambiwalencję oraz próbę równoważenia krytyki samoakceptacją (*„wciąż czasem jest piękne", „staram się je zaakceptować"*).

Przykłady takich rozbieżności w grupie osób chorych przedstawiono poniżej:

> *„Moje ciało mnie się trochę podoba. Fajne w nim są oczy, włosy, usta, dłonie. W ciele nie podoba mnie się brzuch, uda, nos i łydki."*

> *„Jako osoba cierpiąca na anoreksję, często mam przekonanie, że moje ciało jest otyłe, niesprawne fizycznie i nieatrakcyjne. To jest dla mnie najtrudniejsze - widzieć siebie w taki sposób, choć inni mogą mieć zupełnie inny obraz mojego ciała. Te negatywne myśli są niestety częścią mojego codziennego życia i toczy się we mnie walka między pragnieniem utrzymania niskiej wagi, a potrzebą zdrowia i akceptacji swojego wyglądu. To ciężkie uczucie, które wpływa na moje samopoczucie i samoocenę. Jednak jestem świadoma, że to, co widzę, może być zniekształcone przez moją chorobę. Pracuję nad tym, aby rozumieć, że moje myśli na ten temat mogą być fałszywe."*

W pierwszej wypowiedzi autorka zestawia dokładnie po cztery cechy pozytywne i negatywne. Eksperci uznali tę symetrię za kontekst mieszany. Algorytm wykazał natomiast przewagę kontekstu pozytywnego, co wynika z ograniczenia modelu worka słów, polegającego na nieuwzględnianiu negacji. W rezultacie zaprzeczony zwrot (*„nie podoba mnie się"*) zwiększył wartość przynależności do kontekstu pozytywnego ze względu na obecność samego słowa kluczowego *„podoba"*.

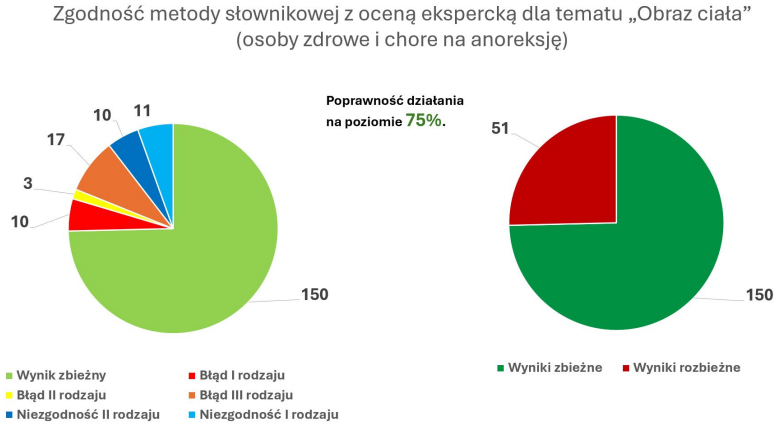
Drugi przypadek stanowi szczególny przykład analizy wypowiedzi osób chorych, w którym autorka konfrontuje objawy anoreksji z próbą ich racjonalizacji. Wypowiedź ta uzyskała wysoką wartość przynależności do kontekstu negatywnego ze względu na duże zagęszczenie pojęć kluczowych o negatywnym ładunku (*„otyłe", „nieatrakcyjne", „walka"*). Eksperci uwzględnili jednak całościowy sens narracji i zakwalifikowali tą notatkę do kontekstu mieszanego. Zauważyli, że autorka ma świadomość swojej choroby, dystansuje się od negatywnych myśli i aktywnie próbuje zaakceptować swoje ciało.

- **Niezgodność II rodzaju** - rozbieżność ta wystąpiła w 10 z 201 analizowanych notatek (5,0% całego zbioru): w 7 przypadkach w notatkach osób chorych (6,0%) oraz w 3 w grupie osób zdrowych (3,5%).

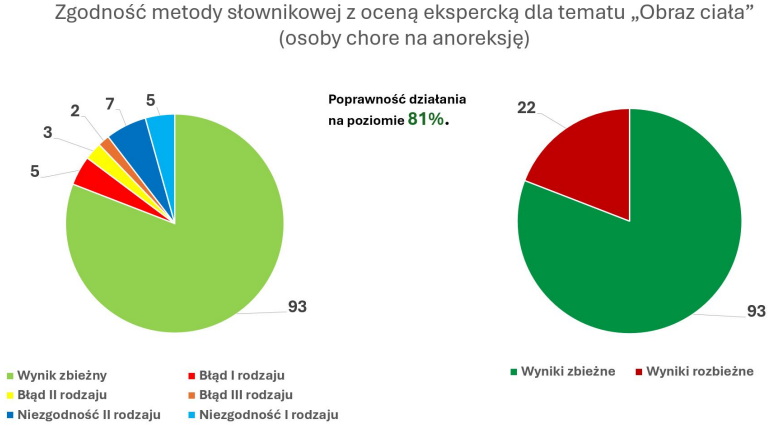
  Zjawisko to dobrze ilustruje wypowiedź jednej z osób chorych:

  > *„Ja generalnie mojego ciała nie lubię. To znaczy nie uważam, żeby ono było specjalnie atrakcyjne, specjalnie ładne. Raczej mam postrzeganie takiego skazania na to ciało, które mam. Zawsze bardziej ceniłam w sobie jakieś takie intelektualne wątki niż ciało. Zawsze uważałam, że to, co związane z ciałem, jest jakieś gorsze, krępujące, jakieś takie niższe."*

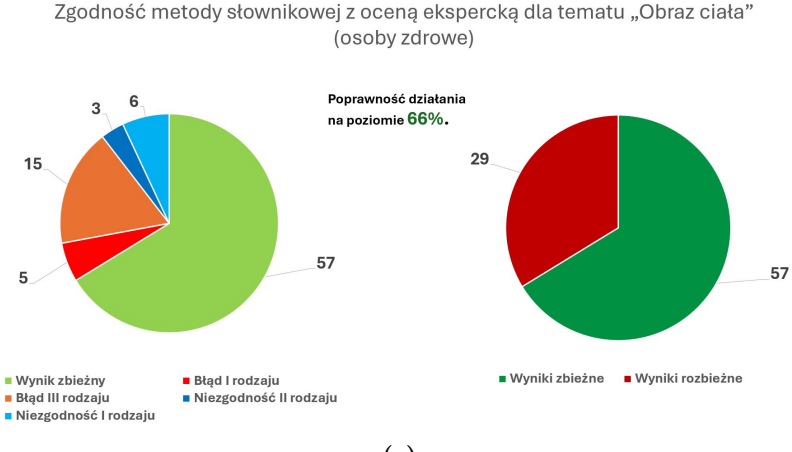
  Algorytm przypisał powyższej notatce kontekst mieszany, ponieważ wartości przynależności dla obu kontekstów (negatywnego i pozytywnego) okazały się zbliżone, nie przekraczając progu różnicy względnej. Wynika to z obecności słów o pozytywnym wydźwięku (*„lubię", „atrakcyjne", „ładne"*), którym model przypisał wysokie wagi. Ze względu na brak uwzględnienia negacji, zaprzeczone komplementy zostały błędnie potraktowane jako przejawy akceptacji ciała.



(a)



(b)



(c)

Rysunek 4.1: Graficzna prezentacja wyników dla obszaru „Obraz ciała” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

Tego typu rozbieżności uwypuklają ograniczenia metody słownikowej opartej na LSA i dekompozycji SVD. Obliczanie stopnia przynależności notatki bazuje na obecności wyizolowanych pojęć powiązanych z danym profilem tematycznym, przez co algorytm nie uwzględnia negacji ani metaforycznych pojęć. Podczas gdy eksperci mogą dostrzec dodatkowe warstwy znaczeniowe. Jednocześnie przykłady te pokazują, że metoda działa w sposób w pełni konsekwentny i powtarzalny, a weryfikacja ekspercka pozostaje kluczowa w przypadku wypowiedzi o złożonej strukturze semantycznej i wysokim nacechowaniu emocjonalnym.

Drugim analizowanym obszarem trudności były „Emocje". Na rysunku 4.2 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.2a przedstawia wyniki dla całej grupy badawczej, 4.2b rezultaty dla osób chorujących na anoreksję, natomiast 4.2c dotyczy notatek osób zdrowych.

W przypadku tematu „Emocji" metoda słownikowa wykazała bardzo wysoką ogólną poprawność działania osiągając 83% poprawności w całym zbiorze (rysunek 4.2a), czyli dla 167 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. W przeciwieństwie do obszaru „Obraz ciała", skuteczność wykrycia tematu emocji okazała się stabilna i zbliżona w notatkach z obu analizowanych grup. W wypowiedziach pisemnych osób chorych na anoreksję metoda osiągnęła poprawność działania na poziomie 84% (z wszystkich 115 notatek 97 było zgodnych z oceną ekspercką, a w przypadku 18 wystąpiły rozbieżności, rysunek 4.2b). Wśród nielicznych błędów, w notatkach osób chorych, najczęściej występował błąd III rodzaju (6 notatek) oraz niezgodność I rodzaju (4 notatki). Błąd I i II rodzaju oraz niezgodność II rodzaju miały charakter incydentalny (wystąpiły odpowiednio 3, 3 i 2 razy). W grupie osób zdrowych metoda osiągnęła poprawność na poziomie 81% (z wszystkich 86 notatek 70 było zgodnych z oceną ekspercką, a w przypadku 16 wystąpiły rozbieżności, rysunek 4.2c). Podobnie jak przy poprzednim obszarze trudności, dominującą kategorią pomyłek był błąd III rodzaju, który stanowił ponad 62% wszystkich nieprawidłowości w tej grupie wypowiedzi (dla 10 notatek występował ten błąd). W tej grupie nie odnotowano żadnego błędu I i II rodzaju. Niezgodności I i II rodzaju miały charakter incydentalny (odnotowano po 3 takie przypadki).

Poniżej przedstawiono przykłady wypowiedzi, w których metoda poprawnie zidentyfikowała obszar emocji. W pierwszej notatce dominują jednoznacznie negatywne emocje. Występuje tu wyraziste, ujemnie nacechowane słownictwo, co poprawnie wychwyciła metoda:

> *„Moje zdanie o moim ciele jest takie, że jest grube, ma grube uda i łydki. Duży brzuch, pulchna i okrągłą twarz. Inni mówią, że mam wystające kości, lecz ja si,e z tym nie zgadzam. Przez ostatni miesiąc czuję się jeszcze bardziej grubo niż w domu. Ciężko mi uwierzyć, że inni ludzie mi mówią, że jestem chuda, ale ja w to nie wierzę."*

W kolejnej notatce autorka nie formułuje swoich stanów wprost poprzez deklaracje typu „jestem załamana" czy „nienawidzę swojego ciała", lecz skupia się na chronologicznym opisie zdarzeń medycznych i wypadków. Zaproponowana metoda skutecznie

zredukowała szum informacyjny w postaci opisu faktów i celnie zidentyfikowała negatywne emocje dotyczące bezsilności i frustracji.

> *„Całe życie byłam osobą szczupłą, nawet chudą. W 2020 r. w ciągu ok 8 miesięcy utyłam prawie 30kg, chociaż nie zmieniłam ani diety ani trybu życia (w mojej rodzinie od strony Taty otyłość oraz cukrzyca występują u wszystkich osób które znam). Potem przytyłam jeszcze ok. 10 kg. Źle się czuję z moją wagą, nie mogę nosić ubrań, czy butów, które mam (a zbierałam je latami) i czuję, że w nic się nie mieszczę. Do tego ma psiaka z którym dużo chodzę, ale jest to dla mnie ogromny wysiłek, bo mam wrażenie, że mięśnie nie dają rady. Do tego ciężko mi się schylać, a przy pracach domowych bardzo się pocę, bo jest to dla mnie ogromny wysiłek. W styczniu 2022r. upadłam na lodzie i mocno uszkodziłam sobie kolano. W kwietniu 2022 r. miałam operację na to kolano, co na ponad pół roku unieruchomiło mnie na kanapie. Bardzo mi wtedy przeszkadzało moje ciało, potrzebowałam pomocy przy myciu, czy chodzeniu do toalety."*

Interesującym przypadkiem weryfikującym skuteczność metody jest poniższa notatka autorstwa osoby chorej. Zastosowany algorytm poprawnie zidentyfikował silną obecność obu kontekstów: pozytywnego (stopień przynależności 0,645) oraz negatywnego (stopień przynależności 0,783), ostatecznie klasyfikując wypowiedź jako reprezentującą kontekst mieszany. Zgodność tego wyniku z oceną ekspercką dowodzi, że słowniki bazowe zostały opracowane prawidłowo, a podejście oparte na LSA i SVD umożliwia identyfikację subtelności semantycznych bez utraty informacji o przeciwstawnych ładunkach emocjonalnych.

> *„Moje ciało podoba mi się w zależności od dnia i ogólnego humoru. Lubię swoje oczy, nos, długie palce u rąk i ręce. Czuję, że moje ciało nie jest wychudzone, pomimo, że wszyscy naokoło wraz z lekarzami mówią, że tak jest. W jego akceptacji przeszkadza mi zaburzony obraz swojego ciała, lecz próbuje z nim walczyć. Czuję jednak, że bardzo wyniszczyłam mój organizm i moje ciało...Z każdym dniem próbuję pokochać je, ale to czasem nie wychodzi... Pomimo wszystko jednak jestem wdzięczna mojemu ciału, że mogę się ruszać, biegać, funkcjonować i się rozwijać. Anoreksji nienawidzę za wszystko, za odebranie mi radości z życia oraz za nienawiść do swojego ciała."*

Największą wartość przynależności notatki do tematu emocji w kontekście negatywnym dla całej grupy badawczej uzyskała notatka pochodząca od osoby chorej, piszącej następująco:

> *„Moje ciało: ogromny nos, niekształtna twarz, głupie kręcone włosy, nudny kolor oczu, brzydka, pulchna twarz, dupa broda, smutny wyraz twarzy, gruby tułów, grube uda, duże stopy - jak u wielkiej stopy. Nieproporcjonalne, brzydkie, bez kształtów, coś strasznego, coś czego nie akceptuję w 100%, nienawidzę go, mój wróg z którym walczę."*

Eksperci również wskazali, że w analizowanej notatce wyraźnie dominują emocje o charakterze negatywnym. Co ciekawe, jest to ta sama notatka, która uzyskała najwyższy

wynik w obszarze negatywnego obrazu ciała. Z kolei maksymalną wartość przynależności do kontekstu pozytywnego metoda zidentyfikowała w wypowiedzi osoby zdrowej, która o swoim ciele napisała następująco:

> *„Moje ciało jest idealne i piękne. Mam duże wcięcie w talii oraz ładne nogi, płaski brzuch i duże cycki i dupę. Bardzo mi się podoba moje ciało i jestem z niego zadowolona."*

Analizując poszczególne kategorie rozbieżnych wyników, można stwierdzić że:

- **Błąd I rodzaju (odwrócona polaryzacja)** - wystąpił zaledwie w 3 notatkach z całego zbioru badawczego, przy czym wszystkie przypadki dotyczyły notatek osób chorych. Przekłada się to na 1,5% całego zbioru oraz 2,6% w grupie notatek osób chorujących na anoreksję. Mimo rzadkiego występowania, błąd ten wyraźnie uwypukla kluczowe ograniczenie zastosowanej metody, jakim jest brak obsługi negacji. Reprezentacja notatki opiera się na modelu worka słów z ważeniem lokalno-globalnym, w którym terminy zliczane są niezależnie od kontekstu składniowego. W konsekwencji obecność słowa kluczowego zwiększa wartość przynależności do danego tematu nawet wtedy, gdy w tekście wystąpiło ono z negacją. Sytuację tę dobrze ilustrują poniższe przykłady:

  > *„Nie lubię swojego brzucha, nie lubię opuchlizny na twarzy, nie lubię przez to kupować nowych ubrań, nie lubię swojej seksualności przez masę ciała."*

  > *„Nie podoba mi się, nie mieszczę się w ulubione ubrania, pomimo ładnych ubrań nie ma porządnego efektu bo mam za duży brzuch, biust, pupę,grube ręce."*

- **Błąd II rodzaju (przeoczenie tematu)** - ponownie wystąpił wyłącznie w wypowiedziach osób chorych (3 przypadki). Odpowiada to 1,5% całego zbioru danych oraz 2,6% w grupie pacjentek z anoreksją. Zjawisko to dobrze ilustruje poniższa notatka:

  > *„Jak to się zaczęło? Bardzo zwyczajnie. Po prostu pewnego dnia zrozumiałam, że skoro nikt mnie nie akceptuje to będę sama siebie akceptować. Tak zaczęłam odchudzanie. [...] Na początku odchudzania jadłam bardzo mało. Po krótkim czasie zdałam sobie sprawę że jak nie jem to czuje niesamowitą satysfakcje - czuje się taka silna i wytrwała. Wiec na początku zrezygnowałam z cukrów, masła i tłuszczy. Teraz moim dniowym posiłkiem jest sałatka. Wiem że potrzebuje pomocy. Już nie czuję się dobrze od nie jedzenia - czuje się złapana w klatkę bez odwrotu."*

  Szczegółowa analiza tych rozbieżności uwidacznia zasadniczą różnicę między sposobem oceniania przez ekspertów a zautomatyzowanym podejściem słownikowym opartym na LSA i SVD. Eksperci interpretują tekst całościowo, uwzględniając emocjonalny ton wypowiedzi, przebieg narracji oraz metaforyczne i ukryte znaczenia. Zaproponowana metoda działa na zredukowanej przestrzeni cech semantycznych generowanej na bazie słowników kluczowych. W analizowanym

przykładzie eksperci jednoznacznie zidentyfikowali negatywny ładunek emocjonalny. Metoda nie wykryła jednak tego tematu, ponieważ negatywne emocje zostały wyrażone pośrednio, czyli w sposób opisowy poprzez pisanie o kontroli, odchudzaniu i poczuciu „uwięzienia", a nie poprzez słowa oznaczające negatywne emocje.

- **Błąd III rodzaju (fałszywe wykrycie)** - podobnie jak w poprzednim obszarze, stanowił najczęstszą rozbieżność także dla tego obszaru. Wystąpił w 16 z 201 notatek (8,0% całego zbioru). W wypowiedziach osób chorych odnotowano 6 takich przypadków (5,0%), natomiast w grupie osób zdrowych 10 (co stanowi 11,6% tej próby).

  Przykładami notatek, w których metoda okazała się zbyt czuła są np.:

  > *„Moje ciało jest w porządku, nie mam z nim problemu, ani nie mam przez nie kompleksów."*

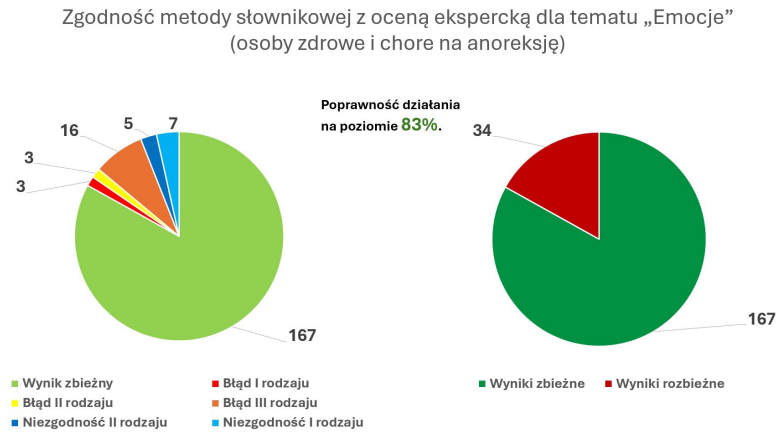
  > *„Nie jestem za gruba, mój zdaniem jestem normalna, ale muszę trochę przytyć, bo teraz chyba trochę jestem za chuda i to zagraża mojemu życiu. Musze tez dojeść, żeby waga nie spadała a rosła do pewnego momentu."*

  Analizując powyższe przykłady można zauważyć, że przez brak uwzględniania negacji obecność słów takich jak „*problem*" czy „*kompleksy*" sztucznie zawyżyła wartość przynależności notatki to tematu emocji w kontekście negatywnym. W drugim przykładzie słowa o „*zagrożeniu życia*" zostały wychwycone jako negatywne emocje przez metodę, podczas gdy eksperci zinterpretowali tę wypowiedź jako rzeczowy, pozbawiony gwałtownych emocji opis faktów oraz planu działania.

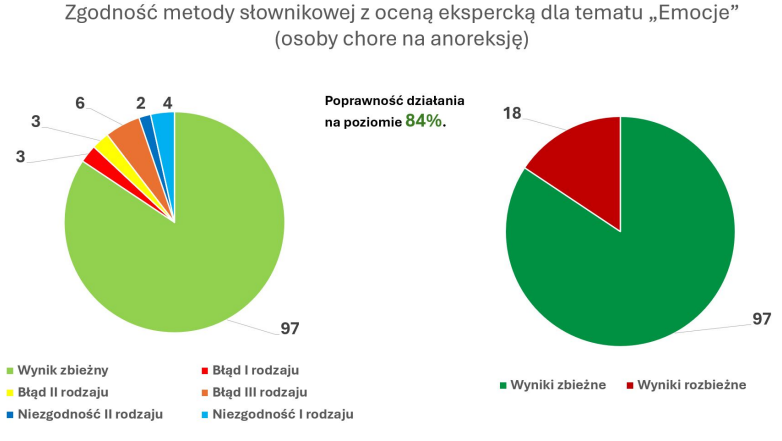
- **Niezgodność I rodzaju** - wystąpiła w 7 z 201 notatek (3,5% całego zbioru). W notatkach osób chorych odnotowano 4 takie przypadki (3,5%) oraz 3 razy w pisemnych wypowiedziach osób zdrowych (3,5%).

- **Niezgodność II rodzaju** - wystąpiła w 5 z 201 notatek (2,3% całego zbioru). W notatkach osób chorych odnotowano 2 takie przypadki (1,7%), natomiast w notatkach osób zdrowych 3 przypadki (3,5%).

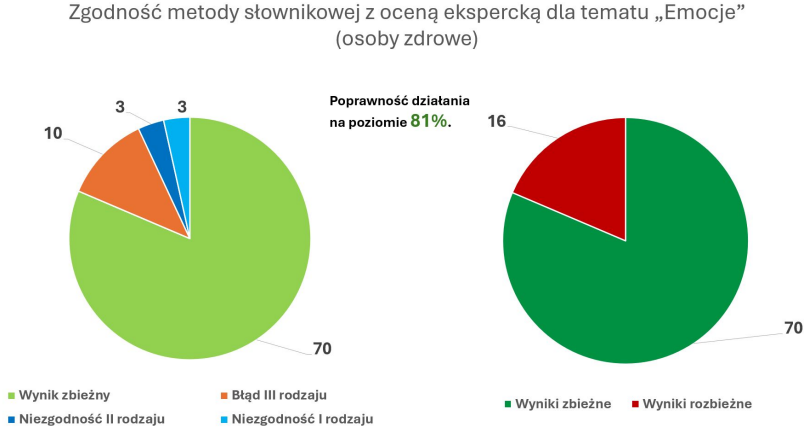
Można przypuszczać, że wysoki poziom zgodności (przekraczający 80%) w obu grupach notatek wiąże się ze specyfiką samego słownika emocji. Emocje są zazwyczaj wyrażane w sposób bardziej jednoznaczny pod względem słownictwa, co potencjalnie ułatwiło automatyczną detekcję w porównaniu z obszarem obrazu ciała. Warto podkreślić, że podobny poziom skuteczności w obu grupach (84% i 81%) sugeruje, że metoda jest stabilna niezależnie od charakteru wypowiedzi oraz możliwych różnic w sposobie formułowania treści przez zdrowe i chore osoby.



(a)



(b)



(c)

Rysunek 4.2: Graficzna prezentacja wyników dla obszaru „Emocje” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

Trzecim analizowanym obszarem trudności była „Samoocena". Na rysunku 4.3 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.3a przedstawia wyniki dla całej grupy badawczej, 4.3b rezultaty dla notatek autorstwa osób chorujących na anoreksję, natomiast 4.3c dotyczy grupy notatek osób zdrowych.

W przypadku tego tematu metoda słownikowa oparta na LSA i SVD wykazała bardzo wysoką ogólną poprawność działania osiągając 86% poprawności w całym zbiorze (rysunek 4.3a), czyli dla 173 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. W przeciwieństwie do obszaru „Obraz ciała", a podobnie jak w przypadku „Emocji" skuteczność wykrycia tematu samooceny okazała się stabilna i zbliżona w obu analizowanych grupach. W grupie notatek osób chorych na anoreksję metoda osiągnęła poprawność działania na poziomie 87% (z wszystkich 115 notatek 100 było zgodne z oceną ekspercką, a 15 było rozbieżnych, rysunek 4.3b). Wśród nielicznych błędów, w notatkach osób chorych, najczęściej występował błąd III rodzaju (5 notatek) oraz niezgodność I rodzaju (5 notatek). Błąd I rodzaju i niezgodność II rodzaju miały charakter incydentalny i wystąpiły odpowiednio w 2 i 3 przypadkach. W grupie wypowiedzi pisemnych osób zdrowych metoda osiągnęła poprawność na poziomie 85% (z wszystkich 86 notatek 73 było zgodnych z oceną ekspercką, a 13 było rozbieżnych, rysunek 4.3c). Podobnie jak przy poprzednim obszarze trudności, dominującą kategorią rozbieżności był błąd III rodzaju, który stanowił ponad 60% wszystkich pomyłek w tej grupie (dla 8 notatek występował ten błąd). Błąd I rodzaju i niezgodność I rodzaju miały charakter incydentalny, występujący odpowiednio w 1 i 4 notatkach.

W obu grupach nie odnotowano błędu II rodzaju (przeoczenie tematu).

Największą wartość przynależności notatki do tematu samooceny w kontekście negatywnym dla całej grupy badawczej uzyskała notatka pochodząca od osoby chorej, która pisała następująco:

> *„Grube, ohydne, brzydkie, pulchne, fajne włosy. Wyniszczone. Widzę się inaczej niż wyglądam, więc nie mogę się ocenić. Dla mnie jestem gruba, ale dla innych wychudzona. Nienawidzę swojego ciała."*

W notatkach osób zdrowych również przejawiała się negatywna samoocena. Przykładem takiej notatki jest:

> *„jest brzydkie - nie jestem z niego zadowolona - mam przesuszoną skórę - mam lekki cellulit - jestem okropnie wysoka - mam krzywe plecy - chciałabym być chudsza - chciałabym mieć więcej mięśni - jestem deską :) - nie lubię swojego ciała."*

Oba powyższe przypadki stanowią również przykłady wyników zbieżnych, w których zarówno metoda słownikowa, jak i zespół ekspertów zgodnie wskazali na dominację samooceny o charakterze negatywnym.

Według metody poniższa notatka pochodząca od osoby zdrowej uzyskała największą wartość pozytywnej samooceny:

> *„ładne zgrabne lubię i w ogóle wysportowane szczupłe wysokie proporcjonalne trochę krzywe (szpotawe kolana, nie polecam) minimalnie pryszczate, ale da się przeżyć często boli ale i tak zajebiste".*

Według ekspertów w tej notatce wyraźnie dominuje samoocena w kontekście pozytywnym. Co prawda metoda słownikowa obok pozytywnej samooceny również wykazała występowanie negatywnej w powyższym przykładzie jednak po obliczeniu różnicy względnej poprawnie wskazała przewagę kontekstu pozytywnego.

Analizując poszczególne kategorie występujących rozbieżnych wyników, można stwierdzić że:

- **Błąd I rodzaju (odwrócona polaryzacja)** - wystąpił zaledwie w 3 notatkach z całego zbioru (1,5%). W notatkach osób chorych odnotowano 2 takie przypadki (1,7%), natomiast w wypowiedziach pisemnych osób zdrowych jeden (1,2%). Podobnie jak w poprzednich obszarach, błąd ten wynika z kluczowego ograniczenia metody słownikowej bazującej na LSA i SVD, która polega na braku analizy zależności słów i ignorowania negacji. Mechanizm ten ilustrują dwa poniższe fragmenty:

  > *„Moje ciało jest w porządku, nie mam z nim problemu, ani nie mam przez nie kompleksów."*

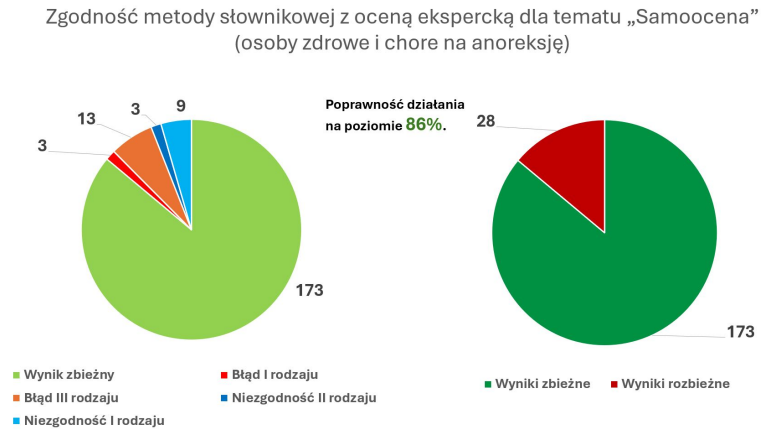
  > *„Nie podoba mi się, nie mieszczę się w ulubione ubrania, pomimo ładnych ubrań nie ma porządnego efektu bo mam za duży brzuch, biust, pupę,grube ręce.".*

  W pierwszej wypowiedzi eksperci wskazali pozytywny kontekst samooceny (akceptacja własnego ciała). Algorytm zaklasyfikował ją jednak jako negatywną. Wynika to z faktu, że terminy o wysokich wagach w słowniku, takie jak *„problem"* czy *„kompleksy"*, zwiększyły wartość wskaźnika powiązania z tematem w kontekście negatywnym, gdyż metoda nie uwzględnia zaprzeczeń. W drugim przypadku doszło do sytuacji odwrotnej. Mimo, że notatka jest ewidentnie samokrytyczna, algorytm przypisał jej przewagę samooceny w kontekście pozytywnym z powodu wyłapania pojedynczych określeń ignorując negacje. Oba przykłady potwierdzają, że choć model oparty na słownikach tematycznych oraz LSA/SVD bezbłędnie identyfikuje samą obecność badanego obszaru, to wyznaczenie właściwej polaryzacji pozostaje wrażliwe na brak uwzględnienia negacji.

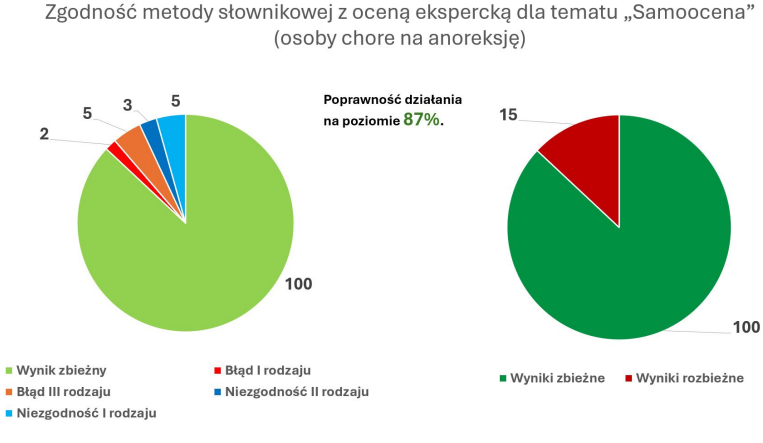
- **Błąd II rodzaju (przeoczenie tematu)** - nie wystąpił.

- **Błąd III rodzaju (fałszywe wykrycie)** - podobnie jak w poprzednich obszarach, stanowił on najczęstszą przyczynę rozbieżności. Wystąpił łącznie w 13 z 201 notatek (6,5%). W grupie notatek osób chorych odnotowano 5 takich przypadków (4,3%), a w grupie wypowiedzi pisemnych osób zdrowych 8 (9,3%).

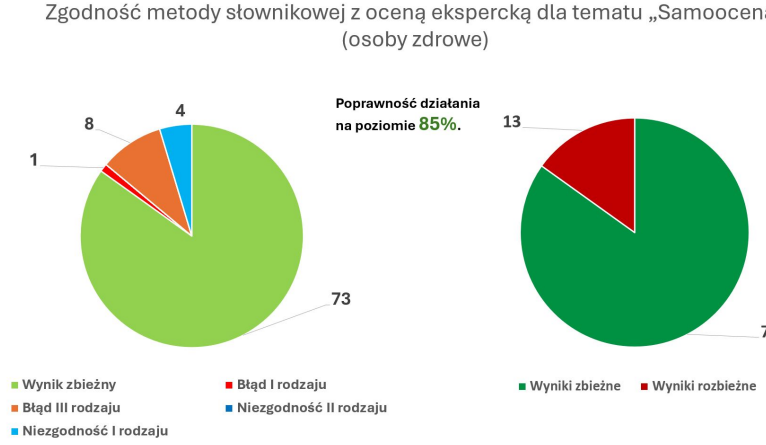
- **Niezgodność I rodzaju** - wystąpiła w 9 notatkach z całego zbioru (4,5%). W grupie wypowiedzi osób chorych odnotowano 5 takich przypadków (4,3%), natomiast w grupie notatek osób zdrowych pojawiła się 4 razy (4,7%).



(a)



(b)



(c)

Rysunek 4.3: Graficzna prezentacja wyników dla obszaru „Samoocena” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

- **Niezgodność II rodzaju** - wystąpiła zaledwie w 3 notatkach (1,5%). Wszystkie przypadki dotyczyły notatek osób chorych na anoreksję, co stanowi 2,6% w tej grupie.

W przypadku niezgodności I oraz II rodzaju mechanizm powstawania tych rozbieżności jest tożsamy z opisanym we wcześniejszych obszarach. Wynika ono z zestawienia sztywnego kryterium ilościowego zastosowanego w metodzie (próg 20% różnicy wartości przynależności) z jakościową oceną ekspercką. Psycholodzy oceniali wypowiedzi całościowo, biorąc pod uwagę ładunek emocjonalny, wagę poszczególnych stwierdzeń oraz intencję osoby badanej, podczas gdy algorytm bazował na ścisłych, algebraicznych wartościach.

Podsumowując, w obszarze trudności „Samoocena" stwierdzono poprawność działania metody słownikowej na poziomie 86% dla całego zbioru. Oznacza to, że w zdecydowanej większości przypadków metoda prawidłowo rozpoznała obecność i kontekst tego tematu. Analizując wyniki osobno w grupie osób chorych i zdrowych, poprawność działania wyniosła odpowiednio 87% i 85%. Warto podkreślić, że podobny poziom skuteczności w obu grupach sugeruje, że metoda jest stabilna niezależnie od charakteru wypowiedzi oraz możliwych różnic w sposobie formułowania treści przez zdrowe i chore osoby.

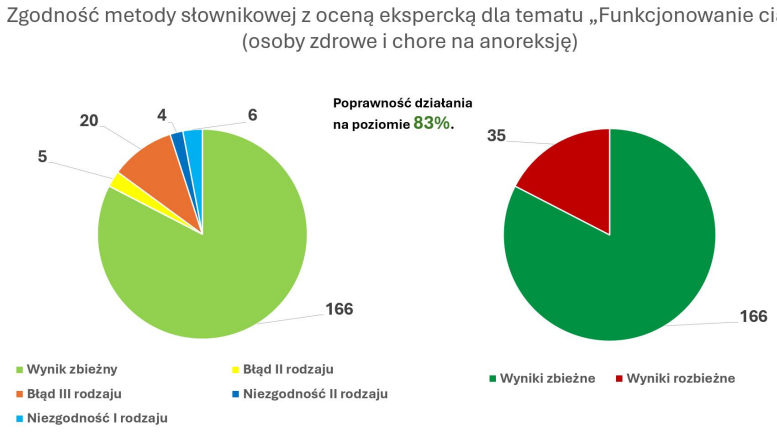
Czwartym analizowanym obszarem trudności było „Funkcjonowanie ciała". Na rysunku 4.4 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.4a przedstawia wyniki dla całej grupy badawczej, 4.4b rezultaty dla osób chorujących na anoreksję, natomiast 4.4c dotyczy notatek osób zdrowych.

W przypadku tego tematu metoda słownikowa wykazała wysoką ogólną poprawność działania osiągając 83% poprawności w całym zbiorze (rysunek 4.4a), czyli dla 166 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. Widać tu różnicę w poprawności działania pomiędzy grupą osób chorych i zdrowych, jednakże nie jest ona tak duża jak w przypadku obszaru „Obraz ciała". W notatkach w grupie osób chorych na anoreksję metoda osiągnęła poprawność działania na poziomie 86% (z wszystkich 115 notatek 99 było zgodne z oceną ekspercką, a 16 było rozbieżnych, rysunek 4.4b). Najczęściej występował błąd III rodzaju. Odnotowano go dla 9 notatek, co stanowi 7,8% wszystkich wyników. W grupie notatek osób zdrowych metoda osiągnęła poprawność na poziomie 78% (z wszystkich 86 notatek 67 było zgodnych z oceną ekspercką, a 19 było rozbieżnych, rysunek 4.4c). Podobnie jak przy poprzednim obszarze trudności, dominującą kategorią rozbieżności był błąd III rodzaju, który stanowił ponad połowę wszystkich pomyłek w tej grupie (dla 11 notatek występował ten błąd).

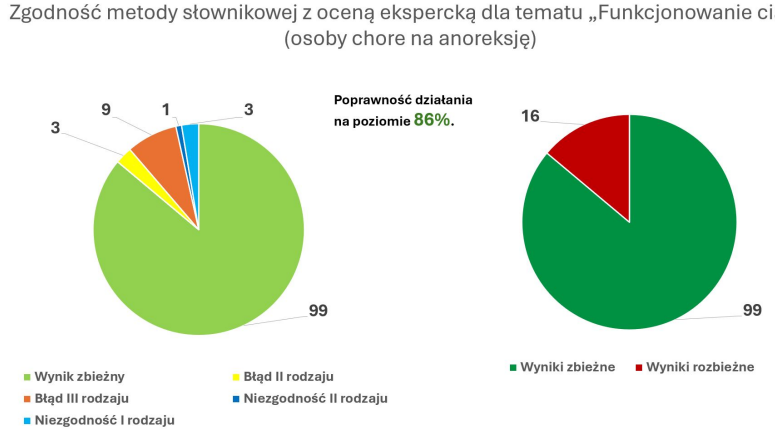
W obu grupach nie odnotowano błędu I rodzaju (odwrócona polaryzacja), a błąd II rodzaju i niezgodności I i II rodzaju miały charakter incydentalny. W całej badanej próbie (201 wypowiedzi pismenych) dotyczyły odpowiednio 5, 6 i 4 przypadków.

Szczegółowa analiza poszczególnych kategorii rozbieżności:

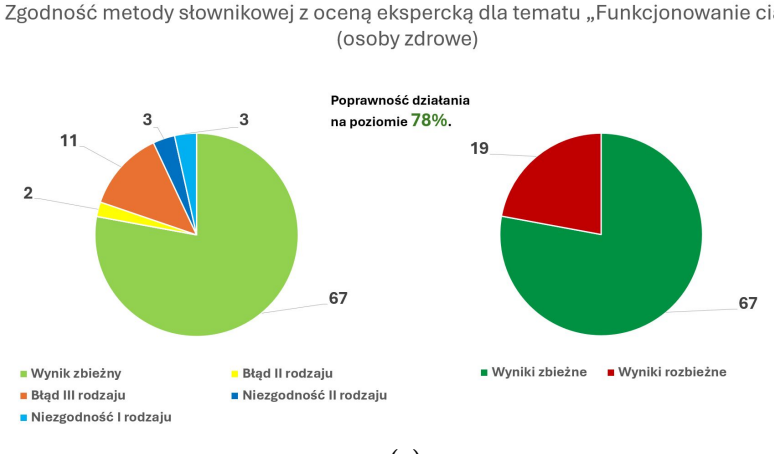
- **Błąd I rodzaju (odwrócona polaryzacja)** - nie wystąpił w żadnej z analizowanych notatek.



(a)



(b)



(c)

Rysunek 4.4: Graficzna prezentacja wyników dla obszaru „Funkcjonowanie ciała” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

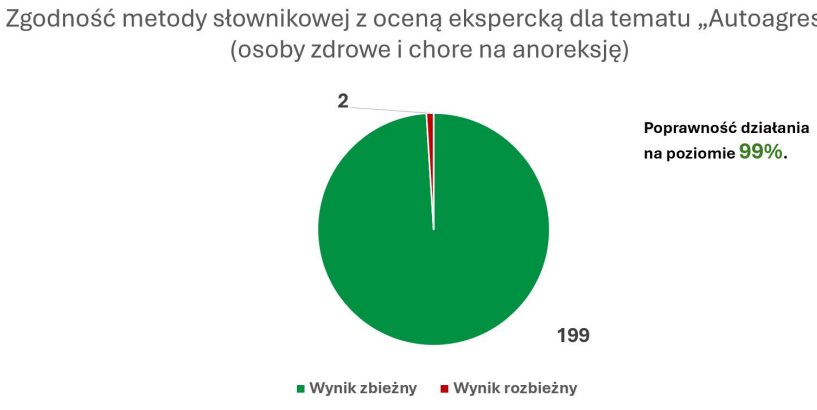
- **Błąd II rodzaju (przeoczenie tematu)** - odnotowano zaledwie w 5 wypowiedziach pisemnych (2,5% całej próby). Trzy przypadki dotyczyły notatek osób chorych (2,6% w tej grupie), natomiast pozostałe dwa dotyczyły grupy osób zdrowych (2,3%).
- **Błąd III rodzaju (fałszywe wykrycie)** - stanowił najczęstszą przyczynę rozbieżności w całym zbiorze, obejmując łącznie 20 notatek (blisko 10% całej próby). W grupie notatek osób chorych wystąpił 9 razy (7,8%), natomiast w grupie wypowiedzi osób zdrowych odnotowano 11 takich przypadków (12,8%).
- **Niezgodność I rodzaju** - pojawiła się w 6 notatkach (prawie 3% całego zbioru), rozkładając się równomiernie między badane próby: 3 notatki autorstwa osób chorych (2,6%) oraz 3 osób zdrowych (3,5%).
- **Niezgodność II rodzaju** - wystąpiła zaledwie w 4 wypowiedziach (niecałe 2% całej próby). Dotyczyła ona tylko jednej notatki w grupie osób chorych (0,9%) oraz 3 notatek w grupie zdrowych (3,5%).

Podsumowując, uzyskane wyniki wskazują na zadowalającą ogólną trafność identyfikacji (83%), przy czym metoda działała skuteczniej w przypadku notatek z grupy osób chorych niż zdrowych (odpowiednio 86% i 78%).

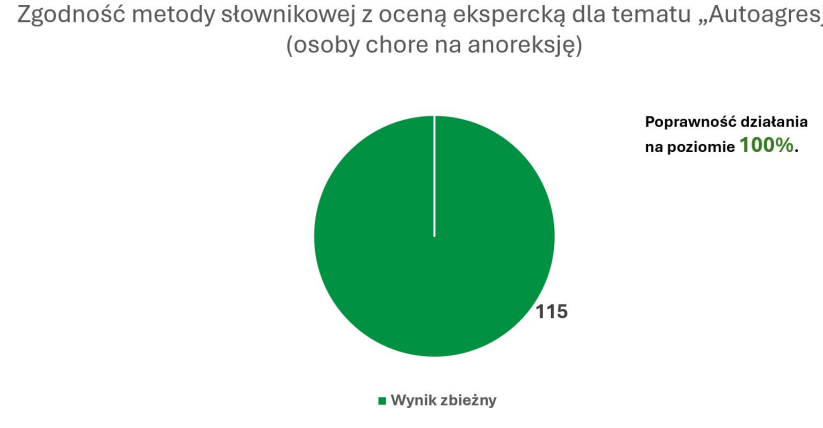
Kolejnym analizowanym obszarem trudności była „Autoagresja". Na rysunku 4.5 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.5a przedstawia wyniki dla całej grupy badawczej, 4.5b rezultaty dla notatek osób chorujących na anoreksję, natomiast 4.5c dotyczy wypowiedzi pisemnych osób zdrowych.

Obszar tematyczny „Autoagresja" jest jednym z dwóch tematów, który charakteryzował się najwyższym poziomem zgodności w całym badaniu, osiągając poziom 99% (rysunek 4.5a), czyli dla 198 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. Eksperci zidentyfikowali wątek autoagresji łącznie w 18 wpisach, przy czym wystąpił on niemal wyłącznie u osób zmagających się z anoreksją (17 przypadków) i tylko w jednej wypowiedzi z grupy osób zdrowych.

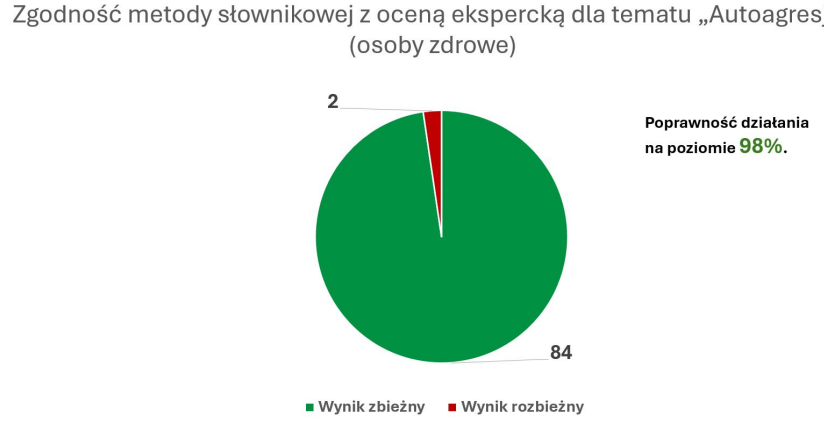
W przypadku analizy opracowaną metodą w notatkach osób chorujących na anoreksję odnotowano 100% zgodności z oceną ekspercką, czyli metoda ani razu się nie pomyliła (rysunek 4.5b). Oznacza, to, że zidentyfikowała wszystkie 17 wzmianek o autoagresji oraz prawidłowo wykluczyła jej obecność w pozostałych 98 tekstach. W wypowiedziach pisemnych autorstwa osób zdrowych poprawność wyniosła 98% (rysunek 4.5c), co odpowiada zgodności w 84 na 86 notatek. Algorytm poprawnie rozpoznał jedyny występujący tam przypadek autoagresji oraz potwierdził jej brak w 83 wypowiedziach. Jedyne rozbieżności stanowiły dwa przypadki fałszywego wykrycia (błąd III rodzaju), w których metoda przypisała obecność tego tematu pomimo, że eksperci nie wykazali jego obecności.



(a)



(b)



(c)

Rysunek 4.5: Graficzna prezentacja wyników dla obszaru „Autoagresja” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

Przykładowe notatki, w których występowała autoagresja to:

> *„Tak jakbym prowadziła dwa życia, jak byłam z nim, to eksponowało się ciało, a jak już go nie było, to żyłam w poczuciu winy i tak jakbym chciała to ciało za to ukarać. Schować je, pokaleczyć, zagłodzić, jakoś ukarać."*

> *„Ja mam taki trochę władczy charakter, ma być tak jak ja mówię. I najczęściej, kiedy mi coś nie wychodziło, karałam siebie... Jeśli coś nie działo się po mojej myśli, to odreagowywałam to na swoim ciele. Zawsze. Albo poprzez wymioty, albo poprzez chudnięcie, albo poprzez cięcie się."*

Rozbieżności między wynikami metody a oceną eksperta wynikały z ograniczeń podejścia słownikowego połączonego z LSA i SVD. Zastosowany algorytm poprawnie wychwycił słowa związane z agresją i cierpieniem (*„wulgarne", „bezlitosne", „okrutne", „ból"*). Ze względu na brak analizy kontekstu algorytm nie uwzględnił, że w tych konkretnych wypowiedziach słowa te nie odnosiły się do aktów autoagresji. Przykłady tej rozbieżności przedstawiono poniżej:

> *„Moje ciało jest niemałe, potężne, umięśnione, wysokie, wulgarne, bezlitosne, denerwujące, okrutne. Czasem bywa lubiane."*

> *„Moje ciało jest zwykłe do bólu, nie ma w nim nic nadzwyczajnego, jest nieproporcjonalne i myślę, że plasuje się gdzieś na samym środku krzywej Gaussa jeśli chodzi o budowę."*

Podsumowując, w przypadku obszaru trudności jakim jest „Autoagresja" stwierdzono poprawność działania metody na poziomie 99%. Zatem, w większości przypadków metoda poprawnie zidentyfikowała obecność lub brak występowania tego tematu. Analizując wyniki osobno w grupie osób chorych i zdrowych, poprawność działania wyniosła odpowiednio 100% i 98%. Warto podkreślić, że podobny poziom skuteczności w obu grupach sugeruje, że metoda jest stabilna niezależnie od charakteru wypowiedzi oraz możliwych różnic w sposobie formułowania treści przez zdrowe i chore osoby. Wykrywanie wzorców językowych związanych z autoagresją może stanowić cenne narzędzie przesiewowe. Chociaż analiza słownikowa nie zastępuje profesjonalnej diagnozy, pozwala ona na sprawną identyfikację wypowiedzi nacechowanych zachowaniami autodestrukcyjnymi.

Szóstym analizowanym obszarem trudności był „Ból". Na rysunku 4.6 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.6a przedstawia rezultaty dla całej grupy badawczej, 4.6b wyniki dla notatek osób chorujących na anoreksję, natomiast 4.6c dotyczy wypowiedzi osób zdrowych.

Ten obszar tematyczny jest drugim, który charakteryzował się najwyższym poziomem zgodności w całym badaniu, osiągając poziom 99% (rysunek 4.6a), czyli dla 198 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. Według ekspertów temat bólu fizycznego nie pojawił się w notatkach osób chorych na anoreksje, a tylko dwa razy w wypowiedziach pochodzących od osób zdrowych.

W notatkach osób chorujących na anoreksję odnotowano 98% zgodności z oceną ekspercką. Metoda błędnie wykryła ten temat tylko w dwóch notatkach (rysunek 4.6b). Zatem algorytm poprawnie wykluczył wzmianki o bólu w 113 notatkach, a wykazał się nadinterpretacją w dwóch. W wypowiedziach tekstowych autorstwa osób zdrowych poprawność wyniosła 99%, co oznacza, że metoda pomyliła się tylko raz (rysunek 4.6c). Poprawnie wykryła poruszenie tego tematu w dwóch notatkach i w jednej wykazała jego obecność pomimo braku według ekspertów.
Poniżej zamieszczono obydwie notatki w których według ekspertów występował temat bólu. Metoda poprawnie wykryła każdą z nich.

> *„ładne zgrabne lubię i w ogóle wysportowane szczupłe wysokie proporcjonalne trochę krzywe (szpotawe kolana, nie polecam) minimalnie pryszczate, ale da się przeżyć często boli ale i tak zajebiste."*

> *„ćwiczenia, odżywianie sterydy urazy"*

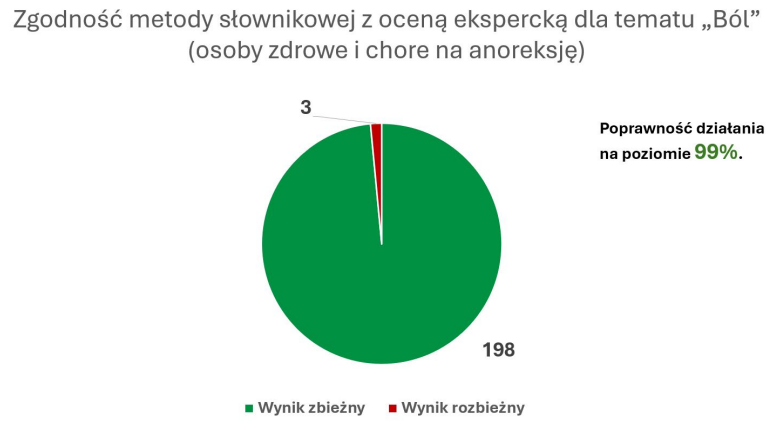
W pierwszym przykładzie autorka wprost deklaruje doznanie bólu fizycznego („*często boli*"). Choć wypowiada się bardzo pozytywnie i w pełni akceptuje swoje ciało („*i tak zajebiste*", „*da się przeżyć*"), to wprost przyznaje, że fizycznie odczuwa ból. Zarówno eksperci, jak i metoda poprawnie to wykryła. W drugim przypadku badana osoba nie sformułowała spójnej pełnej wypowiedzi, lecz podała zbiór pojedynczych pojęć. Takie notatki również zdarzały się dysponowanym materiale badawczym. Słowo „ból" nie pada tu dosłownie, ale pojawia się pojęcie „urazy", które jednoznacznie kojarzy się z dolegliwościami fizycznymi i uszkodzeniami ciała, co zostało poprawnie wychwycone zarówno przez ekspertów jak i metodę.

Rozbieżności między wynikami metody a oceną eksperta w temacie „Ból" wynikały z ograniczeń podejścia słownikowego połączonego z LSA i SVD. Zastosowany algorytm poprawnie powiązał w przestrzeni semantycznej słowa związane z urazami i stanem zapalnym (*„ból", „kontuzja", „opuchlizna"*). Ze względu na brak analizy kontekstu algorytm nie uwzględnił jednak, że w tych konkretnych wypowiedziach słowa te nie odnosiły się do aktualnie odczuwanego bólu fizycznego, lecz stanowiły elementy związku frazeologicznego (*„jest zwykłe do bólu"*), odniesienie do przeszłości lub opis cechy wyglądu (*„nie lubię opuchlizny na twarzy"*). Przykłady tych rozbieżności przedstawiono poniżej:

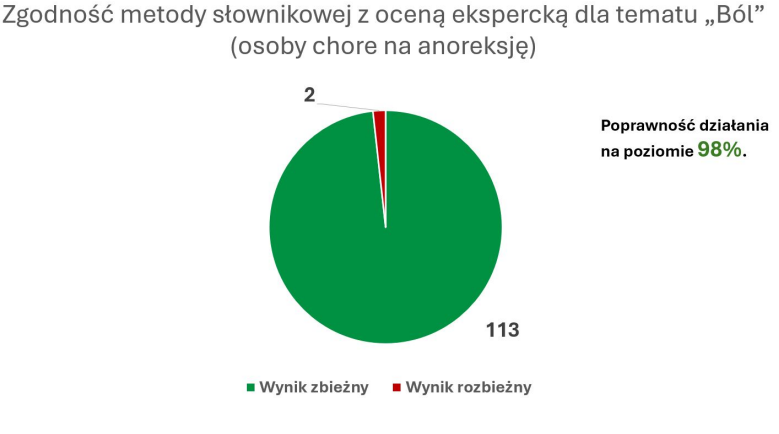
> *„Nie lubię swojego brzucha, nie lubię opuchlizny na twarzy, nie lubię przez to kupować nowych ubrań, nie lubię swojej seksualności przez masę ciała."*

> *„Postrzegam się pozytywnie. Ja przybrałam na wadze po kontuzji. Wiem tylko, że przytyć jest łatwo, mnie przynajmniej, bo to nie jest regułą, i szybko się to dzieje, ale pozbyć się nadwagi to dużo pracy i czasu."*

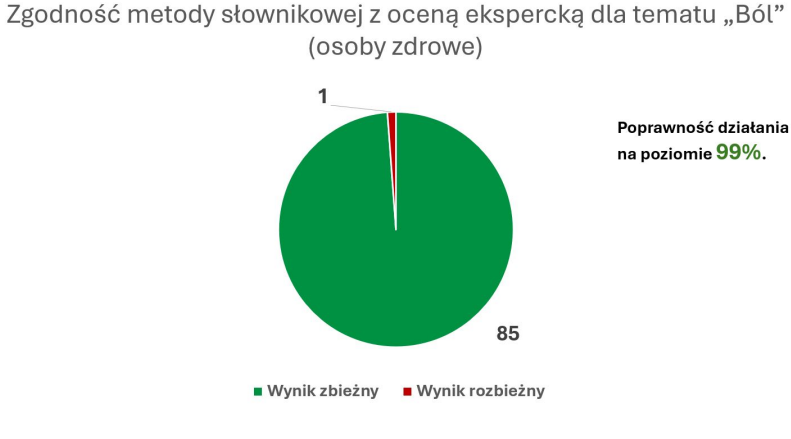
> *„Moje ciało jest zwykłe do bólu, nie ma w nim nic nadzwyczajnego, jest nieproporcjonalne i myślę, że plasuje się gdzieś na samym środku krzywej Gaussa jeśli chodzi o budowę."*



(a)



(b)



(c)

Rysunek 4.6: Graficzna prezentacja wyników dla obszaru „Ból” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

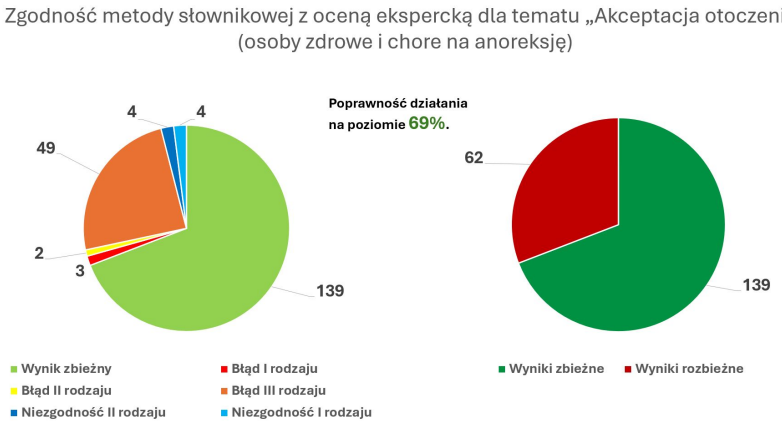
Podsumowując, w przypadku obszaru trudności jakim jest „Ból" stwierdzono poprawność działania metody na poziomie 99%. Zatem, w większości przypadków metoda poprawnie zidentyfikowała obecność lub brak występowania tego tematu. Analizując wyniki osobno w grupie osób chorych i zdrowych, poprawność działania wyniosła odpowiednio 98% i 99%. Warto podkreślić, że podobny poziom skuteczności w obu grupach sugeruje, że metoda jest stabilna niezależnie od charakteru wypowiedzi oraz możliwych różnic w sposobie formułowania treści przez zdrowe i chore osoby. Istniejące rozbieżności między metodą a oceną ekspercką miały charakter jednostkowy (metoda wykazała obecność tematu) i wynikały przede wszystkim ze specyfiki podejścia słownikowego. Metoda okazała się czuła na obecność pojedynczych terminów silnie powiązanych z tematem bólu fizycznego, ignorując kontekst.

Ostatnim, siódmym analizowanym obszarem trudności była „Akceptacja otoczenia". Na rysunku 4.7 zestawiono wyniki uzyskane za pomocą opracowanej metody z oceną ekspercką. Rysunek 4.7a przedstawia wyniki dla całej grupy badawczej, 4.7b rezultaty dla notatek osób chorujących na anoreksję, natomiast 4.7c dotyczy wypowiedzi osób zdrowych.

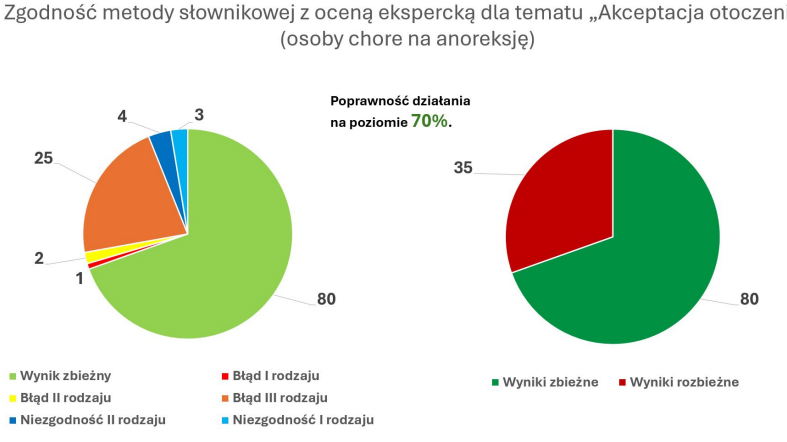
Obszar „Akceptacja otoczenia" okazał się najbardziej wymagający dla wykorzystanej metody spośród wszystkich analizowanych tematów. Ogólna zgodność poprawności działania wyniosła 69% w całym zbiorze (rysunek 4.7a), czyli dla 139 notatek z 201 metoda okazała się zbieżna z oceną ekspercką. W przypadku notatek autorstwa osób chorujących na anoreksję skuteczność wyniosła 70% (z wszystkich 115 notatek 80 było zgodnych z oceną ekspercką oraz 35 było rozbieżnych, rysunek 4.7b).Główną kategorią rozbieżnych wyników był błąd III rodzaju, który wystąpił w 25 przypadkach (ponad 71% wszystkich pomyłek w tej grupie). Pozostałe błędy: błąd I i II rodzaju oraz niezgodność I i II rodzaju miały charakter incydentalny. Ich częstość występowania wynosiła odpowiednio 1, 2, 3 oraz 4 przypadki i nie odbiegała istotnie od pozostałych obszarów tematycznych. W notatkach autorstwa osób zdrowych poprawność działania osiągnęła niemal identyczny poziom - 69% (z wszystkich 86 notatek 59 było zgodnych z oceną ekspercką, a 27 było rozbieżnych, rysunek 4.7c). Również i w tej grupie najliczniej występował błąd III rodzaju, ponieważ w aż 24 wypowiedziach pisemnych, odpowiadając za niemal 89% wszystkich błędnych rozpoznań. W grupie tej nie odnotowano natomiast żadnego przypadku błędu II rodzaju ani niezgodności II rodzaju. Błąd I rodzaju i niezgodność I rodzaju miały charakter incydentalny i wystąpiły odpowiednio 2 i 1 raz.

Analizując poszczególne kategorie rozbieżnych wyników, można stwierdzić że:

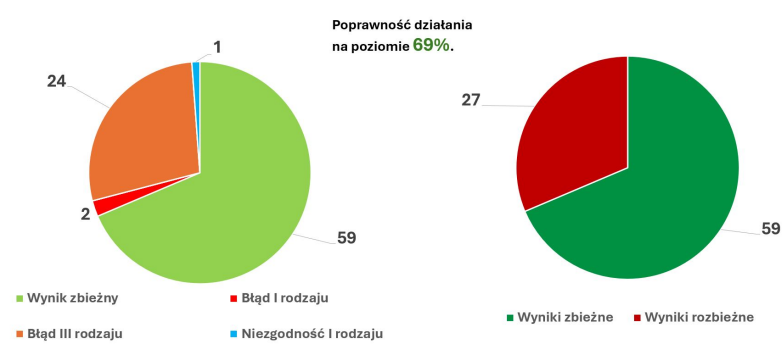
- **Błąd I rodzaju (odwrócona polaryzacja)** - odnotowano zaledwie w 3 wypowiedziach pisemnych (1,5% całej próby). Dwa przypadki dotyczyły notatek osób zdrowych (2,3% w tej grupie) i tylko jednej notatki osób chorych (niecały procent w tej grupie).
- **Błąd II rodzaju (przeoczenie tematu)** - odnotowano w tylko dwóch notatkach, co stanowi niecały procent wszystkich wyników. Błędy te wystąpiły w wypowiedziach osób chorych.



(a)



(b)



(c)

Rysunek 4.7: Graficzna prezentacja wyników dla obszaru „Akceptacja otoczenia” dla wszystkich uczestników (a), dla osób chorych na anoreksję (b) i dla osób zdrowych (c).

- **Błąd III rodzaju (fałszywe wykrycie)** - była to najczęstsza kategoria błędów. Wystąpiła w przypadku 49 notatek, co stanowi 24% wszystkich wyników, a wśród wszystkich rozbieżności to dokładnie 79%. W notatkach osób chorych błąd ten pojawił się w 25 przypadkach, co stanowi ponad 71% wszystkich rozbieżności w tej grupie. W wypowiedziach pisemnych osób zdrowych błąd ten wystąpił w aż 24 notatkach, co stanowi ponad 88% wszystkich rozbieżności w tej próbie.

- **Niezgodność I rodzaju** - wystąpiła 4 razy, co stanowi niecałe 2% wszystkich wyników. Wśród notatek osób chorych wystąpiła 3 razy i tylko w jednej notatce od osoby zdrowej.

- **Niezgodność II rodzaju** - wystąpiła tylko 4 razy, co stanowi niecałe 2% wszystkich wyników. Wszystkie przypadki odnotowano w notatkach osób chorych.

Podsumowując, skuteczność na poziomie 69% sprawia, że obszar „Akceptacja otoczenia" okazał się tematem najbardziej podatnym na błędy w całym badaniu. Wynik ten uwidacznia zasadnicze ograniczenie metody opartej na słownikach i LSA: algorytm wyznacza wskaźnik przynależności wyłącznie na podstawie zliczeń obecności poszczególnych słów kluczowych i ich synonimów, pomijając ich wzajemną relację. Główną przyczyną rozbieżności jest wysoka kontekstowość słownictwa przypisanego do tej kategorii. Algorytm sumuje wagi pojęć ze słownika i na tej podstawie generuje wysoką wartość przynależności, co prowadzi do błędów fałszywie pozytywnych (błąd III rodzaju) nawet wtedy, gdy kontekst wypowiedzi był neutralny. Eksperci czytają całą notatkę i oceniają ją całościowo, analizując intencję autorki.

W tabeli 4.1 przedstawiono zestawienie zbiorcze wyników detekcji dla wszystkich siedmiu analizowanych obszarów trudności, uwzględniające liczbę notatek zbieżnych, strukturę popełnionych błędów i niezgodności oraz ostateczną poprawność metody z rozbiciem na grupę osób chorych i zdrowych.

Najwyższą, niemal bezbłędną skuteczność metoda osiągnęła w obszarach takich jak: „Autoagresja" (99%) oraz „Ból" (99%). W obu tych kategoriach wystąpiły jedynie nieliczne błędy III rodzaju, czyli fałszywe wykrycie (odpowiednio 2 i 3 przypadki). Niemal stuprocentowa skuteczność metody w tych tematach wiąże się ze specyfiką tych obszarów, które charakteryzują się ściśle zdefiniowanym i jednoznacznym słownictwem.

Wysoki poziom zbieżności uzyskano również dla obszarów: „Samoocena" (86%), „Emocje" (83%) oraz „Funkcjonowanie ciała" (83%). Może to wynikać z faktu, że tematy te, choć są bardziej rozbudowane niż w przypadku bólu czy autoagresji, nadal opierają się na stosunkowo spójnym zestawie słów kluczowych i bezpośrednich deklaracjach autorów notatek (np. otwarte i jasne pisanie o emocjach takich jak: smutek, złość, lęku czy jasno wyrażanie problemów z codziennymi czynnościami). Występujące w tych kategoriach błędy miały charakter umiarkowany i wynikały głównie z czułości metody (błędy III rodzaju), a rzadziej z całkowitego pominięcia tematu czy błędnego przypisania kontekstu.

Z kolei najniższą poprawnością charakteryzowały się tematy: „Obraz ciała" (75%) oraz „Akceptacja otoczenia" (69%). W przypadku obszaru „Obraz ciała" słabszy wynik wynikał w dużej mierze ze specyfiki wypowiedzi osób chorych, które czasami racjonalizują swój stan, a nawet wyrażają zadowolenie z pogarszającego się wyglądu. Ponadto zdarzało się, że autorki notatek używały metaforycznych określeń, co utrudniało ich jednoznaczną klasyfikację. Bardzo istotnym źródłem pomyłek był również brak uwzględniania negacji przez metodę, przez co występujące zaprzeczenia w opisie wyglądu były błędnie interpretowane. W przypadku obszaru „Akceptacja otoczenia" trudność polega na tym, że ocena relacji z innymi ludźmi i otoczeniem wymaga rozumienia i poznania głębszego kontekstu, a nie jedynie wyłapania pojedynczych, kluczowych pojęć. Istotnym ograniczeniem wykorzystanej metody okazał się brak analizy kontekstu całej wypowiedzi, co często prowadziło do błędów popełnianych przez zaproponowane podejście.

Analiza struktury rozbieżności prowadzi do dwóch istotnych wniosków:

- Dominacja błędu III rodzaju - W większości obszarów, główną kategorią rozbieżności były przypadki, w których metoda wykryła dany temat, podczas gdy eksperci go pominęli. Świadczy to o wysokiej czułości metody. Jest to szczególnie widoczne w obszarze „Akceptacja otoczenia", gdzie odnotowano aż 49 błędów III rodzaju (przy zaledwie 3 błędach I rodzaju i 2 błędach II rodzaju i po 4 niezgodnościach I i II rodzaju).
- Wpływ specyfiki badanej grupy (notatki osób chorych względem zdrowych) - W prawie wszystkich analizowanych obszarach (oprócz bólu) metoda osiągnęła wyższą skuteczność w analizie notatek autorstwa osób chorych niż zdrowych. Różnica ta jest najbardziej widoczna w obszarze „Obraz ciała" (81% poprawności w grupie chorych wobec 66% dla zdrowych) oraz „Funkcjonowanie ciała" (86% względem 78%). Fakt, że zaproponowana metoda radzi sobie lepiej u osób chorych, a u zdrowych generuje dużo błędów III rodzaju (fałszywe wykrycie) może wynikać z charakterystyki języka używanego przez obie grupy. Może to skłaniać do wniosku, że wypowiedzi osób chorych charakteryzują się zazwyczaj większą dosadnością, jednoznacznością oraz bezpośrednim opisywaniem doświadczanych dolegliwości i ograniczeń, co ułatwia automatyczną detekcję. Podczas gdy osoby zdrowe częściej stosują język subtelny, wykorzystując metafory lub potoczne odniesienia do ciała w kontekście neutralnym. Skutkowało to występowaniem błędów III rodzaju (fałszywe wykrycie), czyli prowadziło do nadinterpretacji ze strony metody, w przeciwieństwie do ekspertów, którzy patrzyli na wypowiedź całościowo, analizując również kontekst wypowiedzi.

Tabela 4.1: Zbiorcze wyniki dla wszystkich obszarów trudności.

Obszar trudności	Liczba notatek zbieżnych	Liczba notatek, dla których metoda nie jest zbieżna: sumarycznie (chorzy, zdrowi)					Ostateczna poprawność metody
		Błąd I rod.	Błąd II rod.	Błąd III rod.	Niezg. I rod.	Niezg. II rod.	
Obraz ciała	150	10 (ch: 5, zdr: 5)	3 (ch: 3, zdr: 0)	17 (ch: 2, zdr: 15)	11 (ch: 5, zdr: 6)	10 (ch: 7, zdr: 3)	75% (ch: 81%, zdr: 66%)
Emocje	167	3 (ch: 3, zdr: 0)	3 (ch: 3, zdr: 0)	16 (ch: 6, zdr: 10)	7 (ch: 4, zdr: 3)	5 (ch: 2, zdr: 3)	83% (ch: 84%, zdr: 81%)
Samoocena	173	3 (ch: 2, zdr: 1)	0	13 (ch: 5, zdr: 8)	9 (ch: 5, zdr: 4)	3 (ch: 3, zdr: 0)	86% (ch: 87%, zdr: 85%)
Funkc. ciała	166	0	5 (ch: 3, zdr: 2)	20 (ch: 9, zdr: 11)	6 (ch: 3, zdr: 3)	4 (ch: 1, zdr: 3)	83% (ch: 86%, zdr: 78%)
Autoagresja	199	0	0	2 (ch: 0, zdr: 2)	0	0	99% (ch: 100%, zdr: 98%)
Ból	198	0	0	3 (ch: 2, zdr: 1)	0	0	99% (ch: 98%, zdr: 99%)
Akceptacja otoczenia	139	3 (ch: 1, zdr: 2)	2 (ch: 2, zdr: 0)	49 (ch: 25, zdr: 24)	4 (ch: 3, zdr: 1)	4 (ch: 4, zdr: 0)	69% (ch: 70%, zdr: 69%)

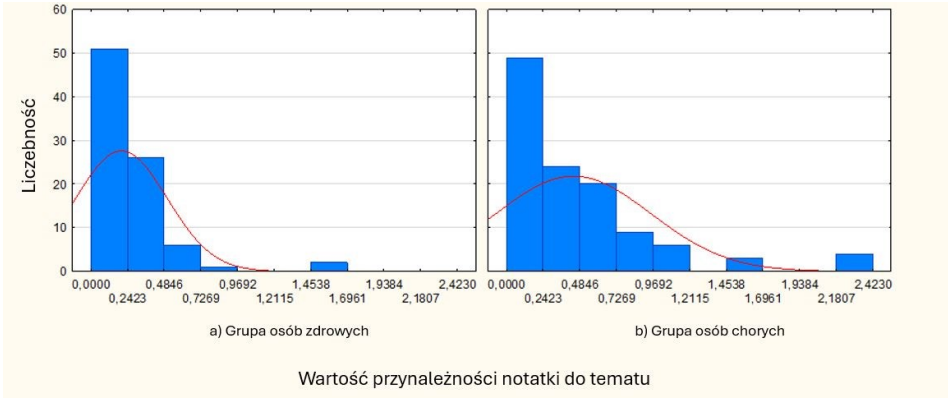
Zidentyfikowane rozbieżności w dużej mierze wynikają z ograniczeń metody słownikowej opartej na LSA i dekompozycji SVD. Do kluczowych czynników wpływających na obniżenie skuteczności należą:

- Brak uwzględnienia negacji - model worka słów stanowiący punkt wyjścia dla SVD operuje na pojedynczych słowach, przez co pomija negacje. Skutkuje to tym, że zaprzeczenie danego stanu (np. *„nie czuję bólu”*) zwiększa wartość przynależności tej notatki w stronę obecności tematu bólu zamiast jego braku.
- Brak analizy kontekstu wypowiedzi - metoda traktuje słowa, jak odizolowane jednostki, ignorując związki składniowe i semantyczne między zdaniami.
- Brak możliwości interpretacji metafor oraz ironii - rzutowanie do przestrzeni semantycznej LSA opiera się na dosłownych wagach słów kluczowych przypisanych do tematów, co prowadzi do błędów, gdy badana osoba posługuje się sarkazmem lub przenośniami.
- Skuteczność metody w dużej mierze opiera się na jakości stworzonych słowników.

4.2 Analiza porównawcza wartości przynależności notatek do obszarów trudności u osób chorych na anoreksję i zdrowych

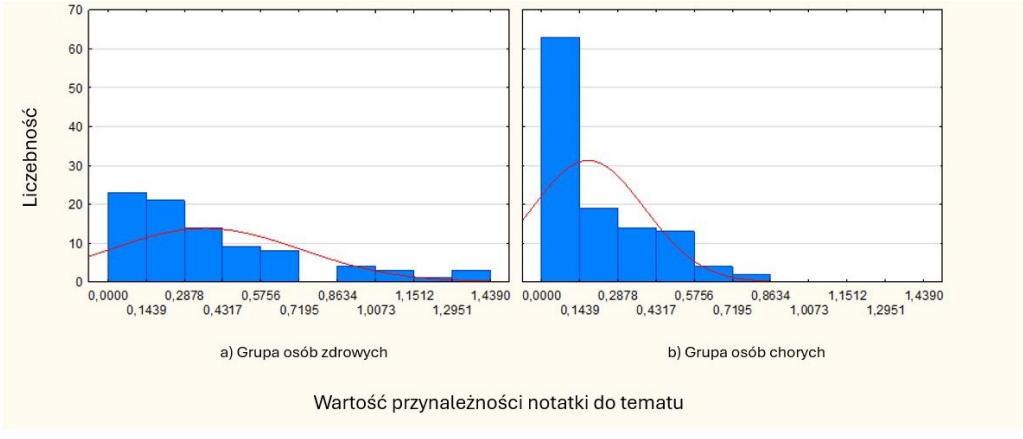
W tym podrozdziale zaprezentowano histogramy rozkładu zmiennych dotyczących wartości przynależności danej notatki do danego tematu w danym kontekście (rysunki 4.8 - 4.19). Przedstawiono ich interpretację oraz analizę statystyk opisowych (średnia i mediana). Analiza wykazała, że rozkłady wszystkich badanych zmiennych odbiegają w sposób istotny od rozkładu normalnego. Ze względu na niespełnienie podstawowego założenia o normalności rozkładów zmiennych zależnych do oceny istotności różnic międzygrupowych zdecydowano się na zastosowanie nieparametrycznego testu U Manna-Whitneya z poprawką na ciągłość. Ze względu na wielokrotne testowanie użyto poprawki Bonferroniego. Statystyki opisowe oraz wyniki testu U Manna-Whitneya znajdują się w tabeli 4.2. Prezentowane wyniki obejmują łączną próbę $N = 201$ osób, w tym 115 pacjentów chorych na anoreksję oraz 86 osób zdrowych.

Dla obszaru obrazu ciała w kontekście negatywnym (rysunek 4.8), w grupie osób chorych jak i zdrowym rozkład wartości ma charakter silnie prawoskośny (asymetryczny). Dla osób zdrowych dominują wartości zerowe lub bliskie zeru. Dla osób chorych rozkład jest znacznie bardziej rozproszony. W tej grupie widoczne są również pojedyncze obserwacje odstające, przyjmujące wartości powyżej 2,0. Osoby chore charakteryzują się wyraźnie wyższymi wartościami przynależności (średnia $M = 0{,}44$; mediana $Me = 0{,}31$) w porównaniu do osób zdrowych gdzie większość badanych nie przejawiała tych tendencji ($Me = 0{,}00$; $M = 0{,}20$). Analiza testu U Manna-Whitneya wykazała istotne statystycznie różnice między porównywanymi grupami ($U = 3289{,}0$; $Zskoryg. = 4{,}17$; $p < 0{,}001$).



Rysunek 4.8: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Obraz ciała w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

W grupie osób zdrowych rozkład wartości przynależności do tematu obrazu ciała w kontekście pozytywnym (rysunek 4.9) cechuje się łagodniejszą skośnością, wyższą średnią ($M = 0{,}36$) i medianą ($Me = 0{,}26$) w porównaniu do grupy osób chorych ($M = 0{,}18$; $Me = 0,11$). U osób chorych, rozkład silnie skupia się wokół zera, co wskazuje na deficyty w obszarze pozytywnego obrazu własnego ciała. Dla tej zmiennej test U Manna-Whitneya potwierdził obecność istotnej statystycznie różnicy pomiędzy analizowanymi grupami ($U = 3361{,}5$; $Zskoryg. = -3{,}99$; $p < 0{,}001$).

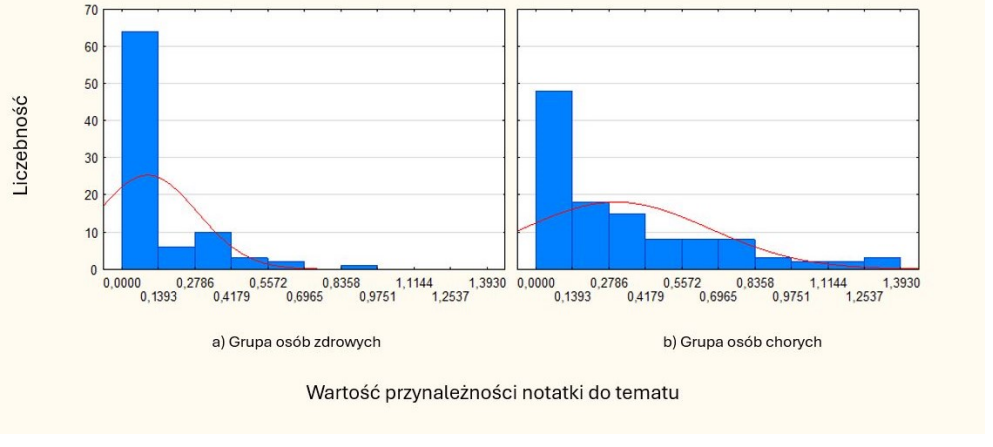


Rysunek 4.9: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Obraz ciała w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

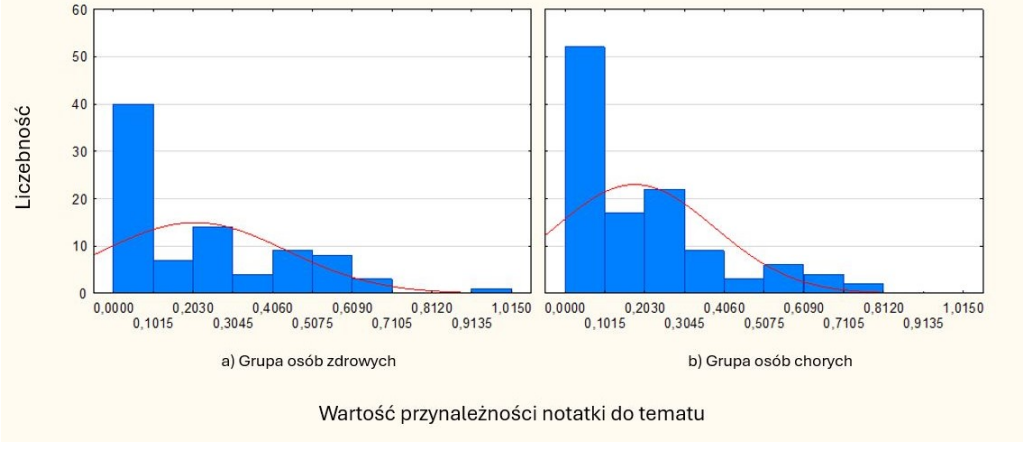
Dla osób zdrowych wartość przynależności do obszaru emocji w kontekście negatywnym charakteryzuje się silną prawoskośnością (rysunek 4.10). Zdecydowana większość badanych uzyskała wyniki bliskie zeru ($M = 0{,}1$; $Me = 0$). Chociaż w grupie osób

chorych rozkład również jest prawoskośny, to jednak charakteryzuje się wyższymi wartościami średniej i mediany ($M = 0{,}31$; $Me = 0{,}21$). Analiza testu U Manna-Whitneya wykazała istotne statystycznie różnice między porównywanymi grupami ($U = 3135{,}0$; $Zskoryg. = 4{,}86$; $p < 0{,}001$).

Analiza poziomu wartości przynależności do tematu emocji w kontekście pozytywnym (rysunek 4.11) nie wykazała istotnych statystycznie różnic pomiędzy grupami ($U = 4712{,}0$; $Zskoryg. = -0{,}6$; $p = 0{,}550$). Zarówno w u osób zdrowych ($M = 0{,}21$; $Me = 0{,}17$), jak i u osób chorych ($M = 0{,}18$; $Me = 0{,}14$) poziomy te są do siebie zbliżone.

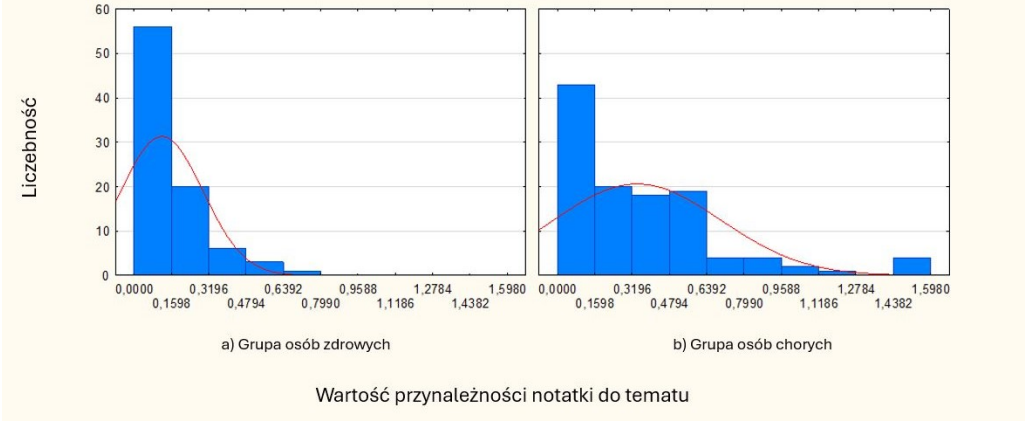


Rysunek 4.10: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Emocje w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.



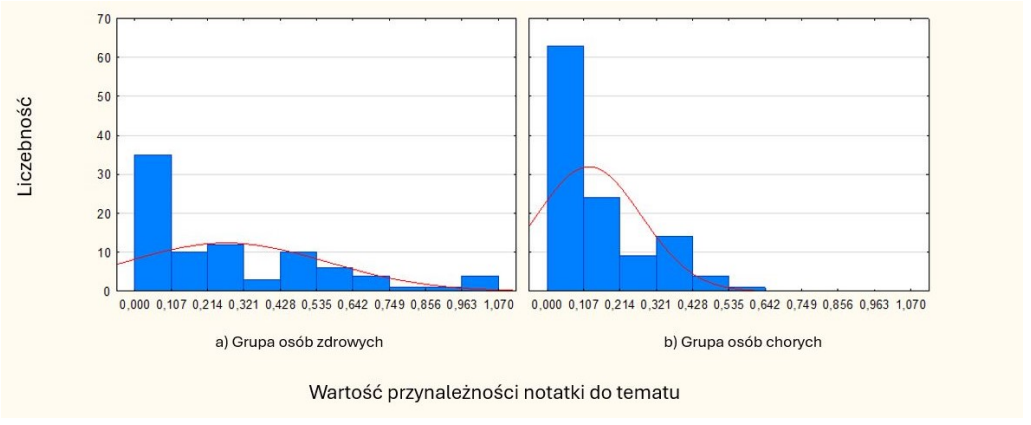
Rysunek 4.11: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Emocje w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

W grupie osób chorych występują zdecydowanie wyższe wartości przynależności notatek do tematu samooceny w kontekście negatywnym ($M = 0{,}34$; $Me = 0{,}27$) w porównaniu do grupy osób zdrowych ($M = 0{,}12$; $Me = 0{,}0$). Histogram reprezentujący wyniki dla osób zdrowych ma charakter skrajnie asymetryczny (ponad 55 osób osiągnęła wynik przynależności równy 0), podczas gdy rozkład grupy osób chorych jest relatywnie szeroki i spłaszczony (rysunek 4.12). Analiza testu U Manna-Whitneya wykazała istotne statystycznie różnice między porównywanymi grupami ($U = 2906{,}5$; $Zskoryg. = 5{,}22$; $p < 0{,}001$).



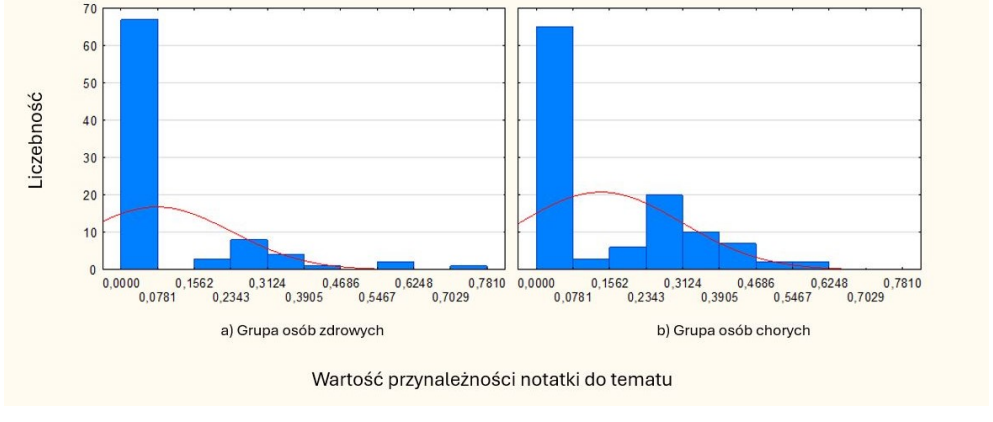
Rysunek 4.12: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Samoocena w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

Osoby zdrowe cechują się istotnie wyższymi wartościami przynależności ich notatek do obszaru samooceny w kontekście pozytywnym ($M = 0{,}27$; $Me = 0{,}20$) niż osoby chore ($M = 0{,}12$; $Me = 0{,}0$). W grupie osób chorych ponad połowa badanych uzyskała wartości równie 0,00 ($Me = 0{,}0$), co potwierdza, że wysoki poziom negatywnej samooceny współwystępuje u nich z niemal całkowitym brakiem pozytywnej samooceny (rysunek 4.13). Analiza testu U Manna-Whitneya wykazała istotne statystycznie różnice między porównywanymi grupami dla tego obszaru trudności ($U = 3682{,}0$; $Zskoryg. = -3{,}27$; $p = 0{,}001$).



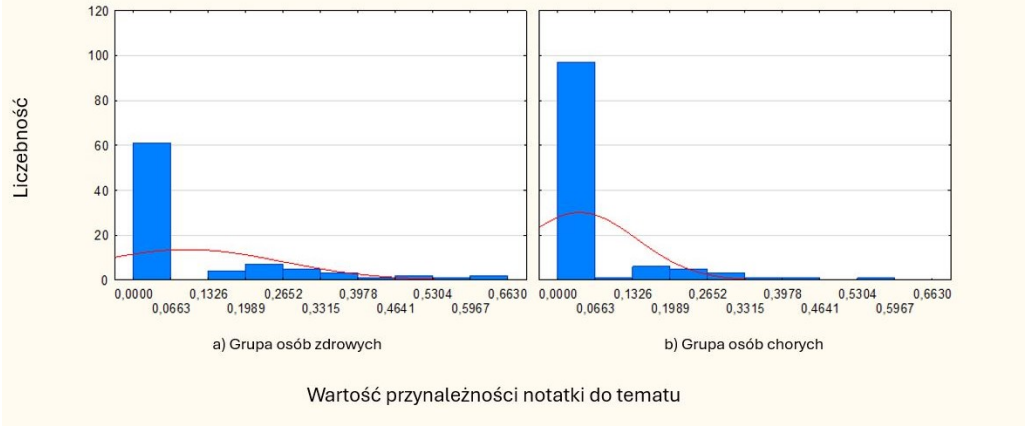
Rysunek 4.13: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Samoocena w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

Analiza testu U Manna-Whitneya dla zmiennej reprezentującej przynależności notatek do tematu funkcjonowania ciała w kontekście negatywnym wykazała istotną przewagę osób chorych ($U = 3911{,}00$; $Zskoryg. = 2{,}99$; $p = 0{,}003$). Mimo że w obu grupach mediany wyniosły 0,00, to wyższa średnia arytmetyczna u osób chorych ($M = 0{,}14$) niż u zdrowych ($M = 0{,}07$) wskazuje na częstsze pojawianie się, w grupie osób zmagających się z anoreksją, krytycznych uwag dotyczących fizjologicznego działania organizmu. Histogram osób chorych ujawnia wyraźne przesunięcie i „rozlanie" rozkładu w stronę wyższych klas wartości, podczas gdy w grupie osób zdrowych niemal cały zbiór danych (blisko 70 obserwacji) koncentruje się w przedziale skrajnie niskim (rysunek 4.14).



Rysunek 4.14: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Funkcjonowanie ciała w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

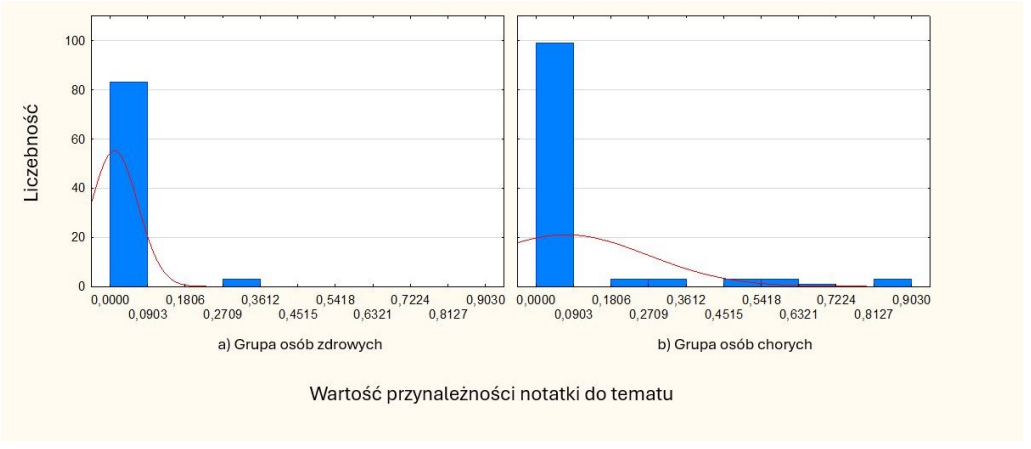
Dla obszaru funkcjonowania ciała w kontekście pozytywnym większą wartość średniej zaobserwowano w grupie osób zdrowych ($M = 0{,}1$) niż chorych ($M = 0{,}04$). Analiza histogramów (rysunek 4.15) ujawnia wyraźną koncentrację wyników w obrębie wartości bliskich zeru w grupie osób chorych - dotyczy to blisko 100 ze 115 badanych. Taki kształt rozkładu świadczy o głębokim deficycie w zakresie dostrzegania i doceniania pozytywnych aspektów funkcjonowania własnego ciała. Analiza testu U Manna-Whitneya nie wykazała istotnych statystycznie różnic między porównywanymi grupami dla tego obszaru trudności ($U = 4188{,}0$; $Zskoryg. = -2{,}59$; $p = 0{,}010$).



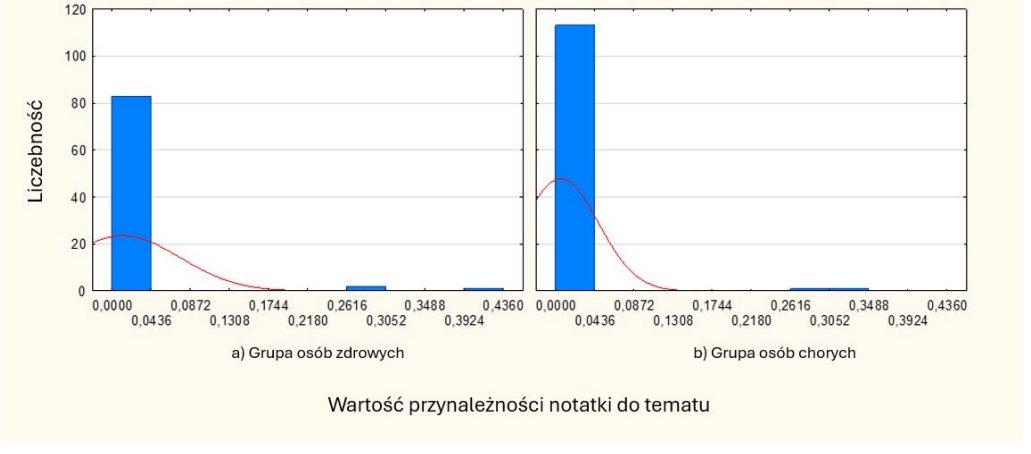
Rysunek 4.15: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Funkcjonowanie ciała w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

Analiza graficzna obszaru autoagresji (rysunek 4.16) wskazuje, że zarówno u osób zdrowych, jak i chorych dominują wyniki zerowe. Niemniej jednak w grupie osób chorych zaobserwowano kilkanaście wyników dodatnich, w tym wartości skrajne dochodzące do 0,9. Dla obu grup wartość mediany wyniosła $Me = 0{,}00$, a wartości średnich wynosiły odpowiednio $M = 0{,}01$ dla osób zdrowych i $M = 0{,}07$ dla osób chorych. Przeprowadzony test U Manna-Whitneya wykazał brak istotnych statystycznie różnic ($U = 4422{,}5$; $Zskoryg. = 2{,}52$; $p = 0{,}012$).

Zmienna reprezentująca ból nie wykazała istotnych statystycznie różnic pomiędzy grupami ($U = 4858{,}50$; $Zskoryg. = -0{,}78$; $p = 0{,}435$). Obie grupy prezentują niemal identyczny, skrajnie asymetryczny profil rozkładu (rysunek 4.17). Zdecydowana większość uczestników (zarówno zdrowych, jak i chorych) skupia się wokół wartości zerowej, co potwierdzają mediany wynoszące 0,00 oraz bardzo niskie średnie ($M = 0{,}01$). Przeżywanie i raportowanie tematyki bólu nie stanowi w tym badaniu cechy różnicującej grupy.



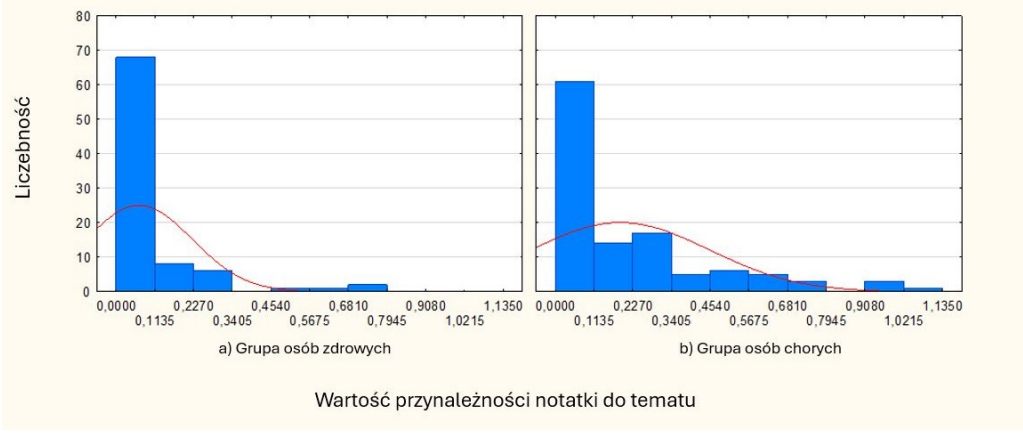
Rysunek 4.16: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Autoagresja" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.



Rysunek 4.17: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Ból" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

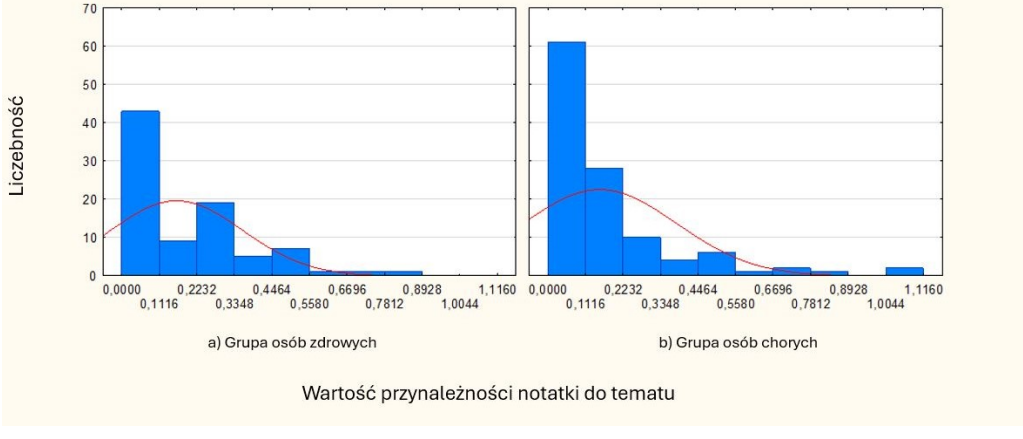
Dla zmiennej reprezentującej temat akceptacji otoczenia w kontekście negatywnym, która związana jest z poczuciem odrzucenia lub braku zrozumienia ze strony środowiska społecznego, wykazano bardzo silną i wysoce istotną różnicę pomiędzy grupą osób chorych jak i zdrowych ($U = 3449{,}50$; $Zskoryg. = 4{,}19$; $p < 0{,}001$). Osoby zmagające się z anoreksją wykazywały wyższe poczucie braku akceptacji ze strony otoczenia. Świadczy o tym mediana dla tej grupy, która jest równa $Me = 0{,}08$, a średnia wynosi $M = 0{,}19$, w porównaniu do grupy osób zdrowych, gdzie $Me = 0{,}00$ i $M = 0{,}07$. Kształty histogramów (rysunek 4.18) wyraźnie separują obie grupy: o ile u osób zdrowych wykres gwałtownie opada zaraz po pierwszym, zerowym słupku, o tyle u osób

chorych tworzy się rozległy, wieloelementowy rozkład, reprezentujący powszechne poczucie wyobcowania osób zmagających się z anoreksją.



Rysunek 4.18: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Akceptacja otoczenia w kontekście negatywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

Dla obszaru trudności reprezentującego pozytywną akceptację otoczenia, test U Manna-Whitneya nie wykazał istotności statystycznej ($U = 4641{,}50$; $Zskoryg. = -0{,}80$; $p = 0{,}425$). Zarówno osoby zdrowe ($M = 0{,}16$; $Me = 0{,}07$), jak i chore ($M = 0{,}15$; $Me = 0{,}00$) charakteryzują się relatywnie zbliżonym poziomem deklarowanej pozytywnej akceptacji z strony środowiska.



Rysunek 4.19: Rozkład częstości występowania wartości przynależności poszczególnych notatek do tematu „Akceptacja otoczenia w kontekście pozytywnym" z podziałem na grupę chorych na anoreksję ($n = 115$) oraz grupę osób zdrowych ($n = 86$). Linie ciągłe reprezentują dopasowanie teoretycznego rozkładu normalnego dla każdej z podgrup.

Podsumowując należy stwierdzić, że:

- Chorzy mają istotnie wyższe wyniki w obszarze negatywnego obrazu ciała, wyższe negatywne emocje oraz wykazują istotnie wyższą negatywną samoocenę.
- Osoby cierpiące na anoreksję istotnie częściej zgłaszają negatywne uwagi dotyczące funkcjonowania własnego ciała oraz silniej odczuwają brak akceptacji ze strony otoczenia.
- Osoby z grupy zdrowych mają istotnie lepszy, pozytywny obraz ciała, istotnie wyższą pozytywną samoocenę.
- Analiza statystyczna ujawniła również punkty wspólne dla obu grup. Po uwzględnieniu poprawki Bonferroniego nie wykazano istotnych statystycznie różnic w obszarach: emocji w kontekście pozytywnym, funkcjonowania ciała w kontekście pozytywnym, autoagresji, bólu oraz akceptacji otoczenia w kontekście pozytywnym.

Tabela 4.2: Statystyki opisowe i wyniki testu U Manna-Whitneya dla stopnia przynależności notatek do obszarów trudności

Zmienna	**Osoby zdrowe (N = 86)**		**Osoby chore (N = 115)**		**Wyniki testu U Manna-Whitneya**		
	M	**Me**	**M**	**Me**	**U**	**Z skoryg.**	**p-value**
Obraz ciała w kontekście negatywnym	0,20	0,00	0,44	0,31	3289,0	4,17	**< 0,001**
Obraz ciała w kontekście pozytywnym	0,36	0,26	0,18	0,11	3361,5	-3,99	**< 0,001**
Emocje w kontekście negatywnym	0,10	0,00	0,31	0,21	3135,0	4,86	**< 0,001**
Emocje w kontekście pozytywnym	0,21	0,17	0,18	0,14	4712,0	-0,60	0,550
Samoocena w kontekście negatywnym	0,12	0,00	0,34	0,27	2906,5	5,22	**< 0,001**
Samoocena w kontekście pozytywnym	0,27	0,20	0,12	0,00	3682,0	-3,27	**0,001**
Funk. ciała w kontekście negatywnym	0,07	0,00	0,14	0,00	3911,0	2,99	**0,003**
Funk. ciała w kontekście pozytywnym	0,10	0,00	0,04	0,00	4188,0	-2,59	0,010
Autoagresja	0,01	0,00	0,07	0,00	4422,5	2,52	0,012
Ból	0,01	0,00	0,01	0,00	4858,5	-0,78	0,435
Akcept. otoczenia w kontekście negatywnym	0,07	0,00	0,19	0,08	3449,5	4,19	**< 0,001**
Akcept. otoczenia w kontekście pozytywnym	0,16	0,07	0,15	0,00	4641,5	-0,80	0,425

Objaśnienia: U - statystyka testu U Manna-Whitneya; $Z_{skoryg.}$ - skorygowana wartość statystyki standaryzowanej Z; p - poziom istotności statystycznej (pogrubiono różnice istotne przy $\alpha_{\text{Bonf}} = \frac{0,05}{12} \approx 0,0042$); M - średnia; Me - mediana.

4.3 Przegląd rezultatów użytych metod uczenia maszynowego

Rozdział zawiera prezentację, analizę oraz interpretację wyników uzyskanych za pomocą wybranych algorytmów uczenia maszynowego. Modele predykcyjne zostały zbudowane w oparciu o wcześniej opracowane obszary trudności, a ich głównym zadaniem była klasyfikacja oraz analiza eksploracyjna. Jako zmienną celu we wszystkich analizach przyjęto zmienną binarną (wystąpienie anoreksji lub jej brak). Wyniki przedstawiono w podrozdziałach odpowiadających kolejnym etapom przyjętej strategii analitycznej.

4.3.1 Modelowanie szans wystąpienia anoreksji

Pierwszy etap analizy objął modelowanie szans wystąpienia anoreksji z wykorzystaniem regresji logistycznej w celu wyłonienia zmiennych istotnych statystycznie. W ramach tej części badań dokonano analizy korelacji, wstępnej selekcji predyktorów, przeprowadzając analizę pojedynczego wpływu, wyznaczono wartość wskaźnika EPV, wygenerowano model regresji logistycznej oraz oszacowano wskaźniki współliniowości.

4.3.1.1 Analiza korelacji predyktorów

Dokonano analizy macierzy korelacji (mapa cieplna), która pozwoliła na określenie siły i kierunku powiązań pomiędzy wszystkimi analizowanymi zmiennymi. Wartości współczynnika korelacji Spearmana (r) zaprezentowano w postaci mapy cieplnej, gdzie:

- silną korelację dodatnią, czyli wzrost jednej zmiennej powoduje wzrost drugiej obrazuje intensywny niebieski kolor,
- brak powiązania został zaprezentowany w odcieniach szarości,
- silną korelację ujemną, czyli wzrost jednej zmiennej powoduje spadek drugiej reprezentuje czerwony kolor.

Analizując wyniki zamieszczone w Tab 4.3 można zauważyć, że pomiędzy kontekstem negatywnym (N) a pozytywnym (P) dla tego samego obszaru trudności korelacja nie występuje lub jest bardzo słaba (bliska zeru):

- Dla obszaru obrazu ciała współczynnik korelacji wynosi $r = -0{,}109$, co oznacza bardzo słabą korelację.
- Dla obszaru emocji współczynnik korelacji wynosi $r = 0{,}000$, co oznacza brak korelacji.
- Dla obszaru samooceny współczynnik korelacji wynosi $r = -0{,}133$, co oznacza bardzo słabą korelację.
- Dla obszaru funkcjonowanie ciała współczynnik korelacji wynosi $r = 0{,}069$, co oznacza bardzo słabą korelację.

- Dla obszaru akceptacja otoczenia współczynnik korelacji wynosi $r = 0{,}090$, co oznacza bardzo słabą korelację.

Tabela 4.3: Macierz korelacji Spearmana dla badanych zmiennych ($N = 201$).

Zmienna	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)
(1) Obraz ciała (N)	1,0000	-0,1088	0,5122	-0,0916	0,8364	-0,1192	0,3545	-0,0614	0,2129	-0,0316	0,4822	-0,0105
(2) Obraz ciała (P)	-0,1088	1,0000	-0,1738	0,5134	-0,1962	0,7747	-0,0908	0,3387	-0,1674	0,1070	-0,1311	0,3490
(3) Emocje (N)	0,5122	-0,1738	1,0000	0,0000	0,5977	-0,1231	0,2507	-0,0972	0,5154	-0,1093	0,4039	-0,0170
(4) Emocje (P)	-0,0916	0,5134	0,0000	1,0000	-0,1307	0,6064	0,0503	0,0677	-0,1440	-0,0016	-0,1156	0,4576
(5) Samoocena (N)	0,8364	-0,1962	0,5977	-0,1307	1,0000	-0,1328	0,3697	-0,1033	0,2265	0,0039	0,4129	-0,1098
(6) Samoocena (P)	-0,1192	0,7747	-0,1231	0,6064	-0,1328	1,0000	-0,0125	0,1515	-0,1793	0,1095	-0,2178	0,3249
(7) Funkcjonowanie ciała (N)	0,3545	-0,0908	0,2507	0,0503	0,3697	-0,0125	1,0000	0,0689	-0,0308	0,0316	0,1753	0,0134
(8) Funkcjonowanie ciała (P)	-0,0614	0,3387	-0,0972	0,0677	-0,1033	0,1515	0,0689	1,0000	-0,0372	0,0265	-0,0797	0,0527
(9) Autoagresja	0,2129	-0,1674	0,5154	-0,1440	0,2265	-0,1793	-0,0308	-0,0372	1,0000	0,0072	0,4230	-0,0491
(10) Ból	-0,0316	0,1070	-0,1093	-0,0016	0,0039	0,1095	0,0316	0,0265	0,0072	1,0000	-0,0947	-0,0641
(11) Akceptacja otoczenia (N)	0,4822	-0,1311	0,4039	-0,1156	0,4129	-0,2178	0,1753	-0,0797	0,4230	-0,0947	1,0000	0,0897
(12) Akceptacja otoczenia (P)	-0,0105	0,3490	-0,0170	0,4576	-0,1098	0,3249	0,0134	0,0527	-0,0491	-0,0641	0,0897	1,0000

Objaśnienia: (N) - kontekst negatywny, (P) - kontekst pozytywny.

Z analizy wynika, że najsilniejsze korelacje dodatnie występują pomiędzy obszarem trudności obraz ciała i samooceną. Obraz ciała w kontekście negatywnym jest wysoce skorelowany z samooceną w kontekście negatywnym ($r = 0{,}836$). Osiągnięta wartość r jest najwyższą wartością wśród wszystkich analizowanych wyników, zatem można powiedzieć, że jest to najsilniejszy związek spośród analizowanych zmiennych. Należy to interpretować tak, że negatywny obraz własnego ciała jest niemal nierozerwalnie związany z ogólnym brakiem poczucia własnej wartości i samooceny. Analogicznie, bardzo wysoka zależność występuje pomiędzy obrazem ciała w kontekście pozytywnym i samooceną w kontekście pozytywnym ($r = 0{,}775$). Nieco niższy wynik uzyskano pomiędzy emocjami w kontekście pozytywnym i samooceną w kontekście pozytywnym ($r = 0{,}606$), emocjami w kontekście negatywnym i samooceną w kontekście negatywnym ($r = 0{,}598$) oraz pomiędzy emocjami w kontekście negatywnym i autoagresją ($r = 0{,}515$). Wśród najsilniejszych korelacji negatywnych brak jest takich, które osiągałyby wysokie wartości. Najwyższa z nich jest równa $r = -0{,}218$ i występuje pomiędzy akceptacją otoczenia w kontekście negatywnym i samooceną w kontekście pozytywnym.

Dokonano również wstępnej selekcji, która polegała na odrzuceniu 3 zmiennych na podstawie analizy pojedynczego wpływu. Zatem do dalszego etapu modelowania przeszło 9 zmiennych. W następnym kroku wyznaczono wartość EPV (równanie 4.1).

$$EPV = \frac{86}{9} \approx 9,56 \tag{4.1}$$

Biorąc pod uwagę obecność kilku wysokich wartości korelacji, relatywnie niskiej wartości wskaźnika EPV, zdecydowano o rezygnacji z tradycyjnego podejścia na rzecz regresji logistycznej z regularyzacją Elastic Net. Występowanie wyraźnych współzależności sprawia, że tradycyjne procedury krokowe mogłyby skutkować nadmiernym dopasowaniem oraz niestabilnością szacowanych parametrów. Problem ten rozwiązano poprzez użycie regresji Elastic Net, która stabilizuje model w warunkach silnych korelacji i zapobiega utracie istotnych informacji. Regresja logistyczna z karą Elastic Net nie opiera się na klasycznych testach istotności dla pojedynczych współczynników. W modelach tego typu nie oblicza się zestawu niezależnych p-values, które wymagałyby korekty na wielokrotne testowanie. Zamiast tego cały proces selekcji zmiennych i ograniczania ryzyka fałszywych odkryć odbywa się poprzez regularyzację, czyli dodanie do funkcji celu kar L1 i L2. Kara L1 (część „Lasso") wymusza zerowanie współczynników, co działa jak automatyczna selekcja zmiennych. Kara L2 (część „Ridge") stabilizuje oszacowania i zmniejsza wariancję. Razem tworzą mechanizm, który zastępuje klasyczne podejście oparte na wielu testach statystycznych. Zatem w dalszej interpretacji badań nie stosowano poprawki na wielokrotność porównań.

4.3.1.2 Wyniki analizy regresji logistycznej

W celu zweryfikowania, które predyktory współwystępują z anoreksją, przeprowadzono analizę regresji logistycznej. Nie określano czynników ryzyka oraz ochrony ze względu na charakter przekrojowy zebranych danych. Ze względu na charakter algorytmu Elastic Net, którego mechanizmy wewnętrzne wyboru zmiennych mogą zakłócić rozkłady statystyczne, dla oceny istotności wybranych przez model Elastic Net predyk-

torów zastosowano metodę podziału próby: zbiór uczący/zbiór testowy w proporcjach 2/3 do 1/3 . Model Elastic Net został wytrenowany na zbiorze uczącym. Następnie do oceny predyktorów został wytrenowany model klasyczny regresji na zbiorze testowym tylko z udziałem predyktorów wybranych przez model Elastic Net.

Uzyskane wyniki zamieszczono w tabeli 4.4. Do ostatecznego modelu trafiły dwa predyktory (zmienne): samoocena w kontekście negatywnym oraz obraz ciała w kontekście pozytywnym. Obie te zmienne w sposób wysoce istotny statystycznie ($p < 0{,}05$) różnicują szanse na współwystępowanie anoreksji.

Tabela 4.4: Ocena parametrów modelu regresji logistycznej dla zmiennej zależnej: czy osoba jest chora na anoreksję

Zmienna	*B*	*SE*	**Wald**	*p*	*OR*	**95% CI dla** *OR*
Wyraz wolny (Intercept)	0,152	0,255	0,354	0,552	1,164	[0,706; 1,918]
Samoocena kontekst negatywny	3,384	0,788	18,419	<0,001	29,485	[6,287; 138,279]
Obraz ciała kontekst pozytywny	-2,130	0,616	11,969	0,001	0,119	[0,036; 0,397]

Objaśnienia: B - oszacowanie parametru, SE - błąd standardowy, Wald - statystyka Walda, p - istotność, OR - iloraz szans, CI - przedział ufności.

Samoocena w kontekście negatywnym wiąże się z wysokim współwystępowaniem anoreksji, natomiast obraz ciała w kontekście pozytywnym wiąże się z niskim współwystępowaniem anoreksji.

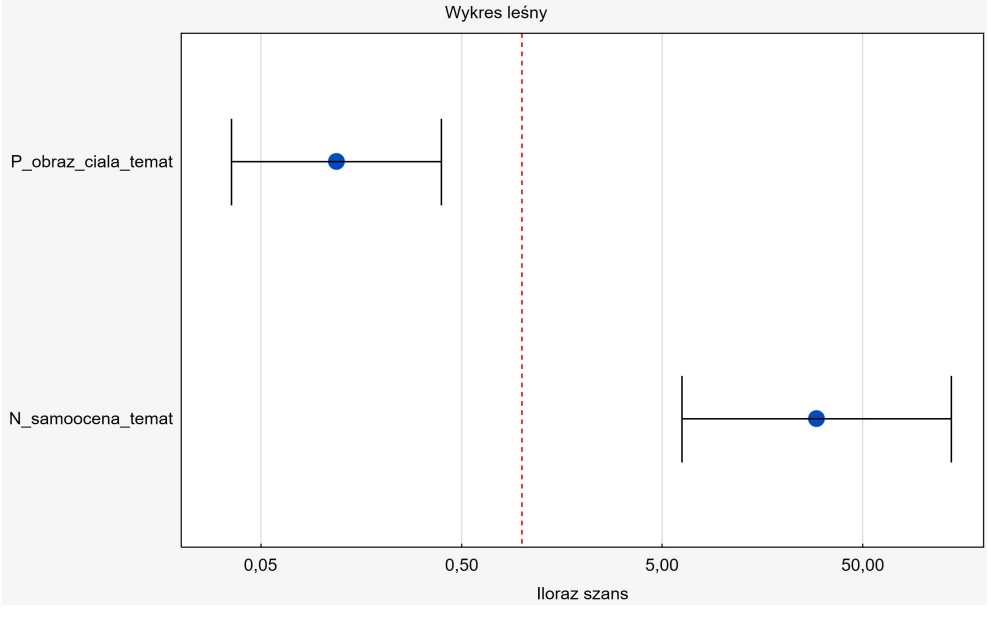
W celu weryfikacji, czy wygenerowany model regresji logistycznej nie jest obciążony błędem multikolinearności, oszacowano wskaźniki współliniowości dla uwzględnionych analizowanych zmiennych. W przypadku zmiennych reprezentujących samoocenę w kontekście negatywnym oraz obrazu ciała w kontekście pozytywnym wyznaczona wartość tolerancji osiąga wartość równą 0,939. Współczynnik inflacji wariancji (VIF) uzyskał wartość równą 1,064. Obie wartości VIF są znacznie niższe od powszechnie stosowanych progów krytycznych (wynoszących odpowiednio 4 lub 10). Wyznaczone poziomy tolerancji są bliskie wartości 1. Uzyskane wyniki świadczą, że między predyktorami nie występują silne powiązania. To gwarantuje poprawność i stabilność wyznaczonych współczynników regresji.

4.3.1.3 Graficzna wizualizacja Ilorazu Szans - analiza wykresu leśnego

Wyznaczone predyktory z modelu regresji logistycznej (tabela 4.4) omawianej w poprzednim podrozdziale przedstawiono za pomocą wykresu leśnego (rysunek 4.20).

Wykres zawiera tylko te zmienne, które zostały włączone do ostatecznego modelu regresji logistycznej jako predyktory. Przerywana czerwona linia reprezentuje wartość

neutralną ($OR = 1$). Przedziały ufności, przedstawione w postaci poziomych odcinków dla zmiennej samooceny w kontekście negatywnym oraz obrazu ciała w kontekście pozytywnym nie przecinają czerwonej linii. Oznacza to, że wpływ obu tych predyktorów na szanse współwystępowania anoreksji jest wysoce istotny statystycznie. Należy zaznaczyć, że pozostałe zmienne analizowane w badaniu nie zostały uwzględnione na wykresie leśnym, ponieważ w procesie estymacji modelu nie wykazały statystycznie istotnego powiązania z obecnością anoreksji i nie weszły do ostatecznego równania regresji. Dla negatywnej samooceny punkt zlokalizowany jest daleko po prawej stronie od czerwonej linii (w okolicach wartości 30,0). Potwierdza to, że jest to silny czynnik sprzyjający wystąpieniu anoreksji. Dla pozytywnego obrazu ciała punkt znajduje się po lewej stronie od linii neutralnej (w okolicach wartości 0,1), co świadczy o odwrotnej zależności i wiąże się ze znacznie niższymi szansami na występowanie zaburzenia. Wykres leśny stanowi graficzne uzupełnienie i potwierdzenie wyników z poprzedniej części analizy.



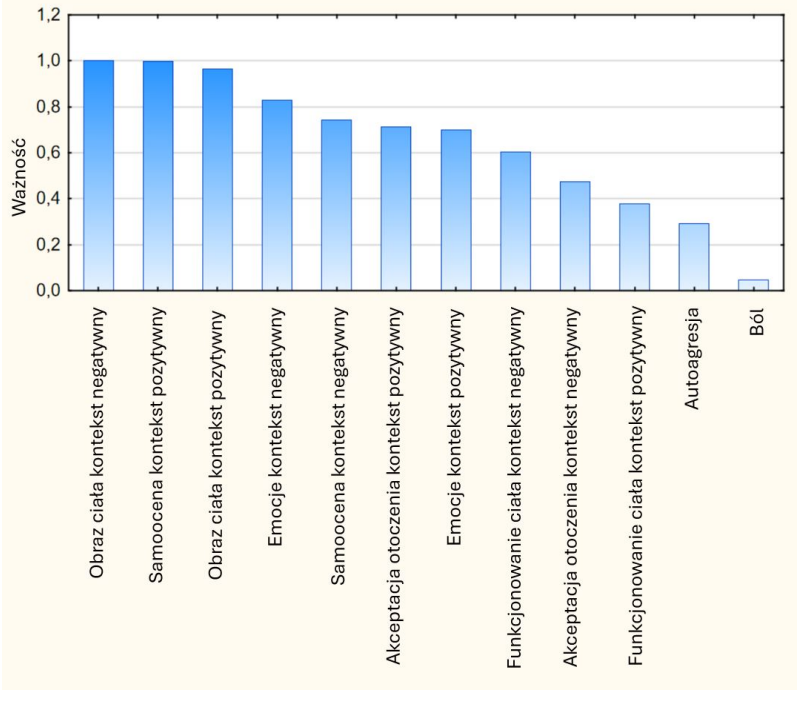
Rysunek 4.20: Wykres leśny uzyskany dla regresji logistycznej przedstawiający iloraz szans dla wybranych predyktorów

4.3.2 Analiza struktury danych za pomocą drzew klasyfikacyjnych

Rozdział prezentuje wyniki działania algorytmu drzew klasyfikacyjnych CRT. Etap ten pełni przede wszystkim funkcję eksploracyjną. W pierwszym kroku zbadano globalny potencjał prognostyczny wszystkich wprowadzonych predyktorów. W drugim etapie, wykorzystując Kryterium Informacyjnym Akaikego (AIC), wyłoniono pojedyncze, optymalne drzewo klasyfikacyjne, które poddano dalszej analizie.

4.3.2.1 Wykres ważności zmiennych

W celu identyfikacji zmiennych (tematów poruszonych w analizowanych notatkach), które najsilniej różnicują wypowiedzi osób chorych i zdrowych, a tym samym wnoszą największy wkład w poprawną klasyfikację, sporządzono wykres ważności cech w oparciu o model lasu losowego. Zastosowanie tego algorytmu pozwoliło na uzyskanie stabilnej i wiarygodnej oceny wkładu predykatorów, które w modelu reprezentowały stopień przynależności danej notatki do danego obszaru trudności w danym kontekście. Zasada działania lasów losowych opiera się na generowaniu wielu drzew w procesie treningu, co wpływa na zapewnienie wysokiej stabilności wyników oraz zminimalizowanie ryzyka przeuczenia modelu, co bywa głównym ograniczeniem w przypadku pojedynczych drzew decyzyjnych. Zasada generowania wykresu ważności predyktorów opiera się na podstawie obliczenia wkładu zmiennych w poprawę czystości podziałów w węzłach drzew. Wykres ten tworzy się poprzez zsumowanie spadków nieczystości węzłów we wszystkich wygenerowanych drzewach w ramach lasu losowego. Uzyskane wyniki są następnie standaryzowane względem najważniejszej zmiennej, która otrzymuje wartość 1,0. Wykres ważności zmiennych został przedstawiony na rysunku 4.21.



Rysunek 4.21: Wykres ważności zmiennych

Analiza wyników pokazuje, że kluczowe znaczenie mają zmienne związane z tym, jak osoba postrzega samą siebie oraz własne ciało. Najważniejszymi predyktorami są: obraz ciała w kontekście negatywnym oraz samoocena w kontekście pozytywnym, które osiągnęły maksymalną wartość wskaźnika ważności zmiennych. Trzecią zmienną, która

uzyskała wartość bliską maksymalnej jest predyktor dotyczący obrazu ciała w kontekście pozytywnym. Uzyskane wyniki potwierdzają, że subiektywny wizerunek fizyczny, niezależnie od tego czy występują emocje i w jakim kontekście, okazuje się głównym czynnikiem objaśniającym występowanie anoreksji. Zatem z tego wynika, że rola obrazu ciała i samooceny ma znacznie większe znaczenie niż obszary dotyczące codziennego funkcjonowania ciała czy też akceptacji otoczenia. Analizując kolejne zmienne warto zwrócić uwagę, że choć dla samooceny kontekst pozytywny ma większe znaczenie niż negatywny, to w przypadku obszaru jakim są emocje zauważalna jest odwrotna zależność. Znacznie wyższą ważność uzyskują emocje w kontekście negatywnym (wartość $> 0{,}8$) niż pozytywnym (wartość równa około 0,7). Może to sugerować, że w kontekście zaburzeń odżywiania, a konkretnie w anoreksji, kluczową rolę ochronną odgrywa stabilne poczucie własnej wartości, przy jednoczesnej dużej wrażliwości na przeżywanie trudnych emocji. Warto również zwrócić uwagę na wysoką wartość akceptacji otoczenia w kontekście pozytywnym (wartość równa około 0,72). Sugeruje to, że równie ważne jest poczucie akceptacji i wsparcia w relacjach z innymi ludźmi, bliskimi i otoczeniem. Najmniejszą wartość ważności predyktorów osiągnęły zmienne reprezentujące autoagresję (wartość równa około 0,30) oraz występowanie bólu (wartość równa około 0,05).

4.3.2.2 Wybrany optymalny model drzewa decyzyjnego

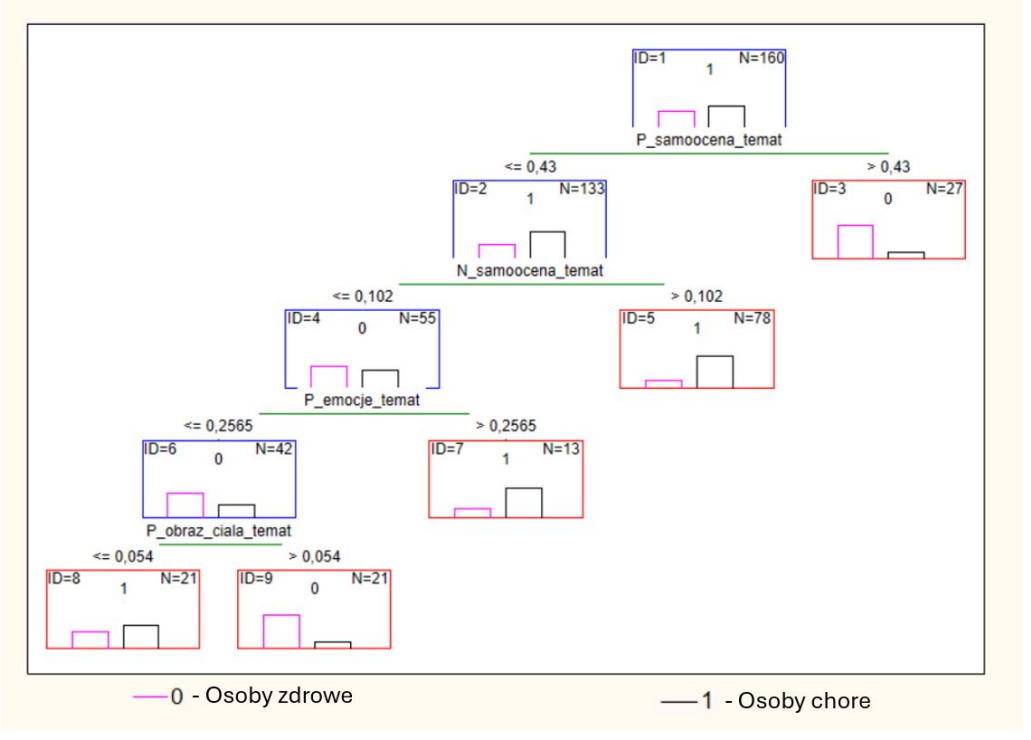
Przyjmując parametry opisane w rozdziale *Materiał badawczy i metodyka badań* w części poświęconej drzewom klasyfikacyjnym (podrozdział 3.2.3.2) wygenerowano ostatecznie 16 modeli drzew. Kombinacje wszystkich parametrów dla każdego z modeli został zamieszczone w tabeli 4.5.

Tabela 4.5: Kombinacje parametrów dla wszystkich wygenerowanych modeli drzew

Numer modelu	**Maksymalna głębokość**	**Minimalny rozmiar liścia**
1	3	1
2	3	3
3	3	5
4	3	8
5	6	1
6	6	3
7	6	5
8	6	8
9	10	1
10	10	3
11	10	5
12	10	8
13	20	1
14	20	3
15	20	5
16	20	8

Na podstawie Kryterium Informacyjnego Akaikego (AIC) wybrano optymalny ze-

staw parametrów. Następnie dla najlepszych ustawień wykonano 4-krotną walidację krzyżową dla zbioru ucząco-walidacyjnego. Proces uczenia i walidacji dokonano na próbie, która była równa 80% całego zbioru danych (co stanowi 160 obserwacji). Następnie na podstawie czterokrotnej walidacji, również na podstawie Kryterium Informacyjnego Akaikego wybrano optymalny model, który został przedstawiony na rysunku 4.22.



Rysunek 4.22: Wygenerowany optymalny model drzewa decyzyjnego

Wybrany model składa się z 5 węzłów końcowych - liści. Na podstawie wykresu ważności zmiennych oraz struktury uzyskanego modelu można zauważyć wysoką spójność. Zmienne, które pojawiły się w wygenerowanym i wybranym modelu, zajmują kluczowe pozycje na wykresie ważności zmiennych. Najważniejszą zmienną w modelu, która stanowi korzeń drzewa (węzeł o ID=1) jest zmienna dotycząca samooceny w kontekście pozytywnym (P_samoocena_temat). To ona dokonuje pierwszego, najsilniejszego podziału całej badanej próby. Ten predyktor osiągnął najwyższą wartość na wykresie ważności zmiennych. Kolejną zmienną jest samoocena w kontekście negatywnym (N_samoocena_temat). Predyktor ten zajął 4 miejsce na wykresie ważności, a w strukturze drzewa odpowiada za kluczowy podział na drugim poziomie (węzeł ID=2). W strukturze wygenerowanego modelu znalazły się również takie zmienne jak: emocje w kontekście pozytywnym (P_emocje_temat) oraz obraz ciała w kontekście pozytywnym (P_obraz_ciala_temat), które znalazły się odpowiednio na szóstym i drugim miejscu na wykresie ważności.

Warto podkreślić fakt, że optymalne drzewo przy pomocy kryterium AIC wykorzystuje predyktory o udowodnionej, wysokiej pozycji na wykresie ważności zmiennych, świadczy to o stabilności wybranego modelu decyzyjnego. Stanowi to podstawę do dalszej analizy jego klastrów (liści).

4.3.2.3 Analiza reguł decyzyjnych, wyodrębnienie profili tekstowych notatek osób chorych oraz analiza uzyskanych klastrów

Przekształcenie wygenerowanego modelu drzewa decyzyjnego z zestaw jawnych reguł klasyfikacyjnych (tabela 4.6) umożliwia pogłębioną analizę leksykalno-tematyczną materiału tekstowego. Uzyskane wyniki wskazują, że notatki sporządzone przez osoby z diagnozą anoreksji nie tworzą jednego, jednorodnego korpusu notatek. Wygenerowane reguły pozwoliły na wyodrębnienie trzech specyficznych profili notatek, z których każdy charakteryzuje się innym stopniem nasilenia oraz odmienną konfiguracją poruszanych tematów.

Wspólnym elementem dla wszystkich profili notatek jest obniżona wartość samooceny w kontekście pozytywnym (P_samoocena_temat $\leq$ 0,43). Jest to kluczowy warunek wstępny, ponieważ dopóki ta zmienna nie osiągnie wartości z wskazanego progu, model automatycznie wyklucza możliwość zakwalifikowania danej notatki jako pochodzącej od osoby chorej. Następnie w połączeniu z wartościami kolejnych cech tworzą się trzy osobne profile notatek:

- Profil 1 (Liść 5) - W tych notatkach niska samoocena w kontekście pozytywnym opisana powyżej łączy się bezpośrednio z wysoką wartością samooceny w kontekście negatywnym (N_samoocena_temat $>$ 0.102). Zatem ta reguła pozwoliła na wyizolowanie podgrupy notatek chorych, u których występowanie choroby (anoreksji) jest najsilniej powiązane z negatywnym postrzeganiem własnej osoby, podczas gdy inne zmienne (emocje czy obraz ciała) nie mają decydującego wpływu.

- Profil 2 (Liść 7) - Ten profil obejmuje notatki, w których paradoksalnie pomimo niskiej samooceny w kontekście pozytywnym (P_samoocena_temat $\leq$ 0,43), nie wykazano silnej samooceny negatywnej (N_samoocena_temat $\leq$ 0,102), a decydująca okazał się wysoki udział słownictwa związanego z emocjami pozytywnymi (P_emocje_temat$>$0,2565) w tekście. Wysoka wartość pozytywnych emocji nie świadczy o ogólnym dobrostanie psychicznym pacjentów, lecz może stanowić językowy przejaw specyficznej satysfakcji z osiąganych celów związanych z redukcją wagi, która współwystępuje z obniżoną samooceną.

- Profil 3 (Liść 8) - Ten profil obejmuje notatki, w których niska samoocena łączy się z ograniczoną ekspresją emocji pozytywnych oraz ze skrajnie niską obecnością wzmianek o pozytywnym obrazie własnego ciała (P_obraz_ciala_temat $\leq$ 0,054).

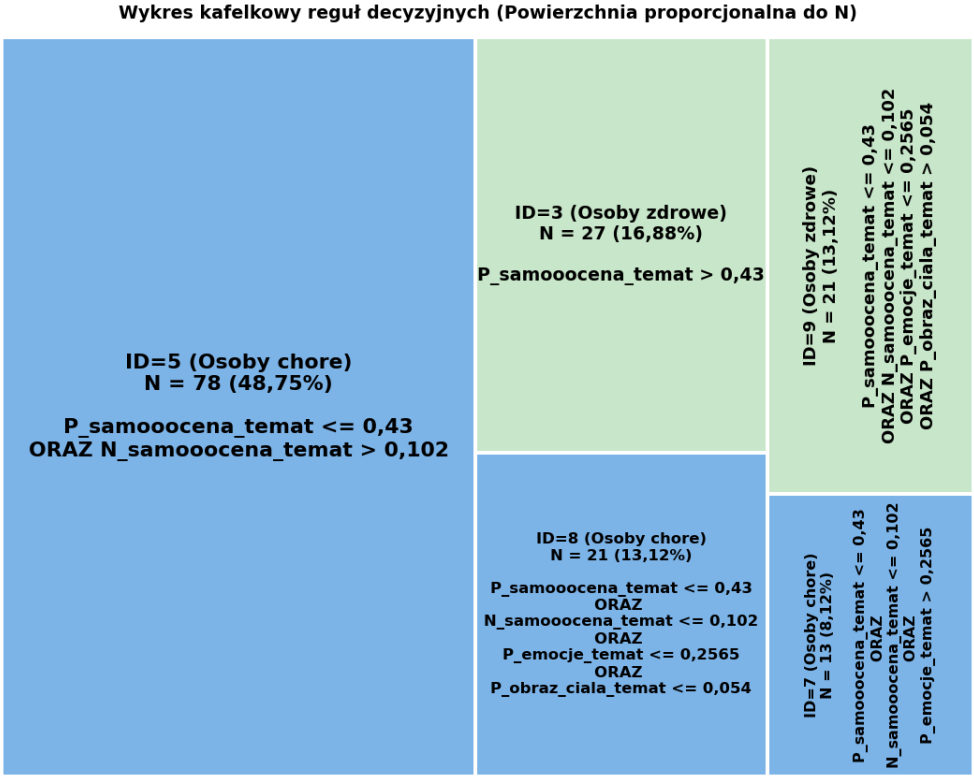
Wyodrębnione reguły decyzyjne posiadają potencjał aplikacyjny w obszarze zautomatyzowanej analizy tekstu jako uzupełniający komponent algorytmów wstępnej sekcji materiałów pisanych. Ponadto wyodrębnienie tych profili z wygenerowanego modelu drzewa decyzyjnego pozwala na lepsze zrozumienie zróżnicowania językowego wypowiedzi osób cierpiących na anoreksję, wskazując na wieloaspektowość wzorców narra-

cyjnych towarzyszących temu zaburzeniu.

Tabela 4.6: Reguły Decyzyjne - Profil notatki osoby chorej (Wynik = 1)

ID Liścia	P_samoocena_temat	N_samoocena_temat	P_emocje_temat	P_obraz_ciala_temat	Pełna Reguła Decyzyjna (Opis)
5	$\leq 0{,}43$	$> 0{,}102$	Dowolne	Dowolne	P_samoocena_temat $\leq 0{,}43$ ORAZ N_samoocena_temat $> 0{,}102$
7	$\leq 0{,}43$	$\leq 0{,}102$	$> 0{,}2565$	Dowolne	P_samoocena_temat $\leq 0{,}43$ ORAZ N_samoocena_temat $\leq 0{,}102$ ORAZ P_emocje_temat $> 0{,}2565$
8	$\leq 0{,}43$	$\leq 0{,}102$	$\leq 0{,}2565$	$\leq 0{,}054$	P_samoocena_temat $\leq 0{,}43$ ORAZ N_samoocena_temat $\leq 0{,}102$ ORAZ P_emocje_temat $\leq 0{,}2565$ ORAZ P_obraz_ciala_temat $\leq 0{,}054$

W celu pełnego zobrazowania struktury wygenerowanego modelu drzewa decyzyjnego oraz oceny realnego znaczenia poszczególnych reguł, które zostały opisane wcześniej, wygenerowano wykres kafelkowy (rysunek 4.23). Każdy kafelek reprezentuje konkrety liść z modelu drzewa. Niebieskie kafelki (ID=5, ID=8, ID=7) reprezentują te liście, w których dominują teksty autorstwa osób chorych. Jeśli do modelu trafi nowa obserwacja, dla których wartości zmiennych spełnią reguły opisane w jednym z tych kafelków, algorytm automatycznie przypisze mu etykietę: „chory". Zielone kafelki (ID=3, ID=9) reprezentują liście z przewagą wpisów pochodzących od osób zdrowych. Jeżeli nowa obserwacja spełni reguły opisane w którymś z tych kafelków, to model zakwalifikuje ją jako: „zdrową". Wykres kafelkowy pozwala zobrazować nie tylko same reguły decyzyjne, ale przede wszystkim to, jak duże grupy obserwacji do nich pasują, ponieważ powierzchnia każdego z pięciu kafelków jest proporcjonalna do liczebności obserwacji (N) zaklasyfikowanych do danego węzła końcowego.



Rysunek 4.23: Wykres kafelkowy przedstawiający klastry wraz z regułami decyzyjnymi (powierzchnia kafelka jest proporcjonalna do liczby obserwacji)

Największy kafelek na wykresie odpowiada liściowi o ID 5, skupiający niemal połowę całego korpusu tekstów (48,75%). Odpowiada on opisanemu wcześniej Profilowi 1. Do tego węzła trafiają notatki cechujące się niską obecnością słów dotyczących pozytywnej samooceny ($\leq 0{,}43$) oraz jednocześnie wysokim nasyceniu słownictwa związanego z samooceną w kontekście negatywnym ($> 0{,}102$).

Drugi pod względem wielkości kafelek (o ID 3) obejmuje 16,88% analizowanego zbioru i reprezentuje notatki zaklasyfikowane do grupy osób zdrowych. Odpowiadająca mu reguła opiera się na jednym warunku: wysoka wartość reprezentacji tematu samooceny w kontekście pozytywnym ($> 0{,}43$) skutkuje automatycznym zakwalifikowaniem tekstu jako pochodzącego od osoby zdrowej.

Dwa kafelki o ID 8 oraz 9 osiągnęły identyczną powierzchnię. Każdy z nich skupia po 13,12% badanych tekstów. Pierwszy z nich (ID 8) klasyfikuje teksty do grupy osób chorych i odzwierciedla profil 3, opisany wcześniej w części poświęconej analizie reguł decyzyjnych. Z kolei kafelek o ID 9 klasyfikuje notatki jako wpisy grupy osób zdrowych. Oba te węzły dzielą tożsamą ścieżkę decyzyjną aż do ostatniego poziomu (pierwsze trzy reguły są identyczne). Ostatecznym separatorem staje się zmienna P_obraz_ciala_temat. Niska wartość przynależności obrazu ciała do kontekstu pozytywnego ($\leq 0{,}054$) skutkuje zaklasyfikowaniem notatki do grupy osób chorych, natomiast wartość wyższa od 0,054 kwalifikuje go do grupy osób zdrowych.

Ostatni, najmniejszy kafelek o ID 7 obejmuje 8,12% analizowanych notatek. Zawarte w nim reguły odpowiadają profilowi 2 tekstów osób chorych, który został szczegółowo omówiony w sekcji dotyczącej analizy reguł decyzyjnych.

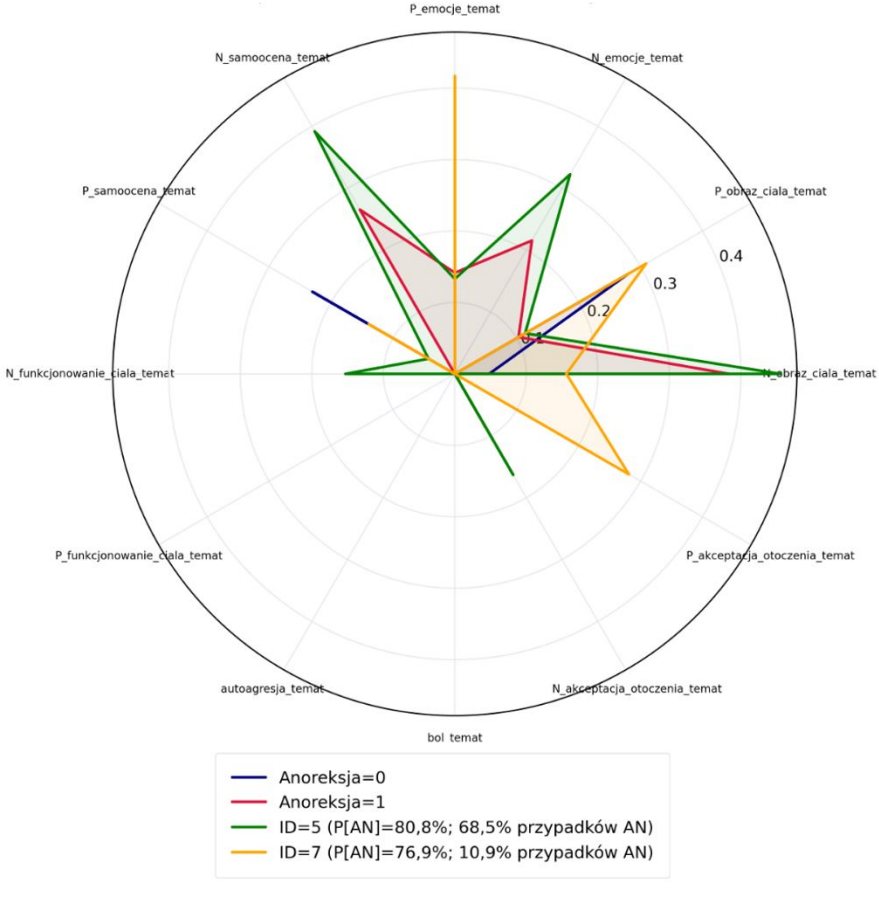
Wykres kafelkowy uwypukla istotną asymetrię w strukturze materiału tekstowego: choć wyłoniono trzy różne reguły identyfikujące teksty osób chorych, kluczowy wolumen stanowi liść ID 5 (blisko połowa wszystkich notatek), podczas gdy profile o ID 7 oraz ID 8 tworzą mniejsze, specyficzne podgrupy narracyjne.

Następnie przeanalizowano, które notatki wpadły do każdego węzła końcowego. Na tej podstawie obliczono mediany wartości przynależności dla wszystkich analizowanych obszarów tematycznych dla uzyskanych klastrów (węzły o ID 5,7 oraz 8). Wyniki przedstawiono na wykresie radarowym (rysunek 4.24). Odrzucono klaster o ID równym 8 ze względu na zerowe wartości median w wielu obszarach oraz na duże zanieczyszczenie węzła (brak wyraźnej dominacji wpisów z jednej grupy). Dodatkowo na wykresie zestawiono mediany dla całego korpusu tekstów osób chorych i zdrowych.

Dwa kluczowe węzły końcowe o ID równym 5 i 7 charakteryzowały się najwyższym prawdopodobieństwem poprawnego przypisania notatki do grupy osób chorych na anoreksję ($P[AN] = 80,8\%$ dla liścia o ID 5 oraz $P[AN] = 76,9\%$ dla liścia o ID 7).

Węzeł o ID równym 5, zawiera aż 68,5% wszystkich notatek sporządzonych przez osoby z diagnozą anoreksji. Analizując wyniki na podstawie wykresu można zauważyć, że ten profil charakteryzuje się nasileniem samooceny, emocji, obrazu ciała oraz akceptacją otoczenia w kontekście negatywnym. Profil ten jest zgodny z wynikami uzyskanymi wykorzystując model regresji logistycznej (rozdział 4.3.1). Taki rozkład cech w pełni pokrywa się z wnioskami z modelu regresji logistycznej i odzwierciedla tradycyjny wzorzec psychopatologiczny, stanowiąc dominujący profil narracyjny w analizowanym korpusie.

W węźle o ID równym 7 znalazło się 10,9% tekstów osób chorych. Prezentuje on odmienny profil tekstowy. Występują w nim wysokie wartości pozytywnych emocji, obrazu ciała i akceptacji otoczenia. Zastosowanie drzewa decyzyjnego pozwoliło na wyodrębnienie tej nieoczywistej grupy wpisów, która nie wpisuje się w standardowy kanon wypowiedzi osób doświadczających zaburzeń odżywiania. Taka specyfika tekstu może odzwierciedlać narracje tworzone na wczesnym etapie zaburzenia, kiedy redukcja masy ciała bywa jeszcze społecznie akceptowana, a nawet podsycana przez otoczenie. Alternatywnie, mogą stanowić językowy przejaw postawy perfekcjonistycznej i dążenia do aprobaty społecznej. W ich przypadku manifestowanie pozytywnych wartości w analizowanych tematach skutecznie maskują realne problemy z odżywianiem, z którym się borykają.



Rysunek 4.24: Wykres radarowy przedstawiający mediany wartości analizowanych zmiennych dotyczących obszarów trudności w grupie osób chorych (Anoreksja=1) i zdrowych (Anoreksja=0) oraz w wyodrębnionych klastrach (ID=5 i ID=7)

Dotychczasowa analiza prowadzi do dwóch ważnych konkluzji. Po pierwsze, teksty pisane przez osoby zmagające się z anoreksją wykazują heterogeniczność tematyczną. Dominująca część notatek (ok. 68%) skupia się wokół jawnej negatywnej samooceny

oraz braku akceptacji obrazu własnego ciała czemu towarzyszą negatywne emocje. Mniejsza podgrupa notatek (ok. 11%) manifestuje paradoksalnie wysokie wskaźniki w tematach pozytywnych emocji i dążenia do akceptacji otoczenia. Po drugie, zróżnicowanie to wskazuje na odmienne potrzeby analityczne i interpretacyjne. Część materiałów tekstowych ujawnia trudności w sposób bezpośredni i liniowy, natomiast identyfikacja problemów w notatkach o profilu zamaskowanym wymaga uwzględnienia złożonych, nieliniowych układów cech leksykalnych i tematycznych.

4.3.2.4 Analiza macierzy błędów i ocena wyznaczonych miar

Pozostałe 20% danych posłużyło do niezależnej oceny jakości predykcji. Zbiór testowy liczył 41 obserwacji, w tym 23 osoby chore na anoreksję i 18 osób zdrowych. Struktura zbioru testowego była stosunkowo zbalansowana. W tabeli 4.7 przedstawiono uzyskaną macierz błędów wyrażoną w procentach, a w tabeli 4.8 oraz 4.9 wyznaczone miary dla tego modelu.

Analiza macierzy pomyłek oraz obliczonych miar oceny klasyfikatora wskazuje na wysokie zróżnicowanie zdolności predykcyjnych modelu w zależności od analizowanej klasy tekstów. Model charakteryzuje się bardzo wysoką czułością na poziomie 0,913 (TPR), co oznacza, że aż 91,30% notatek pochodzących od osób rzeczywiście chorych zostało poprawnie przypisanych do klasy pozytywnej (TP = 91,30%). Konsekwencją tego jest niski współczynnik fałszywie negatywnych wyników (FNR = 0,087; FN = 8,70%), co oznacza, że jedynie niewielki odsetek notatek osób z anoreksją nie został wykryty przez algorytm. W zagadnieniu medycznym takie zjawisko jest pożądane, ponieważ minimalizuje ryzyko pominięcia materiału świadczącego o chorobie.

Z drugiej strony, model cechuje się niską swoistością wynoszącą zaledwie 0,333 (TNR). Oznacza to, że tylko 33,33% notatek od osób zdrowych sklasyfikowano poprawnie jako negatywne (TN = 33,33%). W pozostałych 66,67% przypadków tekstów od osób zdrowych błędnie przypisano do klasy tekstów od osób chorych (FPR = 0,667; FP = 66,67%). Wygenerowane drzewo decyzyjne wykazuje zatem silną tendencję do nadmiernej klasyfikacji w stronę klasy pozytywnej, co negatywnie wpływa na jego ogólną skuteczność (ACC = 0,659). Oznacza to, że model poprawnie klasyfikuje blisko 66% wszystkich analizowanych notatek. Współczynnik błędnych klasyfikacji równy 0,341 pokazuje, że model myli się w 34% przypadków. Wartość precyzji dodatniej (PPV = 0,636) oznacza, że prawdopodobieństwo, iż notatka zaklasyfikowana jako pozytywna faktycznie pochodzi od osoby chorej wynosi 63,6%. Pozostały odsetek równy 0,364 (czyli 36,4%) stanowią teksty osób zdrowych, które fałszywie oznaczono jako autorstwa chorych - miara ta nazywana jest współczynnikiem fałszywych odkryć (FDR). Wartość precyzji ujemnej (NPV) osiągnęła wartość 0,750. Wskaźnik ten informuje, że z prawdopodobieństwem równym 75% notatka zaklasyfikowana jako negatywna rzeczywiście została sporządzona przez osobę zdrową. Pozostały odsetek równy 0,250 (czyli 25%) to teksty osób chorych, które fałszywie sklasyfikowano jako teksty osób zdrowych - miara ta nazywana jest współczynnikiem fałszywych pominięć (FOR). Wyższa wartość miary F dla klasy pozytywnej ($F_P = 0{,}750$) niż dla klasy negatywnej ($F_N = 0{,}462$) potwierdza, że model radzi sobie znacznie lepiej z identyfikacją cech charakterystycznych dla notatek osób chorych niż zdrowych.

Współczynnik korelacji Matthewsa (MCC = 0,309) uwzględnia wszystkie wartości macierzy pomyłek. Wynik 0,309 świadczy o słabej korelacji dodatniej. Model klasyfikuje notatki lepiej niż losowe zgadywanie (gdzie $MCC = 0$), ale wciąż jest daleki od idealnego klasyfikatora. Indeks Youdena (J = 0,246), który jest sumą czułości i swoistości pomniejszoną o 1, przyjmuje niską wartość. Idealny klasyfikator osiąga wartość 1. Należy podkreślić, że ten niski wynik bezpośrednio wynika z niskiej swoistości modelu.

Tabela 4.7: Macierz pomyłek wyrażona w procentach.

Udział (%)			
TP Prawdziwie Pozytywny	**FN Fałszywie Negatywny**	**TN Prawdziwie Negatywny**	**FP Fałszywie Pozytywny**
91,30	8,70	33,33	66,67

Tabela 4.8: Obliczone pozostałe miary oceny modelu dla wybranego drzewa decyzyjnego - część 1.

Swoistość TNR	**Czułość TPR**	**Skuteczność ACC**	**Wsp. błędnych klasyfikacji**	**Precyzja PPV**	**Precyzja NPV**	**Miara F** F_P	**Miara F** F_N
0,333	0,913	0,659	0,341	0,636	0,750	0,750	0,462

Tabela 4.9: Obliczone pozostałe miary oceny modelu dla wybranego drzewa decyzyjnego - część 2.

Wsp. korelacji Matthewsa	**Indeks Youdena J**	**Wsp. fałszywie pozytywnych wyników FPR**	**Wsp. fałszywie negatywnych wyników FNR**	**Wsp. fałszywych odkryć FDR**	**Wsp. fałszywych pominięć FOR**
0,309	0,246	0,667	0,087	0,364	0,250

4.3.2.5 Podsumowanie analizy z wykorzystaniem drzew decyzyjnych

Podsumowując analizę z wykorzystaniem algorytmu drzew decyzyjnych, należy podkreślić, że ich zastosowanie w niniejszej pracy miało przede wszystkim charakter eksploracyjny i pomocniczy, a nie czysto klasyfikacyjny. Główną zaletą tego modelu jest jego transparentność w podejmowaniu decyzji i łatwa interpretacja wyników, co jest kluczowe w badaniach z dziedziny medycyny i psychologii. Analiza miar jakościowych ujawnia asymetrię w zdolnościach prognostycznych modelu. Z jednej strony, drzewo charakteryzowało się bardzo wysoką czułością ($TPR = 0{,}913$), co w kontekście wstępnej analizy danych jest cechą pożądaną, ponieważ oznacza to, że model skutecznie identyfikuje przeważającą większość próbek tekstowych autorstwa osób ze zdiagnozowaną anoreksją, minimalizując ryzyko przeoczenia. Z drugiej strony niska swoistość ($TNR = 0{,}333$) przekłada się na częste błędne przypisywanie tekstów osób zdrowych do grupy chorych. W rezultacie model uzyskał umiarkowaną skuteczność ($ACC = 0{,}659$) oraz niskie wartości współczynnika korelacji Matthews'a ($MCC = 0{,}309$) i indeksu Youdena ($J = 0{,}246$). Taka charakterystyka uzyskanych

miar metryk, czyli bardzo wysoka czułość kosztem swoistości, sprawia, że model bardzo dobrze sprawdza się jako narzędzie przesiewowe (screeningowe). Jego głównym zadaniem jest wyłapanie jak największej liczby podejrzanych notatek, tak aby żadnej nie przeoczyć, nawet jeśli część z nich zostanie błędnie zaklasyfikowana i będzie wymagała późniejszego sprawdzenia dokładniejszą metodą. Pomimo, że w dziedzinie uczenia maszynowego istnieją klasyfikatory osiągające wyższą ogólną efektywność, takie jak: sieci neuronowe czy lasy losowe, to niestety ich cechą wspólną jest to, że są zaliczane do algorytmów tzw. „czarnych skrzynek". Algorytmy te mogą uzyskać znacznie lepsze rezultaty klasyfikacyjne jednak kosztem utraty transparentności i interpretowalności wyników. W niniejszej pracy algorytm drzewa decyzyjnego posłużył jako narzędzie komplementarne, w którym głównym priorytetem była pełna interpretowalność. Umożliwiło to analizę hierarchii predykatorów oraz wygenerowanie reguł decyzyjnych. Pozwoliło to na wyodrębnienie czytelnych, lingwistycznych wzorców i markerów stylistyczno-tematycznych współwystępujących z notatkami osób cierpiących na anoreksję. W tym kontekście, słabsze wyniki obliczonych miar drzewa decyzyjnego nie dyskwalifikują go, lecz definiują jego rolę w procesie badawczym. Ten model nie ma służyć jako ostateczny klasyfikator, lecz jako przejrzyste narzędzie do wstępnej selekcji notatek.

4.3.3 Wykorzystanie algorytmu lasu losowego do klasyfikacji notatek do klas zdrowy/chory

Rozdział prezentuje wyniki działania algorytmu lasu losowego wykorzystanego do klasyfikacji notatek osób zdrowych i chorych na anoreksję. Zasada działania lasu losowego opiera się na generowaniu wielu drzew w procesie uczenia, a następnie agregacji ich poszczególnych decyzji. Proces treningu dokonano na próbie, która była równa 80% całego zbioru danych (160 obserwacji). W przypadku algorytmu lasu losowego wydzielanie osobnego zbioru walidacyjnego nie jest konieczne, ponieważ model posiada wbudowany mechanizm estymacji błędu oparty na próbach out-of-bag (OOB). Pozostałe 20% danych posłużyło do niezależnej oceny jakości predykcji. Efektywność algorytmu lasu losowego w dużej mierze zależy od właściwego doboru jego parametrów. W tabeli 4.10 zamieszczono przyjęte wartości analizowanych parametrów.

Tabela 4.10: Wartości przyjętych parametrów dla modelu lasu losowego

Parametr	**Przyjęta wartość**
Liczba drzew	100
Wielkość podpróby dla każdego drzewa	50%
Ziarno generatora liczb losowych	1
Liczba predyktorów losowanych w każdym podziale	4
Maksymalna głębokość drzewa	10
Minimalna liczba przypadków w węźle	5
Minimalna liczba przypadków w węźle potomnym	5
Maksymalna liczba węzłów	100

Las losowy został zbudowany z 100 niezależnych drzew decyzyjnych. Miało to na celu zapewnienie stabilności predykcji i ograniczenie wpływu losowych fluktuacji danych. Na każdym podziale drzewa, rozważano losowo 4 predyktory, odpowiadające liczbie wszystkich zmiennych wejściowych uwzględnionych w analizie. Dzięki temu każde drzewo było budowane w oparciu o nieco odmienny zestaw informacji, co zwiększało różnorodność modeli składowych i poprawiało zdolność generalizacji całego lasu. W procesie uczenia algorytmu każde pojedyncze drzewo decyzyjne było budowane w oparciu o losowy podzbiór obserwacji, obejmujący 50% danych z próby uczącej. Losowość procesu kontrolowano przy użyciu ustalonej wartości ziarna generatora liczb pseudolosowych (seed = 1), co umożliwiało odtworzenie wyników analizy. Ponadto, w każdym podziale drzewa rozważano losowo 4 wybrane predyktory. Wartość ta bezpośrednio wynika z teorii, w której dla zadań klasyfikacji optymalną liczbą rozważanych predyktorów jest pierwiastek kwadratowy z łącznej liczby wszystkich dostępnych predyktorów ($\sqrt{12} \approx 3,46$). Kolejne dobrane parametry związane są z kryteriami zatrzymania wzrostu drzewa, które mają za zadanie przeciwdziałania zjawisku nadmiernego dopasowania i rozrostu wygenerowanych drzew w ramach lasu. Maksymalną głębokość pojedynczego drzewa ograniczono do 10 poziomów. Minimalna liczba obserwacji, jaka musi znajdować się w danym węźle, aby algorytm w ogóle rozważał dokonanie jego dalszego podziału to 5. Wartość ta jest równa minimalnej liczbie obserwacji wymaganej do utworzenia liścia. Ostatnim parametrem było ustawienie maksymalnej liczby wszystkich węzłów (zarówno rozgałęzień jak i liści) w danym drzewie na 100. Dobór takiej konfiguracji parametrów pozwolił na zachowanie równowagi pomiędzy elastycznością modelu w wykrywaniu nieliniowych relacji, ale również chronił go przed nadmiernym dopasowaniem się do danych uczących, czyli zabezpieczał model przed przeuczeniem.

4.3.3.1 Analiza macierzy błędów i ocena wyznaczonych miar

Tak samo jak w przypadku drzew decyzyjnych pozostałe 20% danych posłużyło do niezależnej oceny jakości predykcji. W tabeli 4.11 przedstawiono uzyskaną macierz błędów, a w tabeli 4.12 oraz 4.13 wyznaczone miary dla tego modelu.

Model charakteryzuje się czułością na poziomie 0,783 (TPR), co oznacza, że prawidłowo zidentyfikował ponad 3/4 notatek autorstwa osób chorych (TP = 78,26%). Jednakże prawie co piąta notatka osoby chorej (FN = 21,74%) została błędnie uznana jako pochodząca od osoby zdrowej. W kontekście diagnostycznym jest to błąd krytyczny, ponieważ może opóźnić proces wdrożenia leczenia. Tylko nieco ponad połowa notatek osób zdrowych została prawidłowo rozpoznana (TN = 55,56%), zatem model charakteryzuje się swoistością równą 0,556 (TNR). Aż 44,44% notatek osób zdrowych zostało fałszywie przypisanych do klasy tekstów osób chorych (FP). Ogólna skuteczność modelu jest równa 0,683 (ACC), zatem model poprawnie klasyfikuje 68% wszystkich analizowanych tekstów, a myli się w 31,7% przypadków (wsp. błędnych klasyfikacji).

Wartość precyzji dodatniej (PPV = 0,692) oznacza, że prawdopodobieństwo wystąpienia choroby u autora notatki zaklasyfikowanej przez model jako pozytywna wynosi 69,2%. Pozostały odsetek równy 0,308 (czyli 30,8%), stanowią teksty osób zdrowych, które fałszywie sklasyfikowano do grupy tekstów chorych (FDR). Wartość precyzji ujemnej (NPV) osiągnęła wartość 0,667. Wskaźnik ten informuje, że notatka zaklasy-

fikowana jako negatywna z prawdopodobieństwem 66,7% faktycznie pochodzi od osoby zdrowej. Pozostały odsetek równy 0,333 (czyli 33,3%) to notatki osób chorych, błędnie uznane za teksty osób zdrowych (FOR). Wyższa wartość miary F dla klasy pozytywnej ($F_P = 0{,}735$) niż dla klasy negatywnej ($F_N = 0{,}606$) potwierdza lepszą jakość rozpoznawania tekstów od osób chorych niż zdrowych. Taki sam wniosek można wyciągnąć analizując wartości FPR i FNR. Współczynnik fałszywie negatywnych wyników równy 0,217(czyli 21,7%) jest istotnie niższy od współczynnika fałszywie pozytywnych wyników, który osiąga wartość 0,444 (czyli 44,4%), co sugeruje większą efektywność modelu w wykrywaniu próbek reprezentujących stan chorobowy.

Współczynnik korelacji Matthewsa (MCC = 0,348), który uwzględnia wszystkie wartości macierzy pomyłek oraz wartość Indeksu Youdena (J = 0,338) pokazują, że model klasyfikuje notatki lepiej niż wybór losowy, jednak charakteryzuje się umiarkowaną ogólną zdolnością do separacji obu klas.

Tabela 4.11: Macierz pomyłek wyrażona w procentach.

Udział (%)			
TP Prawdziwie Pozytywny	**FN Fałszywie Negatywny**	**TN Prawdziwie Negatywny**	**FP Fałszywie Pozytywny**
78,26	21,74	55,56	44,44

Tabela 4.12: Obliczone pozostałe miary oceny modelu dla wygenerowanego modelu lasu losowego - część 1.

Swoistość TNR	**Czułość TPR**	**Skuteczność ACC**	**Wsp. błędnych klasyfikacji**	**Precyzja PPV**	**Precyzja NPV**	**Miara F** F_P	**Miara F** F_N
0,556	0,783	0,683	0,317	0,692	0,667	0,735	0,606

Tabela 4.13: Obliczone pozostałe miary oceny modelu dla wygenerowanego modelu lasu losowego - część 2.

Wsp. korelacji Matthewsa	**Indeks Youdena J**	**Wsp. fałszywie pozytywnych wyników FPR**	**Wsp. fałszywie negatywnych wyników FNR**	**Wsp. fałszywych odkryć FDR**	**Wsp. fałszywych pominięć FOR**
0,348	0,338	0,444	0,217	0,308	0,333

4.3.4 Podsumowanie dotychczasowych wyników

Analizując uzyskane wyniki klasyfikacyjne dla poszczególnego drzewa opisanego w poprzednim podrozdziale z wygenerowanym lasem losowym można potwierdzić, że algorytmy zespołowe radzą sobie lepiej niż pojedyncze klasyfikatory. Las losowy uzyskał wyższą ogólną skutecznością (ACC = 0,683 dla lasu i 0,659 dla wybranego pojedynczego modelu) oraz wyższą stabilność predykcyjną. Potwierdzają to uzyskane wyż-

sze wartości współczynnika korelacji Matthewsa (MCC = 0,348 dla lasu i MCC = 0,309 dla drzewa) oraz indeksu Youdena (J = 0,338 dla lasu i J = 0,246 dla drzewa). Należy podkreślić, że pojedyncze drzewo uzyskało znacznie lepsze wyniki czułości (TPR = 0,913 dla drzewa i TPR = 0,783 dla lasu), co wskazuje, że drzewo prawie bezbłędnie klasyfikuje notatki osób chorych. Jednakże warto zaznaczyć, że pojedyncze drzewo uzyskało gorszy wynik swoistości (TNR = 0,333). Las losowy poprawił wynik swoistości (TNR = 0,556) kosztem spadku czułości oraz wyraźnie zredukował odsetek fałszywie pozytywnych wyników (FPR spadł z 0,667 do 0,444).

4.3.5 Wykorzystanie algorytmu sieci neuronowej do klasyfikacji notatek do klas zdrowy/chory

Niewystarczająco zadowalające wyniki uzyskane w poprzednim podrozdziale dla lasu losowego skłoniły do rozszerzenia badań o kolejny model. Mając na uwadze stosunkowo mały zbiór danych zdecydowano się na wykorzystanie sztucznych sieci neuronowych o prostej architekturze MLP (Multilayer Perceptron, czyli Perceptron Wielowarstwowy) oraz RBF (Radial Basis Function, czyli Sieć z Radialnymi Funkcjami Bazowymi). Celem wykorzystania tych dwóch różnych, ale klasycznych architektur sieci jednokierunkowych było sprawdzenie, czy będą w stanie osiągnąć lepsze wyniki klasyfikacyjne od lasu losowego. Na proces uczenia przeznaczono 60% danych, a na walidację oraz testowanie po 20%.

Dla analizowanych sieci MLP przebadano architektury zawierające od 5 do 14 neuronów w warstwie ukrytej. Analizie poddano różne kombinacje funkcji aktywacji neuronów warstwy ukrytej (analizie poddano funkcje: liniową, logistyczną, tangens hiperboliczny oraz wykładniczą) i wyjściowej (analizie poddano funkcje: logistyczną oraz funkcje Softmax, która jest typowa dla zadań klasyfikacyjnych).

Dla analizowanych sieci RBF badano architektury zawierające od 20 do 28 neuronów w warstwie ukrytej i wykorzystano standardową dla nich funkcję Gaussa.

Do uczenia sieci wykorzystano dwie funkcje błędu: sumę kwadratów oraz entropię. Następnie spośród wszystkich wytrenowanych modeli wybrano 5 najlepszych sieci, na podstawie uzyskanych wyników jakościowych na zbiorze walidacyjnym i testowym. Wybrane modele, wraz z ich charakterystyką zostały przedstawione w tabeli 4.14.

Wstępna ocena skuteczności procesów uczenia wskazuje na zróżnicowaną stabilność analizowanych pięciu modeli. Zjawisko przeuczenia w najmniejszym stopniu odnotowano dla sieci 25. MLP 12-10-2. Spadek jakości klasyfikacji między zbiorem uczącym (76,67%) a testowym (75,61%) był najmniejszy. Dla zbioru walidacyjnego skuteczność klasyfikacji również była zbliżona do pozostałych zbiorów (75%). Te niewielkie różnice pomiędzy uzyskanymi wynikami wskazują na dobrą zdolność generalizacji.

Tabela 4.14: Podsumowanie wybranych sieci wraz z informacjami o strukturze warstw

ID	Typ	Wejścia	Neurony ukryte	Wyjścia	Uczenie	Test	Walidacja	Algorytm	Błąd	Aktywacja ukryta	Aktywacja wyjściowa
22	MLP	12	13	2	82,500	73,171	75,000	BFGS 31	Entropia	Wykładnicza	Softmax
23	MLP	12	12	2	75,833	68,293	67,500	BFGS 5	Entropia	Tangens hiperb.	Softmax
24	RBF	12	21	2	60,833	63,415	70,000	RBFT	Entropia	Gaussa	Softmax
25	MLP	12	10	2	76,667	75,610	75,000	BFGS 6	SOS	Wykładnicza	Logistyczna
26	MLP	12	13	2	70,000	60,976	67,500	BFGS 2	Entropia	Liniowa	Softmax

Warto zwrócić uwagę na sieć 22. MLP 12-13-2. Wspomniany model mimo największej efektywności w procesie uczenia (82,50%), wykazał znaczący spadek skuteczności klasyfikacji na zbiorze testowym (73,17%), co sugeruje lekką tendencję do nadmiernego dopasowywania się do danych uczących. Sieć 24. RBF 12-21-2, która jest jedynym modelem bazującym na funkcjach radialnych uzyskał najniższą skuteczność podczas uczenia (60,83%). Podczas testowania, model ten charakteryzował się równie niską skutecznością (63,42%).

Macierz pomyłek przedstawiono w tabeli 4.15, a wyznaczone miary oceny jakości klasyfikacji analizowanych pięciu sieci zamieszczono w tabeli 4.16.

Wśród testowanych modeli, sieć 25. MLP 12-10-2 wydaje się być najbardziej stabilna i zbalansowana. Charakteryzuje się najwyższą swoistością równą 0,833 (TNR), co oznacza, że 83,33% notatek osób zdrowych zostało poprawnie zaklasyfikowanych jako negatywne (TN), generując jednocześnie najniższy odsetek fałszywych alarmów (notatek osób zdrowych zaklasyfikowanych jako pochodzące od osób chorych: FP = 16,67%). W klasie pozytywnej sieć ta uzyskała umiarkowaną czułość na poziomie 0,696 (TPR), czyli 69,57% notatek osób chorych zostało poprawnie zidentyfikowanych (TP). Zbliżone rezultaty wykazuje model 22. MLP 12-13-2, charakteryzujący się wysoką swoistością równą 77,78% oraz czułością wynoszącą 69,57%. Dla obydwu wspomnianych modeli aż 30,43% notatek osób chorych została fałszywie uznana za notatki osób zdrowych (FN).

Z punktu widzenia medycyny bardzo ważna jest wartość czułości. Sieci 26. MLP 12-13-2 oraz 24. RBF 12-21-2 osiągają znacznie wyższe wartości czułości, ale niższe wartości swoistości niż poprzednie wspomniane modele sieci. Pierwsza z nich charakteryzuje się czułością równą 0,783 (TPR), co pozwala na przeoczenie mniejszej liczby notatek osób chorych (FN = 21,74%). Należy jednak zaznaczyć, że model ten generuje aż 61,11% fałszywych wyników (FP). Podobną charakterystykę ma model 24. RBF 12-21-2. Sieć osiąga wysoką czułość równą 0,773 (TPR) oraz generuje aż 56,25% fałszywych alarmów (FP). Obydwie sieci charakteryzują się swoistością nie przekraczającą wartości 0,5 (50%).

Tabela 4.15: Macierz pomyłek dla analizowanych klasyfikatorów wyrażona w procentach.

	Udział (%)			
Klasyfikator	**TP Prawdziwie Pozytywny**	**FN Fałszywie Negatywny**	**TN Prawdziwie Negatywny**	**FP Fałszywie Pozytywny**
22. MLP 12-13-2	69,57%	30,43%	77,78%	22,22%
23. MLP 12-12-2	73,91%	26,09%	61,11%	38,89%
24. RBF 12-21-2	77,27%	22,73%	43,75%	56,25%
25. MLP 12-10-2	69,57%	30,43%	83,33%	16,67%
26. MLP 12-13-2	78,26%	21,74%	38,89%	61,11%

Najwyższą ogólną skuteczność uzyskał model 25. MLP 12-10-2 ($ACC = 0{,}756$), jednocześnie uzyskując najniższą wartość współczynnika błędnych klasyfikacji (0,244). Potwierdza to, że redukcja liczby neuronów w warstwie ukrytej do 10 uchroniła sieć

przed przeuczeniem. Bardzo dobrą skuteczność wykazuje również model 22. MLP 12-13-2 ($ACC = 0{,}732$). Najniższe wartości ACC uzyskuje sieć 26. MLP 12-13-2 ($ACC = 0{,}610$) oraz 24. RBF 12-21-2 ($ACC = 0{,}632$). Wskazuje to na brak balansu w modelach, w których wysoka wykrywalność notatek osób chorych skutkuje nieproporcjonalnie dużą liczbą błędów popełnianych na próbach negatywnych.

Dla modelu z najwyższą wartością ACC (25. MLP 12-10-2) wartość precyzji dodatniej osiąga PPV = 0,842. Oznacza to, że notatka zakwalifikowana jako pozytywna w 84,2% przypadków faktycznie pochodzi od osoby chorej. Pozostały odsetek równy 0,158 (czyli 15,8%) to notatki osób zdrowych błędnie przypisane do grupy osób chorych (FDR). Wartość precyzji ujemnej (NPV) dla tej sieci osiągnęła wielkość 0,682, co wskazuje, że z prawdopodobieństwem 68,2% notatka sklasyfikowana jako negatywna rzeczywiście należy do osoby zdrowej (FOR = 0,318). Model ten uzyskał najwyższe wartości miary F zarówno dla klasy pozytywnej ($F_P = 0{,}762$), jak i negatywnej ($F_N = 0{,}750$). Wyższy współczynnik fałszywie negatywnych wyników ($FNR = 0{,}304$) względem fałszywie pozytywnych ($FPR = 0{,}167$) wskazuje, że sieć skuteczniej unika fałszywych alarmów niż bezbłędnie wychwytuje wszystkie notatki pacjentów chorych.

Model 22. MLP 12-13-2 charakteryzuje się precyzją dodatnią $PPV = 0{,}800$ ($FDR = 0{,}200$) oraz precyzją ujemną $NPV = 0{,}667$ ($FOR = 0{,}333$). Dla tej sieci miara F dla klasy pozytywnej wynosi $F_P = 0{,}744$, a dla negatywnej $F_N = 0{,}718$. Wyższa wartość $FNR = 0{,}304$ w porównaniu do $FPR = 0{,}222$ potwierdza relatywnie większą stabilność modelu w poprawnej weryfikacji notatek osób zdrowych niż w bezwzględnej detekcji przypadków chorobowych.

Najsłabiej pod kątem precyzji wypada model 26. MLP 12-13-2. Prawdopodobieństwo, że notatka sklasyfikowana jako pozytywna faktycznie pochodzi od osoby chorej, wynosi jedynie 62,1% ($PPV = 0{,}621$, $FDR = 0{,}379$), a dla notatki negatywnej 58,3% ($NPV = 0{,}583$, $FOR = 0{,}417$). Model ten uzyskał najniższe miary F ($F_P = 0{,}692$, $F_N = 0{,}467$). Nadmierna czułość sieci pozwala na minimalizację liczby pominiętych notatek osób chorych ($FNR = 0{,}217$), jednak tendencja ta skutkuje bardzo wysokim wskaźnikiem fałszywie pozytywnych rozpoznań wśród notatek osób zdrowych ($FPR = 0{,}611$).

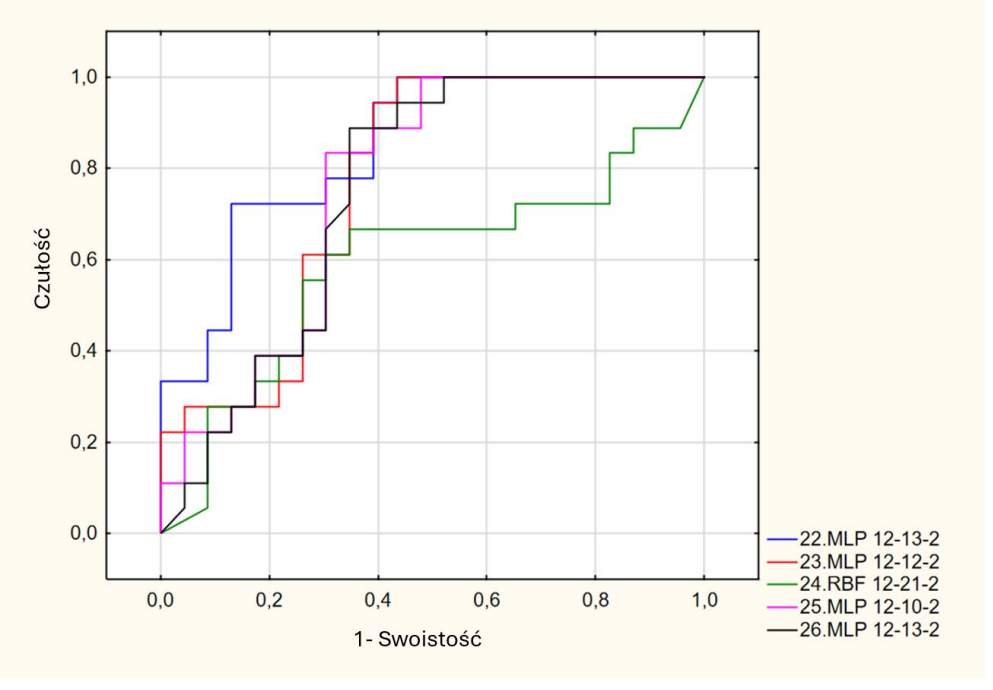
Wyniki współczynników korelacji Matthewsa i indeksów Youndena potwierdzają, że najlepszą siecią na tle pozostałych jest model 25. MLP 12-10-2. Miary te są najwyższe i równe odpowiednio $MCC = 0{,}526$ oraz $J = 0{,}529$. Bardzo zbliżone wyniki odnotowała sieć 22. MLP 12-13-2 ($MCC = 0{,}470$ i $J = 0{,}473$). Najsłabsze wyniki osiągnęła sieć 26. MLP 12-13-2 ($MCC = 0{,}187$, $J = 0{,}171$) oraz nr 24. RBF 12-21-2 ($MCC = 0{,}223$, $J = 0{,}210$).

Tabela 4.16: Miary oceny jakości klasyfikacji analizowanych sieci.

Klasyfikator	Swoistość TNR	Czułość TPR	Skuteczność ACC	Współczynnik błędnych klasyfikacji	Precyzja PPV	Precyzja NPV	Miara F Fp	Miara F FN
22. MLP 12-13-2	0,778	0,696	0,732	0,268	0,800	0,667	0,744	0,718
23. MLP 12-12-2	0,611	0,739	0,683	0,317	0,708	0,647	0,723	0,629
24. RBF 12-21-2	0,438	0,773	0,632	0,368	0,654	0,583	0,708	0,500
25. MLP 12-10-2	0,833	0,696	0,756	0,244	0,842	0,682	0,762	0,750
26. MLP 12-13-2	0,389	0,783	0,610	0,390	0,621	0,583	0,692	0,467

Klasyfikator	Współczynnik korelacji Matthewsa	Indeks Youdena J	Wsp. fałszywie pozytywnych wyników FPR	Wsp. fałszywie negatywnych wyników FNR	Współczynnik fałszywych odkryć FDR	Współczynnik fałszywych pominięć FOR
22. MLP 12-13-2	0,470	0,473	0,222	0,304	0,200	0,333
23. MLP 12-12-2	0,353	0,350	0,389	0,261	0,292	0,353
24. RBF 12-21-2	0,223	0,210	0,563	0,227	0,346	0,417
25. MLP 12-10-2	0,526	0,529	0,167	0,304	0,158	0,318
26. MLP 12-13-2	0,187	0,171	0,611	0,217	0,379	0,417

Kluczowym kryterium do oceny jakości wygenerowanych modeli sieci jest wartość AUC. Wskaźnik ten reprezentuje pole pod krzywą, która powstała wykorzystując wyniki uzyskane ze zbioru testowego. Krzywe zamieszczono na wykresie na rysunku 4.25, a wartość AUC dla każdego modelu w tabeli 4.17.



Rysunek 4.25: Wykres krzywych ROC dla pięciu wybranych modeli wygenerowane dla zbioru testowego

Najwyższą zdolnością klasyfikacyjną charakteryzuje się Sieć 22. MLP 12-13-2, osiągając wartość punktową AUC = 0,848. Zatem ten model jest najbardziej efektywny w zadaniach, które polegają na klasyfikacji (rozróżnieniu notatki osób zdrowych od notatki osób chorych na anoreksję). Niższe choć zbliżone do siebie wyniki uzyskały modele MLP 12-12-2 i MLP 12-10-2, osiągając wyniki równe odpowiednio AUC = 0,768 oraz AUC = 0,761. Znacząco niższą wartość punktową AUC uzyskał model RBF 12-21-2, osiągając AUC = 0,592. Wynik ten jest niewiele wyższy od modelu klasyfikatora losowego AUC = 0,5, co w praktyce dyskwalifikuje ten model z dalszych zastosowań.

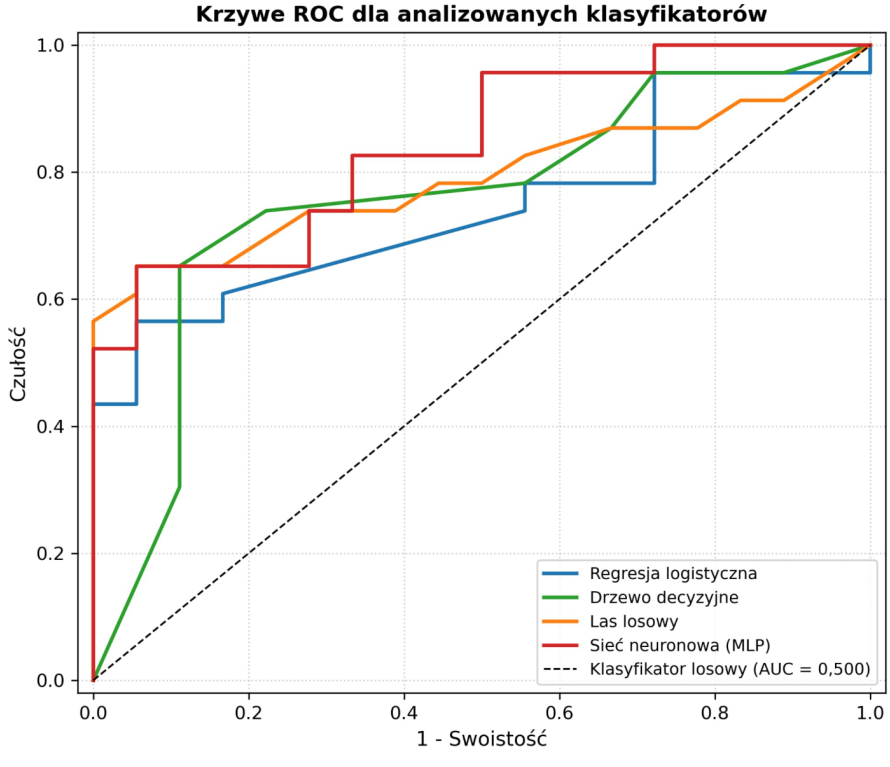
Tabela 4.17: Wartość pola pod krzywą ROC (AUC) dla zbioru testowego dla wybranych pięciu analizowanych sieci.

	Sieć 22 MLP 12-13-2	**Sieć 23 MLP 12-12-2**	**Sieć 24 RBF 12-21-2**	**Sieć 25 MLP 12-10-2**	**Sieć 26 MLP 12-13-2**
AUC	0,848	0,768	0,592	0,761	0,749

4.3.6 Kompleksowa analiza porównawcza modeli predykcyjnych

W celu porównania skuteczności badanych modeli (regresji logistycznej, drzewa decyzyjnego, lasu losowego oraz sieci neuronowej MLP), wykorzystano analizę krzywych ROC oraz wartość AUC. Zbiorcze zestawienie wyników zostało zamieszczone w tabeli 4.18, a wykresy krzywych ROC na rysunku 4.26.

Wszystkie cztery analizowane modele charakteryzują się zadowalającą lub bardzo dobrą zdolnością dyskryminacyjną (klasyfikacyjną), osiągając wartości AUC istotnie wyższe od klasyfikatora losowego (AUC = 0,500; $p < 0{,}001$). Analiza przebiegu krzywych ROC (rysunek 4.26) oraz zbiorczych wyników w tabeli 4.18 wskazuje na wyraźną zależność: jakość klasyfikacji rosła wraz ze stopniem złożoności matematycznej algorytmu. Klasyczna regresja logistyczna uzyskała najniższą punktową skuteczność (AUC = 0,745), podczas gdy pojedyncze drzewo decyzyjne podniosło ten wynik do poziomu 0,773. Zastosowanie lasu losowego, który jest zbudowany z wielu modeli drzew, pozwoliło na dalszą poprawę wskaźnika (AUC = 0,792; 95% CI:[0,650; 0,934]). W ujęciu bezwzględnym najwyższą punktową sprawność predykcyjną odnotowano dla modelu sieci neuronowej MLP (AUC = 0,848; 95% CI:[0,730; 0,966]), która jako jedyna przekroczyła próg 0,80, wykazując jednocześnie najniższy błąd standardowy estymacji (SE = 0,060).



Rysunek 4.26: Porównanie krzywych ROC dla czterech analizowanych klasyfikatorów

Tabela 4.18: Zbiorcze porównanie zdolności dyskryminacyjnej badanych klasyfikatorów wraz z 95% przedziałami ufności

Klasyfikator	**AUC**	**95% CI**	SE	p
Regresja logistyczna	0,745	[0,622; 0,868]	0,063	$< 0{,}001$
Drzewo decyzyjne	0,773	[0,634; 0,912]	0,071	$< 0{,}001$
Las losowy	0,792	[0,650; 0,934]	0,072	$< 0{,}001$
Sieć neuronowa (MLP)	0,848	[0,730; 0,966]	0,060	$< 0{,}001$

Chociaż przeanalizowane punktowe wartości pola pod krzywą ROC sugerują przewagę sieci neuronowej nad pozostałymi modelami, weryfikacji istotności tych rozbieżności wymagała formalnej oceny statystycznej. W tym celu zastosowano test DeLonga dla prób zależnych, który na przyjętym poziomie istotności ($\alpha = 0{,}05$) nie wykazał statystycznie istotnych różnic pomiędzy badanymi modelami. Wyniki zamieszczono w tabeli 4.19.

Tabela 4.19: Wyniki testu DeLonga dla prób zależnych oceniającego istotność różnic pomiędzy polami pod krzywymi ROC

Porównywane modele	**ΔAUC**	SE_Δ	**Statystyka** Z	**Wartość** p
Regresja logistyczna vs Drzewo decyzyjne	0,0280	0,0724	0,3867	0,6989
Regresja logistyczna vs Las losowy	0,0470	0,0585	0,8034	0,4217
Regresja logistyczna vs Sieć MLP	0,1030	0,0861	1,1963	0,2316
Drzewo decyzyjne vs Las losowy	0,0190	0,0492	0,3862	0,6993
Drzewo decyzyjne vs Sieć MLP	0,0750	0,0789	0,9506	0,3418
Las losowy vs Sieć MLP	0,0560	0,0682	0,8211	0,4116

Przeprowadzona analiza wykazała, że żadna z zaobserwowanych różnic pomiędzy modelami nie osiągnęła poziomu istotności we wszystkich zestawieniach. Nawet biorąc pod uwagę najbardziej wyraźną rozbieżność pomiędzy siecią neuronową a modelem regresji logistycznej, gdzie bezwzględna różnica wielkości pola pod krzywą przekroczyła 0,10 ($\Delta\text{AUC} = 0{,}1030$), test DeLonga nie dał podstaw do odrzucenia hipotezy zerowej o równoważności predykcyjnej obu podejść ($Z = 1{,}1963$; $p = 0{,}2316$).
Brak istotności statystycznej przy wyraźniej różnicy punktowej wynika ze specyfiki testu DeLonga oraz wielkości badanej próby. Metoda ta szacuje błąd standardowy różnicy pól (SE_Δ) na bazie pełnej macierzy kowariancji predykcji. Przy próbie $N = 201$ błędy estymacji poszczególnych modeli oraz błąd samej różnicy pozostają na tyle szerokie, że moc statystyczna testu jest niewystarczająca do potwierdzenia przewagi algorytmu nieliniowego.

Podsumowując, choć sieć neuronowa wykazuje silny potencjał aplikacyjny, ostateczne dowiedzenie jej przewagi nad tradycyjnymi modelami liniowymi w analizowanym problemie badawczym wymaga weryfikacji na znacznie liczniejszej próbie walidacyjnej.

Wykorzystując regresję logistyczną, zidentyfikowano dwa najważniejsze predyktory powiązane z obecnością anoreksji (tabela 4.20). Uzyskane wyniki wskazują, że samoocena w kontekście negatywnym wiąże się z wysokim współwystępowaniem anoreksji, natomiast obraz ciała w kontekście pozytywnym wiąże się z niskim współwystępowaniem anoreksji.

Tabela 4.20: Wyłonione najważniejsze predyktory przy wykorzystaniu modelu regresji logistycznej

Zmienna	p	OR
Samoocena kontekst negatywny	<0,001	29,485
Obraz ciała kontekst pozytywny	0,001	0,119

Eksploracja danych przy wykorzystaniu algorytmu drzewa decyzyjnego pozwoliła na pogłębienie wniosków uzyskanych z regresji logistycznej. Choć przyrost pola pod krzywą nie osiągnął progu istotności statystycznej, model drzewa umożliwił wyodrębnienie reguł decyzyjnych, identyfikację zależności progowych oraz wyodrębnienie specyficznych profili wypowiedzi w zebranym materiale tekstowym:

- Klaster ID = 5 (Profil ogólnego braku akceptacji siebie i własnego ciała) - Reprezentuje on większość analizowanego korpusu tekstów pochodzących od osób z anoreksją - aż 68,5% wpisów z tej grupy, przy warunkowym prawdopodobieństwie klasyfikacji na poziomie 80,8%. Wypowiedzi te charakteryzują się współwystępowaniem trzech zmiennych: wysokiej negatywnej samooceny, wysokiej wartości postrzegania obrazu własnego ciała w sposób negatywny oraz wysokiego poziomu negatywnych emocji. Taka struktura notatek odzwierciedla klasyczne, tradycyjne narracje opisywane w literaturze przedmiotu i jest spójna z predyktorami wyłonionym przez model regresji logistycznej.
- Klaster ID = 7 (Profil nietypowy / maskowany narracyjnie) - Reprezentuje mniejszą grupę badanych notatek autorstwa osób chorych (10,9%), jednak przy wysokim prawdopodobieństwie klasyfikacji równym 76,9%. Wyróżnia się on obecnością wysokich wartości pozytywnych emocji, obrazu ciała i akceptacji otoczenia. Wyodrębnienie tej grupy stanowi cenny wkład eksploracyjny, dowodząc, że część wypowiedzi osób zmagających się z anoreksją nie wykazuje cech typowych dla standardowego wzorca leksykalnego. Ze względu na wielkość próby obserwację tę należy traktować jako hipotezę roboczą wymagającą dalszych badań na szerszym korpusie tekstowym.

Wykorzystanie lasu losowego oraz sieci neuronowej MLP przyniosło punktowy wzrost wartości AUC (odpowiednio do 0,792 i 0,848). Brak istotności statystycznej tych różnic w tekście DeLonga nakazuje jednak dużą ostrożność w formułowaniu wniosków o jednoznacznej przewadze algorytmów złożonych nad modelami prostymi.

W kontekście analizy zgromadzonego materiału tekstowego uzyskane rezultaty prowadzą do dwóch wniosków:

- Satysfakcjonujący wynik regresji logistycznej ($AUC = 0{,}745$) wskazuje, że relacje liniowe oparte na kilku kluczowych wymiarach tematycznych (przede wszystkim kontekście negatywnej samooceny i deficycie pozytywnego obrazu ciała) wystarczająco dobrze rozróżniają notatki osób chorych i zdrowych.
- Zbliżona skuteczność punktowa pojedynczego drzewa decyzyjnego ($AUC = 0{,}773$) oraz lasu losowego ($AUC = 0{,}792$) sugeruje, że zależności obecne w danych dają

się w dużej mierze opisać za pomocą stosunkowo prostych, bezpośrednich reguł podziału. Niewielka różnica pomiędzy tymi podejściami sugeruje, że struktura danych nie ma charakteru chaotycznego, a zidentyfikowane wzorce językowe powiązane z anoreksją są spójne, dobrze ustrukturowane i dają się z powodzeniem opisać za pomocą prostych reguł decyzyjnych.

4.4 Zastosowanie metody wykrywania obszarów trudności w innych dziedzinach - wyniki dla otyłości, nadwagi i nowotworów głowy i szyi

W notatkach osób z nadwagą i otyłością najczęściej były poruszane trzy obszary trudności: obraz ciała, emocje i samoocena. Celem tego badania była obserwacja jak zmieniały się wyniki po udziale w porównaniu do tych z okresu przed udziałem w programie dietetycznym.

W grupie osób z nadwagą przed programem dietetycznym negatywny obraz ciała wykryto metodą słownikową w 65% analizowanych notatek, a pozytywny w 22%. Po udziale w programie negatywny obraz ciała zidentyfikowano już tylko w 17% wypowiedzi, natomiast pozytywny w 52%. Porównanie wartości przynależności do danego obszaru w notatkach sporządzonych przed i po programie pozwoliło ocenić kierunek zmian dla poszczególnych uczestników. Spadek negatywnego obrazu ciała w wypowiedziach odnotowano w 65% przypadków, a wzrost pozytywnego w 52% (tabela 4.21). Jednoczesną poprawę (rozumianą jako równoczesny spadek negatywnej i wzrost pozytywnej wartości) zaobserwowano w notatkach 43% badanych. Przed rozpoczęciem programu negatywne emocje zidentyfikowano w 30% notatek, a emocje pozytywne w 17%. Po udziale w programie dietetycznym negatywne emocje wystąpiły w 17% wypowiedzi, a pozytywne w 52%. Analiza porównawcza wypowiedzi tych samych osób przed i po programie wykazała, że spadek nasilenia negatywnych emocji wystąpił w 30% przypadków, podczas gdy wzrost emocji pozytywnych dotyczył 52% wypowiedzi. Łączną poprawę w obszarze emocji odnotowano w notatkach 26% uczestników (tabela 4.21). W przypadku samooceny przed programem polaryzację negatywną stwierdzono w 39% notatek, a pozytywną w 22%. Po programie negatywną samoocenę zidentyfikowano w 22% wypowiedzi, a pozytywną w 39%. Zestawienie tekstów przed i po udziel w programie dietetycznym wykazało spadek negatywnej samooceny w wypowiedziach 35% badanych oraz wzrost pozytywnej samooceny w 39% przypadków. Łączną poprawę w tym wymiarze zaobserwowano w notatkach 22% uczestników (tabela 4.21).

Analogiczny charakter zmian odnotowano w grupie osób z otyłością. Przed programem dietetycznym negatywny obraz ciała wykryto w 77% wypowiedzi pisemnych, a pozytywny w 27%. Po programie negatywny obraz ciała zidentyfikowano w 36% notatek, natomiast pozytywny w 55%. Porównanie wypowiedzi przed i po interwencji wykazało spadek negatywnego obrazu ciała u 64% badanych, a wzrost pozytywnego u 46% (tabela 4.21). Jednoczesną poprawę odnotowano w notatkach 36% uczestników. Przed udziałem w programie negatywne emocje zarejestrowano w 23% notatek, a pozytywne w 18%. Po programie emocje negatywne obecne były w 18% wypowiedzi, a pozytywne w 45%. W analizie par wypowiedzi spadek negatywnych emocji stwierdzono w 14%

przypadków, natomiast wzrost emocji pozytywnych w 36%. Łączną poprawę zaobserwowano w notatkach 9% uczestników (tabela 4.21). Przed programem w 59% notatek odnotowano negatywną samoocenę, a w 27% pozytywną. Po zakończeniu programu negatywną samoocenę wykryto w 32% wypowiedzi, a pozytywną w 45%. Oznacza to, że negatywna samoocena w wypowiedziach uległa obniżeniu w 50% przypadków, a pozytywna wzrosła w 32% (tabela 4.21). Łączną poprawę w zakresie samooceny odnotowano w notatkach 18% badanych.

Tabela 4.21: Zmiany w negatywnym i pozytywnym obrazie ciała, emocjach oraz samoocenie po udziale w programie dietetycznym wśród uczestników z nadwagą i otyłością (wartości procentowe).

Obraz ciała			
	Zmiana	**Nadwaga (%)**	**Otyłość (%)**
Negatywny obraz ciała	Spadek	65,3	63,7
	Wzrost	13,0	13,6
	Bez zmian	21,7	22,7
Pozytywny obraz ciała	Spadek	26,1	9,1
	Wzrost	52,2	45,5
	Bez zmian	21,7	45,5
Łączna poprawa*	–	43,5	36,4
Emocje			
Zmienna	**Zmiana**	**Nadwaga (%)**	**Otyłość (%)**
Negatywne emocje	Spadek	30,4	13,6
	Wzrost	17,4	13,6
	Bez zmian	52,2	72,8
Pozytywne emocje	Spadek	13,0	9,1
	Wzrost	52,2	36,4
	Bez zmian	34,8	54,5
Łączna poprawa*	–	26,1	9,1
Samoocena			
Zmienna	**Zmiana**	**Nadwaga (%)**	**Otyłość (%)**
Negatywna samoocena	Spadek	34,8	50,0
	Wzrost	17,4	9,1
	Bez zmian	47,8	40,9
Pozytywna samoocena	Spadek	21,7	9,1
	Wzrost	39,1	31,8
	Bez zmian	39,1	59,1
Łączna poprawa*	–	21,7	18,2

* Łączna poprawa definiowana jest jako jednoczesny spadek negatywnego i wzrost pozytywnej przynależności notatki w danym obszarze (temacie).

Zastosowane podejście pozwoliło na wykrycie poruszenia danych tematów w wypowiedziach uczestników badania, a następnie uchwycenie i porównanie dynamiki zmian w postrzeganiu własnego ciała, emocjach i samoocenie przez uczestników po udziale w programie dietetycznym.

Wyniki analizy metodą słownikową dotyczące wypowiedzi pisemnych osób, u których zdiagnozowano raka górnego odcinka przewodu pokarmowego lub głowy i szyi stanowią część badań własnych autora i zostały wcześniej opublikowane w artykułach [132] i [133].

W artykule [133] przedstawiono wyniki badań z wykorzystaniem metody słownikowej do analizy notatek pacjentów pod kątem wykrycia obszarów trudności takich jak: obraz ciała, samoocena oraz akceptacja otoczenia. Skuteczność metody dla obszaru akceptacji otoczenia była najwyższa i wyniosła 82% (błąd odnotowano w 16% przypadków). Niewiele niższą skuteczność uzyskano dla obszaru samooceny. Zgodność z oceną ekspercką była na poziomie 80%, przy czym ewidentny błąd wystąpił w 4% przypadków. Największym wyzwaniem okazał się kontekst mieszany. W 16% notatek algorytm wskazywał na przewagę jednego z kontekstów, podczas gdy eksperci diagnozowali kontekst mieszany. Dla obszaru „obraz ciała" zgodność metody wyniosła 78%, błąd odnotowano w 8% przypadków, a w 12% notatek metoda nie rozpoznała kontekstu mieszanego, wskazując na przewagę jednej z polaryzacji.

W artykule [132], który jest kontynuacją tematyki z artykułu [133], poddano analizie trzy obszary trudności: obraz ciała, samoocenę oraz ból. Uczestników podzielono na trzy grupy w zależności od etapu i czasu trwania żywienia dojelitowego (grupy: I stadium, II stadium i pacjenci paliatywni). W przypadku obszaru obraz ciała skuteczność metody różniła się w zależności od grupy. Najwyższą zgodność z oceną ekspertów odnotowano u pacjentów paliatywnych (86%), gdzie przeważał negatywny obraz ciała (67% przypadków, podczas gdy pozytywny i mieszany stanowiły po 16,5%). W grupie I zgodność wyniosła 82% (78% pacjentów ujawniało negatywny, a 22% pozytywny obraz ciała). W grupie II zgodność ukształtowała się na poziomie 75% (negatywny obraz ciała odnotowano u 46% osób, pozytywny u 42%, a mieszany u 8%). W obszarze samoocena najwyższą zgodność (87%) osiągnięto w grupie II (negatywna samoocena u 46% badanych, pozytywna u 36%). W grupie pacjentów paliatywnych zgodność metody była równa 71%. W przypadku 80% notatek wykazano negatywną samoocenę, a w 20% pozytywną. Zgodność na poziomie równym 64% wykazano u pacjentów w I stadium choroby. W tej grupie dominowała negatywna samoocena (71%). Pozytywna samoocena została wykryta w 29% przypadków. Dla obszaru trudności jakim był ból, metoda wykazała 100% skuteczność na każdym etapie choroby.

5. Podsumowanie i dyskusja

W ramach rozprawy doktorskiej, wypowiedzi pisemne osób chorych na anoreksję jak i zdrowych przeanalizowano pod kątem siedmiu wybranych tematów takich jak: obraz ciała, emocje, samoocena, funkcjonowanie ciała, akceptacja otoczenia, autoagresja oraz ból. Wskazane tematy oprócz dwóch ostatnich analizowano zarówno w kontekście negatywnym jak i pozytywnym. Wyboru obszarów trudności dokonano na podstawie przeprowadzonej analizy literatury. Wiele prac wskazuje, że zniekształcony i silnie niepoprawny obraz ciała stanowi kluczowy obszar, z którym zmagają się pacjenci chorzy na anoreksję [50, 51, 55]. Praca nad tym tematem odgrywa ważną rolę w procesie leczenia [52], podkreślając, że im wyższy jest poziom zniekształcenia obrazu ciała, tym leczenie okazuje się trudniejsze [53]. Ponadto badacze zwracają uwagę, że obraz ciała często współwystępuje z innymi obszarami trudności np. z samooceną lub trudnościami emocjonalnymi [54]. W licznych publikacjach podkreśla się, że osoby zmagające się z zaburzeniami odżywiania często odczuwają silne emocje, w tym: lęk, wstyd, winę, ból czy złość [51, 55, 56]. Autorzy często zwracają uwagę, że emocje odzwierciedlają wysoki poziom wewnętrznego napięcia, z którym zmagają się osoby chore [56]. Współczesne badania wskazują, że sfera emocjonalna odgrywa istotną rolę zarówno w rozwoju, jak i w podtrzymywaniu zaburzeń odżywiania [54]. Zaburzony obraz ciała bardzo często powiązany jest z obniżoną samooceną [54, 56, 61]. Wśród osób chorujących na anoreksję zauważalne są różne zachowania autoagresywne, począwszy od stosowania środków przeczyszczających, poprzez głodzenie się, zadawanie bólu czy samookaleczanie się [56, 59, 62], a także próby samobójcze [61, 3]. Występowanie autoagresji wskazuje na cięższy przebieg zaburzenia, utrudnia terapię i pogarsza rokowania [59, 62]. U osób z anoreksją w obszarze funkcjonowania ciała często występują zachowania kompulsywne, obejmujące m.in. prowokowanie wymiotów, stosowanie środków przeczyszczających, głodzenie się oraz narażanie się na urazy fizyczne [56]. W literaturze często poruszana jest również kwestia akceptacji otoczenia osób cierpiących na zaburzenia odżywiania. Zwraca się uwagę, że postrzeganie własnego obrazu ciała, szczególny wpływ ma otoczenie, w tym społeczeństwo [63]. Osoby chore mogą unikać kontaktów społecznych [51]. Badania wskazują, że negatywne doświadczenia społeczne, czy brak wsparcia społecznego mogą odgrywać istotną rolę w podtrzymywaniu objawów anoreksji [49].

Istotnym elementem przeprowadzonych badań było opracowanie autorskich słowników tematycznych dedykowanych analizowanym obszarom trudności, które posłużyły do zautomatyzowanej detekcji tematów w pisemnych notatkach. Zastosowanie metod eksploracji tekstu, obejmujących wstępne przetwarzanie (m.in. lematyzację, eliminację wyrazów ze stop-listy, w tym spójników i przyimków), przekształcenie wypowiedzi do modelu worka słów oraz ważenie lokalno-globalne (Log-IDF), umożliwiło utworze-

nie macierzy częstości X. W celu redukcji wymiarowości wykorzystano metodę analizy ukrytych relacji semantycznych (LSA) opartą na dekompozycji według wartości osobliwych (SVD). Profile tematyczne rzutowano na przestrzeń cech metodą fold-in, a miara podobieństwa kosinusowego pozwoliła na rozszerzenie słowników o bliskoznaczne terminy. Ostateczne wyznaczenie stopnia przynależności notatki (W_{raw}) oparto na iloczynie skalarnym wektora wag pojęć oraz wektora cech dokumentu.

Zaproponowana metoda wykazała się wysoką skutecznością ogólną, choć jej efektywność różniła się w zależności od specyfiki danego tematu. Niemal bezbłędną skuteczność osiągnięto w obszarach „Autoagresja" (99% zgodności) oraz „Ból" (99% zgodności). Tak wysoki wynik wynika ze specyfiki tych tematów, opierających się na wysoce jednoznacznym i specyficznym słownictwem, w którym odnotowano jedynie pojedyncze błędy III rodzaju (fałszywe wykrycia). Bardzo dobrą zbieżność z oceną ekspercką zaobserwowano również dla obszarów: „Samoocena" (86% zgodności), „Emocje" (83% zgodności) oraz „Funkcjonowanie ciała" (83% zgodności). W przeciwieństwie do „Bólu" czy „Autoagresji" tematy te cechują się znacznie bogatszym słownictwem. Uzyskane wyniki wskazują jednak, że wciąż opierają się one na stosunkowo spójnym zestawie pojęć bazowych oraz bezpośrednich deklaracjach autorek dotyczących nastroju, emocji czy problemów fizycznych. W obszarach tych rozbieżności miały umiarkowany charakter i wynikały głównie z wysokiej czułości metody generującej błędy III rodzaju, a znacznie rzadziej dotyczyły przeoczenia tematu (błąd II rodzaju) czy niepoprawnej polaryzacji (błąd I rodzaju). Najniższą poprawnością działania charakteryzowały się tematy „Obraz ciała" (75% zgodności) oraz „Akceptacja otoczenia" (69% zgodności), w których odnotowano najwyższy odsetek rozbieżności. W obszarze „Obrazu ciała" słabszy wynik wynikał ze specyfiki wypowiedzi osób chorych, obejmującej ambiwalencję oraz częste stosowanie zaprzeczeń. Ograniczenia te w połączeniu z brakiem uwzględniania negacji w modelu worka słów prowadziło do błędnego przypisania kontekstu (negatywny lub pozytywny). W temacie „Akceptacji otoczenia" aż 49 fałszywych wykryć (błąd III rodzaju) uwypukliło zasadnicze ograniczenie metody, która dotyczyła tego, że ocena relacji z otoczeniem wymaga interpretacji pełnego kontekstu i struktury składniowej zdania, podczas gdy wykrywanie obecności słów w metodach LSA/SVD prowadzi do nadinterpretacji wypowiedzi. Można również podejrzewać, że niższa wartość zgodności dla tych obszarów w porównaniu z resztą wynika ze specyfiki psychopatologicznej tych obszarów, które w pierwszej kolejności ulegają zniekształceniu przez mechanizmy obronne, takie jak wyparcie czy racjonalizacja.

Analiza porównawcza wypowiedzi pisemnych z wykorzystaniem testu U Manna-Whitneya wykazała istotne statystycznie różnice między badanymi grupami w stopniu poruszenia poszczególnych tematów (przy uwzględnieniu poprawki Bonferroniego, $\alpha_{Bonf} = 0{,}0042$). W narracji osób cierpiących na anoreksję odnotowano istotnie wyższy poziom treści dotyczących negatywnego obrazu ciała, negatywnych emocji, negatywnej samooceny, krytycznej oceny funkcjonowania własnego ciała oraz poczucia braku akceptacji ze strony otoczenia. W notatkach z grupy osób zdrowych odnotowano istotną przewagę wątków skoncentrowanych na pozytywnym obrazie ciała oraz pozytywnej samoocenie. Uwzględniając korektę na wielokrotne testowanie nie wykazano istotnych statystycznie różnic w odniesieniu do pozytywnych emocji, pozytywnego funkcjonowania ciała, autoagresji, bólu oraz akceptacji otoczenia w kontekście

pozytywnym.

Wykorzystanie algorytmów uczenia maszynowego pozwoliło na głębszą analizę uzyskanych wyników z pierwszej części badań własnych, które dotyczyły identyfikacji obszarów tematycznych w danym kontekście. Wyniki uzyskane przy pomocy regresji logistycznej pozwoliły na wskazanie zmiennych, które w sposób wysoce istotny statystycznie ($p < 0{,}05$) różnicują szanse współwystępowania choroby. Samoocena w kontekście negatywnym ($B = 3{,}384$; $OR = 29{,}485$; $p < 0{,}001$) wiąże się z wysokim współwystępowaniem anoreksji. Wyniki te potwierdzają ustalenia wielu badań psychologów i psychiatrów. Prace Garnera i wsp. podkreślają znaczenie niskiej samooceny w anoreksji [149, 150]. Fairburn i wsp. piszą, że niska samoocena jest kluczowa w zaburzeniach odżywiania, ponieważ jest czynnikiem podtrzymującym dynamikę choroby [151]. Ponadto autorzy zwracają uwagę, że niska samoocena u pacjentów może sprzyjać w poszukiwaniu obszaru, w którym mogliby oni potwierdzić własną skuteczność, sprawczość oraz poczucie kontroli. Najczęściej rolę tę przejmuje kontrolowanie masy ciała, wyglądu zewnętrznego oraz sposobu przyjmowania pokarmów. Wyniki analizy regresji ujawniły ponadto, że obraz ciała w kontekście pozytywnym ($B = -2{,}13$; $OR = 0{,}119$; $p = 0{,}001$) wykazuje silną odwrotną zależność z obecnością zaburzenia. Wynik ten znajduje potwierdzenie w pracach Tylka i wsp. oraz Smolaka, wskazującymi na współwystępowanie akceptacji własnego ciała z rzadszą obecnością objawów zaburzeń odżywiania [152, 153].

Wykorzystanie modelu drzewa decyzyjnego pozwoliło na głębszą eksplorację danych. Po pierwsze uzyskano trzy, czytelne reguły decyzyjne, które zdefiniowały trzy węzły końcowe, do których zakwalifikowały się notatki osób z zdiagnozowaną anoreksją. Następnie wygenerowano wykres kafelkowy w celu pełnego zobrazowania struktury wygenerowanego modelu drzewa decyzyjnego oraz oceny realnego znaczenia poszczególnych reguł. Wśród trzech klastrów, które przedstawiały osoby chore wybrano dwa (węzły o ID 5 oraz 7), które cechowały się najwyższym prawdopodobieństwem przypisania notatek do korpusu wypowiedzi osób chorujących na anoreksję. Oprócz wiedzy o regułach decyzyjnych, którymi opisane są te klastry obliczono mediany wartości przynależności dla wszystkich 12 analizowanych obszarów tematycznych (nie tylko tych tematów, które występowały w regułach decyzyjnych). Dzięki temu powstały dwa profile tekstowe notatek osób chorych na anoreksję. Pierwszy z nich obejmował większość z badanej próby, stanowiącą 68,5% notatek osób chorujących, przy precyzji klasyfikacji równej 80,8%. Profil ten reprezentuje notatki z ogólnym brakiem akceptacji siebie i własnego ciała. Reguły zawierały informacje o wartości pozytywnej i negatywnej samooceny. Dodatkowa analiza median w obrębie wszystkich badanych wymiarów wykazała współwystępowanie w tych tekstach trzech dominujących wątków: wysokiej negatywnej samooceny, wysokiej wartości negatywnego obrazu własnego ciała i wysokiego poziomu negatywnych emocji. Profil ten jest spójny z wynikami uzyskanymi w regresji logistycznej i jest zgodny z klasycznym, powszechnie opisywanym w psychopatologii obrazem anoreksji. Wyodrębniona charakterystyka wypowiedzi jest zgodna z danymi literaturowymi przedstawionymi przykładowo w pracach Fairburna i wsp. [151], Abdoli i wsp.[54], gdzie autorzy piszą, że zaburzenia w tych trzech obszarach są ze sobą ściśle powiązane i stanowią trzon kliniczny zaburzeń odżywiania. Ponadto Ciwoniuk i wsp. [51] podkreślali związek zaburzonego obrazu ciała z nasileniem depresji

i bólu psychicznego, a Buczak i Samujło potwierdzili współwystępowanie negatywnej samooceny z negatywnym obrazem ciała [57].
Drugi z profili reprezentował mniejszy odsetek wypowiedzi pisemnych (10,9% notatek chorych na anoreksję), ale charakteryzował się wysokim prawdopodobieństwem klasyfikacji do tej grupy na poziomie równym 76,9%. Ze względu na swoją specyfikę profil ten można określić jako nietypowy lub „maskowany". Analiza median wykazała, że profil ten charakteryzuje się wysokimi wartościami pozytywnych emocji, obrazu ciała i akceptacji otoczenia. Wystąpienie takiego wzorca w wypowiedziach można interpretować dwojako. Praca Westen'a i Harnden-Fischer'a pokazała, że osoby z anoreksją nie są jedną i jednorodną grupą i można wyróżnić podtyp wysokofunkcjonujący/perfekcjonistyczny [154]. Pacjenci reprezentujący tę grupę cechują się mniejszymi zaburzeniami osobowości lepiej funkcjonują na co dzień i rzadziej wymagają hospitalizacji, co może znajdować odzwierciedlenie w bardziej stonowanym, zracjonalizowanym języku notatek. Z drugiej strony, profil ten nazwano „maskowanym"co znajduje potwierdzenie w pracy Vitousek i wsp. [155]. Autorzy podkreślają, że osoby cierpiące na anoreksję często nie traktują swoich objawów jako oznak choroby. Są dumne, zadowolone i mają poczucie kontroli kiedy stosują restrykcyjne odchudzanie i czują głód. Dlatego też takie osoby w swoich wypowiedziach mogą deklarować, że świetnie się czują i są zadowolone ze swojego ciała. Wychwycenie tego drugiego profilu stanowi szczególną zaletę zastosowania drzew decyzyjnych, które zdołały powiązać te notatki z grupą kliniczną pomimo powierzchownie optymistycznego wydźwięku badanych tematów. Podsumowując, ekstrakcja reguł decyzyjnych oraz wyodrębnienie profili narracyjnych na podstawie poruszanych tematów pokazują wielowymiarowość języka osób chorujących na anoreksję. Choć zastosowane podejście nie ma charakteru diagnostycznego wobec jednostek, analiza cech leksykalno-tematycznych może w przyszłości stanowić element systemów wspomagających analizę materiałów tekstowych lub badań przesiewowych treści internetowych pod kątem wczesnych sygnałów zaburzeń odżywiania.

W ostatnim etapie badań zastosowano algorytm lasów losowych oraz sieci neuronowych do zbudowania modeli klasyfikujących analizowane notatki pod kątem ich pochodzenia od osób z grupy chorych lub zdrowych. Porównano wartości AUC dla wszystkich wygenerowanych modeli uczenia maszynowego. W ujęciu punktowym wartość wskaźnika AUC rosła wraz ze złożonością algorytmów: od 0,745 dla regresji logistycznej, przez drzewo decyzyjne (0,773) i las losowy (0,792), do 0,848 dla sieci neuronowej. Należy jednak podkreślić, że przeprowadzony test DeLonga nie wykazał statystycznie istotnych różnic w polach pod krzywymi ROC ($p > 0,05$), co oznacza brak twardych podstaw do stwierdzenia, że bardziej złożone modele radziły sobie w tej próbie istotnie lepiej niż zwykła regresja. Uzyskane wyniki niosą ze sobą dwa kluczowe wnioski. Po pierwsze, regresja logistyczna poradziła sobie na tyle dobrze, że do odróżnienia obu grup notatek w dużej mierze wystarczą podstawowe relacje liniowe. Po drugie, zbliżona jakość drzewa decyzyjnego i lasu losowego sugeruje, że kluczowe wzorce językowe są na tyle czytelne, że agregacja wielu drzew nie przynosi wyraźnego skoku skuteczności. Choć punktowy zysk na poziomie $\Delta\text{AUC} = 0,103$ na korzyść sieci neuronowej może sugerować, że lepiej wychwytuje ona subtelne, złożone wzorce w tekście, to ze względu na brak istotności w teście DeLonga jednoznaczne potwierdzenie tej przewagi wymaga weryfikacji na większym zbiorze danych.

Niezależnie od wybranego modelu, najważniejszymi cechami, które często się pojawiały i różnicują teksty osób zdrowych i chorych okazały się tematy powiązane z samooceną oraz obrazem własnego ciała. Spójność wyników uzyskanych w regresji, drzewie decyzyjnym oraz lesie losowym potwierdza, że sposób odwoływania się do samooceny i obrazu ciała stanowi kluczowy element różnicujący analizowane teksty. Jednocześnie analiza materiału pokazała, że wypowiedzi te nie są jednorodne. Choć łączy je wspólny motyw relacji z własnym ciałem, to forma i wydźwięk poszczególnych notatek wyraźnie się od siebie różnią. W ujęciu psychologicznym może to wskazywać na odmienne mechanizmy radzenia sobie u osób zmagających się z zaburzeniami odżywiania. Podczas gdy część badanych wprost wyraża negatywne emocje i krytyczny stosunek do siebie, inni prezentują narracje oparte na deklarowanym zadowoleniu, które może pełnić funkcję obronną i maskować faktyczne trudności. Sugeruje to, że może warto uważniej przyglądać się stylowi wypowiedzi pacjentów, ponieważ pozorne poczucie spokoju może maskować rzeczywiste nasilenie choroby.

Warto również podkreślić, że opracowana w niniejszej pracy metodyka identyfikacji obszarów trudności charakteryzuje się wysokim potencjałem uogólniania i możliwością zastosowania w innych obszarach medycznych. Pomyślne zastosowanie zaproponowanego podejścia w analizie wypowiedzi osób zmagających się z nadwagą i otyłością, a także w notatkach pacjentów z nowotworami głowy i szyi, dowodzi jego uniwersalności. Grupy te łączy to, że osoby w obu przypadkach również mają trudności z akceptacją i postrzeganiem własnego ciała. Tym wynikom został poświęcony osobny podrozdział niniejszej pracy. Podsumowując, w notatkach osób z nadwagą i otyłością zaproponowana metodyka pozwoliła na uchwycenie zmian w obszarach tematycznych przed i po udziale uczestników w programie dietetycznym. Wyniki te zostały opisane w artykule, który obecnie znajduje się w recenzji. Szczególnym obszarem, w którym potwierdzono potencjał zaproponowanej metody słownikowej jest psychoonkologia pacjentów z nowotworami głowy i szyi. Choroby te wiążą się z widocznymi zmianami w wyglądzie pacjentów oraz utrudnieniem w komunikacji lub przyjmowaniem pokarmów. Wstępne badania wykazały wysoką skuteczność identyfikacji trzech tematów: dla obszaru akceptacji otoczenia zbieżność z flagami ekspertów była równa 82%, dla samooceny 80% oraz dla obrazu ciała 78% [133]. Kontynuacja tych prac pozwoliła na przeprowadzenie analizy z uwzględnieniem podziału pacjentów na trzy grupy chorych w zależności od etapu i czasu trwania żywienia dojelitowego: stadium I, II oraz grupę pacjentów paliatywnych [132].

Zaprezentowane rezultaty analizy notatek osób chorych na anoreksję oraz osób zdrowych pozwoliły na jednoznaczną weryfikację założeń badawczych. Głównym założeniem niniejszej rozprawy doktorskiej była weryfikacja następującej tezy:

> *Metody eksploracji danych tekstowych łączące polskojęzyczne słowniki dziedzinowe z procedurą ukrytej analizy semantycznej (LSA) opartej na dekompozycji według wartości osobliwych (SVD) pozwalają na automatyczne rozpoznawanie obecności i wydźwięku wybranych tematów psychologicznych w wypowiedziach osób z anoreksją i osób zdrowych.*

Uzyskane w ten sposób wyniki umożliwiają przy wykorzystaniu algorytmów uczenia maszynowego identyfikację istotnych statystycznie predyktorów, wyodrębnienie interpretowalnych reguł decyzyjnych oraz klasyfikację i odróżnienie wypowiedzi osób zmagających się z anoreksją od grupy osób zdrowych.

Weryfikacja tak sformułowanej tezy wymagała osiągnięcia określonych celów badawczych. Głównym celem niniejszej pracy była analiza pisemnych wypowiedzi osób pod kątem identyfikacji specyficznych obszarów trudności towarzyszących osobom narażonym na zaburzenia odżywiania, ze szczególnym uwzględnieniem anoreksji. Realizacja tego zadania wymagała połączenia metodyki z zakresu wydobywania wiedzy z danych tekstowych oraz zastosowania algorytmów uczenia maszynowego.

Sformułowane na etapie planowania badań cele pracy zostały w pełni zrealizowane:

1. Cel naukowo-badawczy - Opracowano i zweryfikowano efektywność metod eksploracji tekstu do automatycznego przetwarzania języka naturalnego. Przegląd literatury pozwolił wyłonić obszary o szczególnym znaczeniu psychologicznym w kontekście anoreksji. W analizie uwzględniono następujące tematy, które nazwano obszarami trudności: obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia oraz ból. Do identyfikacji konkretnych obszarów w danym kontekście (pozytywnym oraz negatywnym) zastosowano metody eksploracji tekstu, w tym metodę słownikową bazującą na autorskich słownikach oraz wykorzystano metody: Latent Semantic Analysis (LSA), która oparta jest na dekompozycji według wartości osobliwych (SVD). Uzyskane wyniki posłużyły jako dane wejściowe dla algorytmów uczenia maszynowego, przy czym:
   - Regresja logistyczna pozwoliła na wyłonienie istotnych statystycznie predyktorów różnicujących szansę współwystępowania anoreksji.
   - Drzewa decyzyjne umożliwiły poznanie reguł decyzyjnych, identyfikację kluczowych zmiennych podziału oraz wyodrębnienie specyficznych klastrów i profili notatek osób cierpiących na anoreksją.
   - Las losowy oraz sieci neuronowe (o architekturze MLP oraz RBF) posłużyły jako narzędzia klasyfikacyjne, których zadaniem było odróżnienie notatek osób chorych od osób zdrowych.
2. Cel utylitarny - Stworzono koncepcję psychologicznego narzędzia wspomagającego pracę psychologów i psychiatrów. Zaproponowane podejście opiera się na automatycznej analizie notatek pisemnych pod kątem obecności siedmiu kluczowych obszarów trudności.
3. Cel dydaktyczny - Praca przyczyniła się do upowszechnienia wiedzy o ważnych obszarach trudności/tematach przejawiających się w wypowiedziach pisemnych osób z zaburzeniami odżywiania, w tym anoreksji.

Z praktycznego punktu widzenia automatyczna identyfikacja tych tematów w wypowiedziach pisemnych może stanowić cenne narzędzie w obszarze komputerowego wspomagania diagnostyki psychologicznej. Tego typu rozwiązanie mogłoby pełnić funkcję wspierającą dla specjalistów przykładowo przy wstępnym nakreśleniu profilu trudności pacjenta czy monitorowaniu dynamiki zmian w trakcie terapii. Na tym etapie prac, przy dysponowanym zbiorze danych uzyskane rezultaty stanowią obiecującą przesłankę do kontynuowania badań na większych zbiorach danych oraz wskazują, że zaproponowana metodyka nie jest rozwiązaniem wąskodziedzinowym, lecz jest zauważalny jej potencjał dla rozwoju procesu komputerowego wspomagania diagnostyki psychologicznej w innych dziedzinach medycyny.

W świetle przeprowadzonych badań oraz zrealizowanych celów niniejszej pracy, za kluczowe elementy stanowiące oryginalny, autorski wkład badawczy można uznać:

- Sformułowanie reprezentacji klinicznie interpretowalnych cech tekstowych w postaci 12 wartości przynależności do siedmiu obszarów trudności i ich polaryzacji.
- Budowa polskojęzycznych słowników domenowych dla: obrazu ciała, emocji, samooceny, funkcjonowania ciała, autoagresji, bólu oraz akceptacji otoczenia.
- Połączenie cech słownikowo-semantycznych z klasyfikatorami klasycznymi: regresją logistyczną, drzewem decyzyjnym, lasem losowym i sieciami neuronowymi (MLP i RBF).
- Zastosowanie opracowanej metodyki w rzeczywistych notatkach medycznych.
- Weryfikacja możliwości adaptacji zaproponowanej metodyki na inne dziedziny.

Rzetelna ocena wartości naukowej niniejszej rozprawy wymaga wskazania jej ograniczeń. W kontekście przeprowadzonej analizy eksploracji tekstu warto podkreślić, że podstawowa bariera wynika z natury metod wykorzystujących koncepcję worka słów (*Bag-of-Words*) z ważeniem Log-IDF, stanowiącego punkt wyjścia dla dekompozycji SVD. Zastosowany algorytm opiera się na założeniu o wzajemnej niezależności wyrazów, co oznacza brak uwzględnienia kolejności wyrazów i zdań, a także ich wzajemnej relacji. W konsekwencji procedura obliczania wskaźnika przynależności (W_{raw}) nie uwzględnia zależności, relacji, w tym przede wszystkim negacji. Skutkuje to tym, że zaprzeczenia słów podwyższają sumaryczną wagę powiązania z danym kontekstem przeciwnym zamiast go redukować. Warto również wskazać podatność podejścia opartego na rzutowaniu słowników na przestrzeń cech LSA na wpływ ironii, sarkazmu lub metafor, co prowadzi do nadinterpretacji. Sprzyja to powstawaniu błędów dotyczących fałszywych wykryć (błąd III rodzaju). Kolejnym ograniczeniem jest jednoośrodkowy charakter badania. Notatki dotyczące anoreksji zostały pozyskane z jednego źródła. Zgromadzenie materiału badawczego z jednej placówki wiąże się z ryzykiem wystąpienia obciążenia próby, a następnie ma to wpływ na uzyskane rezultaty. Warto również podkreślić liczebność zgromadzonego materiału badawczego. Początkowo zbiór obejmował 96 wypowiedzi (44 od osób chorych oraz 52 od osób zdrowych). W toku realizacji badań korpus powiększono do 201 notatek (115 autorstwa pacjentek z anoreksją oraz 86 osób zdrowych). Choć próba ta okazała się w pełni wystarczająca do redukcji wymiarowości za pomocą dekompozycji SVD i eksploracji opartej na dedykowanych słownikach, jej rozmiar uniemożliwił wykorzystanie nowoczesnych modeli językowych

opartych na architekturze transformerów. Należy jednak podkreślić, że nie istnieją gotowe, otwarte zbiory danych notatek osób chorych na zaburzenia odżywiania lub anoreksję.

Zidentyfikowane ograniczenia wskazują kluczowe kierunki dalszych badań. Przyszłe prace powinny skupiać się na czterech głównych obszarach: zasobowym, technologicznym, aplikacyjnym oraz metodologicznym.

W obszarze zasobowym kluczowym zadaniem jest weryfikacja opracowanej metodyki na większym zbiorze danych. Cel ten można zrealizować zarówno poprzez sukcesywne powiększanie zasobów z obecnego ośrodka, jak i nawiązanie współpracy z innymi placówkami. Dodatkowo warto rozważyć wprowadzenie podłużnego (longitudinalnego) modelu gromadzenia danych, polegającego na wielokrotnym pozyskiwaniu notatek od tych samych pacjentów na przestrzeni dłuższego czasu, czy w kluczowych fazach leczenia. Pozwoliłoby to na precyzyjne śledzenie dynamiki zmian w poszczególnych obszarach trudności w czasie, umożliwiając obiektywną analizę postępów oraz wczesną detekcję sygnałów wskazujących na ryzyko nawrotu objawów. Interesującym kierunkiem badawczym byłoby w szczególności monitorowanie zmian wartości detekcji poszczególnych tematów w kolejnych notatkach tej samej osoby, co mogłoby stanowić cenną informację.

W obszarze technologicznym powiększenie zbioru danych może umożliwić zastosowanie głębokich modeli językowych opartych na architekturze transformerów np.: HerBERT. Zaawansowane modele potrafią analizować nie tylko poszczególne słowa ale również kontekst i zależności między terminami. Pozwoliłoby to na automatyczną i precyzyjną obsługę negacji, eliminując błędy I rodzaju (odwrócona polaryzacja) oraz poprawną interpretację wyrażeń wieloznacznych czy sformułowań metaforycznych, których dekompozycja SVD w LSA nie jest w stanie zarejestrować.

W obszarze aplikacyjnym obiecujące rezultaty zastosowania metody słownikowej w analizie notatek osób cierpiących na anoreksję, a także pozytywne wyniki uzyskiwane w badaniach nad innymi obszarami, takimi jak nadwaga i otyłość czy psychoonkologia (np. w grupie pacjentów z nowotworami głowy i szyi) wskazują na znaczny potencjał adaptacyjny opracowanego podejścia. Metodyka bazująca na tworzeniu słowników słów kluczowych może znaleźć zastosowanie w innych jednostkach chorobowych powiązanymi z zaburzeniami postrzegania własnego ciała, emocji, czy problemów z jedzeniem. Nie wszystkie z siedmiu analizowanych w niniejszej pracy obszarów trudności (obraz ciała, emocje, samoocena, autoagresja, funkcjonowanie ciała, akceptacja otoczenia oraz ból) znajdą bezpośrednie zastosowanie w innych dziedzinach, to architektura przyjętego podejścia pozostaje elastyczna. Przyszłe badania mogą skupić się na adaptacji narzędzia poprzez modyfikację istniejących tematów oraz tworzenie nowych, dedykowanych słowników dziedzinowych, dopasowanych do specyfiki innej wybranej gałęzi medycyny.

W obszarze metodologicznym i wdrożeniowym priorytetem pozostaje przeprowadzenie pogłębionej walidacji opracowanego rozwiązania. Obejmuje to ocenę odporności algorytmu na odmienne style językowe, analizę podatności na obciążenia próby (ang.

bias) oraz ryzyko niepożądanego przenikania informacji między zbiorami (ang. data leakage). Z punktu widzenia metodologii eksploracji danych zasadne jest wykazanie formalnej przewagi metody nad prostszymi modelami odniesienia (ang. baselines) oraz potwierdzenie poprawności ilościowej wyodrębnionych cech w kontekście klinicznym. Ostatecznie, kluczowym wyzwaniem pozostaje ocena bezpieczeństwa i skuteczności takiego podejścia w roli systemów komputerowego wspomagania diagnostyki psychologicznej zaburzeń odżywiania.

Podsumowując uzyskane wyniki z przeprowadzonych badań, które obejmowały analizę notatek osób chorych na anoreksję jak i zdrowych pozwoliły potwierdzić postawioną tezę. Pomimo wskazania pewnych ograniczeń w zakresie metodyki oraz relatywnie małego zbioru danych, osiągnięte rezultaty potwierdzają potencjał opracowanej metodyki. Potwierdzenie tezy, wysoka zbieżność identyfikacji obszarów trudności w notatkach, dosyć wysoka skuteczność klasyfikacyjna modeli oraz obiecujące wyniki w innych dziedzinach stanowią wyraźną przesłankę do dalszego rozwoju zaprezentowanej metodyki. Uzyskane wyniki tworzą fundament pod budowę zautomatyzowanych narzędzi komputerowego wspomagania diagnostyki psychologicznej, które w przyszłości mogą realnie wspomóc lekarzy i terapeutów w codziennej praktyce. Koncepcja przedstawiona w niniejszej rozprawie doktorskiej w założeniu nie ma na celu zastąpienia ekspertów, lecz stanowi obiektywne wsparcie w ich codziennej pracy.

Warto podkreślić, że wybrane zagadnienia powiązane z tematyką niniejszej rozprawy były przedstawiane oraz publikowane na forum naukowym. Pełny wykaz prac współautorskich wraz z opisem bibliograficznym zamieszczono w Dodatku A do niniejszej pracy.

Bibliografia

[1] A. Gandomi, M. Haider. „Beyond the hype: Big data concepts, methods, and analytics". *International Journal of Information Management* 35.2 (2015), s. 137–144. DOI: 10.1016/j.ijinfomgt.2014.10.007 (cytowane na stronie 5).

[2] K. Batko. „Możliwości wykorzystania Big Data w ochronie zdrowia". *Roczniki Kolegium Analiz Ekonomicznych* 42 (2016), s. 267–282 (cytowane na stronie 6).

[3] J. Arcelus, A. J. Mitchell, J. Wales, S. Nielsen. „Mortality rates in patients with anorexia nervosa and other eating disorders: A meta-analysis of 36 studies". *Archives of General Psychiatry* 68.7 (2011), s. 724–731. DOI: 10.1001/archgenpsychiatry.2011.74 (cytowane na stronach 6, 9, 19 i 133).

[4] E. Chesney, G. M. Goodwin, S. Fazel. „Risks of all-cause and suicide mortality in mental disorders: A meta-review". *World Psychiatry* 13.2 (2014), s. 153–160. DOI: 10.1002/wps.20128 (cytowane na stronie 6).

[5] L. Cierpiałowska, H. Sęk. „Psychologia zaburzeń odżywiania". *Psychologia kliniczna*. Warszawa: Wydawnictwo Naukowe PWN, 2021. Rozd. 20. ISBN: 978-83-011-8816-0 (cytowane na stronach 6, 9 i 11).

[6] J. M. S. Pearce. „Richard Morton: origins of anorexia nervosa". *European Neurology* 52.4 (2004), s. 191–192. DOI: 10.1159/000082033 (cytowane na stronie 7).

[7] J. A. Silverman. „Sir William Gull (1819-1890). Limner of anorexia nervosa and myxoedema. An historical essay and encomium". *Eating and Weight Disorders* 2 (1997), s. 111–116. DOI: 10.1007/BF03339960 (cytowane na stronie 7).

[8] A. Walenda, K. Bogusz, M. Kopera, A. Jakubczyk, M. Wojnar, K. Kucharska. „Emotion regulation in binge eating disorder". *Psychiatria Polska* 55.6 (2021), s. 1433–1448. DOI: 10.12740/PP/OnlineFirst/122212 (cytowane na stronach 8 i 9).

[9] G. Gradl-Dietsch, M. Föcker, J. Hebebrand. „Eating Disorders in the ICD-11 and DSM-5". *Handbook of Eating Disorders and Obesity*. Red. S. Herpertz, M. de Zwaan, S. Zipfel. Berlin, Heidelberg: Springer, 2024, s. 15–25. ISBN: 978-3-662-67662-2. DOI: 10.1007/978-3-662-67662-2_3 (cytowane na stronie 8).

[10] American Psychiatric Association. *Diagnostic and Statistical Manual of Mental Disorders (DSM-5)*. 5th. Washington, DC: American Psychiatric Association, 2013 (cytowane na stronie 8).

[11] World Health Organization. *International Classification of Diseases (ICD-11)*. 11th. World Health Organization, 2022 (cytowane na stronie 8).

[12] M. Chęć, S. Michałowska. „Terapia poznawczo-behawioralna zaburzeń odżywiania w adolescencji z uwzględnieniem roli perfekcjonizmu". *Psychiatria Polska* 58.5 (2024), s. 773–788. DOI: 10.12740/PP/175717 (cytowane na stronie 8).

[13] K. Jowik, A. Dutkiewicz, A. Słopień, M. Tyszkiewicz-Nwafor. „Wieloaspektowa analiza rozpowszechnienia, czynników etiologicznych, obrazu klinicznego i postępowania terapeutycznego zaburzeń z napadami objadania (Binge Eating Disorder, BED)". *Psychiatria Polska* 54.2 (2020), s. 223–238. DOI: 10.12740/PP/105502 (cytowane na stronie 8).

[14] A. Brytek-Matera, S. Touyz, P. Hay. „Comparative utility of the DSM-5 and ICD-11 diagnostic classifications of eating disorders of recurrent binge eating in an Australian community-based sample". *European Eating Disorders Review* 32.3 (2024), s. 524–531. DOI: 10.1002/erv.3068 (cytowane na stronie 8).

[15] J. Morris, S. Anderson. „An update on eating disorders". *BJPsych Advances* 27.1 (2021), s. 9–19. DOI: 10.1192/bja.2020.24 (cytowane na stronach 8, 9 i 10).

[16] B. T. Walsh, H. W. Hoek. „Overview of the Classification and Epidemiology of Eating Disorders". *The Handbook of the Neurobiology of Eating Disorders*. 2025. DOI: 10.1093/9780197675212.003.0002 (cytowane na stronie 8).

[17] J. Treasure, T. A. Duarte, U. Schmidt. „Eating disorders". *The Lancet* 395.10227 (2020), s. 899–911. DOI: 10.1016/S0140-6736(20)30059-3 (cytowane na stronie 8).

[18] M. Solmi, J. Radua, B. Stubbs, V. Ricca, D. Moretti, D. Busatta, A. F. Carvalho, E. Dragioti, A. Favaro, A. M. Monteleone, J. I. Shin, P. Fusar-Poli, G. Castellini. „Risk factors for eating disorders: an umbrella review of published meta-analyses". *Brazilian Journal of Psychiatry* 43.3 (2021). DOI: https://doi.org/10.1590/1516-4446-2020-1099 (cytowane na stronie 8).

[19] M. Galmiche, P. Déchelotte, G. Lambert, M. P. Tavolacci. „Prevalence of eating disorders over the 2000-2018 period: a systematic literature review". *The American Journal of Clinical Nutrition* 109.5 (2019), s. 1402–1413. ISSN: 0002-9165. DOI: 10.1093/ajcn/nqy342 (cytowane na stronie 9).

[20] D. E. Nicholls, R. Lynn, R. M. Viner. „Childhood eating disorders: British national surveillance study". *British Journal of Psychiatry* 198.4 (2011), s. 295–301. DOI: 10.1192/bjp.bp.110.081356 (cytowane na stronie 9).

[21] M. Górski, B. Całyniuk, J. Garbicz, M. Buczkowska, K. Siudmak, K. Górska, R. Polaniak. „Specific eating disorders - selected aspects of pathogenesis and risk factors". *Psychiatria i Psychologia Kliniczna* 22.1 (2022), s. 45–54. DOI: 10.15557/PiPK.2022.0006 (cytowane na stronie 9).

[22] Deloitte Access Economics. *The Social and Economic Cost of Eating Disorders in the United States of America: Report for the Strategic Training Initiative for the Prevention of Eating Disorders and the Academy for Eating Disorders*. Spraw. tech. Deloitte Access Economics, 2020 (cytowane na stronie 9).

[23] J. F. López-Gil, A. García-Hermoso, L. Smith i in. „Global Proportion of Disordered Eating in Children and Adolescents: A Systematic Review and Meta-analysis". *JAMA Pediatrics* 177.4 (2023), s. 363–372. DOI: 10.1001/jamapediatrics.2022.5848 (cytowane na stronie 9).

[24] H. W. Hoek. „Incidence, prevalence and mortality of anorexia nervosa and other eating disorders". *Current Opinion in Psychiatry* 19.4 (2006), s. 389–394. DOI: 10.1097/01.yco.0000228759.95237.78 (cytowane na stronie 9).

[25] E. I. Capuano, A. Ruocco, B. Scazzocchio, G. Zanchi, C. Lombardo, A. Silenzi, E. Ortona, R. Varì. „Gender differences in eating disorders". *Frontiers in Nutrition* 12 (2025). ISSN: 2296-861X. DOI: 10.3389/fnut.2025.1583672 (cytowane na stronie 9).

[26] P. Hay, P. Aouad, A. Le, P. Marks, D. Maloney, National Eating Disorder Research Consortium, S. Touyz, S. Maguire. „Epidemiology of eating disorders: population, prevalence, disease burden and quality of life informing public policy in Australia-a rapid review". *Journal of Eating Disorders* 11, 23 (2023). DOI: 10.1186/s40337-023-00738-7 (cytowane na stronie 9).

[27] A. Brytek-Matera. „Prevalence of anorexia nervosa and bulimia nervosa in Eastern Europe". *Psychiatria i Psychologia Kliniczna* 23.4 (2023), s. 332–337. DOI: 10.15557/PiPK.2023.0041 (cytowane na stronie 9).

[28] L. Hog, L. Dinkler. „Recent insights into the epidemiology of avoidant/restrictive food intake disorder (ARFID)". *Current Opinion in Psychiatry* 38.6 (2025), s. 402–409. DOI: 10.1097/YCO.0000000000001041 (cytowane na stronie 9).

[29] C. A. Fisher, S. Skocic, K. A. Rutherford, S. E. Hetrick. „Family therapy approaches for anorexia nervosa". *Cochrane Database of Systematic Reviews* 10 (2018). ISSN: 1465-1858. DOI: 10.1002/14651858.CD004780.pub3 (cytowane na stronie 9).

[30] H. Himmerich, J. Treasure. „Anorexia nervosa: diagnostic, therapeutic, and risk biomarkers in clinical practice". *Trends in Molecular Medicine* 30.4 (2024), s. 350–360. DOI: 10.1016/j.molmed.2024.01.002 (cytowane na stronach 9 i 10).

[31] C. Żechowski. *Zaburzenia odżywiania się - problem współczesnej młodzieży.* Warszawa: Ośrodek Rozwoju Edukacji, 2013 (cytowane na stronach 9 i 10).

[32] W. Chytra-Gędek, A. Kobierecka. „Gotowość anorektyczna u dziewcząt i młodych kobiet". *Psychiatria* 5.1 (2008), s. 7–12. ISSN: 1732-9841 (cytowane na stronie 9).

[33] A. Wojtyła, P. Biliński, I. Bojar, C. Wojtyła. „Zaburzenia odżywiania u polskich gimnazjalistów". *Problemy Higieny i Epidemiologii* 92.2 (2011), s. 343–350 (cytowane na stronie 9).

[34] A. Rzepko, P. Osińska, M. Makowska. „Am I thin enough? An introduction to anorexia nervosa. Face of this eating disorder in Poland". *Health Problems of Civilization* 10.3 (2016), s. 7–14. DOI: 10.5114/hpc.2016.61359 (cytowane na stronie 9).

[35] D. M. Sikora. „Pacjenci z zaburzeniami odżywiania w dobie COVID-19". *Psychoterapia* 197.2 (2021), s. 29–38. ISSN: 0239-4170. DOI: 10.12740/PT/140058 (cytowane na stronie 10).

[36] B. Melisse, E. de Beurs, E. F. van Furth. „Eating disorders in the Arab world: a literature review". *Journal of Eating Disorders* 8.1 (2020), s. 59. DOI: 10.1186/s40337-020-00336-x (cytowane na stronie 10).

[37] J. Wu, J. Liu, S. Li, H. Ma, Y. Wang. „Trends in the prevalence and disability-adjusted life years of eating disorders from 1990 to 2017: results from the Global Burden of Disease Study 2017". *Epidemiology and Psychiatric Sciences* 29 (2020), e191. DOI: 10.1017/S2045796020001055 (cytowane na stronie 10).

[38] S. Zipfel, K. E. Giel, C. M. Bulik, P. Hay, U. Schmidt. „Anorexia nervosa: aetiology, assessment, and treatment". *The Lancet Psychiatry* 2.12 (2015), s. 1099–1111. DOI: 10.1016/S2215-0366(15)00356-9 (cytowane na stronach 10 i 11).

[39] S. Zipfel, B. Wild, G. Groß, H. C. Friederich, M. Teufel, D. Schellberg, K. E. Giel, M. de Zwaan, A. Dinkel, S. Herpertz, M. Burgmer, B. Löwe, S. Tagay, J. von Wietersheim, A. Zeeck, C. Schade-Brittinger, H. Schauenburg, W. Herzog, ANTOP Study Group. „Focal psychodynamic therapy, cognitive behaviour therapy, and optimised treatment as usual in outpatients with anorexia nervosa (ANTOP study): randomised controlled trial". *The Lancet* 383.9912 (2014), s. 127–137. DOI: 10.1016/S0140-6736(13)61746-8 (cytowane na stronach 10 i 11).

[40] H. P. Luhn. „The Automatic Creation of Literature Abstracts". *IBM Journal of Research and Development* 2.2 (1958), s. 159–165. DOI: 10.1147/rd.22.0159 (cytowane na stronie 11).

[41] P. Lula. *Text mining jako narzędzie pozyskiwania informacji z dokumentów tekstowych*. Czytelnia Data Mining StatSoft. 2005 (cytowane na stronach 11, 22, 26 i 27).

[42] M. A. Hearst. „Untangling Text Data Mining". *Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics on Computational Linguistics*. ACL '99. College Park, Maryland, 1999, s. 3–10. ISBN: 1558606093. DOI: 10.3115/1034678.1034679 (cytowane na stronie 11).

[43] Y. Cai, J.-T. Sun. „Text Mining". *Encyclopedia of Database Systems*. Red. L. Liu, M. T. Özsu. Boston, MA: Springer US, 2009, s. 3061–3065. ISBN: 978-0-387-39940-9. DOI: 10.1007/978-0-387-39940-9_418 (cytowane na stronie 11).

[44] E. Cambria, B. White. „Jumping NLP Curves: A Review of Natural Language Processing Research [Review Article]". *IEEE Computational Intelligence Magazine* 9.2 (2014), s. 48–57. DOI: 10.1109/MCI.2014.2307227 (cytowane na stronie 12).

[45] C. C. Aggarwal, C. Zhai, red. *Mining Text Data*. New York: Springer, 2012. ISBN: 978-1-4614-3222-7. DOI: 10.1007/978-1-4614-3223-4 (cytowane na stronach 12, 22, 25 i 28).

[46] A. M. Cohen, W. R. Hersh. „A survey of current work in biomedical text mining". *Briefings in Bioinformatics* 6.1 (2005), s. 57–71. DOI: 10.1093/bib/6.1.57 (cytowane na stronie 12).

[47] S. C. Gupta, N. Goyal. „Text Mining: Techniques, Applications and Issues". *International Journal of Innovative Research in Computer Science & Technology* 12.1 (2024). DOI: 10.55524/CSISTW.2024.12.1.49 (cytowane na stronie 12).

[48] N. Zanini, V. Dhawan. „Text Mining: An introduction to theory and some applications". *Research Matters* (sty. 2015), s. 38–44 (cytowane na stronie 12).

[49] A. Oldershaw, H. Startup, T. Lavender. „Anorexia nervosa and a lost emotional self: A psychological formulation of the development, maintenance, and treatment of anorexia nervosa". *Frontiers in Psychology* 10 (2019), s. 219. ISSN: 1664-1078. DOI: 10.3389/fpsyg.2019.00219 (cytowane na stronach 17, 20 i 133).

[50] S. Torres, A. I. Vieira, F. M. Vieira, K. M. Miller, M. P. Guerra, L. Lencastre, A. C. Reis, S. Timóteo, P. Nunes, M. R. Barbosa. „A Comprehensive Study of Positive Body Image as a Predictor of Psychological Well-Being in Anorexia Nervosa". *Nutrients* 16.11 (2024), s. 1787. DOI: 10.3390/nu16111787 (cytowane na stronach 17 i 133).

[51] N. Ciwoniuk, M. Wayda-Zalewska, K. Kucharska. „Distorted Body Image and Mental Pain in Anorexia Nervosa". *International Journal of Environmental Research and Public Health* 20.1 (2023), s. 718. DOI: 10.3390/ijerph20010718 (cytowane na stronach 17, 18, 19, 20, 133 i 135).

[52] F. Junne, S. Zipfel, B. Wild, P. Martus, K. Giel, G. Resmark, H.-C. Friederich, M. Teufel, M. de Zwaan, A. Dinkel, S. Herpertz, M. Burgmer, S. Tagay, E. Rothermund, A. Zeeck, K. Ziser, W. Herzog, B. Löwe. „The relationship of body image with symptoms of depression and anxiety in patients with anorexia nervosa during outpatient psychotherapy: Results of the ANTOP study". *Psychotherapy* 53.2 (2016), s. 141–151. DOI: 10.1037/pst0000064 (cytowane na stronach 17 i 133).

[53] K. A. Glashouwer, R. M. L. van der Veer, F. Adipatria, P. J. de Jong, S. Vocks. „The role of body image disturbance in the onset, maintenance, and relapse of anorexia nervosa: A systematic review". *Clinical Psychology Review* 74 (2019), s. 101771. DOI: 10.1016/j.cpr.2019.101771 (cytowane na stronach 17 i 133).

[54] M. Abdoli, E. Schiechtl, M. Scotto Rosato, B. Mangweth-Matzek, P. Cotrufo, K. Hüfner. „Body image, self-esteem, emotion regulation, and eating disorders in adults: a systematic review". *Neuropsychiatrie* 39.3 (2025), s. 118–132. DOI: 10.1007/s40211-025-00544-4 (cytowane na stronach 18, 19, 133 i 135).

[55] H. Biney, S. Astbury, A. Haines, J. Grant, N. Malone, M. Hutt, R. Matthews, J. F. Morgan, S. White, J. H. Lacey. „A novel 'practical body image' therapy for adolescent inpatients with anorexia nervosa: A randomised controlled trial". *Eating and Weight Disorders - Studies on Anorexia, Bulimia and Obesity* 26 (2021), s. 1825–1834. DOI: 10.1007/s40519-020-00997-2 (cytowane na stronach 18 i 133).

[56] A. Mioduchowska-Zienkiewicz. „Zachowania autoagresywne a obraz własnego ciała u kobiet z zaburzeniami odżywiania się". *Studia Psychologica UKSW* 15.1 (2015), s. 45–62 (cytowane na stronach 18, 19 i 133).

[57] A. Buczak, M. Samujło. „Samoocena globalna i postrzeganie własnego ciała a zachowania żywieniowe studentów". *Lubelski Rocznik Pedagogiczny* 32 (2013) (cytowane na stronach 18 i 136).

[58] B. Izydorczyk, A. Rybicka-Klimczyk. „Poznawcze aspekty obrazu ciała u kobiet a zaburzenia odżywiania". *Endokrynologia Polska* 60.4 (2009), s. 287–294 (cytowane na stronie 19).

[59] A. John, A. Marchant, J. Demmler, J. Tan, M. DelPozo-Banos. „Clinical management and mortality risk in those with eating disorders and self-harm: E-cohort study using the SAIL databank". *BJPsych Open* 7.2 (2021), e67. DOI: 10.1192/bjo.2021.23 (cytowane na stronach 19 i 133).

[60] K. Nitsch, E. Prajs, J. Kurpisz, E. Tyburski. „Obraz ciała i jego zaburzenia. Aspekty teoretyczne w kontekście wybranych jednostek psychopatologicznych". *Psychiatria i Psychologia Kliniczna* 12.3 (2012), s. 176–182 (cytowane na stronie 19).

[61] G. Jagielska, I. Kacperska. „Outcome, comorbidity, and prognosis in anorexia nervosa". *Psychiatria Polska* 51.2 (2017), s. 205–218. DOI: 10.12740/PP/64580 (cytowane na stronach 19 i 133).

[62] A. Lavis, S. McNeil, H. Bould, A. Winston, K. Reid, C. L. Easter, R. Pendrous, M. Michail. „Self-Harm in Eating Disorders (SHINE): A mixed-methods exploratory study". *BMJ Open* 12.7 (2022). ISSN: 2044-6055. DOI: 10.1136/bmjopen-2022-065065 (cytowane na stronach 19 i 133).

[63] D. Krzemionka-Brózda. „Sekret ciała. Doświadczanie przez młode kobiety własnego ciała jako piętna jawnego (nadwaga) bądź ukrytego (zaburzenia odżywiania) a określenie własnej tożsamości". *Ciało w dobie współczesności. Wybrane zagadnienia z problematyki własnego ciała*. Red. A. Brytek-Matera. Warszawa: Difin, 2010, s. 131–148. ISBN: 978-83-7587-248-4 (cytowane na stronach 20 i 133).

[64] M. Mirończuk. „Przegląd metod i technik eksploracji danych tekstowych". *Studia i Materiały Informatyki Stosowanej* 4.6 (2012), s. 100–117 (cytowane na stronach 21, 22, 24 i 26).

[65] K. Kuligowska, M. Lasek. „Eksploracja danych tekstowych (text mining) w przedsiębiorstwie". *Polskie Stowarzyszenie Zarządzania Wiedzą. Seria: Studia i Materiały* 13 (2008), s. 1–10 (cytowane na stronie 21).

[66] C. D. Manning, P. Raghavan, H. Schütze. *Introduction to Information Retrieval*. Cambridge: Cambridge University Press, 2008. DOI: 10.1017/CBO9780511809071 (cytowane na stronach 21, 22 i 24).

[67] Y. HaCohen-Kerner, D. Miller, Y. Yigal. „The influence of preprocessing on text classification using a bag-of-words representation". *PLOS ONE* 15.5 (2020), s. 1–22. DOI: 10.1371/journal.pone.0232525 (cytowane na stronie 22).

[68] K. Toutanova, D. Klein, C. D. Manning, Y. Singer. „Feature-Rich Part-of-Speech Tagging with a Cyclic Dependency Network". *Proceedings of the 2003 Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (NAACL)*. NAACL '03. Edmonton, Canada: Association for Computational Linguistics, 2003, s. 173–180. DOI: 10.3115/1073445.1073478 (cytowane na stronie 22).

[69] Y. Sun, J. Han, X. Yan, P. S. Yu, T. Wu. „PathSim: Meta Path-Based Top-K Similarity Search in Heterogeneous Information Networks". *Proceedings of the VLDB Endowment* 4.11 (2011), s. 992–1003. DOI: 10.14778/3402707.3402736 (cytowane na stronie 24).

[70] S. Deerwester, S. T. Dumais, G. W. Furnas, T. K. Landauer, R. Harshman. „Indexing by latent semantic analysis". *Journal of the American Society for Information Science* 41.6 (1990), s. 391–407. DOI: https://doi.org/10.1002/(SICI)1097-4571(199009)41:6<391::AID-ASI1>3.0.CO;2-9 (cytowane na stronach 25, 26, 28, 50, 51 i 52).

[71] D. Jurafsky, J. H. Martin. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*. 3rd draft. Stanford University, 2023 (cytowane na stronie 25).

[72] F. Doshi-Velez, B. Kim. „Towards A Rigorous Science of Interpretable Machine Learning". *arXiv: Machine Learning* (2017). DOI: https://doi.org/10.48550/arXiv.1702.08608 (cytowane na stronach 25 i 28).

[73] H. V. Cook, L. J. Jensen. „A Guide to Dictionary-Based Text Mining". *Bioinformatics and Drug Discovery*. Red. R. Larson, T. I. Oprea. T. 1939. Methods in Molecular Biology. New York, NY: Humana Press, 2019, s. 73–89. ISBN: 978-1-4939-9089-4. DOI: 10.1007/978-1-4939-9089-4_5 (cytowane na stronie 26).

[74] K. Nastou, M. Koutrouli, S. Pyysalo, L. J. Jensen. „Improving dictionary-based named entity recognition with deep learning". *Bioinformatics* 40.Supplement$_2$ (2024), s. ii45–ii52. DOI: https://doi.org/10.1093/bioinformatics/btae402 (cytowane na stronie 26).

[75] T. Anwar, M. Fuller-Tyszkiewicz, H. K. Jarman, M. Abuhassan, A. Shatte, W. Team, S. Sukunesan. „EDBase: Generating a Lexicon Base for Eating Disorders Via Social Media". *IEEE Journal of Biomedical and Health Informatics* 26.12 (2022), s. 6116–6125. DOI: 10.1109/JBHI.2022.3211151 (cytowane na stronie 26).

[76] D. Spinczyk, M. Dzieciątko. *Text Mining: metody, narzędzia i zastosowania*. Warszawa: Wydawnictwo Naukowe PWN, 2016. ISBN: 978-83-011-8686-9 (cytowane na stronie 27).

[77] N. E. Evangelopoulos. „Latent semantic analysis". *WIREs Cognitive Science* 4 (2013), s. 683–692. DOI: 10.1002/wcs.1254 (cytowane na stronie 27).

[78] M. W. Berry, S. T. Dumais, G. W. O'Brien. „Using linear algebra for intelligent information retrieval". *SIAM Review* 37.4 (1995), s. 573–595. DOI: 10.1137/1037127 (cytowane na stronach 28 i 51).

[79] W.-Y. Loh. „Classification and regression trees". *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 1 (2011), s. 14–23. DOI: 10.1002/widm.8 (cytowane na stronie 28).

[80] M. Lasek, M. Pęczkowski. *Enterprise Miner. Wykorzystanie narzędzi Data Mining w systemach SAS*. Warszawa: Wydawnictwa Uniwersytetu Warszawskiego, 2013. ISBN: 978-83-235-2770-1 (cytowane na stronie 29).

[81] S. R. Safavian, D. Landgrebe. „A survey of decision tree classifier methodology". *IEEE Transactions on Systems, Man, and Cybernetics* 21.3 (1991), s. 660–674. DOI: 10.1109/21.97458 (cytowane na stronie 29).

[82] H. Blockeel, L. Devos, B. Frénay, G. Nanfack, S. Nijssen. „Decision trees: From efficient prediction to responsible AI". *Frontiers in Artificial Intelligence* 6 (2023). ISSN: 2624-8212. DOI: 10.3389/frai.2023.1124553 (cytowane na stronie 29).

[83] A. J. Owczarek. „Drzewa klasyfikacyjne w medycynie". *Annales Academiae Medicae Silesiensis* 68.6 (2014), s. 449–456 (cytowane na stronie 29).

[84] L. Breiman. „Random Forests". *Machine Learning* 45 (2001), s. 5–32. DOI: 10.1023/A:1010933404324 (cytowane na stronie 30).

[85] B. Talekar, S. Agrawal. „A Detailed Review on Decision Tree and Random Forest". *Bioscience Biotechnology Research Communications* 13.14 (2020), s. 245–248. DOI: 10.21786/bbrc/13.14/57 (cytowane na stronie 30).

[86] S. Haykin. *Neural Networks and Learning Machines*. 3rd. Upper Saddle River, NJ: Pearson Education, 2009. ISBN: 978-0-13-147139-9 (cytowane na stronach 30 i 31).

[87] I. Goodfellow, Y. Bengio, A. Courville. *Deep Learning*. Cambridge, MA: MIT Press, 2016. ISBN: 978-0-262-03561-3 (cytowane na stronach 30 i 31).

[88] X. Zhang, J. Zhao, Y. LeCun. „Character-level Convolutional Networks for Text Classification". 2016. eprint: 1509.01626 (cytowane na stronie 31).

[89] T. Young, D. Hazarika, S. Poria, E. Cambria. „Recent Trends in Deep Learning Based Natural Language Processing [Review Article]". *IEEE Computational Intelligence Magazine* 13.3 (2018), s. 55–75. DOI: 10.1109/MCI.2018.2840738 (cytowane na stronie 31).

[90] T. Hastie, R. Tibshirani, J. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. Springer Series in Statistics. New York, NY: Springer, 2009. ISBN: 978-0-387-84857-0. DOI: 10.1007/978-0-387-84858-7 (cytowane na stronie 32).

[91] G. James, D. Witten, T. Hastie, R. Tibshirani. *An Introduction to Statistical Learning: with Applications in R*. 2nd. Springer Texts in Statistics. New York, NY: Springer, 2021. ISBN: 978-1-0716-1417-4. DOI: 10.1007/978-1-0716-1418-1 (cytowane na stronie 32).

[92] D. M. Blei, A. Y. Ng, M. I. Jordan. „Latent Dirichlet Allocation". *Journal of Machine Learning Research* 3 (2003), s. 993–1022 (cytowane na stronie 32).

[93] R. Alghamdi, K. Alfalqi. „A Survey of Topic Modeling in Text Mining". *International Journal of Advanced Computer Science and Applications* 6.1 (2015). DOI: 10.14569/IJACSA.2015.060121 (cytowane na stronie 32).

[94] J. C. Carter, K. B. Mercer-Lynn, S. J. Norwood, C. V. Bewell-Weiss, R. D. Crosby, D. B. Woodside, M. P. Olmsted. „A prospective study of predictors of relapse in anorexia nervosa: implications for relapse prevention". *Psychiatry Research* 200.2 (2012), s. 518–523. ISSN: 0165-1781. DOI: 10.1016/j.psychres.2012.04.037 (cytowane na stronie 32).

[95] J. F. Morgan, F. Reid, J. H. Lacey. „The SCOFF questionnaire: assessment of a new screening tool for eating disorders". *BMJ* 319.7223 (1999), s. 1467–1468. DOI: 10.1136/bmj.319.7223.1467 (cytowane na stronie 33).

[96] C. Jacobi, C. Hayward, M. de Zwaan, H. C. Kraemer, W. S. Agras. „Coming to terms with risk factors for eating disorders: application of risk terminology and suggestions for a general taxonomy". *Psychological Bulletin* 130.1 (2004), s. 19–65. DOI: 10.1037/0033-2909.130.1.19 (cytowane na stronie 33).

[97] K. A. A. Fox, O. H. Dabbous, R. J. Goldberg, K. S. Pieper, K. A. Eagle, F. Van de Werf, A. Avezum, S. G. Goodman, M. D. Flather, F. A. Anderson Jr., C. B. Granger. „Prediction of risk of death and myocardial infarction in the six months after presentation with acute coronary syndrome: prospective multinational observational study (GRACE)". *BMJ* 333.7578 (2006), s. 1091. DOI: 10.1136/bmj.38985.646481.55 (cytowane na stronie 33).

[98] V. Lyssenko, A. Jonsson, P. Almgren, N. Pulizzi, B. Isomaa, T. Tuomi, G. Berglund, D. Altshuler, P. Nilsson, L. Groop. „Clinical risk factors, DNA variants, and the development of type 2 diabetes". *The New England Journal of Medicine* 359.21 (2008), s. 2220–2232. DOI: 10.1056/NEJMoa0801869 (cytowane na stronie 33).

[99] A. Chayakova, O. Tsigengagel, G. Zhussupova. „Beyond Clinical Acuity: Cardiac Comorbidity and Complication Profiles and the Prehospital Hospitalization/Transport Decision in Ischemic Heart Disease-A Five-Year Retrospective Emergency Medical Service Study in Astana, Kazakhstan". *Healthcare* 14.15 (2026). ISSN: 2227-9032. DOI: 10.3390/healthcare14152308 (cytowane na stronie 33).

[100] J. Y. Kim, A. Dirks, R. M. Ford, L. Pai, C. Ludwig, U. Tapan. „How exclusion criteria can hinder eligibility for lung cancer studies among different racial and ethnic groups". *PLOS Digital Health* 5.3 (2026), s. 1–11. DOI: 10.1371/journal.pdig.0001262 (cytowane na stronie 33).

[101] X. Ma, Q. Xu, L. Kuai, F. Shen, Z. Duan, X. Gao, R. Zhang, R. Wang. „Beyond Skin Clearance: Personalized Strategies for DLQI Improvement in Psoriasis - Insights From a Shanghai Prospective Cohort". *Psoriasis: Targets and Therapy* 15 (2025), s. 373–387. DOI: 10.2147/PTT.S534881 (cytowane na stronie 34).

[102] G. Brizzi, C. Pupillo, E. Sajno, M. Botto, F. Brusa, F. Scarpina, L. Mendolicchio, G. Riva. „Predicting anorexia nervosa treatment efficacy: An explainable machine learning approach". *Journal of Eating Disorders* 13 (2025). DOI: 10.1186/s40337-025-01265-3 (cytowane na stronie 34).

[103] B. C. Izydorczyk, B. W. Wojciechowski. „Differential diagnosis of eating disorders with the use of classification trees (decision algorithm)". *Archives of Psychiatry and Psychotherapy* 18.4 (2016), s. 53–62. DOI: 10.12740/APP/66519 (cytowane na stronie 34).

[104] N. Vijayalakshmi, C. Vidhya. „Using decision tree induction to predict the type of eating disorder". *International Journal of Computer Science and Mobile Computing* 4.7 (2015), s. 537–543 (cytowane na stronie 34).

[105] J. Xie. „Prediction of anorexia risk based on decision tree". *Highlights in Science, Engineering and Technology* 85 (2024), s. 20–25 (cytowane na stronie 34).

[106] J. A. Benítez-Andrades, J.-M. Alija-Pérez, M.-E. Vidal, R. Pastor-Vargas, M. T. García-Ordás. „Traditional machine learning models and Bidirectional Encoder Representations from Transformer (BERT)-based automatic classification of tweets about eating disorders: Algorithm development and validation study". *JMIR Medical Informatics* 10.2 (2022), e34492. DOI: 10.2196/34492 (cytowane na stronie 34).

[107] A. Zeeshan, A. Mir, M. P. S. Hattamurrahman. „Obesity prediction using machine learning algorithms". *Engineering Proceedings* 107.1, 125 (2025). ISSN: 2673-4591. DOI: 10.3390/engproc2025107125 (cytowane na stronie 35).

[108] H. Abou-Warda, N. A. Belal, Y. El-Sonbaty, S. Darwish. „A Random Forest Model for Mental Disorders Diagnostic Systems". *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics 2016*. T. 533. Advances in Intelligent Systems and Computing. Springer International Publishing, 2017, s. 670–680. ISBN: 978-3-319-48308-5. DOI: 10.1007/978-3-319-48308-5_64 (cytowane na stronie 35).

[109] S. Mathur, A. Rai, D. Mathur. „Predictive data mining for disease diagnosis: Decision tree approach". *International Journal of Engineering Research & Technology* 14.5 (2025). DOI: 10.5281/zenodo.18106559 (cytowane na stronie 35).

[110] D. Liu, X. Zhang, T. Zheng i in. „Optimisation and evaluation of the random forest model in the efficacy prediction of chemoradiotherapy for advanced cervical cancer based on radiomics signature from high-resolution T2 weighted images". *Archives of Gynecology and Obstetrics* 303 (2021), s. 811–820. DOI: 10.1007/s00404-020-05908-5 (cytowane na stronie 35).

[111] S. Ghosh, P. Burger, M. Simeunovic-Ostojic, J. Maas, M. Petković. „Review of machine learning solutions for eating disorders". *International Journal of Medical Informatics* 189 (2024), s. 105526. ISSN: 1386-5056. DOI: https://doi.org/10.1016/j.ijmedinf.2024.105526 (cytowane na stronach 35 i 36).

[112] M. Buscema, M. M. di Pietralata, V. Salvemini, M. Intraligi, M. Indrimi. „Application of Artificial Neural Networks to Eating Disorders". *Substance Use & Misuse* 33.3 (1998), s. 765–791. DOI: 10.3109/10826089809115895 (cytowane na stronie 35).

[113] F. Bernardoni, D. Arold, L. Schoppik, K. Bahnsen, R. Ge, C. Moreau i in. „Brain morphology in Anorexia Nervosa and its subtypes: A multi-cohort study of individual participant data". *PLoS Medicine* 23.5 (2026), s. 1–21. DOI: 10.1371/journal.pmed.1004809 (cytowane na stronie 36).

[114] D. Spinczyk, M. Bas, M. Dzieciątko i in. „Computer-aided therapeutic diagnosis for anorexia". *BioMedical Engineering OnLine* 19, 53 (2020). DOI: 10.1186/s12938-020-00798-9 (cytowane na stronie 36).

[115] C. A. Levinson, C. M. Trombley, L. C. Brosof, B. M. Williams, R. A. Hunt. „Binge Eating, Purging, and Restriction Symptoms: Increasing Accuracy of Prediction Using Machine Learning". *Behavior Therapy* 54.2 (2023), s. 247–259. ISSN: 0005-7894. DOI: https://doi.org/10.1016/j.beth.2022.08.006 (cytowane na stronie 36).

[116] J. Feldman. „Classifying pro-eating disorder images on Twitter using deep learning". *Intersect: The Stanford Journal of Science, Technology, and Society* 16.2 (2023), s. 1–15 (cytowane na stronie 36).

[117] S. Abdullahi, S. Sathasivam. „TPOT-MLP-SVM: Hybrid Model of Multilayer Perceptron with Support Vector Machines Based on Genetic Programming for Predictive Analysis". *Applied Mathematics and Computational Intelligence* 14.3 (2025), s. 13–28. DOI: https://doi.org/10.58915/amci.v14i3.1507 (cytowane na stronie 36).

[118] Y. Zhong, Y. Piao, B. Tan, J. Liu. „A multi-task fusion model based on a residual–Multi-layer perceptron network for mammographic breast cancer screening". *Computer Methods and Programs in Biomedicine* 247 (2024), s. 108101. ISSN: 0169-2607. DOI: https://doi.org/10.1016/j.cmpb.2024.108101 (cytowane na stronie 36).

[119] Q. K. Al-Shayea. „Artificial Neural Networks in Medical Diagnosis". *International Journal of Computer Science Issues (IJCSI)* 8.2 (2011). ISSN: 1694-0814 (cytowane na stronie 36).

[120] M. Abdullah. „Artificial intelligence-based framework for early detection of heart disease using enhanced multilayer perceptron". *Frontiers in Artificial Intelligence* 7 (2025). ISSN: 2624-8212. DOI: 10.3389/frai.2024.1539588 (cytowane na stronie 36).

[121] S. A. Kumar, S. Sasikala. „Enhanced Alzheimer's disease classification using multilayer deep convolutional neural network-based experimentations". *Iranian Journal of Science and Technology, Transactions of Electrical Engineering* 47 (2023), s. 1595–1621. DOI: 10.1007/s40998-023-00622-9 (cytowane na stronie 36).

[122] H. Zou, W. Yang, M. Wang, Q. Zhu, H. Liang, H. Wu, L. Tang. „Predicting length of stay ranges by using novel deep neural networks". *Heliyon* 9.2 (2023). DOI: 10.1016/j.heliyon.2023.e13573 (cytowane na stronie 36).

[123] G. Merhbene, A. Puttick, M. Kurpicz-Briki. „Investigating machine learning and natural language processing techniques applied for detecting eating disorders: A systematic literature review". *Frontiers in Psychiatry* 15 (2024). ISSN: 1664-0640. DOI: 10.3389/fpsyt.2024.1319522 (cytowane na stronie 37).

[124] M. Chopra, A. Chatterjee, L. Dey, P. P. Das. „Deciphering psycho social effects of eating disorder: Analysis of Reddit posts using large language models (LLMs) and topic modeling". *Proceedings of the 4th International Conference on Natural Language Processing for Digital Humanities*. Association for Computational Linguistics, 2024, s. 156–164. DOI: 10.18653/v1/2024.nlp4dh-1.15 (cytowane na stronie 37).

[125] C. Cliffe, A. Seyedsalehi, K. Vardavoulia, A. Bittar, S. Velupillai, H. Shetty, U. Schmidt, R. Dutta. „Using natural language processing to extract self-harm and suicidality data from a clinical sample of patients with eating disorders: a retrospective cohort study". *BMJ Open* 11.12 (2021). ISSN: 2044-6055. DOI: 10.1136/bmjopen-2021-053808 (cytowane na stronie 37).

[126] D. Ramírez-Cifuentes, M. Mayans, A. Freire. „Early Risk Detection of Anorexia on Social Media". *Internet Science*. Cham: Springer International Publishing, 2018, s. 3–14. ISBN: 978-3-030-01437-7. DOI: 10.1007/978-3-030-01437-7_1 (cytowane na stronie 38).

[127] D. McCaig, S. Bhatia, M. T. Elliott, L. Walasek, C. Meyer. „Text-mining as a methodology to assess eating disorder-relevant factors: Comparing mentions of fitness tracking technology across online communities". *International Journal of Eating Disorders* 51.7 (2018), s. 647–655. DOI: 10.1002/eat.22882 (cytowane na stronie 38).

[128] K. Rojewska, S. Maćkowska, M. Maćkowski, A. Różańska, K. Barańska, M. Dzieciątko, D. Spinczyk. „Natural Language Processing and Machine Learning Supporting the Work of a Psychologist and Its Evaluation on the Example of Support for Psychological Diagnosis of Anorexia". *Applied Sciences* 12.9, 4702 (2022). DOI: 10.3390/app12094702 (cytowane na stronie 38).

[129] M. Rujas, B. Merino-Barbancho, P. Arroyo, G. Fico. „Development of a Natural Language Processing-Based System for Characterizing Eating Disorders". *IberLEF@SEPLN*. 2023 (cytowane na stronie 38).

[130] H. Yan, E. E. Fitzsimmons-Craft, M. Goodman, M. Krauss, S. Das, P. Cavazos-Rehg. „Automatic detection of eating disorder-related social media posts that could benefit from a mental health intervention". *International Journal of Eating Disorders* 52.10 (2019), s. 1150–1156. DOI: 10.1002/eat.23148 (cytowane na stronie 38).

[131] P. Sarangi, S. Kumar, S. Agarwal, T. Basu. „A Natural Language Processing Based Framework for Early Detection of Anorexia via Sequential Text Processing". *Conference and Labs of the Evaluation Forum*. 2024 (cytowane na stronie 39).

[132] A. Różańska, E. Gliwska, K. Barańska, S. Maćkowska, A. Sobol, D. Spinczyk. „The Use of Natural Language Processing Elements for Computer-Aided Diagnostics and Monitoring of Body Image Perception in Enterally Fed Patients with Head and Neck or Upper Gastrointestinal Tract Cancers". *Cancers* 16.7, 1353 (2024). ISSN: 2072-6694. DOI: 10.3390/cancers16071353 (cytowane na stronach 39, 132 i 137).

[133] E. Gliwska, K. Barańska, S. Maćkowska, A. Różańska, A. Sobol, D. Spinczyk. „The Use of Natural Language Processing for Computer-Aided Diagnostics and Monitoring of Body Image Perception in Patients with Cancers". *Cancers* 15.22, 5437 (2023). ISSN: 2072-6694. DOI: 10.3390/cancers15225437 (cytowane na stronach 39, 132 i 137).

[134] M. Riegel, M. Wierzba, M. Wypych, Ł. Żurawski, K. Jednoróg, A. Grabowska, A. Marchewka. „Nencki Affective Word List (NAWL): the cultural adaptation of the Berlin Affective Word List-Reloaded (BAWL-R) for Polish". *Behavior Research Methods* 47 (2015), s. 1222–1236. DOI: 10.3758/s13428-014-0552-1 (cytowane na stronie 48).

[135] SAS Institute Inc. *SAS Enterprise Miner*. Wer. 15.3. SAS Institute Inc. Cary, NC, 2023 (cytowane na stronie 49).

[136] G. Chakraborty, M. Pagolu, S. Garla. *Text Mining and Analysis: Practical Methods, Examples, and Case Studies Using SAS*. Cary, NC: SAS Institute Inc., 2014. ISBN: 978-1612905518 (cytowane na stronach 49, 51 i 52).

[137] R. Albright. „Taming Text with the SVD". *SAS Institute Inc.* (sty. 2004) (cytowane na stronach 49 i 50).

[138] A. Różańska. „Analiza notatek medycznych z wykorzystaniem metod eksploracji tekstów". Praca magisterska. Zabrze: Politechnika Śląska, Wydział Inżynierii Biomedycznej, Katedra Informatyki Medycznej i Sztucznej Inteligencji, 2021 (cytowane na stronie 55).

[139] A. Field. *Discovering Statistics Using IBM SPSS Statistics*. wyd. 4. London: SAGE Publications, 2013. ISBN: 978-1-4462-4918-6 (cytowane na stronie 58).

[140] S. Siegel, N. J. Castellan Jr. *Nonparametric Statistics for the Behavioral Sciences*. wys. 2. New York, NY: McGraw-Hill, 1988. ISBN: 978-0-07-057357-4 (cytowane na stronie 58).

[141] P. Peduzzi, J. Concato, E. Kemper, T. R. Holford, A. R. Feinstein. „A simulation study of the number of events per variable in logistic regression analysis". *Journal of Clinical Epidemiology* 49.12 (1996), s. 1373–1379. DOI: 10.1016/S0895-4356(96)00236-3 (cytowane na stronie 59).

[142] E. Vittinghoff, C. E. McCulloch. „Relaxing the rule of ten events per variable in logistic and Cox regression". *American Journal of Epidemiology* 165.6 (2007), s. 710–718. DOI: 10.1093/aje/kwk052 (cytowane na stronie 59).

[143] D. S. Courvoisier, C. Combescure, T. Agoritsas, A. Gayet-Ageron, T. V. Perneger. „Performance of logistic regression modeling: beyond the number of events per variable, the role of data structure". *Journal of Clinical Epidemiology* 64.9 (2011), s. 993–1000. DOI: 10.1016/j.jclinepi.2010.11.012 (cytowane na stronie 59).

[144] E. O. Ogundimu, D. G. Altman, G. S. Collins. „Adequate sample size for developing prediction models is not simply related to events per variable". *Journal of Clinical Epidemiology* 76 (2016), s. 175–182. DOI: 10.1016/j.jclinepi.2016.02.031 (cytowane na stronie 59).

[145] R. M. O'Brien. „A Caution Regarding Rules of Thumb for Variance Inflation Factors". *Quality & Quantity* 41.5 (2007), s. 673–690. DOI: 10.1007/s11135-006-9018-6 (cytowane na stronie 59).

[146] F. E. Harrell Jr. *Regression Modeling Strategies: With Applications to Linear Models, Logistic and Ordinal Regression, and Survival Analysis*. 2nd. Springer Series in Statistics. Springer, 2015. ISBN: 978-3-319-19424-0. DOI: 10.1007/978-3-319-19425-7 (cytowane na stronie 59).

[147] H. Zou, T. Hastie. „Regularization and variable selection via the elastic net". *Journal of the Royal Statistical Society Series B: Statistical Methodology* 67.2 (2005), s. 301–320. ISSN: 1369-7412. DOI: 10.1111/j.1467-9868.2005.00503.x (cytowane na stronie 59).

[148] E. R. DeLong, D. M. DeLong, D. L. Clarke-Pearson. „Comparing the Areas under Two or More Correlated Receiver Operating Characteristic Curves: A Nonparametric Approach". *Biometrics* 44.3 (1988), s. 837–845. DOI: https://doi.org/10.2307/2531595 (cytowane na stronie 67).

[149] D. M. Garner, K. M. Bemis. „A cognitive-behavioral approach to anorexia nervosa". *Cognitive Therapy and Research* 6.2 (1982), s. 123–150. DOI: 10.1007/BF01183887 (cytowane na stronie 135).

[150] D. M. Garner, K. M. Vitousek, K. M. Pike. „Cognitive-behavioral therapy for anorexia nervosa". *Handbook of Treatment for Eating Disorders*. Red. D. M. Garner, P. E. Garfinkel. 2nd. New York, NY: The Guilford Press, 1997, s. 94–144. ISBN: 978-1-57230-186-3 (cytowane na stronie 135).

[151] C. G. Fairburn, Z. Cooper, R. Shafran. „Cognitive behaviour therapy for eating disorders: A "transdiagnostic" theory and treatment". *Behaviour Research and Therapy* 41.5 (2003), s. 509–528. DOI: 10.1016/S0005-7967(02)00088-8 (cytowane na stronie 135).

[152] T. L. Tylka, N. L. Wood-Barcalow. „What is and what is not positive body image? Conceptual foundations and construct definition". *Body Image* 14 (2015), s. 118–129. ISSN: 1740-1445. DOI: 10.1016/j.bodyim.2015.04.001 (cytowane na stronie 135).

[153] L. Smolak. „Elementary school curricula for the primary prevention of eating problems". *Preventing Eating Disorders*. Red. N. Piran, M. P. Levine, C. Steiner-Adair. Philadelphia, PA: Brunner/Mazel, 1999, s. 84–105. ISBN: 978-0-87630-968-1 (cytowane na stronie 135).

[154] D. Westen, J. Harnden-Fischer. „Personality profiles in eating disorders: Rethinking the distinction between axis I and axis II". *American Journal of Psychiatry* 158.4 (2001), s. 547–562. DOI: 10.1176/appi.ajp.158.4.547 (cytowane na stronie 136).

[155] K. Vitousek, S. Watson, G. T. Wilson. „Enhancing motivation for change in treatment-resistant eating disorders". *Clinical Psychology Review* 18.4 (1998), s. 391–420. ISSN: 0272-7358. DOI: 10.1016/S0272-7358(98)00012-9 (cytowane na stronie 136).

A. Dodatek - lista publikacji współautorskich

Poniższy wykaz zawiera spis publikacji naukowych powstałych w toku prac nad niniejszą rozprawą doktorską, których współautorem jest autor rozprawy doktorskiej.

1. Różańska, A., Gliwska, E., Barańska, K., Maćkowska, S., Sobol, A., & Spinczyk, D. (2024). The use of natural language processing elements for computer-aided diagnostics and monitoring of body image perception in enterally fed patients with head and neck or upper gastrointestinal tract cancers. *Cancers*, 16(7), art. nr 1353. DOI: `https://doi.org/10.3390/cancers16071353`.

2. Maćkowska, S., Barańska, K., Różańska, A., Gliwska, E., & Spinczyk, D. (2023). NLP methods applied in computer-aided diagnostics of body image in head and neck cancer. P. Strumiłło, A. Klepaczko, M. Strzelecki, & D. Bociąga (red.), *XXIII Polish Conference on Biocybernetics and Biomedical Engineering. Book of abstracts*, s. 118. Łódź, Polska. DOI: `https://pcbbe.p.lodz.pl/images/pdf/PCBBE_2023_Book_of_Abstracts.pdf`.

3. Gliwska, E., Barańska, K., Maćkowska, S., Różańska, A., Sobol, A., & Spinczyk, D. (2023). The use of natural language processing for computer-aided diagnostics and monitoring of body image perception in patients with cancers. *Cancers*, 15(22), art. nr 5437. DOI: `https://doi.org/10.3390/cancers15225437`.

4. Maćkowska, S., Barańska, K., Różańska, A., Rojewska, K., & Spinczyk, D. (2022). Morphological language features of anorexia patients based on natural language processing. E. Piętka, P. Badura, J. Kawa, & W. Więcławek (red.), *Information Technology in Biomedicine: 9th International Conference, ITIB 2022* (Lecture Notes in Networks and Systems, vol. 1429, s. 111–123). Springer, Cham. DOI: `https://doi.org/10.1007/978-3-031-09135-3_9`.

5. Barańska, K., Różańska, A., Maćkowska, S., Rojewska, K., & Spinczyk, D. (2022). Determining the intensity of basic emotions among people suffering from anorexia nervosa based on free statements about their body. *Electronics*, 11(1), art. nr 138. DOI: `https://doi.org/10.3390/electronics11010138`.

6. Rojewska, K., Maćkowska, S., Maćkowski, M., Różańska, A., Barańska, K., Dzieciątko, M., & Spinczyk, D. (2022). Natural Language Processing and Machine Learning Supporting the Work of a Psychologist and Its Evaluation on the Example of Support for Psychological Diagnosis of Anorexia. *Applied Sciences*, 12(9), art. nr 4702. DOI: `https://doi.org/10.3390/app12094702`.