ADN
Uczenie maszynowe i głębokie
Analiza sentymentu

Marzena Nowakowska
Wydział Zarządzania i Modelowania Komputerowego
Politechnika Świętokrzyska

Definicja pojęcia

Analiza sentymentu (AS) (*Sentiment Analysis*, *Opinion Mining*), znana jako analiza opinii, to metoda polegająca na wykorzystaniu technik AI i lingwistyki komputerowej w procesie automatycznego rozpoznawania i klasyfikowania emocji oraz nastroju wyrażonych w tekście (opinie, recenzje, komentarze).

Lingwistyka komputerowa (*Computational Linguistics*) interdyscyplinarna dziedzina z obszaru językoznawstwa i informatyki obejmująca modelowanie języka naturalnego (gramatyka, składnia) przy użyciu technologii komputerowych (programowanie, analiza danych).

Zastosowania: asystenci głosowi (Siri, Google Assistant), tłumacze maszynowe (DeepL), korektory tekstu, analiza sentymentu.

Język figuratywny – znaczący aspekt AS

Język figuratywny - sposób komunikacji, w którym słowa i wyrażenia są używane w znaczeniu niedosłownym. Zamiast przekazywać informacje wprost, wykorzystuje on wyobraźnię, symbole i porównania, aby wzmocnić emocjonalność oraz plastyczność wypowiedzi

Cechy:

- odejście od dosłowności
- obrazowość
- ekspresja

Środki języka figuratywnego

Metafora (przenośnia) – obrazowe sformułowania poprzez łączenie słów w nietypowy sposób; „morze potrzeb” (potrzeby nie są wodą), „złote serce” (serce nie jest z kruszcu, oznacza dobroć), „stalowe nerwy” (nerwy nie są z metalu).

Porównanie – zilustrowanie jednej rzeczy poprzez odwołanie się do innej, zazwyczaj bardziej obrazowej poprzez wyrazy takie jak: „jak”, „niby”, „niczym”, „na kształt”; np. „uparty jak osioł”, „zwinny niczym kot”.

Uosobienie (personifikacja) – nadawanie cech ludzkich przedmiotom nieożywionym, zwierzętom, roślinom, zjawiskom przyrody, wprowadzając emocjonalną głębię lub plastyczność; . „słońce się do nas uśmiecha”, „wiatr gwiżdże w kominie”, „smutna wierzba”.

Hiperbola (wyolbrzymienie, przesadnia) – celowe przesadne opisanie czegoś; „umierać ze śmiechu”, „zjeść konia z kopytami”.

Idiom – stały zwrot właściwy dla danego języka, którego nie można tłumaczyć dosłownie; „flaki z olejem”.

Ironia – sposób wypowiadania się lub przedstawiania rzeczywistości, w którym słowa znaczą coś przeciwnego do komentowanej rzeczywistości, często drwiącego lub złośliwego; świetna robota” (ktoś coś zepsuł), „śliczna pogoda” (podczas ulewy).

Sarkazm – szczególnie złośliwa odmiana ironii, która służy do drwiny, szyderstwa i naśmiewania się z kogoś lub czegoś; „Naprawdę jesteś taki niemądry, czy tylko udajesz?”.

Wymiary AS – poziom szczegółowości

Poziom ziarnistości (*Granularity Level*)

- Poziom **dokumentu** (niska szczegółowość); kasyfikacja całego tekstu (np. recenzji, artykułu) jako jednej jednostki wyrażającej ogólną opinię.
- Poziom **zdania** (średnia szczegółowość); badanie relacji między wyrazami, uwzględniając jak słowa takie jak „nie”, „nigdy” lub „chyba”, które zmieniają wydźwięk zdania, np. „Ten telefon jest dobry” (pozytywny) kontra „Ten telefon nie jest dobry” (negatywny).
- Poziom **aspektu** (ABSA – *Aspect Based Sentiment Analysis*) (wysoka szczegółowość); polega na rozbijaniu opinii na poszczególne cechy (aspekty, rzeczowniki) produktu lub usługi i przypisywaniu sentymentu (pozytywnego, negatywnego lub neutralnego) do każdego z nich z osobna.

  To obecnie jedno z najważniejszych podejść w NLP biznesowym.

  Przykład. W zdaniu „Jedzenie było świetne, ale kelner niemiły” – aspekt jedzenia → [+], a obsługi → [-].

Wymiary AS – zakres wartości klasyfikacji

- **Binarna** (*Binary*). Wyróżnia się dwie klasy o wartościach sentymentu: pozytywny, negatywny.
- **Trójkowa** (*Ternary*). Określane jako sentyment podstawowy z wartościami: pozytywny, negatywny, neutralny.
- **Wieloklasowa** (*Fine-grained)*. Rozróżnia więcej poziomów sentymentu, najczęściej pięć: bardzo negatywny, negatywny, neutralny, pozytywny, bardzo pozytywny.
- Klasyfikacja/Wykrywanie **emocji** w kontekście psychologicznym (*Emotion Classification*). Bazuje na psychologicznych kategoriach emocji, takich jak: (radość, zadowolenie, entuzjazm), (gniew, frustracja, złość), (smutek, rozczarowanie), (strach, niepokój).

Wymiary AS – metody analizy

Klasyfikacja sentymentu korzysta z różnych podejść algorytmicznych, które ewoluowały razem z postępem technologicznym. Od prostych słowników, przez zaawansowane algorytmy uczenia maszynowego, aż po głębokie uczenie – każda metoda ma swoje unikalne cechy i zastosowania.

- **Słownikowa** (*Lexicon-based approach*)
- **Regułowa** (*Rule-based Approach*)
- **Uczenia maszynowego** (*Machine Learning-based Approach*) – klasyczny ML, uczenie głębokie DL
- **Hybrydowa** (*Hybrid approach*); działa poprzez połączenie: słowników, reguł językowych i uczenia maszynowego

Słownikowa metoda AS

Porównywanie słów zawartych w tekście z wcześniej przygotowaną listą – tzw. słownikiem sentymentu (leksykonem; *sentiment lexicon*). Każde słowo ma w nim przypisaną wartość (wagę), np.: „świetny” (+1), „okropny” (-1), „zwyczajny” (0).

Program skanuje tekst i sumuje wartości znalezionych słów i w wyniku końcowym tekst uznaje się za:

- pozytywny, jeżeli suma wag jest dodatnia,
- negatywny, jeśli suma wag jest ujemna,
- neutralny w sytuacjach: brak w słowniku słów z wartością +/-, równowaga wag, słowo nieznane.

Możliwość wprowadzenia „czułości”:

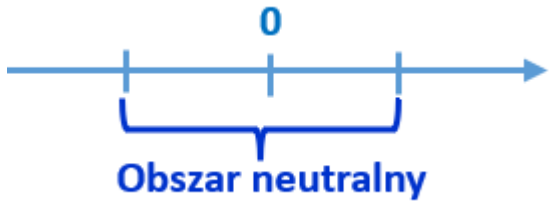

Metoda nie wymaga ogromnych zbiorów danych do trenowania algorytmu.
Są trudności z klasyfikacją w przypadku sarkazmu czy ironii.
Istnieją gotowe bazy, z których korzystają badacze, takie jak: SentiWordNet (popularny słownik dla języka angielskiego), specjalistyczne bazy, np. słownik Loughrana i McDonalda używany w finansach.
Możliwość tworzenia własnych słowników.

Słownik w AS – forma tablicy asocjacyjnej

Przykład dla języka angielskiego

Słowo (klucz)	Waga (wartość)	Kontekst emocjonalny
outstanding	5	Bardzo pozytywne
love	3	Pozytywne
good	1	Lekko pozytywne
the / is	0	Neutralne
sad	-2	Negatywne
hate	-3	Silnie negatywne
disaster	-5	Ekstremalnie negatywne

Przykład dla języka polskiego

Słowo (klucz)	Waga (wartość)	Kontekst emocjonalny
zachwycający	2.0	Silny pozytyw
uśmiech	1.2	Pozytyw
dom	0.0	Neutralny (obiekt)
brak	-0.5	Lekki negatyw
rozczarowanie	-1.5	Negatyw
morderstwo	-3.0	Silny negatyw

Regułowa metoda AS

Metoda ocenia sentyment tekstu na podstawie punktów przypisanych słowom pozytywnym lub negatywnym (predefiniowany słownik emocji) oraz reguł gramatycznych.

Działanie

- Leksykon sentymentu i reguły – gotowa lista słów z przypisaniem ich roli (funkcji):
  - Słowa nacechowane („świetny” = +1, „uwielbiam = +2, „okropny” = -1, „koszmarny = -2)
  - Słowa funkcyjne i neutralne; pomijane (spójniki; „oraz”, „w”) lub mają wartość neutralną 0 (bez wydźwięku emocjonalnego, np. „stół", „idę”, „dom”)
  - Modyfikatory: wzmacniacze (zwiększają siłę emocji; „bardzo”), osłabiacze (zmniejszają siłę emocji; „nieco”), negacje (odwracają lub zmieniają polaryzację; „nie”)

  Połączenia wzmacniaczy i osłabiaczy w jednym zdaniu są przetwarzane wg kolejności odtwarzania od lewej do prawej, gdzie każda reguła modyfikuje wynik poprzedniej.
- Przetwarzanie tekstu; badanie słów pozytywnych i negatywnych w zdaniu i zastosowanie reguł językowych, które dostarczają końcowy wynik jako jako pozytywny, negatywny lub neutralny.

Przykład. Obliczenie sentymentu dla zdania: „Film był może trochę zbyt długi”

- „długi”: bazowa wartość ujemna (np. -1)
- „zbyt” (wzmacniacz): podbija negatyw (-2)
- „trochę” (osłabiacz): tonuje wynik końcowy z powrotem do -1.5 lub -1

Metody uczenia maszynowego w AS

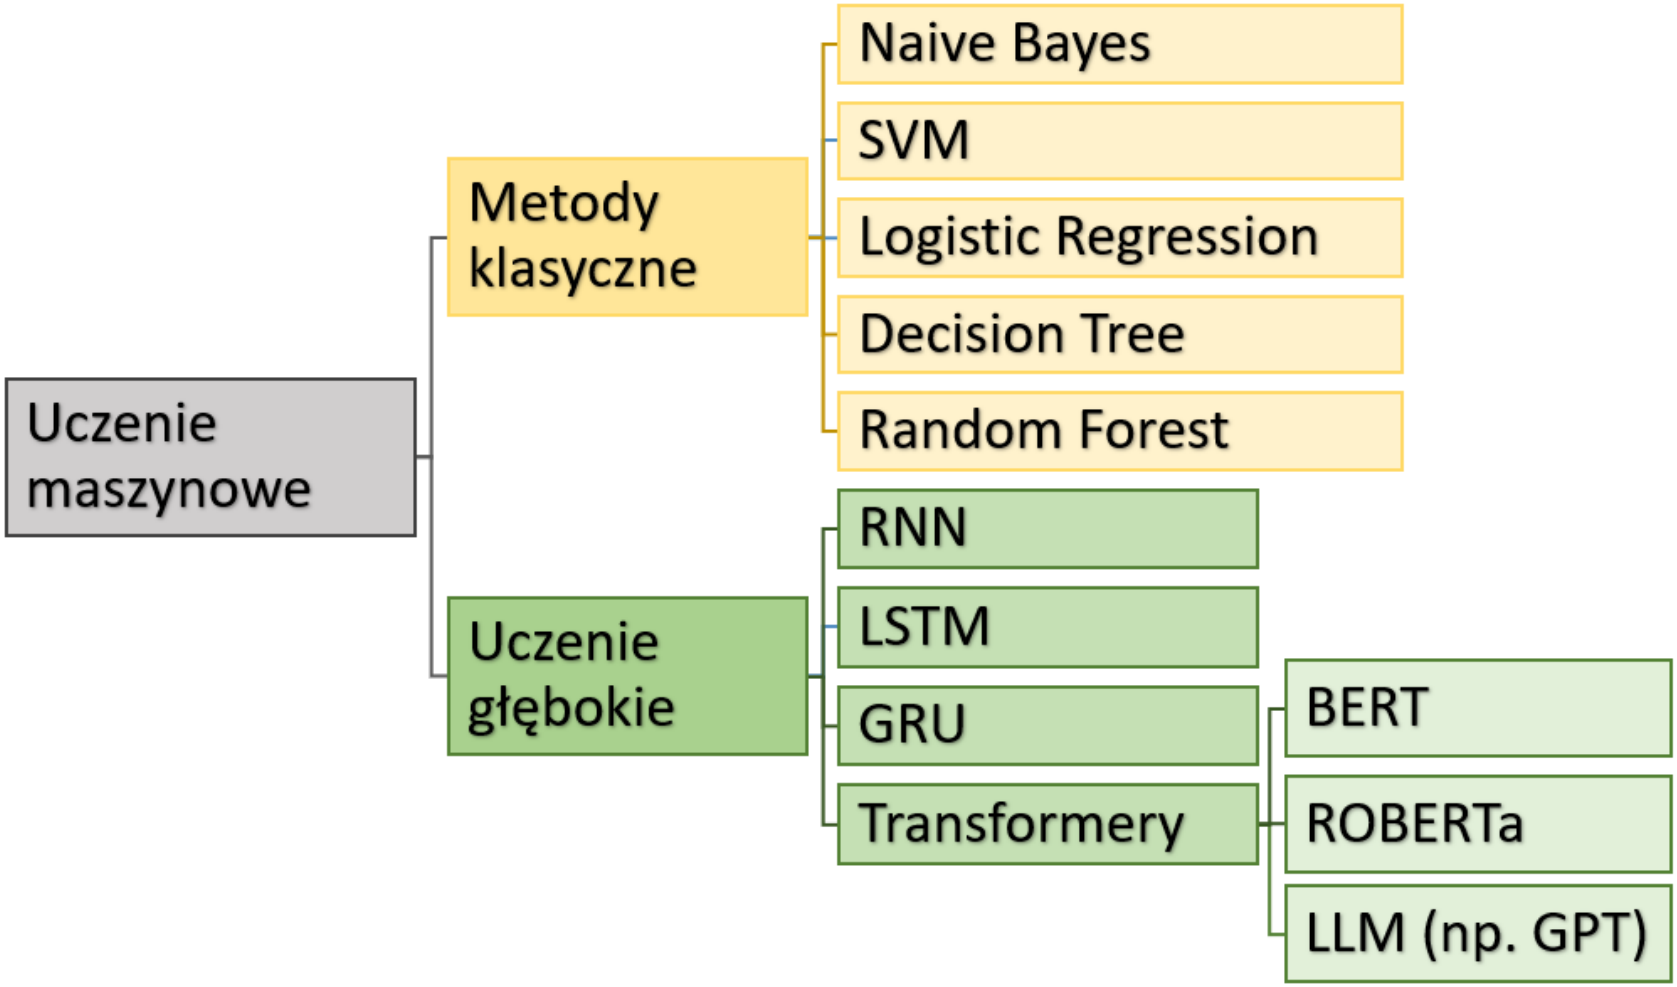

AS z wykorzystaniem metod uczenia maszynowego klasycznego

W podejściu opartym na uczeniu maszynowym, modele klasyfikacyjne uczą się rozpoznawać sentyment na podstawie zaetykietowanych zestawów treningowych. Obejmuje kilka kroków.

1. Wstępne przetwarzanie tekstu (Preprocessing): tokenizacja (podział na słowa), zamiana na małe litery, usuwanie znaków specjalnych, usuwanie stop words, lematyzacja lub stemming
2. Zamiana tekstu na jego reprezentację statystyczną (Feature Extraction) – wektory liczbowe (słowo to wymiar przestrzeni):
   - BoW – każdy tekst jest reprezentowany przez wektor częstości słów w nim występujących
   - TF-IDF – uwzględnienie ważności słów w całym korpusie; słowa ogólne mniejsza wagę, charakterystyczne są bardziej istotne
   - n-gramy – uwzględnienie kolejności słów
3. Zastosowanie klasyfikatora:
   - naiwny klasyfikator Bayesa (*Naive Bayes*)
   - maszyna wektorów nośnych (*SVM – Support Vector Machine*)
   - regresja logistyczna (*Logistic Regression*)
   - drzewa decyzyjne (*Decision Tree*)
   - las losowy (*Random Forest*)
4. Przypisanie sentymentu na podstawie zidentyfikowanych wzorców.

We wszystkich tych klasyfikatorach zbiór zmiennych niezależnych to słowa a wartości tych zmiennych to wagi (reprezentacja wektorowa), zmienna celu to kategoria sentymentu.

AS z ML: naiwny klasyfikator Bayesa

Model probabilistyczny. Algorytm oblicza prawdopodobieństwo wystąpienia poszczególnych słów zbioru treningowego w klasach „pozytywna” i „negatywna”. Gdy dostaje nowe zdanie, sprawdza, jakie słowa w nim występują i mnoży prawdopodobieństwa wszystkich słów w zdaniu wg zależności poniżej. Decyduje ta klasa, dla której wynik jest wyższy.

$$Wynik_{Klasy} = P(Klasa) \times P(Słowo_1|Klasa) \times P(Słowo_2|Klasa) \times \ldots$$

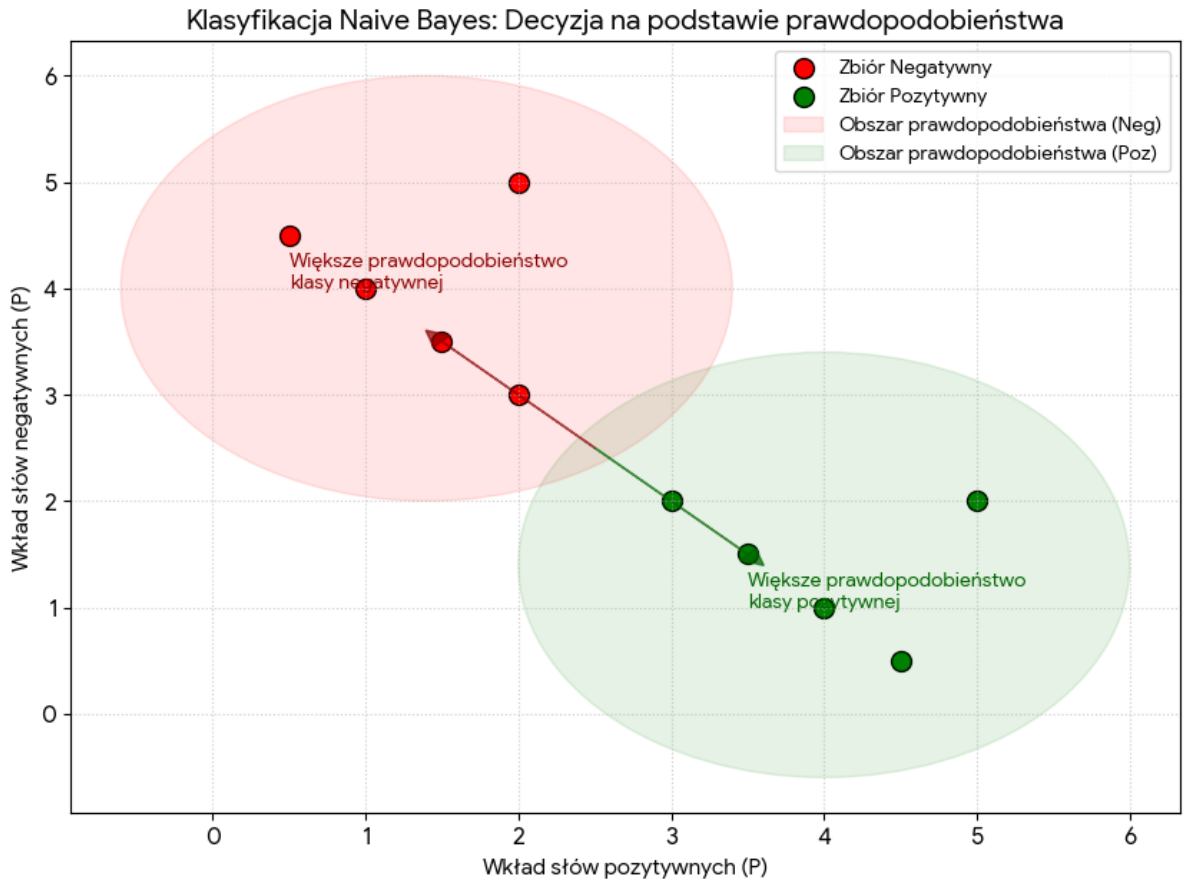

„Naiwność” polega na założeniu, że słowa występują niezależnie jeden od drugiego.

AS z ML: maszyna wektorów nośnych

Wyznaczana jest optymalna hiperpłaszczyzna rozdzielająca dwie klasy danych (np. opinie pozytywne i negatywne). Ta hiperpłaszczyzna zapewnia największy odstęp od najbliższych punktów obu klas. Wektory nośne są punktami danych leżącymi najbliżej granicy podziału – po ich usunięciu model może się zmienić, pozostałe punkty nie wpływają na model

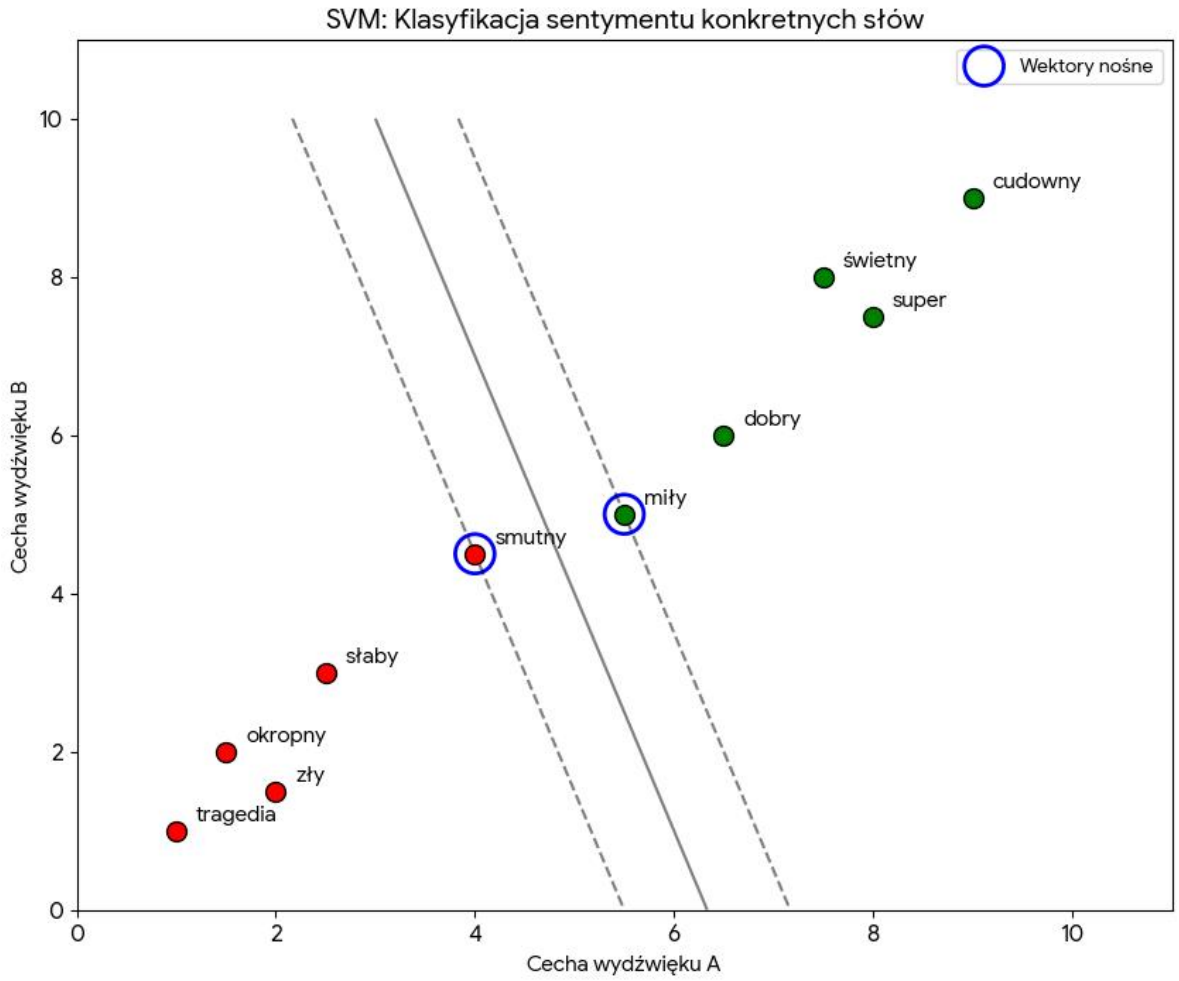

AS z ML: regresja logistyczna

Wyznaczane jest prawdopodobieństwo przynależności do konkretnej klasy (zazwyczaj klasy pozytywnej) pod warunkiem określonych wartości zmiennych wejściowych (określonego zbioru wyrazów). Kategorią sukcesu jest jedna wartość sentymentu, zazwyczaj wydźwięk pozytywny.

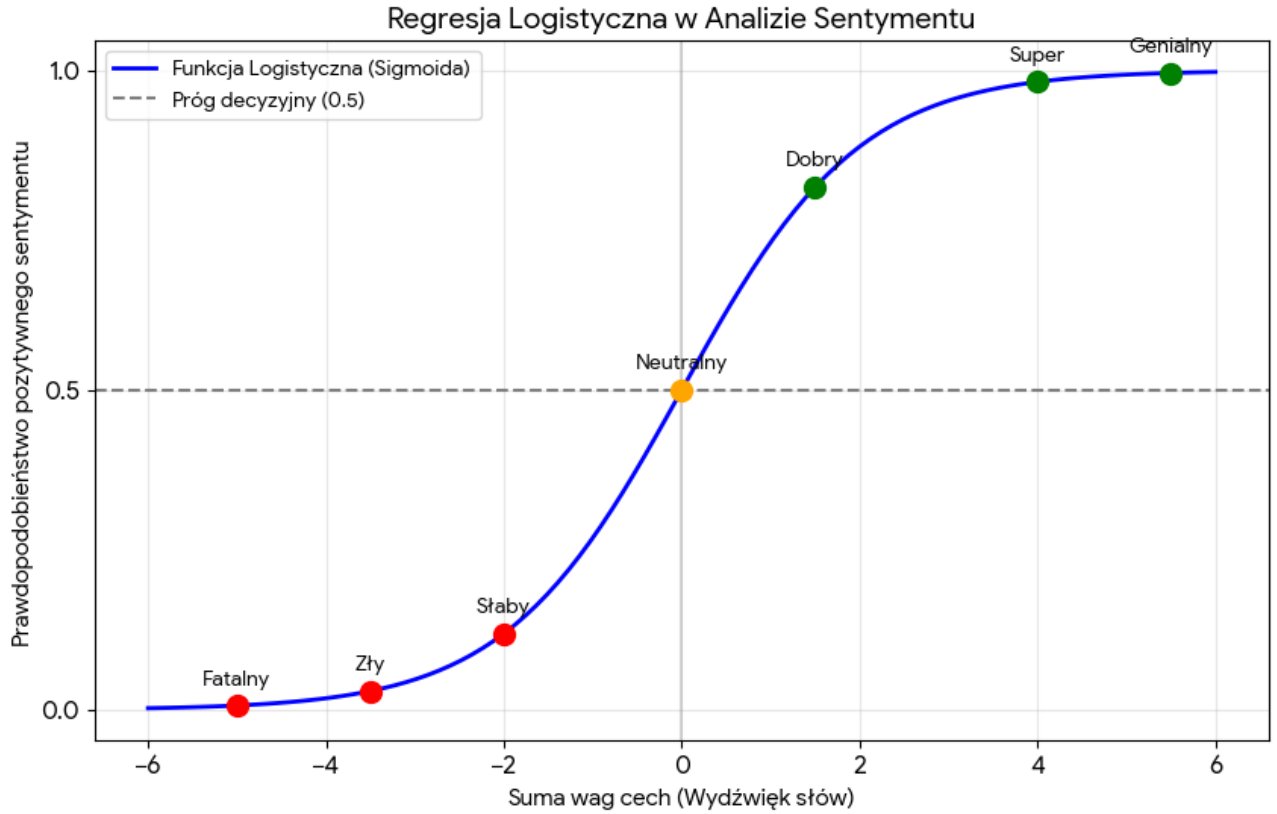

Wynik regresji logistycznej interpretuje się jako pewność modelu:
0.95: „Jest 95% pewności, że to zdanie jest pozytywne”.
0.50: „Granica niepewności (punkt decyzyjny)”.
0.10a: „Bardzo wysokie prawdopodobieństwo negatywnego sentymentu”.

AS z ML: drzewo decyzyjne

Algorytm buduje hierarchię reguł na podstawie słów kluczowych, dzieląc rekurencyjnie zbiór korpusu wg słów zgodnie z ich wagą (znaczeniem; test chi2 → Chi-squared Automatic Interaction Detector CHAID; Information gain →Top-Down Induction of Decision Trees TDIDT, C4.5; Gini impurity reduction → CART). Ostateczna klasyfikacja sentymentu: pozytywny, neutralny, negatywny następuje w węźle końcowym – liściu.

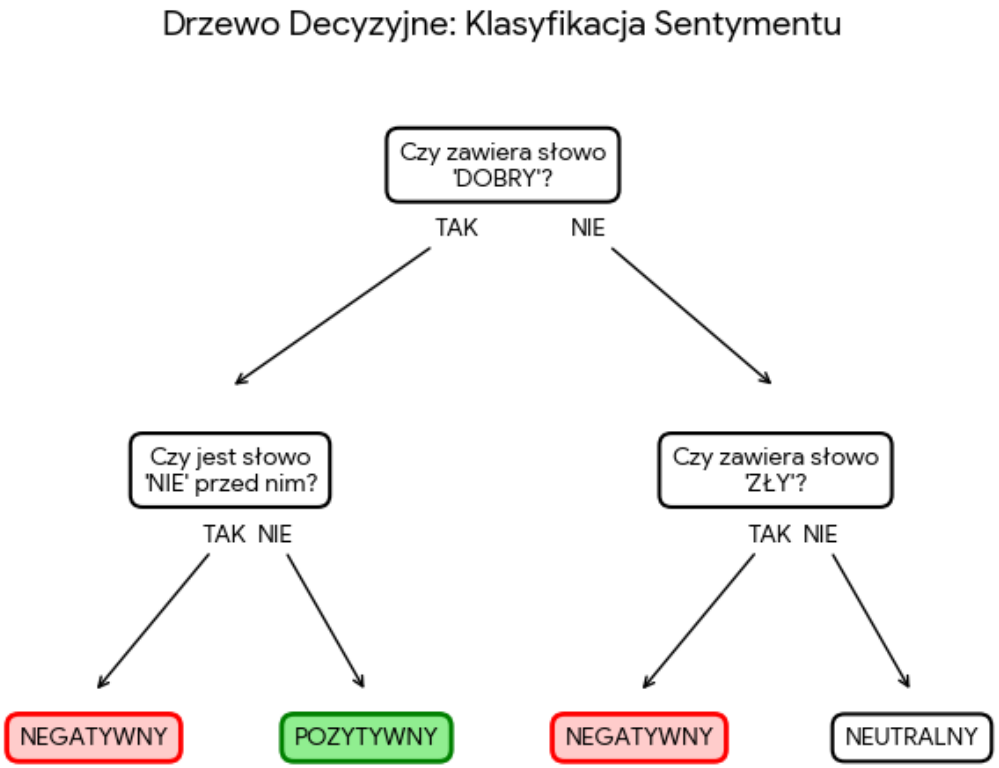

1. W korzeniu drzewa znajduje się cały zbiór (cała reprezentacja statystyczna korpusu). Tu jest identyfikowana zmienna (słowo), które najlepiej rozdziela zbiór danych.
2. W kolejnych węzłach (podzbiorach) działa algorytm rekurencyjny – następuje podział zbioru wg „najlepszego słowa”.
3. Węzły, w których nie ma już podziału (różne powody) - to węzły końcowe (terminalne) czyli liście.

AS z ML: las losowy

Algorytm tworzy cały „las” (dziesiątki lub setki) niezależnych drzew. Każde drzewo w lesie uczy się na nieco innym fragmencie danych i na losowym zestawie cech (słów). Ostateczny wynik wybieramy w drodze głosowania większościowego wyników drzew decyzyjnych.

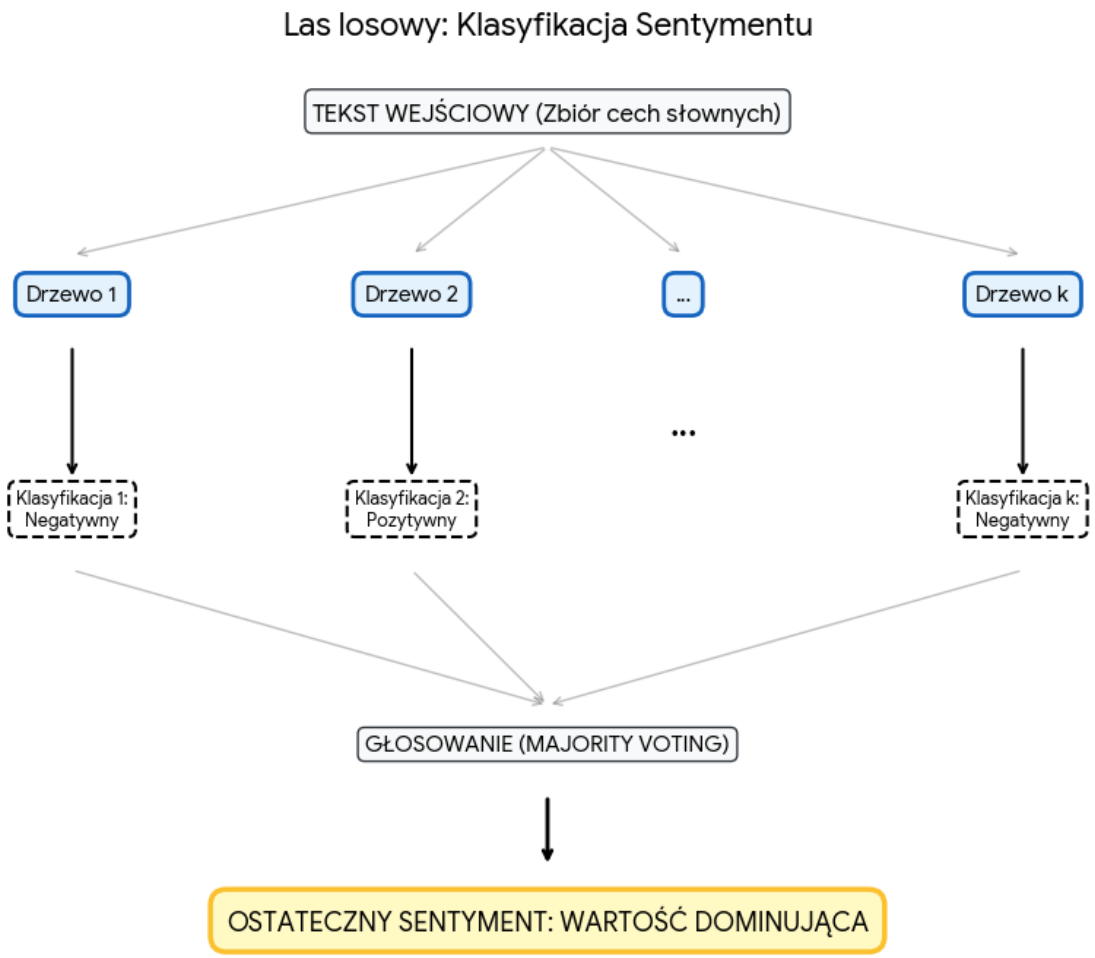

Uczenie głębokie

Architektura sieci głębokiej (Deep Learning) opiera się na kaskadowym układzie warstw, gdzie każda kolejna warstwa przetwarza dane na wyższym poziomie abstrakcji.

1. Wielowarstwowa architektura sieci
   - Warstwa wejściowa (*Input Layer*). Każdy neuron odpowiada za jedną cechę wejściową.
   - Blok warstw ukrytych (*Hidden Layers*) – serce "głębokości". Tu sieć identyfikuje złożone zależności; pierwsze warstwy mogą wykrywać związki między sąsiednimi słowami, a głębsze – sarkazm czy ogólny ton wypowiedzi.
   - Warstwa wyjściowa (*Output Layer*). Generuje wynik końcowy (np. prawdopodobieństwo, że tekst jest pozytywny).
2. Uczenie jest procesem iteracyjnym i polega na kalibracji wag (połączeń między neuronami), który odbywa się w dwóch krokach
   - Propagacja w przód (*Forward Pass*). Każdy neuron otrzymuje sygnały od wszystkich neuronów z poprzedniej warstwy. Mnoży każde wejście przez odpowiadającą mu wagę, a następnie wszystko to dodaje do siebie i przepuszcza przez funkcję aktywacji.
   - Sieć stawia diagnozę (np. "80% pozytywny").
   - Propagacja wsteczna (*Back Pass*). Algorytm sprawdza, jak bardzo się pomylił (używając tzw. funkcji straty). Następnie wagi błędnych klasyfikacja są korygowane tak, aby przy kolejnej próbie błąd był mniejszy.
3. Algorytm kończy działanie gdy spełnione jest jedno z kryteriów: (a) osiągnięcie kryterium stopu, (b) osiągnięcie zbieżności (funkcja błędu się nie zmienia), (c) ograniczenie zasobów.

Struktura sieci w uczeniu głębokim

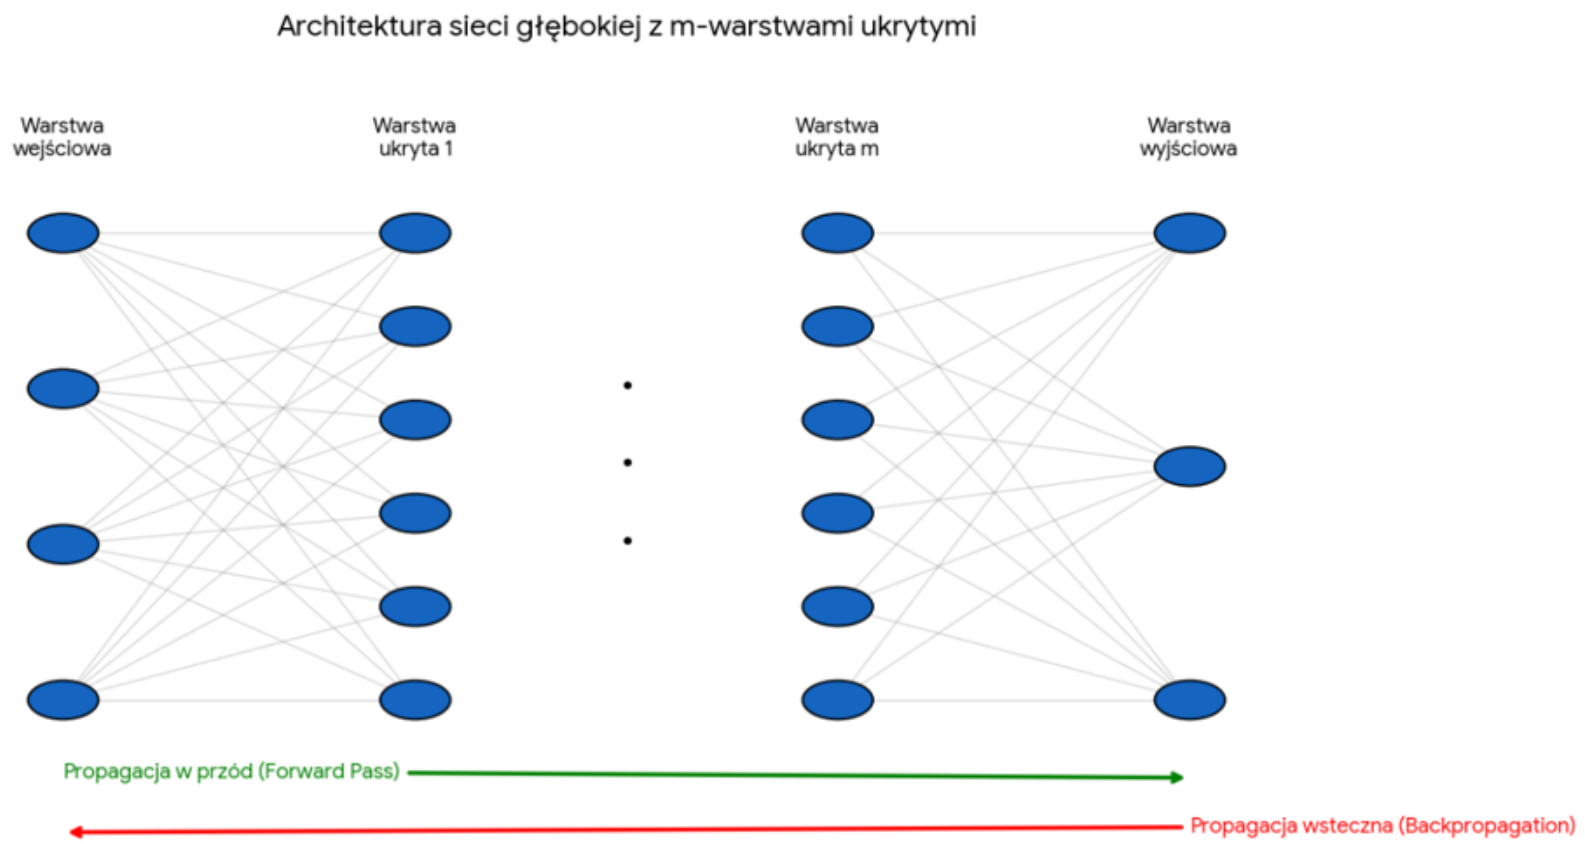

Koniec pracy - warstwa wyjściowa
Zamrożenie wag neuronów.

Faza inferencji (zastosowania): nie ma treningu – model przetwarza nowe dane i podaje wyniki

AS z wykorzystaniem metod uczenia głębokiego

W strukturze sieci głębokiej każda warstwa od 1 do m odpowiada za coraz wyższy stopień identyfikacji cech.

1. Warstwa wejściowa; przyjmuje surowe liczby, np. wektory słów (embeddingi).
2. Warstwa ukryta 1 (niski poziom abstrakcji); przetwarza wejścia w celu ekstrakcji podstawowych korelacji lokalnych.
3. Warstwy środkowe; realizują wielopoziomowe operacje matematyczne, które agregują rozproszone sygnały, sieć wykrywa złożone zależności strukturalne w tekście (łączy wcześniejsze wzorce w bardziej złożone struktury), uwzględniane są relacje między odległymi słowami.
4. Warstwa ukryta *m* (wysoki poziom abstrakcji); generuje końcowy wektor wysokopoziomowych cech semantycznych; model rozpoznaje abstrakcyjne wzorce, takie jak subiektywność, intencję czy zabarwienie emocjonalne, które są zakodowane w formie wektorowej.
5. Warstwa wyjściowa; agregacja sygnałów z ostatniej warstwy ukrytej i ostateczne mapowanie na przestrzeń wyjściową. Zastosowanie funkcji aktywacji (np. Softmax) i przekształcenie wartości liczbowe na rozkład prawdopodobieństwa wartości sentymentu

Wynik: liczba z przedziału [0, 1] – pewność, co do przynależności tekstu do danej klasy (np. 0,98 dla klasy „pozytywny”).

Architektura modelu uczenia głębokiego w AS: modele sekwencyjne

Przetwarzają słowo po słowie, „pamiętając” poprzednie wyrazy. Każdy krok obliczeniowy zależy od wyniku kroku poprzedniego. Stan ukryty (*hidden state*) przenosi informację przez całą sekwencję, co pozwala sieci „pamiętać” kontekst wcześniejszych wyrazów.

Słowo 1 → Słowo 2 → Słowo 3 → ... → [Wektor Kontekstu] → Wynik

- RNN – Recurrent Neural Network; podstawa przetwarzania sekwencyjnego (zapoczątkowały pamięć w sieciach). Cechy: w przypadku gdy zdanie jest zbyt długie, ma wtrącenia oraz złożenia podrzędne:
  - zanikający gradient (*vanishing gradient*) – sieć nie uczy się kontekstu (pamięć krótkotrwała)
  - gradient wybuchający (*exploding gradient*) – sieć matematycznie niestabilne (błędy NaN – wartość niezdefiniowana lub niemożliwa do obliczenia)
- LSTM – Long Short-Term Memory; rozwiązanie problemu RNN poprzez wprowadzenie komórki pamięci (*cell state*) oraz trzech bramek (wejścia, zapomnienia, wyjścia).
- GRU – Gated Recurrent Unit; uproszczona wersja LSTM aby działała szybciej, łączy bramki w dwie (aktualizacji i resetu), oferując szybsze trenowanie przy podobnej wydajności.

Architektura modelu uczenia głębokiego w AS: modele transformerowe

Analizują wszystkie słowa w zdaniu jednocześnie

Słowo 1, Słowo 2, Słowo 3 (wszystkie naraz) ⇉ [Wektor Kontekstu] ⇉ Wynik

- Mechanizm uwagi (Self-Attention); każde słowo jest kojarzone ze wszystkimi innymi i sprawdzane, które z nich są dla zdania istotne; model identyfikuje najważniejsze słowa dla wydźwięku całości, nawet jeśli stoją daleko od siebie.
- Pozycjonowanie (Positional Encoding); do każdego wektora słowa dodawany jest specjalny „znacznik czasu” (kod pozycji), aby nie utracić informacji o ich kolejności (co jest na początku, a co na końcu).
- Architektura Encoder / Decoder
  - Encoder (tylko koder): pobiera tekst wejściowy i zamienia go na abstrakcyjną mapę znaczeń (reprezentację matematyczną). Analizuje tekst dwukierunkowo (kontekst po lewej i prawej stronie słowa). Służy do analizy i ekstrakcji cech.
  - Decoder: analizuje tekst jednokierunkowo (autotregresyjnie, kontekst poprzedzający – w tył) i przewiduje kolejne słowa na podstawie słów, które pojawiły się wcześniej, maskując przyszłe tokeny. Służy do generowania treści.
  - Encoder-Decoder: architektura sekwencja-do-sekwencji. Encoder przetwarza całą sekwencję wejściową (np. zdanie w języku polskim), a Decoder na podstawie wygenerowanego przez niego stanu tworzy nową sekwencję (np. zdanie w języku angielskim). Służy do transformacji jednej sekwencji w drugą.

Przykład pracy transformera

Zdanie: „Mimo kiepskiej pogody, koncert był niesamowity!”

1. Embedding:

   słowa zamieniane są na wektory.

2. Attention/Context

   model wykrywa, że „niesamowity” odnosi się do „koncertu”, a „kiepska” tylko do „pogody”.

3. Output:

   model nadaje najwyższą wagę słowu „niesamowity” i klasyfikuje zdanie jako pozytywne.

Modele transformerowe

- Enkodery
  - Flagowy przykład: BERT (Bidirectional Encoder Representations from Transformers)
  - Inne: RoBERTa, DistilBERT, ALBERT
  - Główne zastosowanie: klasyfikacja tekstów, analiza sentymentu, rozpoznawanie encji nazwanych (NER), wyszukiwarki semantyczne
- Dekodery
  - Flagowy przykład: Seria GPT (od GPT-1, przez GPT-3, nowoczesne modele LLM jak GPT-4)
  - Inne: Llama (Meta), Mistral, Claude, Gemini Flash
  - Główne zastosowania: generowanie tekstu, pisanie kodu, chatboty konwersacyjne (np. ChatGPT), kontynuowanie wątków
- Enkoder-Dekodery
  - Flagowy przykład: T5 (Text-to-Text Transfer Transformer)
  - Inne: BART (Bidirectional and Auto-Regressive Transformers), model multimodalny: Whisper (OpenAI) – enkoder przetwarza sygnał audio (mowę), a dekoder generuje tekst (transkrypcję)
  - Główne zastosowania: tłumaczenie maszynowe, automatyczne streszczanie tekstów (summarization), systemy Text-to-Speech i Speech-to-Text

Przykład analizy sentymentu wg metod

Zdanie:

Jedzenie było całkiem niezłe, ale obsługa była fatalna i bardzo powolna.

Metoda	**Działanie**	**Wynik (sentyment)**
Słownikowa	Sumowanie punktów przypisanych słowom w bazie (np. „niezłe” +1, „fatalna” -2, „powolna” -1).	Negatywny (suma: -2)
Regułowa	Uwzględnienie gramatyki i logiki, np. spójnik „ale” osłabia pierwszą część zdania i wzmacnia drugą.	Silnie negatywny (skupienie na części po "ale")
Uczenia maszynowego	Model uczył się na tysiącach opinii, że słowa „fatalna” i „obsługa” występują najczęściej w złych recenzjach.	Negatywny
Uczenie głębokie	Identyfikuje kontekst: sprawdza, że „całkiem niezłe” to tylko umiarkowana pochwała, która ginie przy emocjonalnym „fatalna”.	Negatywny (z precyzyjną pewnością, np. 89%)
Podejście hybrydowe	Łączy szybkość słownika (znajduje konkretne wady) z modelem ML, który ocenia ogólny ton wypowiedzi.	Mieszany / Negatywny (z listą konkretnych cech)