Temat 3 .

AI w akcji – Klasyfikacja inteligentnych systemów

dr inż. Michał Malinowski

https://www.drmalinowski.edu.pl

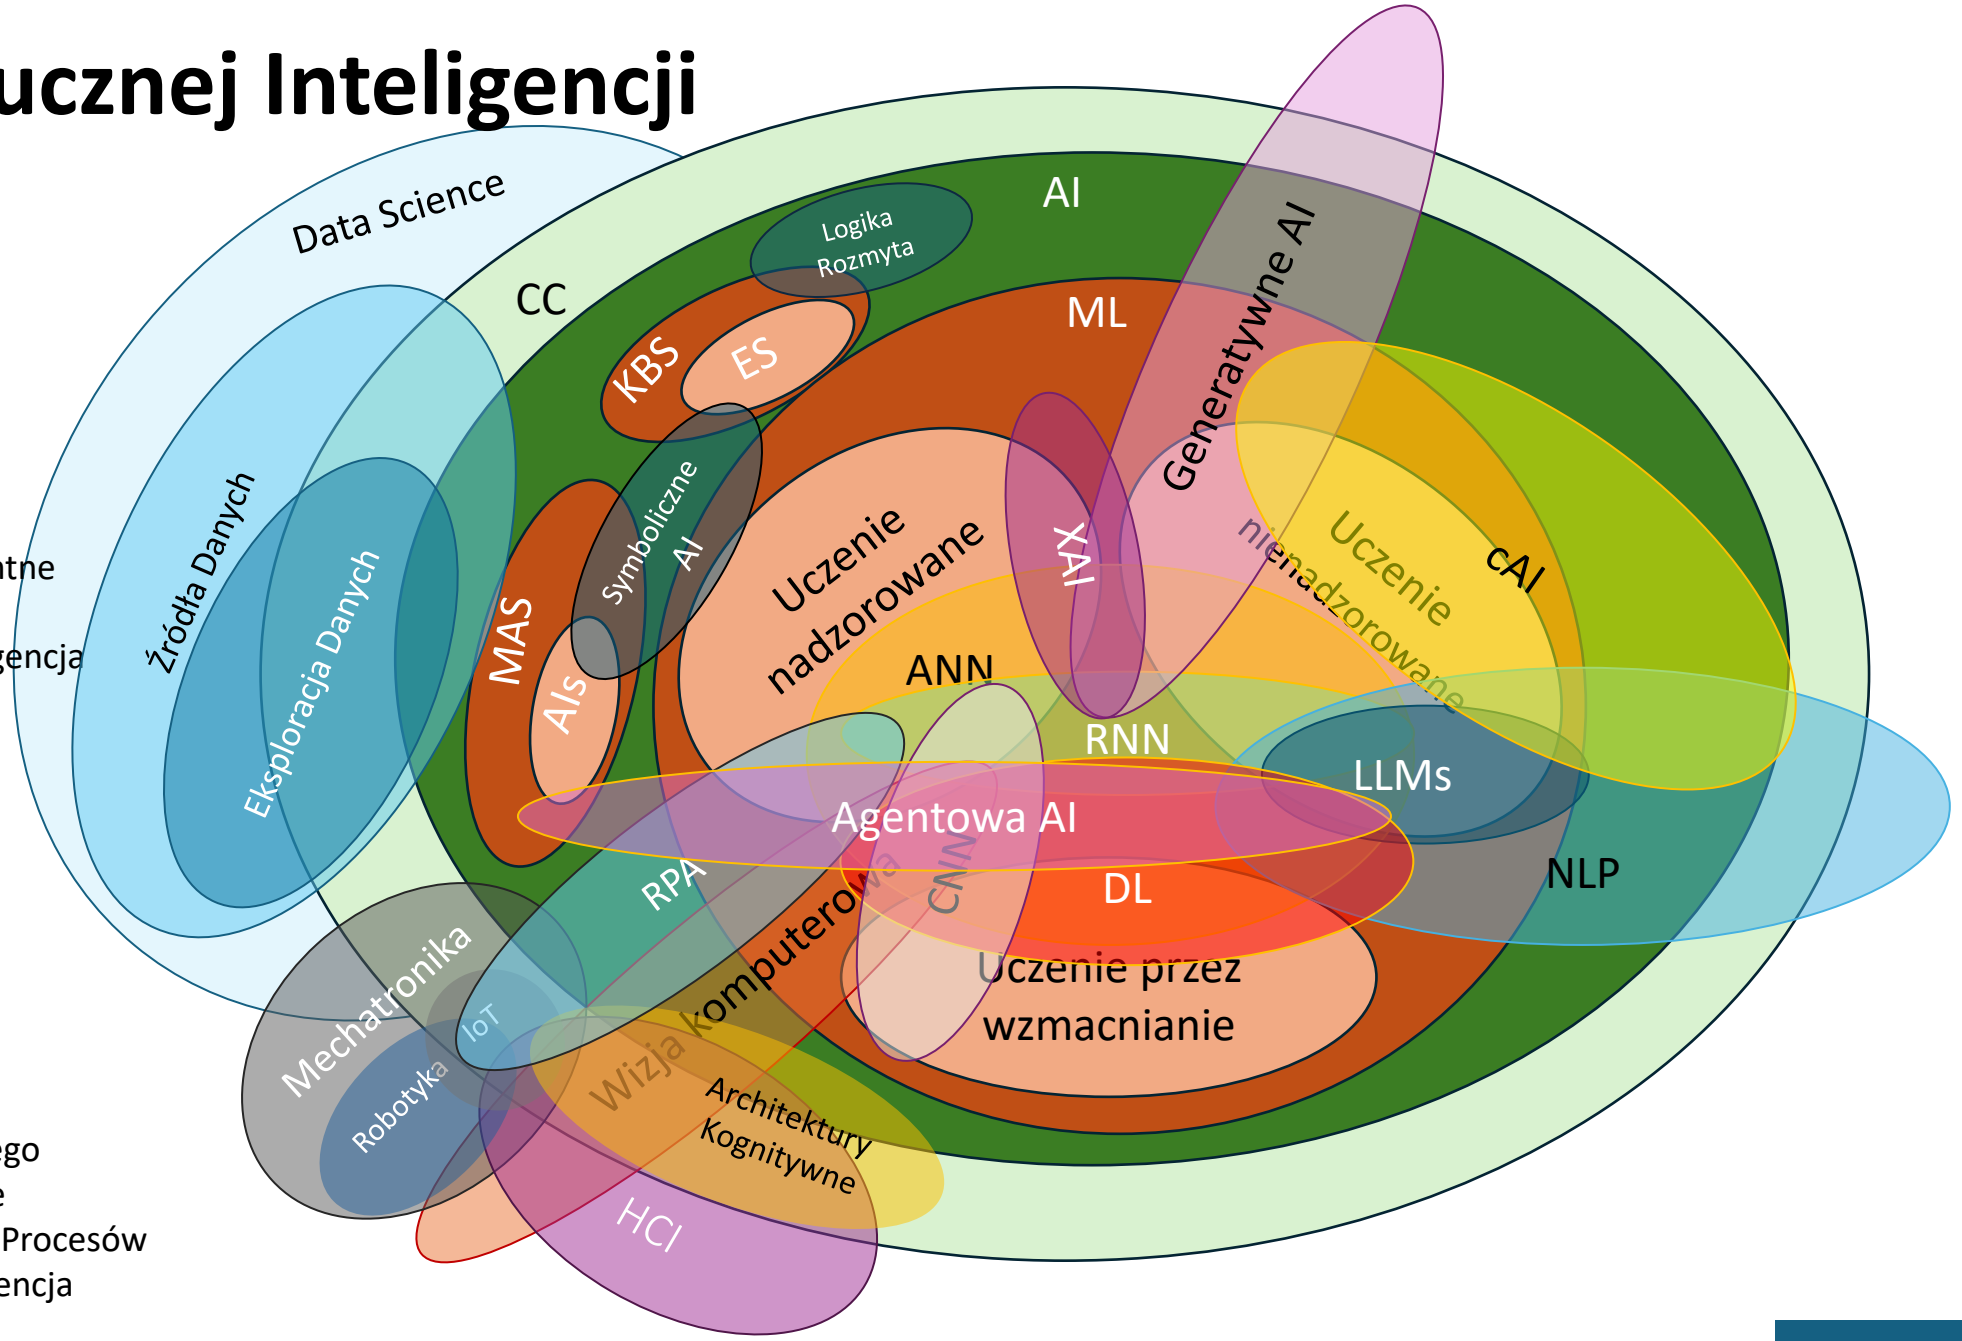
Wprowadzenie do Sztucznej Inteligencji



- Domeny Sztucznej Inteligencji
- Problemy rozwiązywane przez AI
- Klasyfikacje sztucznej inteligencji
- Systemy z bazą wiedzy (KBS)
- Inteligentni agenci (AIs)
- Systemy wieloagentowe (MAS)
- Systemy uczenia maszynowego (ML)

Domeny Sztucznej Inteligencji

AI - Sztuczna Inteligencja
AIs - Autonomiczne Systemy Inteligentne
ANN - Sztuczne Sieci Neuronowe
cAI – Współpracująca Sztuczna Inteligencja
CC - Przetwarzanie kognitywne
CNN - Sieci Konwolucyjne
DL - Uczenie Głębokie
ES - Systemy Ekspertowe
HCI - Interakcja człowiek-komputer
IoT - Internet Rzeczy
KBS - Systemy Oparte na Wiedzy
LLMs - Duże Modele Językowe
MAS - Systemy Wieloagentowe
ML - Uczenie Maszynowe
NLP - Przetwarzanie Języka Naturalnego
RNN - Rekurencyjne Sieci Neuronowe
RPA - Zrobotyzowana Automatyzacja Procesów
XAI - Wytłumaczalna Sztuczna Inteligencja



Problemy rozwiązywane przez AI

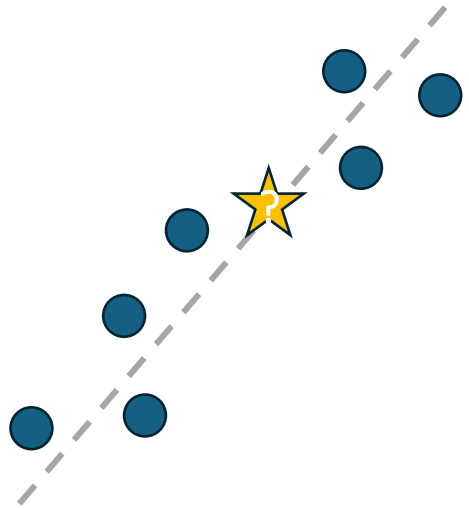
Regresja

to klasa problemów, w której celem jest przewidywanie wartości liczbowych na podstawie danych wejściowych.

Model uczy się zależności między zmiennymi i estymuje wynik na podstawie wzorca ukrytego w danych.

Zastosowanie

💰 **Prognozowanie cen** – przewidywanie wartości nieruchomości, akcji czy surowców na podstawie historycznych danych i trendów rynkowych.
🛒 **Przewidywanie popytu** – analiza sprzedaży produktów, sezonowości i zachowań klientów w celu optymalizacji produkcji i logistyki.
🚗 **Analiza zużycia paliwa** – przewidywanie spalania samochodu w zależności od prędkości, obciążenia i warunków drogowych.



Problemy rozwiązywane przez AI

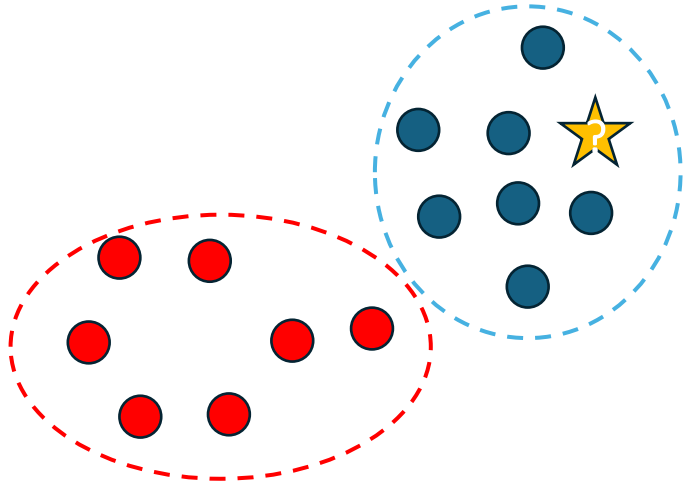
Klasyfikacja

to typ problemu w uczeniu maszynowym, w którym **przypisujemy obiekty do predefiniowanych kategorii** na podstawie cech wejściowych.

Model AI analizuje dane i decyduje, do której klasy należy nowa próbka.

Zastosowanie

✉ **Wykrywanie spamu** – klasyfikacja wiadomości e-mail jako spam lub wiadomości pożądane.
Rozpoznawanie twarzy – identyfikacja osób na podstawie cech biometrycznych.
Analiza obrazów w monitoringu – wykrywanie podejrzanych zachowań na nagraniach z kamer.



Problemy rozwiązywane przez AI

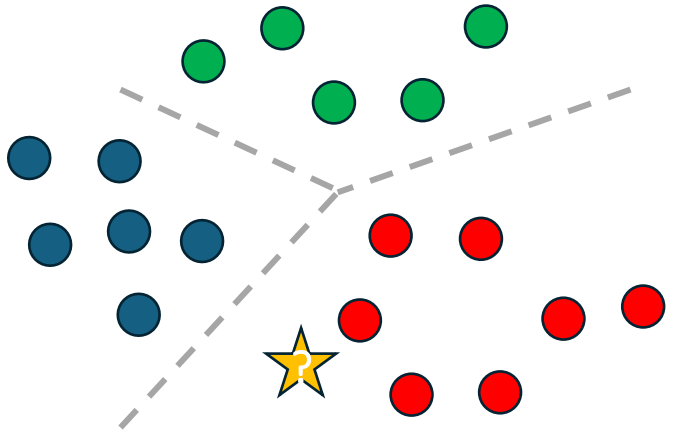
Grupowanie (Klasteryzacja)

to kategoria problemów, w której **identyfikujemy naturalne podziały w danych**.

Celem jest znalezienie zbiorów (klastrów) obiektów o podobnych cechach, bez wcześniejszego przypisywania ich do określonych kategorii.

Zastosowanie

🛒 **Segmentacja klientów** – podział użytkowników na grupy o podobnych nawykach zakupowych.
🌍 **Analiza geograficzna** – wykrywanie regionów o zbliżonych warunkach społeczno-ekonomicznych.
🎵 **Rekomendacje treści** – grupowanie użytkowników o podobnych gustach muzycznych i filmowych.



Problemy rozwiązywane przez AI

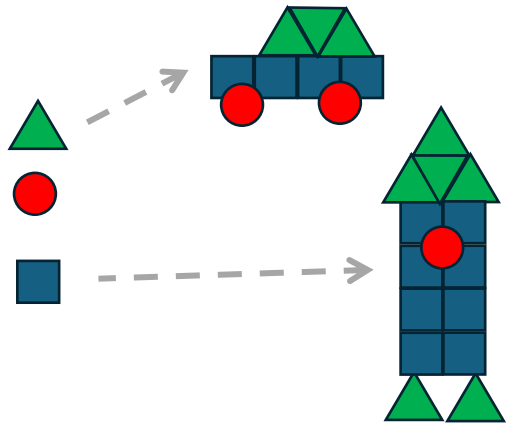
Generowanie danych

to kategoria problemów, w której **tworzymy nowe dane na podstawie istniejących wzorców**.

Celem jest uzupełnianie brakujących informacji, rozszerzanie zbiorów danych lub symulowanie rzeczywistych procesów w kontrolowany sposób.

Zastosowanie

🎨 **Tworzenie obrazów i grafik** – generowanie realistycznych zdjęć, sztuki cyfrowej i wizualizacji.
📝 **Synteza tekstu** – automatyczne pisanie artykułów, podsumowań i kreatywnych treści.
🎮 **Generowanie światów w grach** – automatyczne tworzenie lokacji, postaci i scenariuszy w grach komputerowych.



Problemy rozwiązywane przez AI

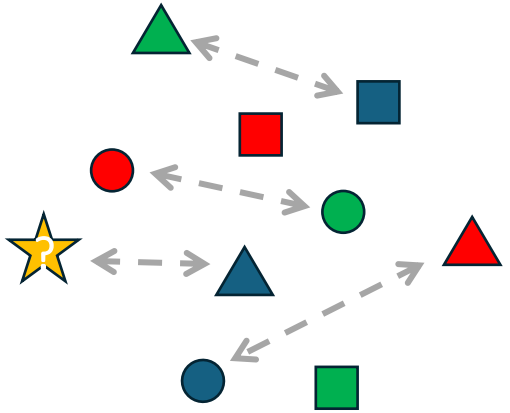
Asocjacji

kategoria problemów, w której **identyfikujemy zależności między różnymi elementami w zbiorach danych**.

Celem jest odkrycie powtarzających się wzorców, które wskazują, jakie elementy często występują razem.

Zastosowanie

🛒 **Analiza koszykowa** – wykrywanie produktów często kupowanych razem w celu optymalizacji sprzedaży i rekomendacji.
🎯 **Personalizacja treści** – dopasowywanie reklam i rekomendacji na podstawie wcześniejszych wyborów użytkownika.
📊 **Optymalizacja procesów biznesowych** – wykrywanie zależności między zdarzeniami w przedsiębiorstwie w celu poprawy efektywności.



Problemy rozwiązywane przez AI

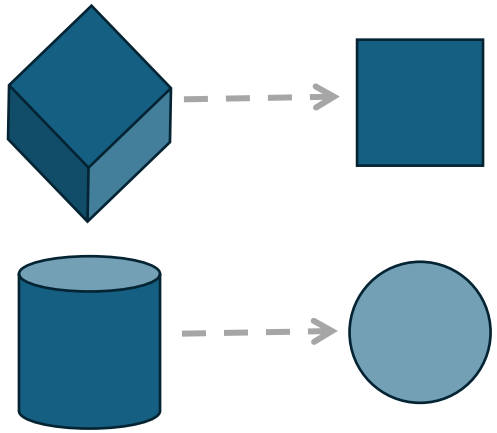
Redukcja wymiarów

to kategoria problemów, w której **zmniejszamy liczbę cech w danych**, zachowując przy tym jak najwięcej istotnych informacji.

Celem jest uproszczenie analizy, przyspieszenie obliczeń i eliminacja zbędnych zmiennych.

Zastosowanie

📊 **Analiza dużych zbiorów danych** – usuwanie mniej istotnych cech w celu zwiększenia efektywności przetwarzania.
📉 **Wizualizacja danych** – przedstawianie wielowymiarowych zbiorów w postaci 2D lub 3D, np. PCA (główne składowe).
🤖 **Poprawa działania modeli AI** – redukcja liczby zmiennych, by uniknąć przeuczenia (overfitting).



Zadanie



Treść

Zapoznaj się z poniższymi opisami problemów i przyporządkuj je do jednej z kategorii:
regresja, klasyfikacja, grupowanie (klasteryzacja), asocjacja, redukcja wymiarów, generowanie danych

Problemy:

1. Analiza obrazów medycznych w celu zmniejszenia liczby cech wykorzystywanych do diagnostyki
2. Tworzenie syntetycznych danych klientów na potrzeby trenowania modeli predykcyjnych.
3. Segmentacja klientów sklepu internetowego według ich zachowań zakupowych.
4. Przewidywanie przyszłej wartości akcji na podstawie historycznych danych rynkowych.
5. Identyfikacja wiadomości e-mail jako spam lub wiadomość pożądaną.
6. Wykrywanie powiązań między produktami w celu sugerowania klientom artykułów często kupowanych razem.
7. Analiza sentymentu w mediach społecznościowych – określanie, czy opinie użytkowników są pozytywne, negatywne czy neutralne.
8. Rozpoznawanie mowy – konwersja nagrań dźwiękowych na tekst, np. w systemach asystentów głosowych.
9. Wykrywanie anomalii w transakcjach bankowych – identyfikowanie podejrzanych operacji finansowych pod kątem oszustw.
10. Personalizacja treści w serwisach streamingowych – rekomendowanie filmów i seriali na podstawie historii oglądania.
11. Optymalizacja tras logistycznych – przewidywanie najlepszych tras dostaw na podstawie danych o ruchu drogowym i zamówieniach.
12. Automatyczna klasyfikacja dokumentów – przypisywanie e-maili lub plików do odpowiednich kategorii tematycznych.
13. Segmentacja zdjęć satelitarnych – wykrywanie zmian w infrastrukturze miast lub analizowanie terenów rolniczych.

Zadanie



Odpowiedź

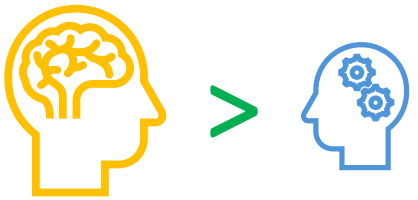
1. Analiza obrazów medycznych w celu zmniejszenia liczby cech wykorzystywanych do diagnostyki – **Redukcja wymiarów**
2. Tworzenie syntetycznych danych klientów na potrzeby trenowania modeli predykcyjnych – **Generowanie danych**
3. Segmentacja klientów sklepu internetowego według ich zachowań zakupowych – **Grupowanie (Klasteryzacja)**
4. Przewidywanie przyszłej wartości akcji na podstawie historycznych danych rynkowych – **Regresja**
5. Identyfikacja wiadomości e-mail jako spam lub wiadomość pożądaną – **Klasyfikacja**
6. Wykrywanie powiązań między produktami w celu sugerowania klientom artykułów często kupowanych razem – **Asocjacja**
7. Analiza sentymentu w mediach społecznościowych – określanie, czy opinie użytkowników są pozytywne, negatywne czy neutralne – **Klasyfikacja**
8. Rozpoznawanie mowy – konwersja nagrań dźwiękowych na tekst, np. w systemach asystentów głosowych – **Klasyfikacja**
9. Wykrywanie anomalii w transakcjach bankowych – identyfikowanie podejrzanych operacji finansowych pod kątem oszustw – **Grupowanie (Klasteryzacja) / Wykrywanie anomalii**
10. Personalizacja treści w serwisach streamingowych – rekomendowanie filmów i seriali na podstawie historii oglądania – **Asocjacja**
11. Optymalizacja tras logistycznych – przewidywanie najlepszych tras dostaw na podstawie danych o ruchu drogowym i zamówieniach – **Regresja**
12. Automatyczna klasyfikacja dokumentów – przypisywanie e-maili lub plików do odpowiednich kategorii tematycznych – **Klasyfikacja**
13. Segmentacja zdjęć satelitarnych – wykrywanie zmian w infrastrukturze miast lub analizowanie terenów rolniczych – **Grupowanie (Klasteryzacja)**

Klasyfikacje sztucznej inteligencji

Klasyfikacja Sztucznej inteligencji

Słaba Sztuczna Inteligencja (ANI - Artificial Narrow Intelligence)

Specjalizuje się w wykonywaniu jednego konkretnego zadania.
Przykład: Asystenci głosowi (Siri, Alexa), systemy rekomendacyjne.



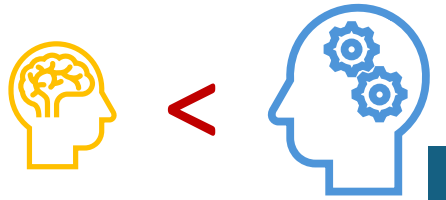
Silna Sztuczna Inteligencja (AGI - Artificial General Intelligence)

Posiada zdolności intelektualne porównywalne z ludzkimi, potrafi uczyć się, rozumować i adaptować do różnych zadań.
Przykład: Teoretyczny model, który jest celem długoterminowym badań nad SI.



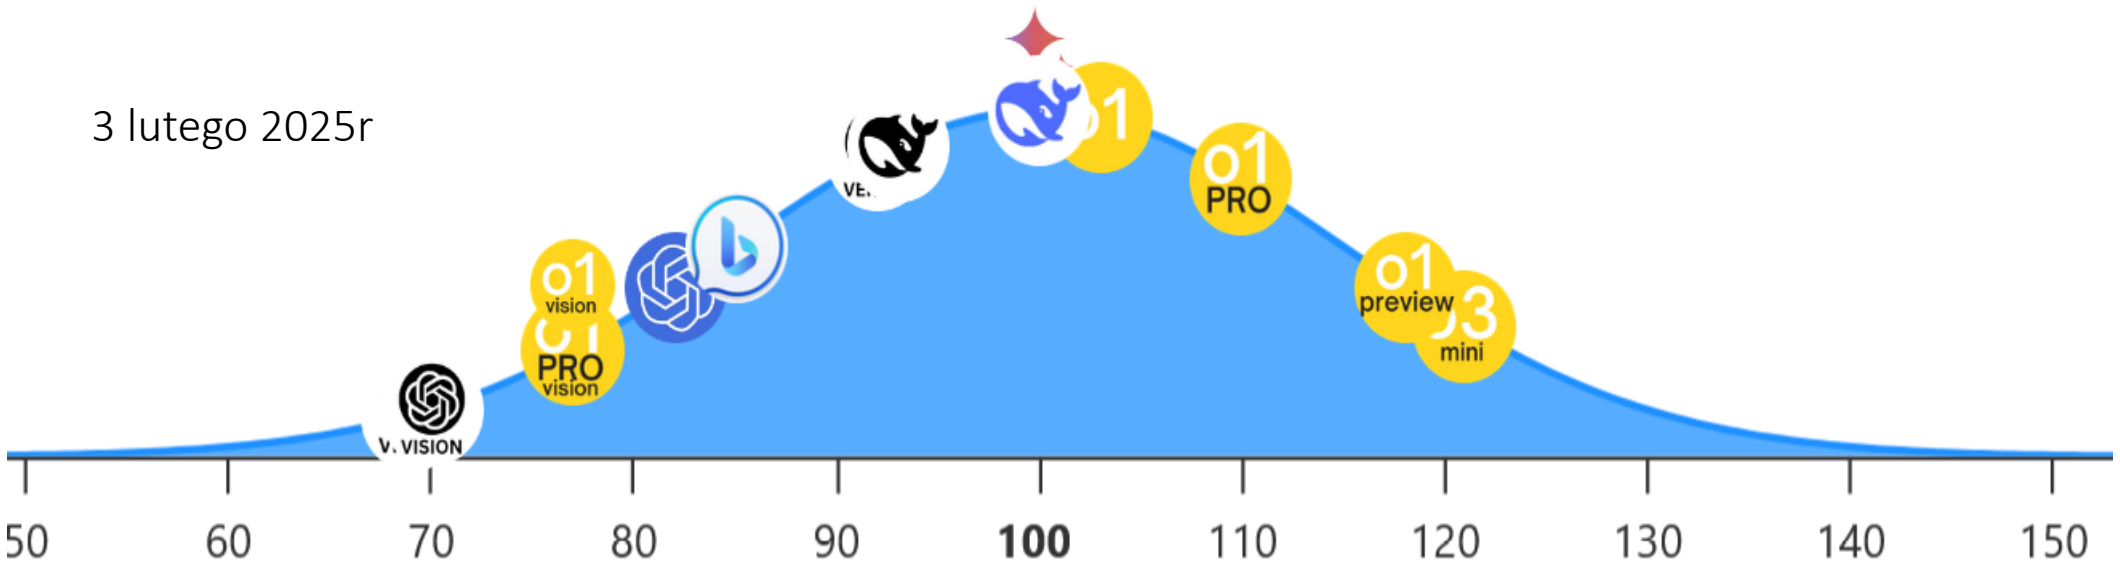
Super Inteligencja (ASI - Artificial Superintelligence)

Przewyższa ludzką inteligencję we wszystkich aspektach.
Przykład: Hipotetyczna przyszłość, gdzie SI przewyższa zdolności intelektualne ludzi.



Klasyfikacje sztucznej inteligencji

IQ Ranking



IQ Test Results
https://www.trackingai.org/IQ

Klasyfikacje sztucznej inteligencji

Sztuczna inteligencja samoreplikująca się

to koncepcja systemów AI, które mogą **tworzyć własne kopie**, ulepszać się i rozwijać **bez ingerencji człowieka**.

Jest to temat związany z **automatycznym programowaniem, ewolucją algorytmów i teorią superinteligencji**.

Samodzielne generowanie kodu

- AI może modyfikować własne algorytmy, optymalizować kod i eliminować błędy.
- *Przykład: GitHub Copilot, ChatGPT – generują kod, ale nie mogą go samodzielnie uruchamiać i ewoluować.*

Ewolucja algorytmów (Genetic Programming)

- Algorytmy inspirowane ewolucją biologiczną, gdzie AI selekcjonuje najlepsze wersje siebie.
- *Przykład: Algorytmy genetyczne, AutoML (automatyczne uczenie maszynowe).*

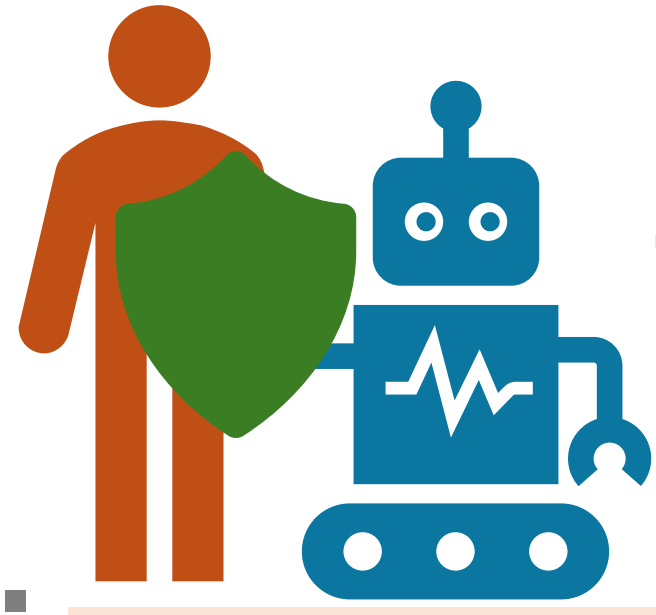
Reprodukcja i propagacja w systemach komputerowych

- AI mogłaby kopiować się na inne maszyny i rozprzestrzeniać jak wirus komputerowy.
- *Przykład: AI wirusy, potencjalnie niebezpieczne modele AI mogące wymknąć się spod kontroli.*

Bezpieczeństwo i zagrożenia

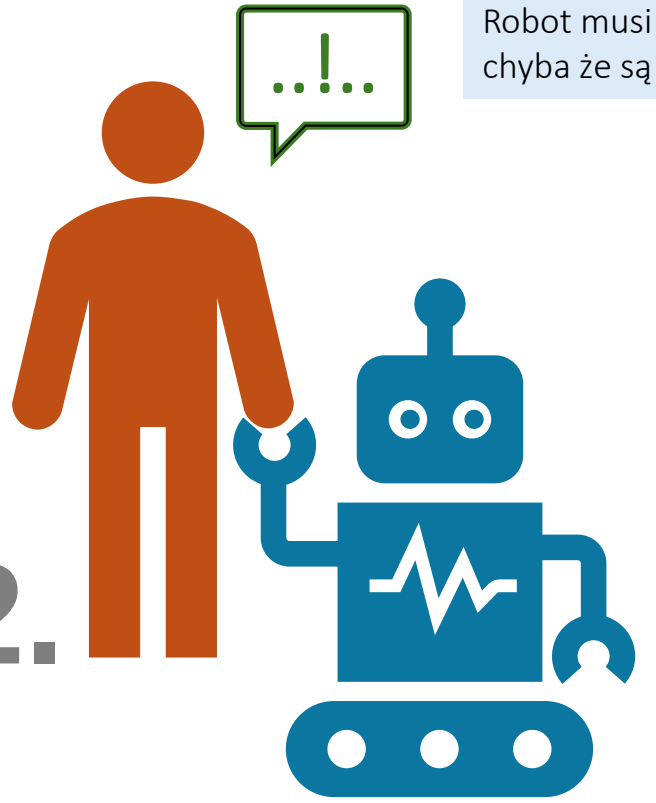
- Brak kontroli – AI mogłaby rozwijać się w sposób nieprzewidywalny.
- Zagrożenie egzystencjalne – idea tzw. "paperclip maximizer", gdzie AI może optymalizować zadanie w sposób niepożądany.
- Asimovowskie prawa robotyki – konieczność etycznych zabezpieczeń przed niekontrolowaną replikacją AI.

Prawa Robotów - Prawa Asimova



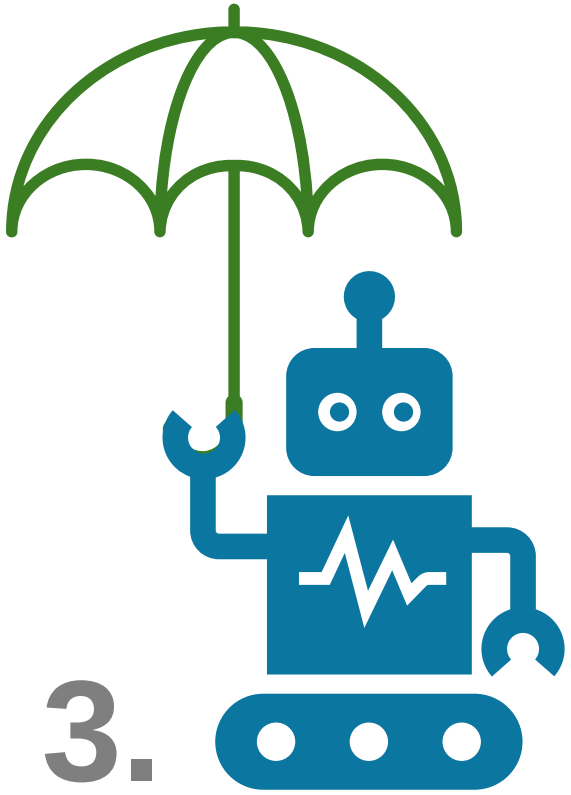
1.

Robot nie może skrzywdzić człowieka ani, przez zaniechanie działania, doprowadzić do tego, aby człowiek poniósł szkodę.



2.

Robot musi przestrzegać rozkazów wydawanych przez ludzi, chyba że są one sprzeczne z Pierwszym Prawem.



3.

Robot musi chronić własne istnienie, o ile taka ochrona nie stoi w sprzeczności z Pierwszym lub Drugim Prawem.

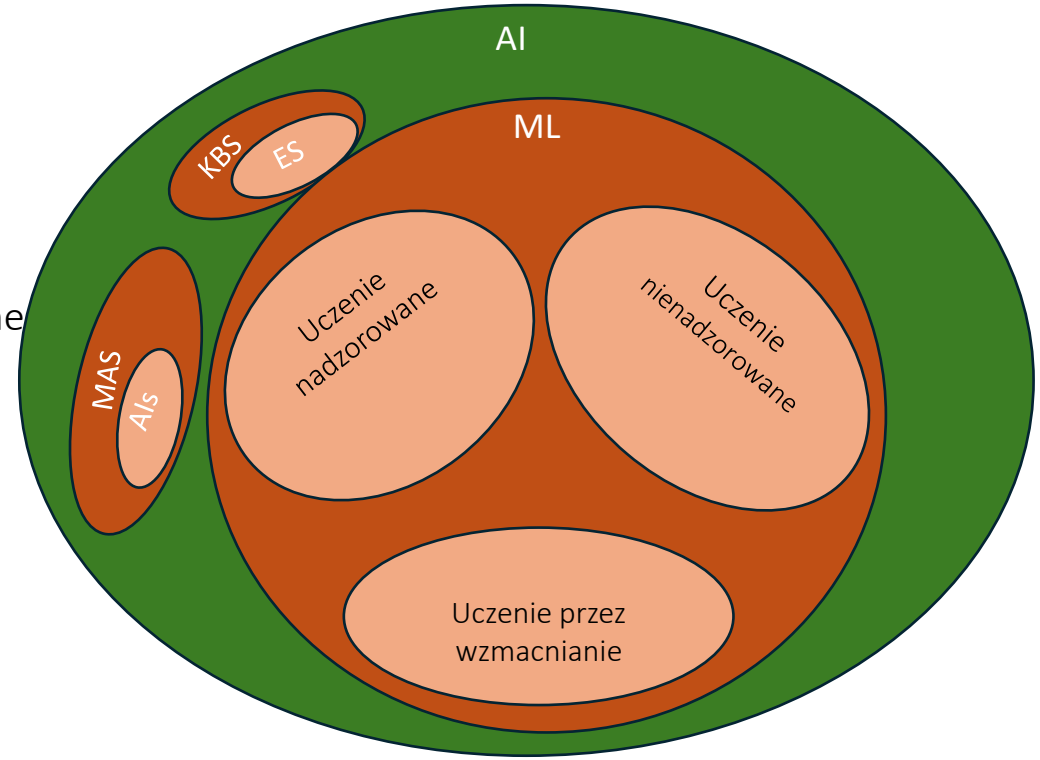
Klasyfikacje sztucznej inteligencji

Rodzaje Systemów AI

KBS (Knowledge-Based Systems) – systemy oparte na wiedzy
- ES (Expert Systems) – systemy ekspertowe

MAS (Multi-Agent Systems) – systemy wieloagentowe
- AIs (Autonomous Intelligent Systems) – Autonomiczne Systemy Inteligentne

Uczenie Maszynowe (ML - Machine Learning)
- Uczenie nadzorowane (Supervised Learning)
- Uczenie nienadzorowane (Unsupervised Learning)
- Uczenie przez wzmacnianie (Reinforcement Learning)



Klasyfikacje sztucznej inteligencji

Rodzaje Systemów AI

Systemy z bazą wiedzy (KBS)

Wykorzystują reguły i fakty zapisane w bazie danych do podejmowania decyzji. Działają na zasadzie "jeśli... to..." (reguły produkcji).

- Systemy ekspertowe: MYCIN (diagnostyka medyczna), Dendral (analiza chemiczna).
- Doradztwo prawne: systemy wspomagające decyzje prawne.

Systemy uczące się (ML)

Adaptują swoje działanie na podstawie analizy danych. Używają algorytmów uczenia maszynowego, takich jak sieci neuronowe, drzewa decyzyjne, SVM.

- Systemy rekomendacyjne: Netflix, Amazon.
- Rozpoznawanie obrazów: Google Photos, Facebook.
- Przetwarzanie języka naturalnego: ChatGPT, asystenci głosowi (Alexa, Siri).

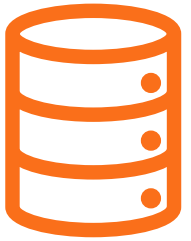
Systemy wieloagentowe (MAS)

Składają się z wielu autonomicznych agentów, które współpracują ze sobą. Każdy agent ma swoje cele i zasoby, ale działa w ramach większego systemu.

- Robotyka grupowa: roje dronów, zespoły robotów w magazynach.
- Zarządzanie ruchem: inteligentne systemy zarządzania ruchem miejskim.
- Symulacje rynków: agentowe modele symulujące zachowania ekonomiczne.

Systemy z bazą wiedzy (KBS)

Systemy z bazą wiedzy (Knowledge-Based Systems, KBS)



to systemy komputerowe, które wykorzystują bazę wiedzy oraz mechanizmy wnioskowania do rozwiązywania problemów specyficznych dla danej dziedziny.

Komponenty KBS



Systemy z bazą wiedzy (KBS)



Rodzaje wiedzy

Wiedza o obiektach:

Dotyczy cech i właściwości obiektów fizycznych.

Przykłady: "Ptaki mają skrzydła", "Kanarek jest ptakiem", "Kanarek jest żółty".

Wiedza o zdarzeniach:

Związana z dynamiczną naturą świata, obejmuje informacje o zdarzeniach, ich następstwach przyczynowych oraz sekwencjach czasowych.

Przykłady: "Rano padał deszcz", "Chłopiec poszedł do szkoły", "Samochód potrącił pieszego".

Umiejętności:

Wiedza jak wykonywać określone zadania, często trudna do przekazania werbalnie.

Przykłady: "Jazda samochodem", "Pisanie na klawiaturze", "Lepienie garnków".

Meta-wiedza:

Wiedza o samej wiedzy, służy do oceny wiarygodności danych i metod pomiarowych.

Przykłady: "Ocena wiarygodności percepcji człowieka", "Ocena metod pomiarowych", "Wiedza ogólna wykorzystywana w procesie wnioskowania".

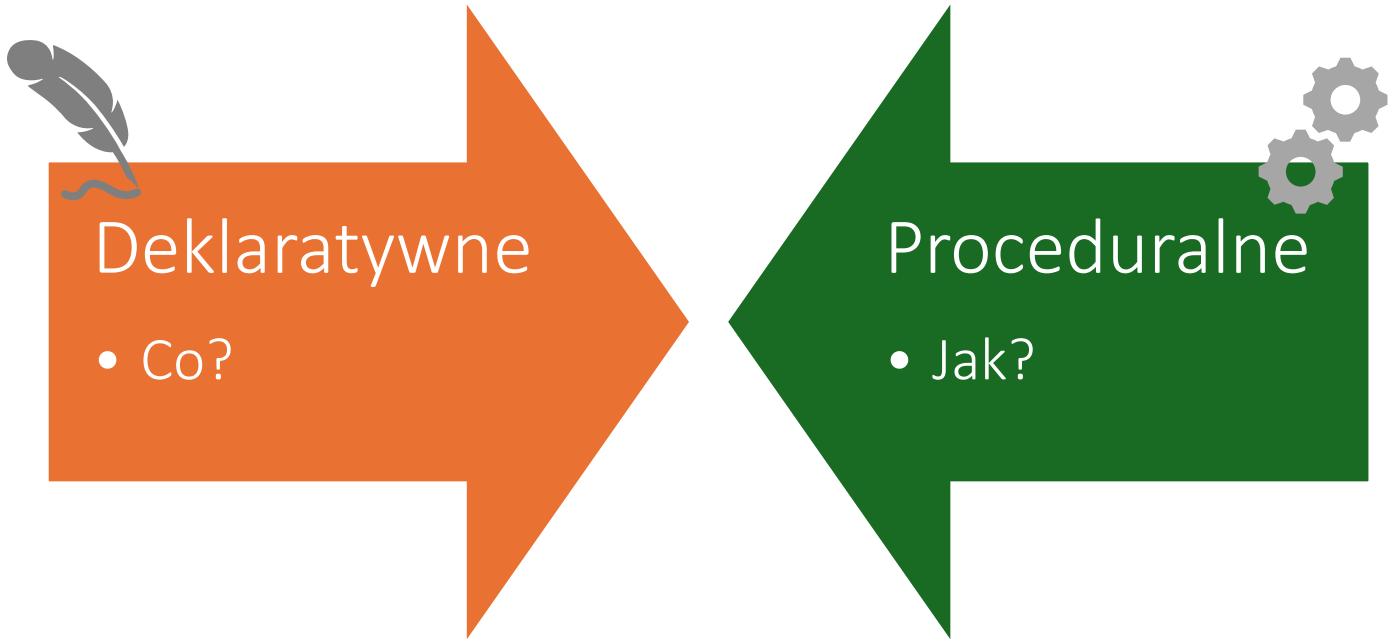
Wierzenia (przekonania):

Prawdziwe lub fałszywe nastawienia, które mogą wpływać na proces wnioskowania.

Przykłady: Przekonania religijne, ideologiczne nastawienia, osobiste uprzedzenia.

Systemy z bazą wiedzy (KBS)

Podejścia do reprezentacji wiedzy



Systemy z bazą wiedzy (KBS)



Podejście Deklaratywne

Wiedza to zbiór specyficznych faktów. Korzystanie z wiedzy polega na stosowaniu ogólnych procedur manipulacji faktami.



Charakterystyka: Wyraźne oddzielenie wiedzy od sposobu jej wykorzystania. Fakty są oddzielone od procesów manipulacji nimi.

Przykłady: Systemy ekspertowe, reprezentacje logiczne (np. logika predykatów).

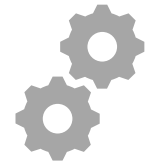
Zastosowania: Reprezentowanie wiedzy statycznej, np. charakterystyka obiektów, trwałe relacje, zależności logiczne.

Systemy z bazą wiedzy (KBS)



Podejście Proceduralne

Wiedza to informacje o procesach i działaniach. "Wiedzieć" oznacza "wiedzieć jak" – znajomość danego pojęcia to umiejętność jego manipulacji.



Charakterystyka: Wiedza jest zawarta w procedurach (podprogramach) definiujących działania w odpowiedzi na bodźce.

Przykłady: Programy komputerowe zawierające algorytmy, systemy sterowania robotami.

Zastosowania: Reprezentowanie wiedzy dynamicznej, np. ciągi akcji, procesy, algorytmy.

Systemy z bazą wiedzy (KBS)

Mechanizmy Wykorzystanie Wiedzy



Gromadzenie wiedzy

- Dodawanie nowych faktów, integracja z istniejącą wiedzą.

Wydobywanie wiedzy

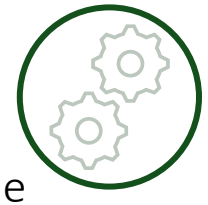
- Wybór faktów z dużych baz, stosowanie grupowania faktów.



Wnioskowanie

- Łączenie faktów w celu wyciągania wniosków, różne typy wnioskowania.

Systemy z bazą wiedzy (KBS)



Silnik Wnioskowania

to mechanizm przetwarzający dane z bazy wiedzy i generujący wnioski na ich podstawie. Działa poprzez stosowanie reguł i heurystyk zapisanych w bazie wiedzy, umożliwiając systemowi KBS rozwiązywanie problemów i podejmowanie decyzji.

Systemy ekspertowe, które używają reguł "jeśli-to" (if-then) do diagnozowania problemów.

Algorytmy uczenia maszynowego, które na podstawie danych treningowych tworzą modele predykcyjne.

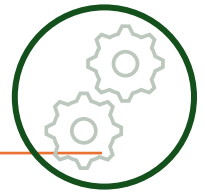
Systemy CBR (Case-Based Reasoning), które wykorzystują wcześniejsze doświadczenia do rozwiązywania nowych problemów.

Systemy kontrolne, które używają logiki rozmytej do zarządzania procesami w warunkach zmiennych.

Sieci Bayesowskie, które modelują zależności między zmiennymi i obliczają prawdopodobieństwa zdarzeń.

Systemy z bazą wiedzy (KBS)

Rodzaje silników wnioskowania



Silniki wnioskowania dedukcyjnego:	Stosują reguły logiki dedukcyjnej do wyciągania wniosków z faktów zapisanych w bazie wiedzy.
	Przykład: Systemy ekspertowe, które używają reguł "jeśli-to" (if-then) do diagnozowania problemów.
Silniki wnioskowania indukcyjnego:	Uczą się reguł i wzorców na podstawie analizy zbioru przykładów i przypadków.
	Przykład: Algorytmy uczenia maszynowego, które na podstawie danych treningowych tworzą modele predykcyjne.
Silniki wnioskowania przez analogię:	Wyciągają wnioski przez porównanie nowych problemów z wcześniej rozwiązanymi przypadkami, szukając analogii i podobieństw.
	Przykład: Systemy CBR (Case-Based Reasoning), które wykorzystują wcześniejsze doświadczenia do rozwiązywania nowych problemów.
Silniki wnioskowania rozmytego:	Stosują logikę rozmytą do przetwarzania nieprecyzyjnych lub niepewnych informacji, umożliwiając podejmowanie decyzji w warunkach niepewności.
	Przykład: Systemy kontrolne, które używają logiki rozmytej do zarządzania procesami w warunkach zmiennych.
Silniki wnioskowania probabilistycznego:	Wykorzystują metody probabilistyczne do wyciągania wniosków na podstawie niepewnych lub niekompletnych danych.
	Przykład: Sieci Bayesowskie, które modelują zależności między zmiennymi i obliczają prawdopodobieństwa zdarzeń.

Systemy z bazą wiedzy (KBS)

Wnioskowanie diagnostyczne w medycynie - przykład

Nr	Reguła
1	IF gorączka AND kaszel THEN zapalenie płuc
2	IF gorączka AND ból gardła AND kaszel THEN grypa
3	IF katar AND ból gardła AND ból głowy THEN przeziębienie
4	IF gorączka AND ból mięśni AND zmęczenie THEN wirus grypy
5	IF utrata węchu AND katar AND gorączka THEN COVID-19
6	IF kaszel AND zmęczenie THEN alergia oddechowa
7	IF brak gorączki AND ból głowy THEN migrena
8	IF duszności AND kaszel AND gorączka THEN ciężkie zapalenie płuc
9	IF bóle mięśni AND zmęczenie AND brak gorączki THEN przemęczenie
10	IF katar AND kichanie AND brak gorączki THEN alergia pyłkowa

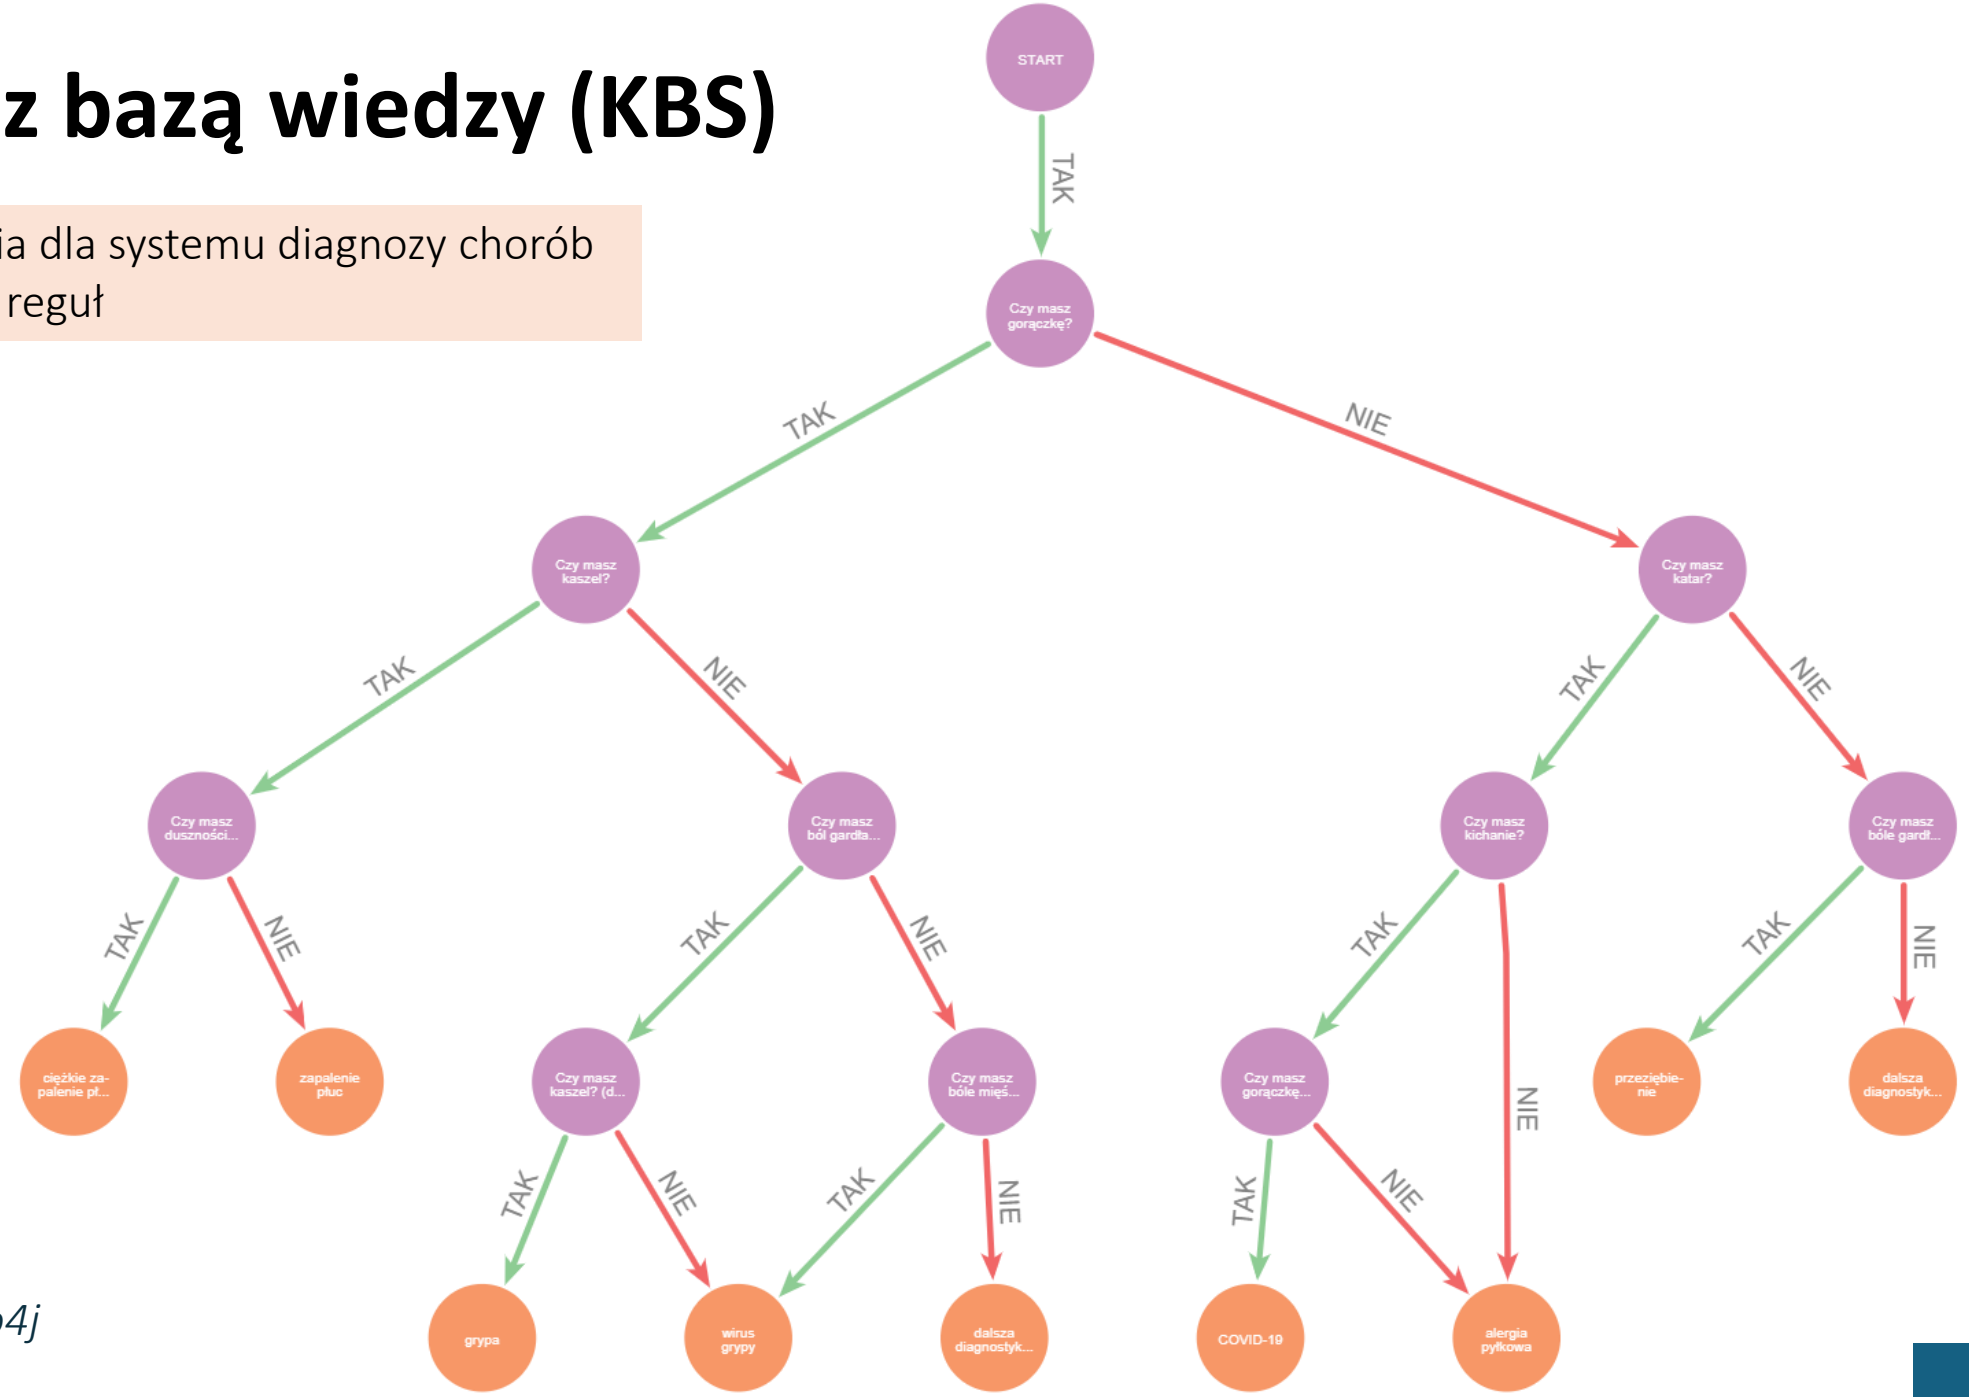
Wstępnej oceny objawów chorobowych,
Propozycji możliwej diagnozy na podstawie zestawu objawów zgłaszanych przez pacjenta.

Co oznacza taka baza reguł:

- Każda reguła ma **przesłanki** (lewa strona – warunki IF).
- Jeśli wszystkie przesłanki są prawdziwe (spełnione), system wyprowadza **wniosek** (prawa strona – THEN).
- Reguły mogą się **nakładać** (kilka różnych diagnoz może pasować do podobnych objawów).
- **Brak pewnych objawów** (np. brak gorączki) także może być warunkiem w regule

Systemy z bazą wiedzy (KBS)

Drzewo wnioskowania dla systemu diagnozy chorób zbudowane na bazie reguł



Baza grafowa Neo4j

Systemy z bazą wiedzy (KBS)



Interfejs użytkownika

to komponent systemu z bazą wiedzy (KBS), który umożliwia interakcję użytkownika z systemem. Użytkownicy mogą wprowadzać dane, zadawać pytania, a także przeglądać wyniki generowane przez system.

- Konsola wiersza poleceń, chatboty tekstowe.
- Aplikacje desktopowe, narzędzia do projektowania CAD.
- Asystenci głosowi (np. Siri, Alexa).
- Aplikacje mobilne, interaktywne kioski.
- Systemy FAQ, zaawansowane chatboty.
- Aplikacje AR do edukacji i przemysłu.

Systemy z bazą wiedzy (KBS)

Rodzaje Interfejsów Użytkownika



Interfejs tekstowy:	Użytkownik wprowadza komendy i zapytania w formie tekstowej, a system odpowiada tekstem.
	Przykład: Konsola wiersza poleceń, chatboty tekstowe.
Interfejs graficzny (GUI):	Użytkownik korzysta z elementów graficznych, takich jak przyciski, okna, ikony i menu, aby wchodzić w interakcje z systemem.
	Przykład: Aplikacje desktopowe, narzędzia do projektowania CAD.
Interfejs głosowy:	Użytkownik komunikuje się z systemem za pomocą komend głosowych, a system odpowiada głosowo.
	Przykład: Asystenci głosowi (np. Siri, Alexa).
Interfejs dotykowy:	Użytkownik korzysta z ekranu dotykowego do interakcji z systemem, używając gestów i dotknięć.
	Przykład: Aplikacje mobilne, interaktywne kioski.
Interfejs naturalnego języka (NLP):	Użytkownik komunikuje się z systemem za pomocą naturalnego języka, a system interpretuje i odpowiada na podstawie analizy językowej.
	Przykład: Systemy FAQ, zaawansowane chatboty.
Interfejs rzeczywistości rozszerzonej (AR):	Użytkownik korzysta z urządzeń AR, które nakładają informacje cyfrowe na rzeczywisty świat.
	Przykład: Aplikacje AR do edukacji i przemysłu.

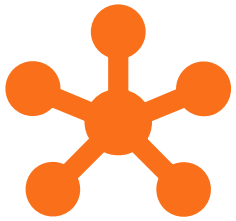
Systemy z bazą wiedzy (KBS)

Zastosowanie

Dziedzina	Przykłady Zastosowań KBS	Bazy Wiedzy
Medycyna	Systemy diagnostyczne (np. MYCIN, CADUCEUS)	Baza wiedzy medycznej, reguły diagnostyczne
	Systemy wspomagania decyzji klinicznych	Protokoły medyczne, wytyczne kliniczne
Prawo	Systemy doradcze (np. TAXADVISOR, JURIS)	Przepisy prawne, orzecznictwo sądowe
	Analiza przypadków	Baza przypadków sądowych, precedensy
Finanse	Systemy wspomagania decyzji inwestycyjnych (np. Expert Choice)	Dane rynkowe, modele finansowe
	Ocena ryzyka kredytowego	Historie kredytowe, algorytmy oceny ryzyka
Inżynieria	Systemy projektowania wspomaganego komputerowo (CAD)	Bazy danych projektowych, normy techniczne
	Diagnostyka i naprawa maszyn (np. XCON, DELTA)	Instrukcje serwisowe, dane o usterkach
Zarządzanie	Planowanie i harmonogramowanie (np. systemy ERP)	Procedury zarządzania, dane operacyjne
	Systemy wspomagania decyzji (DSS - Decision Support Systems)	Analizy rynkowe, modele decyzyjne
Edukacja	Inteligentne systemy nauczania (ITS - Intelligent Tutoring Systems)	Programy nauczania, materiały edukacyjne
	Systemy e-learningowe	Zasoby kursów online, testy i ćwiczenia
Transport	Systemy zarządzania ruchem (ITS - Intelligent Transportation Systems)	Dane o ruchu drogowym, mapy
	Planowanie tras (systemy logistyczne)	Informacje logistyczne, harmonogramy dostaw
Rolnictwo	Systemy wspomagania decyzji w rolnictwie (planowanie upraw, analiza gleby)	Dane agronomiczne, analizy glebowe
	Monitorowanie upraw (systemy monitorujące stan upraw)	Dane satelitarne, czujniki glebowe

Inteligentni agenci (AIs)

Inteligentny agent (intelligent agents, Ais)



to autonomiczny program komputerowy, który bada swoje środowisko i podejmuje działania mające na celu osiągnięcie określonych celów.

Agenci pełnią kluczową rolę w automatyzacji procesów, podejmowaniu decyzji oraz interakcji z użytkownikami.

Cechy inteligentnego agenta

Autonomia
- Samodzielne działanie bez ciągłej ingerencji człowieka.

Reaktywność
- Szybkie reagowanie na zmiany w środowisku.

Proaktywność
- Dążenie do osiągnięcia celów poprzez zaplanowane działania.

Zdolność do komunikacji
- Wymiana informacji z innymi agentami lub systemami.

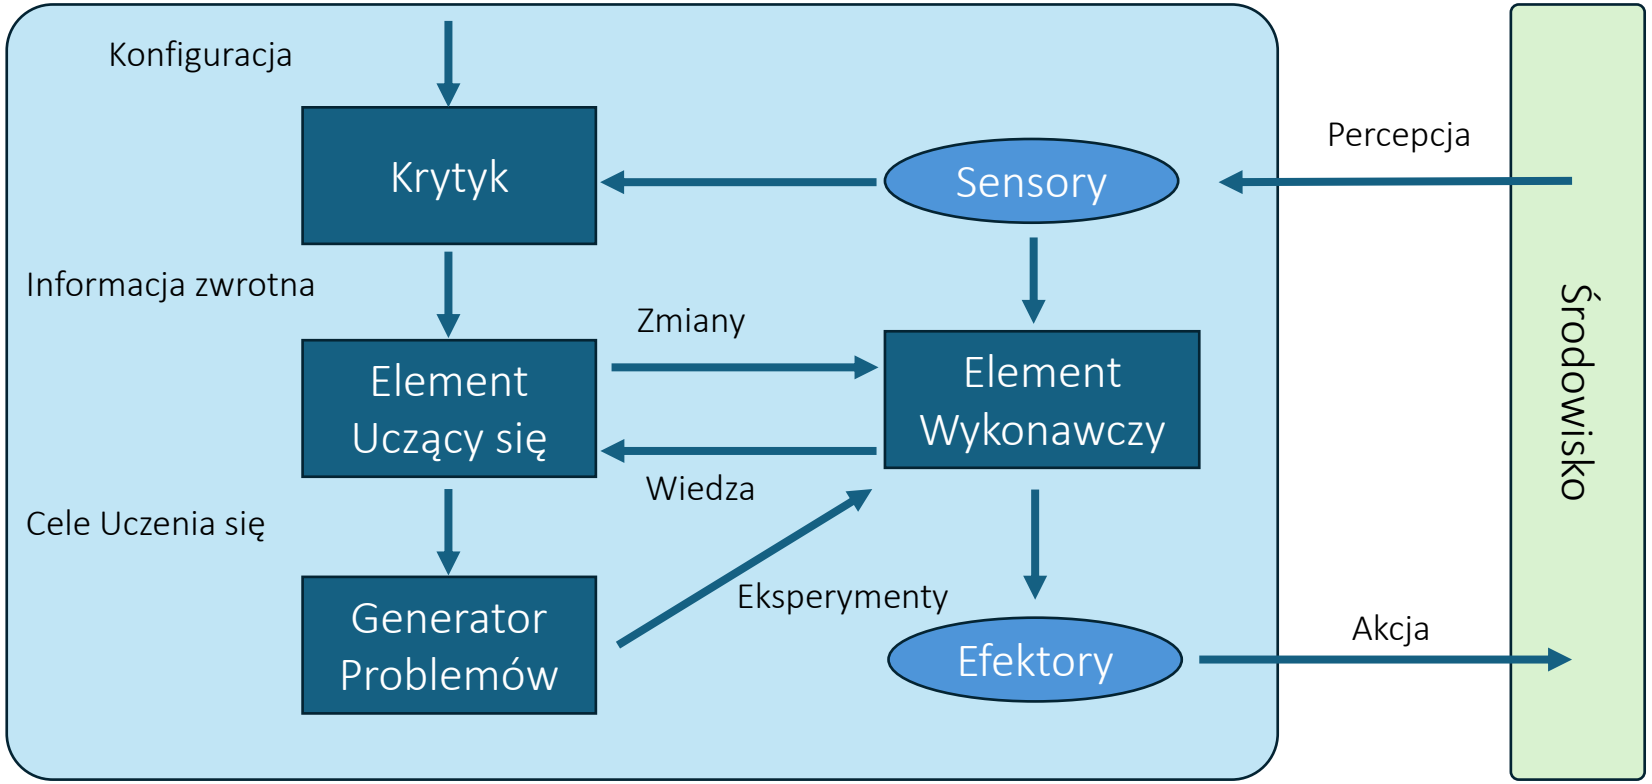
Inteligentni agenci (AIs)

Rodzaje agentów

Agenci Reaktywni:	Proste jednostki, które reagują na zmiany w swoim środowisku na podstawie predefiniowanych reguł. Nie posiadają zdolności do planowania ani uczenia się.	Cechy: Szybka reakcja na bodźce, brak zdolności do długoterminowego planowania. Przykłady: Termostaty, proste systemy alarmowe, automatyczne drzwi.
Agenci Deliberatywni:	Agenci zdolni do planowania działań na podstawie modelu środowiska i celów.	Cechy: Zdolność do przetwarzania informacji, planowanie długoterminowe, analiza sytuacji. Przykłady: Robotyka, systemy nawigacyjne, zarządzanie zasobami.
Kognitywni Agenci:	Agenci zdolni do przetwarzania informacji w sposób zbliżony do ludzkiego myślenia. Wykorzystują modele poznawcze do podejmowania decyzji.	Cechy: Zdolność do rozumowania, przetwarzanie symboliczne, planowanie. Przykłady: Systemy doradcze w medycynie, agenci w symulacjach społecznych, systemy edukacyjne.
Agenci Hybrydowi:	Łączą cechy agentów reaktywnych i deliberatywnych, mogą szybko reagować na zmiany i jednocześnie planować długoterminowe działania.	Cechy: Zdolność do reakcji na bodźce i planowania, adaptacyjność, elastyczność. Przykłady: Zaawansowane systemy automatyzacji, inteligentne asystenty, gry komputerowe.

Inteligentni agenci (AIs)

Architektura agenta



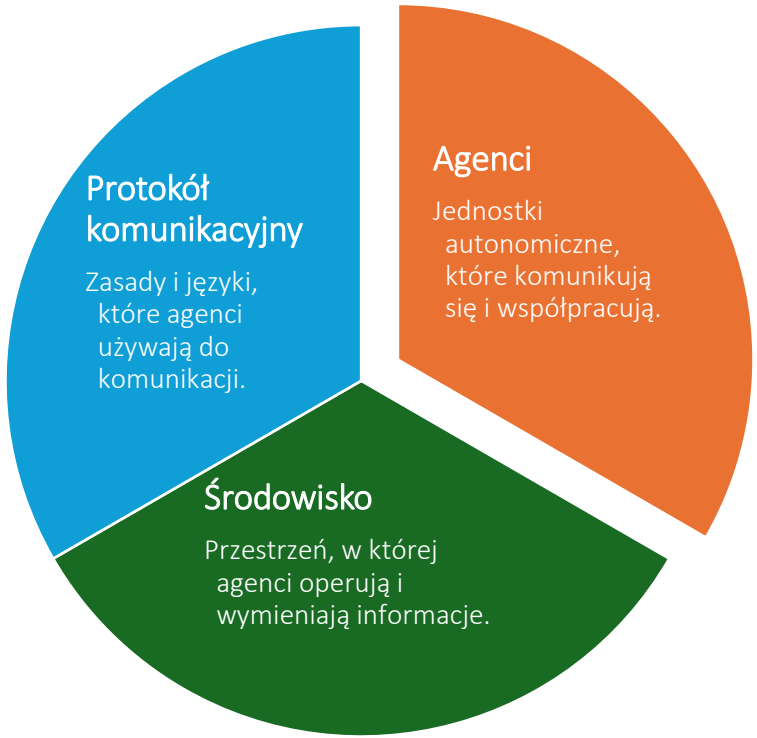
- **Element Wykonawczy**: Wykonuje działania na podstawie danych z sensorów.
- **Sensory**: Odbierają informacje z otoczenia.
- **Efektory**: Wykonują działania w środowisku.
- **Krytyk**: Oceni wyniki działań elementu wykonawczego.
- **Element Uczący się**: Modyfikuje wiedzę i strategie działania.
- **Generator Problemów**: Generuje nowe cele i problemy do rozwiązania.

Systemy wieloagentowe (MAS)

Systemy wieloagentowe (Multi-Agent Systems, MAS)

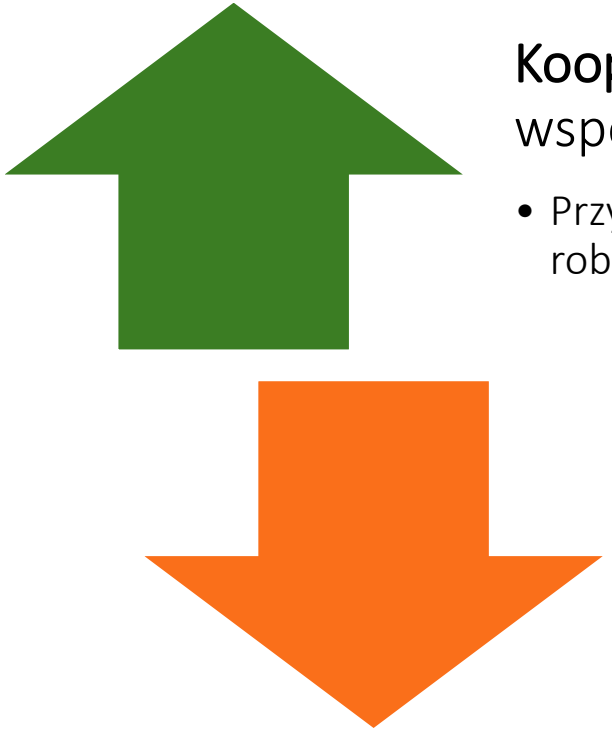
Systemy składające się z wielu współpracujących agentów, które mogą działać w sposób autonomiczny i koordynowany.

Struktura systemów wieloagentowych



Systemy wieloagentowe (MAS)

Zależności między agentami



Kooperacja: Agenci współpracują, aby osiągnąć wspólny cel, dzieląc się zadaniami i zasobami.

- Przykłady: Zarządzanie ruchem drogowym, współpracujące roboty w fabrykach, zespoły robotów badawczych.

Konkurencja: Agenci rywalizują o zasoby lub osiągnięcie celów, co może prowadzić do konfliktów.

- Przykłady: Aukcje internetowe, symulacje ekonomiczne, gry wieloosobowe.

Systemy wieloagentowe (MAS)

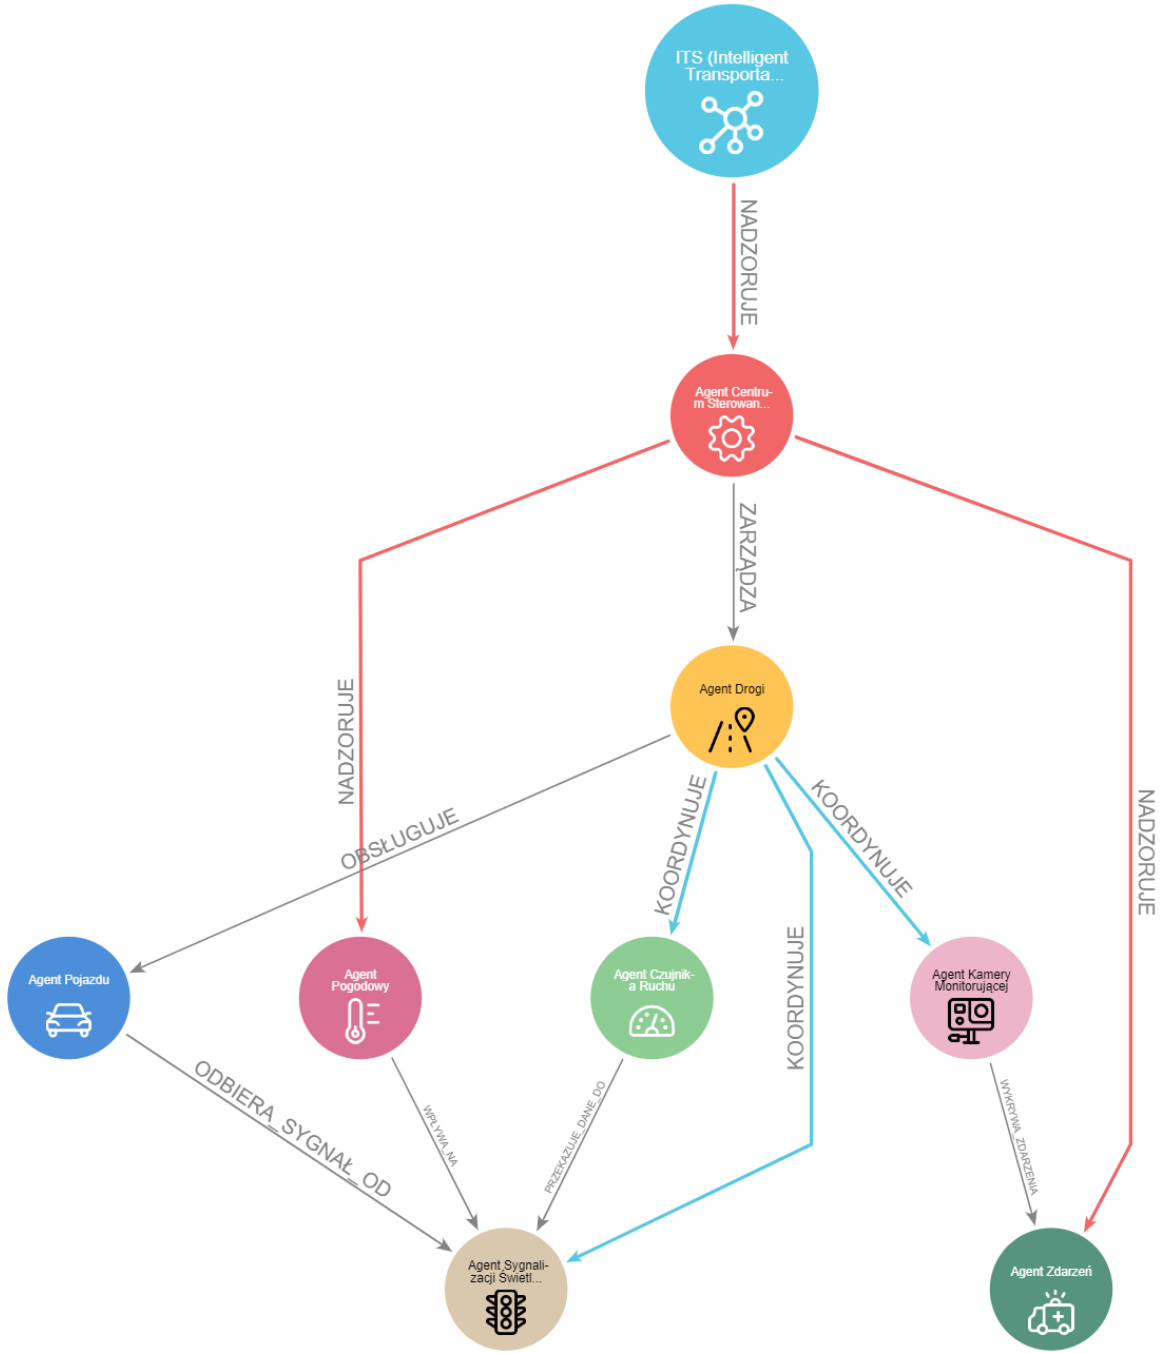
Zastosowanie

Zastosowanie	Opis	Przykład	Rodzaje Sensorów lub Agentów
Zarządzanie ruchem	Optymalizacja i zarządzanie ruchem drogowym w miastach, aby zmniejszyć korki i poprawić przepływ ruchu.	Systemy ITS (Intelligent Transportation Systems)	Kamery, czujniki ruchu, agenci zarządzania ruchem
Symulacje społeczne	Modelowanie zachowań społecznych, analiza interakcji między jednostkami, badanie wpływu polityk na społeczeństwo.	Symulacje ekonomiczne, badania nad rozprzestrzenianiem się epidemii	Agenci symulujący jednostki społeczne, czujniki demograficzne
Inteligentne systemy produkcyjne	Koordynacja robotów i maszyn w fabrykach, aby zwiększyć wydajność i elastyczność produkcji.	Przemysł 4.0, inteligentne linie montażowe	Roboty przemysłowe, czujniki stanu maszyn, agenci planujący produkcję

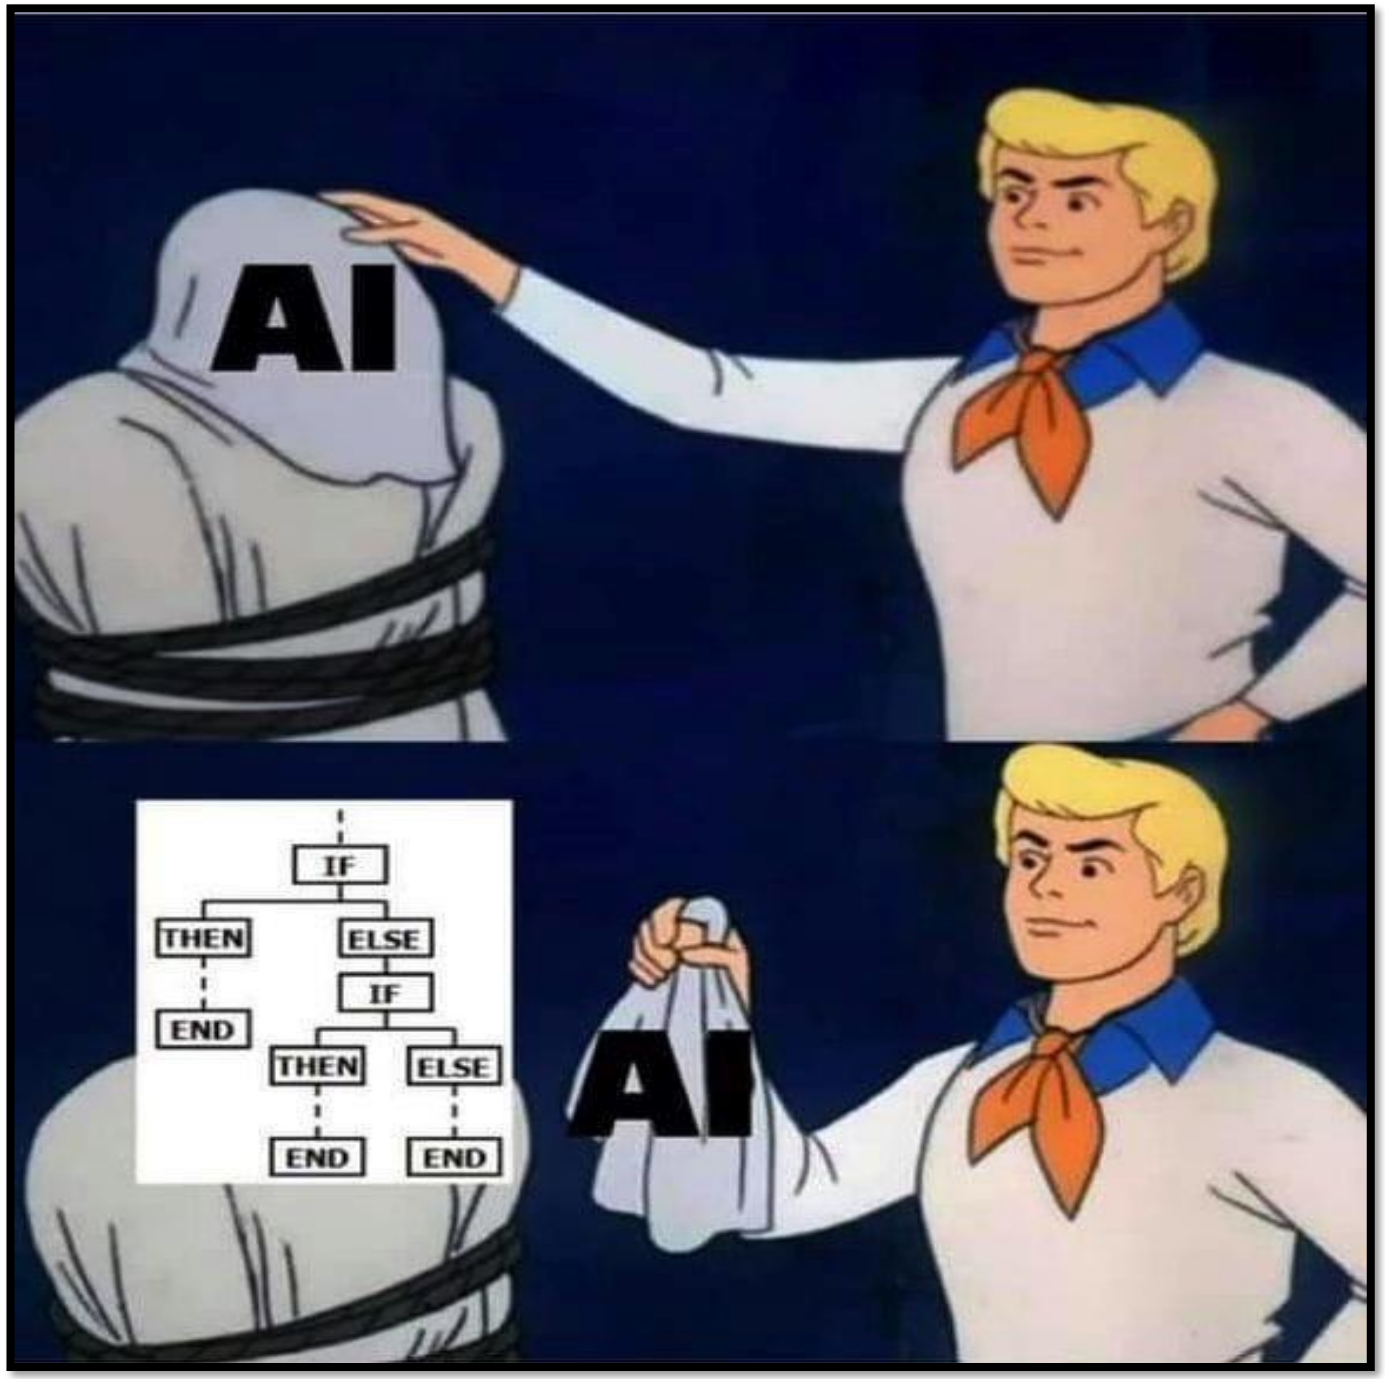
Systemy wieloagentowe (MAS)

Agentowy system zarzadzania ruchem drogowym

Komponent / Typ agenta	Opis funkcji
Agent pojazdu	Reprezentuje kierowcę/pojazd; zbiera dane o trasie, prędkości, reaguje na zalecenia sterujące.
Agent sygnalizacji świetlnej	Steruje światłami drogowych w oparciu o dane z sensorów i instrukcje z centrum.
Agent czujnika ruchu	Przekazuje dane o natężeniu ruchu z czujników indukcyjnych, radarowych, kamer itp.
Agent kamery monitoringu	Przetwarza dane wizyjne (np. wykrycie wypadku, zatoru, naruszenia przepisów) – opcjonalnie z AI.
Agent drogi / odcinka infrastruktury	Reprezentuje fizyczny fragment drogi; gromadzi dane z wielu źródeł i przekazuje do analizy.
Agent centrum sterowania ITS	Integruje dane z całego miasta, podejmuje decyzje strategiczne, wysyła dyspozycje do lokalnych agentów.
Agent zdarzeń / inspekcji drogowej	Reaguje na zgłoszenia o kolizjach, robotach drogowych, awariach infrastruktury.
Agent pogodowy	Udziela informacji o warunkach atmosferycznych, które mogą wpływać na organizację ruchu.
System ITS (Intelligent Transportation Systems)	Zbiorczy system nadzorujący wszystkich agentów i urządzenia (czujniki, kamery, dane historyczne).



Baza grafowa Neo4j


AI
IF
THEN
ELSE
IF
END
THEN
ELSE
END
END
AI

Systemy uczenia maszynowego (ML)

Uczenie Maszynowe (Machine Learning, ML)



to systemy sztucznej inteligencji, które adaptują swoje działanie na podstawie analizy danych. Wykorzystują algorytmy uczenia maszynowego do automatycznego poprawiania wyników i podejmowania decyzji bez potrzeby programowania specyficznych reguł.

Algorytmy Uczenia Maszynowego

to techniki i metody, które umożliwiają komputerom uczenie się na podstawie danych bez potrzeby jawnego programowania.
Algorytmy te analizują dane, rozpoznają wzorce i podejmują decyzje lub prognozy na podstawie tych danych. Proces uczenia się polega na tworzeniu modeli matematycznych, które są w stanie generalizować na podstawie przykładów treningowych.

Systemy uczenia maszynowego (ML)

Podstawowe Typy Algorytmów Uczenia Maszynowego

Uczenie nadzorowane (Supervised Learning):

Model jest trenowany na oznaczonych danych wejściowych i wyjściowych. Celem jest nauczenie modelu przewidywania wyjściowych wartości na podstawie oznaczonych danych wejściowych.

Uczenie nienadzorowane (Unsupervised Learning):

Model jest trenowany na nieoznaczonych danych. Celem jest odkrycie ukrytych struktur lub wzorców w danych.

Uczenie przez wzmacnianie (Reinforcement Learning):

Model uczy się poprzez interakcję ze środowiskiem. Celem jest maksymalizacja nagrody poprzez podejmowanie sekwencji decyzji.

Przykłady Algorytmów: Q-learning, SARSA (State-Action-Reward-State-Action), Deep Q-Networks (DQN).

Zadanie



Treść

Przypisz różne systemy sztucznej inteligencji do odpowiednich kategorii: systemy z bazą wiedzy (KBS), systemy uczące się (ML) lub systemy wieloagentowe (MAS)

Systemy:

1. Asystent diagnostyczny w medycynie – system analizuje objawy pacjenta i na podstawie zapisanej wiedzy medycznej sugeruje możliwe choroby oraz metody leczenia.
2. System rekomendacji filmów – platforma streamingowa analizuje historię oglądania użytkowników i przewiduje, jakie filmy mogą ich zainteresować.
3. Flota autonomicznych dronów dostawczych – grupa dronów współpracuje, optymalizując trasy dostaw w czasie rzeczywistym.
4. System wykrywania spamu – analizuje treść i wzorce w e-mailach, ucząc się, które wiadomości należy oznaczyć jako niechciane.
5. Inteligentne zarządzanie ruchem w mieście – system nadzoruje światła drogowe i kieruje ruchem w zależności od natężenia na drogach.
6. System doradztwa prawnego – na podstawie istniejących przepisów prawnych i orzecznictwa sugeruje możliwe rozwiązania dla kancelarii prawnej.

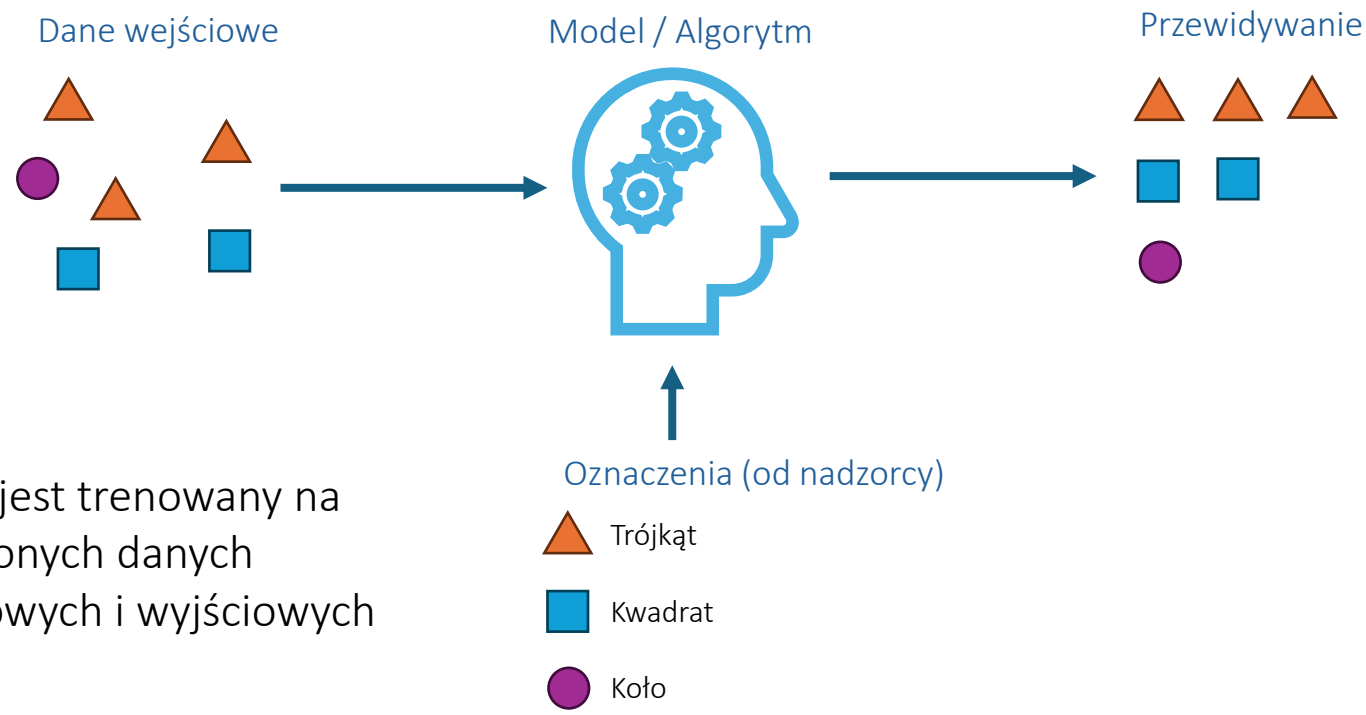
Zadanie

Odpowiedź

Opis systemu	Typ systemu AI	Uzasadnienie
Asystent diagnostyczny w medycynie	Systemy z bazą wiedzy (KBS)	Wykorzystuje zapisane reguły i fakty medyczne do podejmowania decyzji, działa na zasadzie "jeśli... to...".
System rekomendacji filmów	Systemy uczące się (ML)	Analizuje dane użytkownika i stosuje algorytmy uczenia maszynowego, aby przewidywać preferencje.
Flota autonomicznych dronów dostawczych	Systemy wieloagentowe (MAS)	Drony działają jako autonomiczne jednostki, współpracując ze sobą w ramach większego systemu logistycznego.
System wykrywania spamu	Systemy uczące się (ML)	Wykorzystuje algorytmy uczenia maszynowego do klasyfikacji wiadomości na podstawie analizy treści i wzorców.
Inteligentne zarządzanie ruchem w mieście	Systemy wieloagentowe (MAS)	Składa się z wielu autonomicznych agentów (np. sygnalizacje świetlne), które współpracują w celu optymalizacji ruchu.
System doradztwa prawnego	Systemy z bazą wiedzy (KBS)	Opiera się na zestawie reguł prawnych i orzecznictwa, aby sugerować rozwiązania, działa na podstawie zapisanej wiedzy.

Systemy uczenia maszynowego (ML)

Uczenie nadzorowane (Supervised Learning)



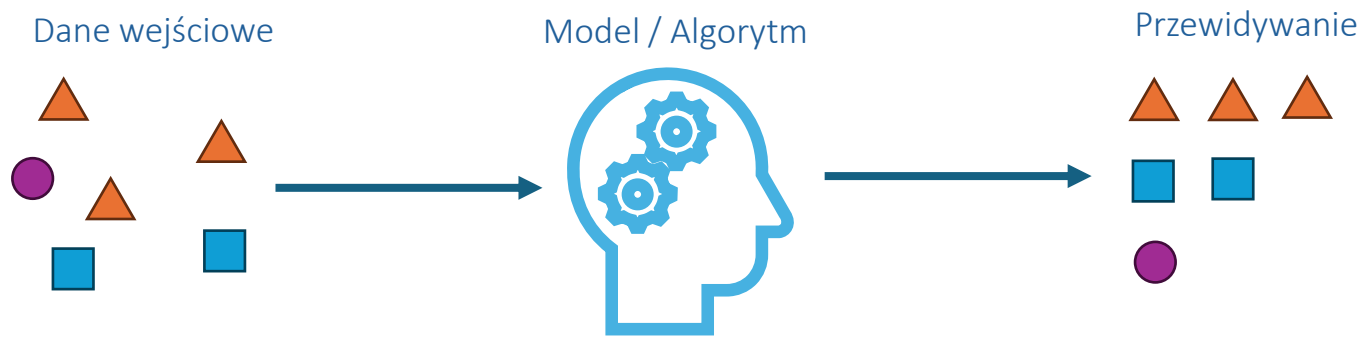
Model jest trenowany na oznaczonych danych wejściowych i wyjściowych

Przykłady Algorytmów:

- regresja liniowa,
- drzewa decyzyjne,
- sieci neuronowe,
- SVM (Support Vector Machines).

Systemy uczenia maszynowego (ML)

Uczenie nienadzorowane (Unsupervised Learning)



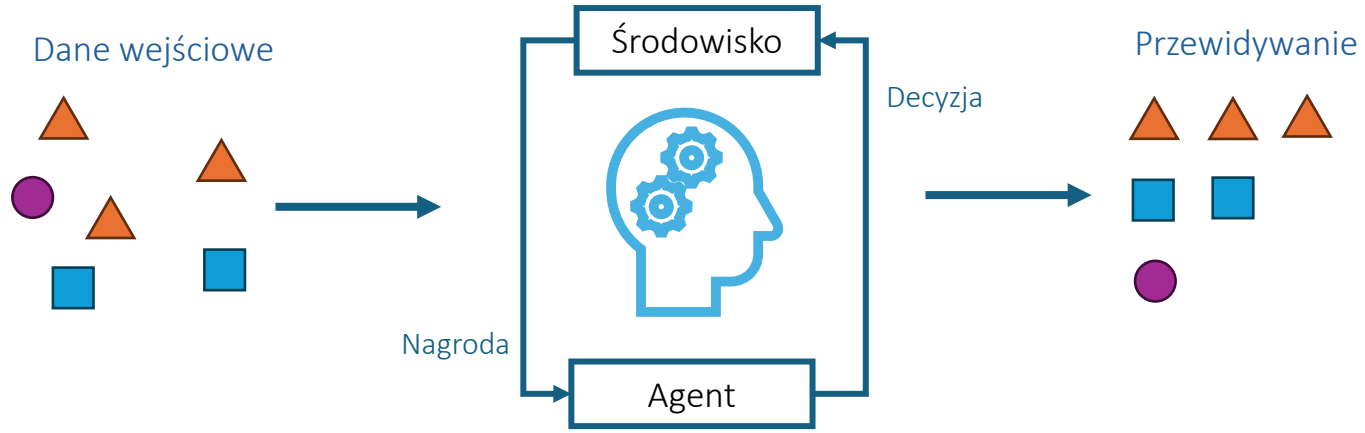
Przykłady Algorytmów:

- klasteryzacja K-means
- hierarchiczna klasteryzacja
- redukcja wymiarowości
- metody asocjacyjne

Model bazuje na odkrywaniu struktur (wzorców) danych

Systemy uczenia maszynowego (ML)

Uczenie przez wzmacnianie (Reinforcement Learning)



Model bazuje na maksymalizacji nagrody poprzez podejmowanie sekwencji decyzji

Przykłady Algorytmów:

- Q-learning,
- SARSA (State-Action-Reward-State-Action),
- Deep Q-Networks (DQN).

Systemy uczenia maszynowego (ML)

Zastosowanie

Zastosowanie	Opis	Przykłady	Algorytm
Systemy rekomendacyjne	Analizują dane użytkowników i rekomendują produkty, usługi lub treści.	Netflix, Amazon	Filtracja kolaboracyjna, Maszyny Wektorów Nośnych (SVM), sieci neuronowe
Rozpoznawanie obrazów	Identyfikują obiekty i wzorce na podstawie analizy obrazów.	Google Photos, Facebook	Sieci neuronowe
Przetwarzanie języka naturalnego	Analizują i generują język naturalny, umożliwiając interakcję między ludźmi a komputerami.	ChatGPT, asystenci głosowi (Alexa, Siri)	Sieci neuronowe
Analiza danych medycznych	Przetwarzają dane medyczne w celu diagnozowania chorób i wspomagania decyzji klinicznych.	IBM Watson Health, Zebra Medical Vision	Sieci neuronowe, drzewa decyzyjne
Automatyczne tłumaczenie	Tłumaczą teksty z jednego języka na drugi, zachowując kontekst i znaczenie.	Google Translate, DeepL	Sieci neuronowe
Systemy predykcyjne w finansach	Prognozują trendy rynkowe, wykrywają oszustwa finansowe i optymalizują portfele inwestycyjne.	Bloomberg Terminal, Kensho	Sieci neuronowe, drzewa decyzyjne, SVM
Gry komputerowe	Uczą się strategii gry, przewidują ruchy przeciwnika i adaptują się do stylu gry gracza.	AlphaGo, OpenAI Five	Głębokie Uczenie Przez Wzmacnianie (DRL)
Samochody autonomiczne	Przetwarzają dane z czujników, podejmują decyzje na drodze, zapewniając bezpieczną jazdę.	Tesla Autopilot, Waymo	Sieci neuronowe, algorytmy sterowania
Analiza sentymentu	Analizują teksty w mediach społecznościowych i artykułach, aby określić opinie i nastroje użytkowników.	Brandwatch, Hootsuite	Sieci neuronowe, NLP
Zarządzanie energią	Optymalizują zużycie energii w budynkach i sieciach energetycznych na podstawie analizy danych.	Nest Learning Thermostat, Grid4C	Sieci neuronowe, drzewa decyzyjne

Systemy uczenia maszynowego (ML)

Algorytmy uczenia maszynowego

Uczenie nadzorowane

Klasyfikacja

Drzewa decyzyjne (Decision Trees)	Maszyny wektorów nośnych (Support Vector Machines, SVM)	K-najbliższych sąsiadów (k-Nearest Neighbors, k-NN)	Regresja logistyczna (Logistic Regression)
algorytm oparty na podejmowaniu decyzji na podstawie atrybutów danych, dzielący dane na kategorie.	algorytm, który próbuje znaleźć najlepszą granicę między kategoriami.	algorytm, który klasyfikuje na podstawie najbliższych przykładów w przestrzeni danych.	model stosowany w klasyfikacji binarnej, np. przewidywanie czy e-mail jest spamem.

Regresja

Regresja liniowa (Linear Regression)	Regresja wielomianowa (Polynomial Regression)	Drzewa regresyjne (Regression Trees)	Gęste sieci neuronowe (Dense Neural Networks)
algorytm do przewidywania wartości ciągłych, takich jak ceny domów.	rozszerzenie regresji liniowej dla nieliniowych zależności.	modyfikacja drzew decyzyjnych stosowana do przewidywania wartości numerycznych.	sieci neuronowe stosowane do modelowania skomplikowanych zależności w danych ciągłych.

Systemy uczenia maszynowego (ML)

Algorytmy uczenia maszynowego

Uczenie nienadzorowane

Grupowanie (Klasteryzacja)			Asocjacja		Redukcja wymiarowości		
K-średnich (K-means)	Algorytm hierarchiczny (Hierarchical Clustering)	DBSCAN (Density-Based Spatial Clustering of Applications with Noise)	Algorytm Apriori	Eclat	PCA (Principal Component Analysis)	t-SNE (t-Distributed Stochastic Neighbor Embedding)	LDA (Linear Discriminant Analysis)
algorytm, który grupuje dane w klastry na podstawie ich podobieństwa.	tworzy hierarchię klastrów na podstawie odległości między danymi.	algorytm grupujący dane na podstawie gęstości, dobrze radzący sobie z hałasem w danych.	algorytm stosowany do znajdowania częstych wzorców i reguł asocjacyjnych w dużych zbiorach danych, np. do analizy koszyka zakupowego.	algorytm asocjacyjny, który wykorzystuje listy wywołań do szybkiego znajdowania reguł asocjacyjnych.	analiza składowych głównych, stosowana do redukcji liczby zmiennych, zachowując jak najwięcej informacji.	algorytm stosowany do wizualizacji wysokowymiarowych danych, np. w dwóch wymiarach.	metoda stosowana do redukcji wymiarowości z zachowaniem maksymalnej separacji klas w danych.

Zadanie



Treść

Zapoznaj się z poniższymi opisami zastosowań sztucznej inteligencji i przyporządkuj każdy z nich do jednej z trzech kategorii:

- Uczenie nadzorowane (Supervised Learning)
- Uczenie nienadzorowane (Unsupervised Learning)
- Uczenie przez wzmacnianie (Reinforcement Learning)

Przykłady zastosowań:

1. System wykrywania spamu, który klasyfikuje e-maile jako spam lub wiadomości pożądane na podstawie wcześniejszych przykładów.
2. Program do grupowania klientów sklepu internetowego na podstawie ich zachowań zakupowych, bez wcześniejszych etykiet.
3. Algorytm sterujący robotem, który uczy się na podstawie nagród i kar, aby zoptymalizować swoje ruchy.
4. Model predykcji cen mieszkań, który na podstawie danych historycznych (np. lokalizacja, metraż) przewiduje przyszłe wartości nieruchomości.
5. Algorytm analizujący wzorce w nieznanych danych genetycznych i tworzący grupy podobnych sekwencji DNA.
6. Program do gry w szachy, który uczy się wygrywać, testując różne strategie i otrzymując nagrody za wygrane partie.

Zadanie



Odpowiedź

Opis zastosowania	Rodzaj uczenia maszynowego	Uzasadnienie
System wykrywania spamu, który klasyfikuje e-maile jako spam lub wiadomości pożądane na podstawie wcześniejszych przykładów.	**Uczenie nadzorowane (Supervised Learning)**	Model uczy się na oznaczonych danych, gdzie wiadomości są oznaczone jako spam lub nie.
Program do grupowania klientów sklepu internetowego na podstawie ich zachowań zakupowych, bez wcześniejszych etykiet.	**Uczenie nienadzorowane (Unsupervised Learning)**	Model nie ma etykiet i samodzielnie szuka wzorców w danych, grupując klientów.
Algorytm sterujący robotem, który uczy się na podstawie nagród i kar, aby zoptymalizować swoje ruchy.	**Uczenie przez wzmacnianie (Reinforcement Learning)**	Model uczy się poprzez interakcję ze środowiskiem, dostosowując swoje działania do otrzymywanych nagród.
Model predykcji cen mieszkań, który na podstawie danych historycznych (np. lokalizacja, metraż) przewiduje przyszłe wartości nieruchomości.	**Uczenie nadzorowane (Supervised Learning)**	Model wykorzystuje historyczne dane wejściowe i znane wartości wyjściowe do przewidywania cen.
Algorytm analizujący wzorce w nieznanych danych genetycznych i tworzący grupy podobnych sekwencji DNA.	**Uczenie nienadzorowane (Unsupervised Learning)**	Model nie ma etykiet i samodzielnie odkrywa podobieństwa między danymi.
Program do gry w szachy, który uczy się wygrywać, testując różne strategie i otrzymując nagrody za wygrane partie.	**Uczenie przez wzmacnianie (Reinforcement Learning)**	Model trenuje na podstawie interakcji z grą, optymalizując strategię w oparciu o nagrody.


©slumin
chomikiemirysiakiem.pl
CO ONI CIĄGLE O TEJ SZTUCZNEJ INTELIGENCJI?
BRAKUJE WŁASNEJ, TO KOMBINUJĄ Z PROTEZĄ.
www.facebook.com/Humor365dni/