

# Taksonomia Technologii AI

Rozróżnienie między Sztuczną Inteligencją, Učeniem Maszynowym i Głębokim Učeniem — fundament każdego inżyniera oprogramowania.

# Dlaczego Taksonomia Ma Znaczenie

## Problem branżowy

Termin „AI” stał się uniwersalnym buzzwordem — tym samym słowem opisuje się prosty skrypt filtrujący e-maile i wielomiliardowy model językowy. To zaciera granice między systemami deterministycznymi a algorytmami zdolnymi do adaptacji.

## Konsekwencje dla inżyniera

- Użycie sieci neuronowej tam, gdzie wystarczy regresja liniowa → **over-engineering**
- Próba reguł if-else dla rozpoznawania obrazu → **porażka projektowa**
- Błędny dobór sprzętu (CPU vs GPU) i zaniżone szacunki danych
- Gigantyczny dług techniczny dla przyszłych programistów

- ❑ Taksonomia AI to hierarchiczny system klasyfikacji metod — od pojęcia najszerszego (AI) do najbardziej wyspecjalizowanego podzbioru (Deep Learning).

# Sztuczna Inteligencja – Pojęcie Parasol


AI to nadrzędna dziedzina informatyki obejmująca wszystkie systemy zdolne do symulowania ludzkich zdolności poznawczych: rozwiązywania problemów, rozpoznawania wzorców, planowania i rozumienia języka.

## Przykłady AI

Deep Blue (szachy, 1997), nawigacja GPS, wirtualni asystenci w smartfonach

## Analogia

AI to jak „pojazd mechaniczny” – termin-parasol dla skuterów, pociągów i samolotów. Nie mówi nic o silniku, tylko o celu: przemieszczaniu się z A do B.



# Trzy Poziomy AI

1



## Superinteligencja (ASI)

Hipotetyczna maszyna przewyższająca ludzki intelekt we wszystkich dziedzinach — kreatywność, mądrość, samodoskonalenie. Nie istnieje.

2



## AI Ogólna (AGI)

Teoretyczny system uczący się i adaptujący jak człowiek w dowolnej domenie. Przedmiot długofalowych badań. Nie istnieje.

3



## AI Wąska (ANI)

Jedyne co istnieje dziś. Zaprojektowana do jednego zadania — filtry spamu, rekomendacje Netflix, rozpoznawanie twarzy. Nawet GPT-4 to ANI.

- 📌 **Kluczowy wniosek:** Wszystko, z czym branża IT ma dziś do czynienia — włącznie z najpotężniejszymi LLM — to wciąż Narrow AI (ANI). Potężne, ale jednozadaniowe kalkulatory.

# Trzy Podejścia do Budowania AI



## Symboliczne (GOFAI)

Ręcznie kodowane reguły if-then-else.

**Zalety:** pełna przejrzystość, determinizm, brak potrzeby danych.

**Wady:** ekstremalnie sztywne — każda nieznana sytuacja powoduje awarię.




## Koneksjonistyczne

Sztuczne sieci neuronowe uczące się z danych. **Zalety:** elastyczność, dane nieustrukturyzowane. **Wady:** „czarna skrzynka”, wymaga ogromnych zbiorów danych i mocy GPU.



## Hybrydowe (Neuro-symbolic)

Łączy DL (percepcja, wzorce) z modułem logicznym (dedukcja). Zachowuje adaptacyjność przy dramatycznej poprawie wyjaśnialności algorytmów.



# Uczenie Maszynowe – Podzbiór AI

**Machine Learning** to wyspecjalizowana dziedzina AI: algorytmy automatycznie analizują dane, identyfikują ukryte wzorce statystyczne i podejmują decyzje – *bez bycia jawnie zaprogramowanymi do konkretnego zadania.*

## Przykład

Algorytm ryzyka kredytowego w banku, który samodzielnie nauczył się prognozować spłatę pożyczki na podstawie historii setek tysięcy klientów.

## Analogia

Nauka jazdy na rowerze przez dziecko – nie przez czytanie podręcznika fizyki, lecz przez tysiące prób i błędów, tworząc własny model równowagi.

# Odwrócenie Paradygmatu Programowania

## Tradycyjne programowanie

**Dane + Reguły → Odpowiedź**

Programista ręcznie pisze: `if kwota > 100: rabat = 10%`. Wynik jest deterministyczny i przewidywalny.

## Uczenie maszynowe

**Dane + Wyniki → Reguły**

Algorytm sam wywnioskuje, że „klienci 25–30 lat, kupujący we wtorki wieczorem z aplikacji mobilnej, mają najwyższe prawdopodobieństwo przedłużenia abonamentu”.

Dzięki temu przełomowi ML rozwiązuje problemy o złożoności dalece przekraczającej zdolności ludzkiej percepcji wielowymiarowej.

# Trzy Paradygmaty Uczenia Maszynowego

1

## Uczenie Nadzorowane

Dane z etykietami. Model minimalizuje błąd między prognozą a prawdziwą odpowiedzią.

- **Klasyfikacja:** wykrywanie spamu (spam / nie spam)
- **Regresja:** predykcja ceny mieszkania

2

## Uczenie Nienadzorowane

Dane bez etykiet. Algorytm sam odkrywa ukryte struktury i wzorce.

- **Klasteryzacja:** segmentacja klientów
- **Wykrywanie anomalii:** oszustwa kartą kredytową

3

## Uczenie przez Wzmacnianie

Agent uczy się przez interakcję ze środowiskiem — nagrody i kary kształtują optymalną strategię.

- **Przykład:** AlphaGo (DeepMind) — miliony partii z samym sobą
- **Przykład:** sterowanie robotami humanoidalnymi

# Klasyczne Algorytmy ML i Narzędzia

## Kluczowe algorytmy

→ **Regresja liniowa/logistyczna** – predykcja wartości i klasyfikacja dwuklasowa

→ **SVM** – szukanie optymalnej hiperpłaszczyzny rozdzielającej klasy

→ **Drzewa decyzyjne i Random Forest** – zestawy drzew logicznych do trudnych decyzji

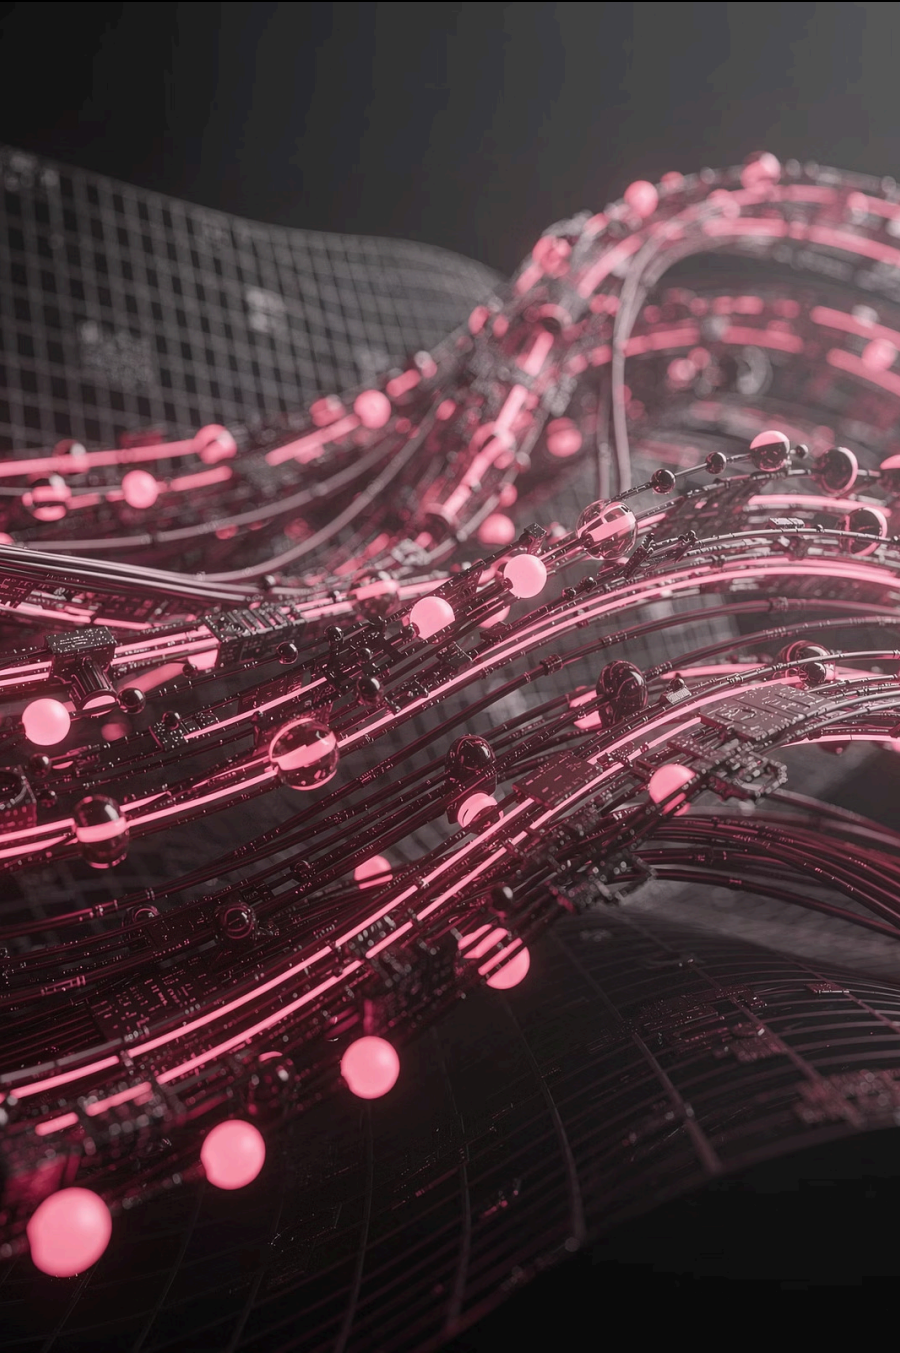
→ **K-Means** – klasteryzacja bez nadzoru wokół środków ciężkości

## Standardowe narzędzie: `scikit-learn`

Biblioteka Python z eleganckim, zunifikowanym API. Ukrywa złożoność matematyczną pod prostymi wywołaniami:

- `.fit()` – rozpoczęcie uczenia
- `.predict()` – uzyskanie prognozy

Często zaledwie kilkanaście linii kodu wystarczy do wytrenowania i ewaluacji modelu.



# Głębokie Uczenie – Podzbiór ML

**Deep Learning** to wyspecjalizowany podzbiór ML oparty na gigantycznych sieciach neuronowych z wieloma warstwami ukrytymi. Od przełomu AlexNet w 2012 roku zrewolucjonizował rozpoznawanie obrazów, tłumaczenie maszynowe i umożliwił powstanie LLM.

- ❏ Termin „głębokie” odnosi się wyłącznie do **fizycznej głębokości sieci** — liczby warstw matematycznych. Nie oznacza „głęboko rozumienia”.

## 3

### Czynniki sukcesu

Big Data, moc GPU i przełomy algorytmiczne  
(backpropagation, ReLU)

## 2012

### Rok przełomu


AlexNet wygrywa konkurs ImageNet,  
inaugurując erę Deep Learning

## 100+

### Warstwy ukryte

Nowoczesne architektury DL mogą posiadać  
setki warstw matematycznych

# Kluczowe Architektury Deep Learning




## Dense / Fully Connected

Każdy neuron połączony z każdym w kolejnej warstwie. Fundament większych systemów, dobry dla danych tabelarycznych.




## CNN – Sieci Konwolucyjne

Przesuwają filtry po obrazie wykrywając krawędzie i kształty. Dominują w Computer Vision, detekcji obiektów i autonomicznych pojazdach.



## RNN / LSTM / GRU

Posiadają „pamięć” poprzednich elementów sekwencji. LSTM rewolucjonizuje NLP, analizę szeregów czasowych i generowanie mowy.



## Transformer

Mechanizm „self-attention” analizuje wszystkie słowa jednocześnie. Podstawa GPT, Claude, Gemini. Dominuje w NLP dzięki zrównolegleniu obliczeń.

# Hierarchia AI $\supset$ ML $\supset$ DL



# Kiedy DL, a Kiedy Klasyczny ML?

Kryterium	Klasyczny ML	Deep Learning
Dane wejściowe	Ustrukturyzowane, tabelaryczne	Nieustrukturyzowane (obraz, dźwięk, tekst)
Ilość danych	Tysiące–setki tysięcy rekordów	Miliony+ (Big Data)
Sprzęt	CPU (standardowy procesor)	GPU / TPU (akceleratorzy)
Interpretowalność	Wysoka (drzewa decyzyjne)	Niska – „czarna skrzynka”
Czas treningu	Sekundy–minuty	Tygodnie–miesiące
Koszt wdrożenia	Niski–średni	Bardzo wysoki

- ❏ Overfitting (przeuczenie) to szczególne zagrożenie DL przy małych zbiorach danych – model zapamiętuje dane treningowe zamiast uogólniać wzorce.

# Zastosowania w Branży IT



## E-commerce

Rekomendacje produktów → **ML (K-Means, drzewa decyzyjne)** Kategoryzacja zdjęć produktów → **DL (CNN)**




## Finanse i Bankowość

Wykrywanie oszustw → **ML nienadzorowane (Anomaly Detection)**  
Scoring kredytowy → **ML nadzorowane (Random Forest, Logistic Regression)**



## Medycyna

Analiza skanów MRI, wykrywanie guzów → **DL (CNN)** Dawkowanie leków wg protokołów → **AI Symboliczne (systemy eksperckie)**



## Automatyka Przemysłowa

Sterowanie ramieniem robotycznym → **DL (Reinforcement Learning)** Nawigacja NPC w grach → **AI Symboliczne (algorytm A\*)**



## Cyberbezpieczeństwo

Filtrowanie spamu → **ML nadzorowane (Naiwny Bayes)**  
Generowanie ofert pracy → **DL / GenAI (LLM, Transformer)**

# Typowe Błędy i Pułapki Pojęciowe

✗ „AI to fizyczny robot z osobowością”

Mit zakorzeniony w popkulturze. AI to nienamacalny skrypt rezydujący na serwerach — matematyczny model trenujący się na danych. Nie potrzebuje ciała ani robotów, by być sztuczną inteligencją.


✗ „ML eliminuje sens pisania reguł algorytmicznych”

Patologiczny over-engineering. W zamkniętych środowiskach biznesowych, gdzie reguły decyzyjne można zapisać na kartce, klasyczne programowanie if/else jest zawsze optymalną odpowiedzią ekonomiczną i inżynierską.

✗ „DL rozumie analizowany tekst czy zjawisko”

LLM to wybitnie skomplikowane kalkulatory statystyczne służące wyłącznie precyzyjnemu dopasowywaniu wzorców (*pattern matching*). Model wylicza, że po słowie „Dzień” statystycznie powinno nastąpić „dobry” — nie rozumie idei za słowami.

## Dunning-Kruger Effect



# Efekt Dunninga-Krugera a AI

Efekt Dunninga-Krugera — osoby o niskiej znajomości domeny dramatycznie przeceniają swoje kompetencje — zyskał nową iterację w erze generatywnej AI.

### 1 Cognitive offloading

Nowicjusze bezkrytycznie cedują na model sprawdzanie rozwiązań logicznych i pisanie złożonego kodu, traktując wyjście modelu jako absolutny fakt.

### 2 Ignorowanie halucynacji

Jeden lakoniczny prompt, przyjęcie wyniku za pewnik — bez walidacji. Modele mają wbudowane sztuczne nadmierne zaufanie przez metody kalibracji producentów.

### 3 Obowiązek inżyniera

Krytyczne, testowe podejście i walidacja wyników AI to absolutny obowiązek każdego informatyka pracującego z modelami generatywnymi.

# Ćwiczenie 1: Taksonomia Problemów Biznesowych

Zakwalifikuj każdy problem do: AI Symboliczne / ML Nadzorowane / ML Nienadzorowane / Deep Learning

#	Problem biznesowy	Odpowiedź
1	Filtrowanie maili spam/nie-spam na podstawie tysięcy oflagowanych wiadomości	ML Nadzorowane
2	Odkurzacz z regułami: if sensor=true then turn_left	AI Symboliczne
3	Automatyczne tagowanie twarzy z monitoringu na lotnisku	Deep Learning (CNN)
4	Segmentacja użytkowników aplikacji według wzorców kliknięć	ML Nienadzorowane
5	Prognozowanie ceny samochodu z 100 000 ogłoszeń	ML Nadzorowane (Regresja)
6	Generowanie fotorealistycznych grafik produktów z opisów tekstowych	Deep Learning (GenAI)
7	Diagnostyka chorób skóry ze zdjęć pieprzyków	Deep Learning (CNN)
8	Rekomendacje seriali szukające korelacji w zachowaniu podobnych użytkowników	ML Nienadzorowane
9	Chatbot bankowy działający na drzewie decyzji z gotowym spisem Q&A	AI Symboliczne
10	Tłumacz w czasie rzeczywistym z polskiego na japoński	Deep Learning (Transformer)

# Ćwiczenie 2: Klasyfikator Iris w scikit-learn

```
# 1. Import niezbędnych modułów
from sklearn.datasets import load_iris
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression

# 2. Załadowanie zbioru
X, y = load_iris(return_X_y=True)

# 3. Podział zbioru i inicjalizacja klasycznego modelu
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3)
model = LogisticRegression(max_iter=200)

# 4. Proces uczenia (fit) i predykcja
model.fit(X_train, y_train)

# 5. Sprawdzenie poprawności wyników
print(f"Skuteczność: {model.score(X_test, y_test)}")
```

- ❏ **Czy to ML czy DL?** Zdecydowanie klasyczne ML. Model używa `LogisticRegression` — jeden z najstarszych mechanizmów uczenia nadzorowanego, bez ani jednej warstwy ukrytej sieci neuronowej, pracujący na doskonale ustrukturyzowanych danych tabelarycznych.

# Słowniczek Kluczowych Pojęć

## • Fundamenty taksonomii

- **AI (Sztuczna Inteligencja)** — nadrzędna dziedzina symulująca ludzkie zdolności poznawcze
- **ANI / AGI / ASI** — wąska (istniejąca) / ogólna (teoretyczna) / superinteligencja (hipotetyczna)
- **ML (Uczenie Maszynowe)** — algorytmy uczące się z danych bez jawnego programowania reguł
- **DL (Głębokie Uczenie)** — ML z wielowarstwowymi sieciami neuronowymi, wymaga GPU i Big Data

## • Paradygmaty uczenia

- **Uczenie nadzorowane** — dane z etykietami, model minimalizuje błąd predykcji
- **Uczenie nienadzorowane** — brak etykiet, odkrywanie ukrytych struktur
- **Uczenie przez wzmocnienie** — agent, nagrody i kary, maksymalizacja skumulowanej nagrody
- **Feature Engineering** — ręczne przygotowanie cech wejściowych dla klasycznego ML

## • Kluczowe pojęcia techniczne

- **Overfitting / Underfitting** — przeuczenie (zapamiętanie danych) / niedouczenie (zbyt prosty model)
- **Klasyfikacja / Regresja / Klasteryzacja** — dyskretne kategorie / wartość ciągła / grupowanie bez etykiet
- **CNN / LSTM / Transformer** — architektury DL dla obrazów / sekwencji / języka naturalnego
- **Hiperparametr** — wartość ustawiana przez programistę przed treningiem (np. liczba warstw)



# Podsumowanie: Kompetencja Inżyniera AI

Nie musisz znać na pamięć wszystkich wzorów macierzowych. Kluczowa kompetencja to umiejętność precyzyjnego mapowania problemu biznesowego na właściwy paradygmat technologiczny.

## ✓ Właściwy dobór narzędzia

Prosta reguła → AI Symboliczne.  
Dane tabelaryczne → klasyczny ML.  
Obraz/dźwięk/tekst w skali → Deep Learning.

## ✓ Precyzyjna komunikacja

Inżynierowie muszą mieć pewność, że „uczenie nadzorowane” oznacza dla obu stron ten sam, ściśle określony proces optymalizacyjny.

## ✓ Krytyczna walidacja

Testuj, weryfikuj, nie ufaj bezkrytycznie modelom AI. Halucynacje i efekt Dunninga-Krugera to realne zagrożenia zawodowe.