

## Sztuczna inteligencja

*"It is the science and engineering of making intelligent machines, especially intelligent computer programs."*  
[About AI : John McCarthy, MIT/Stanford]

**Sztuczna inteligencja [ang. artificial intelligence]** - dział informatyki zajmujący się tworzeniem modeli inteligentnych zachowań, które mogą być inkorporowane w programach komputerowych. Celem takich programów jest naśladowanie ludzkich przejawów inteligencji. Problemy rozwiązywane przy użyciu sztucznej inteligencji są problemami, których nie jesteśmy w stanie efektywnie rozwiązywać przy użyciu klasycznych algorytmów.

Przykładowe zastosowania sztucznej inteligencji to:

- Podejmowanie decyzji w warunkach niepewności;
- Analiza i synteza języków naturalnych;
- Dowodzenie twierdzeń;
- Gry logiczne, np. szachy, go;
- Systemy eksperckie i diagnostyczne.

## Uczenie maszynowe

**Uczenie maszynowe [ang. machine learning]** - nauka o algorytmach i systemach usprawniających swoją wiedzę oraz wyniki wraz ze zdobywanym doświadczeniem [Peter Flach]. Uczenie maszynowe to dziedzina sztucznej inteligencji, która na podstawie wyszukiwania relacji w danych uczących - próbuje naśladować inteligentne zachowania (np. rozpoznawanie obiektów).

Przez *zdobycie doświadczenia* rozumiemy pozyskiwanie nowych *danych uczących*.

Przez *wiedzę* rozumiemy sformalizowany opis relacji występujących w *danych uczących*. Wiedzę formalizujemy w tzw. *modelu danych*.

Przez usprawnienie wyników algorytmu uczenia maszynowego rozumiemy ulepszenie zdolności do rozwiązywania *zadań uczenia maszynowego*.

Algorytmy w uczeniu maszynowym nazywamy **algorytmami uczącymi [ang. learning algorithms]**. W odróżnieniu od klasycznych algorytmów (np. poszukiwania najkrótszej ścieżki w grafie), które opisują konkretną sekwencję instrukcji, algorytmy uczące tworzą **model** zawierający listę instrukcji do wykonania na podstawie analizy przekazanych im **danych uczących**. Proces tworzenia wiedzy o rozwiązaniu nazywamy **uczeniem**, a jako wyniki procesu budujemy **model danych**.


## Dane uczące

**Zbiór uczący/dane uczące [ang. learning dataset]** - zestaw danych przeznaczony do uczenia algorytmów uczących. Składa się z obiektów pochodzących z pewnej dziedziny, opisanych przy pomocy cech.

**Próbka, Instancja [ang. sample, instance, example]** - opis pojedynczego obiektu w zbiorze danych. W przypadku zbioru uczącego w postaci tabeli, instancjami są kolejne wiersze.

**Atrybut [ang. feature]** - cecha użyta do opisu obiektu. W przypadku zbioru uczącego w postaci tabeli, atrybutami są kolejne kolumny.

Przykładem zbioru uczącego jest *Iris flower data set* utworzony w 1936 r. przez Ronalda Fishera. Zbiór uczący opisuje kwiaty irysa przy pomocy 4 atrybutów: długości oraz szerokości płatków PETAL oraz SEPAL oraz przyporządkowuje każdemu z kwiatów jego faktyczny gatunek.



	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.7	3.2	1.6	0.2	setosa
3	7.0	3.2	4.7	1.4	versicolor
4	6.4	3.2	4.5	1.5	versicolor
5	6.3	3.3	6.0	2.5	virginica
6	5.8	2.7	5.1	1.9	virginica

Fragment zbioru zawiera 5 atrybutów w tym klasę (etykiety; ostatnia kolumna) dla 6 instancji.

## Podziały zbiorów uczących

### Ze względu na opis obiektów

- **Etykietowany [ang. labeled dataset]** - dane zawierają informacje o klasach instancji (przeznaczone do wykorzystania przy uczeniu nadzorowanym, np. klasyfikacja [ang. classification]);
- **Nieetykietowany [ang. unlabeled dataset]** - dane nie zawierają informacji o klasach dla instancji (wykorzystywane przy uczeniu nienadzorowanym, np. nienadzorowana klasteryzacja, klasteryzacja bez nauczyciela [ang. unsupervised clusterization]).

### Ze względu na strukturę zbioru

- **Strukturalne dane [ang. structured data]** - zestawy danych powiązane relacjami (np. relacyjne bazy danych);
- **Pół-strukturalne dane [ang. semi-structured data]** - pojedynczy zestaw danych, najczęściej o płaskiej reprezentacji w formie tabeli;
- **Nieustrukturizowany dane [ang. unstructured data]** - przeważnie dane multimedialne (np. zdjęcia, próbki dźwięku, strony internetowe, dokumenty tekstowe, email).

### *Ze względu na typ danych*

- **Płaska reprezentacja (tabela)** - przechowuje typowe dane statystyczne;
- **Obraz** - tekst do analizy, przedmioty do rozpoznawania;
- **Tekst** - rozpoznawanie zawartości, klasyfikacja i etykietowanie dokumentów;
- **Szereg czasowy** - zawiera dźwięk, element mowy;
- **Graf** - reprezentuje budowę sieci społecznościowych.

### Repozytoria zawierające dane uczące dla uczenia maszynowego

- [UCI Machine Learning Respository](#)
- [SNAP Datasets: Stanford Large Network Dataset Collection](#)
- [OpenML: Open Collaborative ML Platform](#)

### Zadania uczenia maszynowego

**Zadanie uczenia maszynowego [ang. machine learning task]** - abstrakcyjny opis problemu, który możemy rozwiązać przy użyciu uczenia maszynowego. Zadania uczenia maszynowego nazywamy często problemami uczenia maszynowego. Wyróżniamy następujące zadania:

- **[Klasyfikacja \[ang. classification\]](#)** - przyporządkowanie klas do obiektów pochodzących z pewnego zbioru. Wyróżniamy:
  - **[Klasyfikację jednoklasową \[ang. one-class classification/unary classification\]](#)** - identyfikowanie obiektów o ustalonej klasie;
  - **[Klasyfikację binarną \[ang. binary/binomial classification\]](#)** - klasyfikacja obiektów do jednej z dwóch klas;
  - **[Klasyfikację wieloklasową \[ang. multiclass/multinomial classification\]](#)** - przyporządkowanie obiektowi klasy pochodzącej ze zbioru składającego się z co najmniej 3 klas. Klasyfikacja wieloklasowa może zostać zredukowana do wielokrotnej klasyfikacji binarnej przy użyciu jednej z dwóch strategii:
    - ❖ **Jeden przeciw wszystkim [ang. one-vs-rest]** - binarna klasyfikacja dla każdej z N klas, zestawiona z klasą powstałą przez połączenie pozostałych N-1 klas;
    - ❖ **Jeden przeciw jednemu [one-vs-one]** - binarna klasyfikacja pomiędzy wszystkim z N rozważanych klas.
  - **[Klasyfikacja wieloetykietowa \[ang. multi-label classification\]](#)** - przyporządkowanie kilku etykiet/klas do każdego z klasyfikowanych obiektów.
- **[Regresja \[ang. regression\]](#)** - przyporządkowanie obiektom wartości liczbowych. Analogicznie jak przy zadaniu klasyfikacji, tylko zamiast etykiet używamy liczb rzeczywistych.
- **[Klasteryzacja \[ang. clustering\]](#)** - grupowanie obiektów o podobnych cechach. Podobieństwo obiektów jest wyrażenie przy użyciu pojęć takich jak: dystans czy metryki podobieństwa.
- **[Reguły asocjacyjne \[ang. association rules\]](#)** - wykrywanie relacji pomiędzy zmiennymi opisującymi obiekty.
- **[Redukcja wielowymiarowości \[ang. dimensionality reduction\]](#)** - redukcja liczby używanych atrybutów pochodzących ze zbioru uczącego. Na przykład w celu optymalizacji procesu uczenia (przy mniejszej ilości cech łatwiej znaleźć te najbardziej wpływowe). Wyróżniamy:
  - **[Selekcja atrybutów \[ang. attribute filter\]](#)** - redukcja zbioru uczącego do podzbioru z najważniejszymi atrybutami (selekcja np. na podstawie przyrostu informacji)

- **Ekstrakcja atrybutów [ang. attribute wrapper]** - łączenia atrybutów przy pomocy operacji liniowych bądź nieliniowych i tworzenie nowych atrybutów łączących cechy wspólne.

## Proces uczenia w uczeniu maszynowym

Rozwiązanie zadania uczenia maszynowego odbywa się na drodze **procesu uczenia [ang. learning process]**. Proces polega na wykorzystaniu algorytmu uczącego i przekazania mu danych uczących w celu utworzenia modelu. Wyróżniamy następujące procesy uczenia:

- **Uczenie nadzorowane/z nauczycielem [ang. supervised learning]** - budowa modelu z wykorzystaniem etykietowanego zbioru uczącego.
- **Uczenie nienadzorowane/bez nauczyciela [ang. unsupervised learning]** - umożliwia budowę modelu opisującego ukryte struktury i relacje w nieetykietowanym zbiorze uczącym.
- **Uczenie pół-nadzorowane [ang. semi-supervised learning]** - rodzaj uczenia nadzorowanego, gdzie wykorzystywane są również dane pochodzące z nieetykietowanego zbioru uczącego (zwykle w małej ilości).
- **Uczenie na bieżąco [ang. online learning]** - uczenie z wykorzystaniem danych uczących zawartych w strumieniu danych. Sekwencja danych ulega ciągłej zmianie, z tego też powodu uczenie na bieżąco jest wykonywane przez cały okres używania modelu, który ewoluuje wraz z napływającymi danymi uczącymi.
- **Uczenie ze wzmocnieniem [ang. reinforcement learning]** - uczenie oparte w wzmocnienie znane z nauk behawioralnych, gdzie model jest iteracyjnie poprawiany na podstawie wzmocnienia (nagrody), które jest miarą oceny jakości działania modelu i wpływa na jego końcową wersję.

## Model w uczeniu maszynowym

**Modele [ang. model, data model]** - opisują relacje zawarte w danych uczących. Wyróżniamy trzy podstawowe rodzaje modeli budowanych przez algorytmy uczące:

1. **Geometryczne [ang. geometrical]** - instancje ze zbioru uczącego są umieszczane na wielowymiarowej płaszczyźnie kartezjańskiej i są od siebie separowane przy użyciu linii, płaszczyzn i hiper-płaszczyzn. Otrzymane podpłaszczyzny reprezentują miejsca, gdzie znajdują instancje przynależące do tej samej klasy.
2. **Probabilistyczne [ang. probabilistic]** - relacje pomiędzy danymi uczącymi zostają opisane przy wykorzystaniu prawdopodobieństw a priori i/lub a posteriori. Tworzony model zawiera brakujące powiązania pomiędzy zmiennymi, którym nadaje odpowiednie wartości prawdopodobieństwa. Do wyliczania prawdopodobieństwa wykorzystuje się regułę Bayesa.
3. **Logiczne [ang. logical]** - opisują relacje w danych z wykorzystaniem sformalizowanych logik matematycznych. Jedną z reprezentacji jest zestaw reguł decyzyjnych.

**Model hybrydowy [ang. hybrid model]** - model łączący ze sobą co najmniej dwa różne rodzaje modeli podstawowych.

Budowane modele mają charakter **predykcyjny (ang. predictive)** - budowane np. na potrzeby zadania klasyfikacji bądź **opisowy (ang. descriptive)** - dla potrzeb klasteryzacji.

## Ewaluacja modeli

**Ewaluacja modelu [ang. model evaluation]** - proces mający na celu sprawdzenie jakości uzyskanego rozwiązania/modeli. Różnice w jakości danych uczących wpływają na jakość utworzonych modeli. Wyróżniamy szereg metod ewaluacji modeli oraz metryk ewaluacji, które mówią nam o jakości rozwiązania w różnych kontekstach.

Do używanych metryk ewaluacyjnych zaliczamy m.in.:

- **Dokładność/celność (ang. accuracy)** - ilość poprawnie przewidzianych klas podzielona przez całkowitą ilość testowanych instancji;
- **Dokładność klasy (ang. per-class accuracy)** - ilość poprawnie przewidzianych klas podzielona przez ilość testowanych instancji z przypisaną tą samą klasą;
- **AUC (ang. area under curve)** - reprezentacja czułości (ang. sensitivity) czyli proporcji **prawdziwie pozytywnych (ang. true positive)** przypisanych klas do **falszywie pozytywnych (ang. false positive)** przypisanych klas.

Do metod ewaluacji zaliczamy m.in.:

- **Przetrzymanie (ang. hold-out)** - polega na podzieleniu zbioru uczącego w proporcji 2/3 i 1/3 na kolejno zbiór uczący i zbiór testowy. Zbiór uczący służy do stworzenia modelu danych przy użyciu algorytmu uczącego, natomiast zbiór testowy zostaje przekazany do modelu i służy do jego ewaluacji.
- **Ewaluacja na k-częściach (ang. k-fold evaluation)** - jest to odmiana przetrzymania, gdzie zbiór uczący dzielimy na k części. Następnie postępujemy analogicznie jak przy przetrzymaniu dla każdej z k części - traktujemy k-1 części jako zbiór uczący, natomiast pozostałą część jako zbiór testowy. Cała czynność powtarzamy k razy, a końcowy wyniki jest średnią ze wszystkich ewaluacji.

## Algorytmy uczące

Wyróżniamy szereg [algorytmów uczących](#) takich jak:

- **Algorytmy regresyjne [ang. regression algorithms]** (Linear Regression, Logistic Regression, Ordinary Least Squares Regression [OLSR], Stepwise Regression, Multivariate Adaptive Regression Splines [MARS], Locally Estimated Scatterplot Smoothing [LOESS]);
- **Bazujące na instancjach danych [ang. instance-based algorithms]** (k-Nearest Neighbour [kNN], Learning Vector Quantization [LVQ], Self-Organizing Map [SOM], Locally Weighted Learning [LWL])
- **Algorytmy z regularyzacją [ang. regularization algorithms]** (Ridge Regression, Least Absolute Shrinkage and Selection Operator [LASSO], Elastic Net, Least-Angle Regression [LARS]);
- **Drzewa decyzyjne [ang. decision tree algorithms]** (Classification and Regression Tree [CART], Iterative Dichotomiser 3 [ID3], C4.5 and C5.0 [different versions of ID3], Chi-squared Automatic Interaction Detection [CHAID], Decision Stump, M5, Conditional Decision Trees);
- **Algorytmy Bayesowskie [ang. bayesian algorithms]** (Naive Bayes, Gaussian Naive Bayes, Multinomial Naive Bayes, Averaged One-Dependence Estimators [AODE], Bayesian Belief Network [BBN], Bayesian Network [BN])

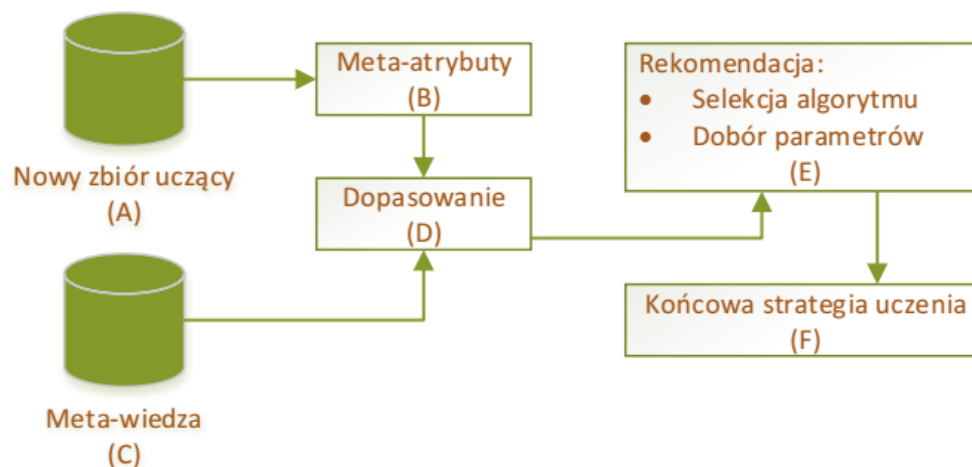
- **Algorytmy klasteryzujące [ang. clustering algorithms]** (k-Means, k-Medians, Expectation Maximization [EM], Hierarchical Clustering);
- **Algorytmy oparte o reguły asocjacyjne [ang. association rule learning algorithms]** (Apriori Algorithm, Eclat Algorithm);
- **Sztuczne sieci neuronowe [ang. artificial neural network]** (Perceptron, Hopfield Network, Radial Basic Function Network [RBFN]);
- **Głębokie uczenie [ang. deep learning algorithms]** (Deep Boltzman Machine [DBM], Deep Belief Network [DBN], Convolutional Neural Network [CNN], Stacked Auto-Encoders);
- **Redukcja wielowymiarowości [ang. dimensionality reduction algorithms]** (Principal Component Analysis [PCA], Principal Component Regression [PCR], Partial Least Squares Regression [PLSR], Sammon Mapping, Multidimensional Scaling [MDS], Projection Pursuit, Linear Discriminant Analysis [LDA], Mixture Discriminant Analysis [MDA], Quadratic Discriminant Analysis [QDA], Flexible Discriminant Analysis [FDA]);
- **Algorytmy łączone [ang. ensemble algorithms]** (Boosting, Bootstrapped Aggregation [Bagging], AdaBoost, Stacked Generalization [blending], Gradient Boosting Machines [GBM], Gradient Boosted Regression Trees [GBRT], Random Forest).

## Meta-uczenie

**Meta-uczenie [ang. meta-learning, learning to learn]** - dział uczenia maszynowego zajmujący się usprawnianiem procesu uczenia w klasycznym uczeniu maszynowym.

**Meta-dane [ang. meta-data]** - dane opisujące zbiór uczący, przebieg uczenia i wszystkie informacje związane z ewaluacją zbudowanego modelu. Dane te mogą następnie zostać użyte do selekcji algorytmu, dopasowania parametrów bądź ustalenia wykonania metod wstępnego przetwarzania danych (np. **selekcja cech [ang. feature selection]**).

**System meta-uczący [ang. meta-learning system]** - system wykonujący automatyczną selekcję algorytmów i/lub dobór parametrów na podstawie przekazanego do systemu zbioru uczącego. Poniższy rysunek przedstawia schemat prostego systemu meta-uczącego:



Rysunek 4.2: Schemat działania trybu rekomendacji proponowanego systemu meta-uczącego.

Rysunek pochodzi z pracy mgr. "Opracowanie konfiguratora regułowego na potrzeby systemu uczenia maszynowego" autorstwa: Patryk Kiepas.

Działanie systemu przedstawia się następująco: zostają obliczone meta-dane dla nowego zbioru uczącego. Następnie meta-dane zostają dopasowane do istniejącej meta-wiedzy przechowującej informacje o dotychczasowych eksperymentach uczenia maszynowego oraz ich wynikach. W wyniku dopasowania zostaje utworzona rekomendacja zawierająca najodpowiedniejszy algorytm uczący dla rozwiązywanego zadania wraz z dobranymi parametrami.

## **Bibliografia**

1. " Machine Learning: The Art and Science of Algorithms ", Peter Flach, 2012.
2. "Machine Learning", Tom Mitchell, McGraw Hill, 1997.
3. Wikipedia (linki w tekście).