

Podstawy uczenia maszynowego (Machine Learning, ML)

Metody sztucznej inteligencji w systemach wytwarzania
i intralogistyce

dr inż. Tomasz Mączka

Politechnika Rzeszowska & Europa Systems



Czym jest uczenie maszynowe


- “Learning is any process by which a system improves performance from experience” – *Herbert Simon*
- Machine Learning is the study of algorithms that
 - improve their performance P
 - at some task T
 - with experience E .

A well-defined learning task is given by $\langle P, T, E \rangle$ – *Tom Mitchell*

Kiedy stosuje się uczenie maszynowe

ML is used when:

- Human expertise does not exist (navigating on Mars)
- Humans can't explain their expertise (speech recognition)
- Models must be customized (personalized medicine)
- Models are based on huge amounts of data (genomics)



Learning isn't always useful:

- There is no need to “learn” to calculate payroll

Przykład typowego zadania dla ML – rozpoznawanie tekstu




Jakiego typu zadania można rozwiązać przy pomocy ML

- Rozpoznawanie wzorców
 - Klasyfikacja, zliczanie, segmentacja obiektów na zdjęciach
 - Mowa lub pismo
 - Wzorce na obrazach z badań medycznych
- Generowanie wzorców
 - Obrazy, sekwencje filmowe, tekst
- Rozpoznawanie anomalii
 - Nietypowe transakcje bankowe
 - Nietypowe działanie procesu przemysłowego
- Przewidywania
 - Kursy akcji lub walut

Rodzaje algorytmów uczenia maszynowego

- Nadzorowane (ang. supervised)
 - Klasyfikacja
 - Regresja
- Nienadzorowane (ang. unsupervised)
 - Klasteryzacja
 - Detekcja nowości
 - Redukcja wymiarowości
- Ze wzmocnieniem (ang. reinforcement)



Uczenie nadzorowane

Given data tuples $(X_1, y_1), (X_2, y_2), \dots, (X_N, y_N)$, find a function F such that:

$$F(X) = y$$

Classification




CAT

**Classification
+ Localization**



CAT

Object Detection



CAT, DOG, DUCK

**Instance
Segmentation**



CAT, DOG, DUCK

Uczenie nadzorowane - regresja

- Given $(x_1, y_1), \dots, (x_n, y_n)$, learn a function that predicts y given x
- **Regression:** Labels y are real-valued





Image: <https://www.flickr.com/photos/gsfcr/5937599688/>
Data from <https://nsidc.org/arcticseaicenews/sea-ice-tools/>

Uczenie nadzorowane - klasyfikacja

- Given $(x_1, y_1), \dots, (x_n, y_n)$, learn a function that predicts y given x
- Inputs x can be multi-dimensional




- Patient age
- Clump thickness
- Tumor Color
- Cell type
- ...



Image: <https://eyecancer.com/uncategorized/choroidal-metastasis-test/>


Idea nadzorowanego ML



Typy uzyskiwanych modeli klasyfikacyjnych


- interpretowalne, biała skrzynka (ang. “white-box”)
 - np. drzewa decyzyjne
- nieinterpretowalne, czarna skrzynka (ang. “black-box”)
 - np. sieci neuronowe

Uczenie nadzorowane vs nienadzorowane




Uczenie nienadzorowane

- Given $x_1, \dots, x_n$ (no labels), output hidden structure in x 's
 - E.g., clustering

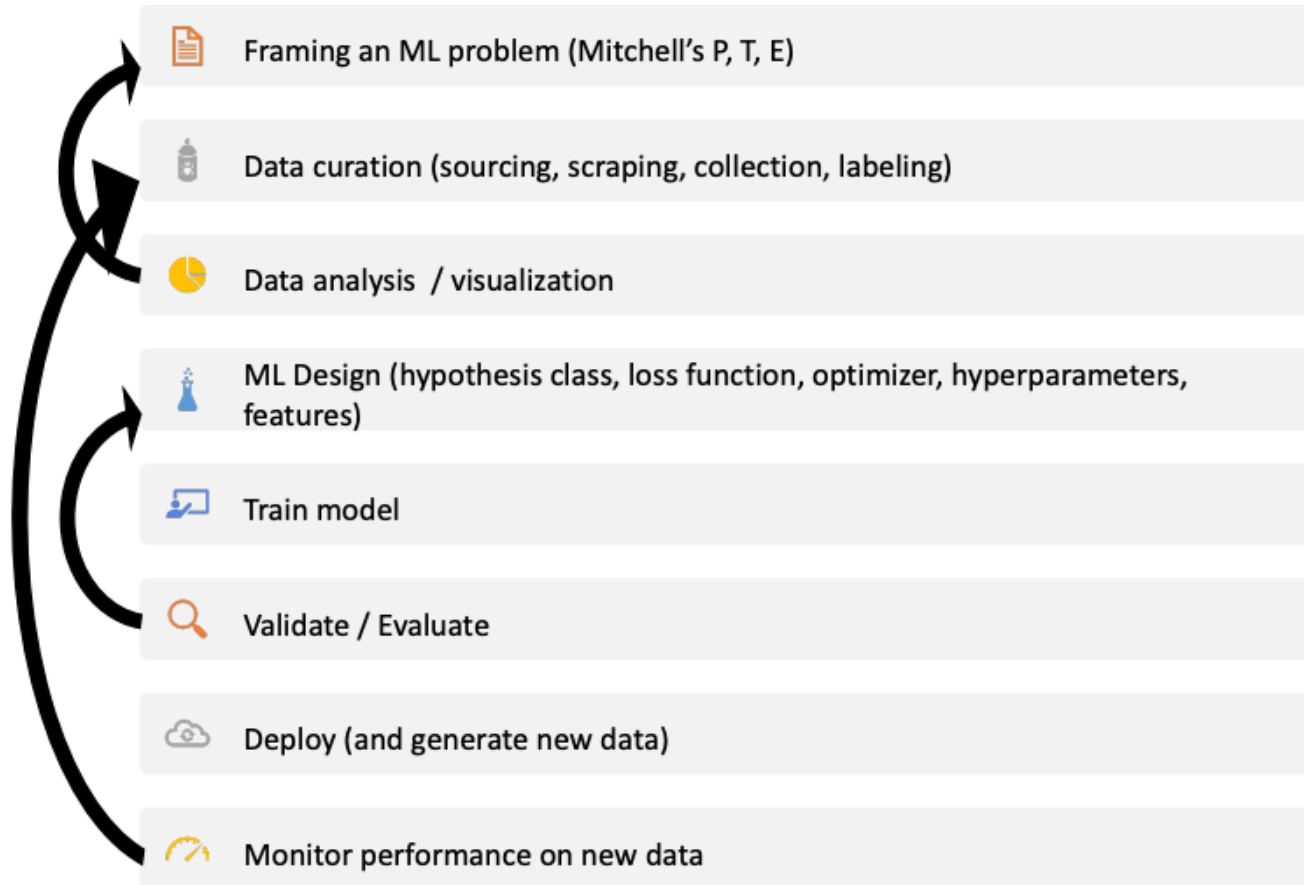


Uczenie ze wzmocnieniem

- Learn how to perform a task from interactions with the **environment**
- **Examples:**
 - Playing chess (interact with the game)
 - Robot grasping an object (interact with the object/real world)
 - Optimize inventory allocations (interact with the inventory system)



Typowy proces ML



Ocena modeli ML

- Macierz rozbieżności
- Wskaźniki jakościowe modeli
 - Dokładność (Accuracy)
 - Czułość (Sensitivity)
 - Specyficzność (Specificity)
 - Pole pod krzywą ROC (AUC)
 - ...
- No free lunch (NFL) theorem

Sposób oceny klasyfikatorów

Ocena indywidualnych klasyfikatorów

- dokładność

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\%$$


- czułość

$$Sen = \frac{TP}{TP + FN} \cdot 100\%$$

- wskaźnik fałszywych alarmów

$$FPr = \frac{FP}{TN + FP} \cdot 100\%$$

- łączna miara dla czułości i wskaźnika fałszywych alarmów (Auc)



		Klasa przewidywana	
		0	1
Klasa rzeczywista	0	TN	FP
	1	FN	TP

Macierz rozbieżności

0 – klasa negatywna (negative, N)
(stan normalny)

1- klasa pozytywna (positive, P)
(stan odmienny od normalnego)

Demo – Python

- Proces ML
 - Wczytanie danych
 - Pogląd na strukturę
 - Czyszczenie i przygotowanie
- Budowa modeli klasyfikacyjnych
- Ocena jakości modeli
 - Podział na zbiór uczący/testowy
 - k-krotna walidacja krzyżowa



Źródła

- CIS 4190/5190: Applied Machine Learning (<https://www.seas.upenn.edu/~cis5190>)
- CIS 419/519: Introduction to Machine Learning by Eric Eaton
- CME 250: Introduction to Machine Learning by Sherrie Wang (<https://web.stanford.edu/class/cme250/>)
- EE376a: Information Theory meets Machine Learning by Kedar Tatwawadi (<https://web.stanford.edu/class/ee376a/>)