

Podstawy uczenia maszynowego (Machine Learning, ML)

Metody sztucznej inteligencji w systemach wytwarzania
i intralogistyce, 22.10.2024

dr inż. Tomasz Mączka

Politechnika Rzeszowska & Europa Systems

dr. inż. Tomasz Żabiński

Politechnika Rzeszowska



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 ML

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

0 0 0 1 1 1 1 1 1 2

2 2 2 2 2 2 2 3 3 3

3 4 4 4 4 4 5 5 5 5

6 6 7 7 7 7 8 8 8


9 9 9 9 9 9 9 9 9

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
 - 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

- 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/gsf/5937599688/>
Data from <https://nsidc.org/arcticseaicenews/sea-ice-tools/>

Uczenie nadzorowane

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

supervised learning




unsupervised learning




Uczenie nienadzorowane

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

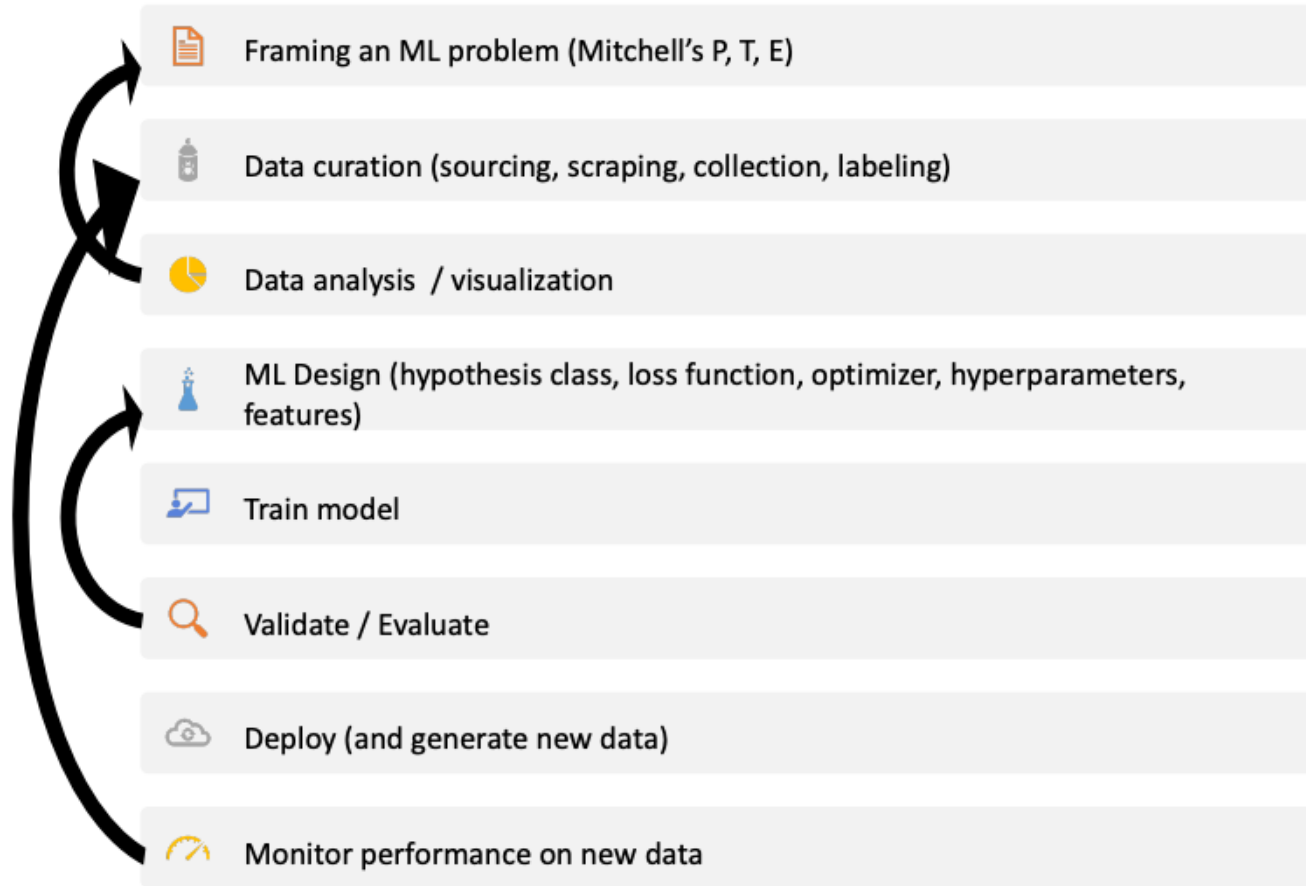


Uczenie ze wzmocnieniem

- 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



Sztuczna inteligencja

Inteligencja – *zdolność rozumienia otaczających sytuacji i znajdowania na nie właściwych celowych reakcji*

[Słownik wyrazów obcych, PWN, 2000]

Sztuczna inteligencja

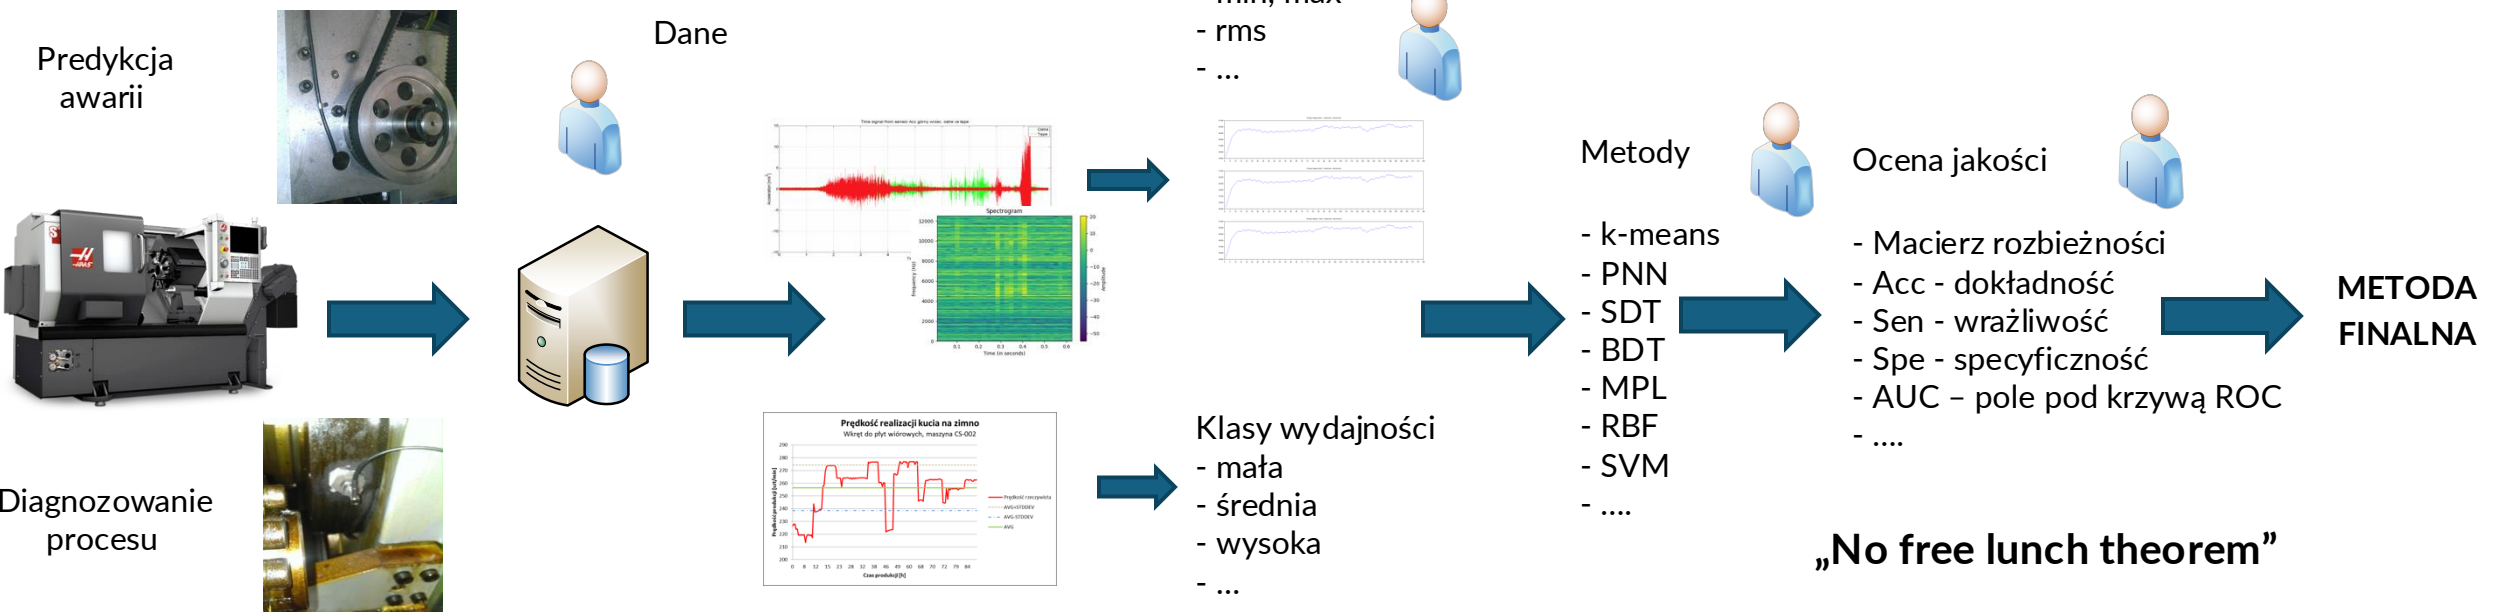
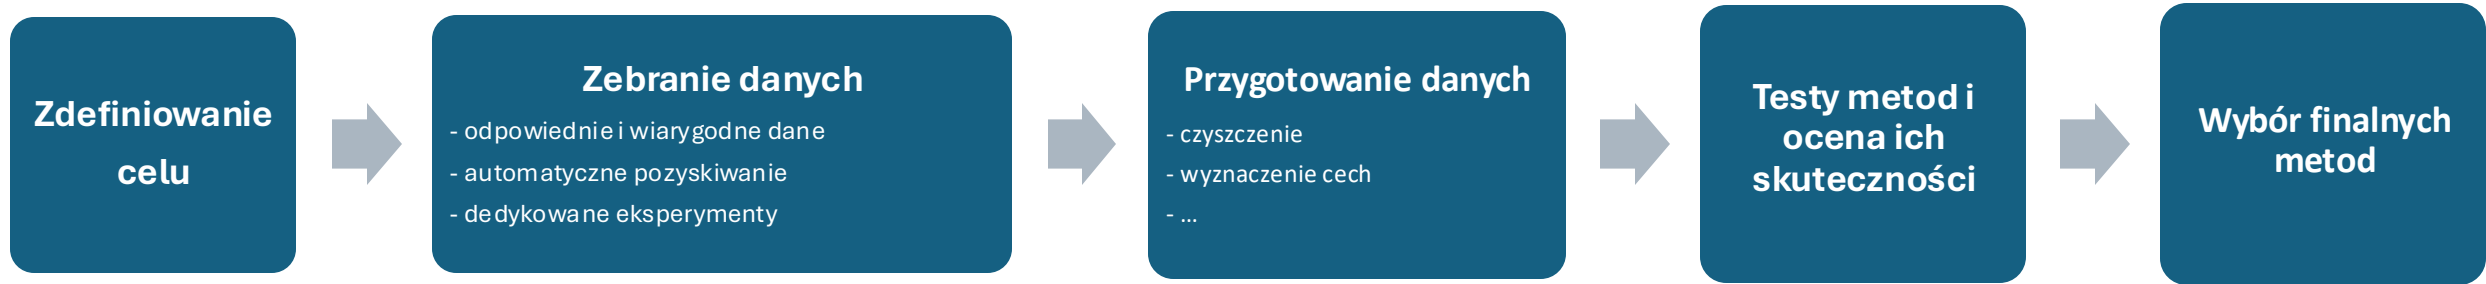
- ❑ Prace nad metodami obliczeniowymi [oprogramowaniem], które umożliwiałyby [maszynom] postrzeganie, wnioskowanie, działanie, odkrywanie wiedzy i mądrości
- ❑ [Automatyzacja] czynności, które wiążemy z myśleniem, takich jak: podejmowanie decyzji, rozwiązywanie problemów, zapamiętywanie... [R. Bellman, An Introduction to Artificial Intelligence, Boyd & Frase, 1978]
- ❑ ...

Inteligencja obliczeniowa

- ❑ Zaawansowana (maszynowa) analiza danych
- ❑ Odkrywanie wiedzy w gromadzonych danych i wsparcie w podejmowaniu decyzji
- ❑ Zdolność uczenia się, generalizacji, adaptacji i wnioskowania
- ❑ Wyszukiwanie związków przyczynowo-skutkowych, odkrywanie zasad, wzorców, zależności ...

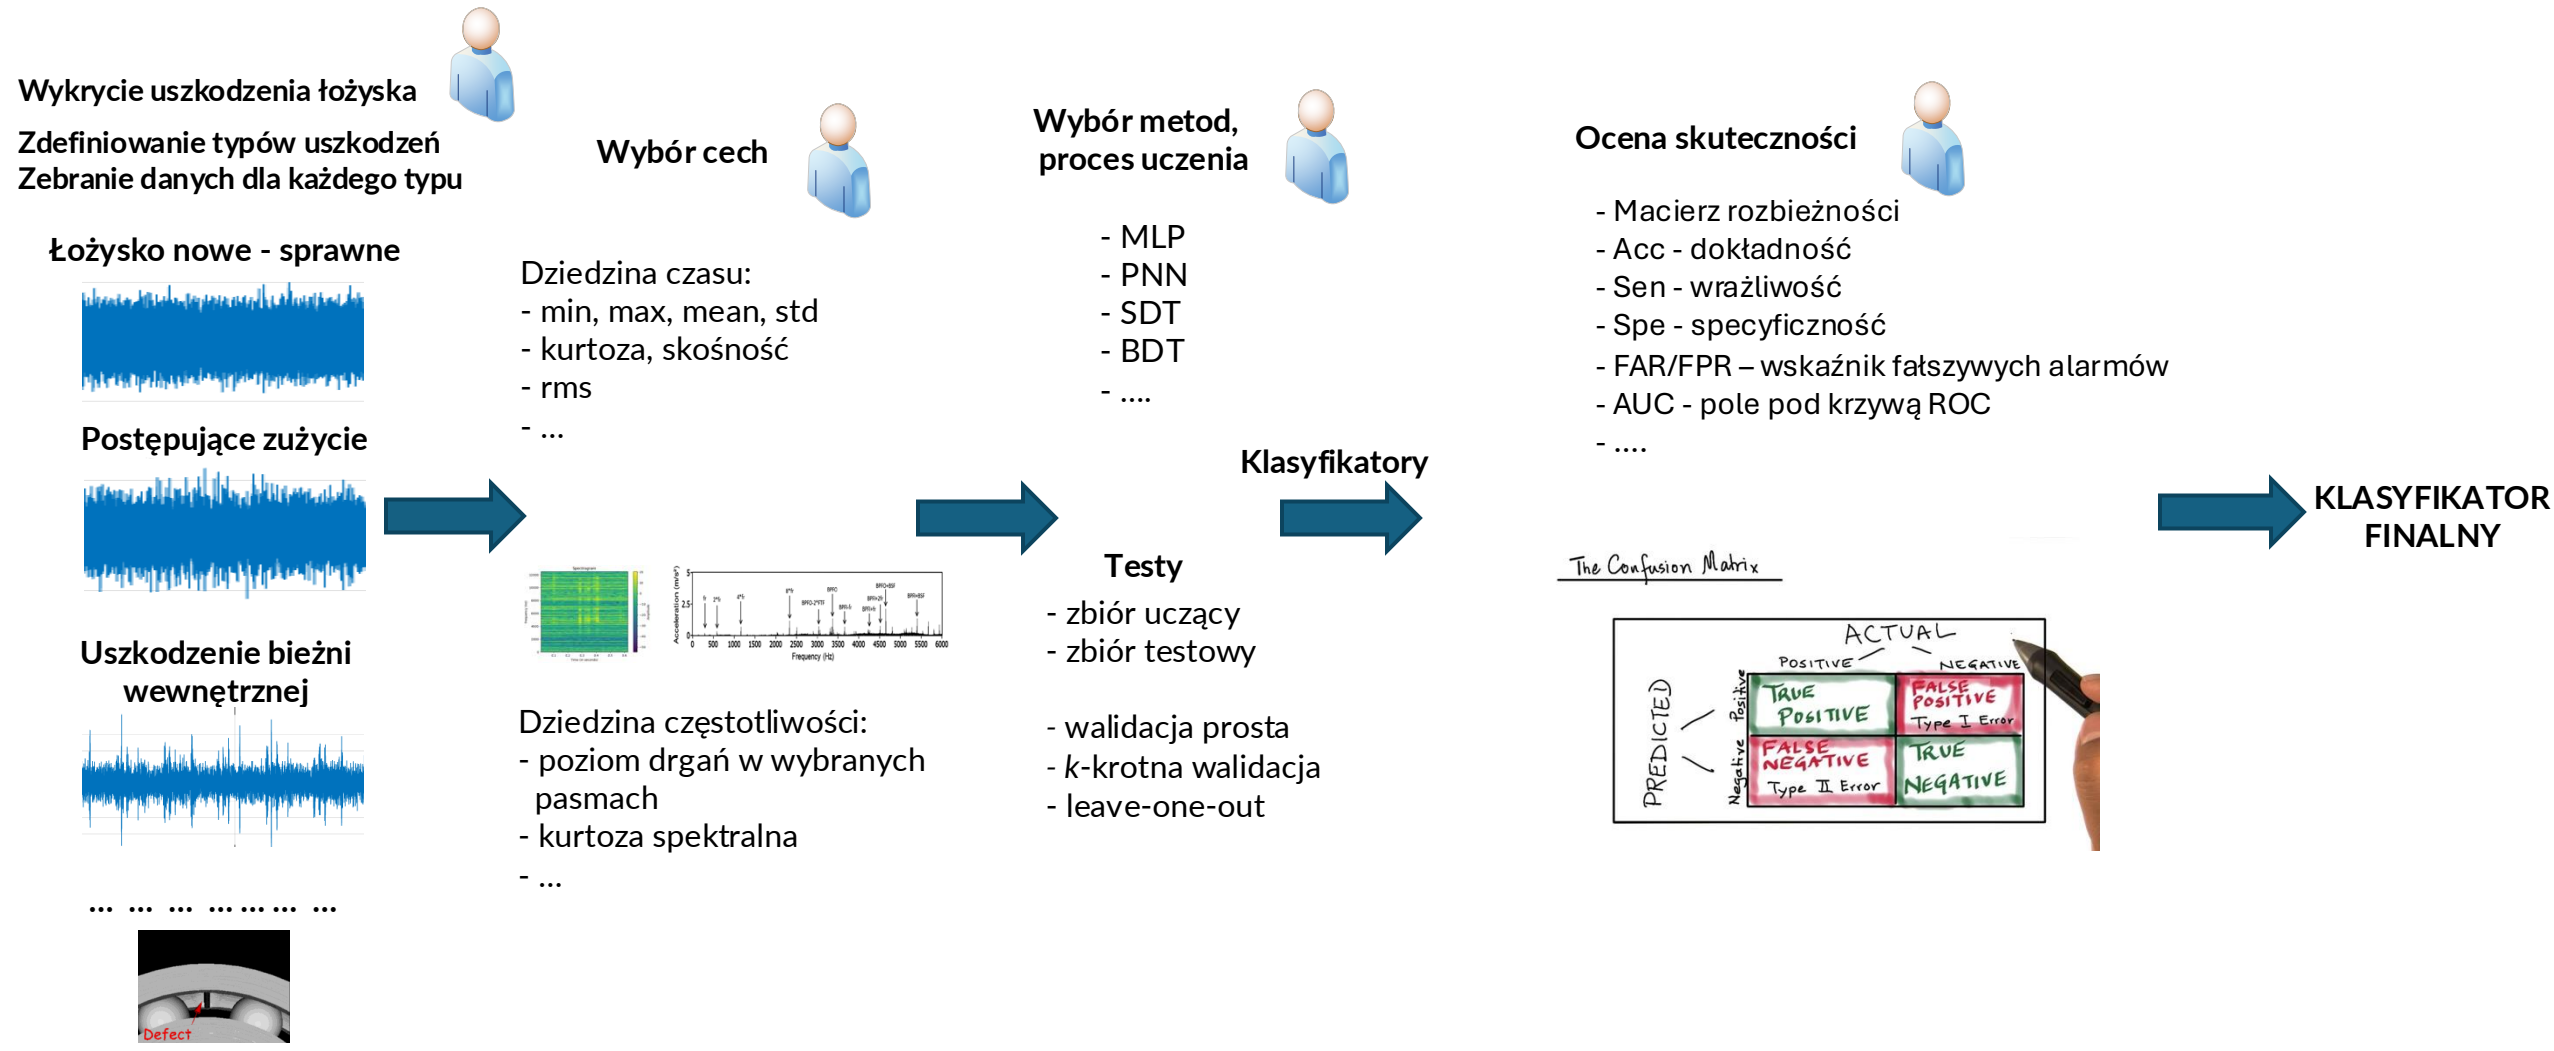
- ❑ Klasyfikacja/detekcja - diagnozowanie stanu procesów i maszyn
- ❑ Predykacja (prognozowanie) - przewidywanie sytuacji, np. awarii maszyn, opóźnień w realizacji planów produkcyjnych, ...
- ❑ Maszynowe odkrywanie sekwencji zdarzeń, np. prowadzących do awarii lub powodujących obniżenie wydajności

Inteligencja obliczeniowa – procedura użycia




Diagnostowanie (klasyfikacja wieloklasowa) – idea metody

- ❑ Działanie: określanie jednego z kilku stanów (klas) na podstawie aktualnych danych
- ❑ Stanów może być wiele, wymagana znajomość wszystkich możliwych przypadków (stanów, klas)
- ❑ Dane wejściowe do procesu uczenia: wymagane zbalansowane dane w dużej ilości dla wszystkich klas
- ❑ Zastosowanie: diagnostowanie stanu maszyn, wykrywanie typów uszkodzeń łożysk, ...



Detekcja anomalii/nowości (klasyfikacja jednoklasowa) – idea metody

- ❑ Działanie: określanie jednego z dwóch stanów na podstawie aktualnych danych – wykrywanie sytuacji niestandardowych (anomalii/nowości)
- ❑ Tylko dwie klasy: Stan typowy (poprawny, Normal) vs Stan odmienny (anomalna, Anomaly, Novelty)
- ❑ Dane wejściowe do procesu uczenia: wymagane dane jedynie dla przypadku typowego (Normal) – dane niezbalansowane
- ❑ Zastosowanie: diagnozowanie stanu – typowy/normalny (sprawny) vs odmienny (nowość/anomalna)



Klasyfikacja – ocena skuteczności klasyfikacji

Diagnostyka techniczna

Positive – stan normalny (urządzenie sprawne)

Negative – awaria

Macierz rozbieżności

		Klasa określona przez klasyfikator	
		Positive	Negative
Klasa rzeczywista	Positive	TP	FN
	Negative	FP	TN



Podstawowe wskaźniki skuteczności klasyfikacji

❑ Dokładność (Accuracy)

Określa ile procent przypadków z całego zbioru testowego rozpoznano poprawnie

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

❑ Wrażliwość (Sensitivity)

Jak skutecznie jest wykrywana awaria

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

❑ Specyficzność (Specificity)

Jak skutecznie jest wykrywany stan poprawny

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

❑ Wskaźnik fałszywych alarmów (False alarm rate)

Jak dużo jest niezasadnych alarmów

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

Uwaga - gdy dane nie są zbalansowane powyższe wskaźniki należy używać ostrożnie

Dane:

- łożysko sprawne (99)

- łożysko uszkodzone (1)

		Sprawne	Uszkodzone
Sprawne	99	0	
Uszkodzone	1	0	

$$Acc = \frac{99 + 0}{99 + 1 + 0 + 0} \cdot 100\% = 99\%$$


$$Sen = \frac{0}{0 + 1} \cdot 100\% = 0\%$$

Klasyfikator nie rozpoznał prawidłowo uszkodzenia !

Detekcja i predykcja – idea

Detekcja, podejście tradycyjne - metoda progowa

Czujnik



Górna granica

Dolna granica

Predykcja - system wczesnego ostrzegania

Czujnik

Czujnik

Ostrzeżenie

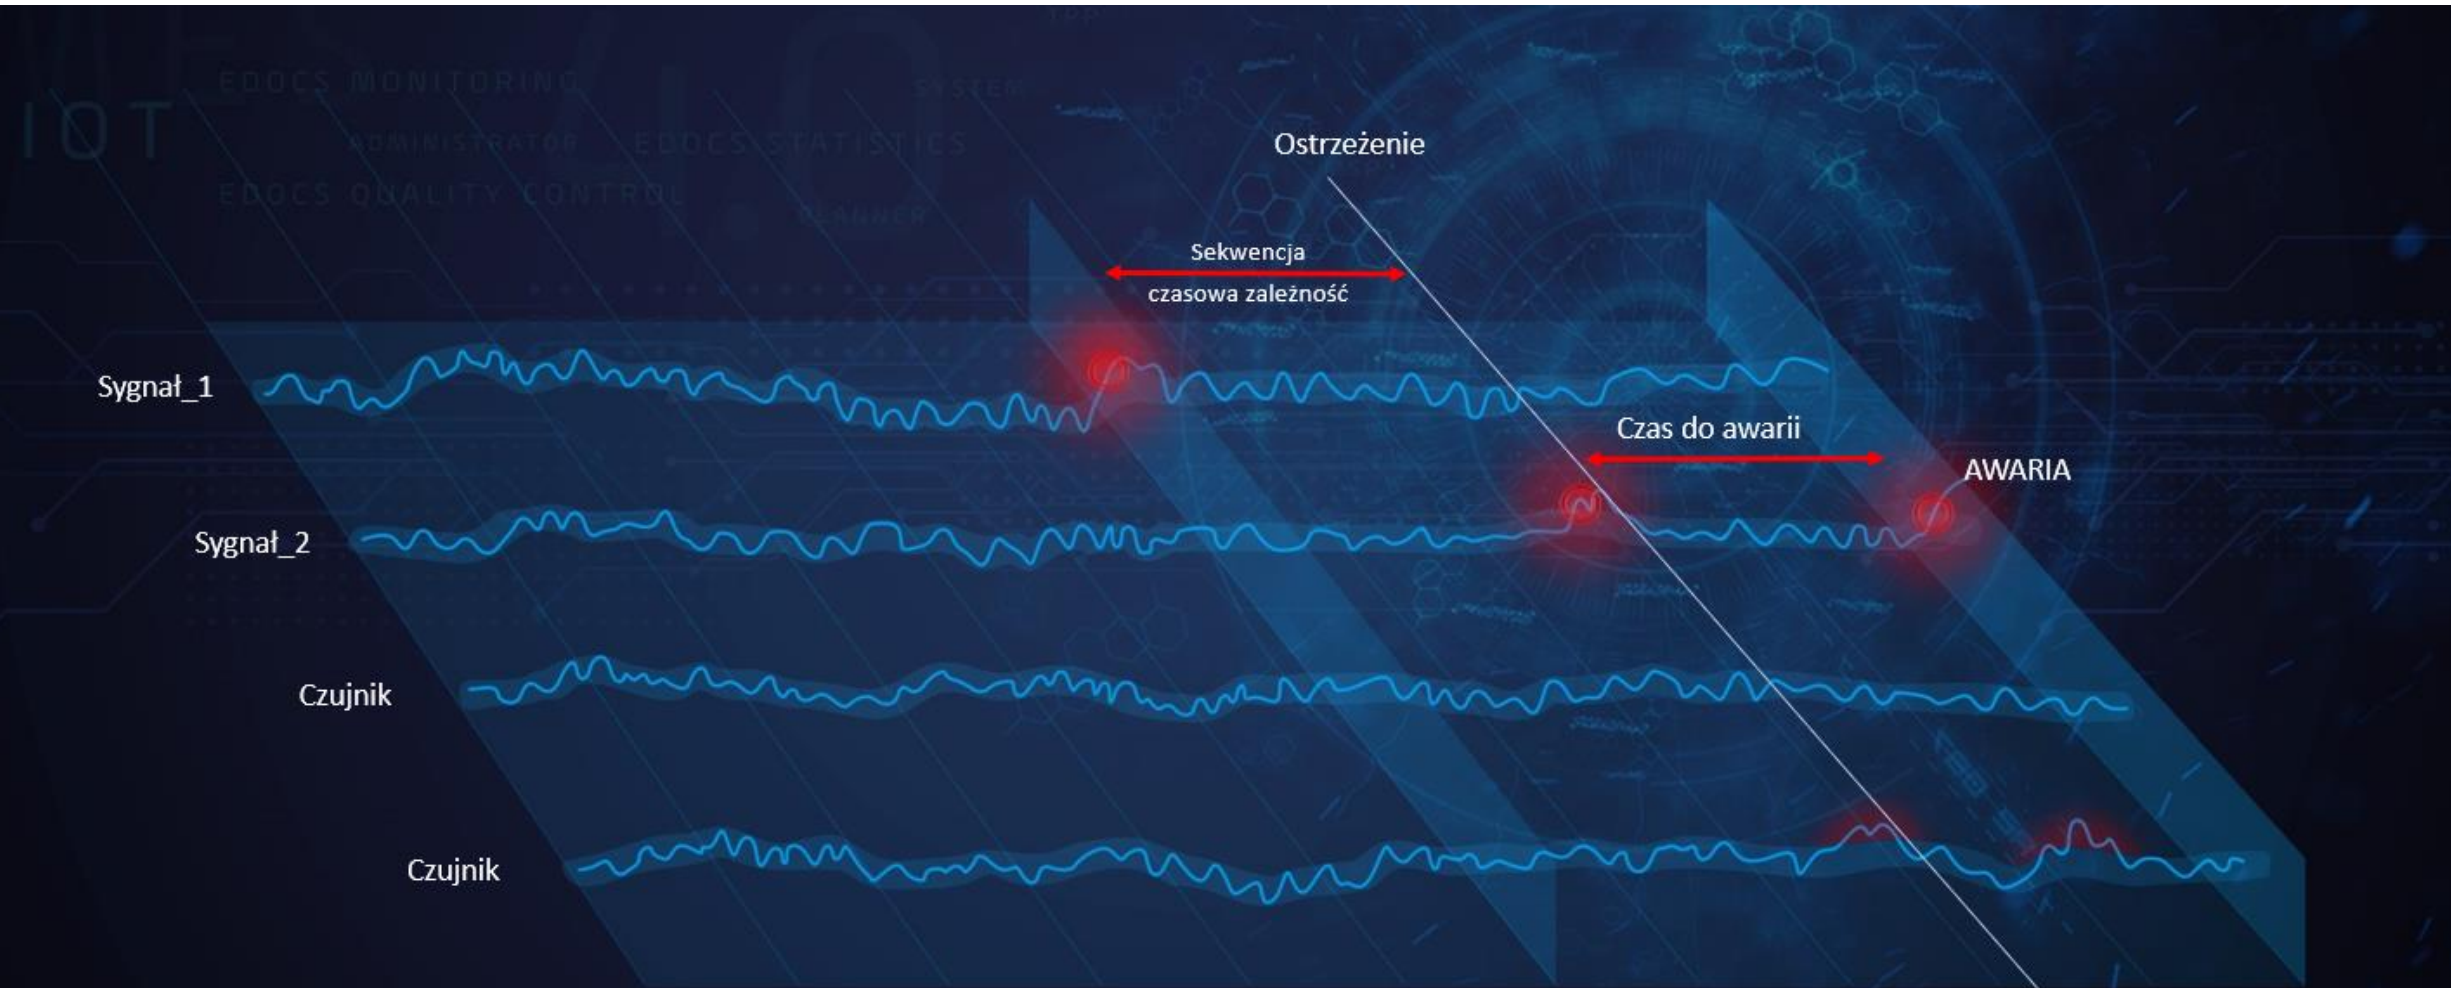
Czas do awarii

AWARIA



Predykcja awarii – idea

System wczesnego ostrzegania - kilka sygnałów, sekwencja czasowa



Związki przyczynowo-skutkowe – idea metody

- Działanie: odkrywanie wzorca sekwencji zdarzeń zachodzących w pewnym przedziale czasu i mogących prowadzić do pewnego skutku (np. awarii, obniżenia efektywności), odkrywanie związków przyczynowo-skutkowych
- Wzorzec zwracany w postaci zdań warunkowych: **JEŻELI A i C lub B TO D**
- Dane wejściowe: dane historyczne dotyczące zdarzeń i czasu ich wystąpienia (np. awarie, symptomy, produkcja braków, zmiana parametrów procesu)
- Zastosowanie: realizacja przeglądów/kontroli na podstawie informacji o możliwości i prognozowanym czasie do wystąpienia potencjalnej awarii, wykrywanie reguł w danych np. jakie symptomy poprzedzają awarię, jakie czynniki powodują obniżenie wydajności lub produkcję braków

Reguła: $L \rightarrow P$

np. **JEŻELI** Sygnał_1 = Górny_Limit i Sygnał_2 = Górny_Limit i Czas pomiędzy nimi = <X, Y> **TO OSTRZEŻENIE – 90 %**

Wskaźniki oceny reguł

- **Wsparcie** (Support)

$$supp(L \rightarrow P) = \frac{|T_{L \cup P}|}{|T|}$$

Informuje jak częsty (istotny) jest przypadek gdy

Sygnał 1 = Górny_Limit i Sygnał 2 = Górny_Limit i Czas między nimi = <X, Y> to AWARIA

w stosunku do wszystkich przypadków awarii danej części

- **Ufność** (Confidence)

$$conf(L \rightarrow P) = \frac{|T_{L \cup P}|}{|T_L|}$$

Informuje jak wiarygodna jest reguła, tzn. ile razy przypadek

Sygnał 1 = Górny_Limit i Sygnał 2 = Gorny_Limit i Czas między nimi = <X, Y>

zakończył się awarią

Związki przyczynowo-skutkowe – przykład



Reguła: $L \rightarrow P$

Browser window showing a PDM application interface. The URL is localhost:8080/result/2. The application header includes 'Zbik' logo and navigation links: Home, My Notifications, Results, Problem List, Delivery Setup, Notifications Setup, Audit, and Logout admin.

Metadata for the process:

- Name: Cold forging process
- Trigger: Every Friday at 09:00 am
- Completed on: 04.05.2017 09:12
- Data set: Production efficiency metrics
- Parameter: Efficiency per machine
- Condition: Speed below tech. card

Results

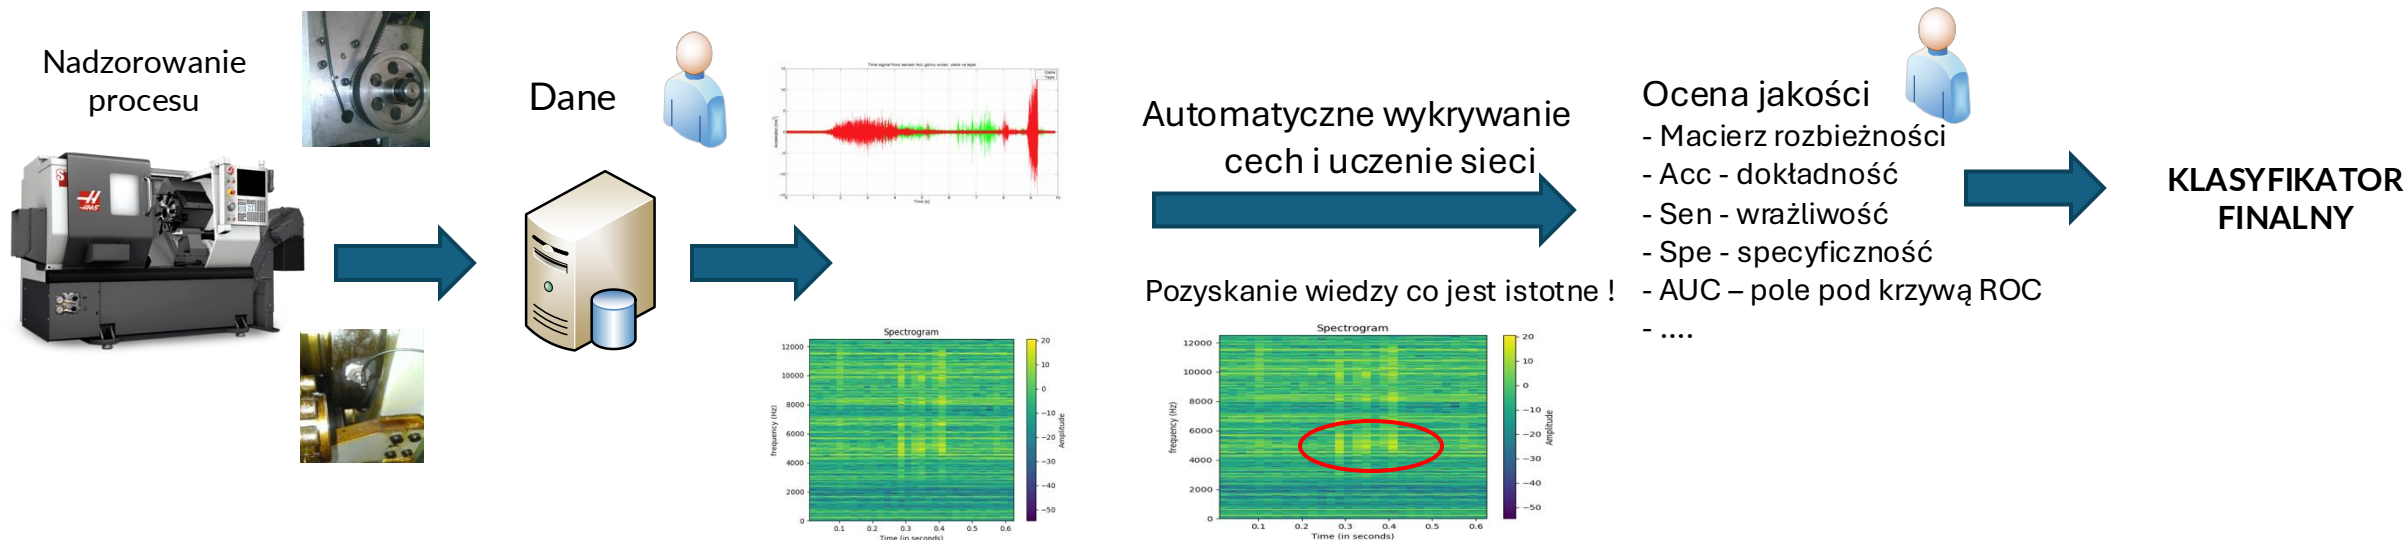
- (12; 0.929): if product_id = 1186-F060-0350 and machine_id = T01 and material_id = 214 => class=-1, [assumed class: 1]
- (15; 0.941) : if product_id = 1186-F060-0350 and machine_id = T01 and material_id = 219 => class=-1, [assumed class: 1]

Interpretation

- Machine: T-01
- Product: Chipboard screw rys.1186 6,0 x 35 . Pz UI.
- Production speed lower than that assumed in the technology card when material is 1022 AL 4,35 Best Wire gal.C1022Al or Wire 19MnB4 - 4,35 Bohumin
- Technology Card: 230 items/min
- Real Speed: 141-187 items/min

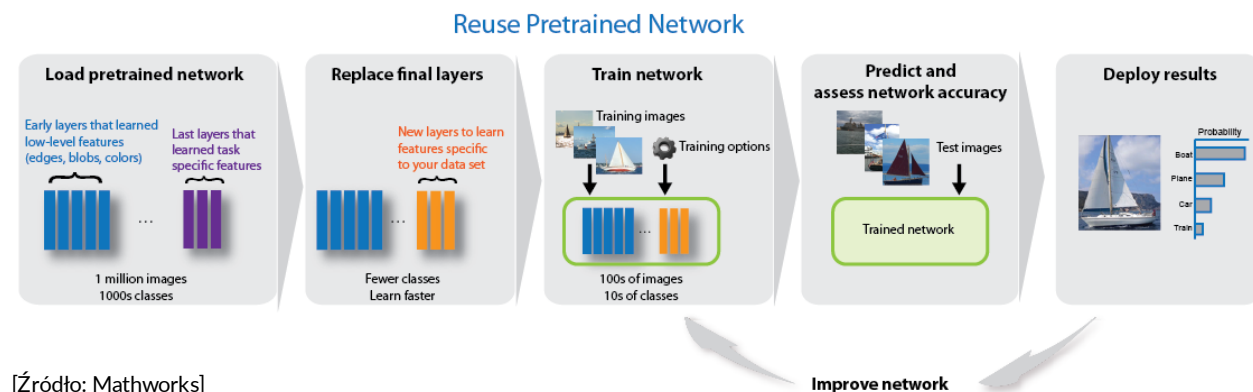
Uczenie głębokie - deep learning

- ❑ Sieć samodzielnie definiuje cechy
- ❑ Wymaga ogromnych ilości danych (masywy danych)




Transfer learning

- ❑ Transfer learning służy do ponownego wykorzystania wcześniej opracowanego modelu (klasyfikatora) do nowego problemu
- ❑ Wymaga stosunkowo niewielkiej ilości danych do douczenia



Sztuczna inteligencja



Artificial Intelligence



what people think it is



what amateur
programmers think it is

```
1  
2 // 10,000 if-statements  
3  
4 if() {  
5     if() {  
6         if() {  
7             if() {  
8                 if() {  
9                     if() {  
10                        if() {  
11                            if() {  
12                                if() {  
13                                    if() {  
14                                        if() .
```

what actually it is

Sztuczna inteligencja

- Działania
 - Strategiczne
 - Taktyczne
 - Operacyjne



Mądrość

Zrozumienie zasad



działania strategiczne
- zrozumienie istoty problemu
- czy uruchomić własną produkcję materiału



Wiedza

Dopasowanie schematów



produkcja z materiału od danego dostawcy powoduje obniżenie efektywności procesu wytwarzania
- reakcja: wycofanie materiału, zmiana dostawcy



Informacje

Ustalenie relacji, kontekst, cel



jaka była struktura czasu pracy maszyny, wydajność, typ materiału, dostawca materiału, ... przy realizacji konkretnych asortymentów/produktów



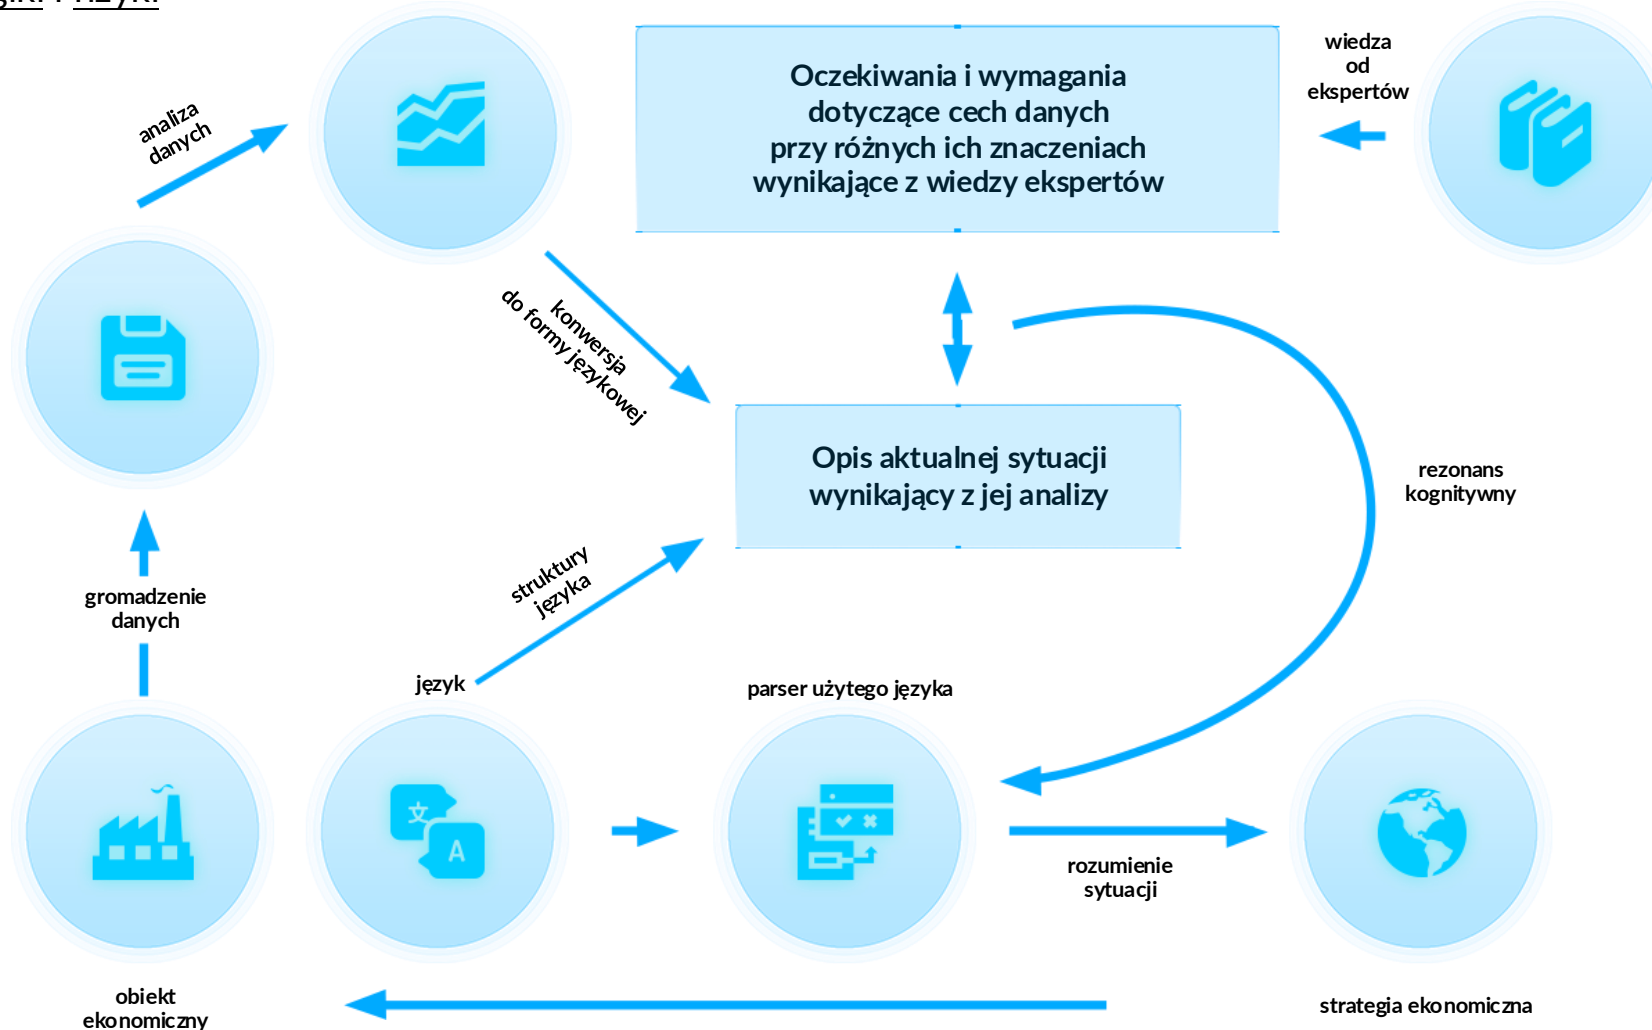
Dane



SCADA, MES, ERP: struktura czasu pracy maszyny, wydajność, realizowane zlecenia, wytwarzane asortymenty/produkty, typy materiału i narzędzi, dostawcy materiałów i narzędzi, ...

Systemy kognatywne (poznawcze) - przyszłość

- ❑ Rozumienie znaczenia danych przez system sztucznej inteligencji
- ❑ Wsparcie działań strategicznych
- ❑ **Kognitywistyka** - interdyscyplinarna dziedzina nauki zajmująca się obserwacją i analizą działania zmysłów, mózgu i umysłu, znajduje się na pograniczu wielu dziedzin: psychologii poznawczej, neurobiologii, filozofii umysłu, sztucznej inteligencji, lingwistyki oraz logiki i fizyki



Demo – Python

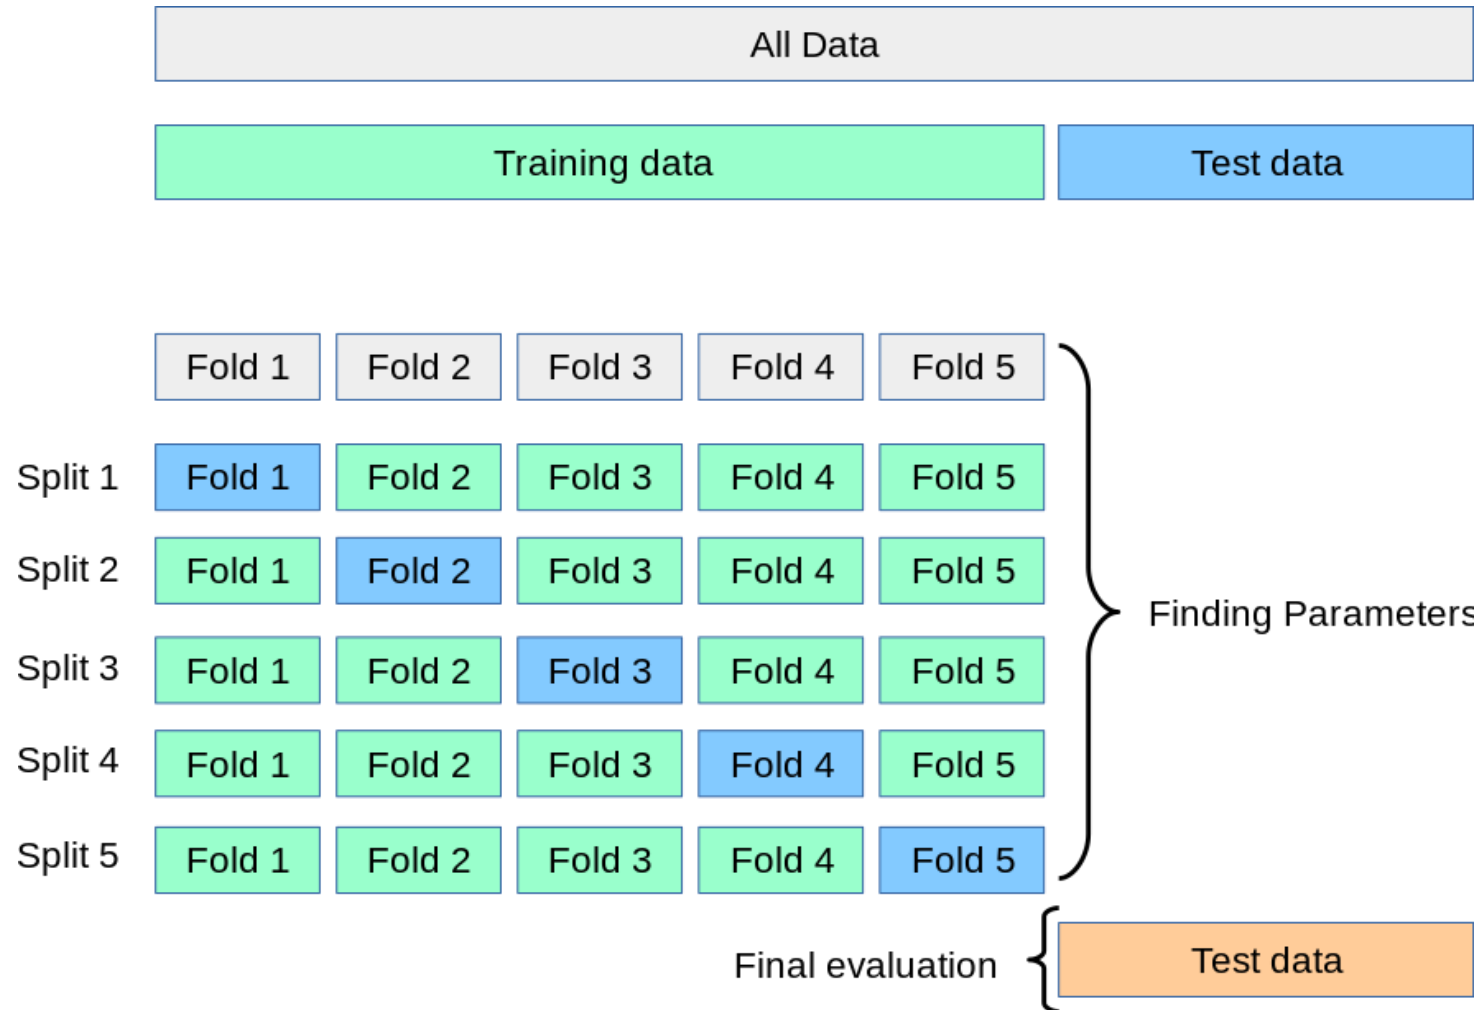
- Proces ML
 - Wczytanie danych
 - Pogląd na strukturę
 - Czyszczenie i przygotowanie
- Budowa modeli klasyfikacyjnych
- Ocena jakości modeli
 - Podział na zbiór uczący/testowy
 - k-krotna walidacja krzyżowa



Demo – zbiory danych

- <https://github.com/mwaskom/seaborn-data>
- <https://datasets.kia.prz.edu.pl>

Demo – testowanie klasyfikatorów



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/>)