

Predyktywna Sztuczna Inteligencja

Uczenie maszynowe I



Włodzisław Duch

Katedra Informatyki Stosowanej UMK

Google: Włodzisław Duch

Co było



- Teorie poznania
- Systemy oparte na wiedzy
- Modele kognitywne
- SOAR
- ACT
- Cog
- Watson
- Cyc

Co będzie



- Uczenie maszyn
- Metody indukcyjne
- Metody oparte na podobieństwie
- Drzewa decyzyjne
- Algorytmy genetyczne
- Sieci neuronowe
- Deep learning

Wykłady z inteligencji obliczeniowej omawiają uczenie maszynowe dokładniej.

Przyszłość AI



Frankly, I don't see any reason to set limits on what AI can do. We have in our heads a wonderful computer. It is made of meat, but it's a computer. It's extremely noisy, but it does parallel processing. It is extraordinarily efficient, but there is no magic there.

So, it is difficult to imagine that, with sufficient data in the future, there will remain things that only humans can do.

You should replace humans by algorithms whenever possible.

Daniel Kahneman (Nobel 2002).

Uczenie maszynowe

- Jeśli problem jest dostatecznie precyzyjnie zdefiniowany może napisać program, który jest implementacją algorytmu. Większość oprogramowania taka była, nie było potrzeby dodatkowego uczenia się.
- Uczenie maszynowe umożliwia mechanizację akwizycji wiedzy. To część sztucznej inteligencji, symbolicznej AI lub obliczeniowej.
- To alternatywa dla tworzenia reguł na podstawie analizy zachowań ekspertów lub samodzielnego odkrywania wiedzy.
- ML czerpie inspiracje z ogólnych metod informatyki, takich dziedzin jak data mining, statystyki, rozpoznawania struktur (pattern recognition), sieci neuronowych i kognitywistyki.
- ML tworzy modele zmieniające swoje wewnętrzne parametry tak, by rozpoznać ogólne cechy danych umożliwiając odkrycie ich znaczenia – kategorii, numerycznej oceny wartości.
- Wielkie zainteresowanie ML nastąpiło dzięki dobrym wynikom analizy obrazów w dekadzie 2010-20.

Porównanie czasów rozwoju ES

Nazwa	Typ	L. reguł	Czas (lat)	Poprawki (lata)
MYCIN	ES	1.000	100	wiele
XCON	ES	8.000	180	30
GASOIL	ML	2.800	1	0,1
BMT	ML	30.000	9	2

Dzięki ML drastycznie skraca się czas rozwoju złożonych systemów ekspertowych.
BMT Group Ltd (British Maritime Technology), sterowanie statkami.

Uczenie maszynowe

- System uczący się używa danych by utworzyć ich model, pozwalający na przewidywanie zachowania dla przyszłych danych. Celem jest generalizacja zdobytej wiedzy.
- Uczenie: zmiany w systemie adaptującym się pozwalające mu w przyszłości działać bardziej efektywnie na zadaniach o podobnym lub analogicznym charakterze. Potrzebne jest wszędzie tam, gdzie nie potrafimy zaprogramować rozwiązania zadania, z braku możliwości symbolicznej reprezentacji, lub nieprzewidywalności opisu wszystkich możliwości.
- Eksperci opisują sytuacje podając przykłady. W GOFAI był to głównie opis symboliczny ale to bardzo ograniczona metoda. Czasami wiedzę można wyrazić w postaci symbolicznej, ale często zdobywamy ją bezpośrednio z obserwacji za pomocą zmysłów i trudna to opisać symbolicznie.
- Reguły potrzebne do wnioskowania otrzymane metodami ML mogą być lepsze niż reguły wydedukowane przez ludzi. Jednak wiele zagadnień nie da się przedstawić w postaci reguł.
- Brak wyjaśnialności jest jednym z ważnych problemów ML, który próbuje rozwiązać XAI.

Motivation: data=>knowledge




- AI systems: “spoon-feeding” knowledge instead of autonomous learning. Meanwhile: computer memory increased, database and sensor technology created data explosion problem.
- Information repositories, data warehouses keep all kinds of data, internet became a source of data about people’s behavior.
- **We are drowning in data, but starving for knowledge!**
- Search for knowledge in data – use on-line analytical processing (OLAP) and machine learning techniques for data mining.
- Extract interesting knowledge (rules, regularities, patterns, constraints, correlations, summaries) from large databases.
- 1990-2000: data mining and data warehousing, multimedia databases, and Web databases started the “big data” movement.
- Data scientist – in 2018 it became a hottest job!

Machine Learning Process





Environment




Data Mining &
Knowledge Discovery


Machine
Learning




Decision
Model



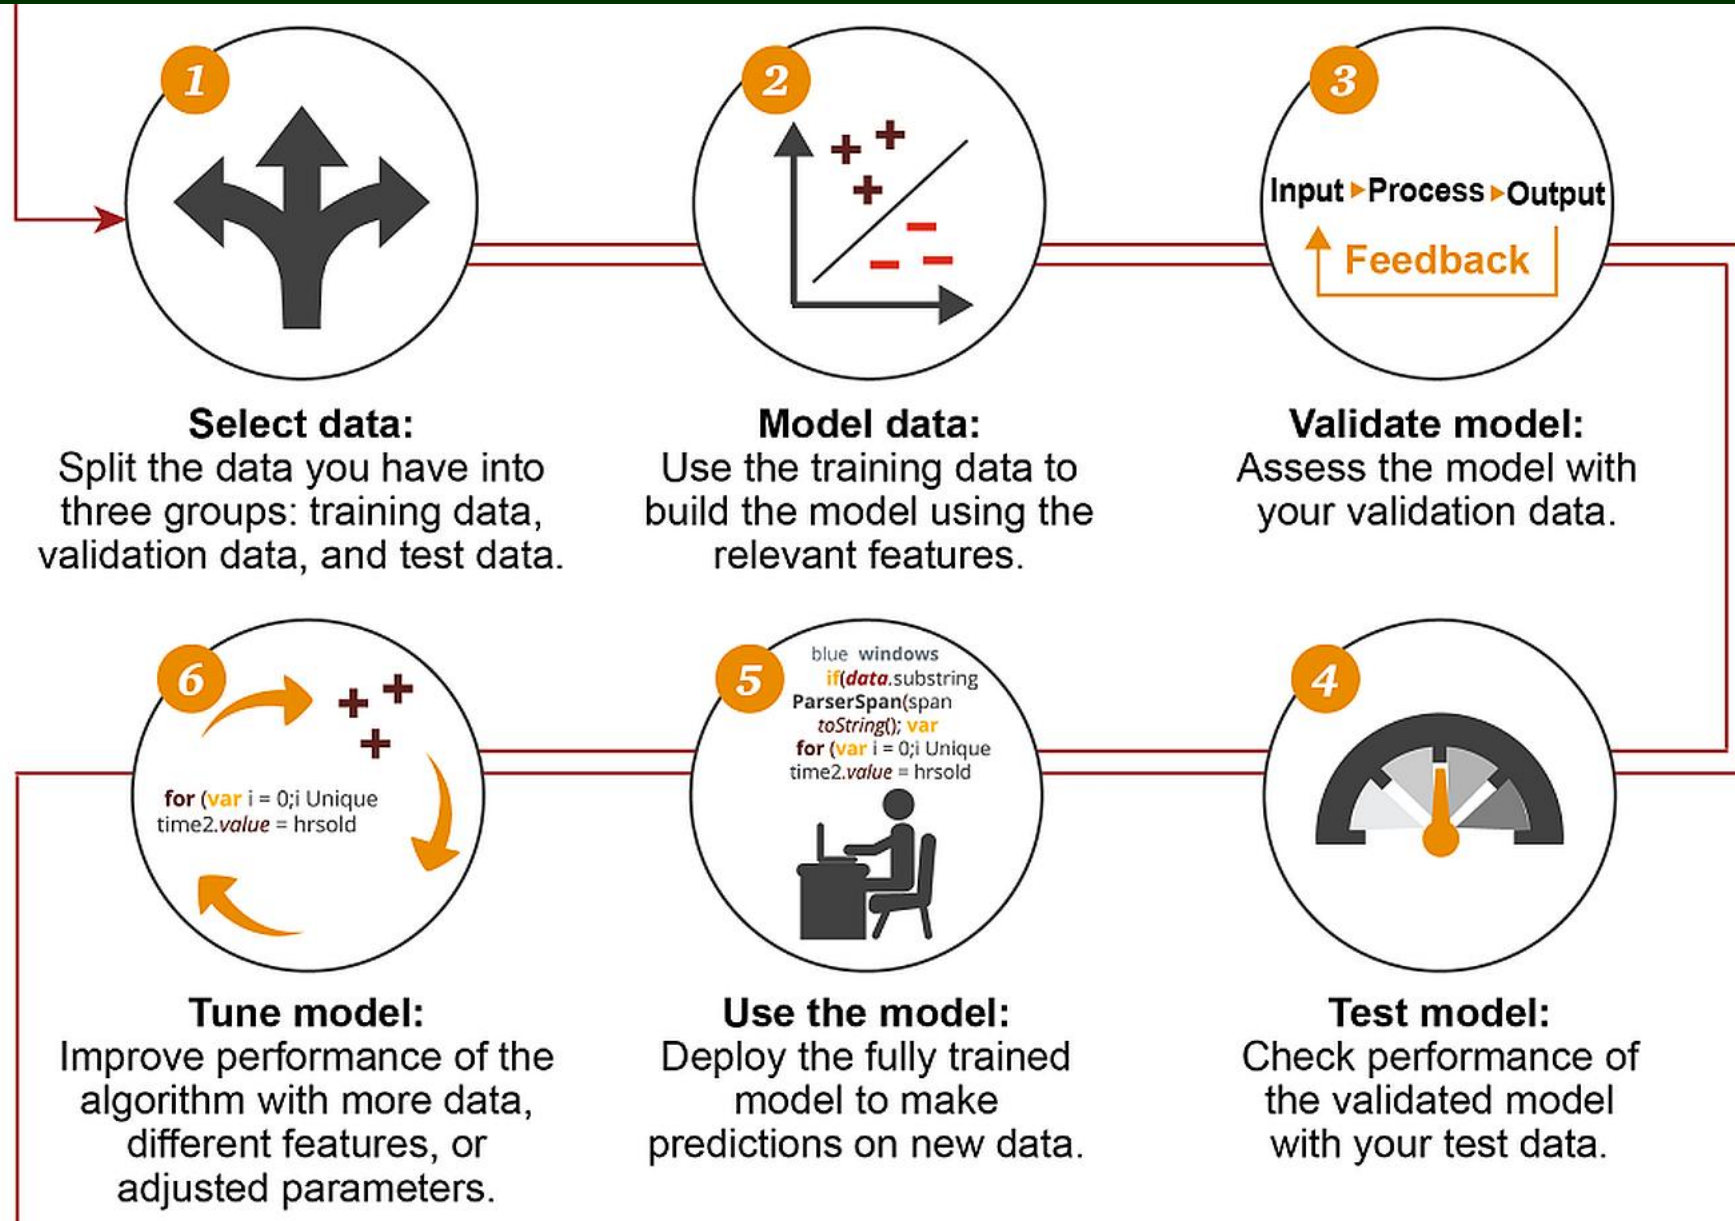
Decision



Data Mining and Business Intelligence




Proces analizy danych: Data Mining



Data Mining

DM część KDD - Knowledge Discovery in Databases.

Szukanie wiedzy w bazach danych, oparte na metodach ML/CI.



Dane - duże bazy, komercyjne, techniczne, tekstowe (WWW).

Selekcja - wybieranie podzbioru danych i atrybutów do analizy.


Pre-processing - wstępne przetwarzanie, czyszczenie danych (szum i wyrzutki), uzupełnianie braków, standaryzacja ...

Transformacja - do postaci akceptowalnej przez program.

DM - klasyfikacja, regresja, klasteryzacja, wizualizacja ...

Tutorial na [temat data mining](#).

Taksonomia metod Data Mining



Machine Learning

DM i statystyka


1 Traditional programming

The software engineer writes a program that solves a problem.



Software engineer writes a procedure that tells the machine what to do to solve the problem.


```
class FREE!!! implements SpamDetector
{
    public function detect($string)
    {
        if (str_word_count($string) = FREE!!!) {
            return true;
        }
        return false;
    }
}
```



Computer follows the procedure and generates a result.

2 Statistics

An analyst compares the relationships of variables.



Klasy metod ML


Powszechnie stosowane metody, ML w Python, [scikit-learn](#)

- Drzewa decyzji/indukcja reguł.
- Logika rozmyta, systemy na regułach rozmytych.
- Rozumowanie oparte na analogiach, precedensach (case-based)
- Skojarzenia oparte na pamięci (memory-based)
- Dyskryminacja liniowa LDA, SVM - Maszyny Wektorów Wsparcia (klasyfikacja, regresja).
- Sieci neuronowe w wielu odmianach, głębokie sieci neuronowe, sieci konwolucyjne.
- Sieci probabilistyczne (Baysowskie), Naiwny Bayes.
- Algorytmy genetyczne.
- Redukcja wymiarowości, rozmaitości (manifolds).
- Indukcyjne programowanie logiczne (ILP)
- Uczenie ze wzmocnieniem (reinforcement), sterowanie, kontrola, strategie.
- HMM, ukryte modele Markova, modele przestrzeni stanów.
- Modele topologiczne (TDA, topological data analysis)


Więcej: [scikit projects](#). Kombinacja wszystkich modułów => miliardy możliwości ...

Metalearning - automatyczne tworzenie modeli.


Wybierz co chcesz zrobić.




3 typy ML



Subtypes of ML



Wiele rodzajów algorytmów ML



Uczenie z nadzorem

Uczenie z nadzorem: podział na znane klasy, przekazywanie znanej wiedzy, heteroasocjacja - kojarzenie obiektów/własności, jak w szkole.

Wymagany jest:

Opis obiektów/danych X , zwykle w postaci wektorów cech, pomiarów własności.


System A adaptujący swoje parametry W do danych.

Pożądane odpowiedzi $Y(X)$

Wyniki działania: $Y' = A(X; W)$

Funkcja błędu/kosztu $E(Y, Y')$

Algorytm minimalizujący błędy na danych treningowych



Cel uczenia: dla nowych danych X otrzymać wyniki $A(X; W) \approx Y(X)$, czyli generalizacja zdobytej wiedzy. Dane treningowe mają tu etykiety.

Uczenie bez nadzoru

Chcemy uprościć opis złożonych danych, bez nadzoru, spontaniczne.

Dominuje w okresie niemowlęcym, nadawanie sensu danym zmysłowym, nauka chodzenia wymaga odkrycia struktur w sygnałach, np. rozumienie mowy wymaga kategoryzacji fonemów w sygnale dźwiękowym.

odkrywanie ciekawych struktur w przestrzeni danych,
korelacja zachowań systemu ze zmianą tych struktur.

Opis danych/sygnałów $p_i \in P$

System adaptujący się


Miary podobieństwa $S(p_i, p_j)$

Algorytm uczący, analizujący rozkłady
miar podobieństwa.

Tworzenie odróżnialnych skupień S_i

Funkcja jakości grupowania $E(S_i, S_j)$

Bioinformatyka – motywy; segmentacja
klientów, analiza sygnałów ...



Uczenie zachowań (reinforcement learning)

Uczymy się też z sukcesów i porażek po wykonaniu jakiegoś zadania.

Nie ma wtedy informacji o błędach po każdym kroku, potrzebna jest strategia, optymalizacja zysków na dłuższą metę. To uczenie behawioralne, nabieranie „mądrości”. Uczenie z krytykiem lub „z wzmocnieniem” ([reinforcement learning](#)) pozwala nauczyć się przydatnych strategii zachowań, np. agenty, roboty, gry z przeciwnikiem: przegrana lub wygrana dopiero na końcu partii.

Potrzebny jest:


Opis stanów X w obserwowanym środowisku.

Opis akcji a , działania agenta A w stanie s .

System adaptujący prawdopodobieństwa zmiany stanu $s \Rightarrow s'$ pod wpływem akcji a .

Zmiana stanu środowiska i miara nagrody.

Algorytm tworzący plany zwiększające końcową nagrodę.



Drzewa decyzji

function DT(E : zbiór przykładów) **returns** drzewo;

$T' :=$ buduj_drzewo(E);

$T :=$ obetnij_drzewo(T');

return T ;

function buduj_drzewo(E : zbiór przykładów) **returns** drzewo;

$T :=$ generuj_tests(E);

$t :=$ najlepszy_test(T, E);

$P :=$ podział E indukowany przez t ;

if kryterium_stopu(E, P)

then return liść(info(E))

else

for all E_j **in** P : $t_j :=$ buduj_drzewo(E_j);

return węzeł($t, \{(j, t_j)\}$);

DT do klasyfikacji

Testy: podział pojedynczej cechy, lub kombinacji
Atrybut={wartość_i} lub Atrybut < wartość_i

Kryteria: maksymalizacja ilości informacji,
maksymalizacja liczby poprawnie podzielonych obiektów,
„czystość” węzła.


Przycinanie: usunąć gałęzie, które zawierają zbyt mało przypadków
prostsze drzewo może lepiej generalizować
ocenić optymalną złożoność na zbiorze walidacyjnym.

Kryterium stopu: osiągnięta dokładność podziałów,
zbyt złożone drzewo, za mało przypadków do podziału.


Popularne systemy: C4.5, CART – szybkie i często wystarczające.
SSV, Separability Split Criterion (K. Grąbczewski)

DT - przykład

Klasy: {rakowe,
zdrowe}




Cechy: ciało komórki: {cienie, paski}
jądra: {1, 2}; ogonki: {1, 2}



Indukcja reguł

DT: tworzą reguły hierarchiczne


Utwórz reguły próbując pokryć obszar przestrzeni, w którym znajdują się wektory określonej klasy.




Zalety: łatwo zrozumiałe, dobra reprezentacja hipotez.

Wady: powolne działanie, algorytmy pokrycia NP-trudne

Przykłady: CN2, AQ-nn, GREEDY ...



Abstrahowanie od
szczegółów => rakowe
jeśli:



Przestrzenie wersji

Indukcja reguł/pojęć na podstawie analizy danych

Miejsce	Posiłek	Dzień	Koszt	Reakcja
DS. 1	śniadanie	Piątek		tanio
Tak				
Kosmos lunch		Piątek	drogo	Nie
DS. 1	lunch	Sobota	tanio	
Tak				
Bar mleczny	śniadanie	Niedziela	tanio	
W jakich warunkach mamy reakcje alergiczne?				
DS. 1				
Tak				
Miejsce	Posiłek	Dzień	Koszt	
3	X	3	X	7
			X	2
				= 126

Jeden z pierwszych algorytmów uczenia w AI.
Obecnie mało używane.

Ocena podobieństwa (similarity-based)

Pamiętaj przykłady i oceniaj podobieństwo; stosuj algorytmy „leniwe”, czyli oceniające sytuację dopiero wtedy, gdy znajdzie potrzeba.

Zalety: brak fazy uczenia, dobra dokładność jeśli dużo danych.


Wady: mogą wymagać dużo pamięci, konieczna selekcja atrybutów, konieczne dobranie odpowiednich funkcji podobieństwa, trudno zrozumiałe wyniki.

Przykłady: kNN, IBn, MBR ...

Możliwości wyboru: cech, prototypów,

liczby uwzględnianych prototypów,

oceny wkładu prototypów ...



Sieci neuronowe

Inspiracja neurobiologiczna: jak robią to mózgi?

Używa:

Neuronów - prostych elementów przetwarzających sygnały.

Synaps - parametrów adaptacyjnych związanych z połączeniami określającymi siłę pobudzeń.

Wyrafinowanych algorytmów korekcji parametrów (uczenia).


Funkcji kosztu/oceny jakości działania.

Wiele modeli: perceptrony wielowarstwowe (MLP), sieci RBF, samoorganizujące się sieci SOM ...

Zalety: uniwersalne, dużo symulatorów, odporne na szum w danych, wiele zastosowań i wariantów.

Wady: niektóre modele wolno się uczą, wymaga wielu danych, uczenie nie zawsze się kończy sukcesem, mają wiele parametrów, interpretacja jest trudna, mogą istnieć prostsze modele.

Selfridge's Model



Based on:

Selfridge, O. G. (1959). *Pandemonium: A paradigm for learning*. In *Symposium on the mechanization of thought processes* (pp. 513-526). London: HM Stationery Office.

A Sensory Stimulus



Sieci neuronowe - przykład

Wejścia: dane ciągłe lub dyskretne.
Neuron sumuje wartości sygnałów wejściowych określając pobudzenie.


$$f\left(\sum_i w_i X_i - \theta\right)$$

$f(\cdot)$ - funkcja schodkowa lub sigmoidalna
 q - prób działania neuronu.

W sieciach neuronowych wiele takich neuronów połączonych jest ze sobą realizując dowolnie skomplikowane funkcje.




Neural Networks



Wsteczna propagacja błędów


Algorytm rozpowszechniony od 1986 roku. Sieć ma wiele warstw elementów, zwanych neuronami.

1. Wiele przykładów (wektorów) na wejściu, znany wynik.
2. Różnica oczekiwanego wyniku od otrzymanego jest podstawą do korekty parametrów (wag).
3. Po nauczaniu, zwykle minimalizacją gradientu funkcji błędu, można ją stosować do nowych danych.
4. Uczenie nowych danych może popsuć działanie na wcześniejszych – katastroficzne zapominanie.




Klasyfikacja za pomocą sieci neuronowych

“Jakie czynniki wpływają na wybór ulubionej karmy psów?”




Klasyfikacja za pomocą sieci neuronowych

“Jakie czynniki wpływają na wybór ulubionej karmy psów?”



Rozpoznawanie cyfr



IBM developer: [Neural networks from scratch](#) in Python

Obrazy 28x28, wyjście 0, 1 ... 9.

Przykład: Grzyby



Baza danych dla grzybów:

Dane z podręcznika opisującego różne gatunki grzybów.

22 cechy i 3 klasy: jadalne, trujące, nie polecane.

4208 (51.8%) jadalnych, 3916 (48.2%) niejadalnych.

Cechy (nazwy oryginalne): 118 binarnych wartości.

cap shape (6, e.g.. bell, conical, flat...), cap surface (4), cap color (10), bruises (2), odor (9), gill attachment (4), gill spacing (3), gill size (2), gill color (12), stalk shape (2), stalk root (7, many missing values), surface above the ring (4), surface below the ring (4), color above the ring (9), color below the ring (9), veil type (2), veil color (4), ring number (3), spore print color (9), population (6), habitat (7).

Zadanie: zidentyfikować grzyby jadalne, znaleźć ważne cechy.

W książce wyraźnie napisano, że nie ma prostej reguły ...

Grzyby – przykładowe dane



Przykładowe dane:

M-1: edible,convex,fibrous,yellow,bruises,anise,free,crowded, narrow, brown, tapering,bulbous,smooth,smooth,white,white, partial,white, one, pendant,purple,several, woods

M-2: edible,flat,smooth,white,bruises,almond,free,crowded, narrow,pink,tapering,bulbous,smooth,smooth,white,white, partial,white,one,pendant,purple,several,woods

.....

M-8124: poisonous,convex,smooth,white,bruises,pungent,free,close, narrow, white, enlarging, equal, smooth, smooth, white, white, partial, white, one,pendant, black, scattered, urban

Grzyby - reguły



Grzyb jest jadalny jeśli:

$\text{odor} = (\text{almond} \vee \text{anise} \vee \text{none}) \wedge \text{spore_print_color} = \text{not.green}$

48 błędów, 99.41% prawidłowych

Grzyb nie jest jadalny jeśli: (używamy tylko 6 cech):

$R_1) \text{odor} = \text{not}(\text{almond} \vee \text{anise} \vee \text{none})$ 120 bł., 98.52%

$R_2) \text{spore_print_color} = \text{green}$ 48 bł., 99.41%


$R_3) \text{odor} = \text{none} \wedge \text{stalk_surface_below_ring} = \text{scaly} \wedge \text{stalk_color_above_ring} = \text{not.brown}$
8 bł., 99.90%

$R_4) \text{IF habitat} = \text{leaves} \wedge \text{cap_color} = \text{white}$ 0 błędów!

Teraz widać, dlaczego węch jest tak ważny dla zwierząt.

Classification

- Example: Credit scoring
- Differentiating between **low-risk** and **high-risk** customers from their *income* and *savings*




Discriminant: IF *income* $> \theta_1$ AND *savings* $> \theta_2$
THEN **low-risk** ELSE **high-risk**

Methods: Random Forest

Random forest

Random forest algorithms improve the accuracy of decision trees by using multiple trees with randomly selected subsets of data. This example reviews the expression levels of various genes associated with breast cancer relapse and computes a relapse risk.



Advantages

Random forest methods prove useful with large data sets and items that have numerous and sometimes irrelevant features.


Use cases

Customer churn analysis, risk assessment

DM & Machine Learning


4 Intelligent apps

Intelligent apps leverage the outputs of AI, as in this precision farming example that uses drone-based data collection.



3 Machine learning

A data scientist uses a training data set to teach the computer what to do, and the system carries out the tasks.



ML applications

Here are just a few of the many ways we've put machine learning to work. How will your company use it?



Rapid 3D mapping and modeling

For a railway bridge reconstruction, PwC data scientists and domain experts applied machine learning to data captured from drones. The combination enabled precise monitoring and quick feedback on work in progress.



Enhanced profiling to mitigate risks

To detect insider trading, PwC combined machine learning with other analytic techniques to develop more comprehensive user profiles and gain deeper insight into complex suspicious behaviors.



Predicting the top performers

PwC used machine learning and other analysis to evaluate the potential of different horses running in the Melbourne Cup.




© 2016 PwC. All rights reserved. PwC refers to the US member firm or one of its subsidiaries or affiliates, and may sometimes refer to the PwC network. Each member firm is a separate legal entity. Please see www.pwc.com/structure for further details. This content is for general information purposes only, and should not be used as a substitute for consultation with professional advisors.

pwc.com/NextinTech

Methods: Decision Trees

Decision trees

Decision tree analysis typically uses a hierarchy of variables or decision nodes that, when answered step by step, can classify a given customer as creditworthy or not, for example.



Advantages

Decision trees are useful when evaluating lists of distinct features, qualities, or characteristics of people, places, or things.

Use cases


Rule-based credit risk assessment, horse race performance prediction

Source: Daniel T. Larose and Chantal D. Larose, *Data Mining and Predictive Analytics*, 2nd Edition, John Wiley & Sons, 2015

Methods: SVM

Support vector machines

Support vector machines classify groups of data with the help of hyperplanes.



Source: Matthew Kelly, *Computer Science: Source*, 2010

Advantages

Support vector machines are good for the binary classification of X versus other variables and are useful whether or not the relationship between variables is linear.


Use cases

News categorization, handwriting recognition

Methods: Regression

Regression

Regression maps the behavior of a dependent variable relative to one or more dependent variables. In this example, logistic regression separates spam from non-spam text.



Advantages


Regression is useful for identifying continuous (not necessarily distinct) relationships between variables.

Use cases

Traffic flow analysis, email filtering

Regression Example

- Navigating a car: Angle of the steering wheel (CMU NavLab)
- Kinematics of a robot arm




Control of cars or robots require calculation of continuous parameters. Linear regression is commonly used in social sciences, but the challenge is to predict complex nonlinear trajectories with many parameters.

Methods: Probabilistic NB

Naive Bayes classification

Naive Bayes classifiers compute probabilities, given tree branches of possible conditions. Each individual feature is “naive” or conditionally independent of, and therefore does not influence, the others. For example, what’s the probability you would draw two yellow marbles in a row, given a jar of five yellow and red marbles total? The probability, following the topmost branch of two yellow in a row, is one in ten. Naive Bayes classifiers compute the combined, conditional probabilities of multiple attributes.



Source: Rod Pierce, et al., *MathIsFun*, 2014

Advantages

Naive Bayes methods allow the quick classification of relevant items in small data sets that have distinct features.


Use cases

Sentiment analysis, consumer segmentation

Methods: Hidden Markov


Hidden Markov models

Observable Markov processes are purely deterministic—one given state always follows another given state. Traffic light patterns are an example.



Source: Derek Kane, 2015

Hidden Markov models, by contrast, compute the probability of hidden states occurring by analyzing observable data, and then estimating the likely pattern of future observation with the help of the hidden state analysis. In this example, the probability of high or low pressure (the hidden state) is used to predict the likelihood of sunny, rainy, or cloudy weather.



Source: Leonardo Guizzetti, 2012

Advantages

Tolerates data variability and effective for recognition and prediction.

Use cases


Facial expression analysis, weather prediction

Methods: Neural Networks


Recurrent neural networks

Each neuron in any neural network converts many inputs into single outputs via one or more hidden layers. Recurrent neural networks [RNNs] additionally pass values from step to step, making step-by-step learning possible. In other words, RNNs have a form of memory, allowing previous outputs to affect subsequent inputs.

Non-recurrent feed-forward neural network



Recurrent neural network—includes loops



Advantages

Recurrent neural networks have predictive power when used with large amounts of sequenced information.

Use cases


Image classification and captioning, political sentiment analysis

Source: Joseph Wilks, 2012

Methods: LSTM

Long short-term memory & gated recurrent unit neural networks

Older forms of RNNs can be lossy. While these older recurrent neural networks only allow small amounts of older information to persist, newer long short-term memory (LSTM) and gated recurrent unit (GRU) neural networks have both long- and short-term memory. In other words, these newer RNNs have greater memory control, allowing previous values to persist or to be reset as necessary for many sequences of steps, avoiding “gradient decay” or eventual degradation of the values passed from step to step. LSTM and GRU networks make this memory control possible with memory blocks and structures called gates that pass or reset values as appropriate.



Source: Genevieve Orr, et al., Willamette University, 1999


Advantages

Long short-term memory and gated recurrent unit neural networks have the same advantages as other recurrent neural networks and are more frequently used than other recurrent neural networks because of their greater memory capabilities.

Use cases


Natural language processing, translation

Methods: NN for images



IBM an [introduction to deep learning](#)



Methods: Deep NN for images



Small patches of image (ex. 5x5 pixels) are filtered through receptive fields in convolution operation, creating elementary features, combined together using sampling, and again filtered to generate more complex features.

Finally generated features are analyzed to determine image category.


Methods: NN for images



Superresolution



Zastosowania ML



Obecnie ML do wszystkiego ...

- ✓ Zintegrowane pakiety programów z elementami ML do data mining.
- ✓ Analiza obrazów i sygnałów.
- ✓ Sterowanie: automatyczny kierowca/pilot/czołg ...
- ✓ Analiza tekstów.

Deep NN for protein folding



The ability to accurately predict protein structures from their amino-acid sequence will vastly accelerate efforts to understand the building blocks of cells, and enable quicker and more advanced drug discovery.


AlphaFold using deep neural networks has made great improvement,

2/3 of predicted structures is equivalent to experimental!

[Nature, 30.11.2020](#)

STRUCTURE SOLVER

DeepMind's AlphaFold 2 algorithm significantly outperformed other teams at the CASP14 protein-folding contest — and its previous version's performance at the last CASP.



Zwijanie białek



AlphaFold 2 wykorzystując głębokie uczenie przewiduje ponad 2/3 struktur białek z dokładnością równoważną eksperymentalnej!


[Nature, 30.11.2020](#)

Rozpoznawanie struktur + uczenie się +wnioskowanie.


Przewidywanie struktur białek na podstawie sekwencji aminokwasów jest podstawą poszukiwania białek i projektowania leków o pożądanых własnościach.

STRUCTURE SOLVER

DeepMind's AlphaFold 2 algorithm significantly outperformed other teams at the CASP14 protein-folding contest — and its previous version's performance at the last CASP.



AlphaFold



Program trenowany na 170.000 struktur białek w otwartej bazy przez kilka tygodni na 100 GPU. Ważna jest metoda numerycznej reprezentacji symbolicznych danych (embedding), czyli łańcuchów aminokwasów.


Szukanie parametrów sieci w tym przypadku oparte jest na minimalizacji funkcji błędu. 7/2022 DeepMind opublikował struktury 220 mln białek około miliona gatunków, Meta Metagenomic atlas ponad 600 mln struktur, 15 mld par.

ML main repositories

- [OpenAI-cookbook](#)
 - [Hugging Face](#) AI community models, datasets, and applications
 - [Futurepedia](#) AI tools, agents, tutorials, innovations.
 - [Papers with code](#)
 - [There's An AI For That](#) - latest AI tools, by the #1 AI aggregator.
 - [Data Science Central](#): online community for data science and AI.
 - [Ozobot](#) that can teach lessons to individuals about coding.
 - [Best Github projects](#) in data science and machine learning.
 - [Human-machine collaboration](#) in scientific research.
-
- [Prompt engineering examples](#)
 - [Illustrated transformer](#) book
 - [Scikit](#),

Generatywna AI: kreatywność

Modele probabilistyczne



Wiele modeli potrafi zakodować w formie skompresjonowanej informację w ukrytej przestrzeni (latent space z) pozwalającą na odtworzenie i generację podobnych treści.



Informacja algorytmiczna (Kolmogorowa) jest tu kluczowa, jest wiele wersji algorytmów kodowania.

Generative art

„Generative art” w Wikipedii, początki AI w sztuce

http://en.wikipedia.org/wiki/Generative_art

<http://www.random-art.org>



<http://www.solaas.com.ar/dreamlines/p5/>

<http://www.jhllabs.com/java/art.html>

Yuki Terai singing animated avatar, first digital idol
from Japan!




AI Virtual Artist

[AIVA](#) – AI Virtual Artist, member of author's rights society ([SACEM](#)), 206 works.

[AIVA YouTube](#) channel, Youtube „[Letz make it happen](#)“, Op. 23

[SoundCloud channel](#)

[Spotify](#) and [Apple](#) channel



Aaron Painter

Harold Cohen has asked about minimal requirements that should be fulfilled to call something art painting, and created in 1973 [Aaron](#) robotic artist.



Aaron examples



Meeting On Gauguin's Beach,



Aaron, with Decorative Panel, 1988
Oil 1992

Basic principles of composition + randomization. [See more here.](#)

Aaron in museums



Liberty & Friends, 1985
Ink



Mural, Capitol
Children Museum 1980

New Rembrandt

Next Rembrandt Project.

- All known 346 Rembrandt van Rijn portraits were scanned in 3D, about ~150 GB.
- Learning to paint in Rembrandt style, detailed movement of brush, using deep neural networks.
- Creation of new portrait in Rembrandt style— 500 hours of image rendering, 148 mln pixels in 3D.
- Printing this with 13 layers of paint.

i



Deep Art



<https://deepart.io/latest/> Deep Neural Networks, Deep Dream,
LA Gatys, AS Ecker, M Bethge, A Neural Algorithm of Artistic Style (2015)

Examples of Deep Art



<https://deepart.io/latest/> Deep Art,
LA Gatys, AS Ecker, M Bethge, A Neural Algorithm of Artistic Style (2015)



[Google Deep Dream/Deep Style i Generator](#),
LA Gatys, AS Ecker, M Bethge, A Neural Algorithm of Artistic Style (2015)

Generative music

„Popcorn”, Hot Butter hit from 1969,

Created through computer analysis of various melodies.

Computer helping human musicians.



Musicians learn by hearing and analyzing.

Why computers should not do the same? With access to all music in the world?

Algorithmic music: John Cage, Iannis Xenakis ...

http://en.wikipedia.org/wiki/Algorithmic_music

Lucasfilm Games' gra Ballblazer (1982) używała komputerowej improwizacji jazzowej, Xbox improwizuje na zadane tematy.

Generative music: Brian Eno started to experiment in 1975!

http://en.wikipedia.org/wiki/Generative_music


Examples of generative music:

<http://jmusic.ci.qut.edu.au/jmMusic.html>




Obrazy i kreatywność

Autoenkodery – kompresja i dekompresja informacji, tworzy przestrzeń ukrytych parametrów.



Generative Adversarial Networks:
Generuj obrazy (G), porównuj z rzeczywistymi (D), zmieniaj parametry by stawały się coraz bardziej realistyczne.

[Przykłady na Youtube](#), [Dall-e2](#)



From images to music

Can music be composed converting images?

Example: finish “metacomposer” Lauri Gröhn:

[Synesthesia Software Music](#)


„I want to show that in future computers may compose as well as people”.



[Turku Archipelago](#), Fog, Sakura – interesting compositions!

Can computer really „feel” music?

[Greta ist trying...](#)



Flow Machines

by Sony CSL

<http://www.flow-machines.com>

Software that learns.
What is programmed
is only the motivation
to learn!

[Learning to Create](#)
(Lrn2Cre8) EU FP7
Project

Daddy's Car: a song composed by Artificial Intelligence - in the style of the Beatles



flowmachines
flowmachines

Computational Creativity

6 AI Tools for music generation

AIVA – AI Virtual Artist, registered in France with an author's rights society (SACEM), many compositions in different styles.

AIVA YouTube channel and SoundCloud channel.

Google Magenta for music, CNET news.

Deep Art: <https://deepart.io/>

27 Incredible Examples Of AI And Machine Learning In Practice

What's the purpose of humanity if machines can learn ingenuity? (extract from Marcus Du Sautoy's book, The Creativity Code).

Open AI Research and Google Deepmind

AI in art

- [This Person Does Not Exist](#) artificial faces.
- Open AI [Dall-e2](#), od opisu do obrazu
- [Digital Humans](#).
- The [First Thinking Sculpture](#): Inspired by Gaudí, by Watson.
- [Autodraw](#), drawing from poor sketch.
- [AI artwork sells](#) for \$432,500 (12/2018); now selling NFT tokens
- [10 Amazing Examples Of How Deep Learning AI Is Used](#)
- [15 examples of AI in marketing](#).
- Reports on AI: The [European Artificial Intelligence landscape](#),
- [EU Digital Transformation 2021-27](#) plans
- [Communication: Artificial Intelligence for Europe](#)
- [Digital Poland: AI strategies \(in Polish\)](#)
- [My Flipboard Art & AI](#) and [Flipboard AI-CI-ML](#)

Examples of AI applications

- Forbes: [27 Incredible Examples of AI and Machine Learning](#) in practice: [Hello Barbie](#), [Coca-Cola](#) bot, [Heineken](#) bot.
- [Botsify](#) - bot assistants, from FAQ bots to tutoring bots.
- [Mika](#) - AI math tutor for higher education.
- [Snatchbot](#) for teachers, for classroom.
- [Ozobot](#) that can teach lessons to individuals about coding.
- [Chef Watson](#) from IBM
- [Project Malmo](#), AI in virtual reality.
- Google [Semantris](#) (word association);
- [Talk to Books](#), [Cyborg Writer](#),
- [Best Github projects](#) in data science and machine learning.
- Image restoration. deblurring, sharpening: [Topaz Labs](#).
- Shared autonomy: [3rd wave AI](#) (industrial)
- [Human-machine collaboration](#) in scientific research.

Tutorials on ML

- Autencoder explanations
- <https://www.youtube.com/watch?v=qJeaCHQ1k2w>
- More ML tutorial videos
- Deep Learning automated
- <https://www.youtube.com/@Deepia-ls2fo>