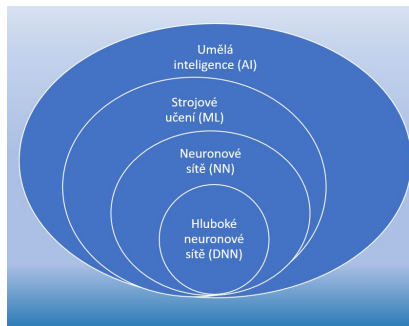


Úvod do problematiky






Umělé neuronové sítě

- rodina výpočetních modelů
- vychází z biologických principů – fungování lidského mozku:
 - rychlost zpracování informací
 - paralelní zpracování informací
 - způsob ukládání informací
 - redundance, řízení

Umělé neuronové sítě – Stručná historie


<https://www.codesofinterest.com/p/build-deeper.html>



Umělé neuronové sítě – Stručná historie

Začátky - 40. a 50.léta 20. století

- 1943 – formální neuron (W. McCulloch, W. Pitts) - první model neuronu, reprezentace logických a aritmetických funkcí



- 1949 – matematický pojem učení (D. Hebb) - podmíněné reflexy
- 1951 – první neuropočítač Snark (M. Minsky)

Umělé neuronové sítě – Stručná historie


Boom - 60.léta 20. století

- 1958 – perceptron (F. Rosenblatt) - reálné parametry, učící algoritmus, praktické aplikace, článek vyvolal obrovské nadšení
- 1958 – první úspěšný neuropočítač *Mark I Perceptron* (F. Rosenblatt, C. Wightman)
- 1962 – Adaline a sigmoidální přenosová funkce (B. Widrow, M. Hoff)
- 60. léta - velký rozvoj neurovýpočtů a neuropočítačů, pak náraz na strop, problémy a diskreditace
- 1969 – článek *Perceptrons* (M. Minsky, S. Papert) - konec boomu, začíná **zima neuronových sítí**

Umělé neuronové sítě – Stručná historie

Renezance - 80.léta 20. století

- opětovná popularizace oboru (John Hopfield, DAPRA)
- 1986 Algoritmus zpětného šíření pro model MLP (vrstevnatá neuronová síť), P. Werbos a D. Rumelhart, již dříve G. Hinton, Y. LeCun



Umělé neuronové sítě – Stručná historie

Renezance - 80.léta 20. století


Celá řada nových modelů

- Kohonenovy mapy (T. Kohonen)
- Hopfieldova síť (J. Hopfield)
- RBF-sítě (RadialBasis Function, J. Moody, C. Darken)
- GNG-model (Growing Neural Gas, B. Fritzke)
- SVM-stroje (Support Vector Machines, V. Vapnik)
- ELM-sítě (Extreme Learning Machines, G.-B. Huang)
- RNN-sítě (Recurrent Neural Networks, např. Jeffrey Elman)
- CNN-sítě (Convolutional neural networks, Y. LeCun, Y. Bengio ad.)

Umělé neuronové sítě – Stručná historie

Renezance - 80.léta 20. století

- 1987 IEEE International Conference on Neural Networks
- 1987 založena INNS (International Neural Network Society), časopis *Neural Networks*
- mezinárodní časopisy: *Neural Computation* (1989), *IEEE Transactions on Neural Networks* (1990), *Neural Network World* (1991) aj.



Umělé neuronové sítě – Stručná historie

Zklidnění - 90.léta 20. století

- dominují modely MLP (vícevrstvá neuronová síť), RNN (rekurentní neuronová síť), Kohonenovy mapy
- Snaha o řešení různých problémů s učením neuronových sítí:
 - Rozvoj různých algoritmů učení, využití sofistikovaných optimalizačních technik
 - Robustnost, generalizace, problém přeučení
 - Strategie učení – paralelizace a efektivita
- Snaha o učení hlubších neuronových sítí
 - Problematika explodujících a mizejících gradientů
 - Omezené výpočetní zdroje

Umělé neuronové sítě – Stručná historie

Boom - po roce 2006

- Rozvoj GPU umožnil rozvoj **hlubokého učení** (Deep Learning, Yoshua Bengio, Geoffrey Hinton, aj.)
- Vítězství CNN v soutěži ImageNet (2012)
- Obrovský boom nových modelů a architektur hlubokých neuronových sítí
 - LSTM rekurentní neuronové sítě (Hochreiter, Schmidhuber, 2014)
 - GAN (I. Goodfellow, 2015)
 - První jazykový generativní model založený na transformer architektuře: GPT-3 (2020, OpenAI), později chat bot ChatGPT (2022)
 - První text-to-image model Stable Diffusion (2022, CompVis)

Umělé neuronové sítě – Stručná historie

Moderní architektury hlubokých neuronových sítí

- **Vícevrstvý perceptron (MLP, někdy DNN)** - Standardní, univerzální model.
- **Konvoluční neuronové sítě (CNNs)** - Zpracování obrazu a videa. Klasifikační úlohy, rozpoznání a segmentace obrazu.
- **Rekurentní neuronové sítě (RNNs)** - Analýza sekvenčních dat (časové řady, řeč, text, písmo)
 - **Sítě s dlouhou-krátkodobou pamětí (Long Short-Term Memory Networks, LSTMs)** - Zpracování jednorozměrných signálů a časových řad (např. rozpoznání řeči a písma), model je schopný zachytit i dlouhodobé závislosti.
 - **Gated Recurrent Unit Networks (GRU)** - Modelování sekvenčních dat, rozpoznání řeči a strojový překlad.
- **Autoenkodery** - Unsupervised learning. Změna reprezentace dat, čištění dat, komprese a rekonstrukce.

Umělé neuronové sítě – Stručná historie

Moderní architektury hlubokých neuronových sítí

- **Generative Adversarial Networks (GANs)** - Generování nových dat na základě naučených vzorů.
- **Deep Belief Networks (DBNs)** - Generativní model učený bez učitele (unsupervised).
- **Deep Q-Networks (DQNs)** - Pro úlohy zpětnovazebného učení.
- **Siamese Networks** - Pro úlohy rozpoznání obrazu, object-tracking. Počítají podobnost mezi dvěma různými vstupy
- **Capsule Networks** - Pro úlohy rozpoznání obrazu. Modelují hierarchické vztahy mezi částmi objektů
- **Transformer Networks (BERT, GPT)** Pro úlohy zpracování přirozeného jazyka (klasifikace textů, překlady apod.).

Umělé neuronové sítě – Stručná historie


Co budeme probírat my v předmětu Neuronové sítě 1?

- Jedná se o úvodní předmět, budeme se tedy zabývat základními věcmi.
- Průřez základní modely neuronových sítí počínaje perceptronem, přes MLP a Kohonenovy mapy až k CNN.

Chcete se naučit používat nebo pochopit i další - modernější a složitější - modely neuronových sítí?

- Více o hlubokých neuronových sítích se dozvíte v navazujících předmětech:
 - Neuronové sítě 2
 - Strojové učení 2
 - Aplikace optimalizačních metod, aj.

Model biologického neuronu



Biologický neuron

- základní stavební jednotka neuronové sítě
- výstup závisí na vstupech neuronu a jejich zpracování uvnitř těla neuronu

Model biologického neuronu



Biologická neuronová síť

- neurony jsou vzájemně propojeny do sítí
 - axony se pomocí synapsí napojují na dendrity dalších neuronů
 - synapse se vytvářejí během celého života – **učení, paměť**

Paměť

- **Krátkodobý paměťový mechanismus**
 - založen na cyklickém oběhu vzruchů v neuronových sítích
 - fixace informace za cca 30 s
- **Střednědobý paměťový mechanismus**
 - založen na změnách synapsí a vah neuronů
 - uchování informace v řádu hodin až dnů
 - klíčovou roli hraje hipokampus
- **Dlouhodobý paměťový mechanismus**
 - klíčovou roli pro dlouhodobou změnu synapsí hrají bílkoviny v jádrech neuronů
 - uchování informace až celý život


Adaptace a učení

Adaptace

- schopnost přizpůsobit se změnám okolního prostředí
- znamená pro organismus vždy ztrátu (materiál, energie,....)

Učení

- minimalizace ztrát vynaložených na adaptaci
- výsledek mnohonásobného opakování adaptace



Strojové učení

Princip

- vychází z biologických principů, model se "vytvoří sám"
- výpočetní model se učí na základě dat (trénovací množina) nebo předchozích zkušeností

Metody učení

- **Učení s učitelem (supervised learning)**
 - trénovací množina ve tvaru [*vstup, požadovaný výstup*]
- **Učení bez učitele (unsupervised learning, samoorganizace)**
 - trénovací množina ve tvaru [*vstup*]
- **Zpětnovazebné učení (reinforcement learning)**
 - program se učí optimální strategii na základě předchozích zkušeností

Strojové učení

Úloha strojového učení - učení s učitelem

- je dána množina trénovacích dat: vstupní a výstupní vzory (požadované výstupy)
- chceme, aby model co nejlépe aproximoval neznámou funkci
→ aby pro každý předložený vstupní správně predikoval hodnotu výstupu
- generalizace = zobecňování – model by měl dát správný výstup i pro data, která nejsou v trénovací množině

Strojové učení

Typy úloh strojového učení s učitelem

- regrese – predikujeme numerickou hodnotu / hodnoty
- klasifikace – predikujeme diskrétní hodnotu / hodnoty
- učení strukturovaných dat

Typické aplikace:

- diagnostika v medicíně
- klasifikace či segmentace obrazu
- detekce bankovních podvodů
- rozpoznávání řeči
- predikce časových řad,
- zpracování přirozeného jazyka,...

Strojové učení

Učení bez učitele (unsupervised learning, samoorganizace)

- trénovací množina obsahuje pouze vstupy
- metody: shlukování, asociační pravidla,...
- aplikace: detekce plagiátů, detekce anomálií, e-komenrce (recomendation systems)

Zpětnovazebné učení (reinforcement learning)

- program se učí optimální strategii na základě předchozích zkušeností
- metody: Q-learning,...
- aplikace: herní průmysl, robotika, správa zdrojů, text mining

Strojové učení

Typický průběh řešení úlohy strojového učení



- Předzpracování dat
 - převedení dat do formátu, se kterým se bude modelu strojového učení nejlépe pracovat
 - např. výběr příznaků
- Učení modelu
 - jaký typ modelu? (záleží na problému)
 - jaký model daného typu? (volba vhodných parametrů)
- Vyhodnocení modelu – nejlépe na nových datech

Strojové učení

Příklady modelů strojového učení

- uložená data
- lineární či nelineární funkce (lineární regrese, logistická regrese apod.)
- rozhodovací strom, množina pravidel
- bayesovská síť
- fuzzy systémy
- evoluční algoritmy
- neuronová síť
- ...

Výpočetní modely založené na znalostech

- 1 expertní - model vytvoří expert
- 2 sehnat data a naučit model z dat – strojové učení
- 3 spolupráce strojového učení a experta – expert kritizuje či opravuje model vytvořený z dat