

18NES1 Neuronové sítě 1 - Úvod do problematiky

18NES1 - 1. hodina, LS 2024/25


Zuzana Petříčková

27. dubna 2025

Neuronové sítě 1 - Úvod do problematiky

- 1 Úvod do problematiky - Umělá inteligence
- 2 Strojové učení
 - Tři základní druhy strojového učení
 - Typický průběh řešení úlohy strojového učení
- 3 Historie
- 4 O předmětu 18NES1

Úvod do problematiky - Umělá inteligence



- Co je vlastně AI (umělá inteligence)?

Úvod do problematiky - Umělá inteligence

- Turingův test (Alan Turing, 1950)
 - Počítač/program projde testem, pokud člověk během pětiminutové konverzace nepozná, že nehovoří s člověkem
- První chatbot: Eliza (1966)

```
Welcome to


EEEEEE LL      IIII  ZZZZZZ  AAAAA
EE      LL      II    ZZ    AA  AA
EEEEEE LL      II    ZZZ   AAAAAA
EE      LL      II    ZZ    AA  AA
EEEEEE LLLLLL  IIII  ZZZZZZ  AA  AA

Eliza is a mock Rogerian psychotherapist.
The original program was described by Joseph Weizenbaum in 1966.
This implementation by Norbert Landsteiner 2005.

ELIZA: Is something troubling you ?
YOU:   Men are all alike.
ELIZA: What is the connection, do you suppose ?
YOU:   They're always bugging us about something or other.
ELIZA: Can you think of a specific example ?
YOU:   Well, my boyfriend made me come here.
ELIZA: Is it important to you that your boyfriend made you come here ?
YOU:   He says I'm depressed much of the time.
ELIZA: I am sorry to hear that you are depressed.
YOU:   It's true. I am unhappy.
ELIZA: Can you explain what made you unhappy ?
YOU:
```


Úvod do problematiky - Umělá inteligence

- Turingův test (Alan Turing, 1950)
 - Počítač/program projde testem, pokud člověk během pětiminutové konverzace nepozná, že nehovoří s člověkem
- Dnes již klasická definice neobstojí:
 - Turingův test překonal jako první chatbot Google BERT, 2022




Úvod do problematiky - Umělá inteligence

- **Klasická definice:** schopnost strojů / počítačových programů napodobovat lidské schopnosti, které považujeme za **inteligentní**:
 - schopnost uvažovat a řešit problémy, plánovat
 - schopnost přizpůsobit se novému prostředí, učit se
 - kreativita, ...
- **Moderní definice:** Vědecká disciplína, která se zabývá návrhem **sofistikovaných systémů** pro řešení **komplexních problémů**
 - rozpoznávání obrazu, jazykový překlad, hraní šachů, medicínská diagnostika, autonomní vozidla, ...
 - **S AI se setkáváme na každém kroku:**
 - personalizace obsahu na soc. sítích, personalizované reklamy, detekce spamu, vyhledávače, chatboty, ...



Strojové učení



- modely a techniky, které umožňují počítačovému systému **učit se** na základě dat nebo předchozích zkušeností
- často inspirované biologickými principy:



Strojové učení

Princip


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



F. Chollet: Deep learning v jazyku Python, obr. 1.2

Strojové učení - tři základní druhy strojového učení

- **Učení s učitelem (supervised learning)**
 - učí se na označených datech (např. klasifikace obrázků)
 - trénovací množina ve tvaru [*vstup*, *požadovaný výstup*]
- **Učení bez učitele (unsupervised learning, samoorganizace, selfsupervised learning)**
 - hledá strukturu v neoznačených datech (např. třídění obrázků)
 - trénovací množina ve tvaru [*vstup*]
- **Zpětnovazebné / posilované učení (reinforcement learning)**
 - učí se optimální strategii na základě předchozích zkušeností, např. prostřednictvím odměn a trestů (např. robotický fotbal)



Strojové učení - tři základní druhy strojového učení


Učení s učitelem (supervised learning)

- **trénovací množina** tvaru [vstup, požadovaný výstup]
- **cíl učení:** 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
- **typické aplikace:**
 - diagnostika v medicíně, detekce bankovních podvodů
 - predikce časových řad,
 - klasifikace či segmentace obrazu
 - zpracování přirozeného jazyka, rozpoznávání řeči

Strojové učení - tři základní druhy strojového učení

Učení s učitelem (supervised learning) - typy úloh:

- **Klasifikace:** predikce třídy (kategorie)



- **Regrese:** predikce numerické hodnoty (cena, teplota, sklon písma, ...)




- **Učení strukturovaných dat** (např. věty v přirozeném jazyce)

Strojové učení - tři základní druhy strojového učení


Učení bez učitele (unsupervised learning, samoorganizace)

- **Trénovací množina** tvaru [vstup]
- **Cíl učení:** najít strukturu nebo vzory v datech
- **Aplikace: snížení dimenzionality** (komprese dat, vizualizace),
detekce anomálií (např. v bankovních transakcích),
shlukování (např. zákazníků podle chování, detekce pagiatů)
e-komerce (doporučovací systémy)

Typy úloh:



Inspirováno: <https://towardsdatascience.com/unsupervised-learning-algorithms-cheat-sheet-d391a39de44a>



<https://eastgate-software.com/what-is-unsupervised-learning/#ftoc-heading-7>

Strojové učení - tři základní druhy strojového učení

Učení bez učitele (unsupervised learning, samoorganizace)

- metody: shlukování, asociační pravidla, autoenkodéry, generativní modely

Zpětnovazebné / posilované učení (reinforcement learning)

- program se učí optimální strategii na základě předchozích zkušeností
- často systém odměn a trestů
- metody: Q-learning, Deep Q-Network, ...
- aplikace: herní průmysl, robotika, správa zdrojů, strojový překlad,...

Typický průběh řešení úlohy strojového učení



- Definice úkolu

- Jakou úlohu řešíme? Jaká máme data? Jaký typ úlohy? Co je přesně cílem?
- Jaké modely strojového učení připadají v úvahu?
- Provedeme rešerši stávajících řešení, omezení,...

- Sběr dat

- a snaha co nejlépe datům porozumět
- zvolíme měřítko úspěchu (různé metriky: přesnost,...)

Typický průběh řešení úlohy strojového učení



- Předzpracování dat

- převedení dat do formátu, se kterým se bude modelu strojového učení nejlépe pracovat
- vektorizace, normalizace, chybějící hodnoty, augmentace,...

- Výběr a tvorba modelu

- Výběr hodnotícího protokolu (např. k-násobná křížová validace)
- Vytvoření jednoduchého referenčního modelu
- jaký typ modelu? ... záleží na problému
- jaký model daného typu? (volba vhodných parametrů, architektury apod.) ... existující šablony

Typický průběh řešení úlohy strojového učení



- Vyhodnocení a ladění modelu
 - různé architektury
 - další techniky (dropout, regularizace),...
 - vyhodnocení modelu – nejlépe na nových datech
- Nasazení / použití modelu
 - nasazení modelu (různá zařízení)
 - sledování a údržba modelu

Strojové učení


Příklady klasických modelů strojového učení

- uložená data
- lineární či nelineární funkce (lineární regrese, logistická regrese apod.)
- rozhodovací strom, množina pravidel
- bayesovská síť, fuzzy systémy, evoluční algoritmy
- umělá neuronová síť
 - napodobuje strukturu a funkci lidského mozku:
 - způsob zpracování informací (rychlost, paralelnost)
 - způsob ukládání informací
 - redundance, řízení

Moderní strojové učení ... hluboké učení


- modely hlubokých neuronových sítí

Strojové učení – hluboké učení



I. Goodfellow and Y. Bengio and Aaron Courville: Deep Learning, 2016, Figure 1.5

- Využívá umělé neuronové sítě s mnoha vrstvami (tzv. hluboké sítě)
- Model sám extrahuje příznaky z dat a snižuje tak nároky na jejich předzpracování



F. Chollet: Deep learning v jazyku Python, obr. 1.6


Strojové učení – hluboké učení

Výhody:

- Schopnost zpracovat obrovské množství dat a nalézt v nich složité vzory
- Flexibilita v různých typech úloh (klasifikace, rozpoznávání, generování obsahu, ...)

Nevýhody:

- Vyžadují velké množství dat a výpočetní výkon, aby se naučily (a mohly používat)
- Fungují jako „černá skříňka“






Neuronové sítě 1 - Úvod do problematiky

- 1 Úvod do problematiky - Umělá inteligence
- 2 Strojové učení
 - Tři základní druhy strojového učení
 - Typický průběh řešení úlohy strojového učení
- 3 Historie
- 4 O předmětu 18NES1

Umělé neuronové sítě – Stručná historie

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



Umělé neuronové sítě – Stručná historie

Vývoj probíhal ve vlnách:

- Střídala se období rozkvětu oboru a velkých očekávání a následného zklamání a útlumu


Zásadní období:

- 1940 – 1960 : první teoretické základy
- 1960 – 1970 : první boom - období „jednoho neuronu“
- 1970 – 1980 : první „Neuronová zima“
- 1980 – 1990 : druhý boom - období „mělkých“ neuronových sítí
- 1990 – 2000 : postupné zklidnění
- 2000 – 2010 : druhá „Neuronová zima“
- 2010 – současnost : třetí boom - období „hlubokých“ neuronových sítí

Umělé neuronové sítě – Stručná historie

Počátky a raný vývoj (1940-1960)

- snaha modelovat, jak funguje biologický neuron
- 1943 - **první matematický model neuronu** (W. McCulloch, W. Pitts), reprezentace logických a aritmetických funkcí



- 1949 – **matematický pojem učení** (D. Hebb) - první učící algoritmus pro umělý neuron, modeluje podmíněné reflexy
- 1951 – první neuropočítač Snarc (M. Minsky)

Umělé neuronové sítě – Stručná historie

První boom (1960–1970) : období „jednoho neuronu“

- 1957 – **Perceptron** (F. Rosenblatt) - praktický model umělého neuronu, s reálnými parametry a s funkčním učícím algoritmem, 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

Umělé neuronové sítě – Stručná historie

- 1969 – článek Perceptrons (M. Minsky, S. Papert) – ukázali limity perceptronu (nezvládne modelovat ani všechny základní logické funkce)
- co spojit více neuronů do jedné sítě?
→ to by šlo, ale jak takový model naučit? (existující algoritmy pro perceptron a lineární neuron nešlo použít)



1970 – 1980 : první “Neuronová zima”

- Zklamání z nerealizovaných očekávání.
- Problémy a diskreditace oboru.
- Klesající financování a zájem o AI výzkum.

Umělé neuronové sítě – Stručná historie

Druhý boom (1980 - 1990): období „mělkých“ neuronových sítí

- opětovná popularizace oboru (John Hopfield, DARPA,...), model vícevrstvé neuronové sítě (MLP, multilayer perceptron)
- 1986 Algoritmus zpětného šíření (backpropagation) pro model MLP (P. Werbos a D. Rumelhart, již dříve G. Hinton, Y. LeCun)
 - Klíčový koncept, který používáme dodnes



<https://playground.tensorflow.org/>

Umělé neuronové sítě – Stručná historie

Druhý boom (1980 - 1990): období „mělkých“ neuronových sítí


Celá řada nových modelů skládajících se z více neuronů (neuronové sítě):

- Vícevrstvá neuronová síť (multilayer perceptron, MLP)
- 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

Druhý boom (1980 - 1990): období „mělkých“ neuronových sítí

- 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

Období zklidnění (1990-2000)

- Dominují modely MLP (vícevrstvá neuronová síť), RNN (rekurentní neuronová síť), Kohonenovy mapy, SVM (metoda podpůrných vektorů)
- Snaha o řešení různých problémů s učením neuronových sítí:
 - Využití sofistikovaných optimalizačních technik
 - Robustnost, generalizace, problém přeučení (model je perfektní na známých datech, ale selhává na nových)
 - Strategie učení – paralelizace a efektivita
- Snaha o učení hlubších neuronových sítí
 - kromě MLP již existují i např. konvoluční neuronové sítě (CNN)
 - Ale náraz na technologický strop: omezené výpočetní zdroje (procesor, paměť)
 - Problematika explodujících a mizejících gradientů

2000 – 2010 : druhá „Neuronová zima“

Umělé neuronové sítě – Stručná historie

2010 – nyní : třetí boom – období hlubokých neuronových sítí

• Co boom nastartovalo?

- Rozvoj GPU, cloud-computingu a snadná dostupnost dat
- Pokroky v učících algoritmech (např. Deep Learning, Y. LeCun, Y. Bengio, G. Hinton, 2015)
- Vítězství CNN v soutěži ILSVRC (2012)
 - ImageNet Dataset: 16 milionů barevných obrázků z 20 tisíc kategorií



Umělé neuronové sítě – Stručná historie


2010 – nyní : třetí boom – období hlubokých neuronových sítí

- Následuje obrovský boom nových modelů a architektur hlubokých neuronových sítí
 - Moderní rekurentní neuronové sítě (LSTM, Hochreiter, Schmidhuber, 1997)
 - GAN – Generative adversarial network (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.
- **Autoenkodery** - Unsupervised learning. Změna reprezentace dat, čištění dat, komprese a rekonstrukce.



Umělé neuronové sítě – Stručná historie

Moderní architektury hlubokých neuronových sítí

- **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.



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.).

Organizačně

Co budeme probírat my v předmětu Neuronové sítě 1?

- Jedná se o úvodní předmět, budeme se tedy zabývat základními věcmi.
- Průřez základní „mělkými“ modely neuronových sítí počínaje perceptronem, po modely s jednou skrytou vrstvou (např. MLP, Kohonenovy mapy)
- Probereme i základní hlubší modely (vícevrstvý perceptron, konvoluční neuronová síť).
- Naším cílem bude pochopit, jak umělé neuronové sítě fungují uvnitř, jak se chovají v různých situacích a proč a jak je správně aplikovat na řešení různých typů úloh.
- Cvičení budou v Pythonu

Organizačně

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

- Více o hlubokých neuronových sítích se dozvíte v navazujících předmětech:
 - Neuronové sítě 2 - praktický, inženýrský pohled na hluboké neuronové sítě
 - Strojové učení 2
 - Aplikace optimalizačních metod, aj.