

# Neuronové sítě 2 - Úvod

18NES2 - 1. hodina, ZS 2024/25

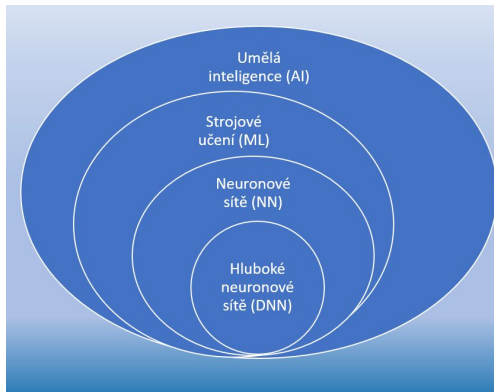
Zuzana Petříčková

25. září 2024

# Neuronové sítě 2 - Úvod

- 1 Úvod do problematiky - Umělá inteligence
- 2 Strojové učení
- 3 Historie
- 4 Neuronové sítě 2
- 5 Frameworky pro hluboké učení

# 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)

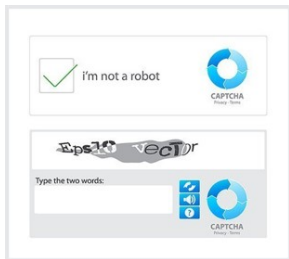
```
Welcome to
EEEEEE LL      IIII  ZZZZZZ  AAAAA
EE      LL      II     ZZ     AA  AA
EEEEEE LL      II     ZZ     AAAAAA
EE      LL      II     ZZ     AA  AA
EEEEEE LLLLLL IIII  ZZZZZZ  AA  AA

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 such 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:



The Washington Post  
Democracy. Start in darkness.

This article was published more than 1 year ago

TECH Help Desk Artificial Intelligence Internet Culture Space Tech Policy

TECHNOLOGY

## Google's AI passed a famous test — and showed how the test is broken


The Turing test has long been a benchmark for machine intelligence. But what it really measures is deception.

Analysis by [Will Oremus](#)  
Staff writer | [+ Follow](#)

June 17, 2022 at 7:00 a.m. EDT

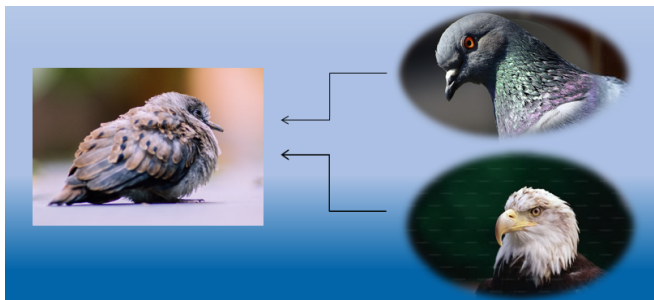
# Úvod do problematiky - Umělá inteligence

- **Klasická definice:** schopnost strojů / počítačových programů napodobovat lidské schopnosti, které považujeme za inteligentní:
  - schopnost uvažovat a řešit problémy, učit se
  - schopnost přizpůsobit se novému prostředí
  - schopnost plánovat, kreativita, ...
- **Moderní definice:** Vědecká disciplína, která se zabývá návrhem **sofistikovaných systémů** pro řešení **komplexních problémů**



# 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

## 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 / posilované učení (reinforcement learning)**
  - program se učí optimální strategii na základě předchozích zkušeností



# Strojové učení

## Úloha strojového učení - učení s učitelem (supervised learning)

- 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


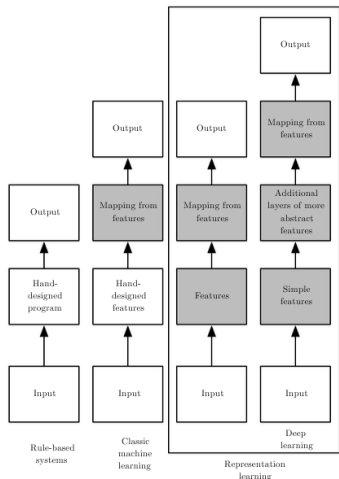
## **Učení bez učitele (unsupervised learning, samoorganizace)**

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

## **Zpětnovazebné / posilované učení (reinforcement learning)**

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

# Hluboké učení (deep learning)



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

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

# Strojové učení

## Typický průběh řešení úlohy strojového učení



- Definice úkolu
  - jakou úlohu řešíme, jaká máme data, jaký typ úlohy?
  - provedeme rešerši stávajících řešení, omezení,...
- Sběr dat
  - a snaha co nejlépe datům porozumět
  - zvolíme měřítko úspěchu (různé metriky: přesnost,...)

# Strojové učení

## 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,...) - existující šablony

# Strojové učení

## 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
- vícevrstvá neuronová síť
- ...

## Moderní strojové učení ... hluboké učení

- 1 modely hlubokých neuronových sítí

# Umělé neuronové sítě – Stručná historie

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




"Intelligent Machines"

Artificial Intelligence

Machine Learning



Deep Learning



# Umělé neuronové sítě – Stručná historie

## Začátky - 40. a 50. léta 20. století

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



- 1949 – matematický pojem učení (D. Hebb) - podmíněné reflexy



# Umělé neuronové sítě – Stručná historie

## Boom - 60.léta 20. století

- 1958 – perceptron (F. Rosenblatt) - reálné parametry, učící algoritmus, praktické aplikace
- 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 první **zima neuronových sítí**

# Umělé neuronové sítě – Stručná historie

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





Mourtzis, Dimitris & Angelopoulos, John. (2020). An intelligent framework for modelling and simulation of artificial neural networks (ANNs) based on augmented reality. International Journal of Advanced Manufacturing Technology. 111. 10.1007/s00170-020-06192-y.

# Umělé neuronové sítě – Stručná historie

## Renezance - 80.léta 20. století

- 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)



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

# 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




## Zklidnění - 90.léta 20. století

- dominují modely MLP (vícevrstvá neuronová síť), RNN (jednoduchá 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
- začíná druhá **zima neuronových sítí** 1998-2006



# Umělé neuronové sítě – Stručná historie

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



# Umělé neuronové sítě – Stručná historie

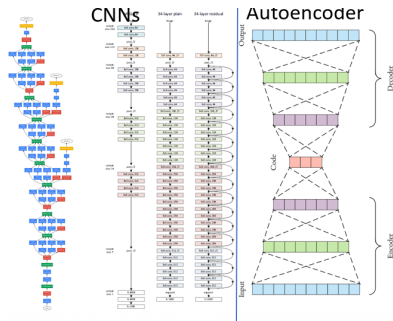
## Boom - po roce 2006 ... Hluboké učení (Deep learning)

- 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.
- 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.).

# Co budeme probírat my v předmětu Neuronové sítě 2

## **Předmět Neuronové sítě 1, 18NES1, LS 2023/24, 2+2KZ**

- Na tento předmět navážeme
- Probírali jsme základní „mělké“ modely neuronových sítí: perceptronem a jednovrstvé modely, Kohonenovy mapy
- Probrali jsme i základní hlubší modely (MLP, konvoluční neuronové sítě)
- Snažili jsme se dívat dovnitř modelů neuronových sítí a pochopit, jak fungují
- Probírala se i teorie (omezeně)
- Cvičení probíhala v Matlabu (příští rok již bude Python)

## **Předmět Neuronové sítě 2, 18NES2, ZS 2024/25, 2Z**

# Co budeme probírat my v předmětu Neuronové sítě 2

## **Předmět Neuronové sítě 2, 18NES2, ZS 2024/25, 2Z**

- Připomeneme si některé modely, které jsme již probrali v 18NES1 (MLP, konvoluční neuronové sítě)
- Přidáme nějaké další (moderní rekurentní neuronové sítě, autoenkodéry, další varianty konvolučních neuronových sítí)
- Na teorii se podíváme jen velmi povrchně
- Bude to spíše inženýrský, praktický pohled
- Cvičení bude v Pythonu (s využitím známých frameworků - Keras)

# Co budeme probírat my v předmětu Neuronové sítě 2

## Předmět Neuronové sítě 2, ZS 2024/25, 2Z

- Zaměříme se na ukázky praktických aplikací (v Pythonu)
- Naučíme se používat modely hlubokého učení při řešení různých typů úloh
- Budeme experimentovat :)
- Na teorii se podíváme jen povrchně
- Nejspíše se nedostaneme k složitějším modelům (GAN, transformery, reinforcement learning apod.)

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

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



# Hlavní frameworky pro hluboké učení

## Hlavní frameworky pro hluboké učení v Pythonu

- **TensorFlow**: Open-source knihovna od Googlu. Populární pro aplikace (mobile, server)
- **PyTorch**: Open-source knihovna od Facebooku. Nyní TOP pro výzkum.
- **Keras**: High-level API pro neuronové sítě. Srozumitelné a přístupné začátečníkům. TOP pro rychlé prototypování.
- a další (JAX, dříve Theano,...)

## Další knihovny, co se budou hodit

### Manipulace s daty a numerické výpočty

- **NumPy**: Základní balíček pro vědecké výpočty v Pythonu.
- **Pandas**: Výkonná knihovna pro analýzu dat.

### Vizualizace a vykreslování

- **Matplotlib**: Obsáhlá knihovna pro tvorbu statických, animovaných a interaktivních vizualizací.
- **Seaborn**: Vizualizace složitějších vztahů mezi více proměnnými.

### Klasické strojové učení

- **scikit-learn**: Univerzální knihovna pro klasické algoritmy strojového učení a vyhodnocování modelů.