



JAK VIDÍ UMĚLÝ NEURON

Jak počítače vnímají a chápou svět?

ZUZANA PETŘÍČKOVÁ

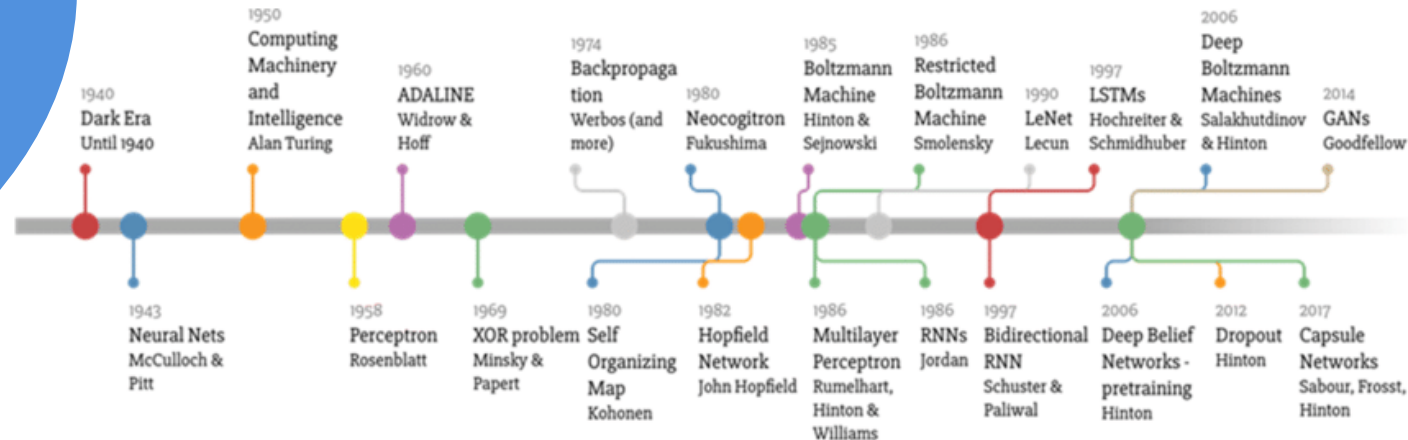

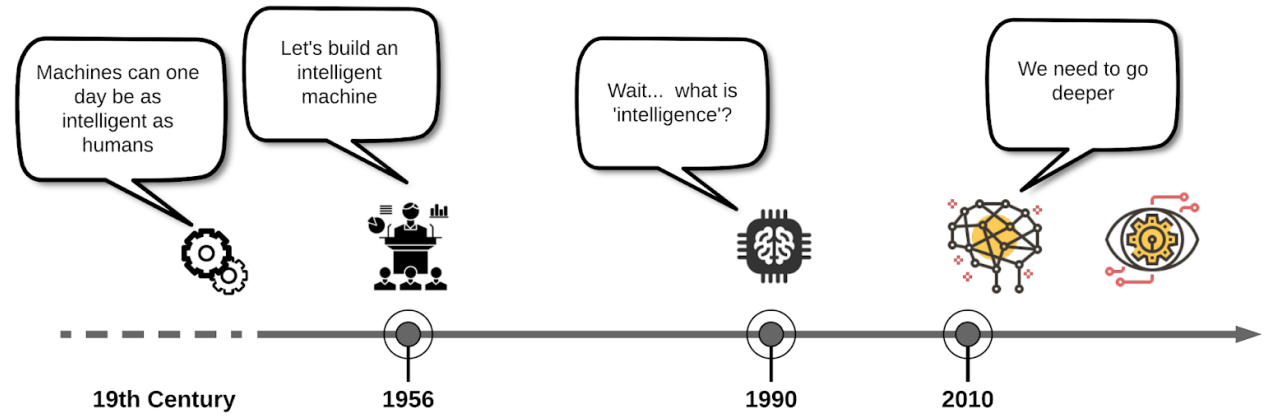
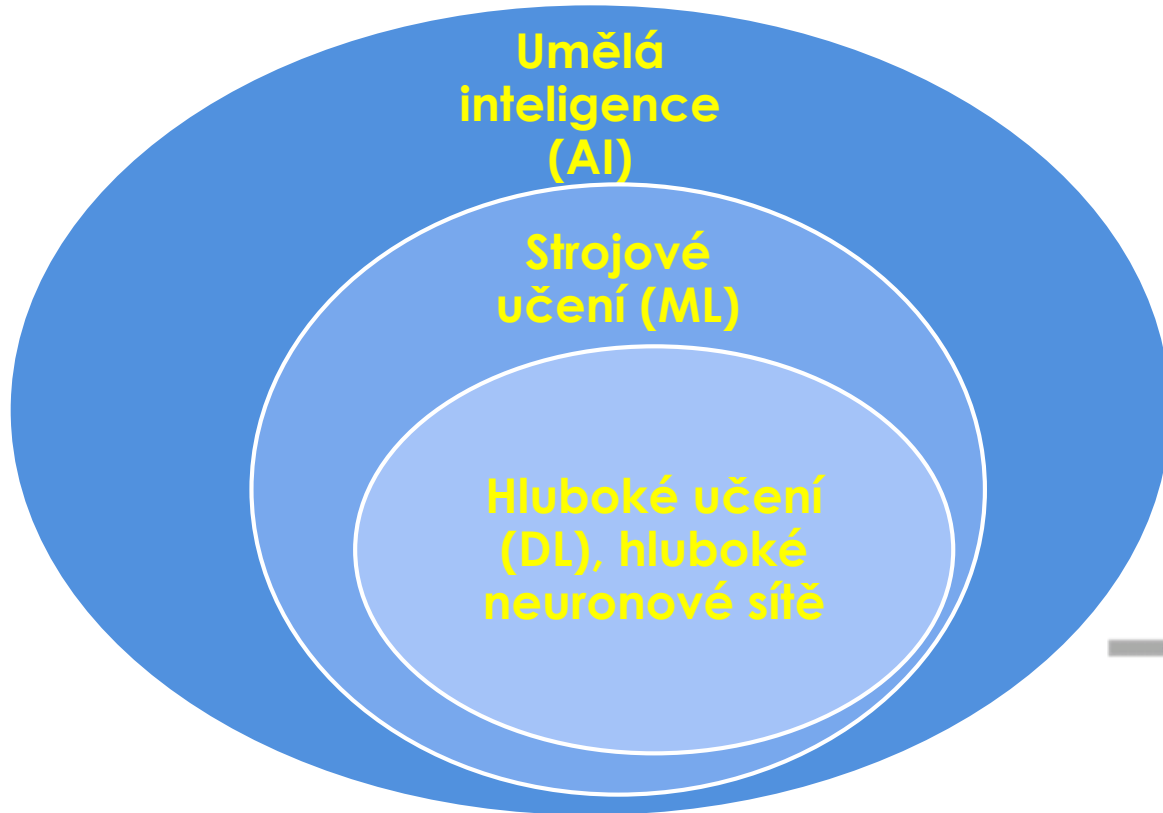
ČVUT V PRAZE, FJFI, KATEDRA KSI

ÚTERKY S VĚDOU, 7. LEDNA 2025

Co nás dnes čeká?

- ▶ **Co je strojové a hluboké učení?** Jak se počítače učí?
- ▶ **Pohled pod pokličku umělých neuronových sítí:**
 - ▶ Jak umělý neuron napodobuje mozek a jak propojené neurony vytvářejí síť schopnou „myslet“?
- ▶ **Od minulosti k současnosti:**
 - ▶ Projdeme vývoj neuronových sítí – od prvních experimentů až po technologie, které mění svět kolem nás.

Umělá inteligence a strojové učení



Co je to umělá inteligence (AI)?

- ▶ **Klasická definice:** schopnost strojů / počítačových programů napodobovat lidské schopnosti, které považujeme za **intelligentní**:
 - ▶ schopnost uvažovat a řešit problémy, plánovat
 - ▶ schopnost přizpůsobit se novému prostředí, učit se
 - ▶ kreativita



Co je to umělá inteligence (AI)?

► 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
      EEEEE LL   IIII ZZZZZ AAAAA
      EE   LL   II   ZZ   AA  AA
      EEEEE LL   II   ZZZ  AAAAAA
      EE   LL   II   ZZ   AA  AA
      EEEEE LLLLL IIII ZZZZZ 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:
  
```

Moderní chatboty:

turingův test překonal jako první Google BERT, 2022:

The Washington Post
Democracy Dies 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


Co je to umělá inteligence (AI)?

- ▶ **Klasická definice:** schopnost strojů / počítačových programů napodobovat lidské schopnosti, které považujeme za **inteligentní**.
- ▶ **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
- ▶ Počítačový systém **se vytvoří sám** bez nutnosti explicitního programování
- ▶ Často inspirované biologickými principy:



Tři typy modelů strojového učení

Supervised learning (učení s učitelem)

- ▶ učí se na označených datech (např. klasifikace obrázků)
- ▶ trénovací množina tvaru [vstup, požadovaný výstup]

Unsupervised learning, Selfsupervised learning (učení bez učitele)


- ▶ hledá strukturu v neoznačených datech (např. třídění obrázků)
- ▶ trénovací množina tvaru [vstup]
- ▶ př. detekce plagiátů či anomálií, recommendation systems

Reinforcement learning (Zpětnovazebné učení)


- ▶ učí se optimální strategii na základě zkušeností: prostřednictvím odměn a trestů v prostředí (např. robotický fotbal)
- ▶ př. herní průmysl, robotika, správa zdrojů, strojový překlad

machine learning


unsupervised learning



supervised learning



reinforcement learning

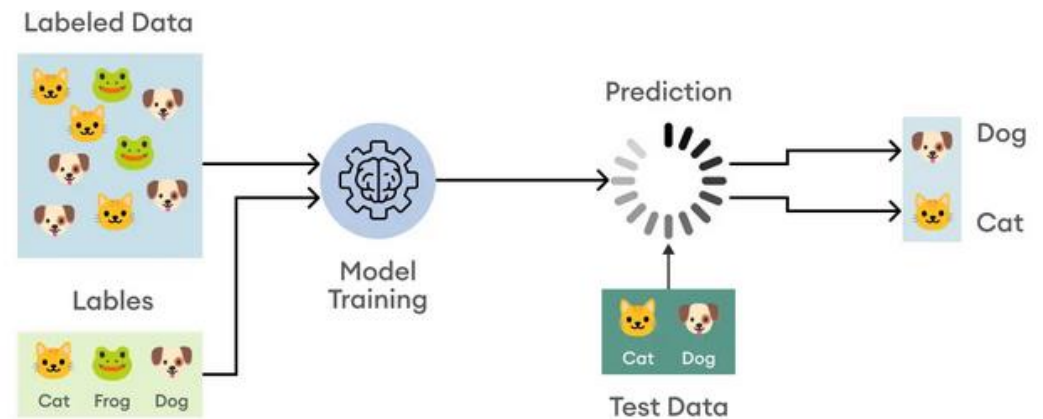


<https://www.mathworks.com/discovery/reinforcement-learning.html>

Učení s učitelem (supervised learning)

- ▶ **Trénovací množina** tvaru [vstup, požadovaný výstup]
- ▶ **Cíl učení:** aby model pro každý vstupní vzor správně predikoval hodnotu výstupu
- ▶ **Zobecňování:** model by měl dát správný výstup i pro data, která v trénovací množině nebyla
- ▶ **Typy úloh:** klasifikace, regrese, učení strukturovaných dat
- ▶ **Aplikace:** diagnostika v medicíně, klasifikace či segmentace obrazu, detekce fraudů (finanční podvody,...), rozpoznávání řeči, zpracování přirozeného jazyka,...

Klasifikace: predikce třídy (kategorie)



<https://www.superannotate.com/blog/image-classification-basics>


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



Učení bez učitele (unsupervised learning)

- ▶ **Trénovací množina:** obsahuje pouze vstupy
- ▶ **Cíl učení:** najít strukturu nebo vzory v datech
- ▶ **Zobecňování:** model by měl být schopný objevovat podobné struktury i v nových datech
- ▶ **Typy úloh:** snížení dimenzionality, detekce anomálií, shlukování, extrakce příznaků
- ▶ **Aplikace:** shlukování zákazníků podle chování, e-komerce (doporučovací systémy), komprese dat, detekce plagiátů, detekce anomálií (např. v bankovních transakcích)

snížení dimenzionality




shlukování

detekce anomálií



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



Typický průběh řešení úlohy strojového učení



► Definice úkolu

- Jakou úlohu řešíme, jaká máme data? O jaký typ úlohy se jedná? Které modely strojového učení připadají v úvahu? Co je přesně cílem?
- Provedeme rešerši stávajících řešení, omezení,...

► Sběr dat

- A snaha co nejlépe datům porozumět

Typický průběh řešení úlohy strojového učení



► Předzpracování dat

- Převedení dat do formátu, se kterým se bude zvolenému modelu strojového učení nejlépe pracovat

► Výběr a tvorba modelu strojového učení

- Jaký typ modelu? ... záleží na úloze
- Jaký model daného typu? ... existují šablony

Hluboké učení (deep learning)

- ▶ Využívá **umělé neuronové sítě** s mnoha vrstvami (tzv. hluboké sítě), které napodobují strukturu a funkci lidského mozku.
 - ▶ Model sám extrahuje příznaky z dat a snižuje nároky na jejich předzpracování
- ▶ **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“.


Klasické strojové učení:



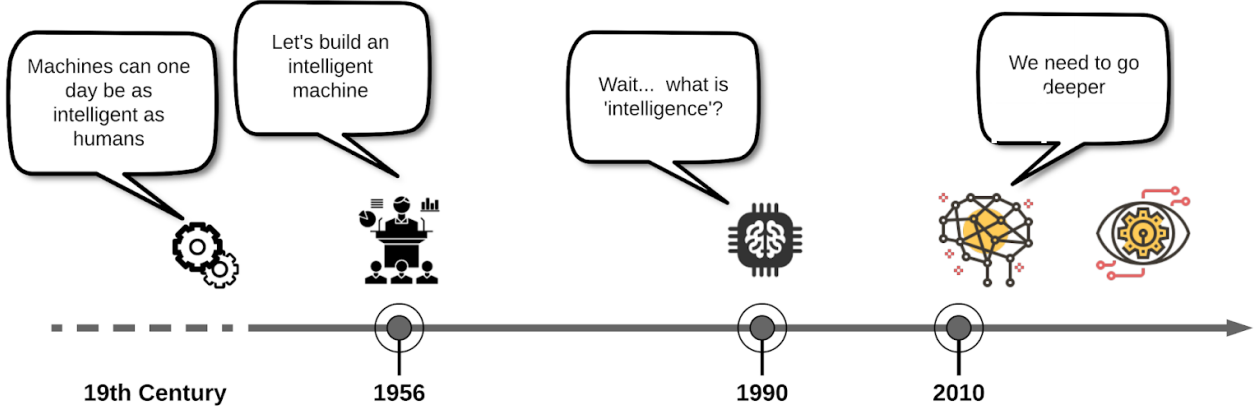
Hluboké učení:



Příklad extrakce příznaků pomocí konvoluční neuronové sítě:



Letmý pohled do historie AI a umělých neuronových sítí

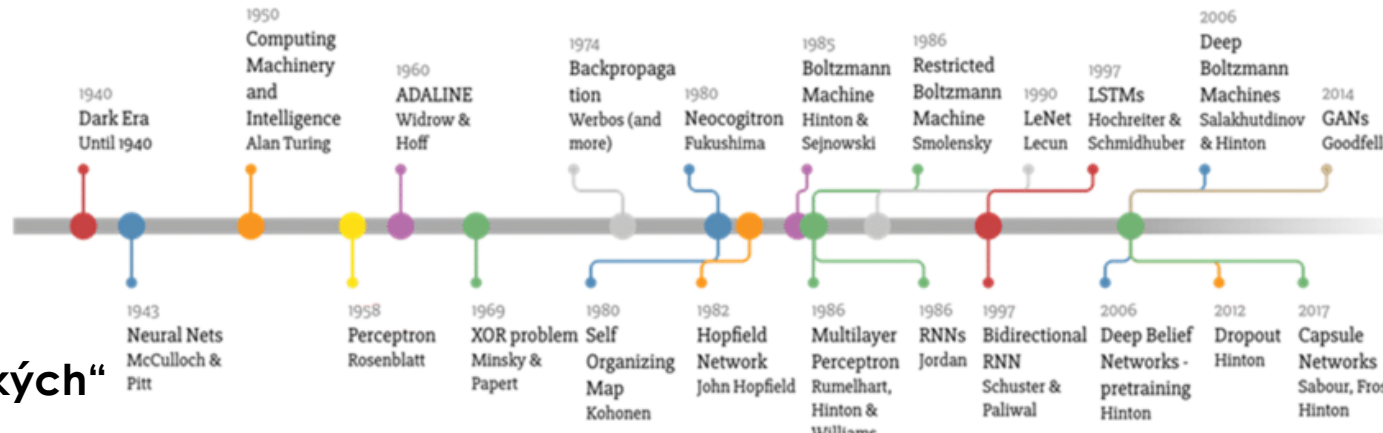



Vývoj probíhal ve vlnách:

- ▶ 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“

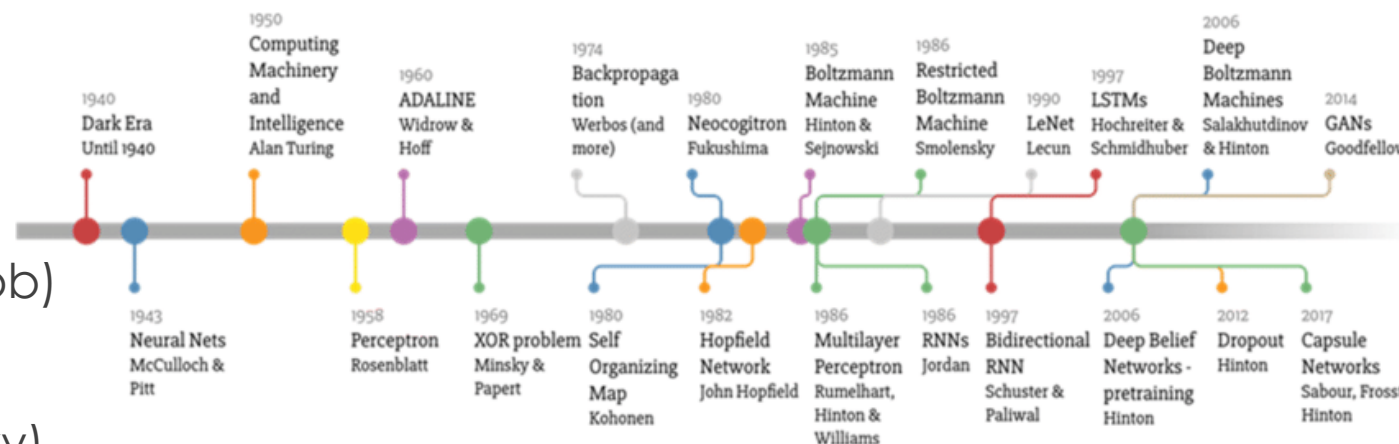

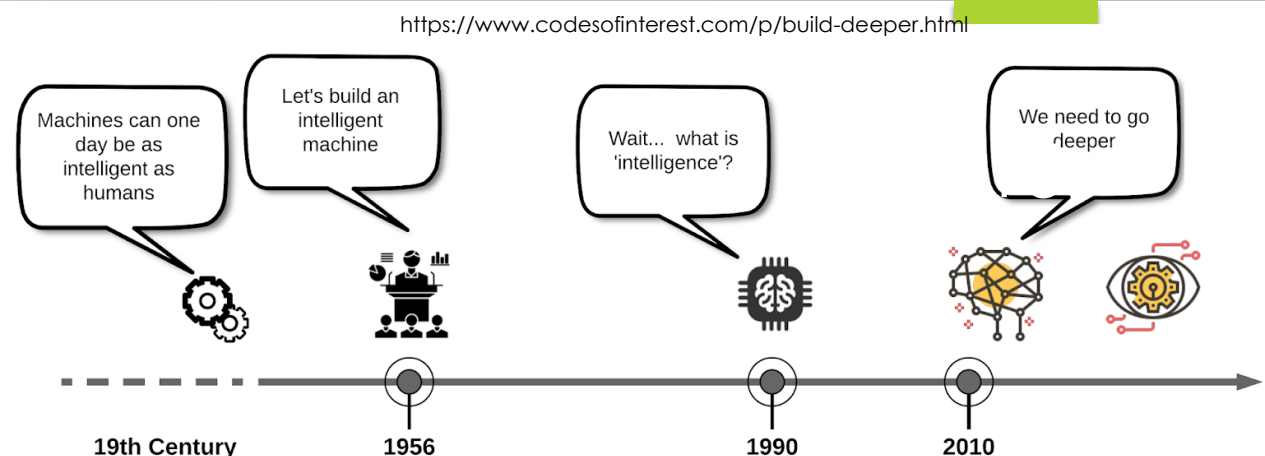


Mourtzis, Dimitris & Angelopoulos, John. (2020). An intelligent framework for modelling and simulation of artificial neural networks (ANNs) based on augmented reality. International Journal of Advanced Manufacturing Technology. 111. 10.1007/s00170-020-06192-y.

Letmý pohled do historie AI a umělých neuronových sítí

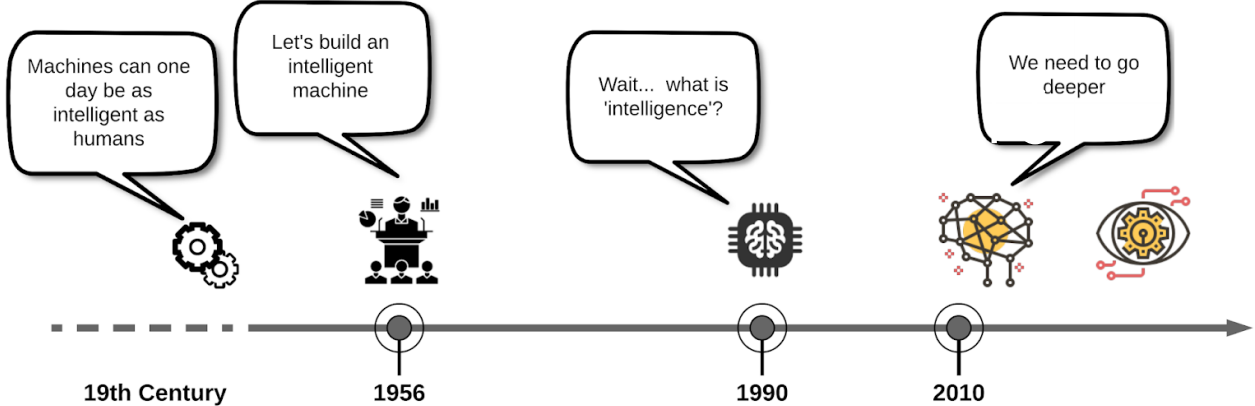
Počátky a raný vývoj (1940–1960)

- ▶ První teoretické základy:
 - ▶ Turingův test (1950).
 - ▶ První programy pro hry a logiku.
- ▶ 1943 – **první matematický model neuronu** (W. McCulloch, W. Pitts)
 - ▶ Reprezentace logických a aritmetických funkcí
- ▶ 1949 – **matematický pojem učení**, první učící algoritmus pro umělý neuron (D. Hebb)
 - ▶ Podmíněné reflexy
- ▶ 1951 – první **neuropočítač** Snarc (M. Minsky)



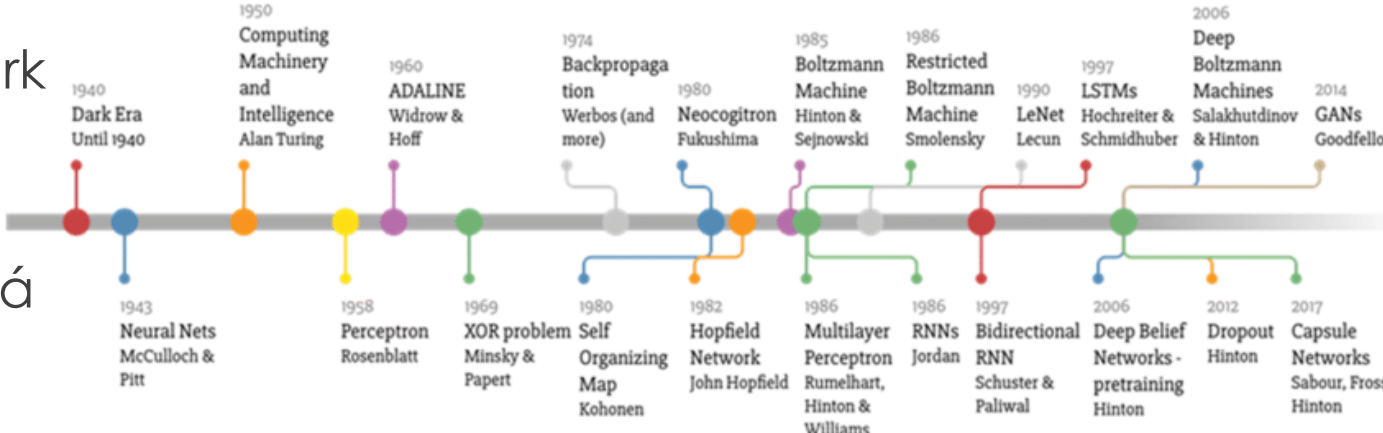
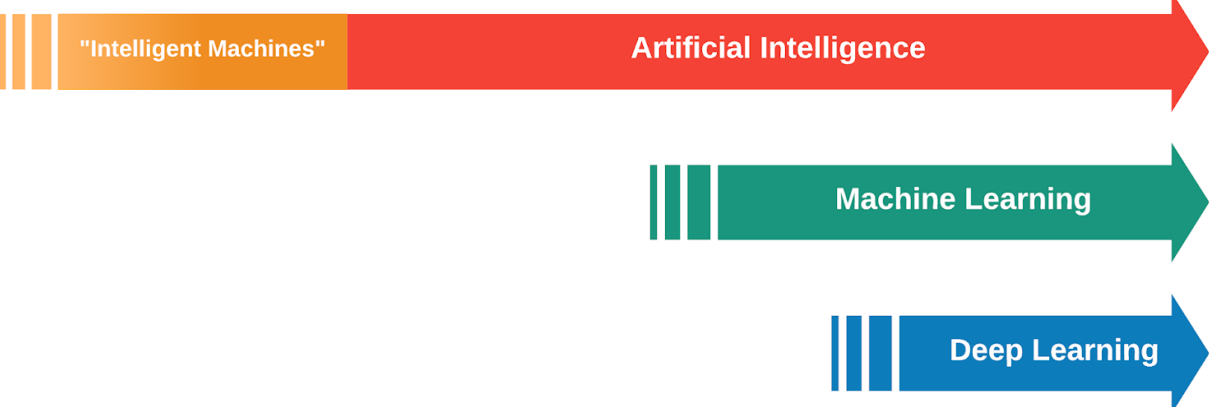
Mourtzis, Dimitris & Angelopoulos, John. (2020). An intelligent framework for modelling and simulation of artificial neural networks (ANNs) based on augmented reality. International Journal of Advanced Manufacturing Technology, 111. 10.1007/s00170-020-06192-v

Letmý pohled do historie AI a umělých neuronových sítí



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

- ▶ 1957 - **Perceptron** (F. Rosenblatt)
 - ▶ Praktický model umělého neuronu, spolu s funkčním učícím algoritmem
 - ▶ článek vyvolal obrovské nadšení
- ▶ 1958 - první úspěšný neuropočítac Mark I Perceptron (F. Rosenblatt, C. Wightman)
- ▶ 1962 - **Adaline** a sigmoidální přenosová funkce (B. Widrow, M. Hoff)




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-v


Jednoduchý neuron (perceptron)

- ▶ Nejjednodušší model neuronové sítě (1957 – F. Rosenblatt)
- ▶ Inspirován fungováním biologických neuronů
- ▶ Učení s učitelem (supervised learning):
 - ▶ Posouvání dělicí nadroviny, aby každý bod byl na správné straně


Binární klasifikace:



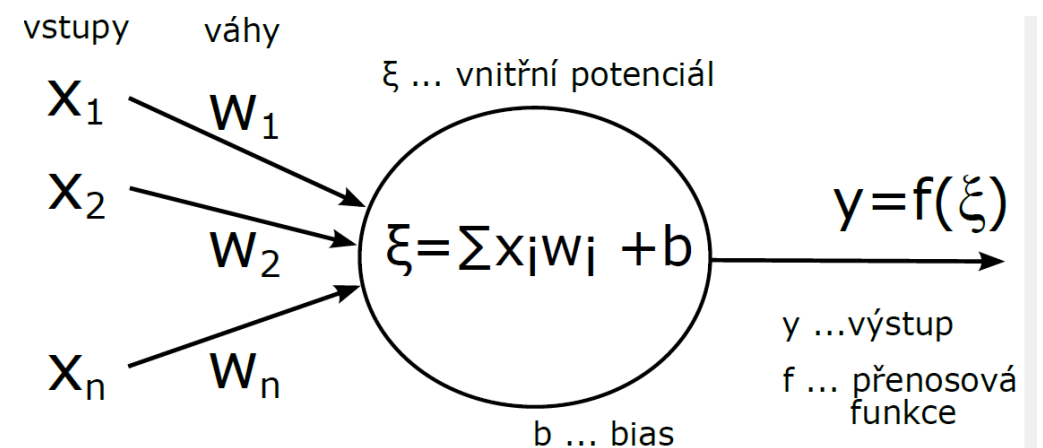
Lineární regrese:



Biologický neuron:



Umělý neuron:




Letmý pohled do historie AI a umělých neuronových sítí

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

- ▶ velký rozvoj neurovýpočtů a neuropočítačů, pak náraz na strop
- ▶ 1969 - článek Perceptrons (M. Minsky, S. Papert) – ukázal limity perceptronu (nezvládne modelovat ani všechny základní logické funkce, např. tzv. XOR)

XOR (exluzivní OR): na to jeden neuron nestačí:





1970 – 1980 : první “Neuronová zima”

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

Letmý pohled do historie AI a umělých neuronových sítí


- ▶ **XOR (exkluzivní OR):** na to jeden neuron nestačí:
- ▶ Ale co spojit více neuronů do jedné sítě?



Zdroj obrázků: Kateřina Horaisová: slidy k předmětu Neuronové sítě 1, FJFI ČVUT Děčín


- ▶ **To je hezké, ale jak takový model učit?**
 - ▶ Algoritmus pro učení perceptronu použít nejde ☹
 - **Algoritmus zpětného šíření chyby (back-propagation)**

Letmý pohled do historie AI a umělých neuronových sítí



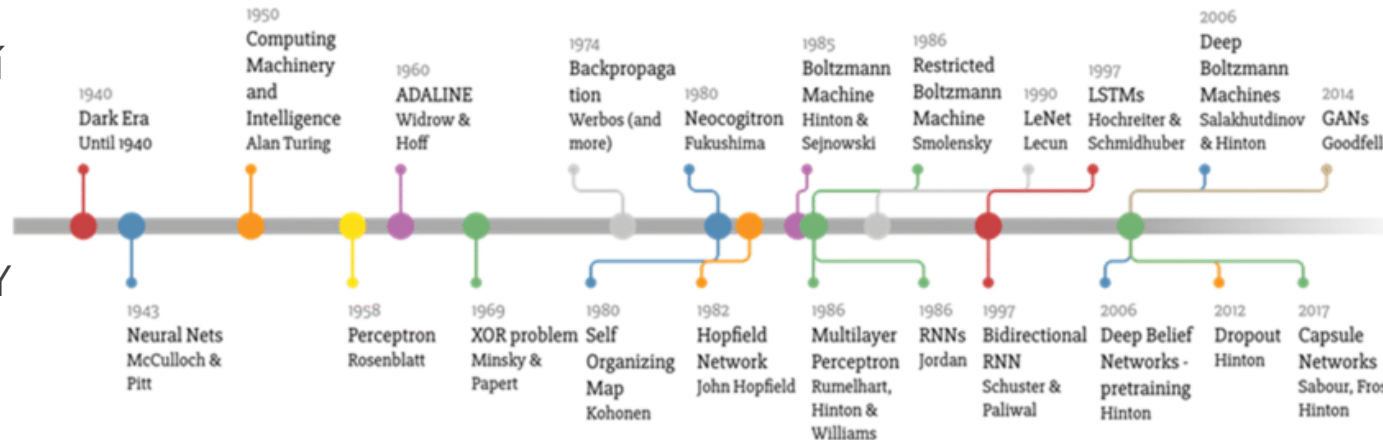
1980 – 1990 : druhý boom - období „mělkých“ neuronových sítí

- ▶ Opětovná popularizace oboru (J. Hopfield aj.)
- ▶ Boom modelů skládajících se z více neuronů (neuronové sítě)
 - ▶ Vícevrstvá neuronová síť (multilayer perceptron)
 - ▶ Kohonenovy mapy, Hopfieldova síť, SVM,...
 - ▶ Ale také: první rekurentní modely, konvoluční neuronové sítě




▶ 1986 – Algoritmus zpětného šíření chyby (back-propagation)

- ▶ P. Werbos a D. Rumelhart, již dříve G.Hinton, Y LeCun
- ▶ Klíčový koncept, který používáme dodnes

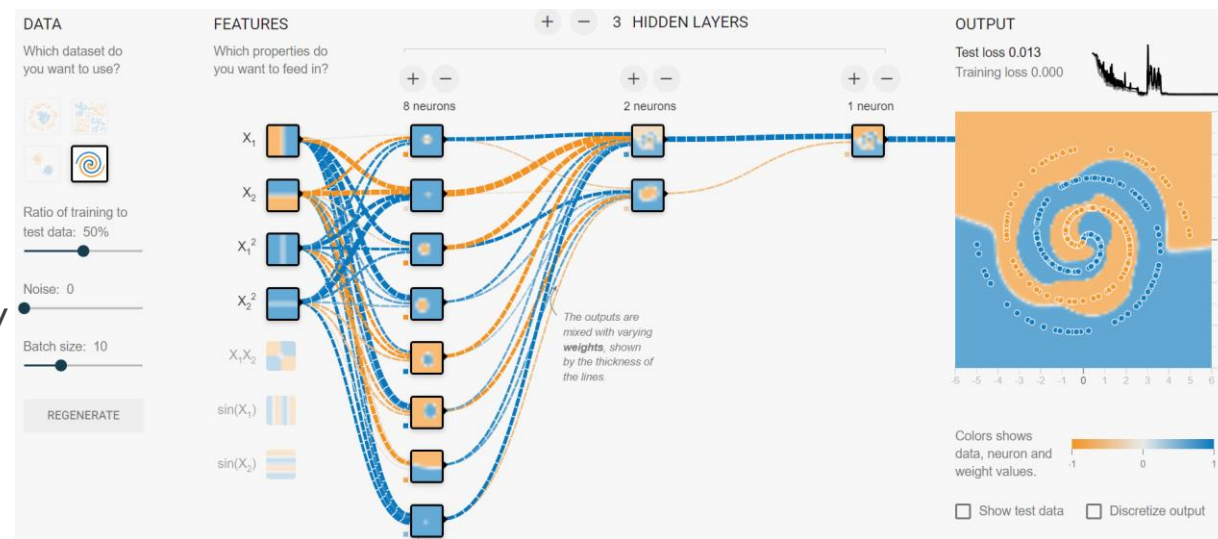


Vícevrstvá neuronová síť (Vícevrstvý perceptron, MLP)

- ▶ Klasický, univerzální model neuronové sítě
- ▶ Neurony jsou uspořádané do vrstev, vrstvy jsou plně propojené
- ▶ Vstupy a výstupy modelu musí být vektory čísel
- ▶ Učení gradientní metodou pomocí algoritmu zpětného šíření (backpropagation)
 - ▶ **Cíl učení:** nastavit parametry modelu (váhy a biasy všech neuronů) tak, aby model pro každý vstupní vzor dal správný výstup




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




Učení neuronových sítí – algoritmus zpětného šíření (backpropagation)

Základní princip učení neuronových sítí:

- ▶ Náhodně inicializujeme parametry modelu (váhy a prahy)
- ▶ V cyklu:
 - ▶ Připravíme si dávku trénovacích vzorů
 - ▶ Spočteme skutečný výstup (**dopředný průchod**)
 - ▶ Spočítáme chybu modelu: jak moc se liší skutečný výstup modelu od požadovaného výstupu
 - ▶ Adaptujeme váhy a prahy (**zpětný průchod**): tak, aby se chyba modelu o něco zmenšila




Letmý pohled do historie AI a umělých neuronových sítí




1990 – 2000 : období zklidnění

- ▶ 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 a problém s přeučením (model je perfektní na známých datech, ale selhává na nových)
- ▶ Snaha o učení hlubokých neuronových sítí
 - ▶ Již existují např. konvoluční neuronové sítě
 - ▶ Ale náraz na technologický strop: omezené výpočetní zdroje (procesor, paměť)




2000 – 2010 : druhá „Neuronová zima“



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-v

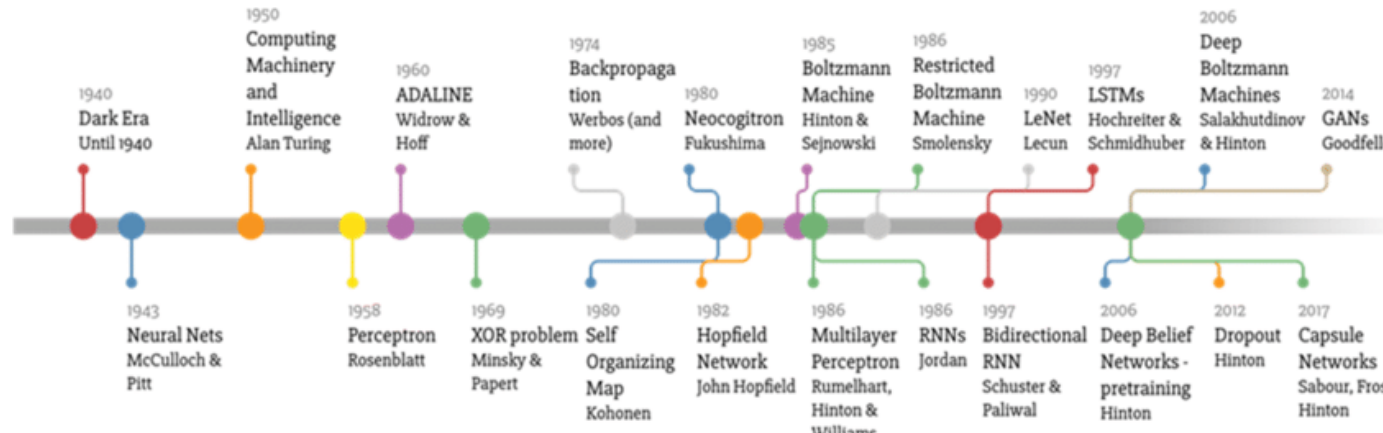

Letmý pohled do historie AI a umělých neuronových sítí



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 modelu CNN (konvoluční neuronová síť) v soutěži ILSVRC 2012:
 - ▶ ImageNet Dataset: 16 milionů barevných obrázků z 20 tisíc kategorií:



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-v

Co umožnilo boom hlubokého učení?

25

- Řada frameworků a dalších nástrojů:

- ▶ **Python:**

- ▶ TensorFlow (2015)
 - ▶ PyTorch (2016)
 - ▶ Keras (2015)
 - ▶ Caffe (2013)
 - ▶ Theano (2007)
 - ▶ MXNet (2015)
 - ▶ ...

- ▶ **Java:**

- ▶ Deeplearning4j (2014)
 - ▶ Neuroph (2008)
 - ▶ DL4J (2014)
 - ▶ **C++:**
 - ▶ Caffe (2013)
 - ▶ Torch (2002)
 - ▶ TensorFlow C++ (2015)

- ▶ **R:**

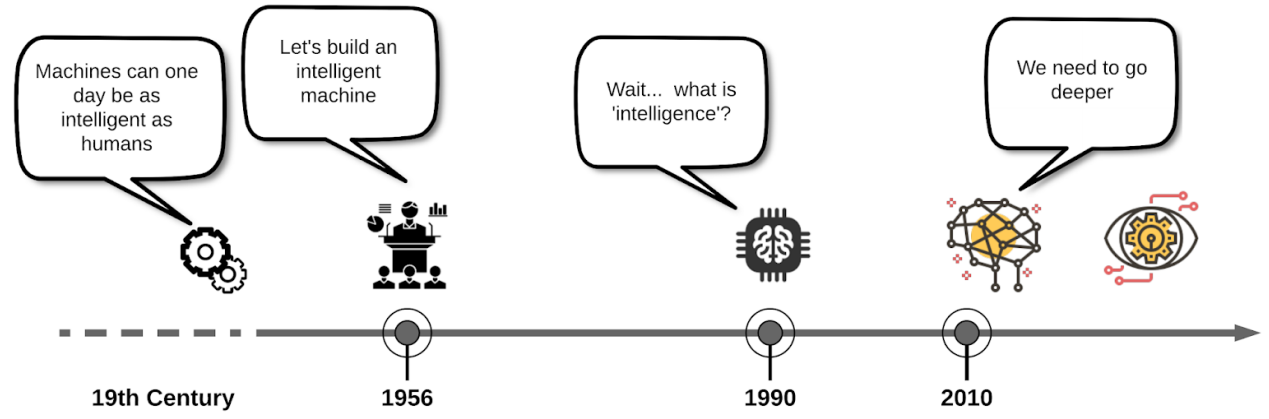
- ▶ MXNet (2015)
 - ▶ TensorFlow (2015)
 - ▶ Keras (2015)
 - ▶ H2O.ai (2012)

- ▶ **Julia:**

- ▶ Flux.jl (2016)
 - ▶ Knet.jl (2017)

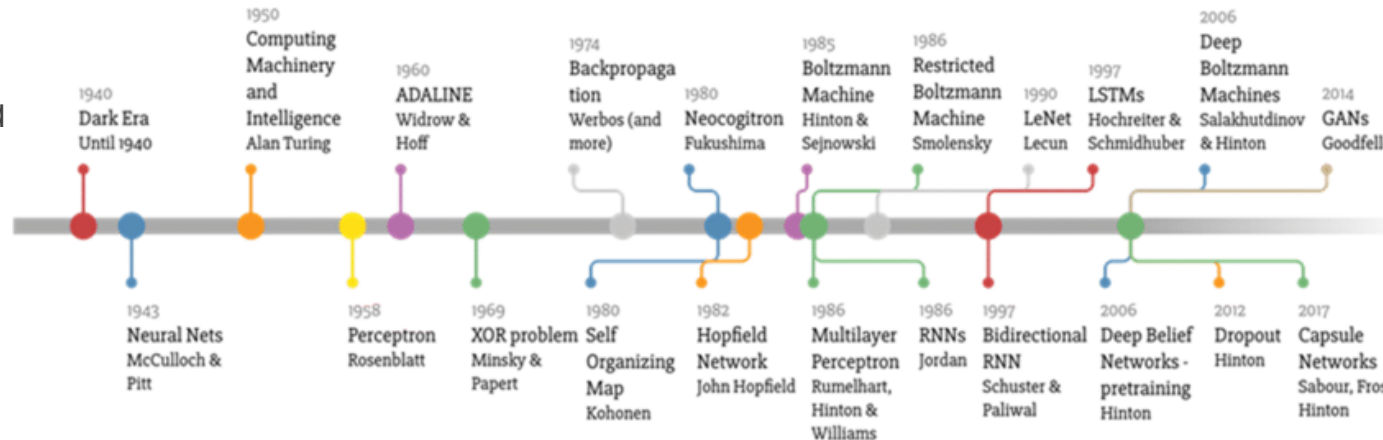

- Snadná dostupnost dat k učení (např. <https://www.kaggle.com/datasets>)
- Velké množství praktických příkladů (use cases)
- Řada předučených modelů (např. <https://keras.io/api/applications/>)

Letmý pohled do historie AI a umělých neuronových sítí



2010 – nyní : třetí boom – období hlubokých neuronových sítí

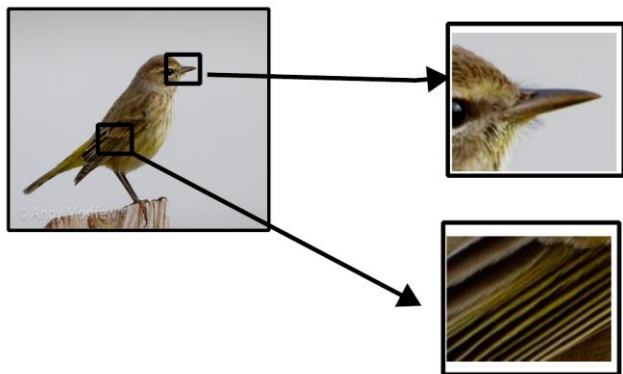
- ▶ Následuje obrovsky boom nových modelů a architektur hlubokých neuronových sítí
 - ▶ Moderní rekurentní neuronové sítě (LSTM, Hochreiter, Schmidhuber, 1997)
 - ▶ GAN – Generative adversarial network (I. Goodfellow, 2015)
 - ▶ První jazykový generativní model založený na transformer architektuře: GPT-3 (2020, OpenAI), později chat bot ChatGPT (2022)
 - ▶ První text-to-image model Stable Diffusion (2022, CompVis)
 - ▶ ...



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-v



Konvoluční neuronové sítě (CNNs)

- ▶ Založeny na operaci konvoluce
- ▶ Jsou schopné rozpoznat v datech vzory (příznaky) různé úrovně: od hran až např. po oči



- ▶ **Hlavní aplikace:** zpracování obrazu (klasifikační úlohy, rozpoznání a segmentace obrazu), zpracování signálů, videa

Ukázka příznaků extrahovaných první konvoluční vrstvou:

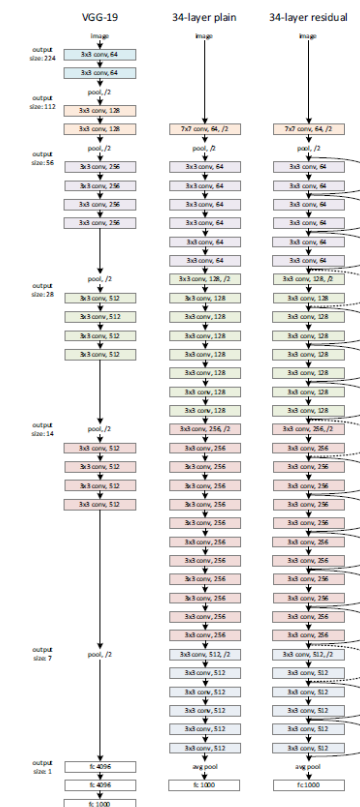


Zdroj : <https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>, upraveno

GoogleNet



ResNet



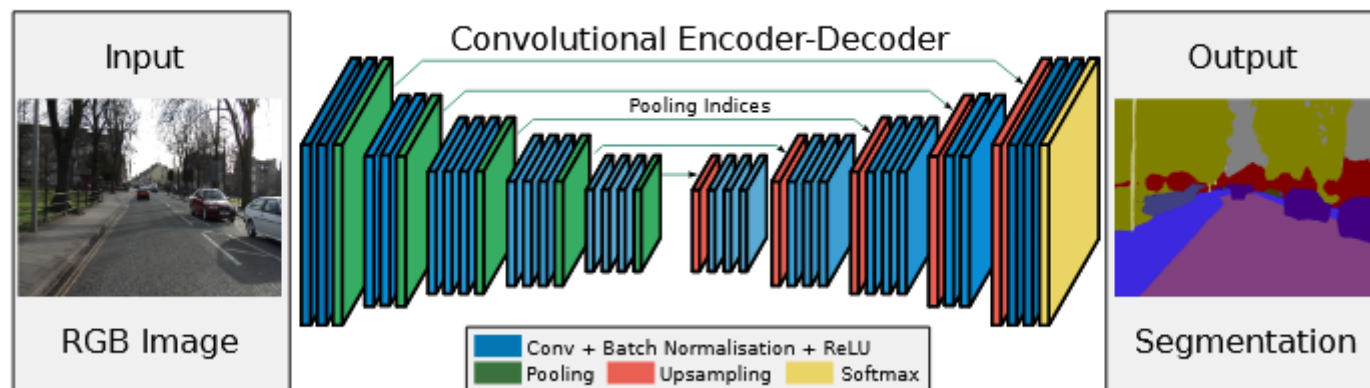
Architektury hlubokých neuronových sítí

Autoencodery

- Model hluboké neuronové sítě učený bez učitele
- Změna reprezentace dat, čištění dat, komprese a rekonstrukce

Encoder-decodery


- Segmentace obrazu, popis obrázků, shrnutí textů,...



Zdroj : SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation <https://arxiv.org/pdf/1511.00561>

Variační autoencodery:

- Kódují data jako pravděpodobnostní rozdělení
- Schopné generovat nová data nebo vytvářet interpolace:



Tom White: Sampling generative networks, <https://arxiv.org/pdf/1609.04468>



F. Chollet: Deep learning v jazyku Python, obr. 5.7

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 schopný zachytit i dlouhodobé závislosti

► Gated Recurrent Unit Networks (GRU)

- Zjednodušená verze LSTM
- Modelování sekvenčních dat
- Rozpoznání řeči a strojový překlad

Příklad: Image captioning (popis obrázků):



A dog is running in the grass with a frisbee






A woman is holding a cat in her hand



Two giraffes standing in a grassy field



A person holding a computer mouse on a desk



Architektury hlubokých neuronových sítí

► Generative Adversarial Networks (GANs)

- Generování nových dat na základě naučených vzorů.

► Siamese Networks

- Pro úlohy rozpoznání obrazu, object-tracking
- Počítají podobnost mezi dvěma různými vstupy

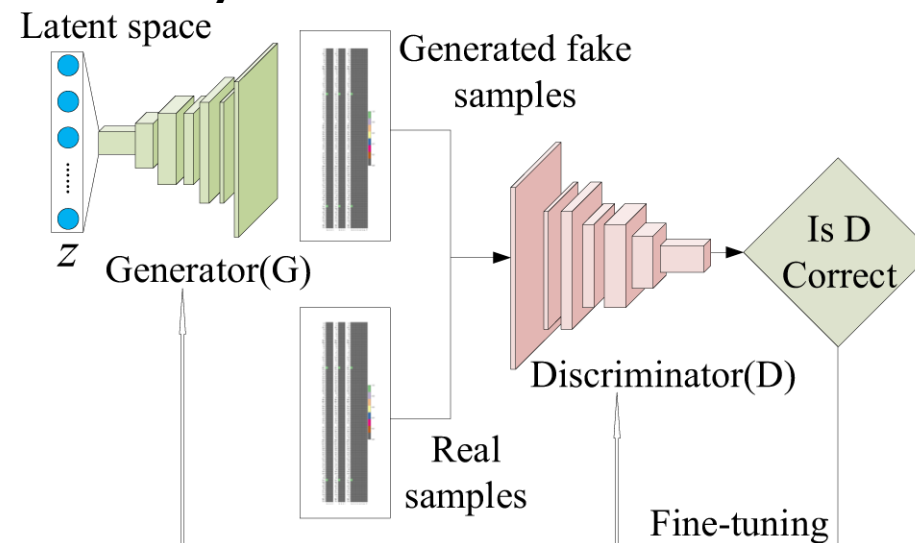
► Capsule Networks

- Pro úlohy rozpoznání obrazu
- Modelují hierarchické vztahy mezi částmi objektů

► Transformer Networks (Gemini, GPT,...)

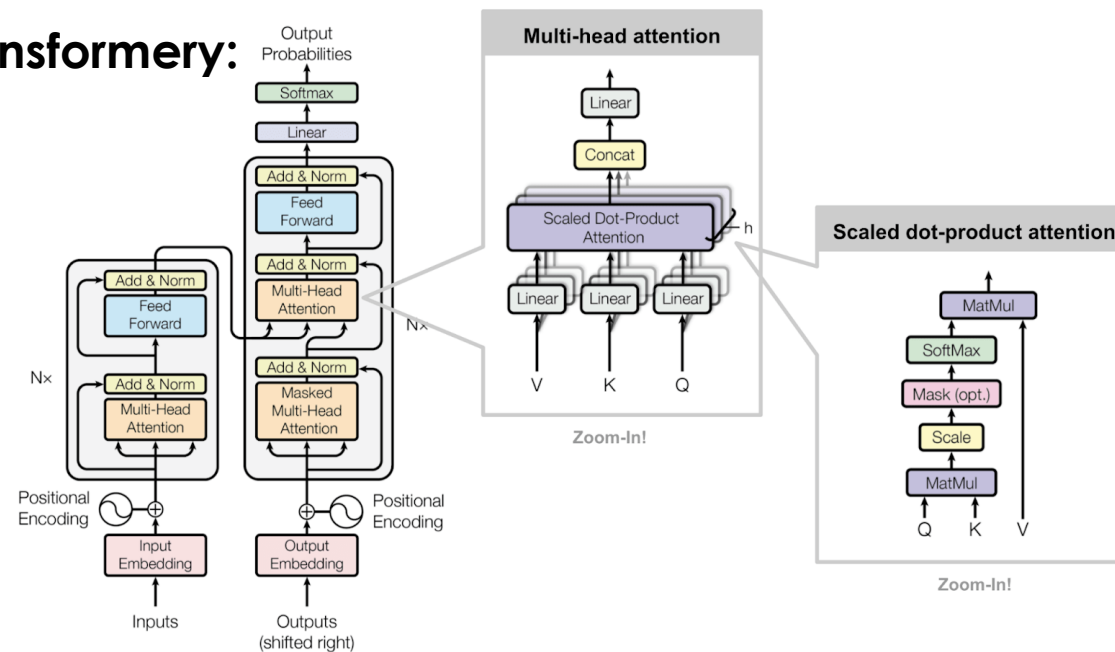
- Pro úlohy zpracování přirozeného jazyka (klasifikace textů, překlady apod.).

Generativní modely:



Dan, Y., Zhao, Y., Li, X. et al. Generative adversarial networks (GAN) based efficient sampling of chemical composition space for inverse design of inorganic materials. *npj Comput Mater* 6, 84 (2020). <https://doi.org/10.1038/s41524-020-00352-0>

Transformery:



Attention is all you need, A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. Gomez, et al.. Advances in Neural Information Processing Systems, page 5998–6008. (2017)

Letmý pohled do historie AI

- ▶ **Současné výzvy a etické otázky**
 - ▶ **Zneužívání AI:** Falešné informace, ztráta soukromí a předpojatost.
 - ▶ **Regulace a odpovědnost:** Jak zajistit bezpečné a spravedlivé použití AI?
 - ▶ **Problematika autorství**
 - ▶ **Tří tovaryši a mluvící panna** (řezbář, krejčí a loutkář)
 - ▶ **Moderní verze:** autor učiva pro AI, programátor struktury AI a autor promptu
 - ▶ **Komu z této trojice náleží autorská práva za produkt generativního AI?**
- ▶ **A co bude dál?**
 - ▶ Bude se opět opakovat historie s přehnanými očekáváním?



Děkuji za pozornost

V případě zájmu:

- **Neuronové sítě a hluboké učení v závěrečných pracích našich studentů**


Hluboké učení v závěrečných pracích našich studentů

- ▶ Hlasově ovládaný robot
- ▶ Generování map pomocí generativního modelu neuronové sítě
- ▶ Analýza a zpracování obrazu (identifikace objektů a odstranění šumu,...)
- ▶ Autonomní agenti v počítačových hrách
- ▶ Fyzikální aplikace, vývoj pro CERN
- ▶ a mnohé další



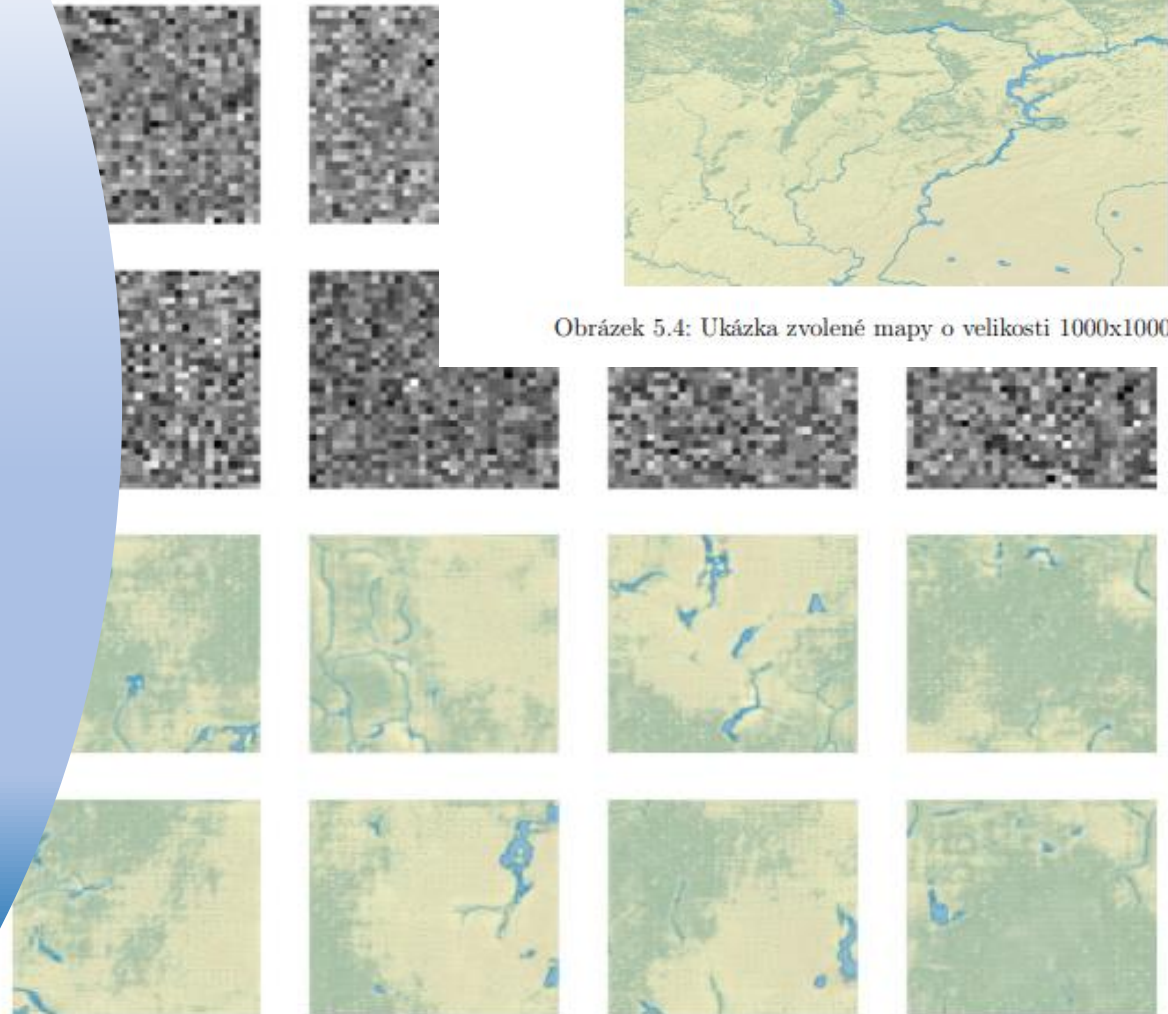
Hlasem ovládaný robot

- Využití metod hlubokého učení (LSTM) pro rozpoznání řeči
- Moderní hardware Nvidia Jetson a Jetbot
- Možnost řízení přes wi-fi
- Online rozpoznávání hlasových příkazů
- Online rozpoznávání předmětů na obraze z kamery



Procedurální generování prostředí

- Generování map z náhodného šumu pomocí generického modelu neuronové sítě (GAN)
- Model učený na satelitních snímcích Země
- Využití v herním průmyslu



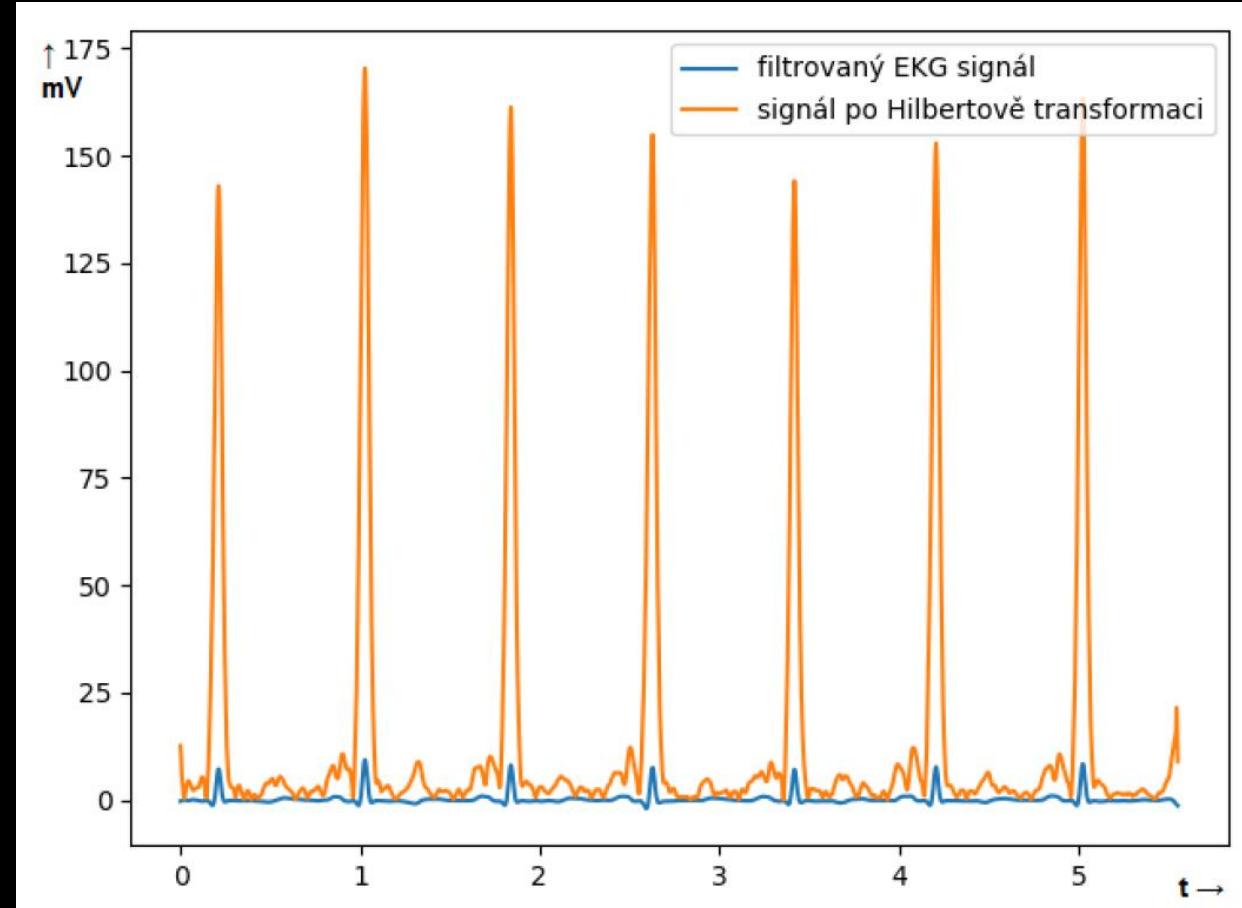
Obrázek 5.4: Ukázka zvolené mapy o velikosti 1000x1000 pixelů

Obrázek 6.3: Ukázka natrénované a negenerované sítě pomocí náhodného šumu

Aplikace strojového učení při zpracování medicínských dat

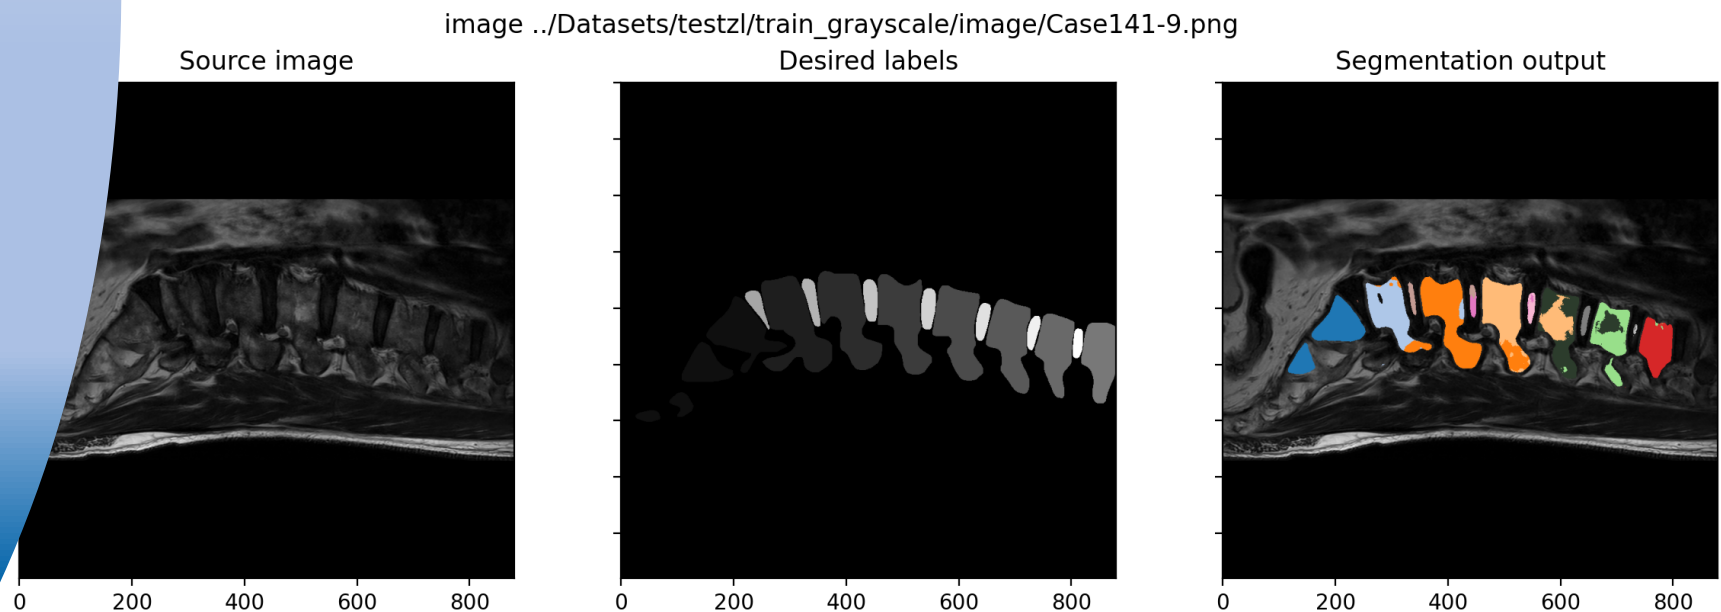

Klasifikace EKG signálů pomocí support vector machines v Pythonu

- Využití volně dostupných dat ručně anotovaných lékaři
- Předzpracování signálu
- Aplikace strojového učení na medicínský problém
- Úspěšnost 99 %



Aplikace strojového učení při zpracování medicinských dat

- Snímky RTG/MR/CT
- Podpora při tvorbě diagnózy
- Čištění obrazu, odstranění šumu
- Automatická segmentace, hledání objektů/struktur
- Klasifikace a predikce nalezených struktur



Využití konvolučních neuronových sítí pro rozpoznání obrazu

- Aplikace konvolučních neuronových sítí s využitím metody přeneseného učení
- Rozpoznávání architektonického stylu budovy z fotografie
- Vyhledání podobných fotografií v databázi
- Vizualizace zajímavých atributů naučené konvoluční sítě



Barokní architektura na 95.23 %

Načíst obrázek

Vyhodnotit

Image retrieval

Reset



Baroko



Baroko




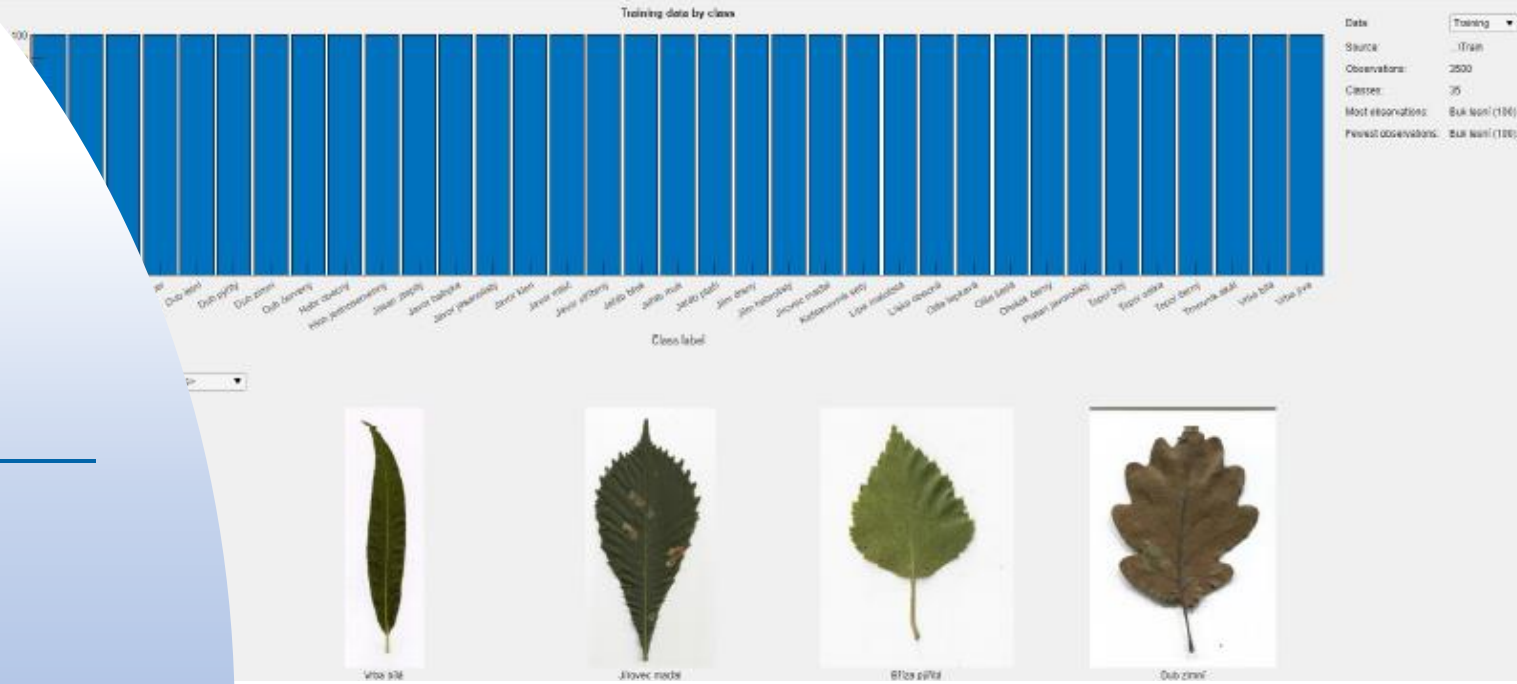
Baroko



Baroko

Využití konvolučních neuronových sítí pro rozpoznání obrazu

- Aplikace konvolučních neuronových sítí s využitím metody přeneseného učení
- Deep Network Designer (MATLAB)
- Vizualizace zajímavých atributů naučené konvoluční sítě
- Rozpoznávání listů stromů



(a) Jírovec maďal





(b) Javor babyka

Využití konvolučních neuronových sítí pro rozpoznání obrazu

Klasifikace RTG snímků trubek kotle

- Detekce stupně důlkové koroze (třídy poškození Q1,...,Q5)
- Srovnání různých modelů CNN



Využití konvolučních neuronových sítí pro rozpoznání obrazu

Rozpoznávání typu automobilu

- Implementace CNN v prostředí Matlab
- Srovnání různých webscrapingových metod pro získání obrazových dat z webu
- Srovnání různých modelů CNN





Aplikace neuronových sítí při vývoji her

- Využití herního engine Unity
- Umělá inteligence pro hru Mario Bros
- Jednoduchý fotbal



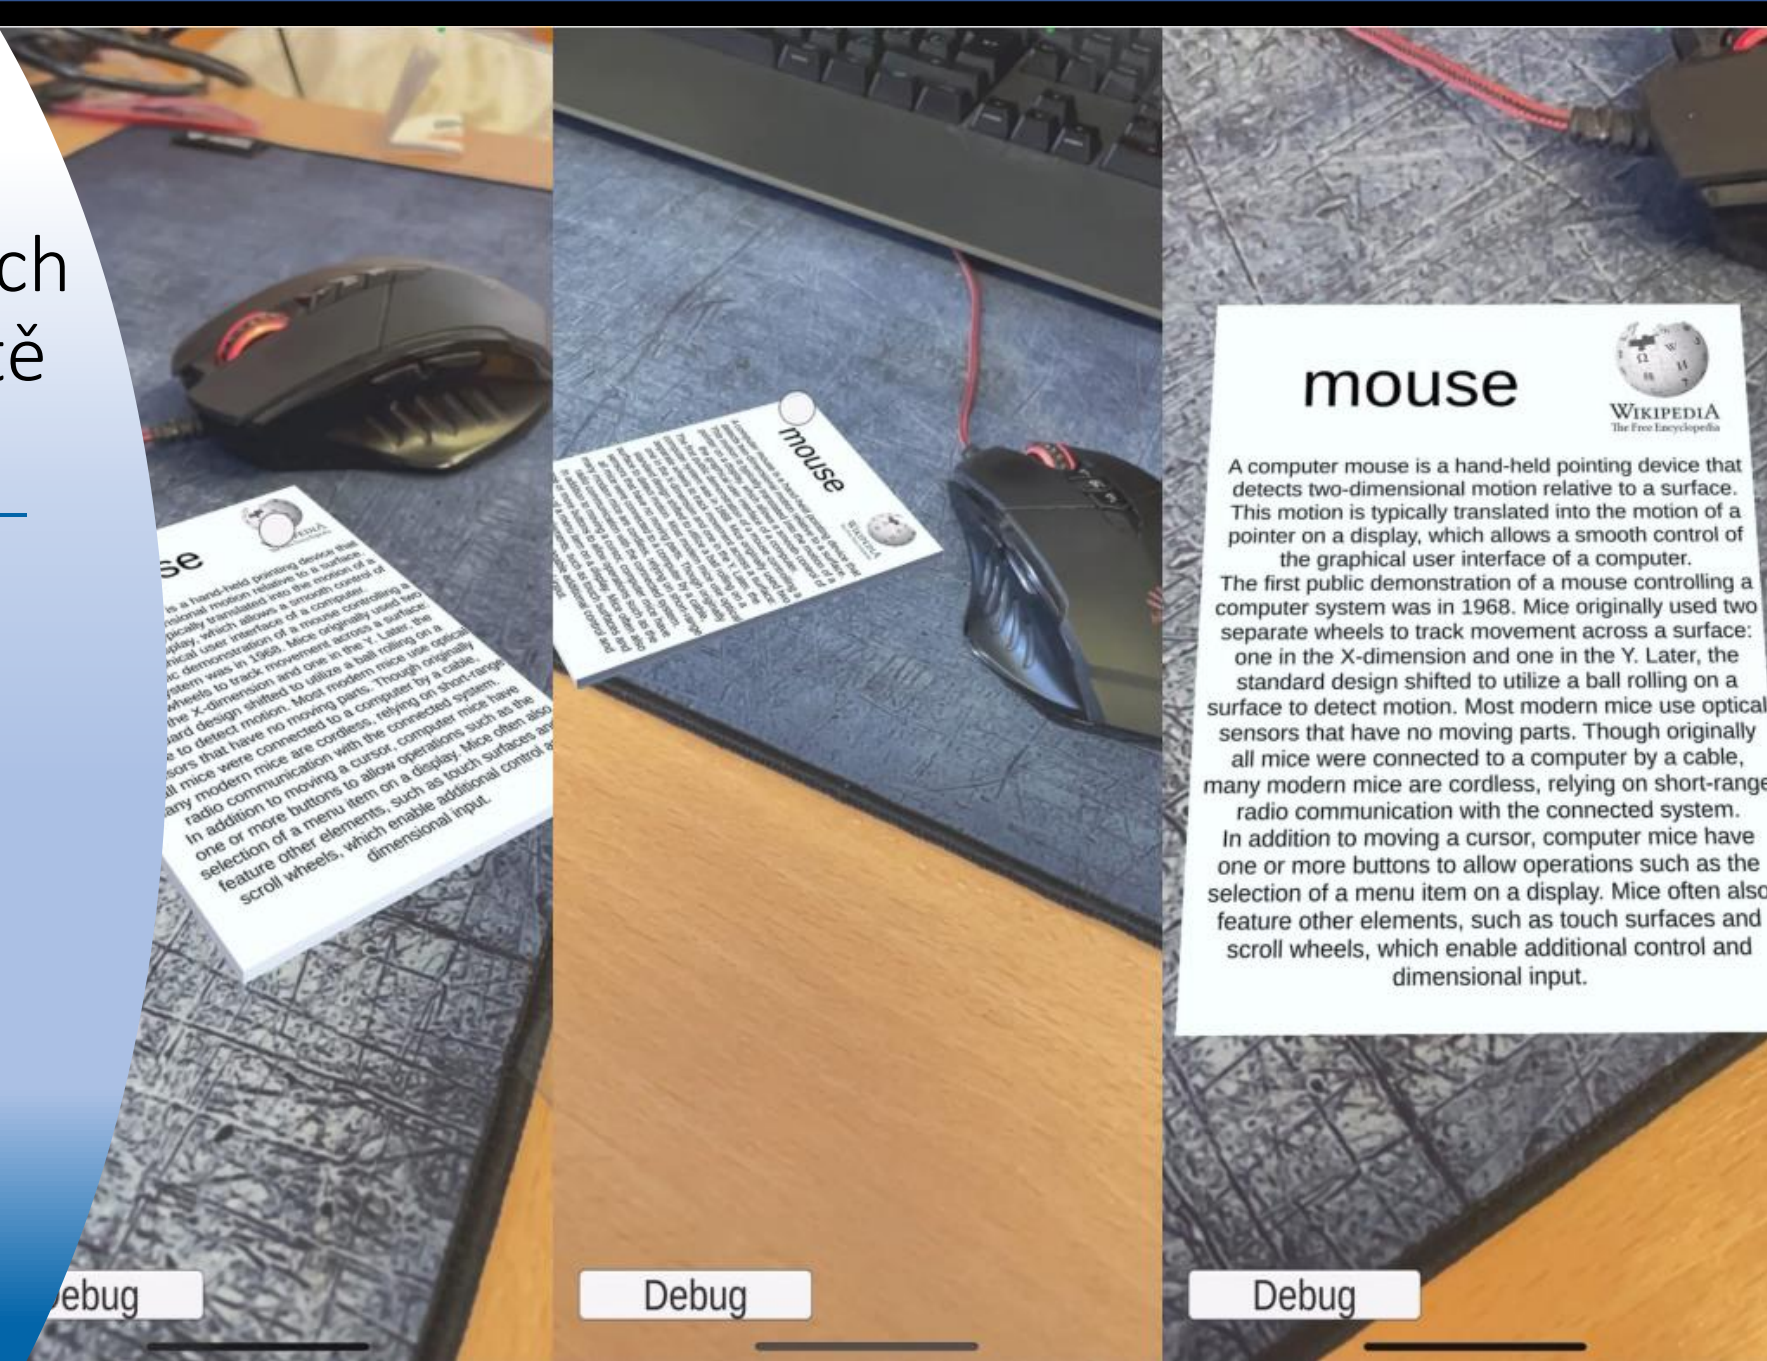
Aplikace neuronových sítí v rozšířené realitě

- Odhad hloubky scény na základě jedné fotografie
- Značná redukce počtu parametrů a tím doby trénování
- Výsledky srovnatelné s modely jiných autorů



Aplikace neuronových sítí v rozšířené realitě

- Využití konvoluční neuronové sítě pro rozpoznání objektů
- Mobilní aplikace pro iOS
- Využití engine Unity a knihovny Tensor Flow Lite, AR foundation



mouse



WIKIPEDIA
The Free Encyclopedia

A computer mouse is a hand-held pointing device that detects two-dimensional motion relative to a surface. This motion is typically translated into the motion of a pointer on a display, which allows a smooth control of the graphical user interface of a computer.

The first public demonstration of a mouse controlling a computer system was in 1968. Mice originally used two separate wheels to track movement across a surface: one in the X-dimension and one in the Y. Later, the standard design shifted to utilize a ball rolling on a surface to detect motion. Most modern mice use optical sensors that have no moving parts. Though originally all mice were connected to a computer by a cable, many modern mice are cordless, relying on short-range radio communication with the connected system.

In addition to moving a cursor, computer mice have one or more buttons to allow operations such as the selection of a menu item on a display. Mice often also feature other elements, such as touch surfaces and scroll wheels, which enable additional control and dimensional input.


Debug

Debug

Debug

CERN

- Mezinárodní výzkumné centrum v Ženevě
- Možnosti stáží a práce na místních experimentech
- Domov velkého množství experimentů s potřebou IT odborníků






CERN – Experimenty AMBER a COMPASS

- Experimenty s pevným terčem na urychlovači SPS v CERN (největší nadzemní – 60 m)

Úlohy:

- Rozpoznávání vzorů
- Detekce anomálií
- Klasifikace
- Rychlé triggery
- Rekonstrukce dat
- Mnoho dalších experimentů i mimo urychlovače (OSQAR, NA64)



Další tvorba studentů

- Predikce vývoje časových řad (akcie, kurzy měn, počasí,...)
- Modelování ekonomických systémů
- Fyzikální aplikace
 - Např. modelování interakce laserového záření s plazmatem s využitím neuronových sítí:

