

# Hluboké učení

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
<http://nlp.fi.muni.cz/uui/>

Obsah:

- Hluboké učení
- Aplikace hlubokého učení
- Techniky hlubokého učení

# Motivace

**vyjadřovací síla** klasických neuronových sítí:

*s jednou skrytou vrstvou* – všechny *spojité funkce*  
*se dvěma skrytými vrstvami* – *všechny funkce*

# Motivace

**vyjadřovací síla** klasických neuronových sítí:

*s jednou skrytou vrstvou* – všechny *spojité funkce*  
*se dvěma skrytými vrstvami* – *všechny funkce*

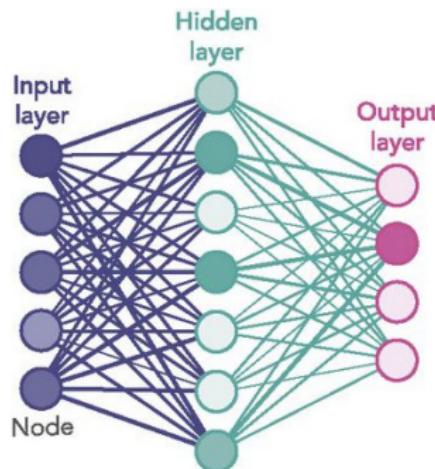
Proč tedy pracovat s **hlubšími architekturami**?

# Motivace

**vyjadřovací síla** klasických neuronových sítí:

*s jednou skrytou vrstvou* – všechny *spojité funkce*  
*se dvěma skrytými vrstvami* – všechny *funkce*

Proč tedy pracovat s **hlubšími architekturami**?



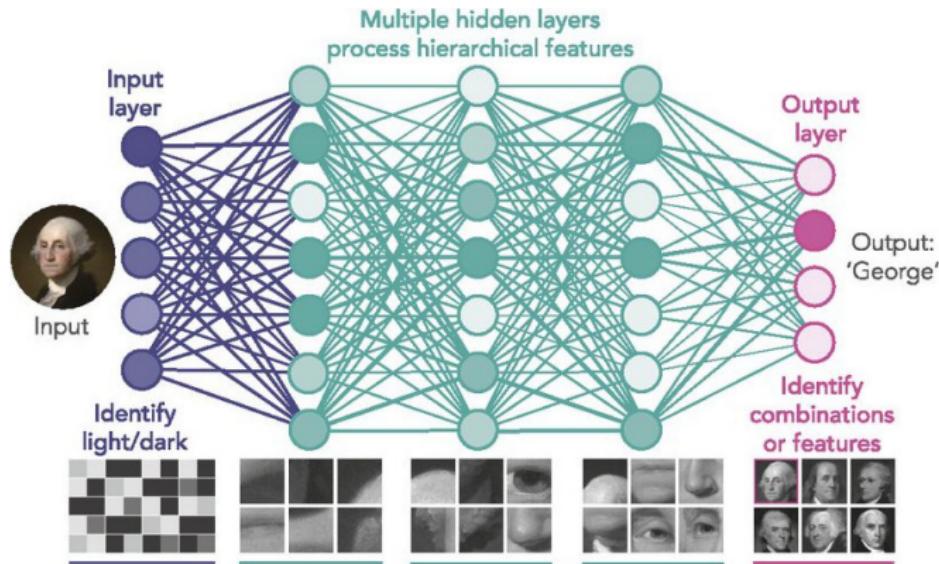
(příklad Waldrop, 2019)

# Motivace

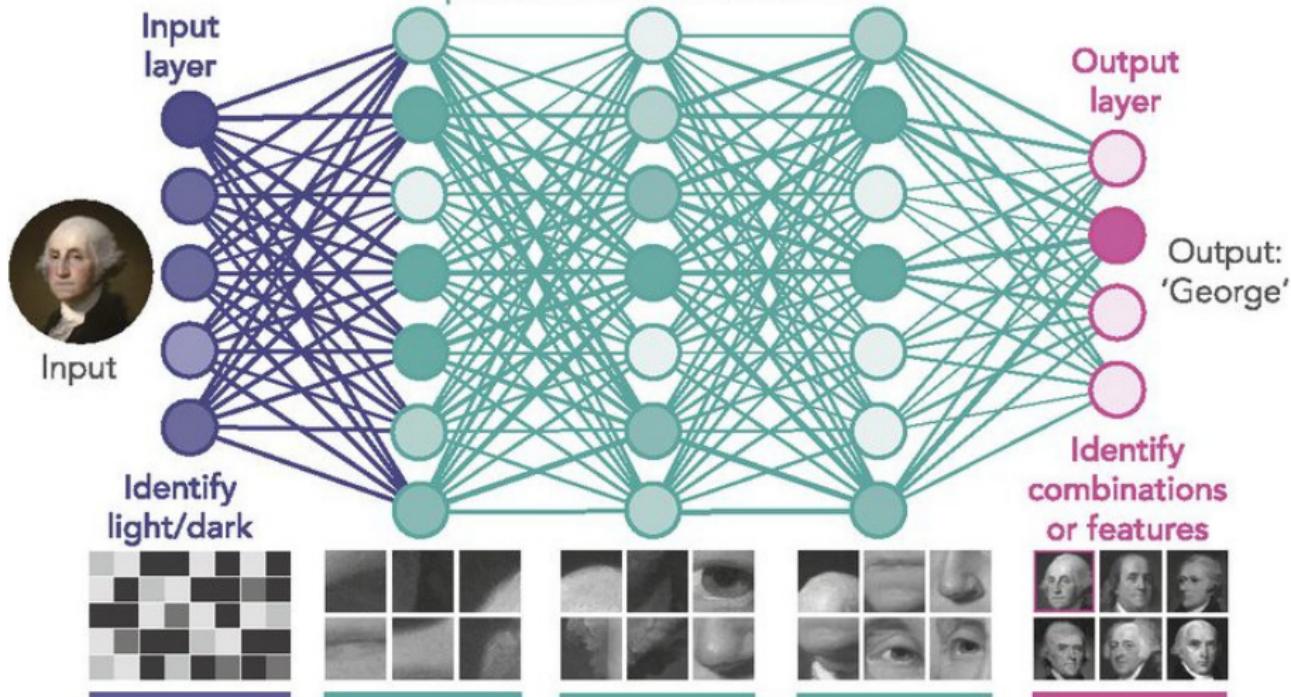
**vyjadřovací síla klasických neuronových sítí:**

*s jednou skrytou vrstvou – všechny spojité funkce  
se dvěma skrytými vrstvami – všechny funkce*

Proč tedy pracovat s **hlubšími architekturami?**



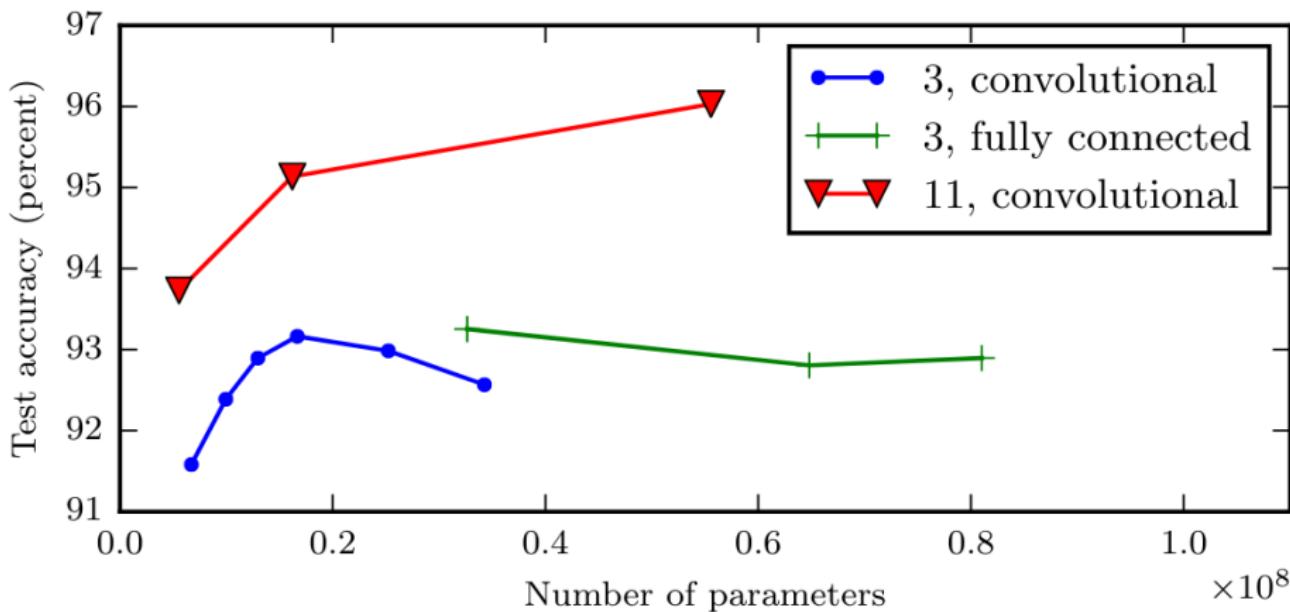
Multiple hidden layers process hierarchical features



# Motivace

**Hluboké učení** (*Deep Learning, Deep Neural Networks*)

komplexní vstup se lépe modeluje pomocí **užší a hlubší sítě**



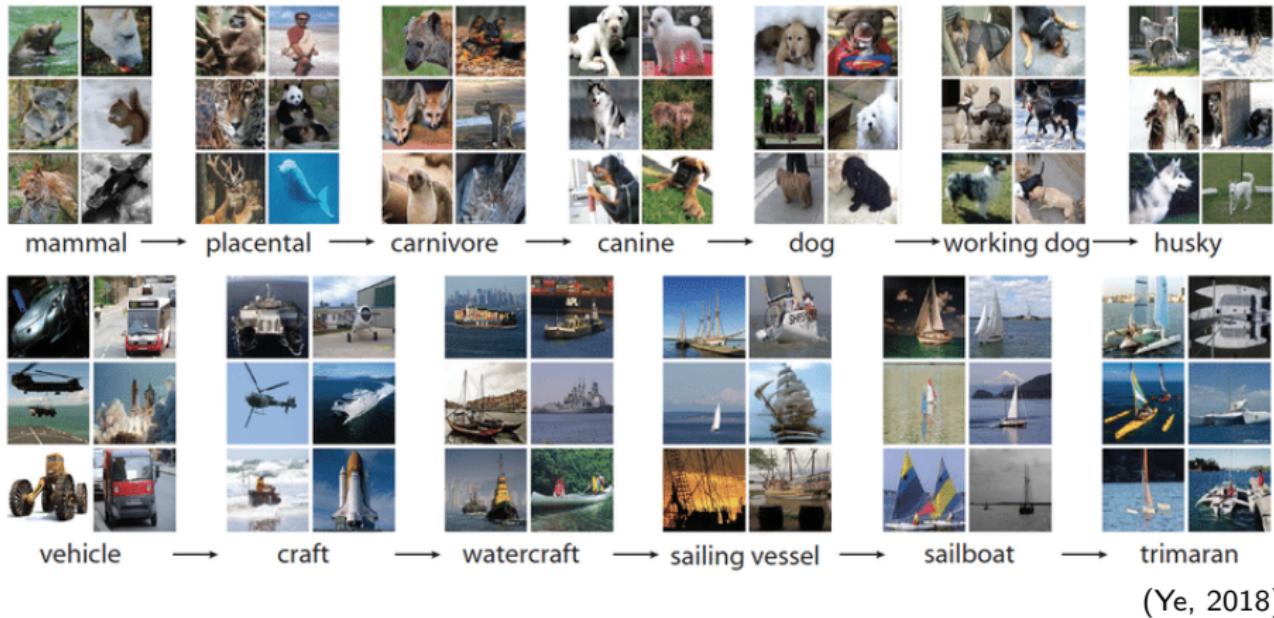
# Aplikace hlubokého učení

## hlavní **aplikační oblasti**

- počítačové vidění
- analýza textu, *analýza signálu, analýza časové řady*
- zpětnovazební učení

# Počítačové vidění

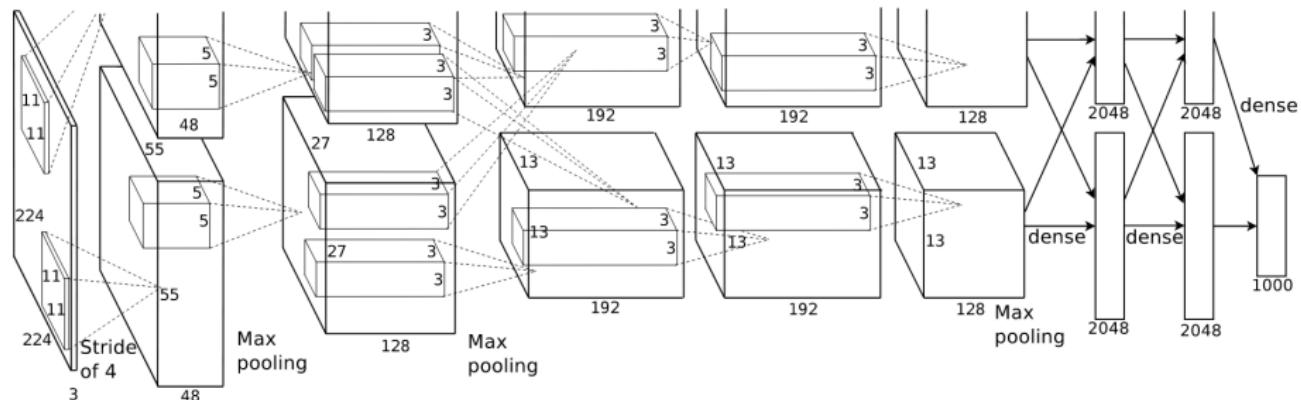
soutěž **ImageNet** – 1.2 mil. obrázků v 1000 kategoriích



# Počítačové vidění

soutěž **ImageNet** – 1.2 mil. obrázků v 1000 kategoriích

2012, síť **AlexNet** (5 konv.vrstev) – chyba **15%**, ostatní  $> 25\%$ , člověk **5%**



(Krizhevsky et al, 2012)

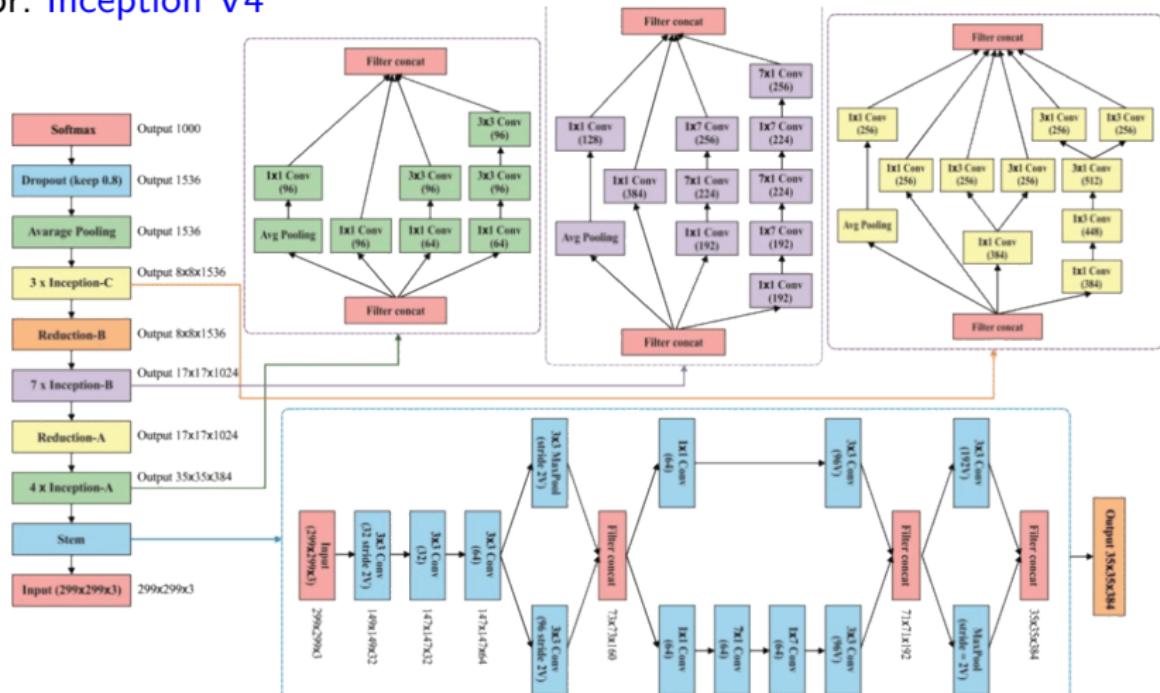
# Počítačové vidění

soutěž **ImageNet** – 1.2 mil. obrázků v 1000 kategoriích

2021 – chyba **1%**, člověk **5%**

např. **Inception V4**

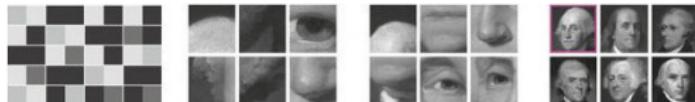
(Shankar et al, 2020)



# Konvoluční sítě

požadavky na **zpracování obrazu**:

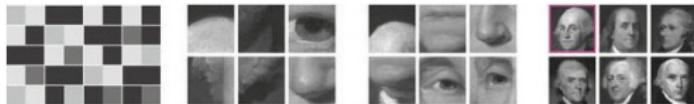
- vztah **sousednosti** bodů
- barva – RGB kanály,  $\times 3$
- (pod)objekty a rysy – **kdekoliv** v obrázku – **prostorová invarianta**



# Konvoluční sítě

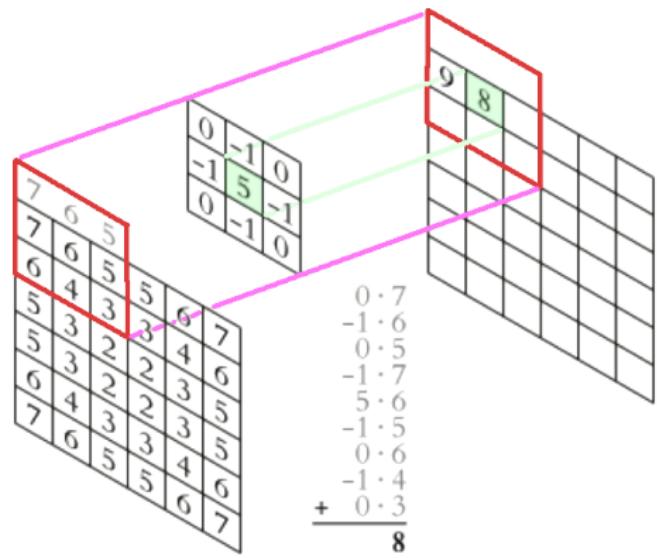
požadavky na **zpracování obrazu**:

- vztah **sousednosti** bodů
- barva – RGB kanály,  $\times 3$
- (pod)objekty a rysy – **kdekoliv** v obrázku – **prostorová invariance**



**Konvoluční sítě (CNN):**

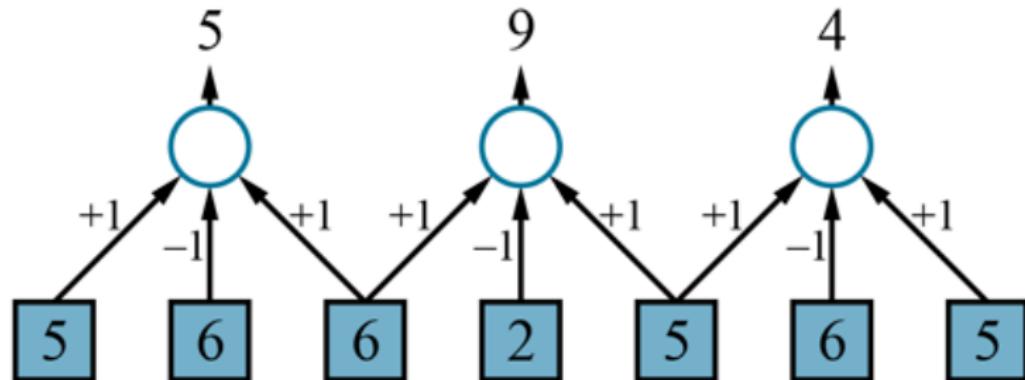
- učí se malou **kernelovou** matici vah (*filtr*) aplikovat na body obrazu, aplikace = **konvoluce**
- kernel matice **sdílí** váhy
- matice se posouvá o **krok** (*stride*)
- výstupem je **mapa rysů** (*feature map*)



(Ganesh, 2019)

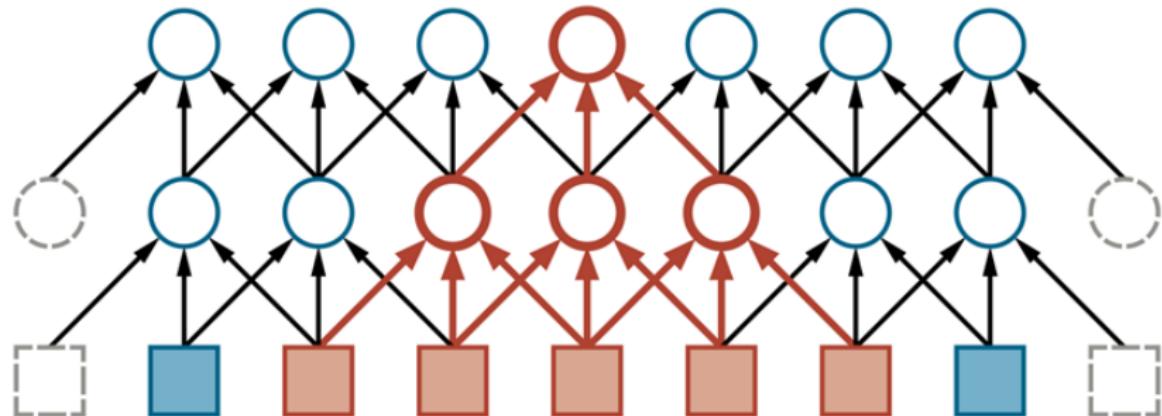
# Parametry konvoluční vrstvy

- rozměry kernelu – 1D ( $\ell$ ), 2D ( $\ell \times r$ ), 3D ...
- počet kernelů k učení  $\times d$
- krok  $s$ ,  $s \geq 2$  redukuje dimenzi



# Vícevrstvé konvoluční sítě

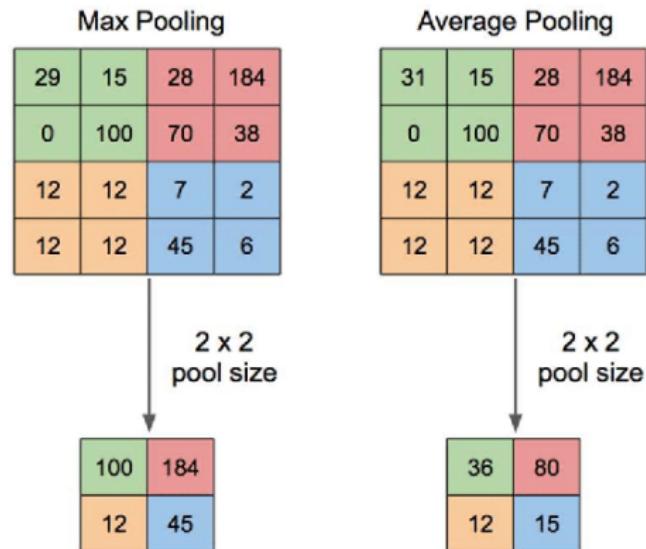
- další konvoluční vrstvy zpracovávají **výstup** předchozích vrstev
- simulují **vyšší úroveň abstrakce**
- mají širší **recepční pole** (*receptive field*)



# Redukce dimenze – sdružování/pooling

## Pooling vrstva (sdružování):

- používá se pro zhuštění informace – redukci dimenze
- snižuje nároky v dalších vrstvách
- podporuje generalizaci
- varianty:
  - **max-pooling** – vybírá maximum vstupu, značí výskyt rysu kdekoliv v recepčním poli
  - **average-pooling** – klasická redukce



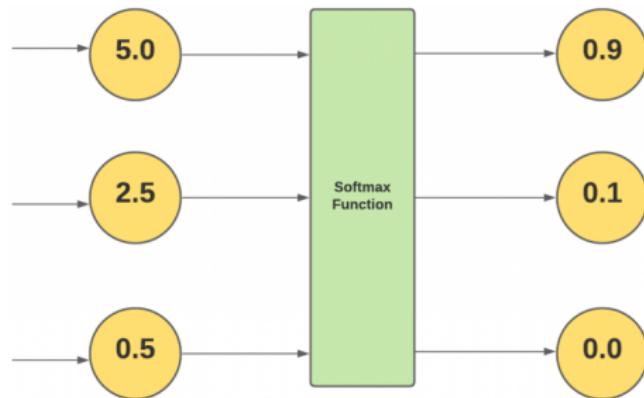
(Yan et al., 2019)

# Klasifikace výstupu – softmax

- klasifikace do  $c$  kategorií – **softmax** vrstva

$$\text{softmax}(\vec{in}) = \left\langle \frac{e^{in_k}}{\sum_{j=1}^c e^{in_j}} \right\rangle_k$$

- reprezentuje pravděpodobnosti (součet je 1), akcentuje rozdíly
- někdy doplněná o 1–2 předcházející plně propojené vrstvy
- *logistická regrese (sigmoid)* – speciální případ pro 2 kategorie (pozitivní a negativní)



(Kumar, 2020)

# Obsah

## 1 Hluboké učení

- Motivace

## 2 Aplikace hlubokého učení

- Počítačové vidění
- **Analýza textu**
- Zpětnovazební učení

## 3 Techniky hlubokého učení

- Hledání architektury
- Soupeřící učení – GANs
- Schopnosti hlubokých sítí

# Analýza textu

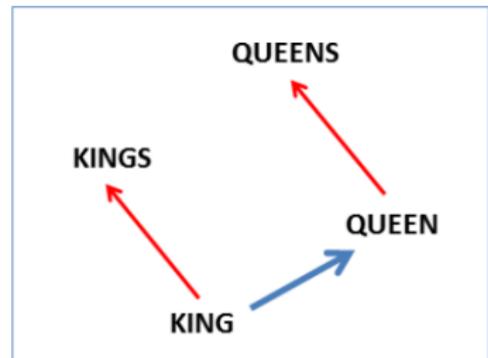
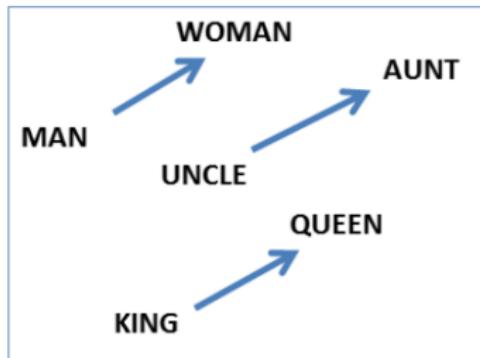
neuronová síť pracuje **pouze s čísly** – jak zadat text?

# Analýza textu

neuronová síť pracuje **pouze s čísly** – jak zadat text?

slova jako **slovní vektory** (*word embeddings*):

- stanovení **pevné dimenze**
- **předpočítání/předtrénování** na velmi velkých neanotovaných textech  
⇒ **neurální jazykové modely**
- zachycení **sémantiky** – podobná slova síť zpracuje podobně
- univerzálnější – **vektory částí slov** (*subword/character embeddings*)
- jen výměnou modelu můžeme **zpřesnit výsledky**



(Mikolov, 2013)

# Predikce textu

vstup: začátek textu jako řetězec slov  $W = w_1 w_2 w_3 \dots w_{i-1}$

výstup: pravděpodobnostní distribuce dalšího slova  $P(w_i | w_1 w_2 \dots w_{i-1})$

# Predikce textu

vstup: začátek textu jako řetězec slov  $W = w_1 w_2 w_3 \dots w_{i-1}$

výstup: pravděpodobnostní distribuce dalšího slova  $P(w_i | w_1 w_2 \dots w_{i-1})$

základní **neurální jazykový model s pevným kontextem** (*fixed-window*)

výstupní distribuce

$$\vec{y} = \text{softmax}(Uh + b_2) \in \mathbb{R}^{|V|}$$

skrytá vrstva

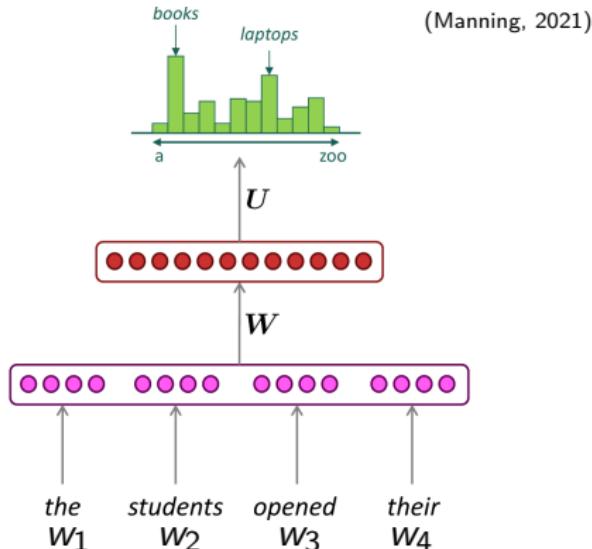
$$h = f(We + b_1)$$

řetězené vektory slov

$$e = [e_1; e_2; e_3; e_4]$$

slova na vstupu

$$w_1 w_2 w_3 w_4$$



# Predikce textu

vstup: začátek textu jako řetězec slov  $W = w_1 w_2 w_3 \dots w_{i-1}$

výstup: pravděpodobnostní distribuce dalšího slova  $P(w_i | w_1 w_2 \dots w_{i-1})$

základní **neurální jazykový model s pevným kontextem** (*fixed-window*)

výstupní distribuce

$$\vec{y} = \text{softmax}(Uh + b_2) \in \mathbb{R}^{|V|}$$

skrytá vrstva

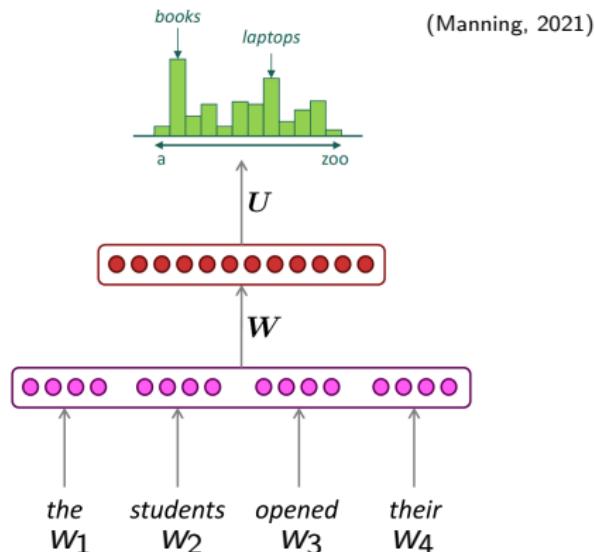
$$h = f(We + b_1)$$

řetězené vektory slov

$$e = [e_1; e_2; e_3; e_4]$$

slova na vstupu

$$w_1 w_2 w_3 w_4$$



**nevýhoda** – pevná velikost vstupu

# Rekurentní jazykový model

skryté stavy

$$h^{(t)} = \sigma(W_h h^{(t)} + W_e e^{(t)} + b_1)$$

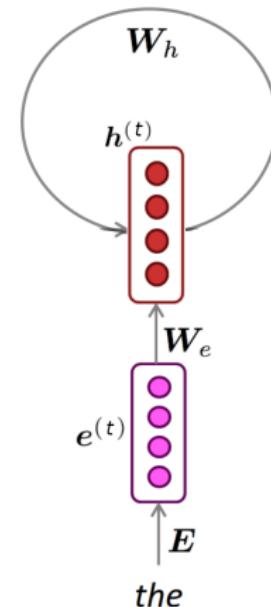
váhy  $W_h$  a  $W_e$  se aplikují opakováně

jednotlivé vektory slov

$$e = [e_1; e_2; e_3; e_4]$$

slova na vstupu

$$w_1 w_2 w_3 w_4$$



# Rekurentní jazykový model

výstupní distribuce

$$\vec{y}^{(t)} = \text{softmax}(Uh^{(t)} + b_2) \in \mathbb{R}^{|V|}$$

skryté stavy

$$h^{(t)} = \sigma(W_h h^{(t)} + W_e e^{(t)} + b_1)$$

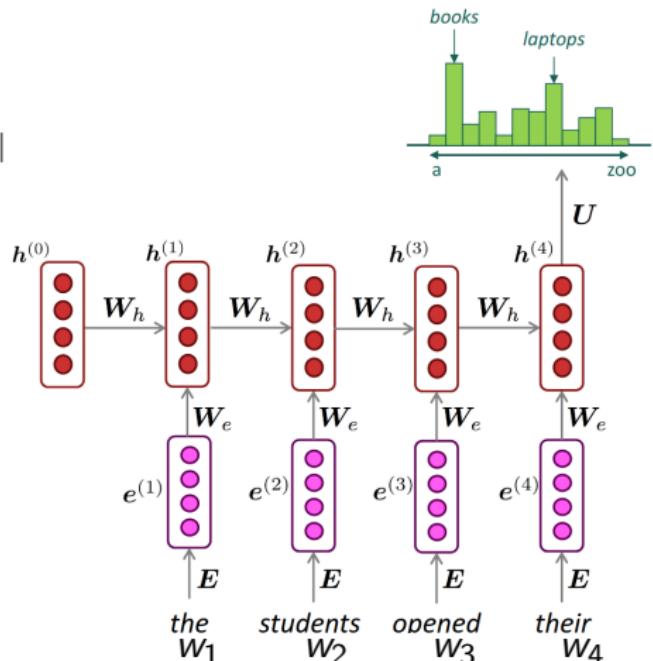
váhy  $W_h$  a  $W_e$  se aplikují opakováně

jednotlivé vektory slov

$$e = [e_1; e_2; e_3; e_4]$$

slova na vstupu

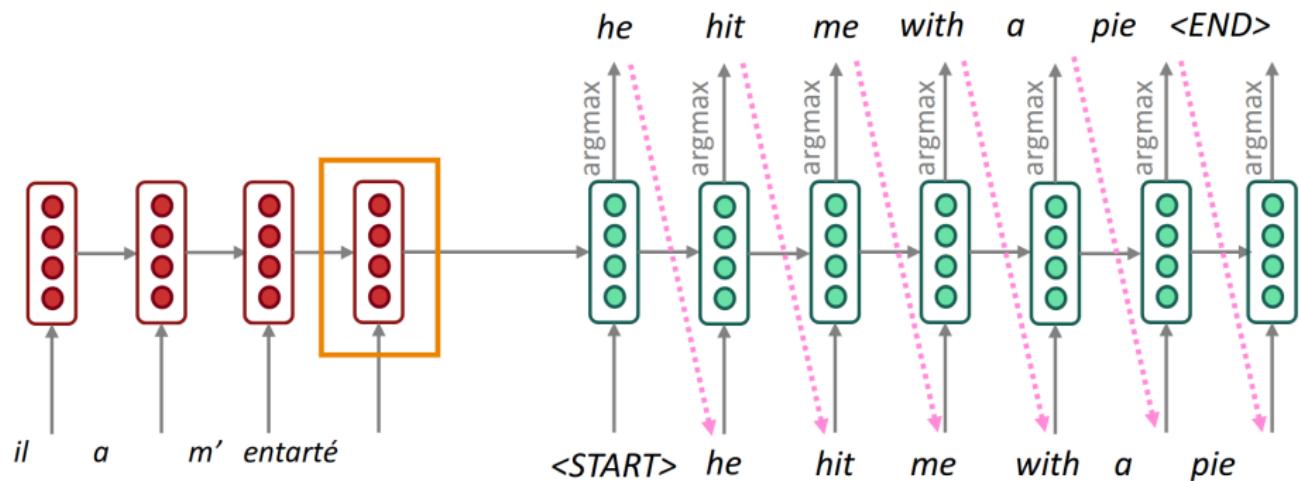
$$w_1 w_2 w_3 w_4$$



# Využití rekurentních sítí – seq2seq

častá varianta – model **sequence-to-sequence (seq2seq)**

dvě rekurentní sítě – **enkodér** a **dekodér**



# Analýza textu

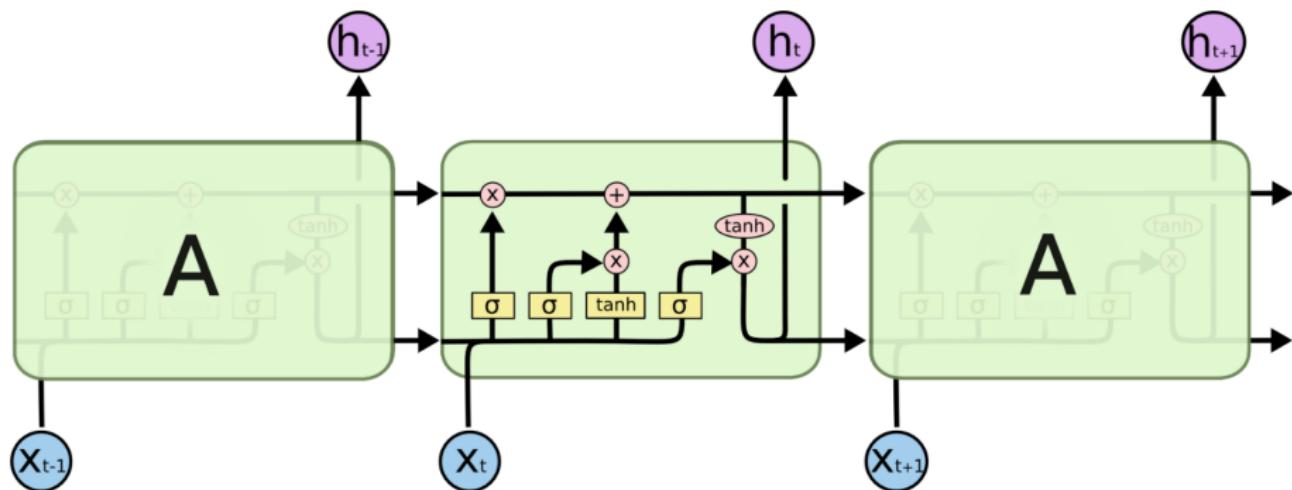
problém trénování velkých RNN – **mizející gradient** (násobení malých čísel → 0)

# Analýza textu

problém trénování velkých RNN – mizející gradient (násobení malých čísel → 0)

řešení – **architektura Long Short-Term Memory, LSTM:**

- buňka (cell)  $c_t$  – pomocná paměť
- 3 brány: vstupní, výstupní a zapomínací (*forget*) – regulace info do a z buňky

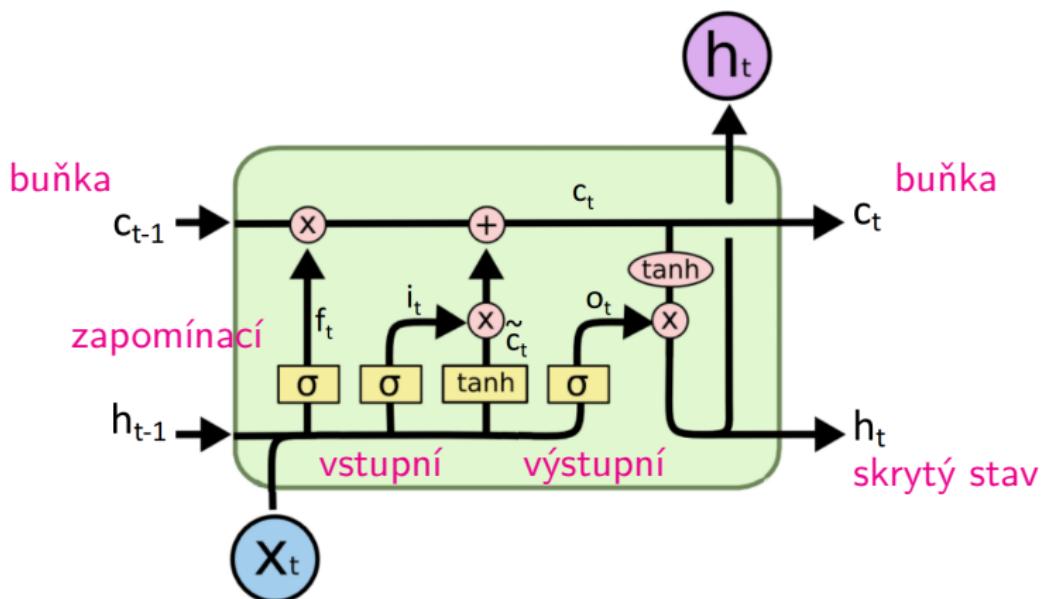


# Analýza textu

problém trénování velkých RNN – mizející gradient (násobení malých čísel → 0)

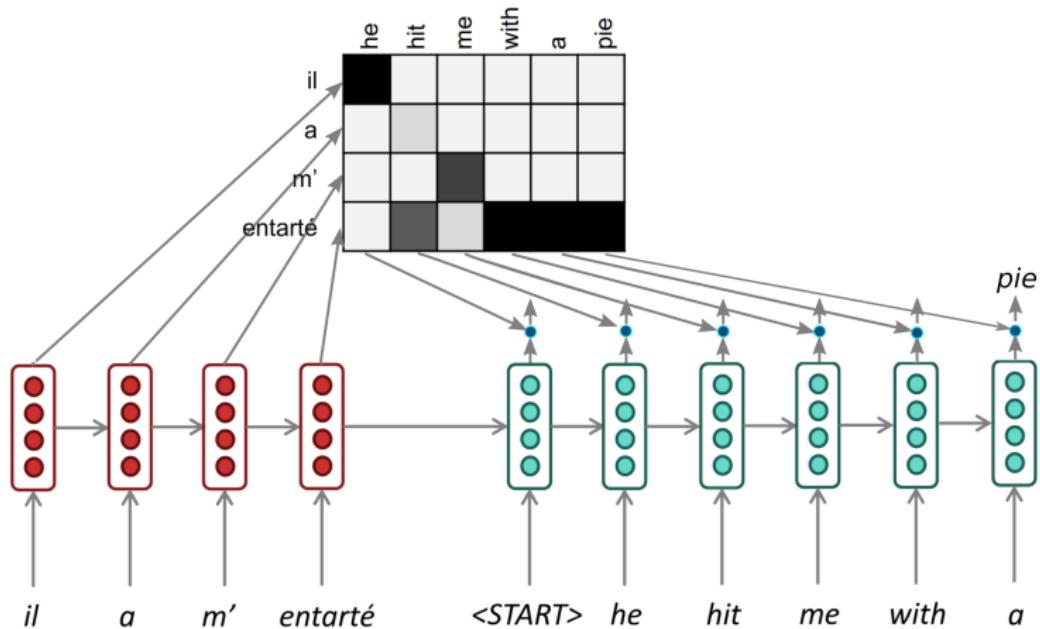
řešení – **architektura Long Short-Term Memory, LSTM:**

- buňka (cell)  $c_t$  – pomocná paměť
- 3 brány: vstupní, výstupní a zapomínací (*forget*) – regulace info do a z buňky



# Mechanismus attention

u rekurentních sítí – celá věta reprezentována jako jeden vektor  
 mechanismus **attention** ("pozornost") – detailní provázání informací



# Architektura Transformer

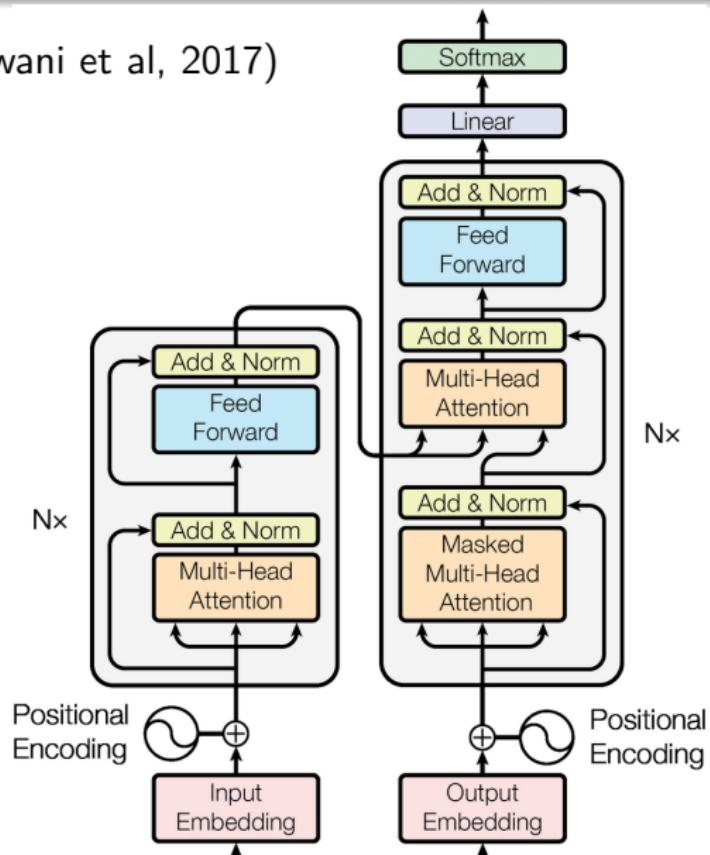
“Attention is All You Need” (Vaswani et al, 2017)

architektura **transformer**:

- vektory pozice
- self-attention
- více **hlav** (*multi-head attention*)
- reziduální spojení, normalizace a škálování

aktuálně **nejlepší** výsledky v mnoha úlohách zpracování **textu**

[beta.openai.com/examples](https://beta.openai.com/examples)



# Obsah

## 1 Hluboké učení

- Motivace

## 2 Aplikace hlubokého učení

- Počítačové vidění
- Analýza textu
- Zpětnovazební učení

## 3 Techniky hlubokého učení

- Hledání architektury
- Soupeřící učení – GANs
- Schopnosti hlubokých sítí

# Zpětnovazební učení

## Hluboké zpětnovazební učení (*deep reinforcement learning*, DRL)

- rozhodování agenta – ze sekvence odměn
- cíl – zvyšovat budoucí odměny
- možná řešení – učení ohodnocovací funkce (AlphaGo), funkce akce Q (Q-learning), nebo politiky
- DRL zatím aplikačně obtížnější než ostatní techniky hlubokého učení

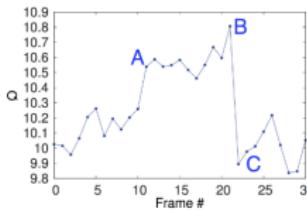
# Zpětnovazební učení

## Hluboké zpětnovazební učení (*deep reinforcement learning*, DRL)

- rozhodování agenta – ze sekvence odměn
- cíl – zvyšovat budoucí odměny
- možná řešení – učení ohodnocovací funkce (AlphaGo), funkce akce Q (Q-learning), nebo politiky
- DRL zatím aplikačně obtížnější než ostatní techniky hlubokého učení

### Deep Q-Networks – Atari hry (2013):

- učení funkce Q přímo z obrázků, využívá konvoluční vrstvy
- odměna – herní skóre
- pozdější varianta lepší než člověk v 57 Atari hrách

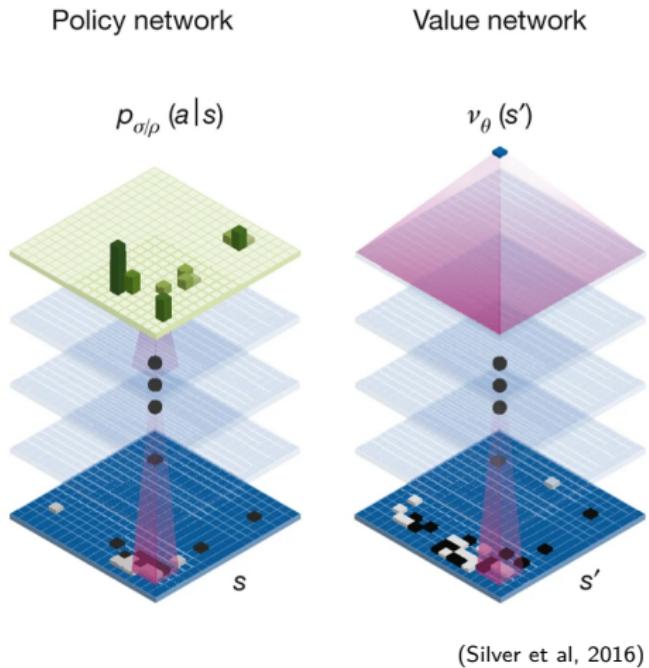


(Mnih et al, 2013)

# AlphaGo

## AlphaGo (2016):

- učení funkce politiky  $p$  a ohodnocovací funkce  $v$
- Monte Carlo Tree Search
- politika  $p$  dává distribuci pravděpodobností možných tahů
- ohodnocovací funkce  $v$  predikuje zisk navrhovaných nových konfigurací  $s'$
- každá síť má 13 konvolučních vrstev

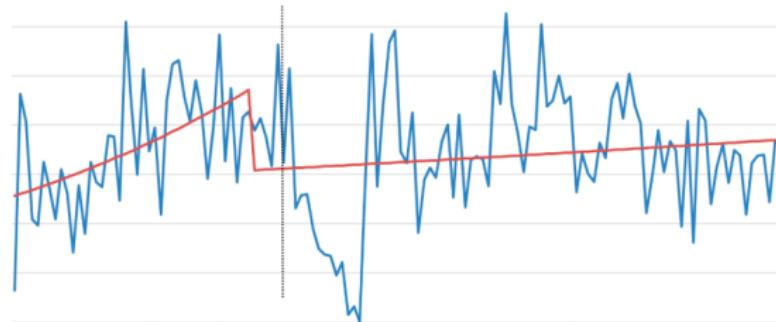


(Silver et al, 2016)

# Hledání architektury

## Hledání správné architektury

- převážně experimentálně
- Auto ML (*automated machine learning*)
- základní prvky:
  - konvoluční vrstvy – pro hledání vzorů (*patterns*) kdekoliv ve vstupu (1D – text, 2D – obráz, ...)  
*a b c d a a d c b c d c c a b d*
  - rekurentní vrstvy – hledání závislostí mezi prvky vstupu (text, signál, časová řada, ...)

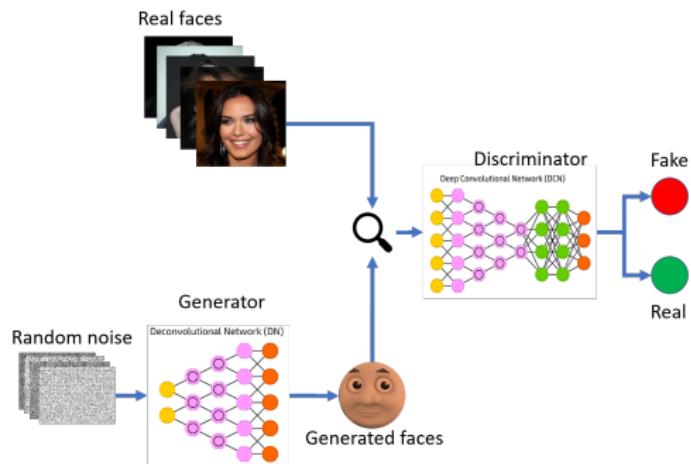


(Adulapuram, 2020)

# Soupeřící učení – GANs

## Generative Adversarial Network (GAN)

- generující soupeřící síť
- 2 části – generátor a diskriminátor trénované současně bez dohledu
- **generátor** – vytváří simulované vstupy podle zadání, snaží se zmást diskriminátor
- **diskriminátor** – učí se rozpoznávat skutečné vstupy od podvržených



(Missinato, 2020)

# Soupeřící učení – GANs

Aplikace GAN:

- **obraz:**

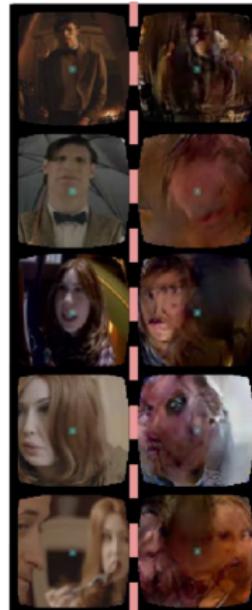
- [StyleGAN](#) – od Nvidia, generované snímky lidí podle atributů (držení těla, brýle, pohlaví, vlasy, ...)
- [superrezoluce](#) – generovaný obraz ve větším rozlišení
- [Brain2Pix](#) – generování obrazu toho, co vidí mozek, podle mozkové aktivity
- [Ganilla](#) – generování uměleckého obrazu podle fotky
- [DeepFake](#) – přenesení vlastností z jednoho obrazu/videa do druhého

- **text:** [SliDo](#)

- [DALL-E](#) (OpenAI) – vytváří obrázky podle textového zadání
- [SentiGAN](#) – generuje text se zadáným sentimentem

- **zvuk:**

- [CereVoice Me](#) – vytvoří hlas podle nahrávek
- [DeepComposer](#) – vytváří orchestrální skladbu podle jednoduché melodie



# Schopnosti hlubokých sítí

## co hluboké sítě umí výborně

- hledat **vzory** a **vztahy** v komplexních datech
- **generovat** nová komplexní data podle podmínek
- **detektovat**, že komplexní data byla vygenerovaná

# Schopnosti hlubokých sítí

## co hluboké sítě umí výborně

- hledat **vzory** a **vztahy** v komplexních datech
- **generovat** nová komplexní data podle podmínek
- **detektovat**, že komplexní data byla vygenerovaná

## co hluboké sítě moc neumí

- **kvantifikovat**
- pracovat s **hierarchickými** strukturami (taxonomie)
- pracovat s **pravidly**

# Schopnosti hlubokých sítí

## co hluboké sítě umí výborně

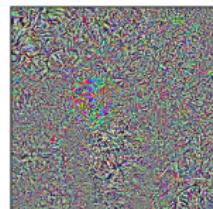
- hledat **vzory** a **vztahy** v komplexních datech
- generovat nová komplexní data podle podmínek
- detektovat, že komplexní data byla vygenerovaná



97 % papoušek

## co hluboké sítě moc neumí

- kvantifikovat
- pracovat s **hierarchickými** strukturami (taxonomie)
- pracovat s **pravidly**



speciální šum

## kdy je vhodné hluboké sítě použít

máme

- velká data
- složité vzory

nevadí

- chybí zdůvodnění
- možná zaujatost
- “nelogické” chyby



99 % knihovna