Hluboké učení

Aleš Horák

E-mail: 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

Proč tedy pracovat s **hlubšími architekturami**?

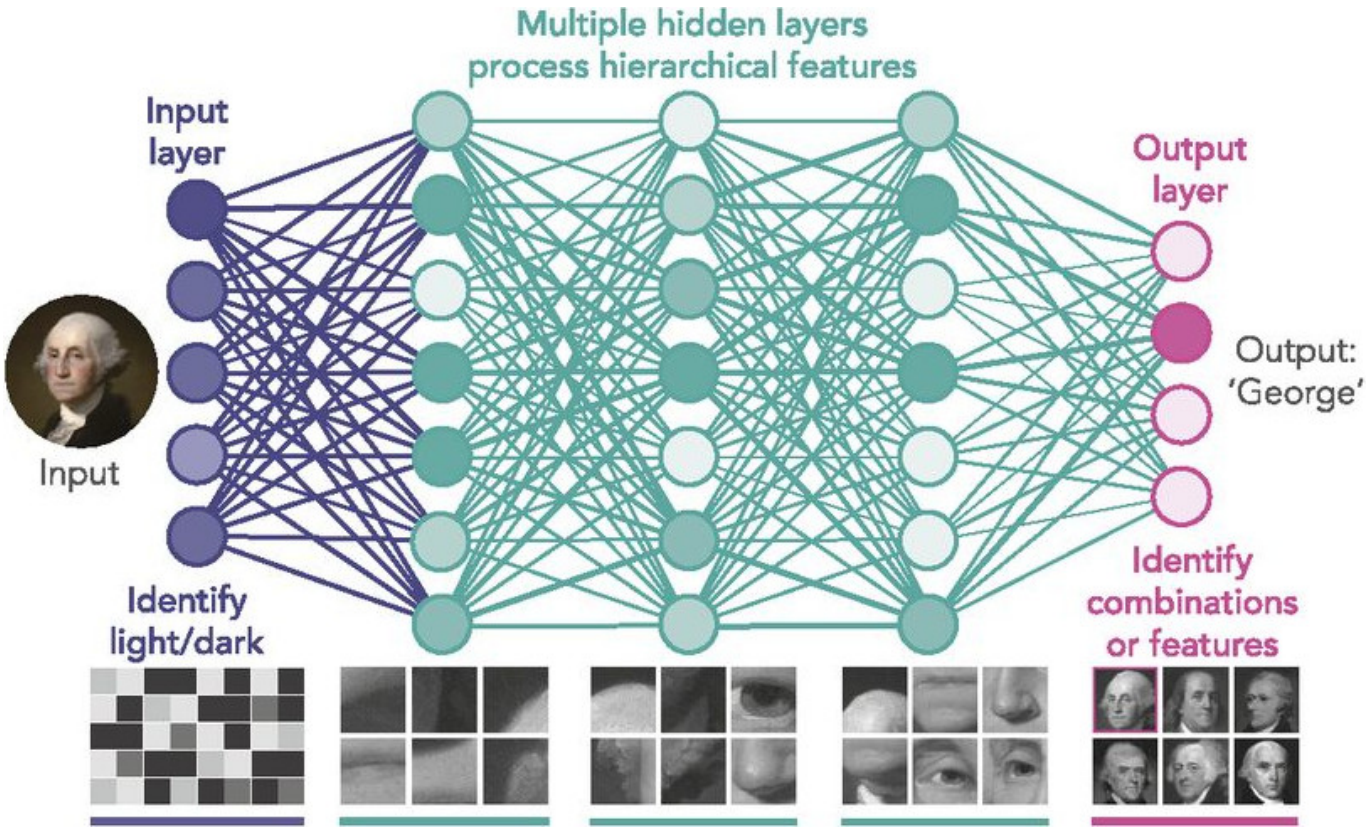

Motivace

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

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

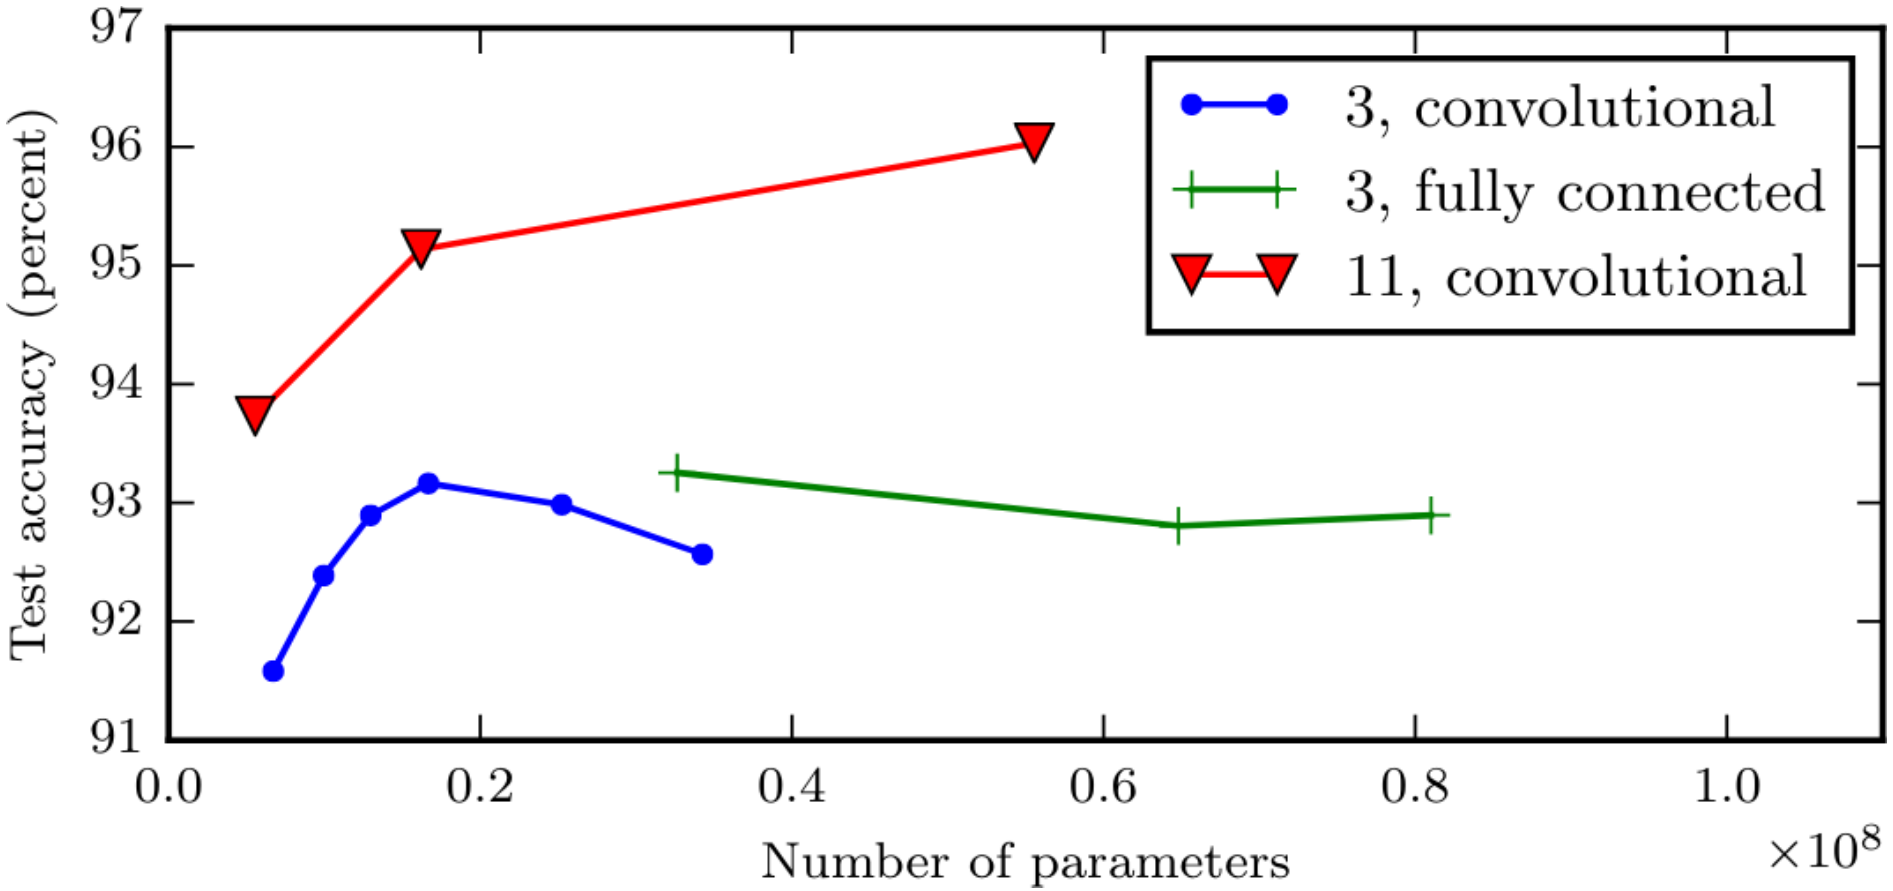

(příklad Goodfellow, 2017)

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

2021 – chyba **1%**, člověk 5%

(Shankar et al, 2020)

např. Inception V4

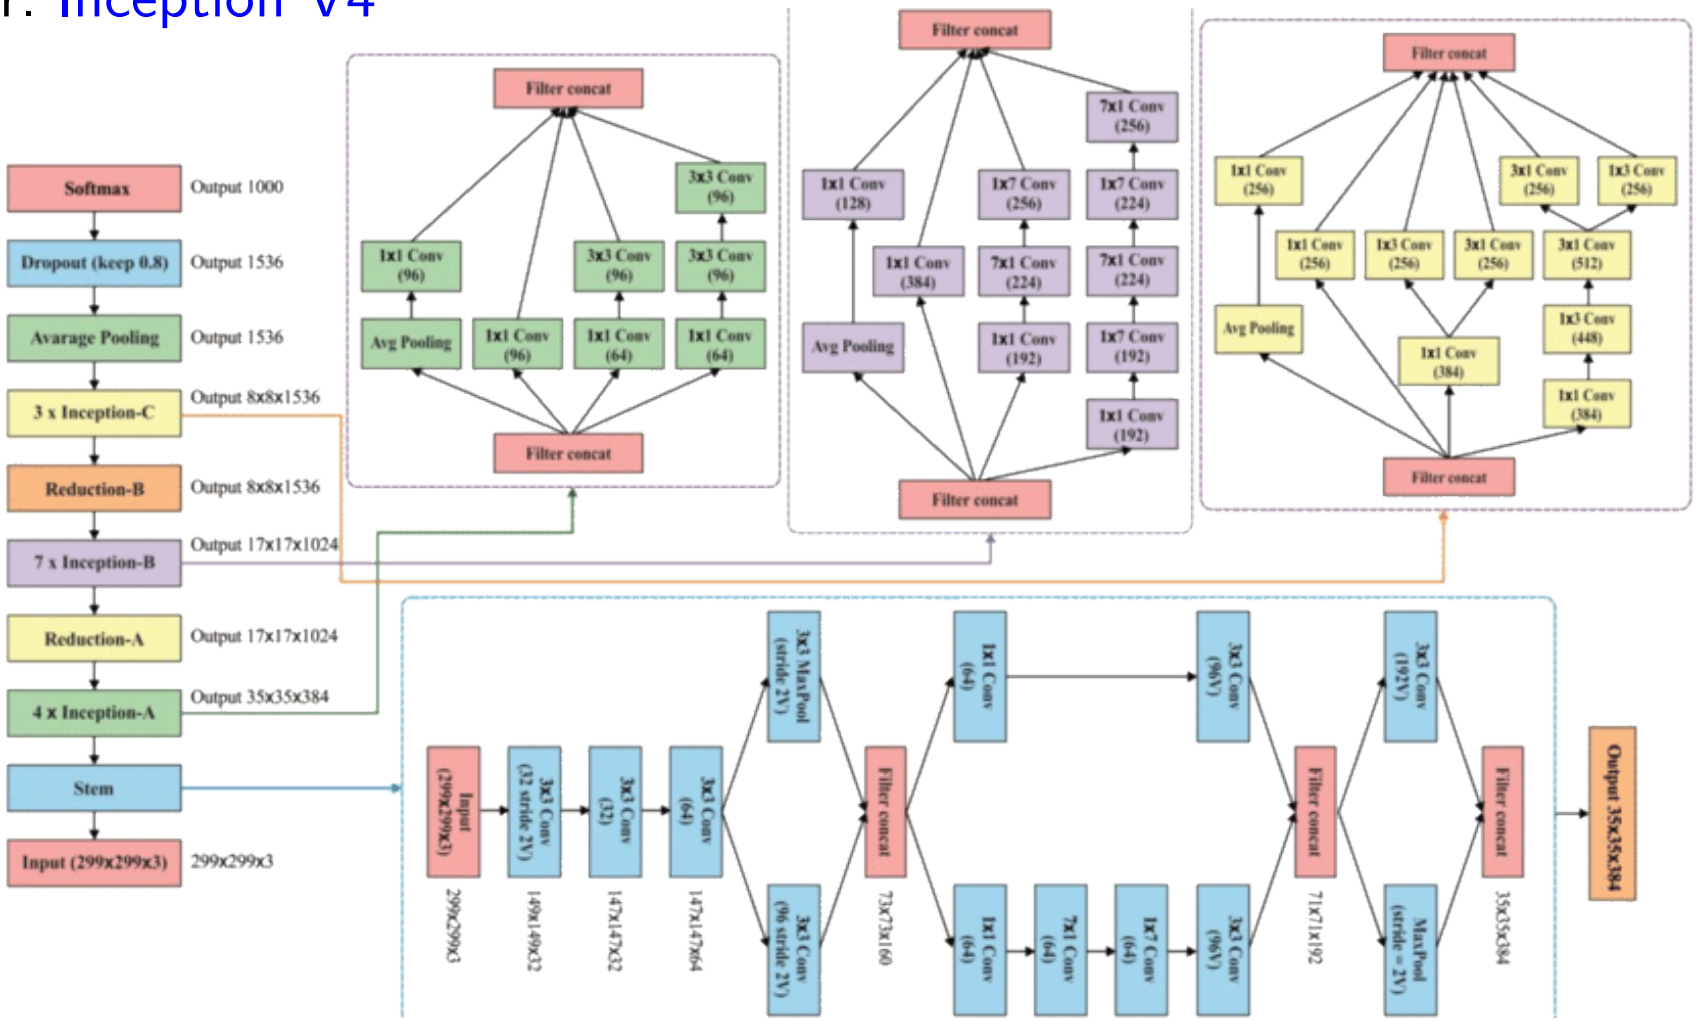

Konvoluční sítě

požadavky na **zpracování obrazu**:

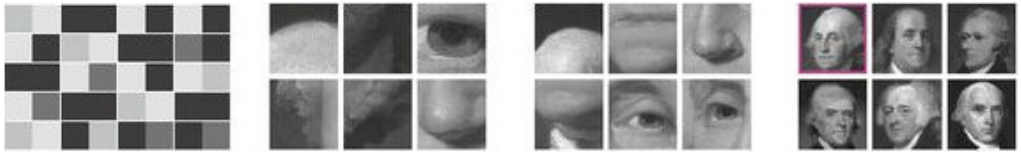

- vztah sousednosti bodů
- barva – RGB kanály, $\times 3$
- (pod)objekty a rysy – kdekoliv v obrázku – prostorová invariance

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*)

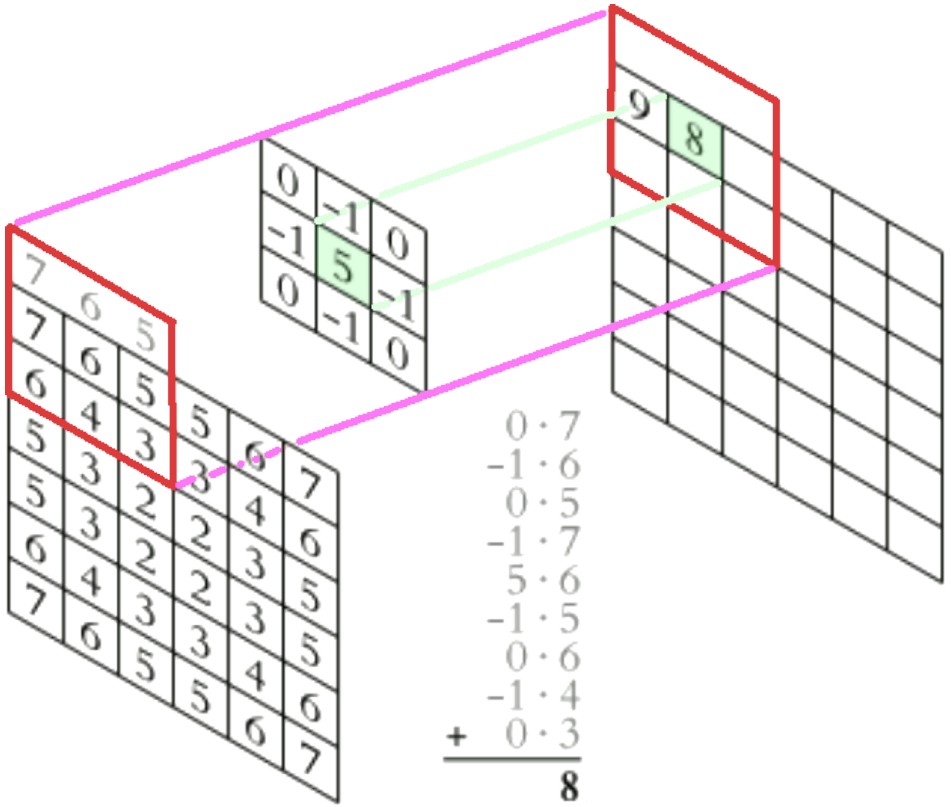

(Ganesh, 2019)

Parametry konvoluční vrstvy

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

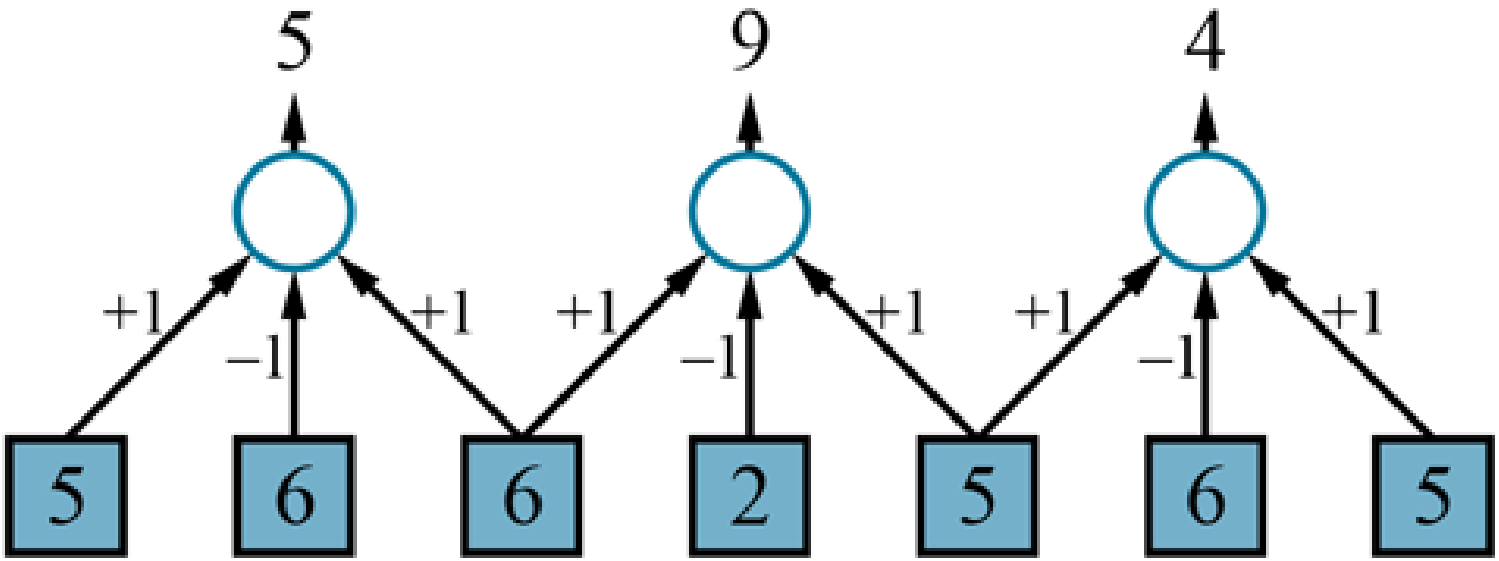

Vícevrstvé konvoluční sítě

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

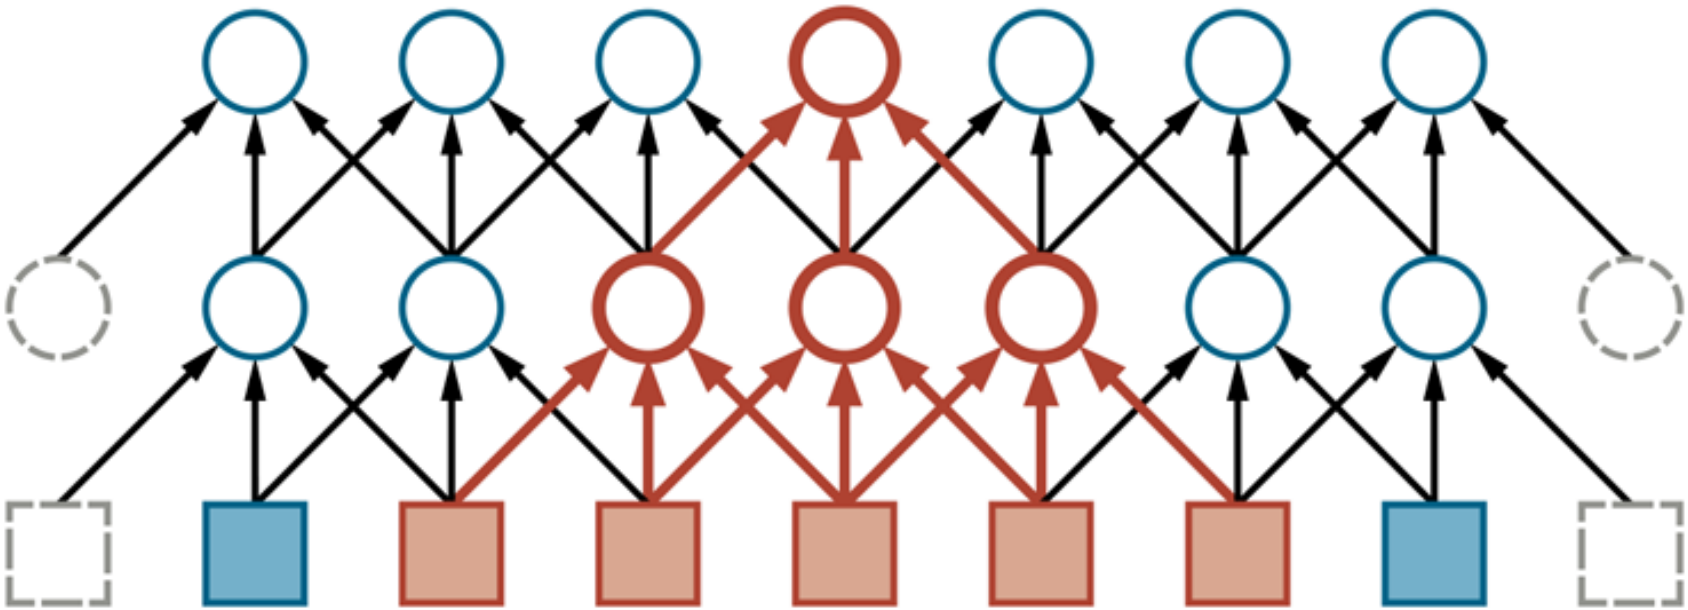

Redukce dimenze – sdružování/pooling

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

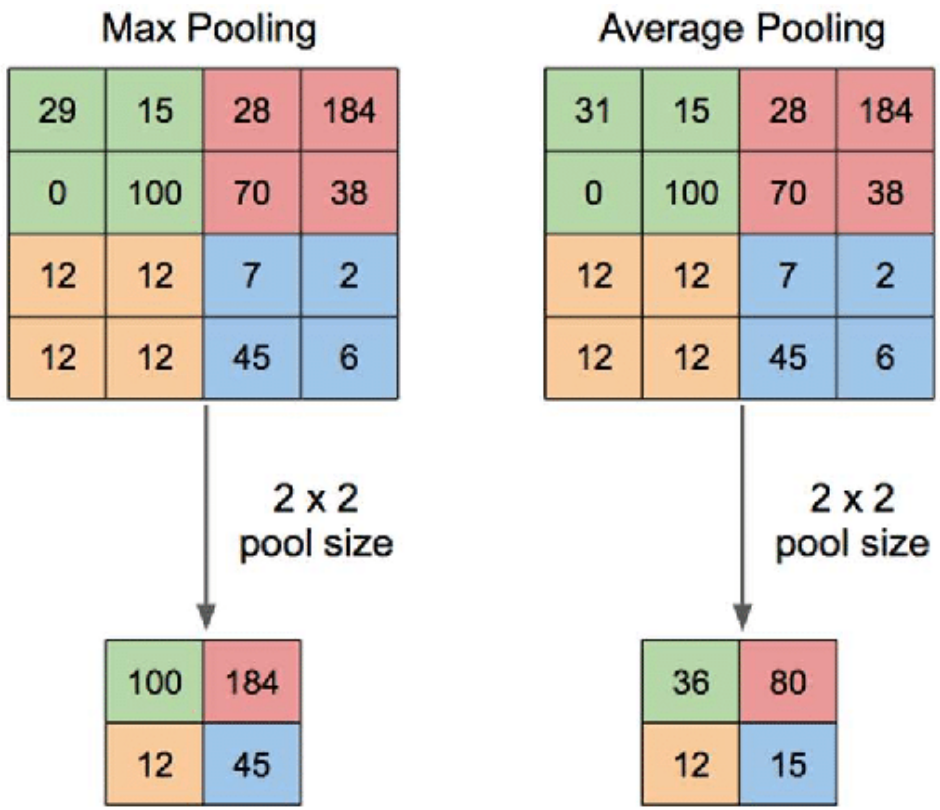

(Yani et al, 2019)

Klasifikace výstupu – softmax

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

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

- 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)

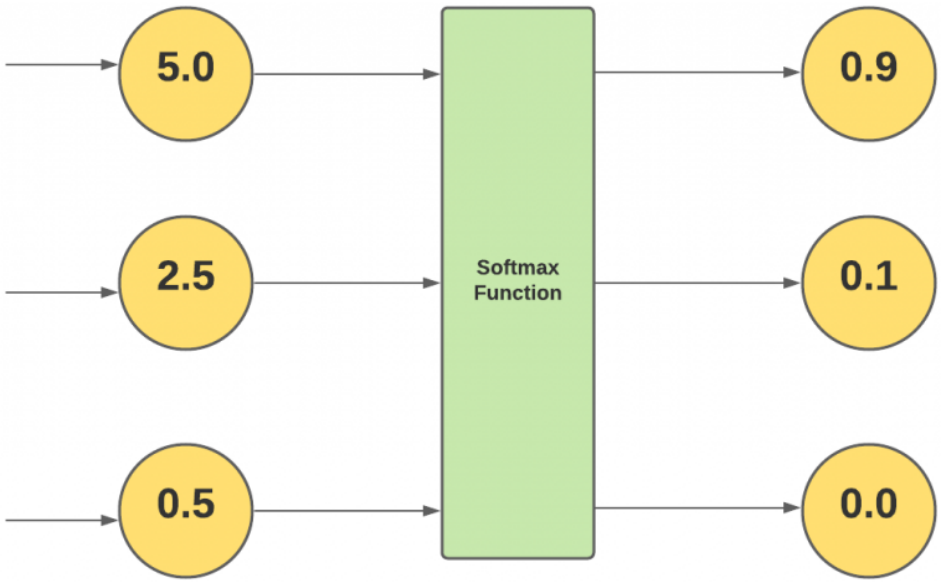

(Kumar, 2020)

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
  $\Rightarrow$ **neurální jazykové modely**
- zachycení sémantiky – podobná slova síť zpracuje podobně
- univerzálnější – vektory částí slov (*subword/character embeddings*)
- jen výměnou modelu můžeme zpřesnit výsledky

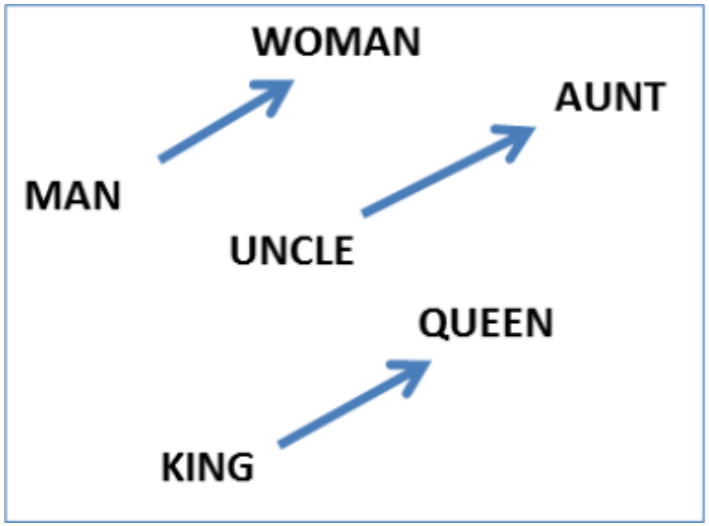

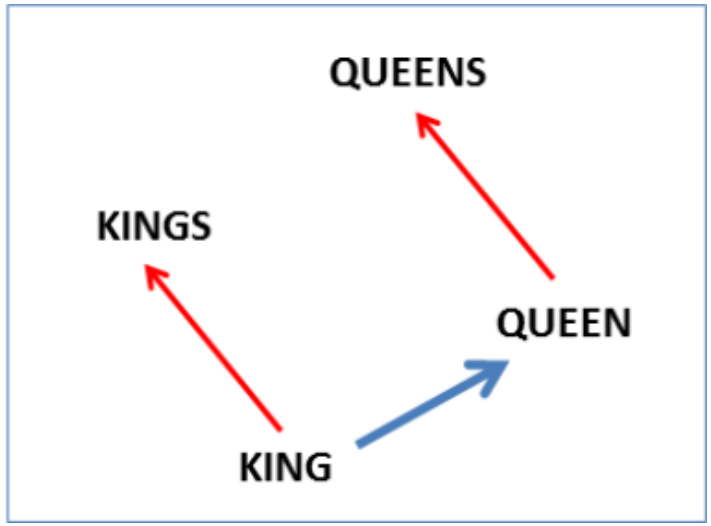

(Mikolov, 2013)

Predikce textu

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

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

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

výstupní distribuce

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

skrytá vrstva

$h = f(We + b_1)$

řetězené vektory slov

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

slova na vstupu

$w_1 w_2 w_3 w_4$

(Manning, 2021)

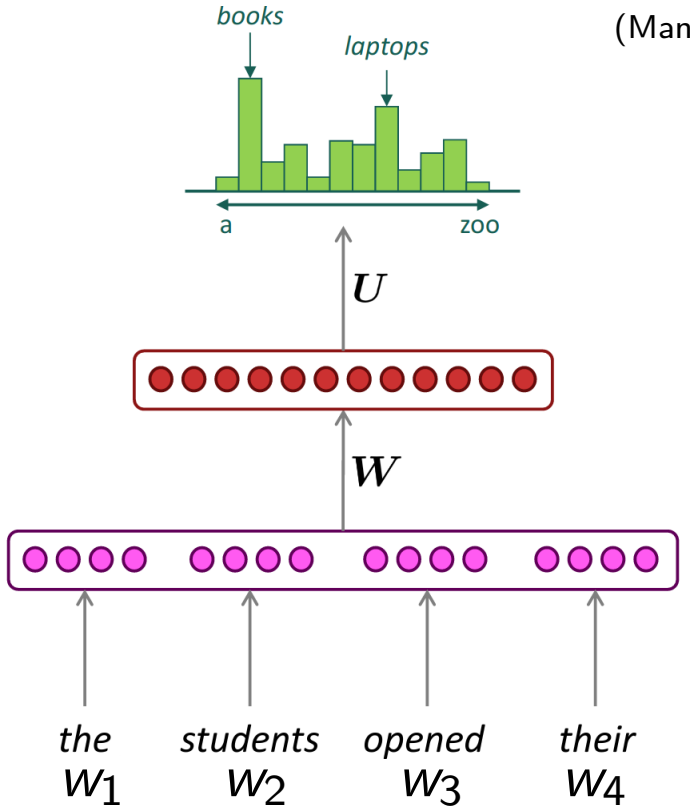

nevýhoda – pevná velikost vstupu

Rekurentní jazykový model

výstupní distribuce

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

skryté stavy

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

váhy W_h a W_e se aplikují opakovaně

jednotlivé vektory slov

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

slova na vstupu

$w_1 w_2 w_3 w_4$

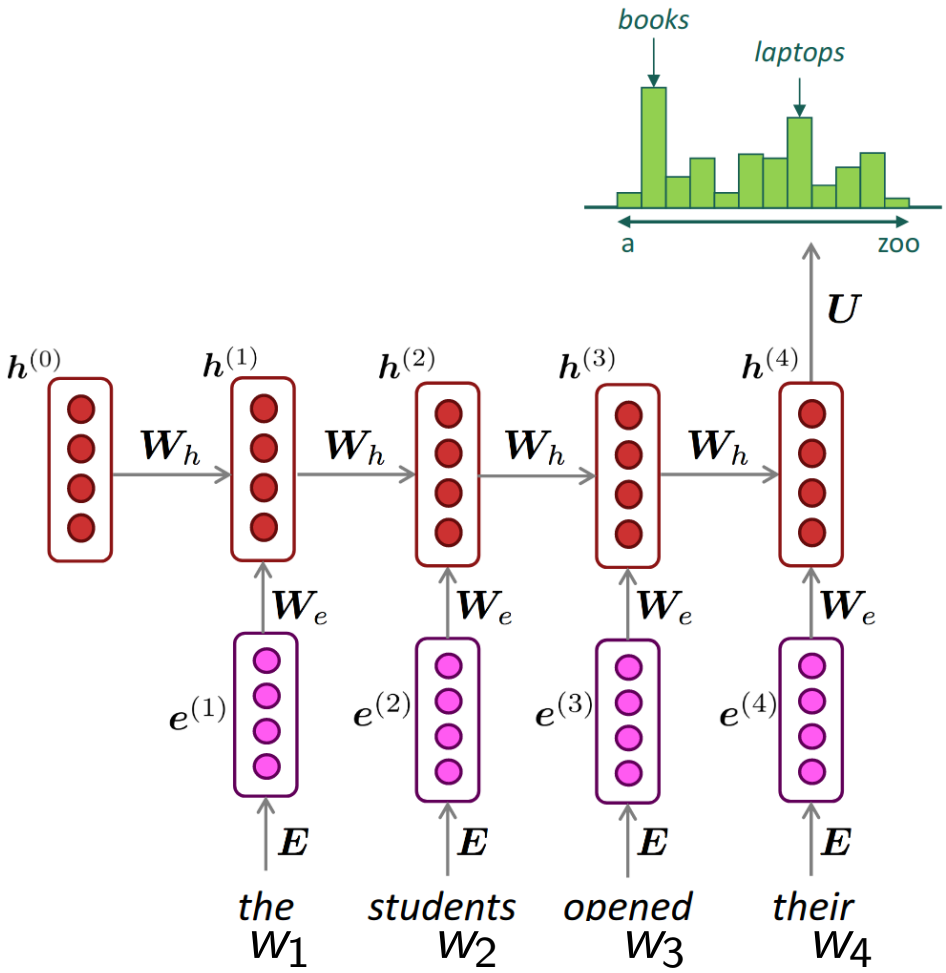

Využití rekurentních sítí – seq2seq

častá varianta – model **sequence-to-sequence** (**seq2seq**)
dvě rekurentní sítě – enkodér a dekodér

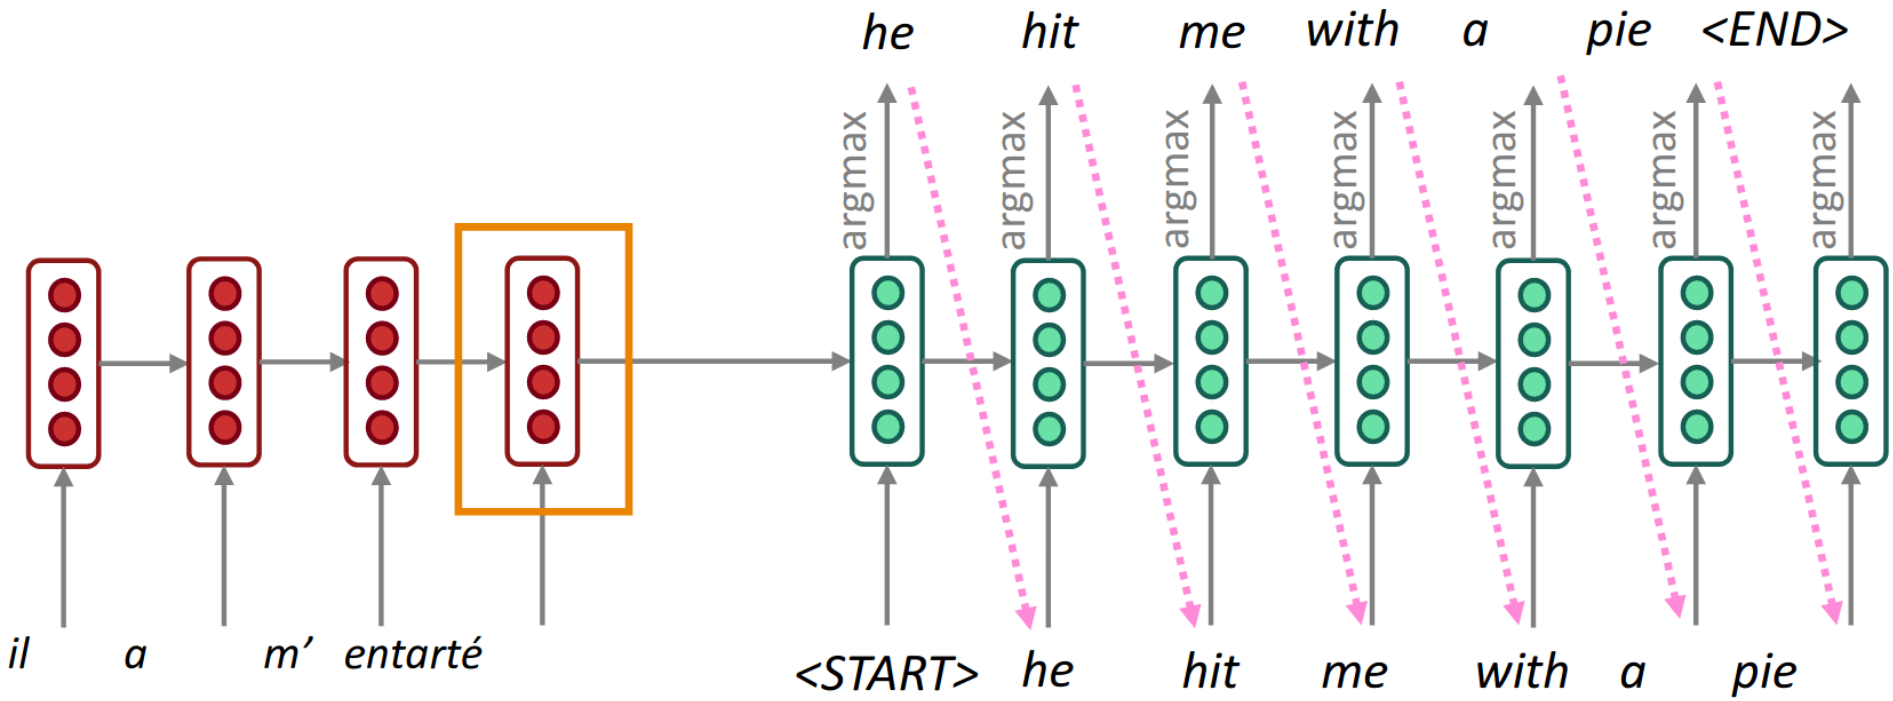

Analýza textu

problém trénování velkých RNN – mizející gradient (násobení malých čísel $\to 0$)
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

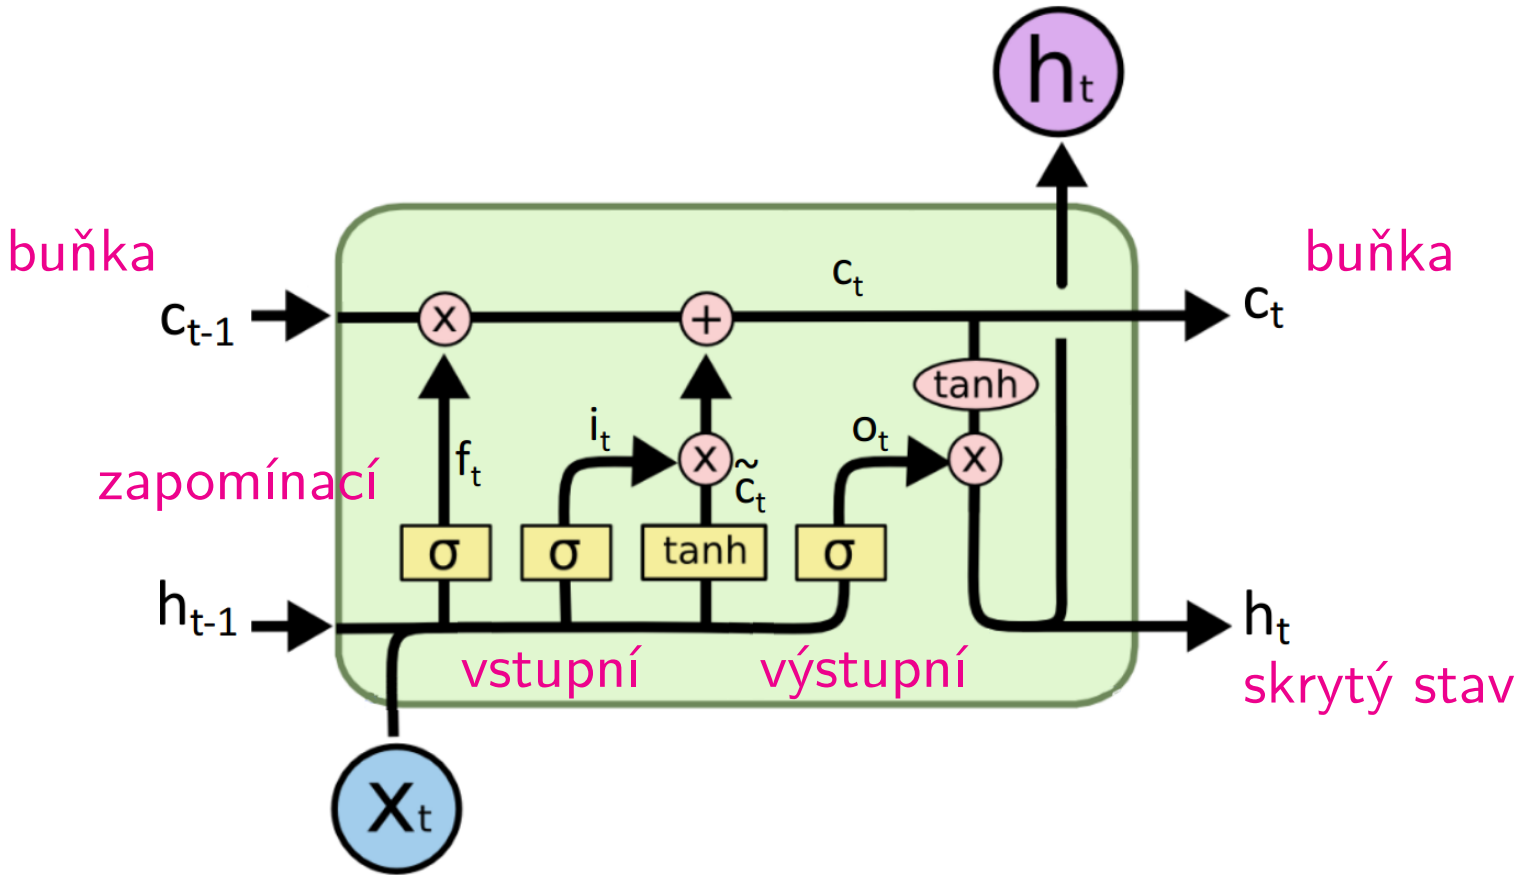

Mechanizmus attention

u rekurentních sítí – celá věta reprezentována jako jeden vektor
mechanizmus **attention** (“pozornost”) – detailní provázání informací

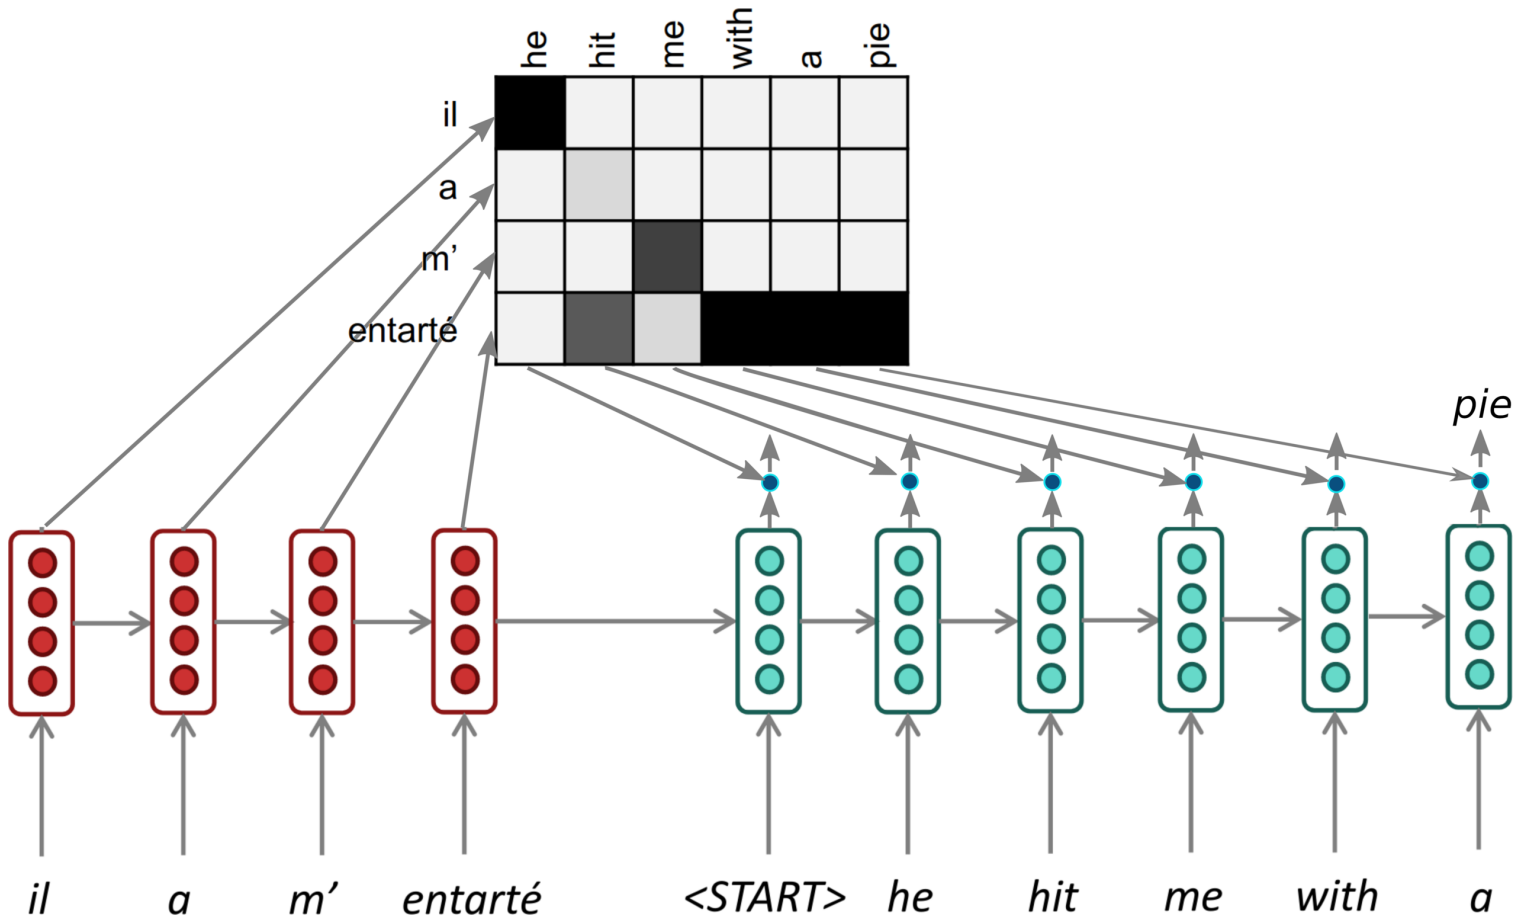

Architektura Transformer

"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`

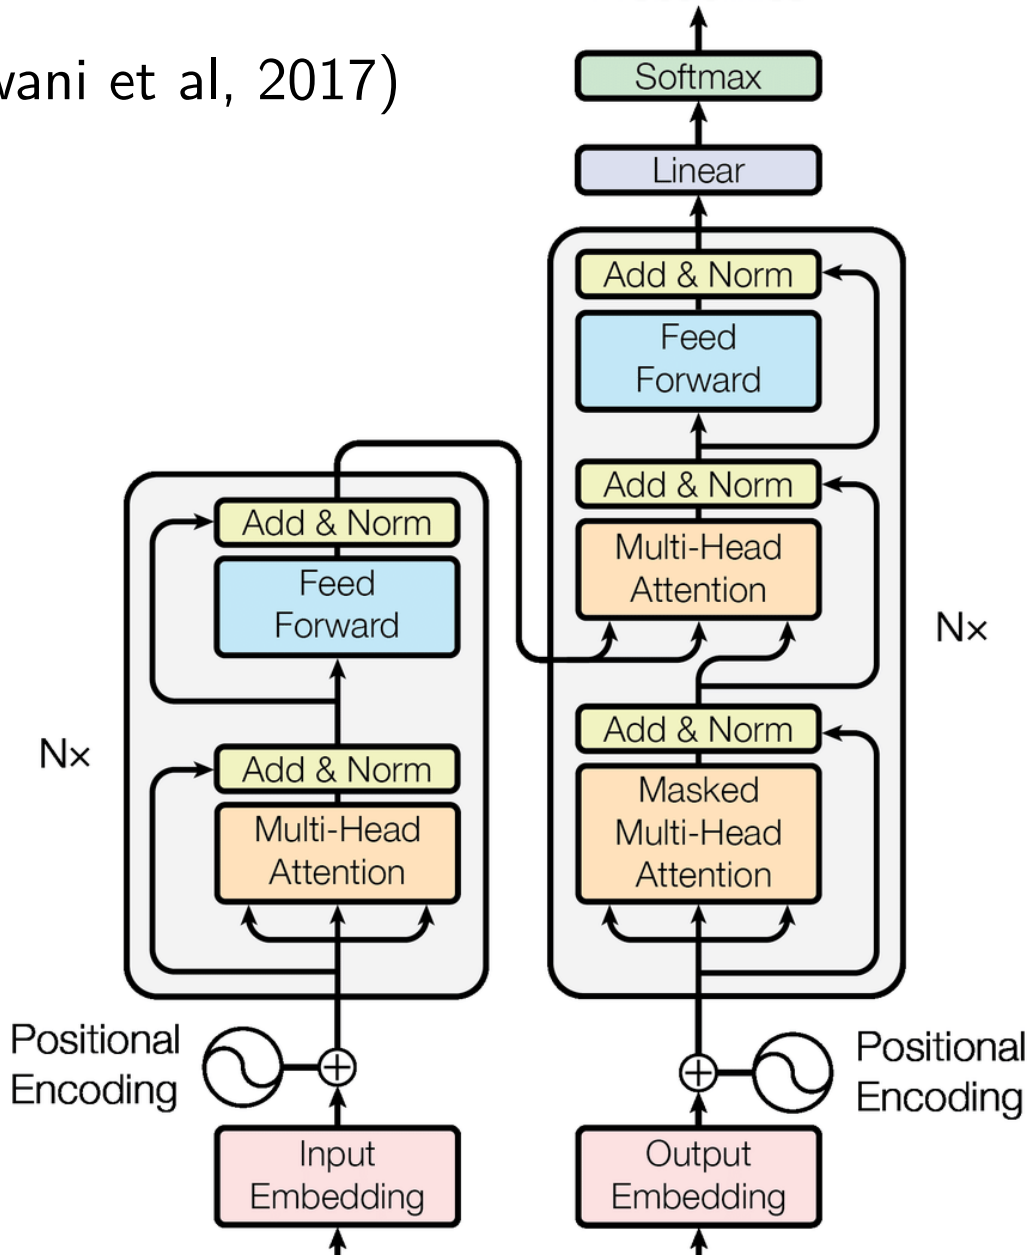

Zpětnovazební učení

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

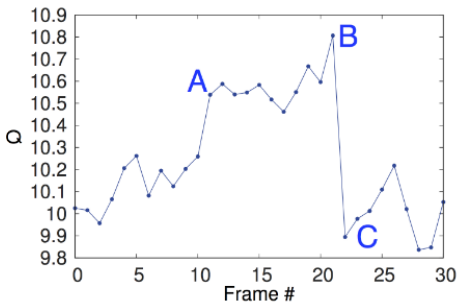

(Mnih et al, 2013)

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

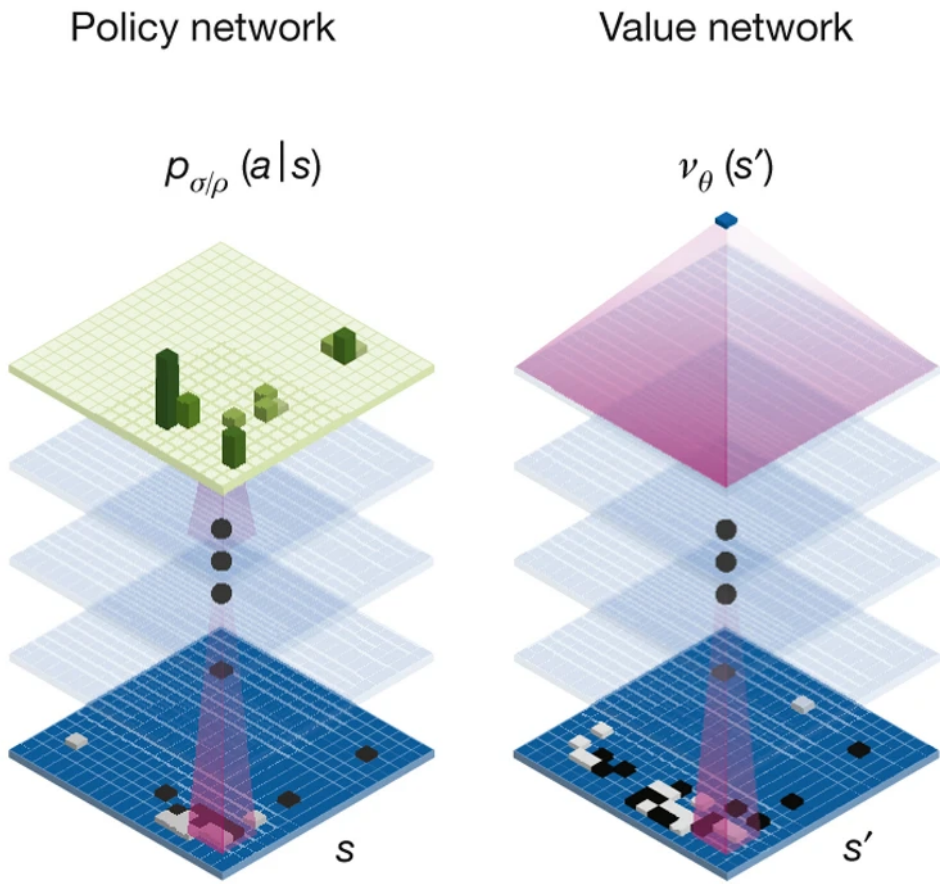

(Silver et al, 2016)

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 – obraz, ...)

    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, ...)

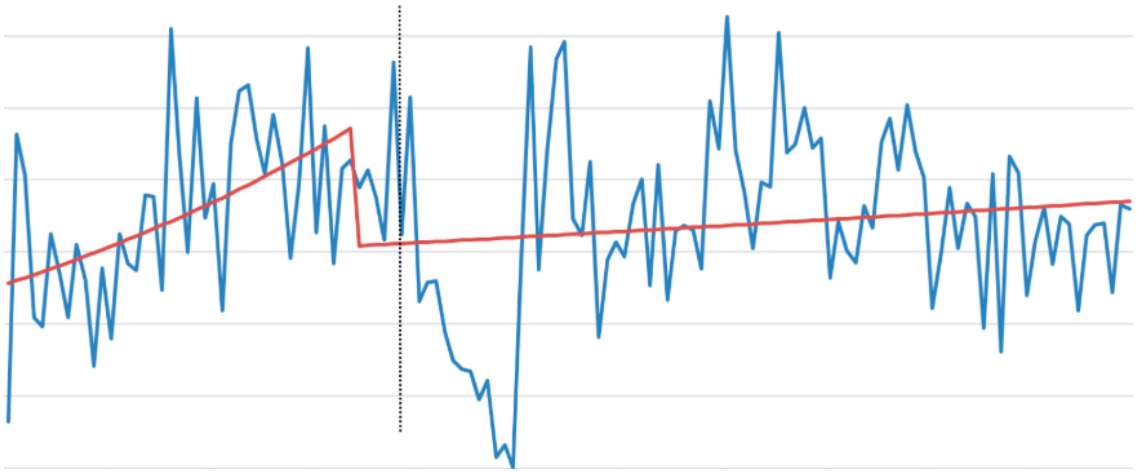

(Adulapuram, 2020)

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

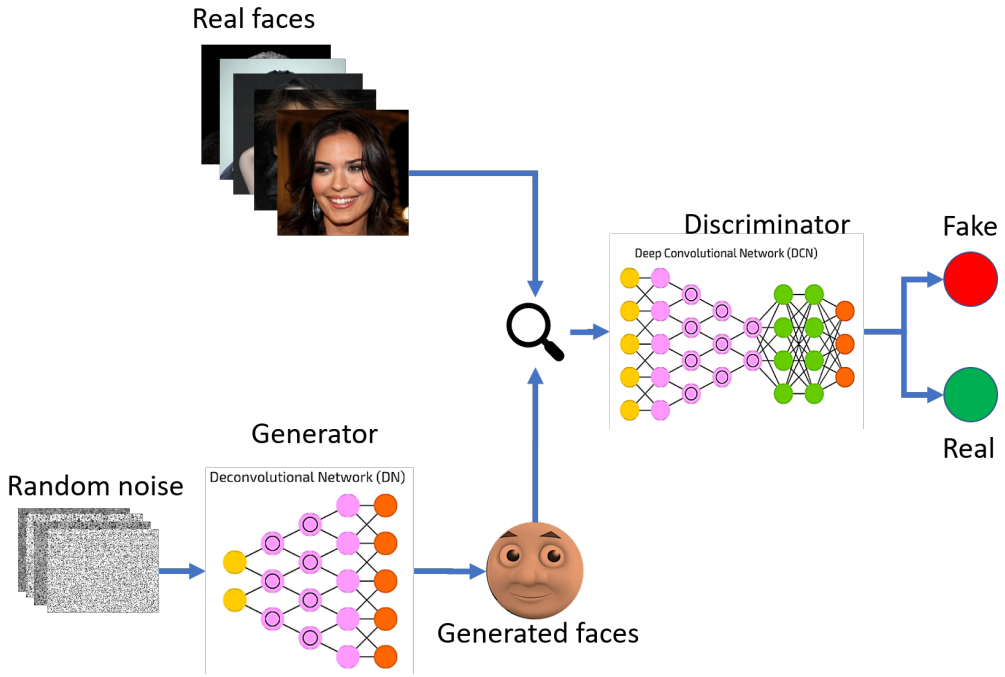

(Missinato, 2020)

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**:
  - DALL-E (OpenAI) – vytváří obrázky podle textového zadání
  - SentiGAN – generuje text se zadaným sentimentem
- **zvuk**:
  - CereVoice Me – vytvoří hlas podle nahrávek
  - DeepComposer – vytváří orchestrální skladbu podle jednoduché melodie

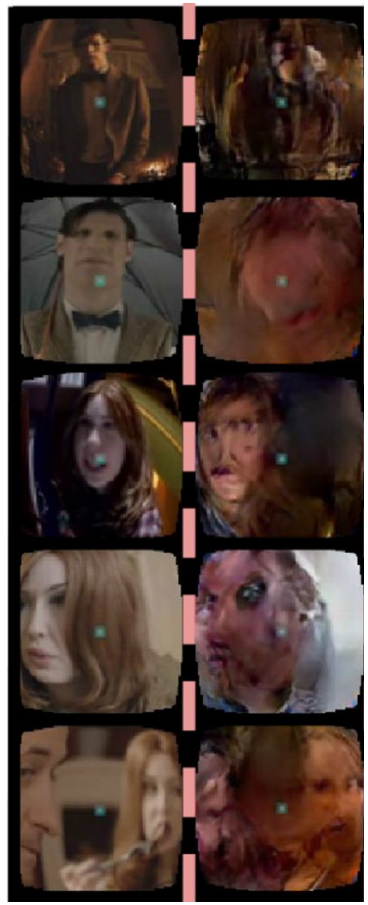

Schopnosti hlubokých sítí

co hluboké sítě umí výborně

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

97 % papoušek

co hluboké sítě moc neumí

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

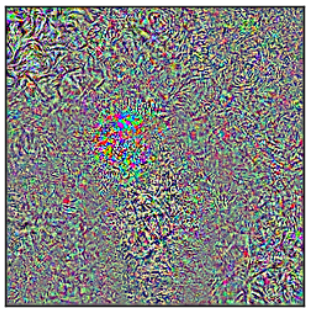

speciální šum

kdy je vhodné hluboké sítě použít

máme

- velká data
- složité vzory

nevadí

- chybí zdůvodnění
- možná zaujatost
- "nelogické" chyby

99 % knihovna