Hluboké učení pro zpracování jazyka

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/nlp_intro/

Obsah:

- Od klasických k hlubokým neuronovým sítím
- Neurální jazykové modely
- Architektura Long Short-Term Memory (LSTM)
- Architektura Transformer

Klasické neuronové sítě a text

Neuronové sítě:

- od 1943 – McCulloch & Pitts – matematický model neuronu
- 1965 – první praktická vícevrstvá dopředná síť
- 1982 – praktická implementace zpětného šíření chyby pro trénování vícevrstvých sítí

praktické využití – klasifikační úlohy

dvouvrstvá

jednovrstvá

Klasické neuronové sítě a text

Neuronové sítě:

- od 1943 – McCulloch & Pitts – matematický model neuronu
- 1965 – první praktická vícevrstvá dopředná síť
- 1982 – praktická implementace zpětného šíření chyby pro trénování vícevrstvých sítí

praktické využití – klasifikační úlohy

jednovrstvá

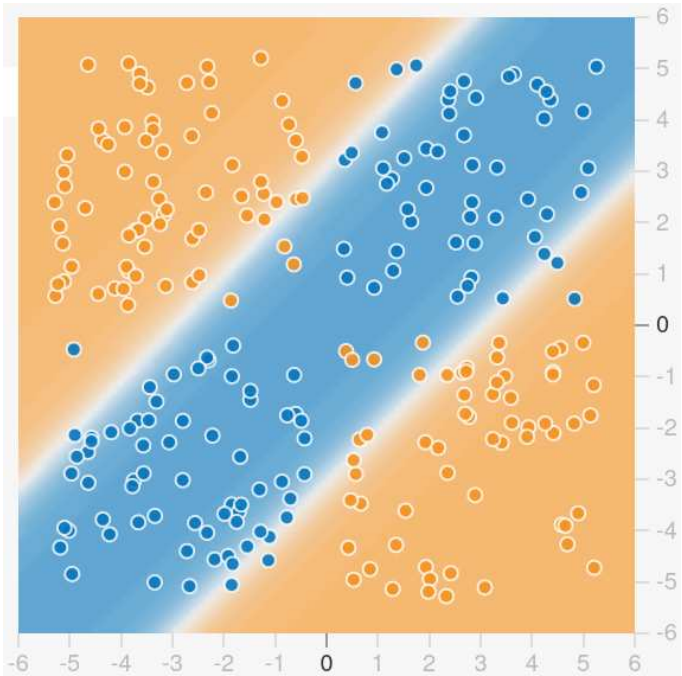

dvouvrstvá

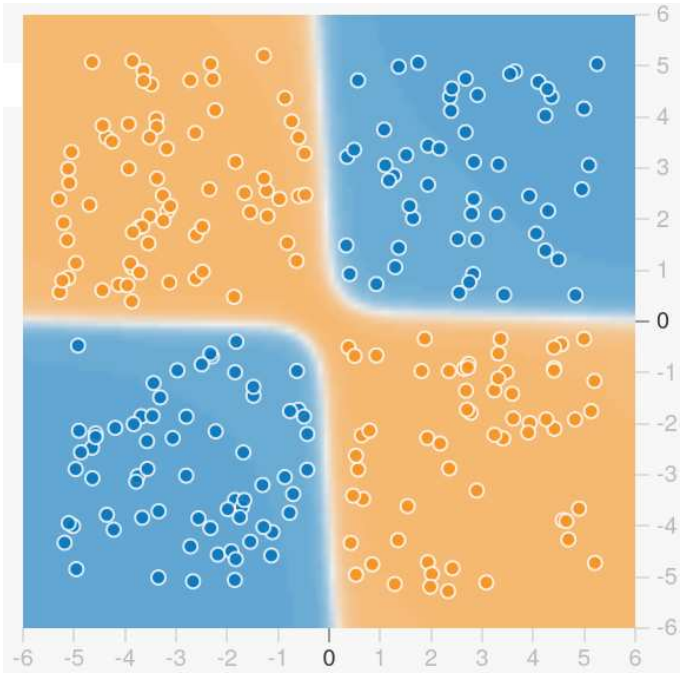

Klasické neuronové sítě a text

Neuronová síť pracuje pouze s čísly – jak zadat text?

1. slova jako prvky vstupu:
   - pevně daný slovník n slov
     one-hot kódování:
     $\langle 1, 0, 0, 0, \ldots \rangle$
     $\langle 0, 1, 0, 0, \ldots \rangle$
   - pevně daná (maximální) délka vstupu m
   - vstup sítě – $m \times n$
   - není vhodné pro velké slovníky

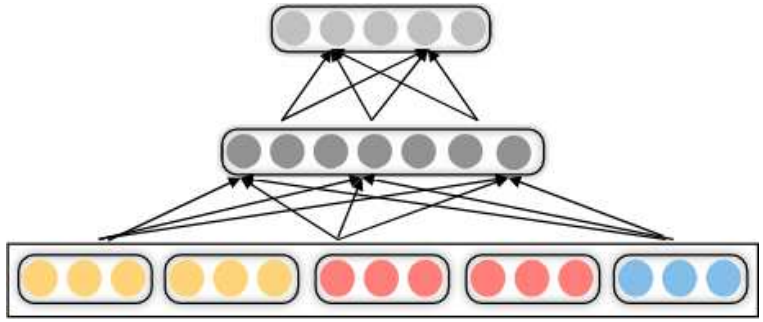

2. slova jako slovní vektory (*word embeddings*):
   - stanovení pevné dimenze
   - předpočítání/předtrénování na velmi velkých neanotovaných textech
     $\Rightarrow$ neurální jazykové modely
   - zachycení sémantiky – podobná slova síť zpracuje podobně
   - univerzálnější – vektory částí slov (*subword/character embeddings*)
   - jen výměnou modelu můžeme zpřesnit výsledky

Klasické neuronové sítě a text

Neuronová síť pracuje pouze s čísly – jak zadat text?

1. slova jako prvky vstupu:
   - pevně daný slovník n slov
     one-hot kódování:
     $\langle 1, 0, 0, 0, \ldots \rangle$
     $\langle 0, 1, 0, 0, \ldots \rangle$
   - pevně daná (maximální) délka vstupu m
   - vstup sítě – $m \times n$
   - není vhodné pro velké slovníky

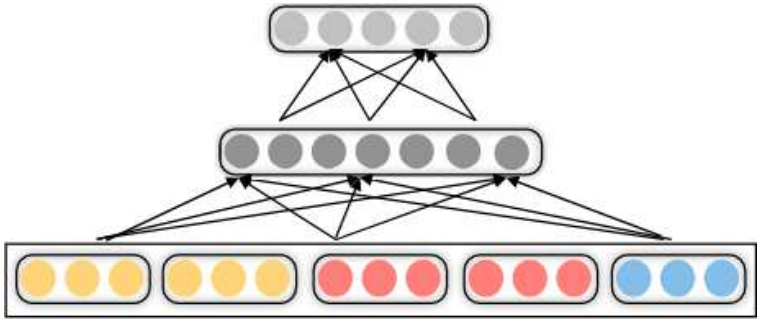

2. slova jako slovní vektory (*word embeddings*):
   - stanovení pevné dimenze
   - předpočítání/předtrénování na velmi velkých neanotovaných textech
     $\Rightarrow$ neurální jazykové modely
   - zachycení sémantiky – podobná slova síť zpracuje podobně
   - univerzálnější – vektory částí slov (*subword/character embeddings*)
   - jen výměnou modelu můžeme zpřesnit výsledky

Hluboké učení

Hluboké neuronové sítě:

- dopředné sítě – plně propojené vrstvy

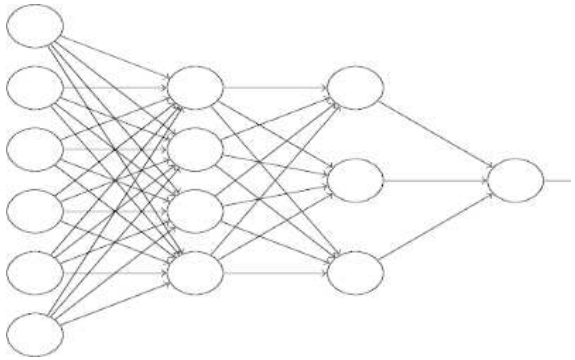

- cca od r. 2000 – metody a HW (GPU karty) pro učení sítí, které se skládají z mnoha (až desítek) heterogenních vrstev: konvoluční, sdružující (*max pooling*), rekurentní, klasifikační (*soft max*), ...

Hluboké učení

Hluboké neuronové sítě:

- dopředné sítě – plně propojené vrstvy

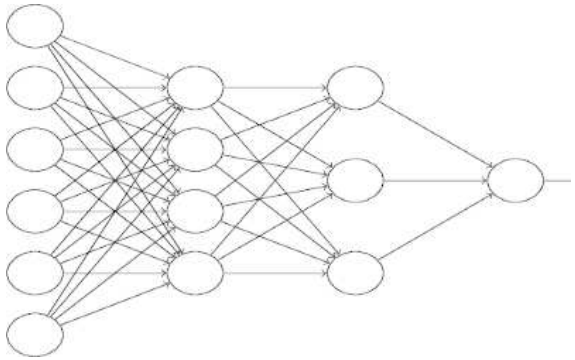

- cca od r. 2000 – metody a HW (GPU karty) pro učení sítí, které se skládají z mnoha (až desítek) heterogenních vrstev: konvoluční, sdružující (*max pooling*), rekurentní, klasifikační (*soft max*), ...

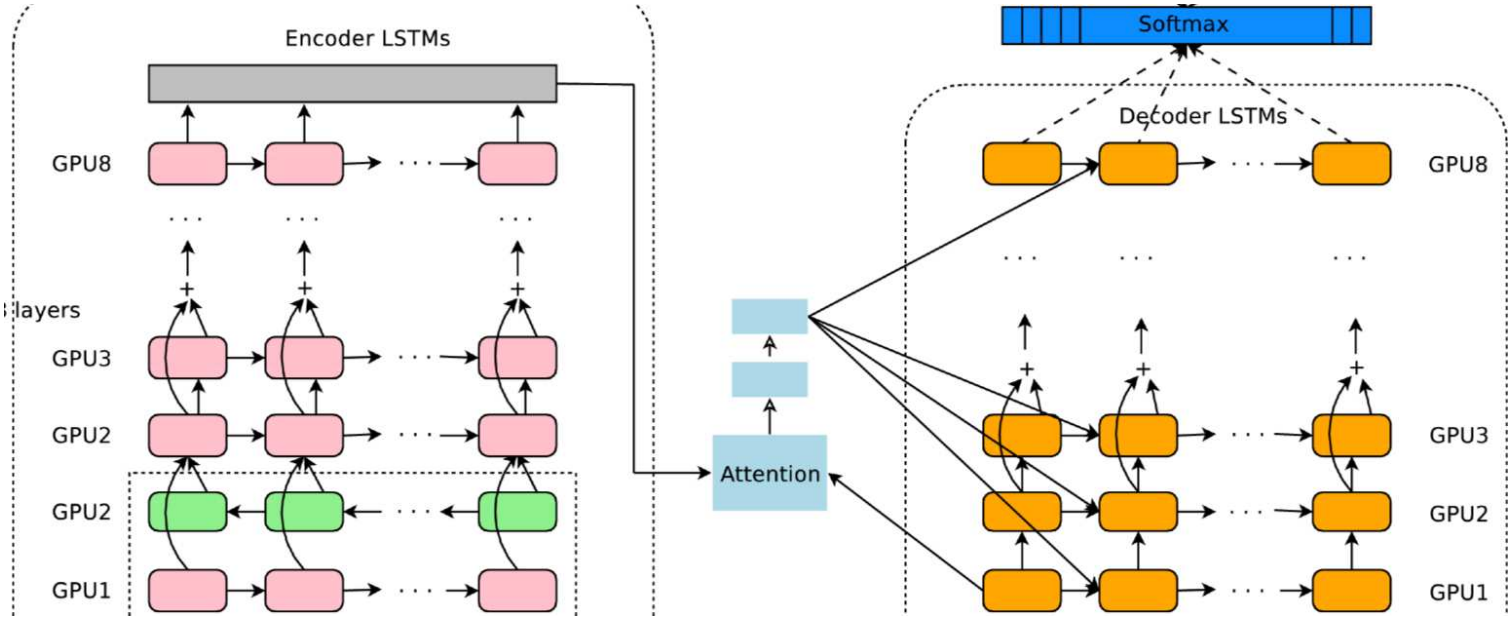

Obsah

Neurální jazykový model

připomínka – jazykový model:

SliDo

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

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

skrytá vrstva

$h = f(We + b_1)$

řetězené vektory slov

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

slova na vstupu

$w_1 w_2 w_3 w_4$

w_1 w_2 w_3 w_4

Neurální jazykový model

SliDo

připomínka – jazykový model:

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

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

skrytá vrstva

$h = f(We + b_1)$

řetězené vektory slov

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

slova na vstupu

$w_1 w_2 w_3 w_4$

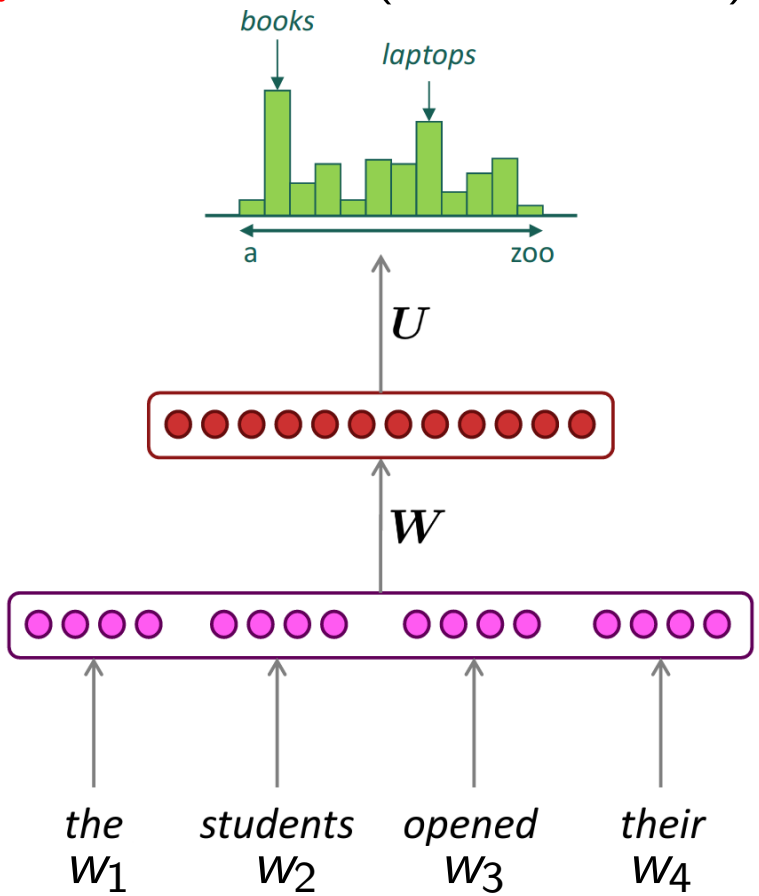

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

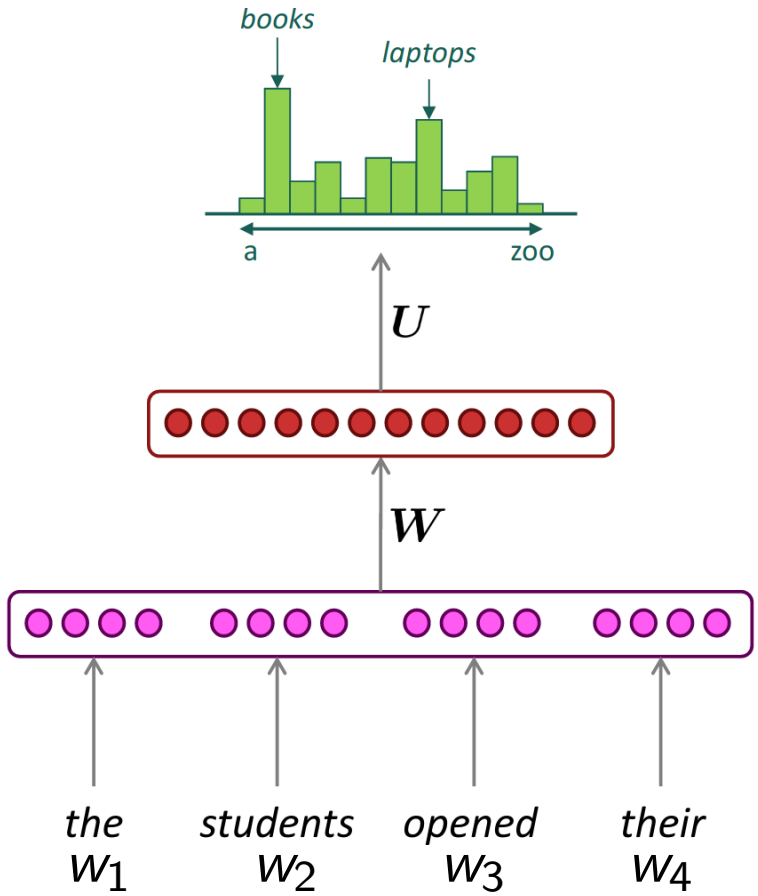

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

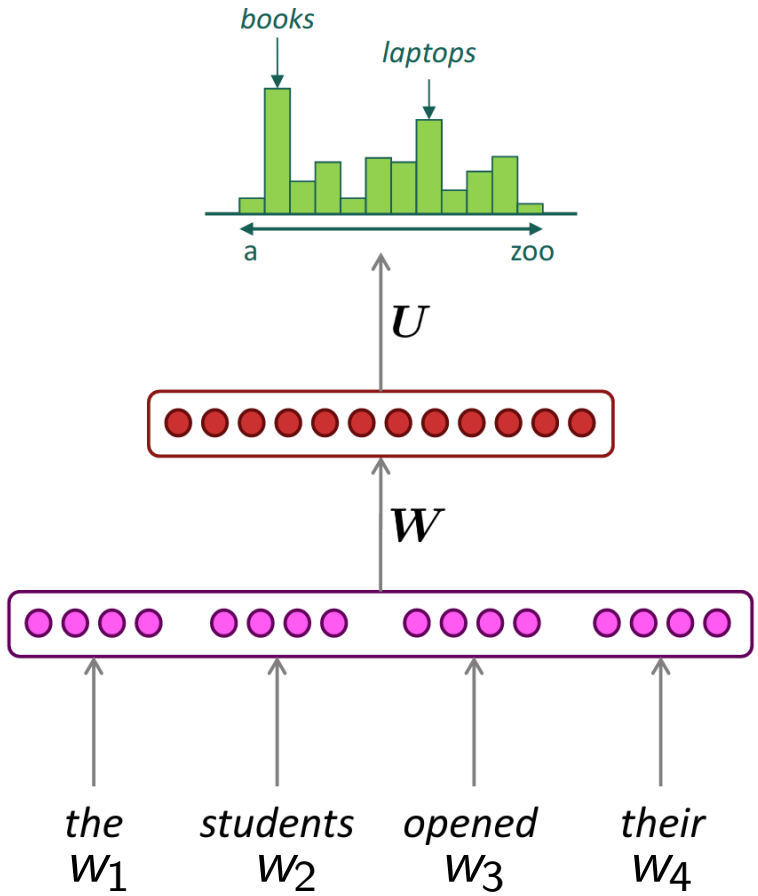

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

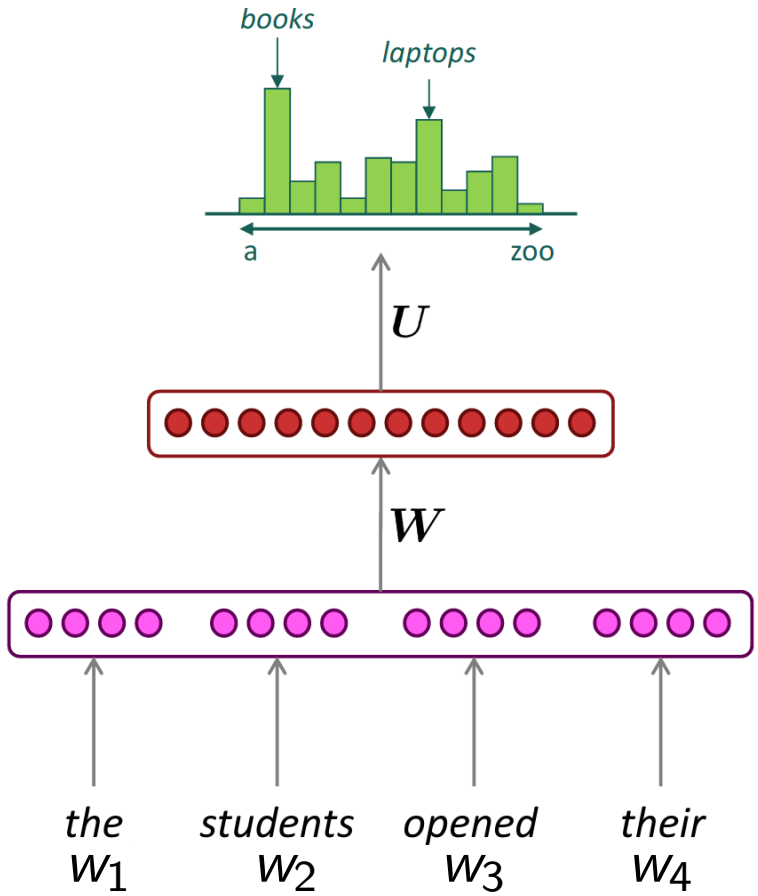

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

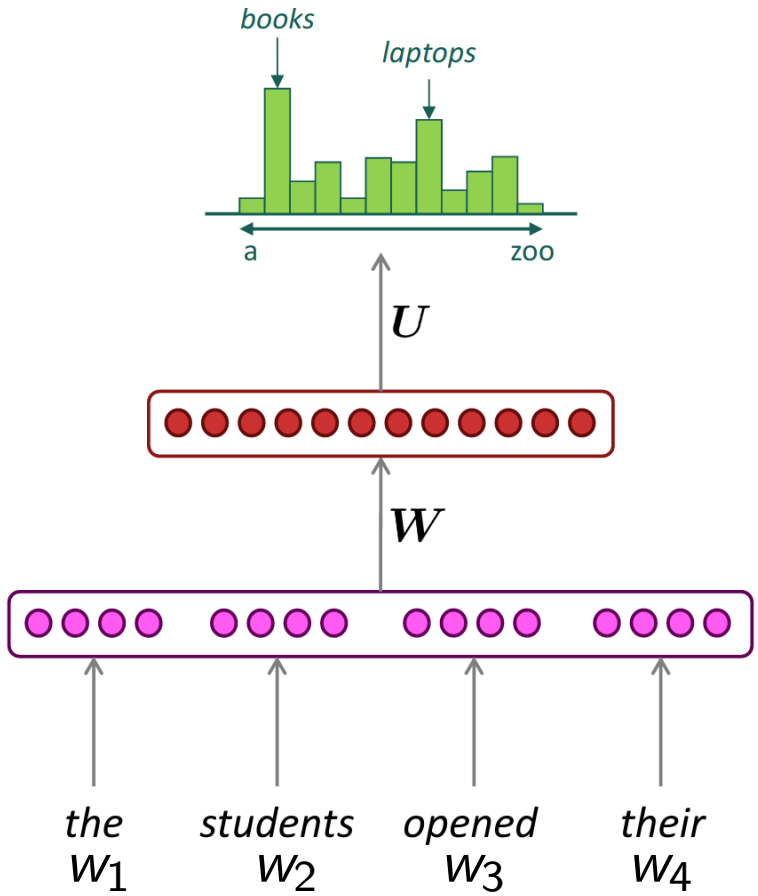

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

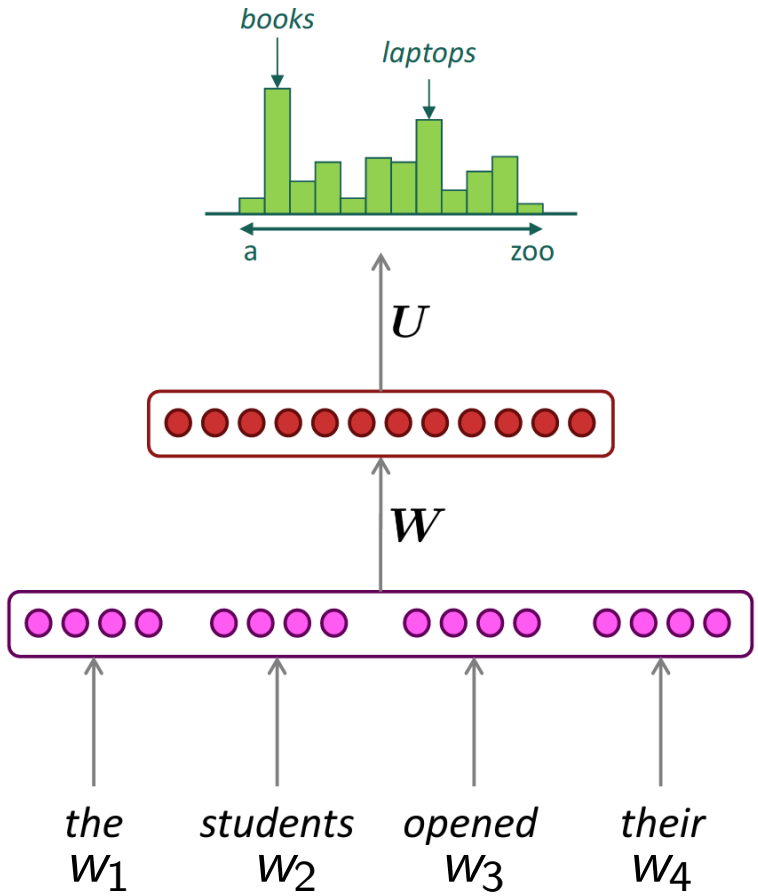

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými n-gramy
- nemusíme počítat a ukládat velké seznamy n-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

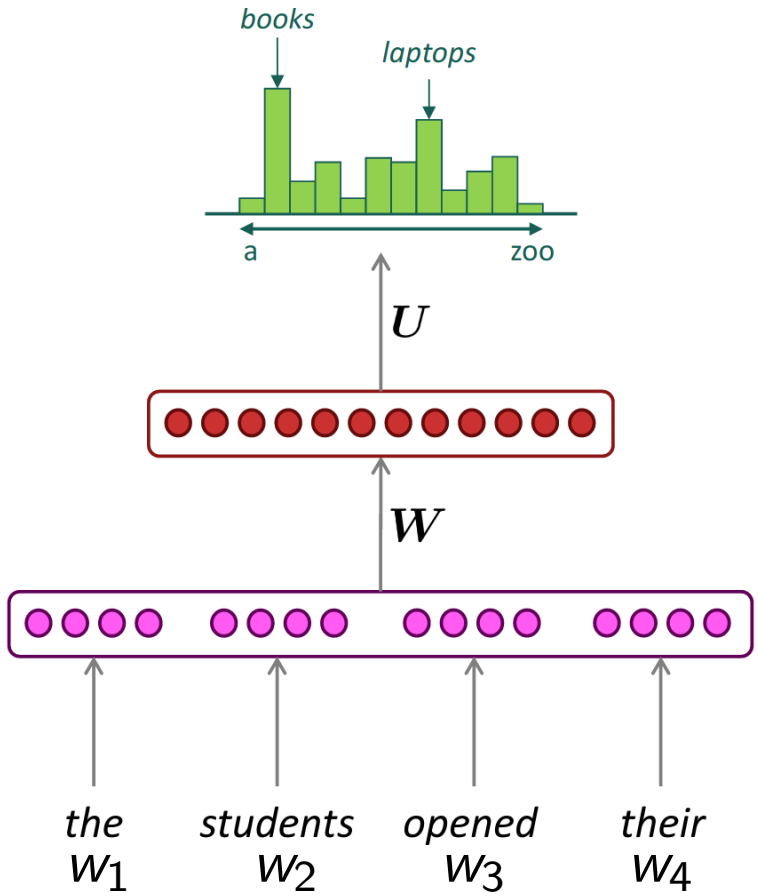

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- není problém s nenalezenými *n*-gramy
- nemusíme počítat a ukládat velké seznamy *n*-gramů

problémy:

- (malá) šířka kontextu
- rozšíření kontextu – zvětšuje W
- ideální kontext je příliš velký
- váhy W závisí na pořadí slov – w_1 má jiné váhy než w_2

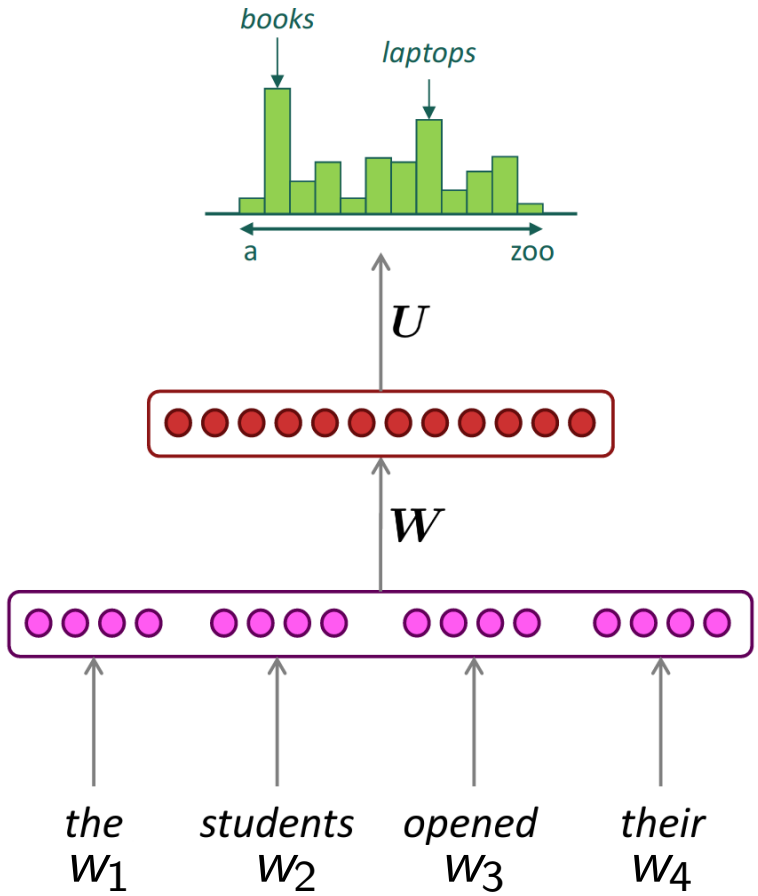

obr. z Stanford.Uni.

je potřebná neurální architektura pro libovolně dlouhý vstup

Rekurentní jazykový model

výstupní distribuce

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

skryté stavy

$$h^{(t)} = \sigma(W_h h^{(t-1)} + W_e e^{(t)} + b_1)$$

váhy W_h a W_e se aplikují opakovaně

jednotlivé vektory slov

$e^{(1)}, e^{(2)}, e^{(3)}, e^{(4)}, \ldots$

slova na vstupu

$w_1 w_2 w_3 w_4$

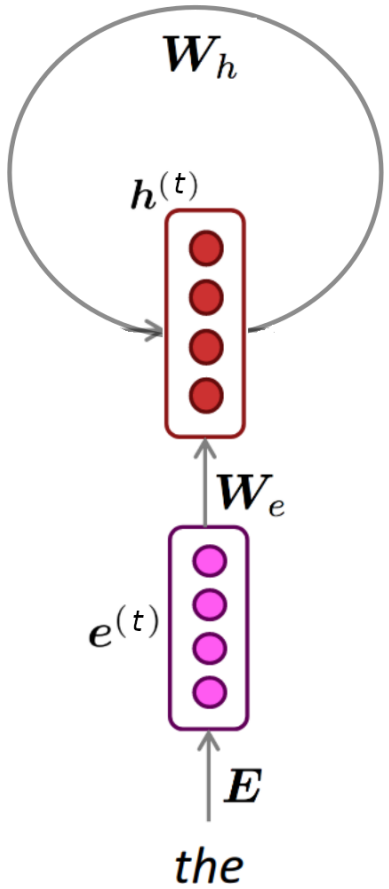

Rekurentní jazykový model

výstupní distribuce

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

skryté stavy

$h^{(t)} = \sigma(W_h h^{(t-1)} + W_e e^{(t)} + b_1)$

váhy W_h a W_e se aplikují opakovaně

jednotlivé vektory slov

$e^{(1)}, e^{(2)}, e^{(3)}, e^{(4)}, \ldots$

slova na vstupu

$w_1 w_2 w_3 w_4$

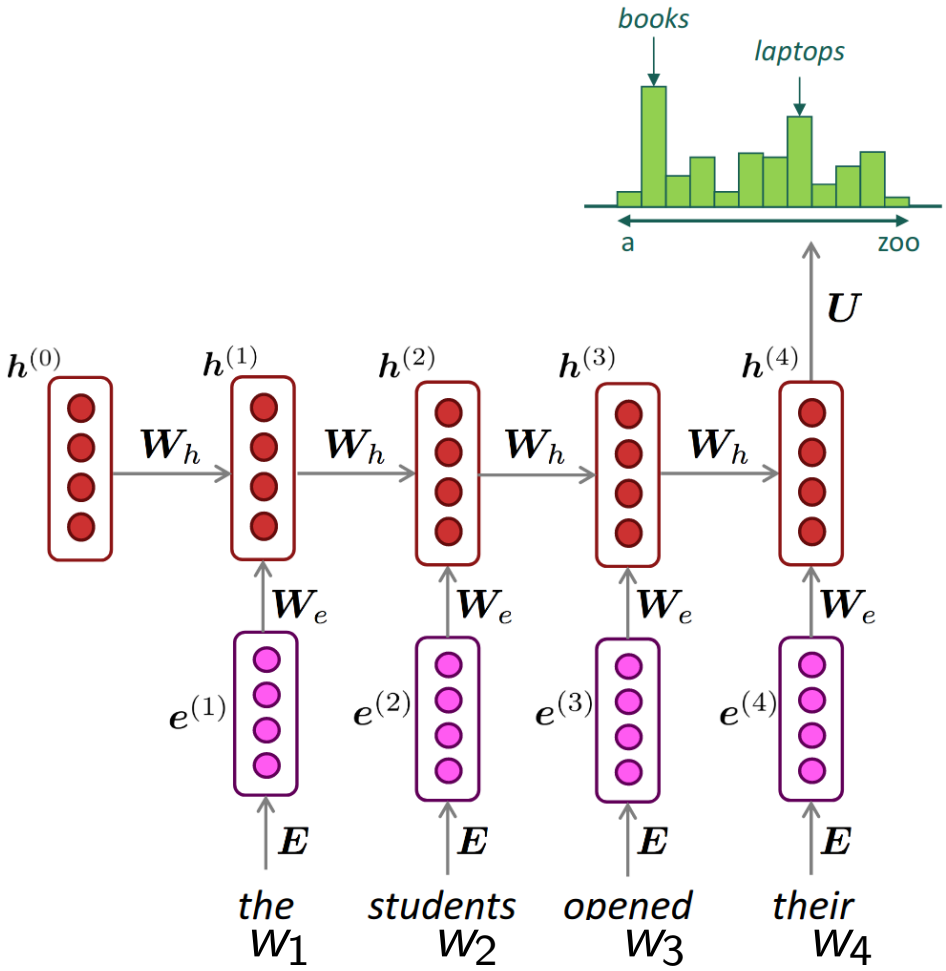

Rekurentní jazykový model

výhody rekurentního modelu:

- může zpracovat vstup libovolné délky (v praxi věta)
- výpočet je založen na celé sekvenci
- váhy jsou stejné – nezávislost na pozici

nevýhody:

- rekurentní výpočet je pomalý
- s délkou sekvence se informace rozmělňuje

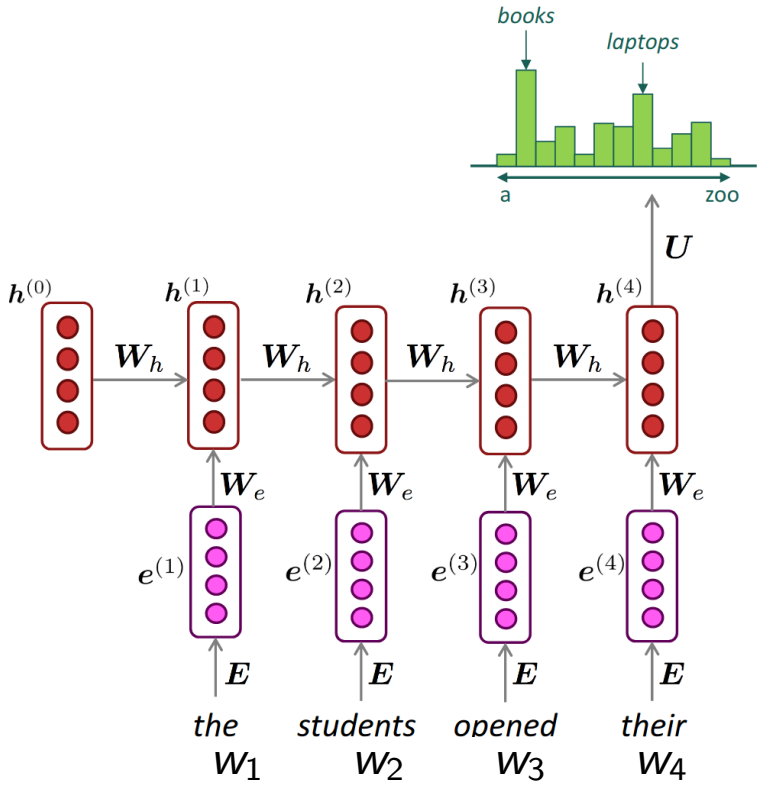

vyzkoušejte – https://muni.cz/go/ib030_text_gener

Rekurentní jazykový model

výhody rekurentního modelu:

- může zpracovat vstup libovolné délky (v praxi věta)
- výpočet je založen na celé sekvenci
- váhy jsou stejné – nezávislost na pozici

nevýhody:

- rekurentní výpočet je pomalý
- s délkou sekvence se informace rozmělňuje

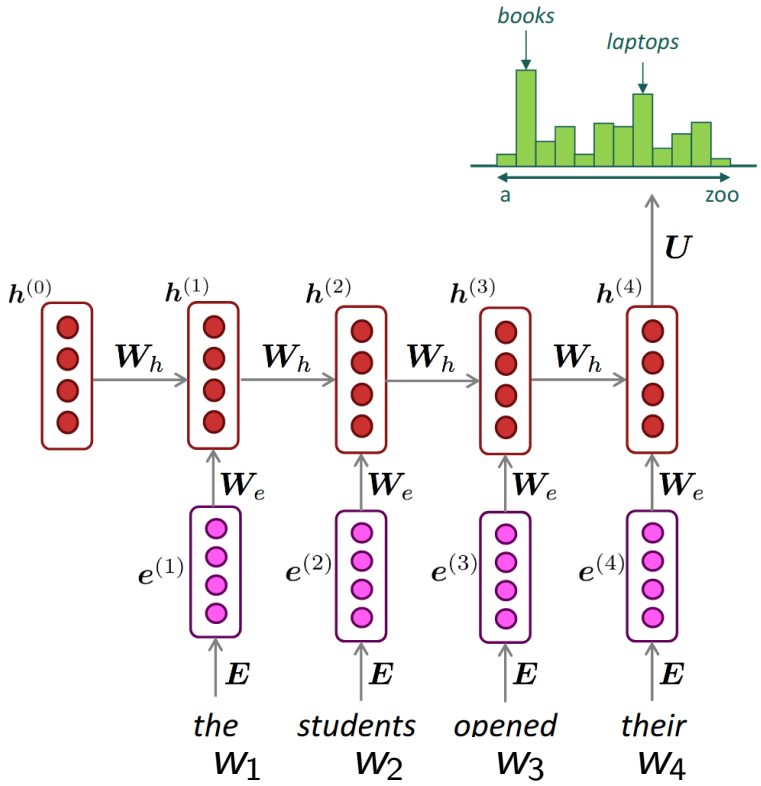

vyzkoušejte – https://muni.cz/go/ib030_text_gener

Rekurentní jazykový model

výhody rekurentního modelu:

- může zpracovat vstup libovolné délky (v praxi věta)
- výpočet je založen na celé sekvenci
- váhy jsou stejné – nezávislost na pozici

nevýhody:

- rekurentní výpočet je pomalý
- s délkou sekvence se informace rozmělňuje

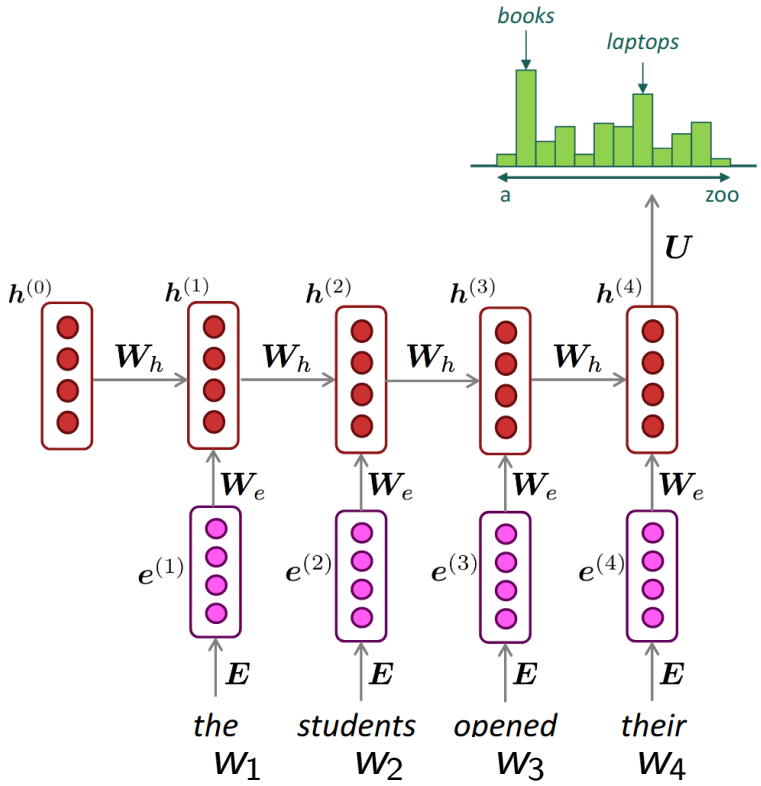

vyzkoušejte – https://muni.cz/go/ib030_text_gener

Rekurentní jazykový model

výhody rekurentního modelu:

- může zpracovat vstup libovolné délky (v praxi věta)
- výpočet je založen na celé sekvenci
- váhy jsou stejné – nezávislost na pozici

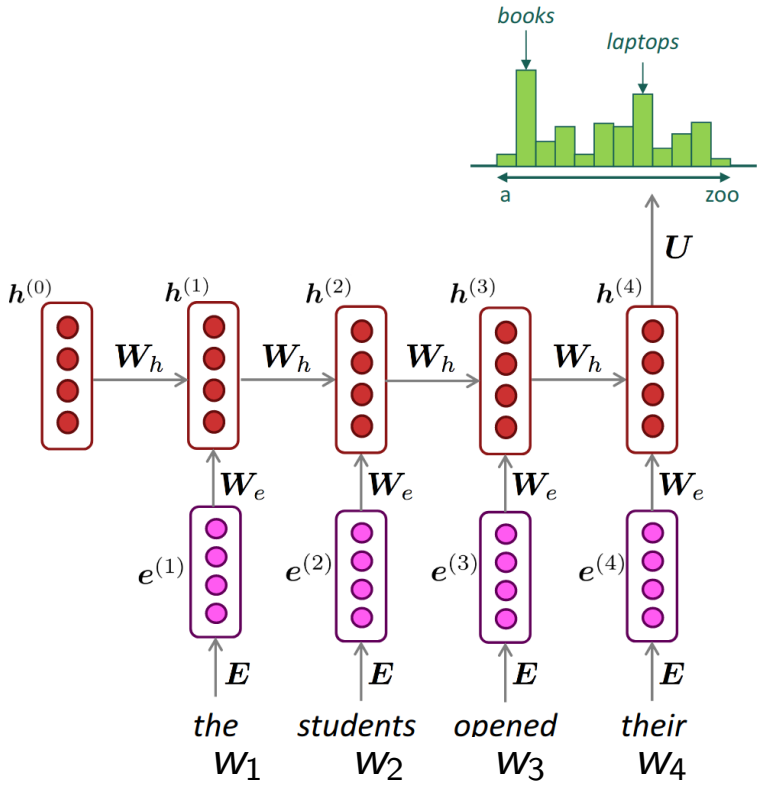

nevýhody:

- rekurentní výpočet je pomalý
- s délkou sekvence se informace rozmělňuje

vyzkoušejte – https://muni.cz/go/ib030_text_gener

Rekurentní jazykový model

výhody rekurentního modelu:

- může zpracovat vstup libovolné délky (v praxi věta)
- výpočet je založen na celé sekvenci
- váhy jsou stejné – nezávislost na pozici

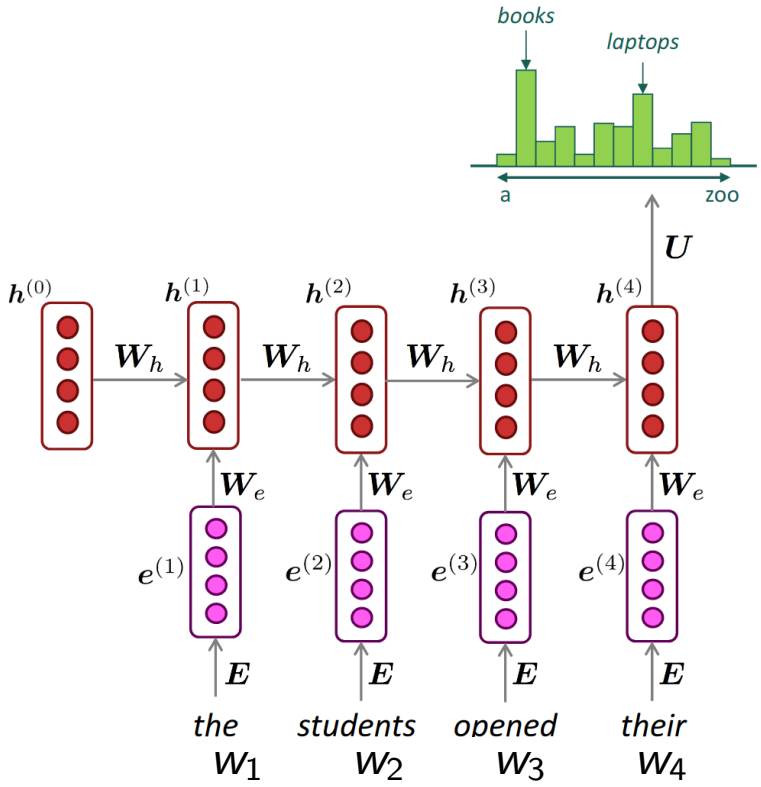

nevýhody:

- rekurentní výpočet je pomalý
- s délkou sekvence se informace rozmělňuje

vyzkoušejte – https://muni.cz/go/ib030_text_gener

Kvalita jazykového modelu

základní srovnávací metrika – perplexita ("zmatenost"):

- srovnání na vybraném testovacím textu
- poměrově vyjadřuje z kolika slov se vybírá predikce
- nižší hodnota = lepší perplexita

Rekurentní modely → zlepšení perplexity

	Model	Perplexita
n-gramový model →	Interpolated Kneser-Ney 5-gram (Chelba et al., 2013)	**67.6**
rekur. ↓ modely	RNN-1024 + MaxEnt 9-gram (Chelba et al., 2013)	51.3
	RNN-2048 + Blackout sampling (Ji et al., 2015)	68.3
	Sparse Non-negative Matrix factorization (Shazeer et al., 2015)	52.9
	LSTM-2048 Oozefowicz et al., 2016)	43.7
	2-layer LSTM-8192 Oozefowicz et al., 2016)	**30.0**

zdroj research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words

Kvalita jazykového modelu

základní srovnávací metrika – perplexita ("zmatenost"):

- srovnání na vybraném testovacím textu
- poměrově vyjadřuje z kolika slov se vybírá predikce
- nižší hodnota = lepší perplexita

Rekurentní modely → zlepšení perplexity

n-gramový model → / rekur. ↓ modely

Model	Perplexita
Interpolated Kneser-Ney 5-gram (Chelba et al., 2013)	**67.6**
RNN-1024 + MaxEnt 9-gram (Chelba et al., 2013)	51.3
RNN-2048 + Blackout sampling (Ji et al., 2015)	68.3
Sparse Non-negative Matrix factorization (Shazeer et al., 2015)	52.9
LSTM-2048 Oozefowicz et al., 2016)	43.7
2-layer LSTM-8192 Oozefowicz et al., 2016)	**30.0**

zdroj research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words

Kvalita jazykového modelu

základní srovnávací metrika – perplexita ("zmatenost"):

- srovnání na vybraném testovacím textu
- poměrově vyjadřuje z kolika slov se vybírá predikce
- nižší hodnota = lepší perplexita

Rekurentní modely → zlepšení perplexity

n-gramový model → / rekur. ↓ modely

Model	Perplexita
Interpolated Kneser-Ney 5-gram (Chelba et al., 2013)	**67.6**
RNN-1024 + MaxEnt 9-gram (Chelba et al., 2013)	51.3
RNN-2048 + Blackout sampling (Ji et al., 2015)	68.3
Sparse Non-negative Matrix factorization (Shazeer et al., 2015)	52.9
LSTM-2048 Oozefowicz et al., 2016)	43.7
2-layer LSTM-8192 Oozefowicz et al., 2016)	**30.0**

zdroj research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words

Kvalita jazykového modelu

základní srovnávací metrika – perplexita ("zmatenost"):

- srovnání na vybraném testovacím textu
- poměrově vyjadřuje z kolika slov se vybírá predikce
- nižší hodnota = lepší perplexita

Rekurentní modely → zlepšení perplexity

n-gramový model → / rekur. ↓ modely

Model	Perplexita
Interpolated Kneser-Ney 5-gram (Chelba et al., 2013)	**67.6**
RNN-1024 + MaxEnt 9-gram (Chelba et al., 2013)	51.3
RNN-2048 + Blackout sampling (Ji et al., 2015)	68.3
Sparse Non-negative Matrix factorization (Shazeer et al., 2015)	52.9
LSTM-2048 Oozefowicz et al., 2016)	43.7
2-layer LSTM-8192 Oozefowicz et al., 2016)	**30.0**

zdroj `research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words`

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet
- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet
- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet

- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet
- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet
- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství hyperparametrů:

- regularizace (např. L2-regularizace) – brání přeučení sítě
  ke ztrátové funkci (*loss function*) přidává "pokutu" $\lambda \sum_k w_k^2$
- dropout – cíleně způsobuje náhodné výpadky vstupních hodnot
  simuluje šum v datech – nutí síť ke generalizaci
- dimenze skryté vrstvy (*hidden layer dimension*)
  vyšší hodnoty umožní síti více si pamatovat,
  ale prodlužují výpočet
- optimalizační funkce (*optimizer*)
  základní – *Stochastic Gradient Descent*, *SGD*
  pro různé úlohy sofistikované varianty *Adagrad*, *RMSprop*, *Adam*, ...
- míra učení (*learning rate*) – řídí rychlost učení
  obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$
  hodně závisí na optimalizační funkci

Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Využití rekurentních sítí – značkování

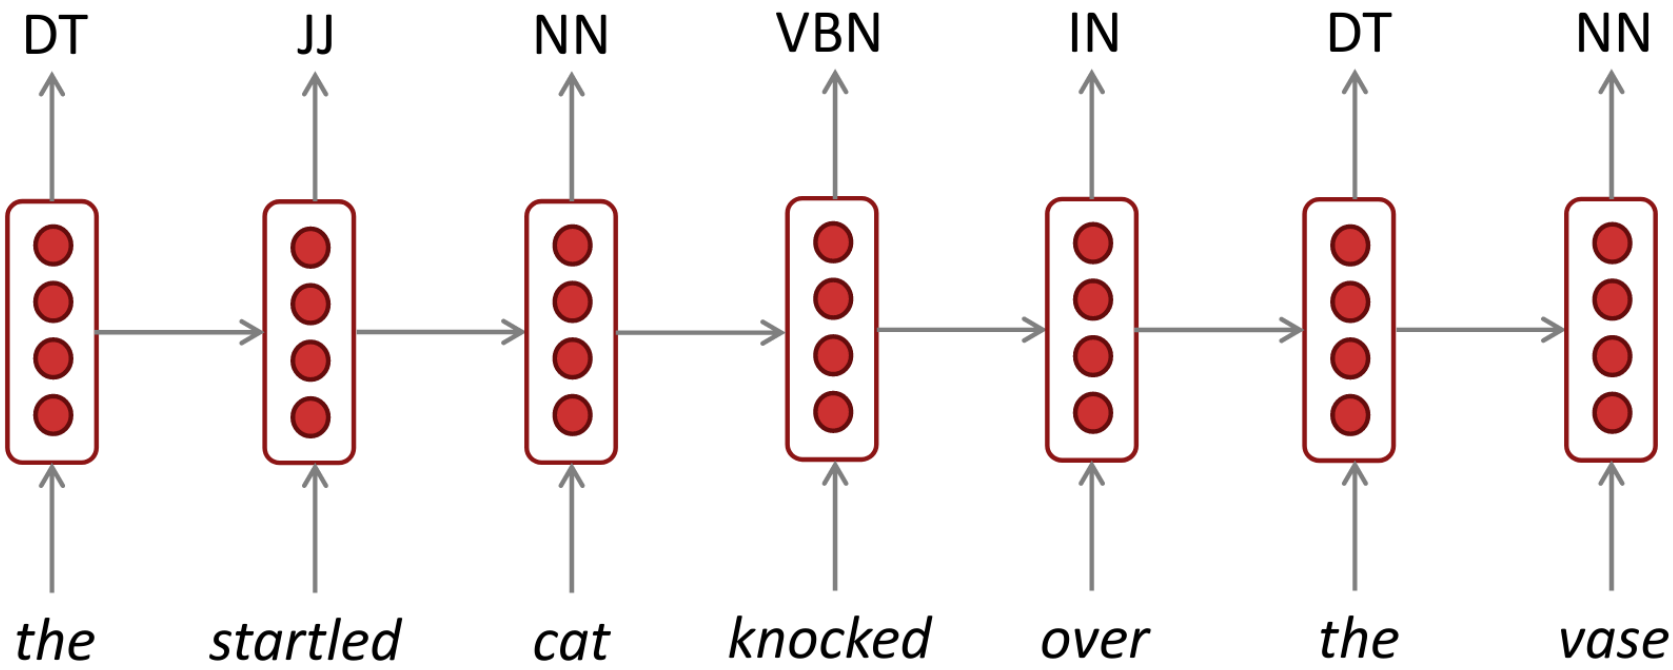

Využití rekurentních sítí – klasifikace vět

např. analýza sentimentu

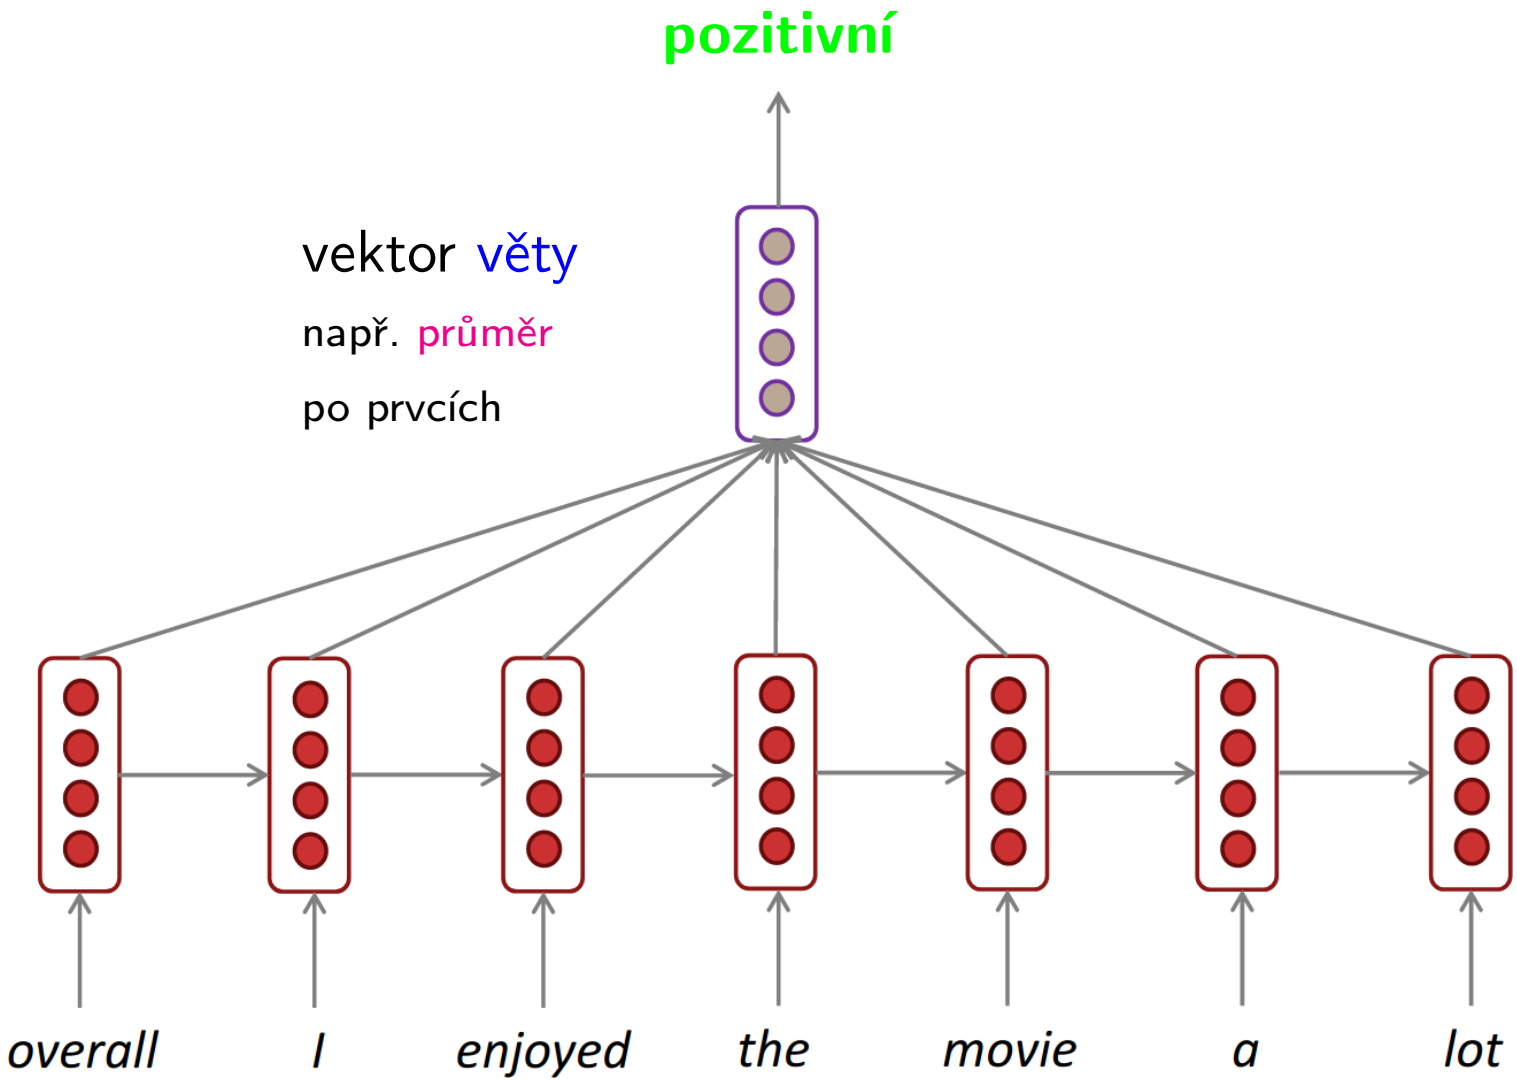

Využití rekurentních sítí – odpovídání na otázky

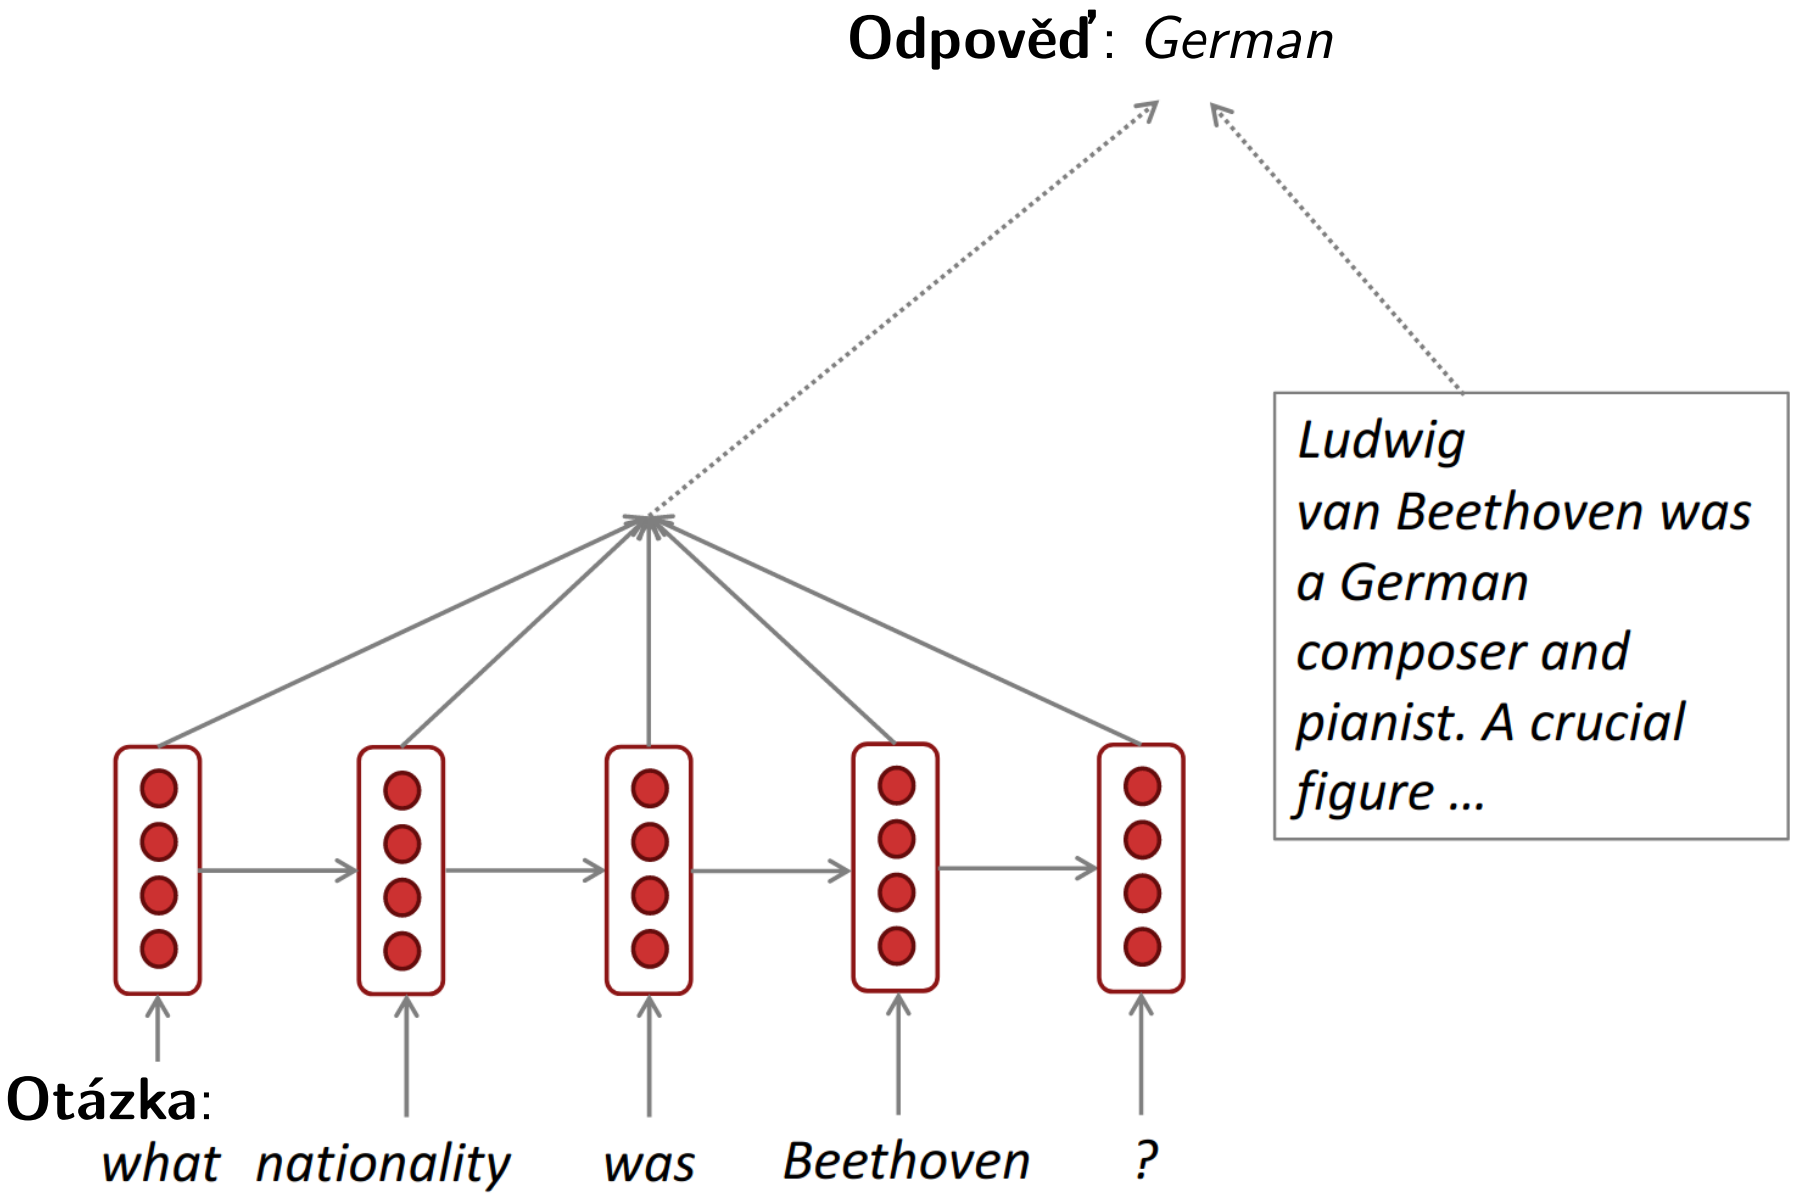

Využití rekurentních sítí – podmíněné generování

zapojení dalších sekvenčních podmínek – syntéza řeči, strojový překlad, sumarizace

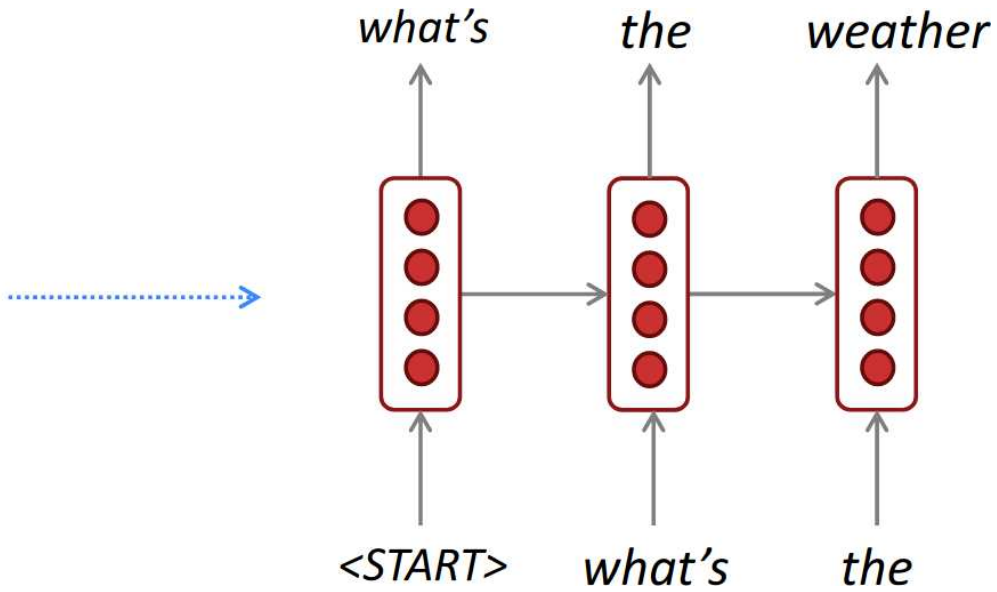

Využití rekurentních sítí – seq2seq

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

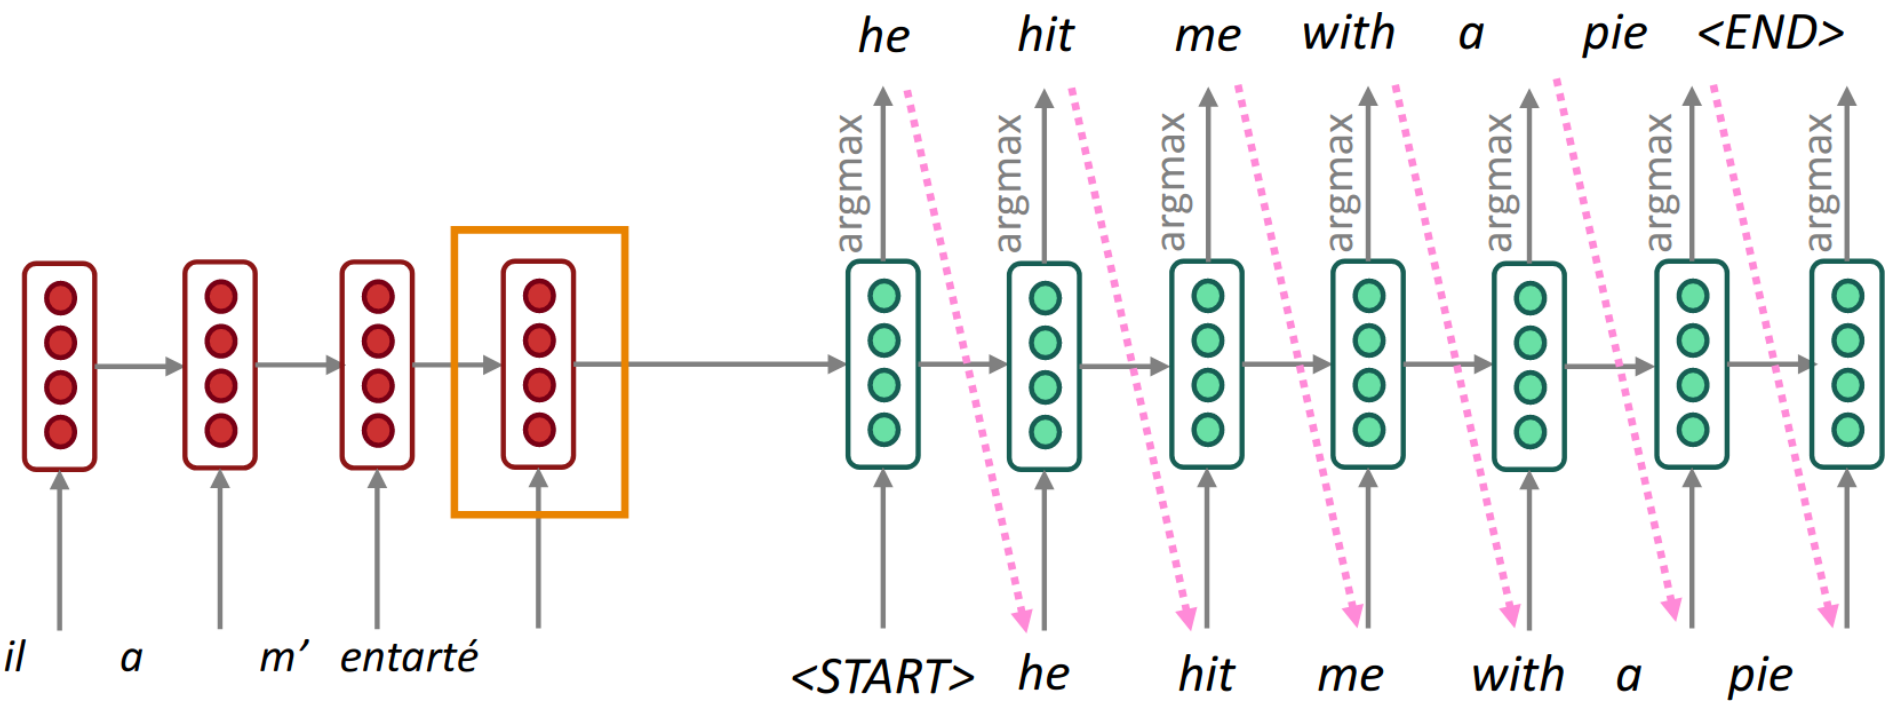

SliDo

Obsah

Architektura Long Short-Term Memory (LSTM)

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

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

Architektura Long Short-Term Memory (LSTM)

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

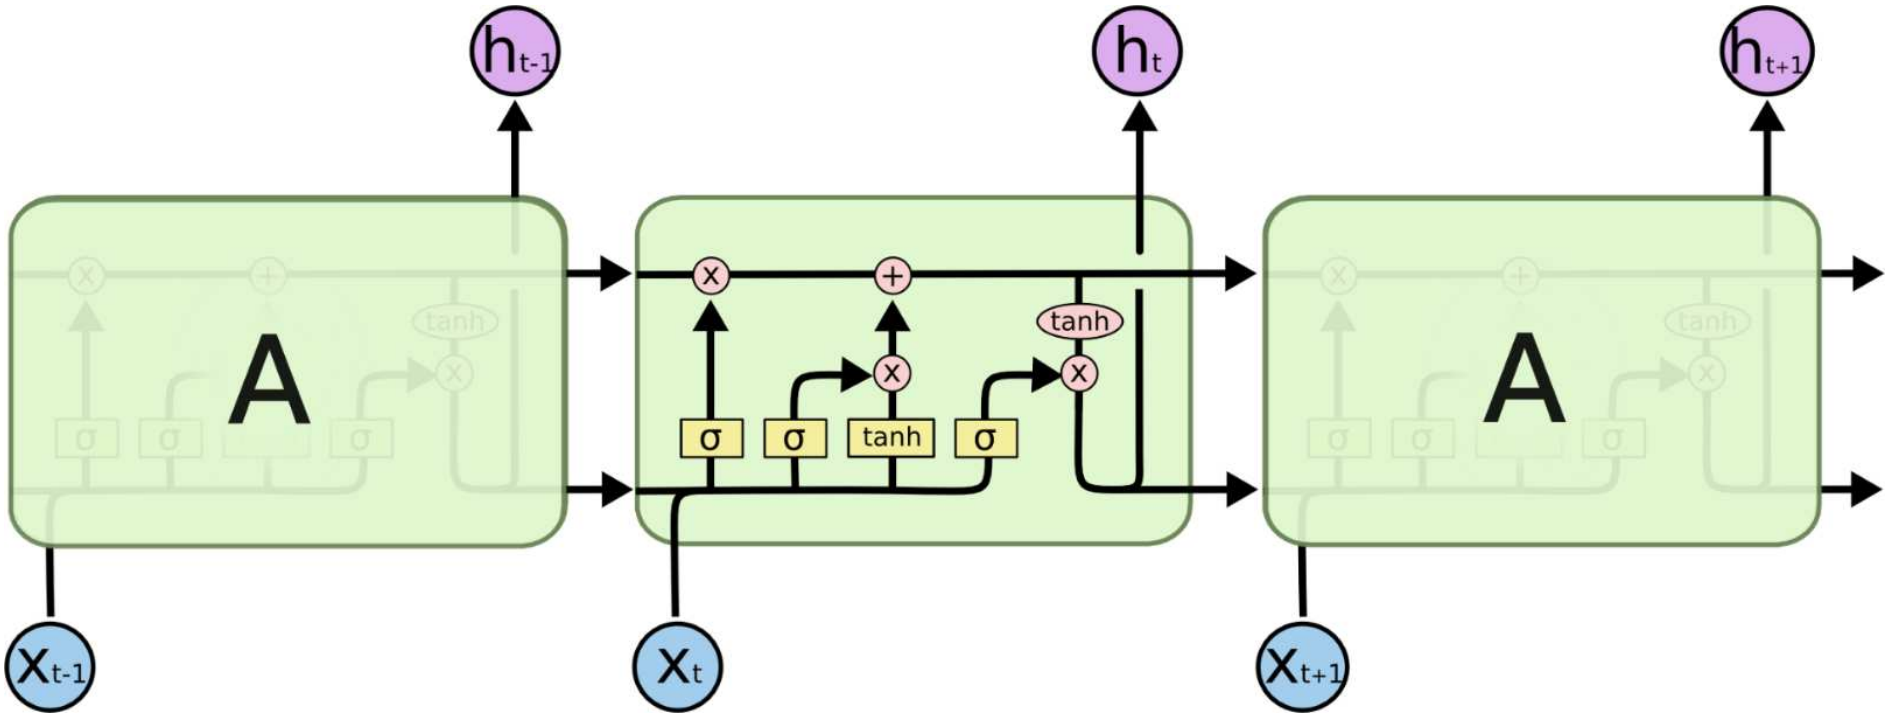

Architektura Long Short-Term Memory (LSTM)

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

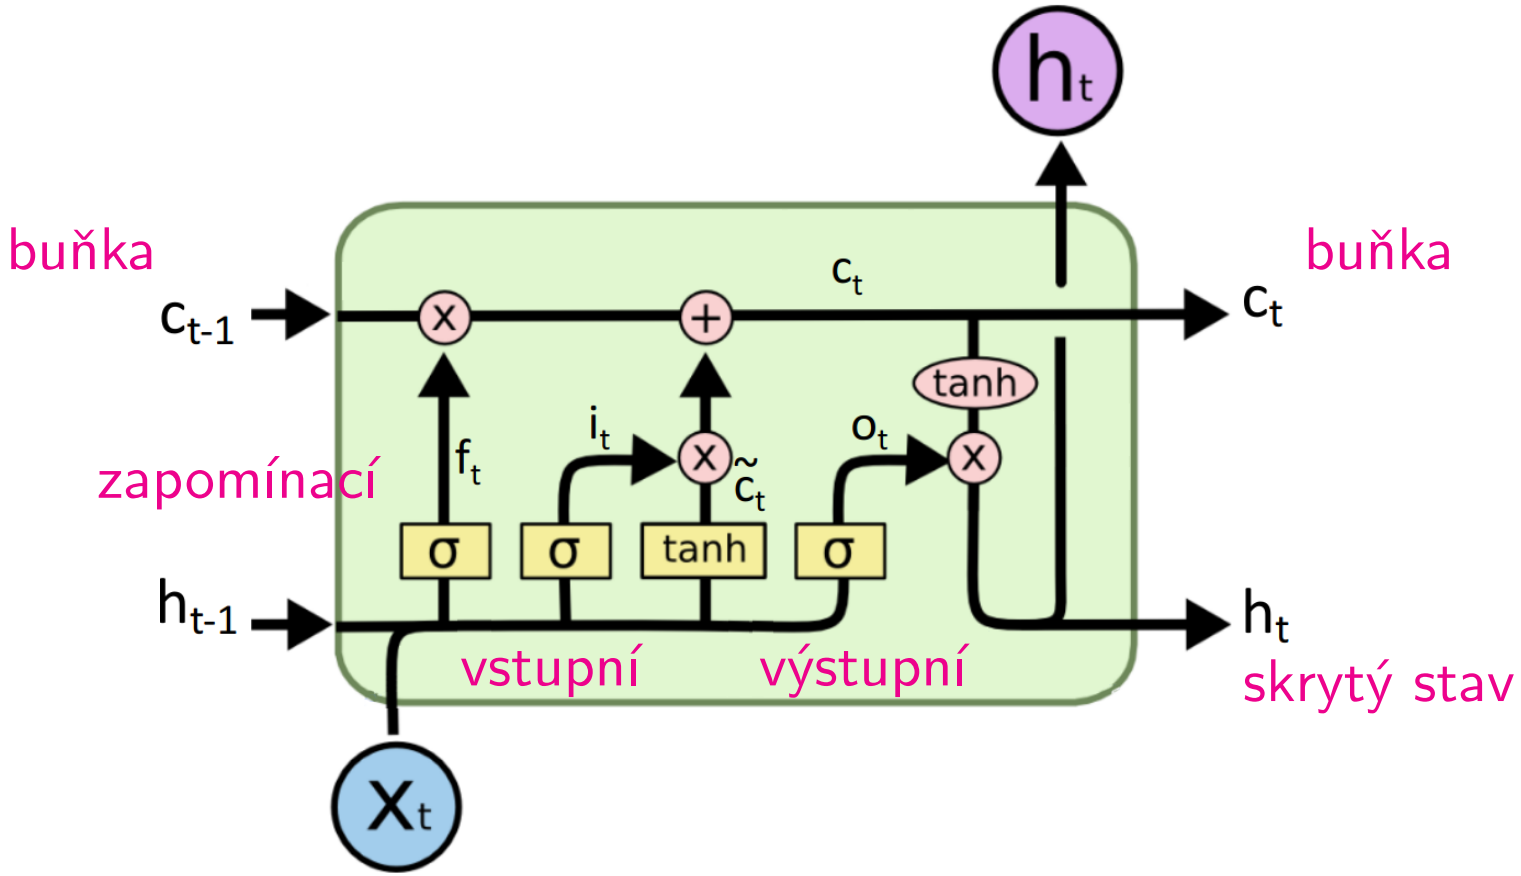

Architektura Long Short-Term Memory (LSTM)

hlavní výhoda LSTM – schopnost nalézt vzdálené závislosti
nevýhody – lineární postup, výpočet nelze paralelizovat

rekurence je směrovaná –
zleva doprava
⇒ jiný důraz při průběhu
zprava doleva

obousměrné (*bidirectional*) BiLSTM
spojení dopředné LSTM
a zpětné LSTM
výstupy se spojí (*concatenate*)
do výsledných vektorů
(2× dimenze)

Architektura Long Short-Term Memory (LSTM)

hlavní výhoda LSTM – schopnost nalézt vzdálené závislosti
nevýhody – lineární postup, výpočet nelze paralelizovat

rekurence je směrovaná –
zleva doprava
⇒ jiný důraz při průběhu
zprava doleva

obousměrné (*bidirectional*) BiLSTM
spojení dopředné LSTM
a zpětné LSTM
výstupy se spojí (*concatenate*)
do výsledných vektorů
(2× dimenze)

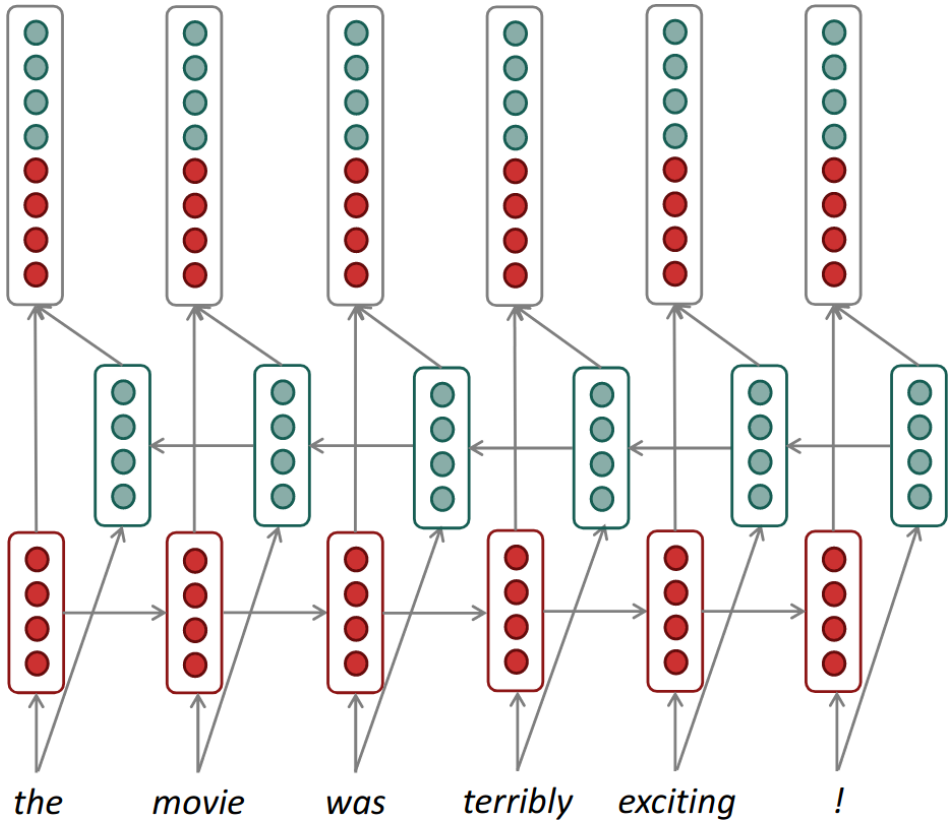

Obsah

Mechanizmus attention

u rekurentních sítí – celá věta reprezentována jako jeden vektor

mechanizmus attention (“pozornost”) – detailní provázání informací

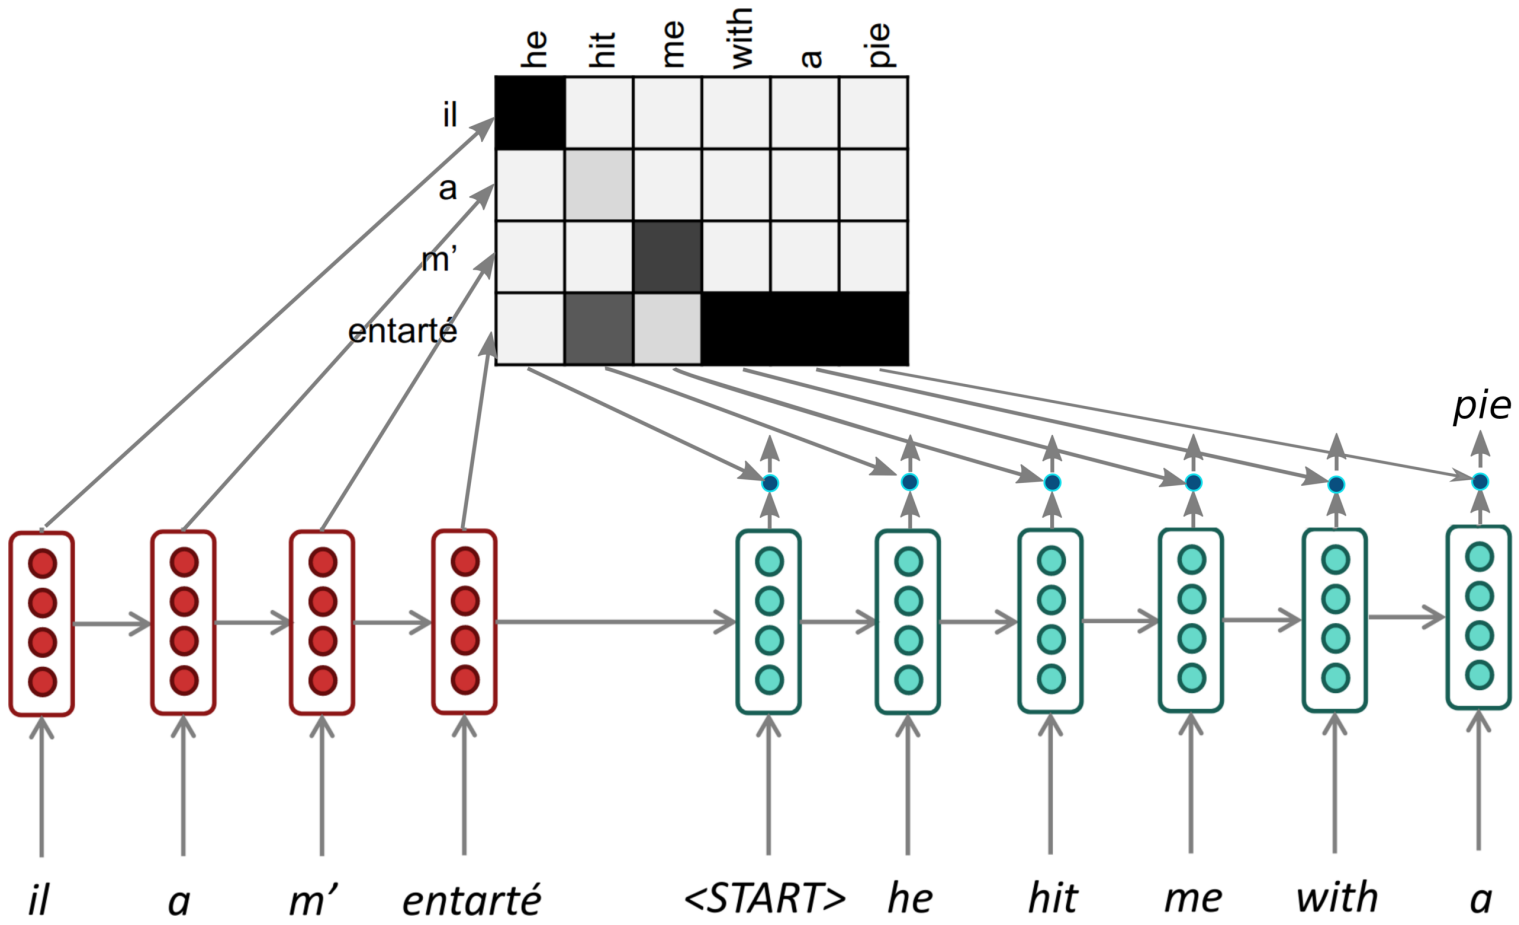

Architektura Transformer

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

Architektura Transformer

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

architektura transformer:

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

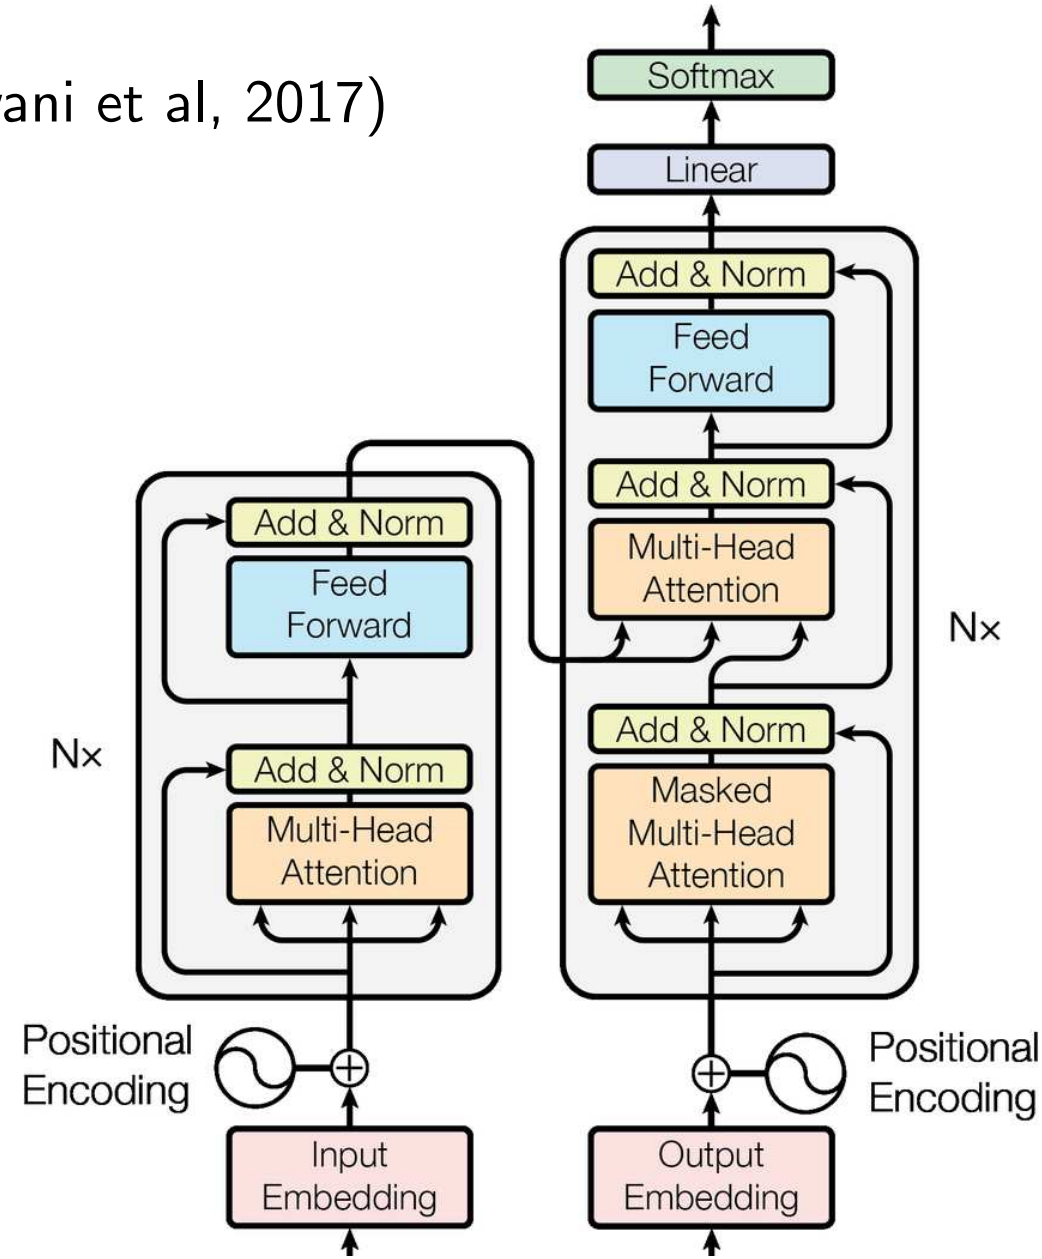

Architektura Transformer

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

architektura transformer:

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

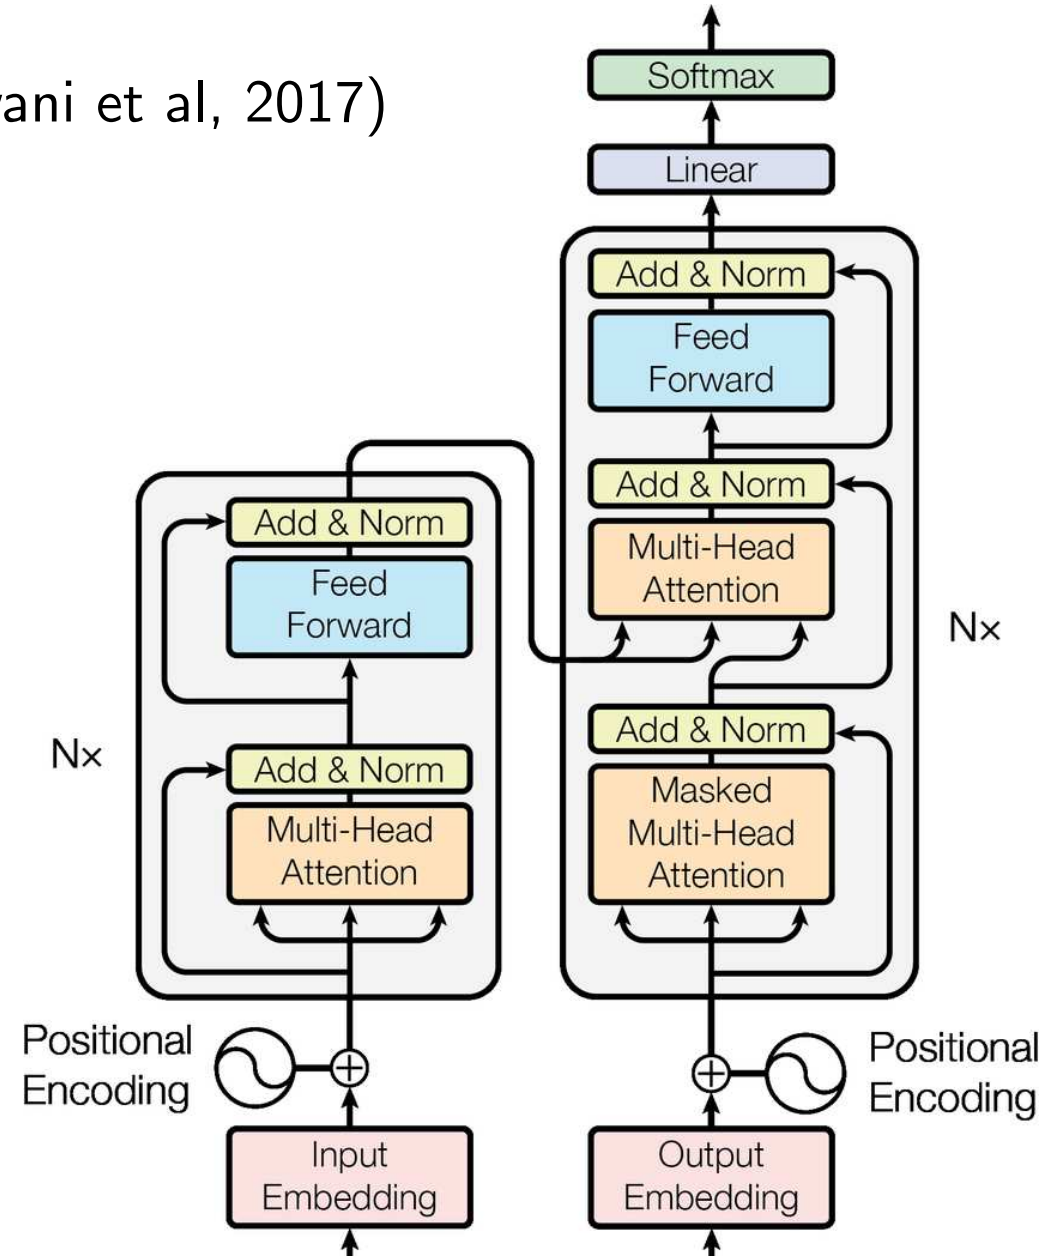

Architektura Transformer

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

architektura transformer:

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

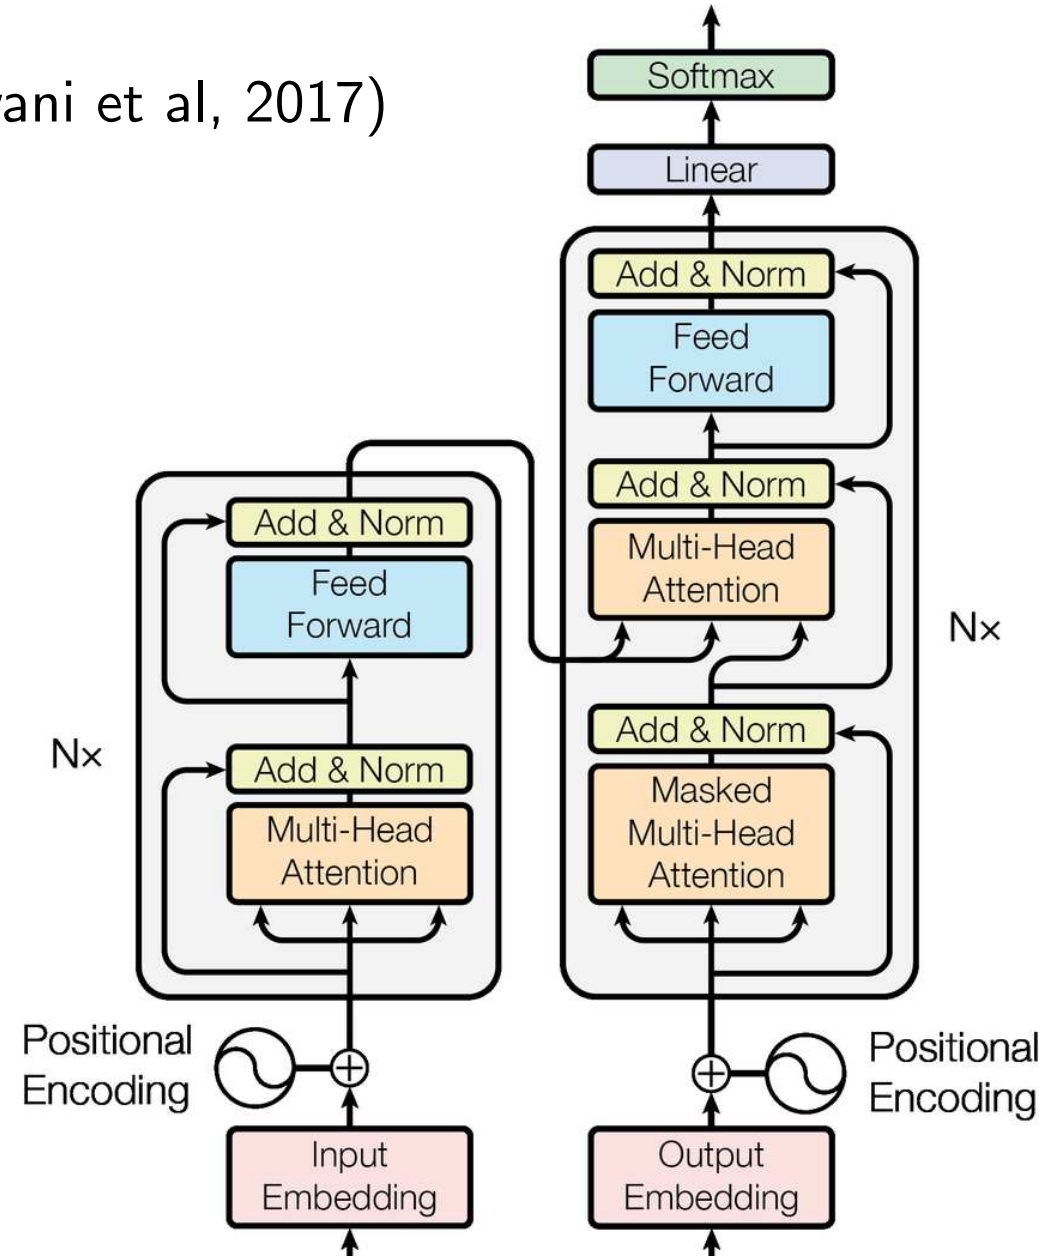

Architektura Transformer

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

architektura transformer:

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

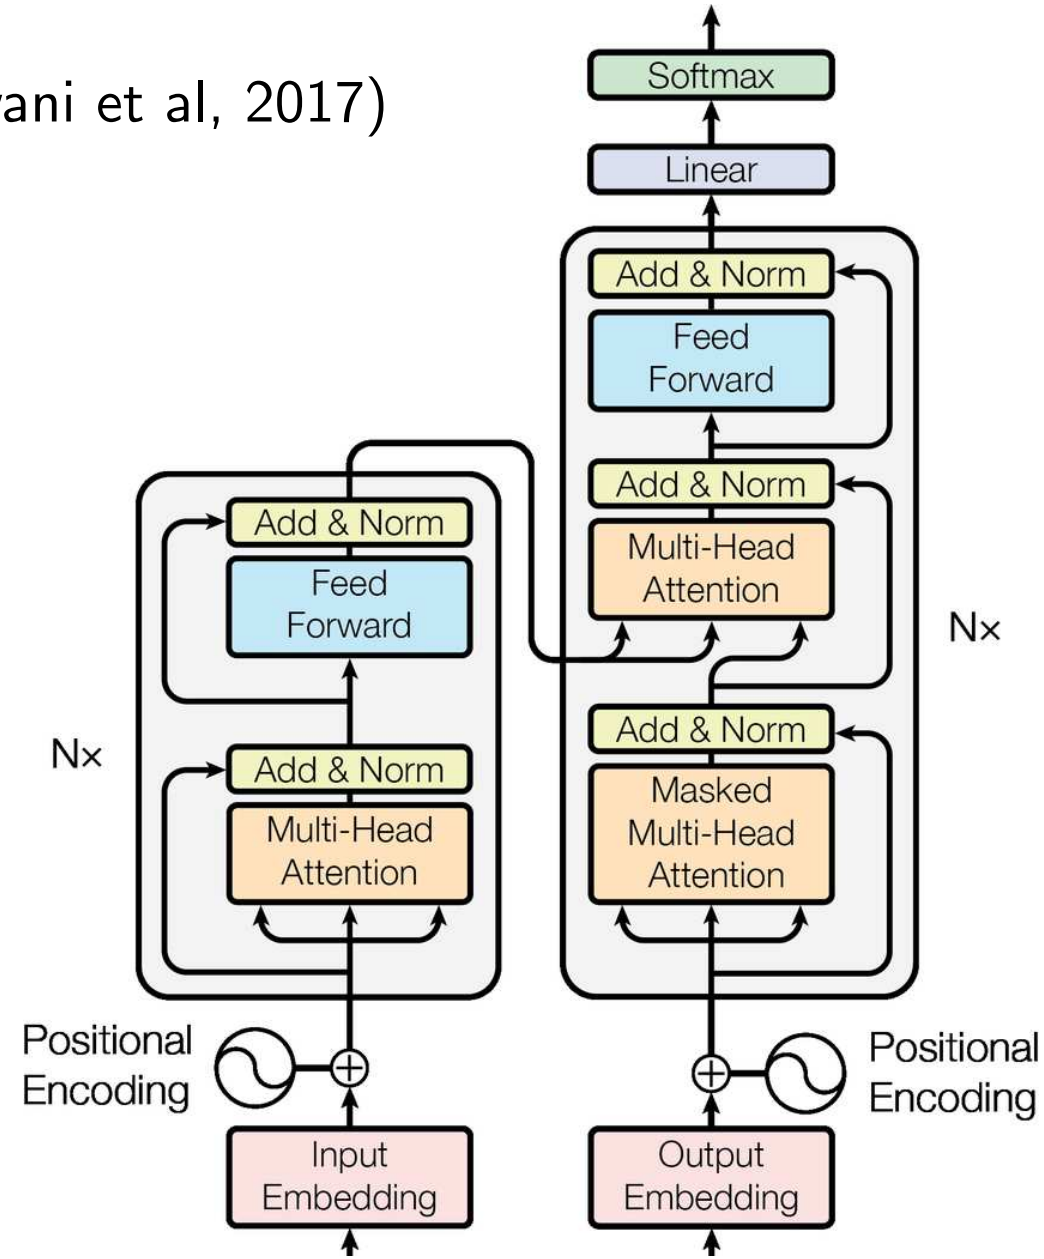

Architektura Transformer

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

architektura transformer:

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

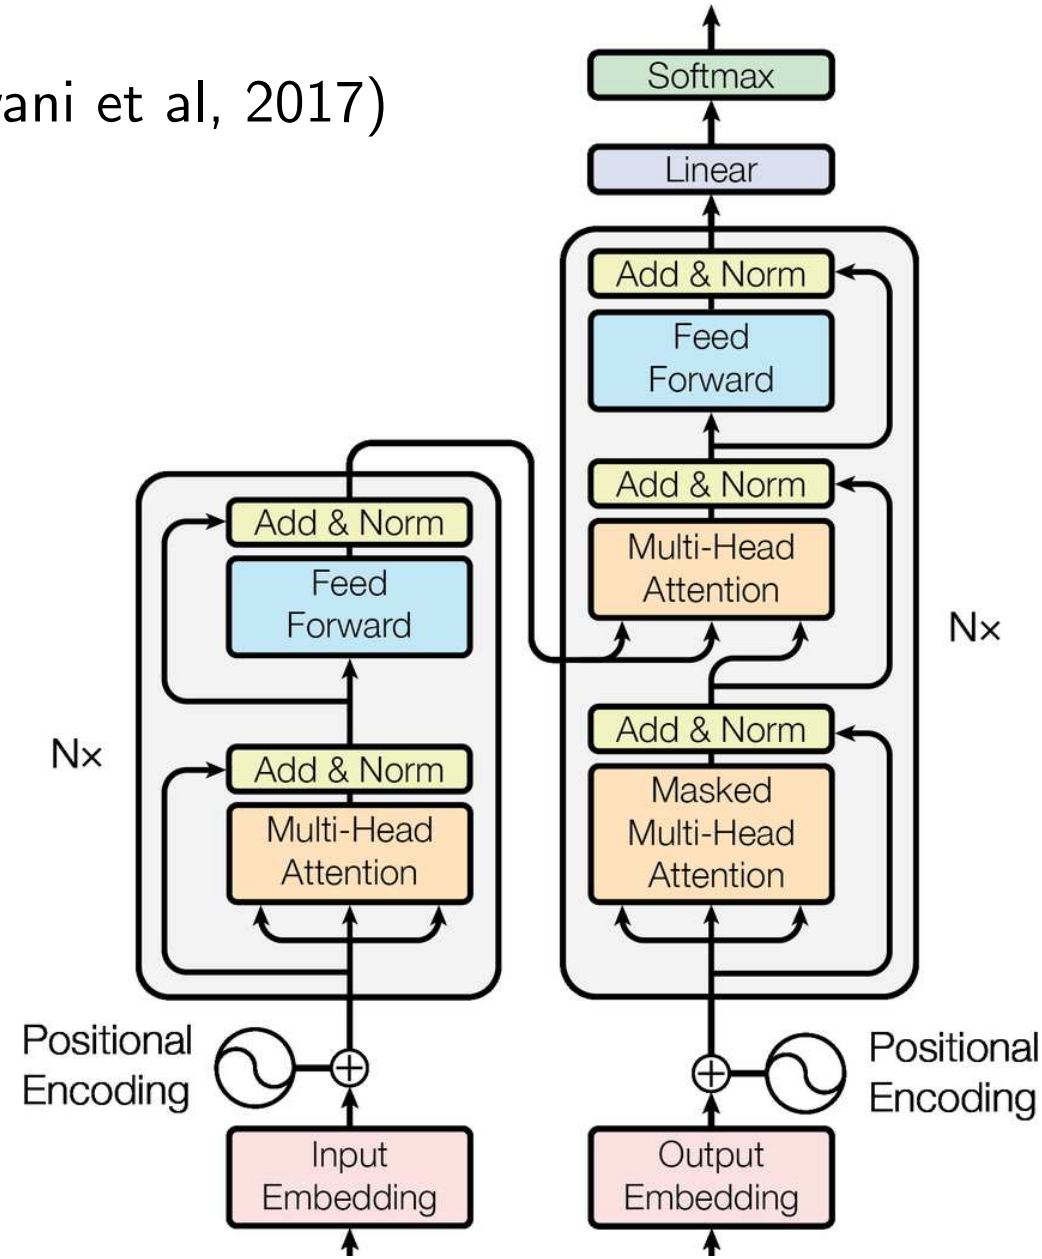

Architektura Transformer

výhody:

- základ pokročilých jazykových modelů s předtrénováním
- aktuálně nejlepší výsledky téměř ve všech NLP úlohách
- trénování je dobře paralelizovatelné

nevýhody:

- kvadratický výpočet (plné) self-attention
  vs. lineární růst u rekurentních modelů
  návrhy – random attention, window attention, ...
- lineární reprezentace pozice
  návrhy – relativní pozice, syntaktická pozice, ...

Architektura Transformer

výhody:

- základ pokročilých jazykových modelů s předtrénováním
- aktuálně nejlepší výsledky téměř ve všech NLP úlohách
- trénování je dobře paralelizovatelné

nevýhody:

- kvadratický výpočet (plné) self-attention
  vs. lineární růst u rekurentních modelů
  návrhy – random attention, window attention, ...
- lineární reprezentace pozice
  návrhy – relativní pozice, syntaktická pozice, ...

Architektura Transformer

výhody:

- základ pokročilých jazykových modelů s předtrénováním
- aktuálně nejlepší výsledky téměř ve všech NLP úlohách
- trénování je dobře paralelizovatelné

nevýhody:

- kvadratický výpočet (plné) self-attention
  vs. lineární růst u rekurentních modelů
  návrhy – random attention, window attention, ...
- lineární reprezentace pozice
  návrhy – relativní pozice, syntaktická pozice, ...

Architektura Transformer

výhody:

- základ pokročilých jazykových modelů s předtrénováním
- aktuálně nejlepší výsledky téměř ve všech NLP úlohách
- trénování je dobře paralelizovatelné

nevýhody:

- kvadratický výpočet (plné) self-attention
  vs. lineární růst u rekurentních modelů
  návrhy – random attention, window attention, ...
- lineární reprezentace pozice
  návrhy – relativní pozice, syntaktická pozice, ...

Architektura Transformer

výhody:

- základ pokročilých jazykových modelů s předtrénováním
- aktuálně nejlepší výsledky téměř ve všech NLP úlohách
- trénování je dobře paralelizovatelné

nevýhody:

- kvadratický výpočet (plné) self-attention
  vs. lineární růst u rekurentních modelů
  návrhy – random attention, window attention, ...
- lineární reprezentace pozice
  návrhy – relativní pozice, syntaktická pozice, ...

BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

- jen enkodér
- symboly `[CLS]`, `[SEP]` a `[MASK]`
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty (*Next Sentence Prediction*)
  u ALBERT predikce pořadí vět (*Sentence Order Prediction*)

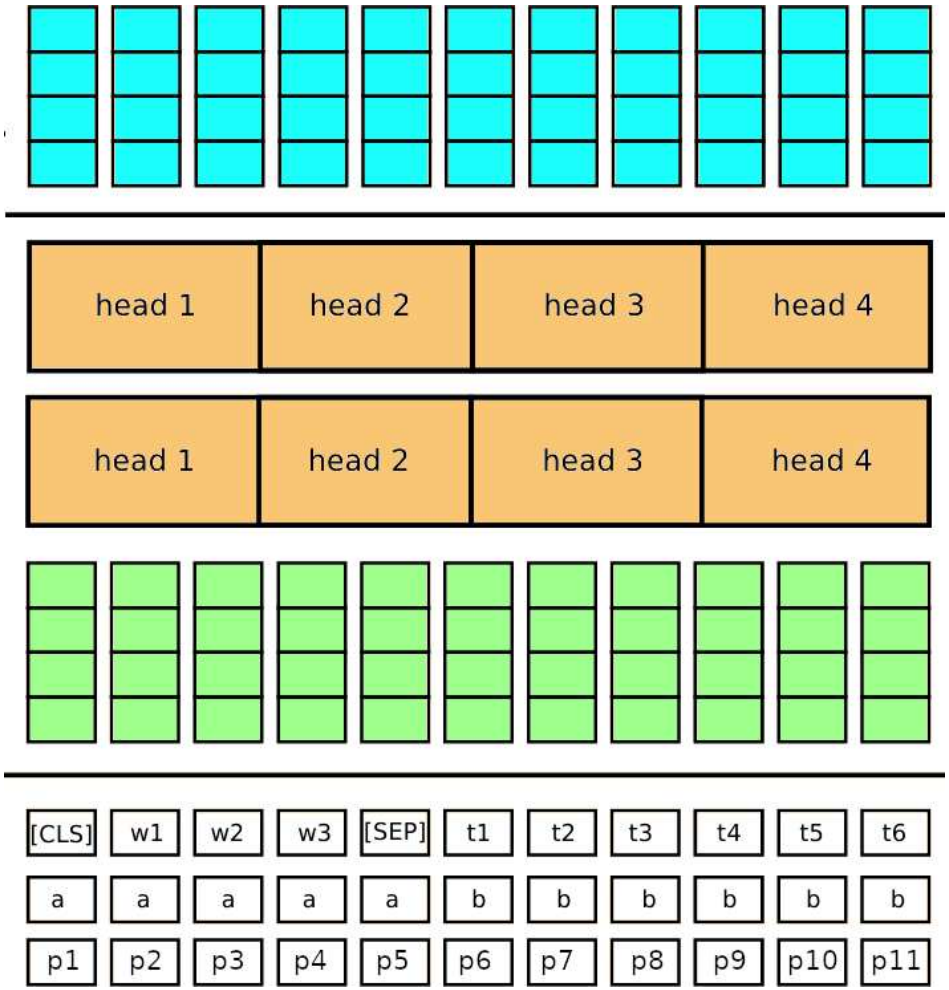

BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

- jen enkodér
- symboly `[CLS]`, `[SEP]` a `[MASK]`
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty (*Next Sentence Prediction*)
  u ALBERT predikce pořadí vět (*Sentence Order Prediction*)

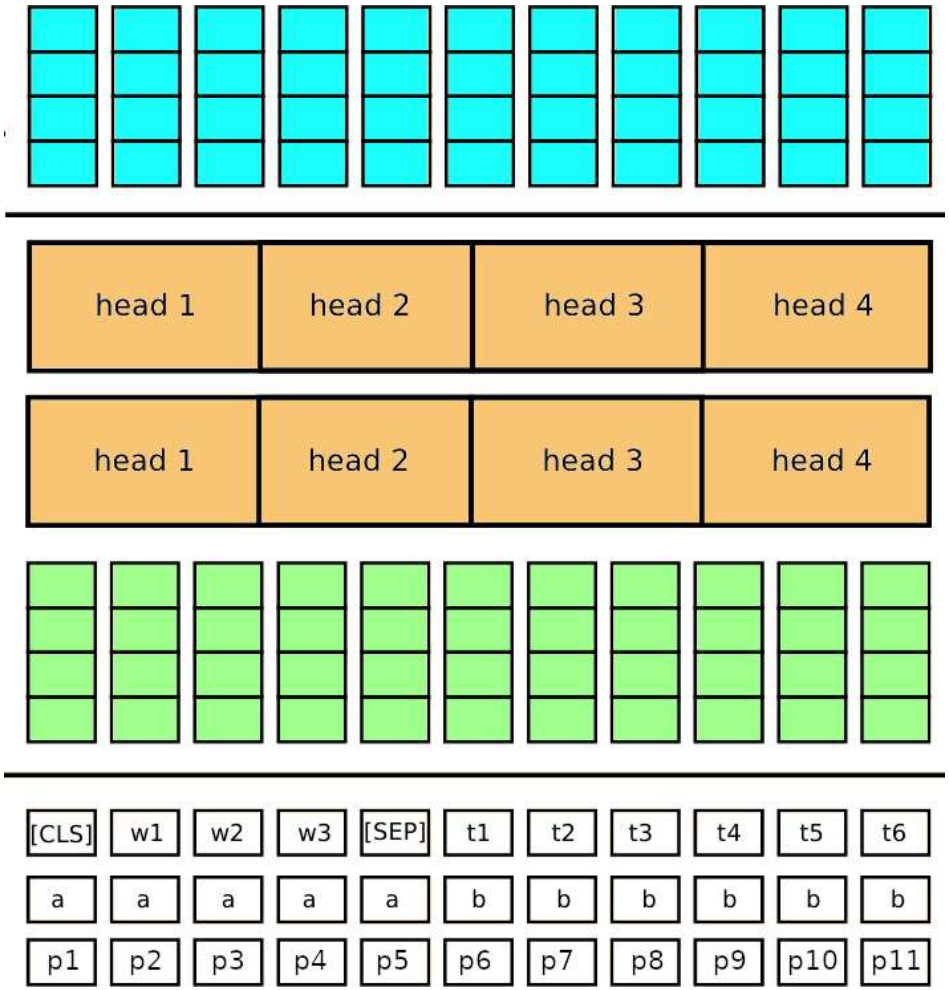

BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

- jen enkodér
- symboly `[CLS]`, `[SEP]` a `[MASK]`
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty (*Next Sentence Prediction*)
  u ALBERT predikce pořadí vět (*Sentence Order Prediction*)

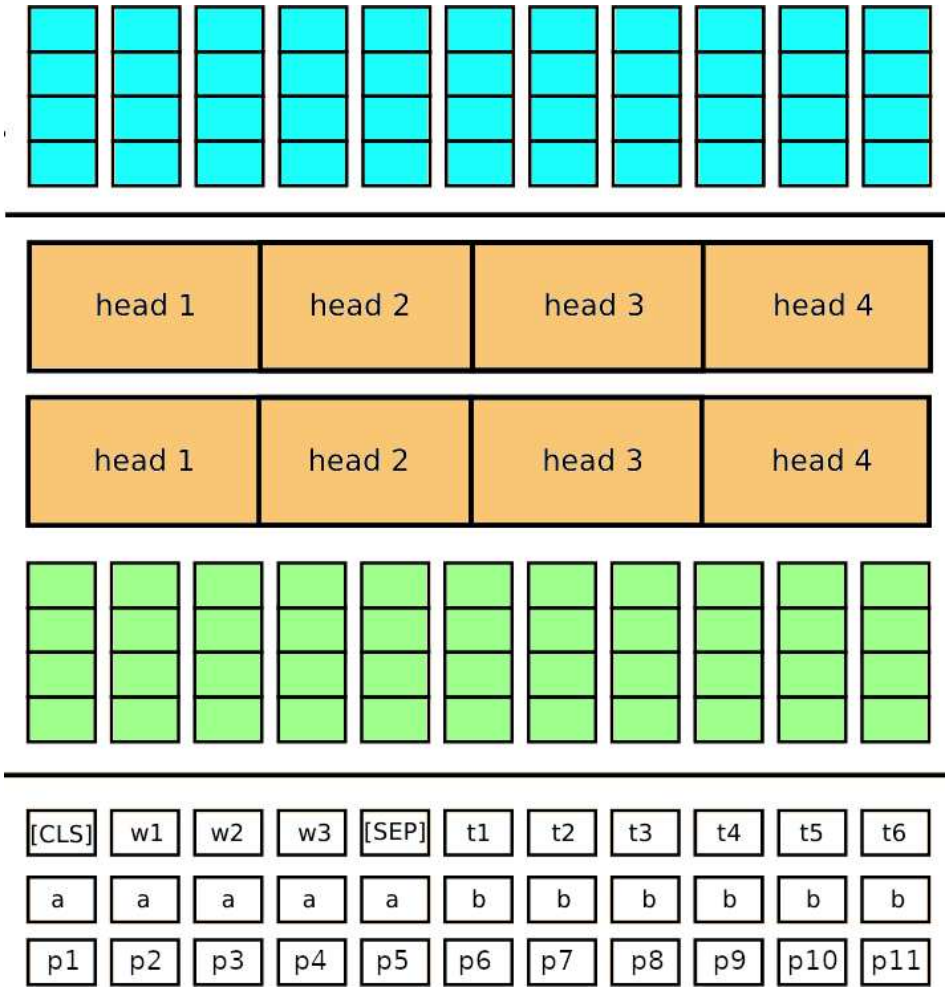

BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

- jen enkodér
- symboly `[CLS]`, `[SEP]` a `[MASK]`
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty (*Next Sentence Prediction*)
  u ALBERT predikce pořadí vět (*Sentence Order Prediction*)

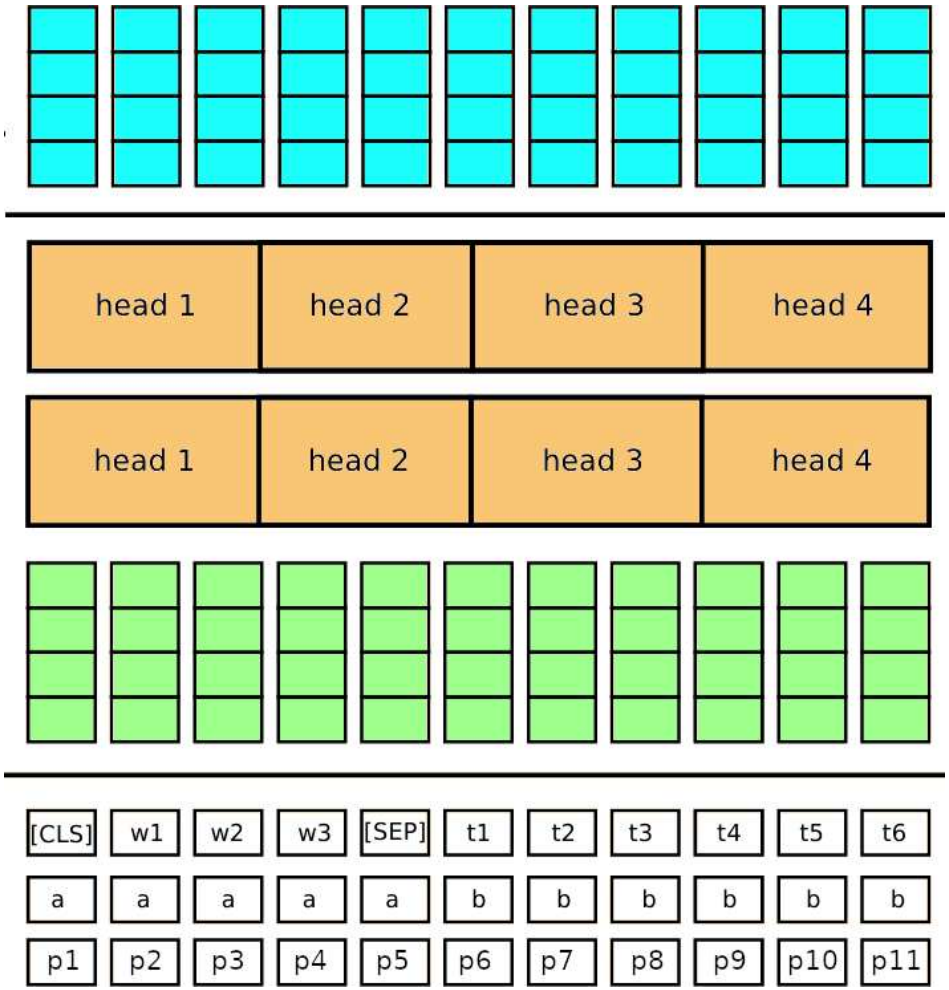

BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

- jen enkodér
- symboly `[CLS]`, `[SEP]` a `[MASK]`
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty (*Next Sentence Prediction*)
  u ALBERT predikce pořadí vět (*Sentence Order Prediction*)

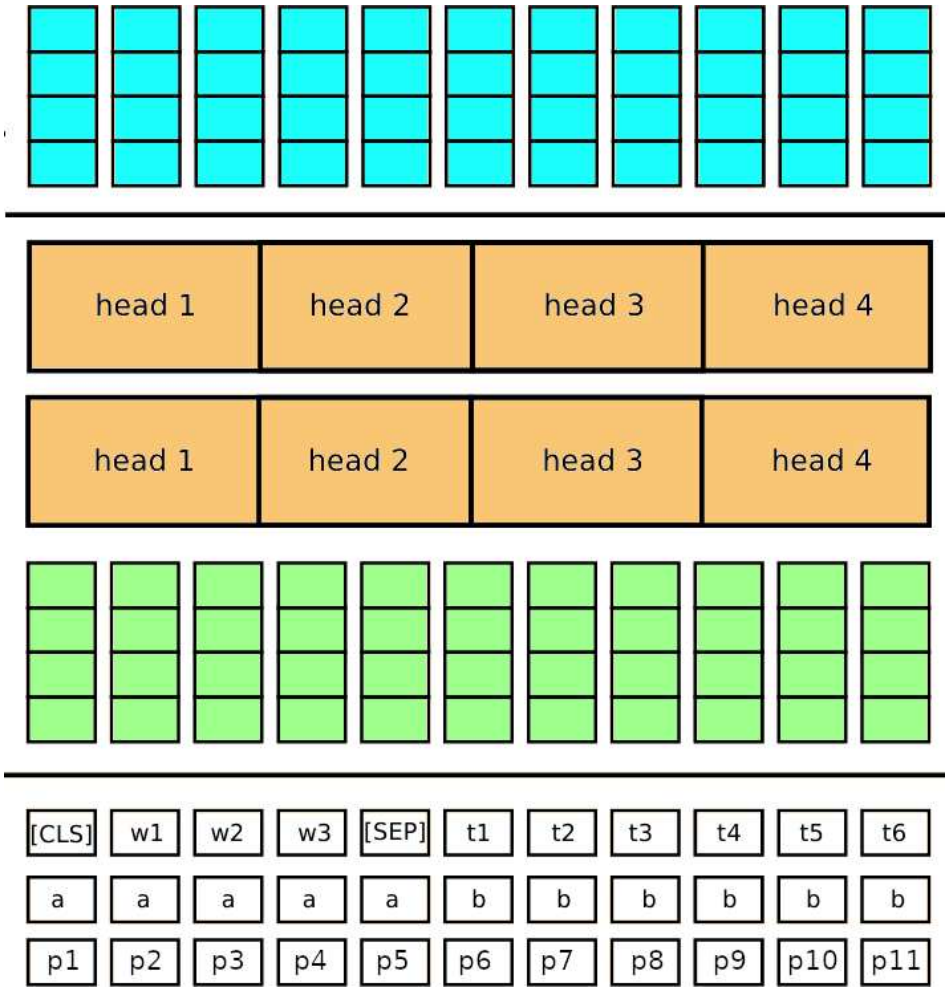

BERT – předtrénování a vyladění

pro většinu úloh se BERT trénuje ve dvou fázích:

- předtrénování (*pre-training*) – na obecných velkých textech
- vyladění (*fine-tuning*) – dotrénování klasifikace pro konkrétní úlohu

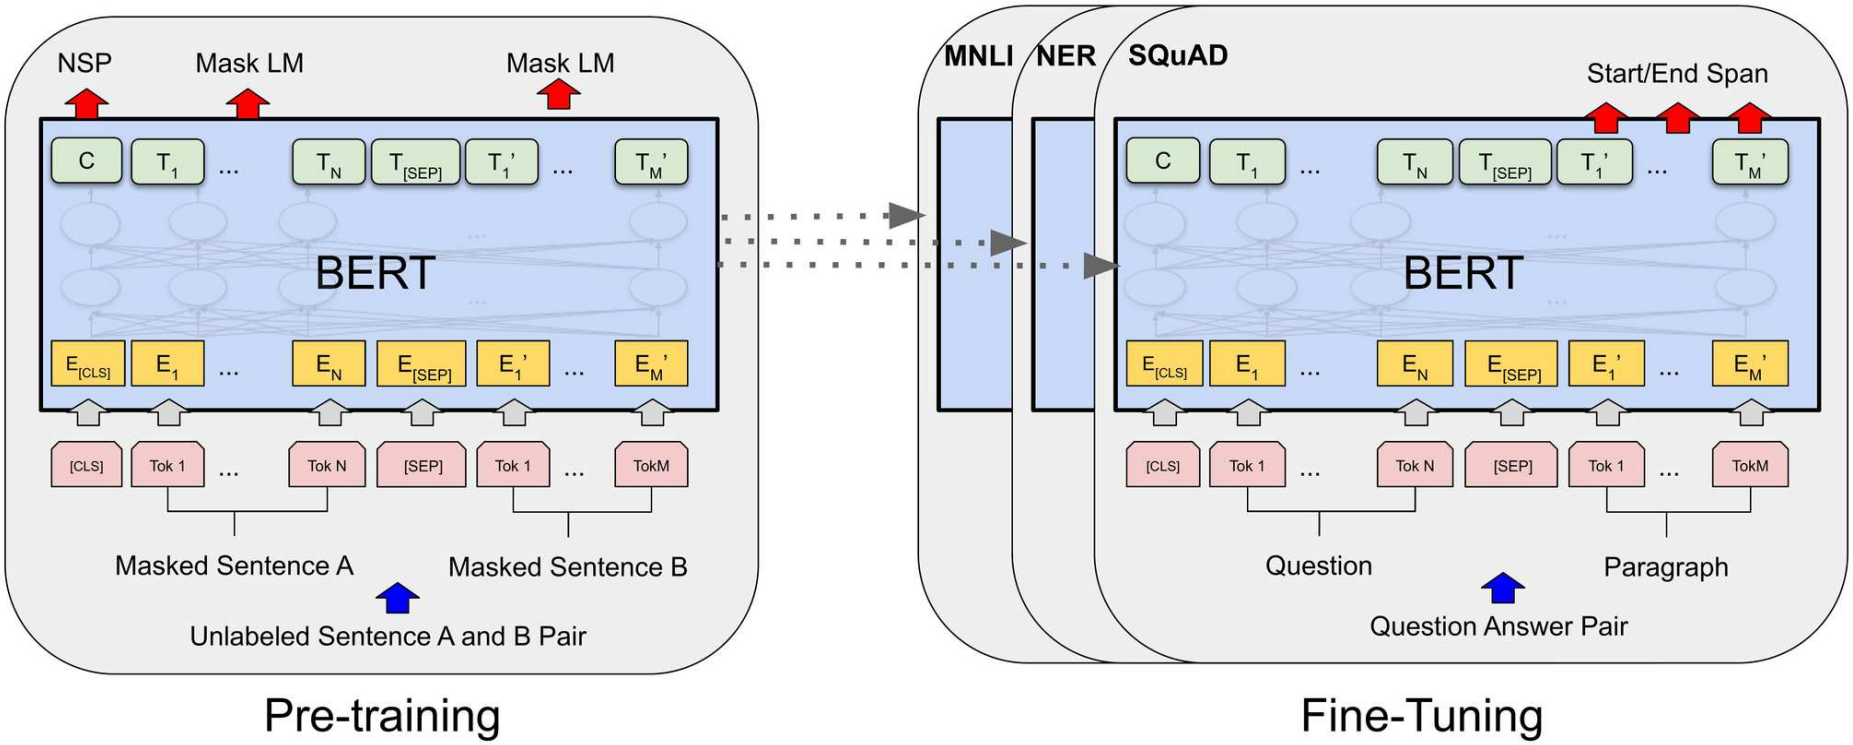

GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství variant architektury transformer podle

- doplnění vstupních vektorů
- techniky předtrénování
- obsahu a velikosti textů pro trénování

většinou platí: větší model → lepší výsledky

SliDo

GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství variant architektury transformer podle

- doplnění vstupních vektorů
- techniky předtrénování
- obsahu a velikosti textů pro trénování

většinou platí: větší model → lepší výsledky

SliDo

GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství variant architektury transformer podle

- doplnění vstupních vektorů
- techniky předtrénování
- obsahu a velikosti textů pro trénování

většinou platí: větší model → lepší výsledky

SliDo

GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství variant architektury transformer podle

- doplnění vstupních vektorů
- techniky předtrénování
- obsahu a velikosti textů pro trénování

většinou platí: větší model → lepší výsledky

SliDo

GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství variant architektury transformer podle

- doplnění vstupních vektorů
- techniky předtrénování
- obsahu a velikosti textů pro trénování

většinou platí: větší model → lepší výsledky

SliDo

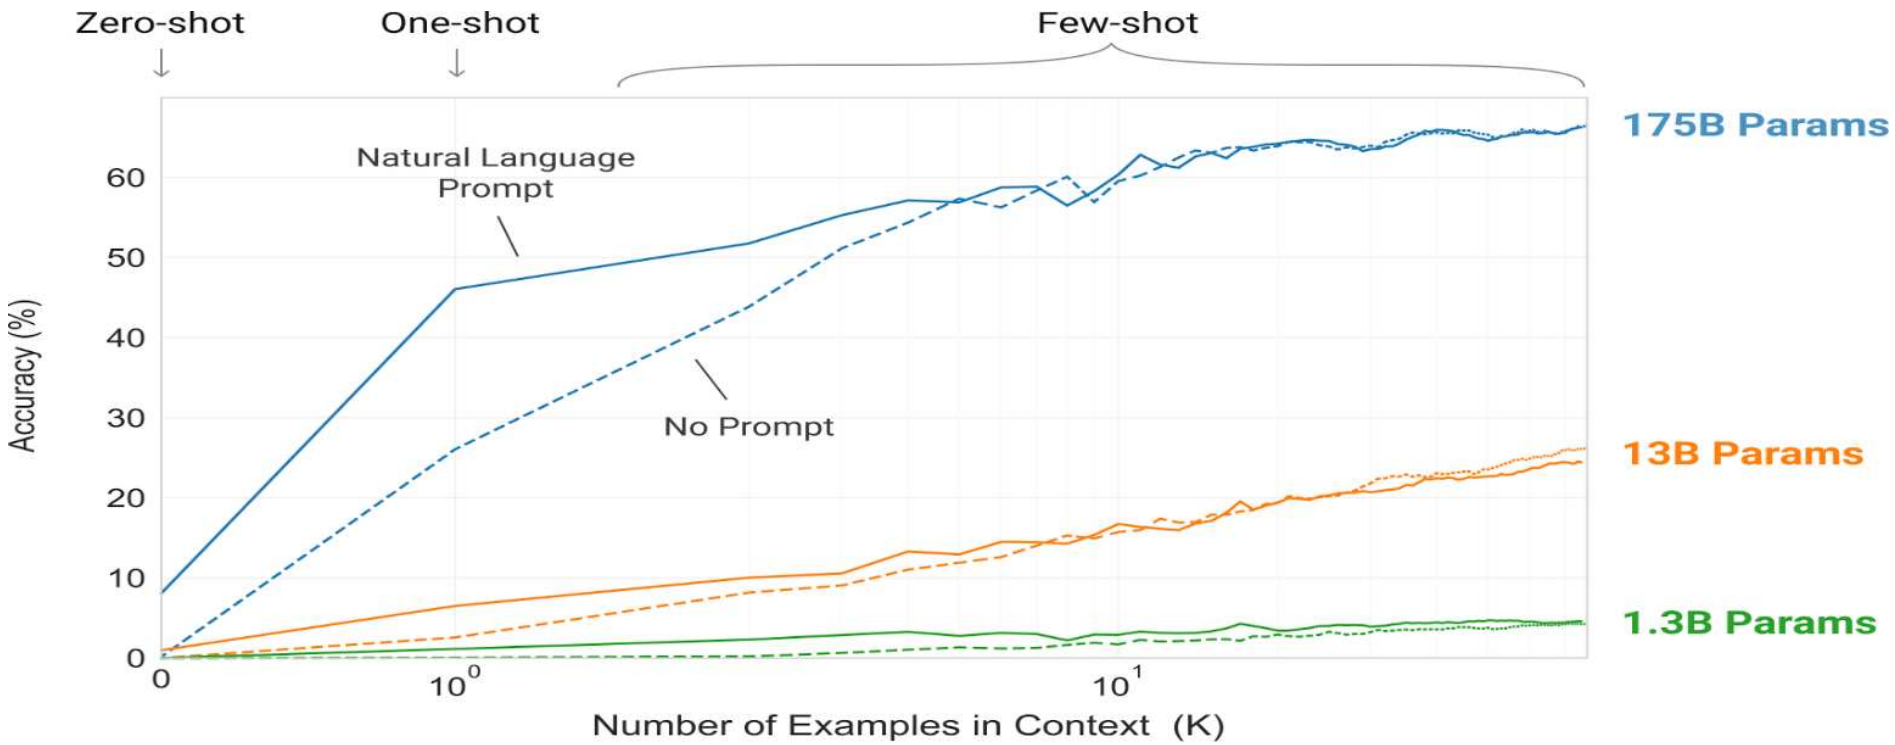

Vyladění s málo příklady

velkým modelům stačí vyladění s málo příklady (*few-shot learning*):

- bez příkladů (*zero-shot*)

```
Translate English to French:
cheese =>
```

- jeden příklad (*one-shot*)

```
Translate English to French:
sea otter => loutre de mer
cheese =>
```

- málo příkladů (*few-shot*)

```
Translate English to French:
sea otter => loutre de mer
peppermint => menthe poivrée
plush girafe => girafe peluche
cheese =>
```

beta.openai.com/examples

Vyladění s málo příklady

velkým modelům stačí vyladění s málo příklady (*few-shot learning*):

- bez příkladů (*zero-shot*)

```
Translate English to French:
cheese =>
```

- jeden příklad (*one-shot*)

```
Translate English to French:
sea otter => loutre de mer
cheese =>
```

- málo příkladů (*few-shot*)

```
Translate English to French:
sea otter => loutre de mer
peppermint => menthe poivrée
plush girafe => girafe peluche
cheese =>
```

beta.openai.com/examples

Vyladění s málo příklady

velkým modelům stačí vyladění s málo příklady (*few-shot learning*):

- bez příkladů (*zero-shot*)

```
Translate English to French:
cheese =>
```

- jeden příklad (*one-shot*)

```
Translate English to French:
sea otter => loutre de mer
cheese =>
```

- málo příkladů (*few-shot*)

```
Translate English to French:
sea otter => loutre de mer
peppermint => menthe poivrée
plush girafe => girafe peluche
cheese =>
```

beta.openai.com/examples