

Hluboké učení pro zpracování jazyka

Aleš Horák

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

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

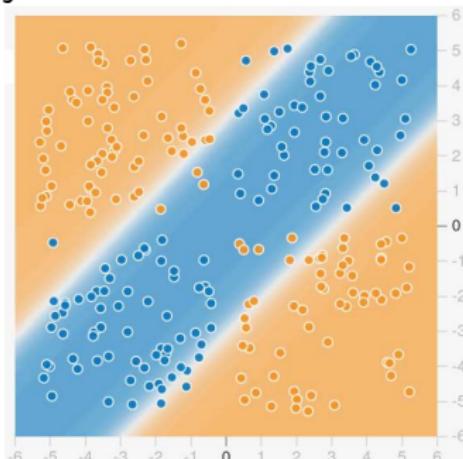
Klasické neuronové sítě a text

Neuronové sítě:

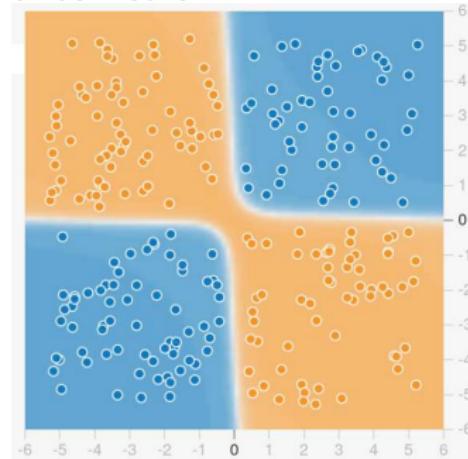
- od 1943 – McCulloch & Pitts – matematický model neuronu
- 1965 – první praktická vícevrstvá dopředná síť
- 1982 – praktická implementace zpětného šíření chyby pro trénování vícevrstvých sítí

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:

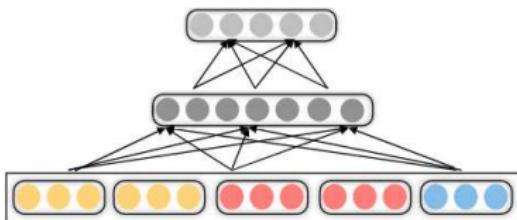
$$\langle 1, 0, 0, 0, \dots \rangle$$

$$\langle 0, 1, 0, 0, \dots \rangle$$

- 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
⇒ **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:

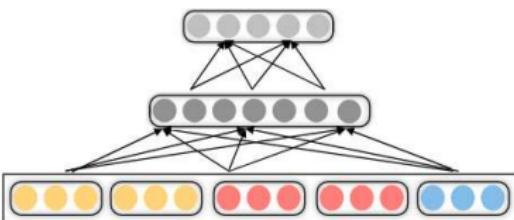
$$\langle 1, 0, 0, 0, \dots \rangle$$

$$\langle 0, 1, 0, 0, \dots \rangle$$

- pevně daná (maximální) **délka vstupu** m

- vstup sítě – $m \times n$

- **není vhodné** pro velké slovníky



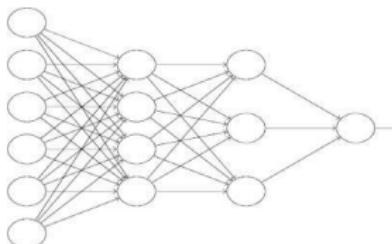
2. slova jako **slovní vektory** (*word embeddings*):

- stanovení **pevné dimenze**
- **předpočítání/předtrénování** na velmi velkých neanotovaných textech
⇒ **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

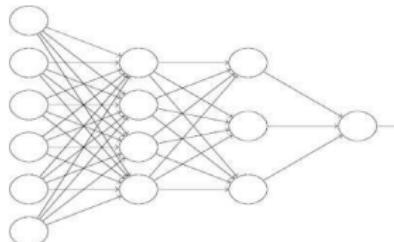


- cca od 2000 – metody a HW (GPU karty) pro učení sítí, které se skládají z mnoha (až desítek) heterogenních vrstev: konvoluční, sdružující (*max pooling*), rekurentní, klasifikační (*soft max*), ...

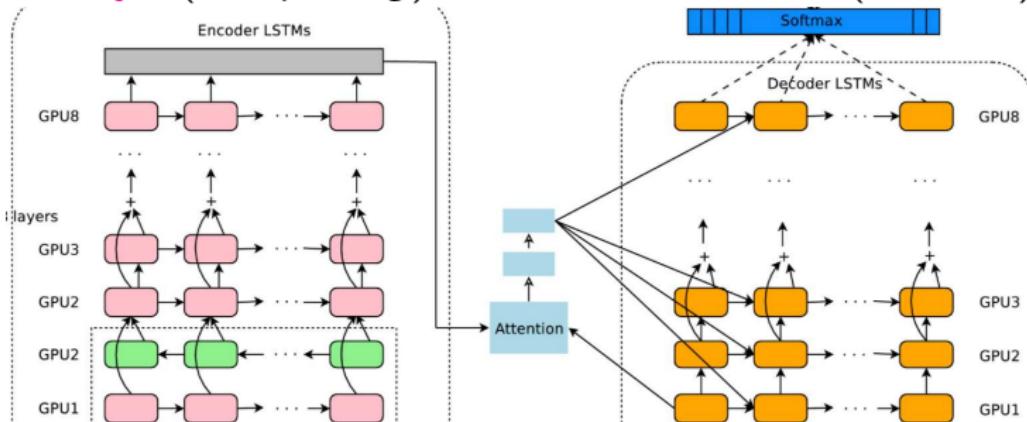
Hluboké učení

Hluboké neuronové sítě:

- dopředné sítě – plně propojené vrstvy



- cca od 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*), ...



Hyperparametry hlubokého učení

Hluboké učení – kromě architektury sítě i množství **hyperparametrů**:

- **regularizace** (např. L2-regularizace) – brání přeúčení 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*)
vetší 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 **rychlosť 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 přeúčení 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*)
vetší 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 rychlosť 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 přeúčení 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*)
vetší 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 rychlosť 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 přeúčení 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*)
vetší 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 **rychlosť 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 přeúčení 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*)
vetší 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 **rychlosť 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 přeúčení 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*)
vetší 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 rychlosť 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

Obsah

1 Od klasických k hlubokým neuronovým sítím

- Klasické neuronové sítě a text
- Hluboké učení

2 Neurální jazykové modely

- S pevným kontextem
- Rekurentní jazykový model
- Praktické využití rekurentních sítí

3 Architektura Long Short-Term Memory (LSTM)

4 Architektura Transformer

- Mechanizmus attention
- Architektura Transformer
- Pokročilé jazykové modely

Neurální jazykový model

připomínka – **jazykový model**:

SliDo

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

$$w_1 w_2 w_3 w_4$$

w_1

w_2

w_3

w_4

Neurální jazykový model

připomínka – **jazykový model**:

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

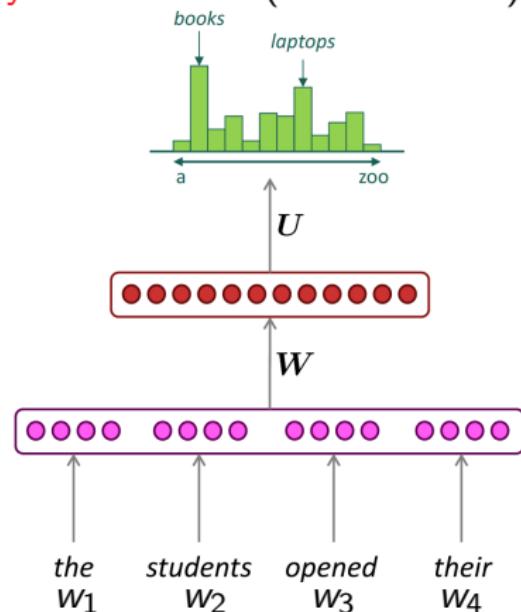
$$h = f(We + b_1)$$

řetězené **vektory slov**

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



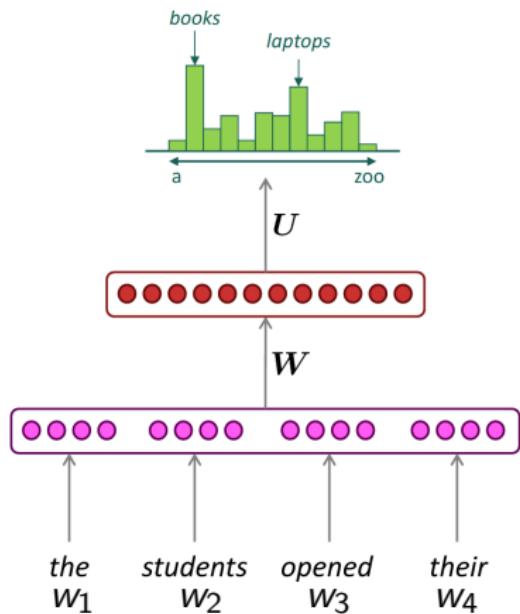
Neurální jazykový model s pevným kontextem

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

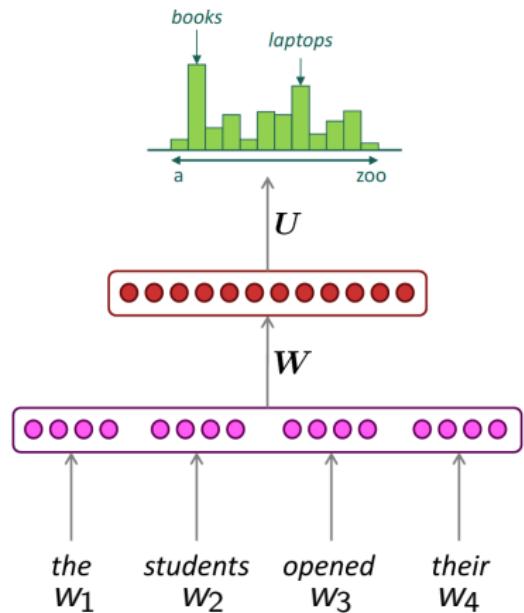
Neurální jazykový model s pevným kontextem

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

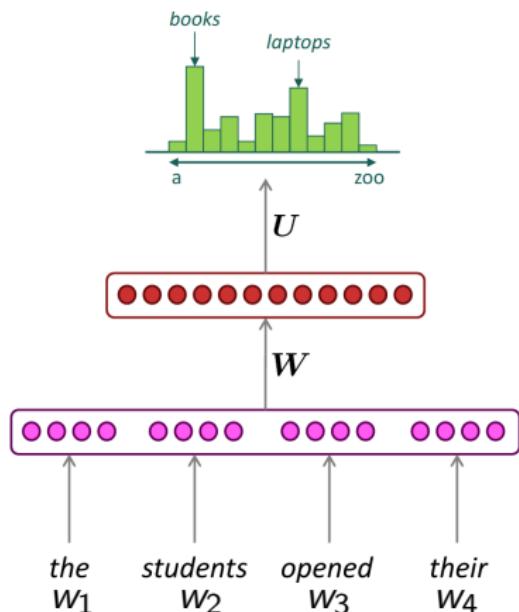
Neurální jazykový model s pevným kontextem

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

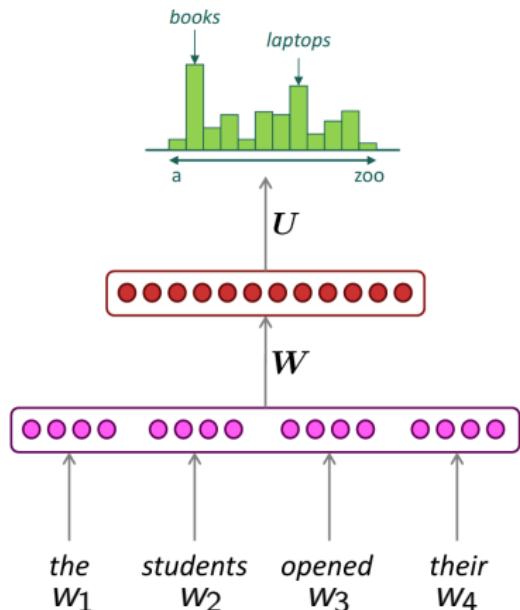
Neurální jazykový model s pevným kontextem

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

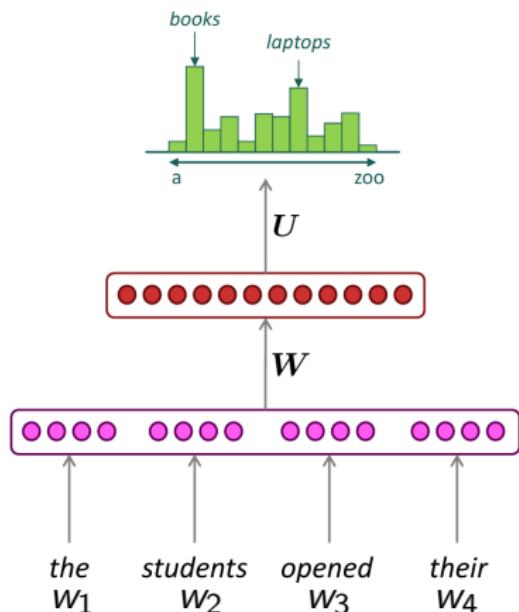
Neurální jazykový model s pevným kontextem

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

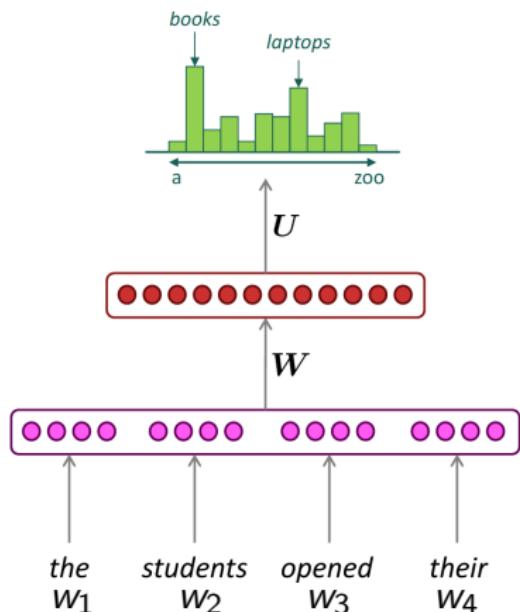
Neurální jazykový model s pevným kontextem

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

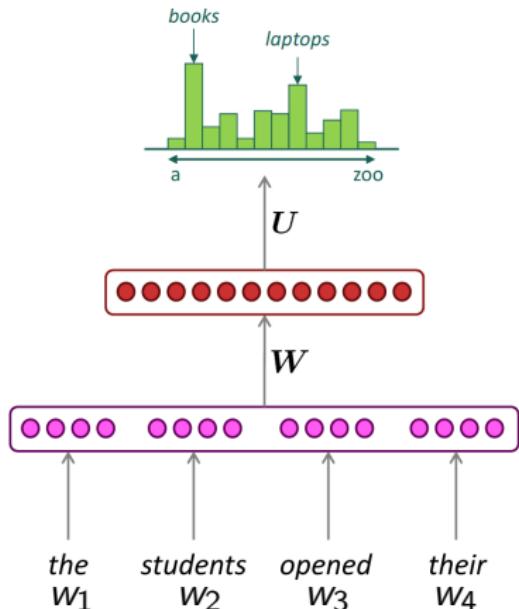
Neurální jazykový model s pevným kontextem

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

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

skryté stavy

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

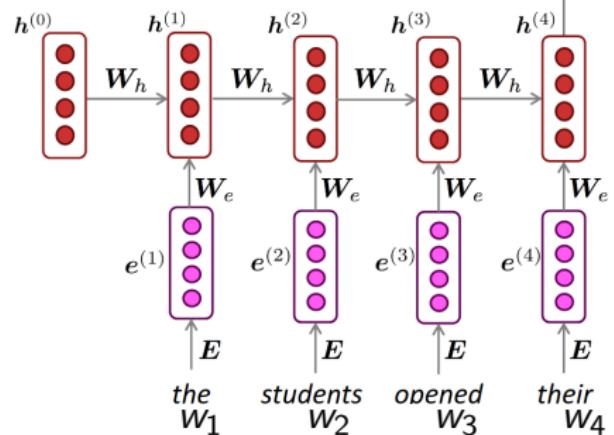
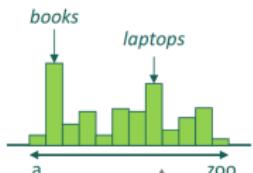
váhy W_h a W_e se aplikují opakováně

jednotlivé vektory slov

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



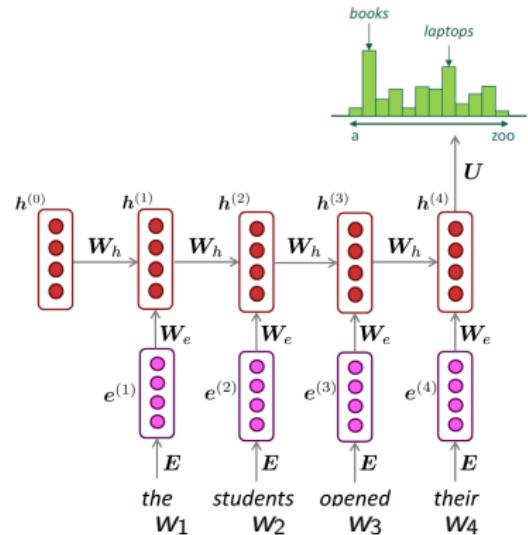
Rekurentní jazykový model

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



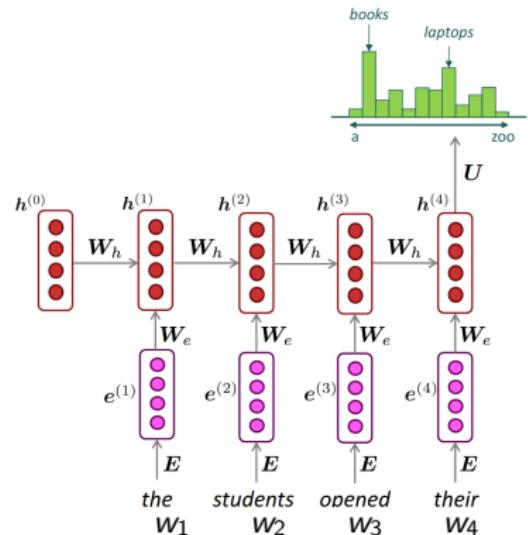
Rekurentní jazykový model

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



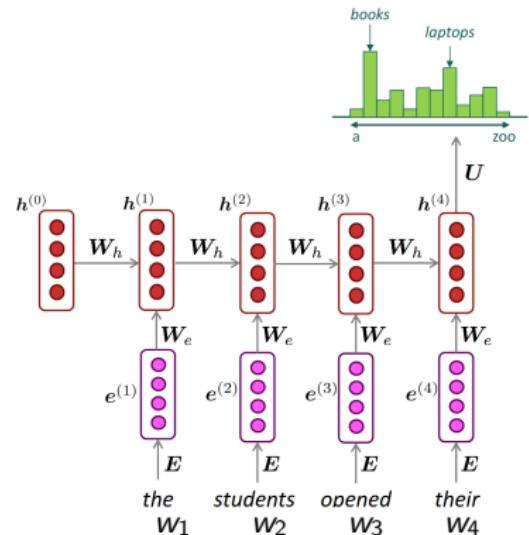
Rekurentní jazykový model

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



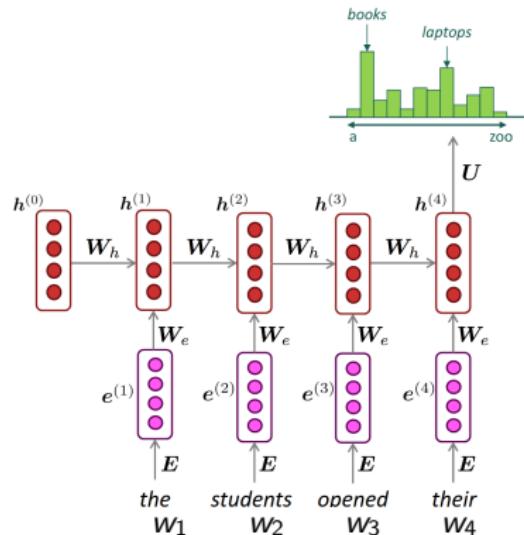
Rekurentní jazykový model

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**



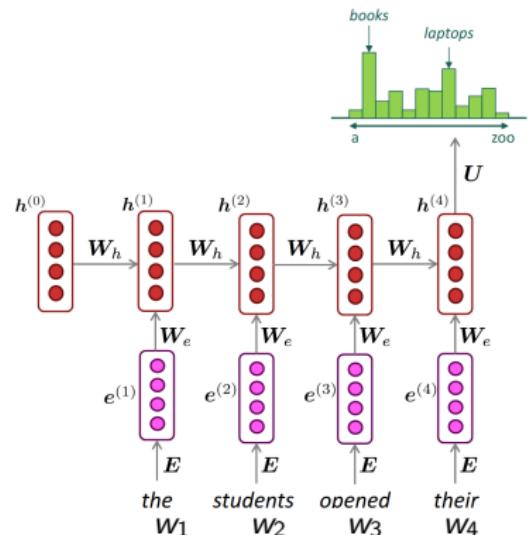
Rekurentní jazykový model

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



Kvalita jazykového modelu

základní **srovnávací metrika – perplexita** (“zmatenosť”):

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

Rekurentní modely → zlepšení perplexity

<i>n</i> -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** (“zmatenosť”):

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

Rekurentní modely → zlepšení perplexity

<i>n</i> -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** (“zmatenosť”):

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

Rekurentní modely → zlepšení perplexity

<i>n</i> -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** (“zmatenosť”):

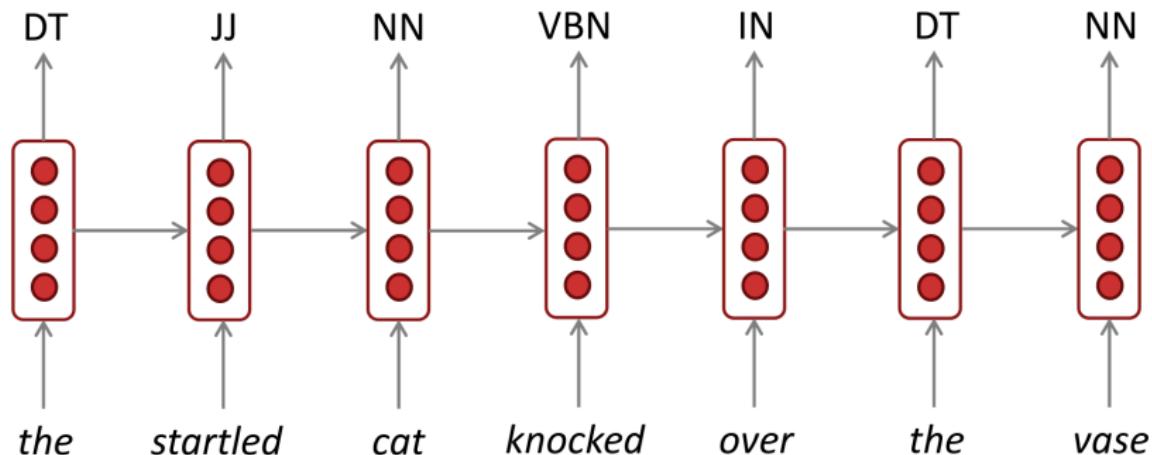
- srovnání na vybraném testovacím textu
- poměrově vyjadřuje z kolika slov se vybírá predikce
- nižší hodnota = lepší perplexita

Rekurentní modely → zlepšení perplexity

<i>n</i> -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

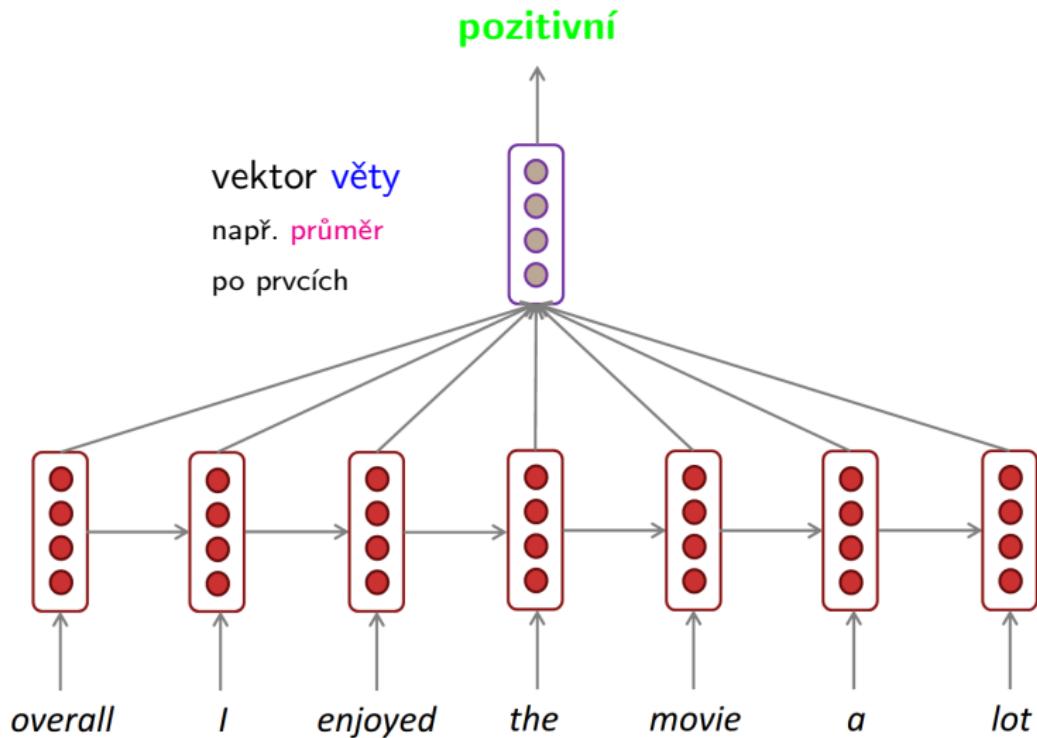
zdroj research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words

Využití rekurentních sítí – značkování



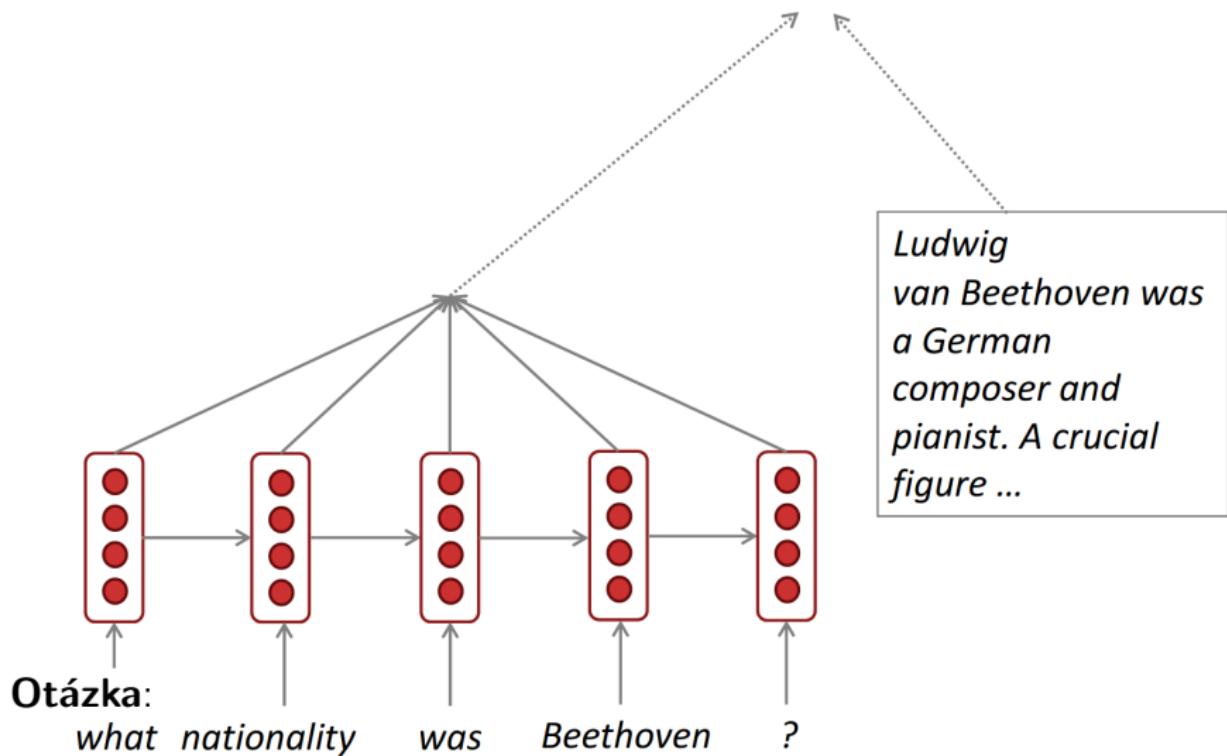
Využití rekurentních sítí – klasifikace vět

např. analýza sentimentu



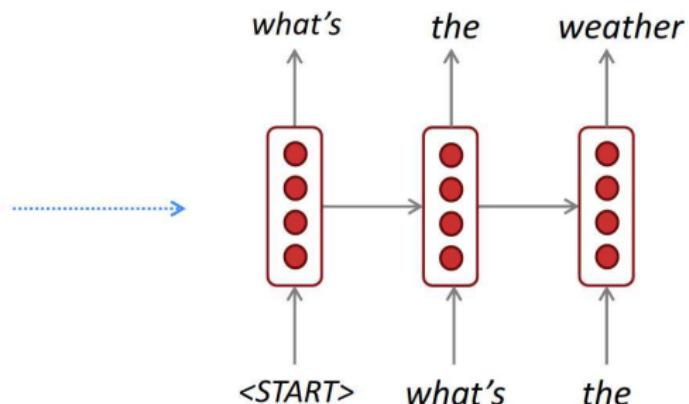
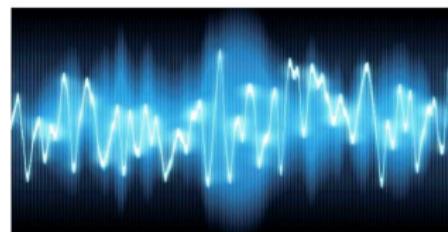
Využití rekurentních sítí – odpovídání na otázky

Odpověď: *German*



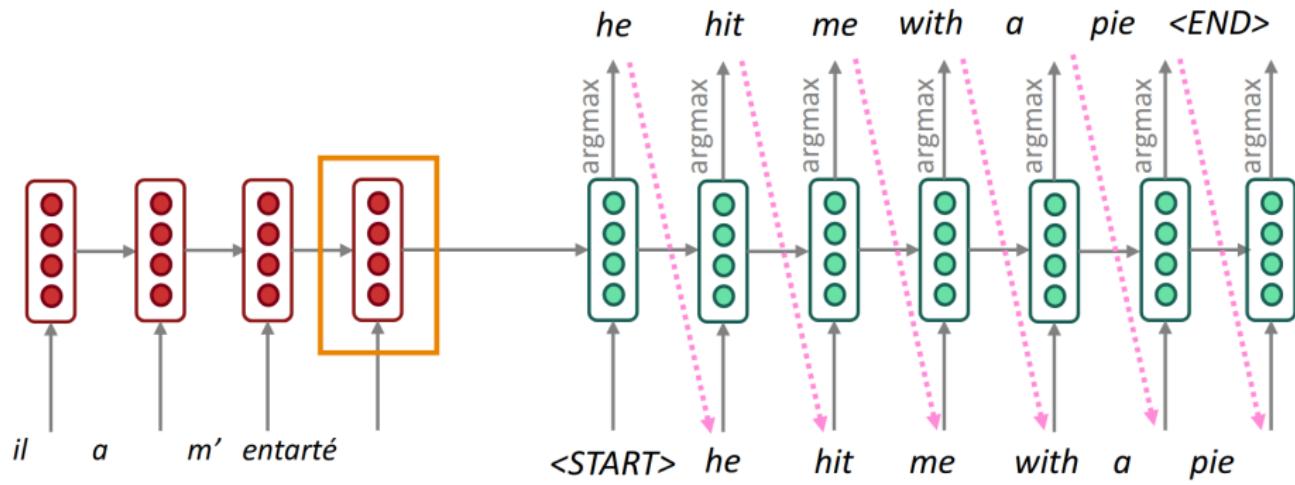
Využití rekurentních sítí – podmíněné generování

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



Využití rekurentních sítí – seq2seq

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



Obsah

1 Od klasických k hlubokým neuronovým sítím

- Klasické neuronové sítě a text
- Hluboké učení

2 Neurální jazykové modely

- S pevným kontextem
- Rekurentní jazykový model
- Praktické využití rekurentních sítí

3 Architektura Long Short-Term Memory (LSTM)

4 Architektura Transformer

- Mechanizmus attention
- Architektura Transformer
- Pokročilé jazykové modely

Architektura Long Short-Term Memory (LSTM)

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

řešení – architektura Long Short-Term Memory, LSTM:

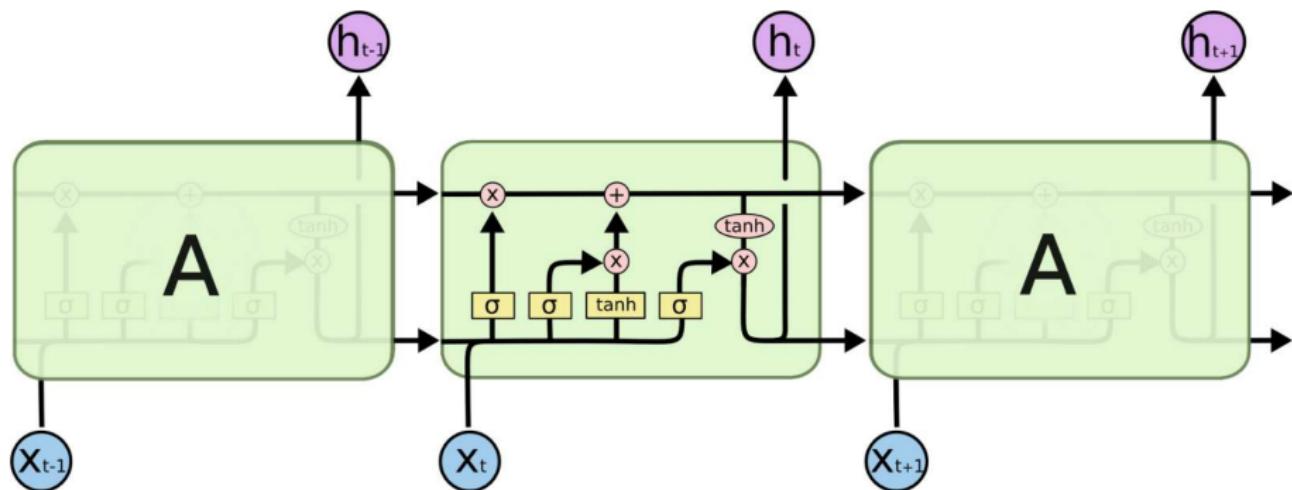
- buňka (*cell*) c_t – pomocná paměť
- 3 brány: vstupní, výstupní a zapomínací (*forget*) – regulace info do a z buňky

Architektura Long Short-Term Memory (LSTM)

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

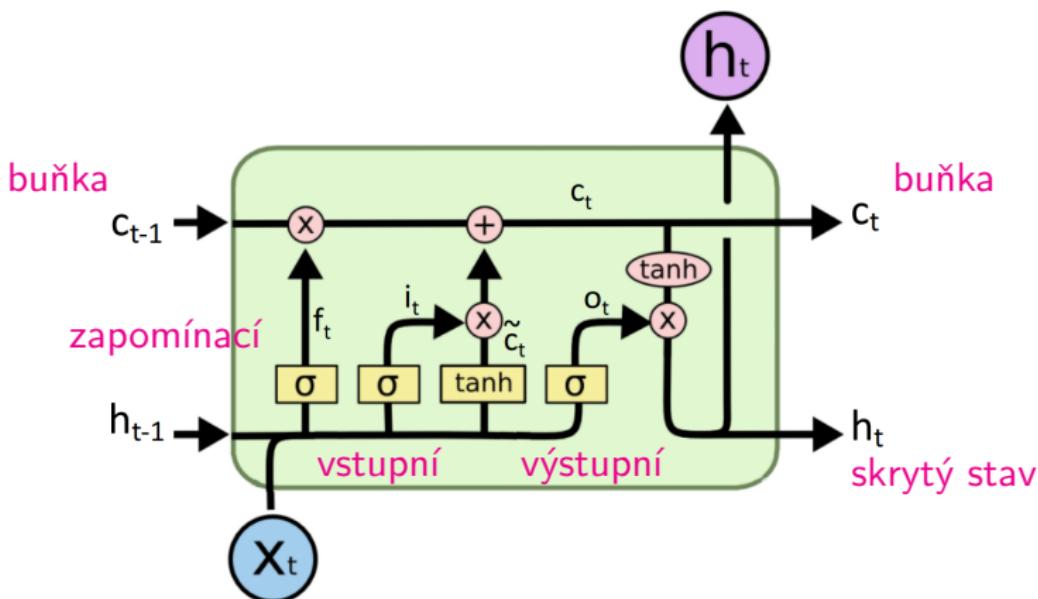


Architektura Long Short-Term Memory (LSTM)

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

řešení – architektura Long Short-Term Memory, LSTM:

- buňka (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

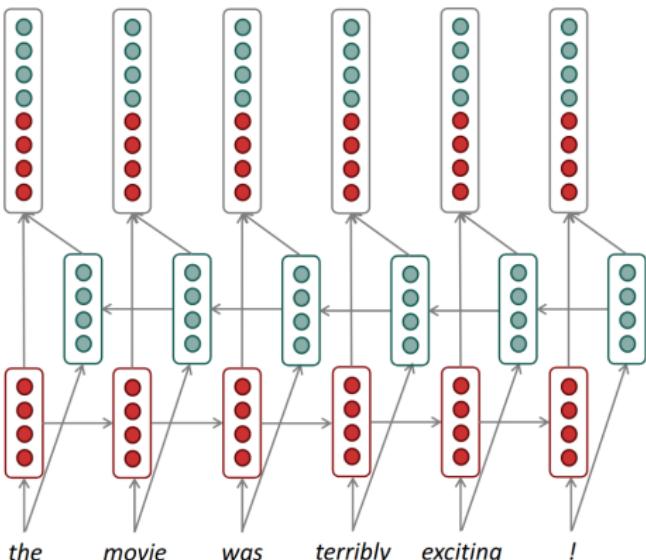
spojení **dopředné** LSTM

a **zpětné** LSTM

výstupy se **spojí** (*concatenate*)

do výsledných vektorů

(2× dimenze)



Obsah

1 Od klasických k hlubokým neuronovým sítím

- Klasické neuronové sítě a text
- Hluboké učení

2 Neurální jazykové modely

- S pevným kontextem
- Rekurentní jazykový model
- Praktické využití rekurentních sítí

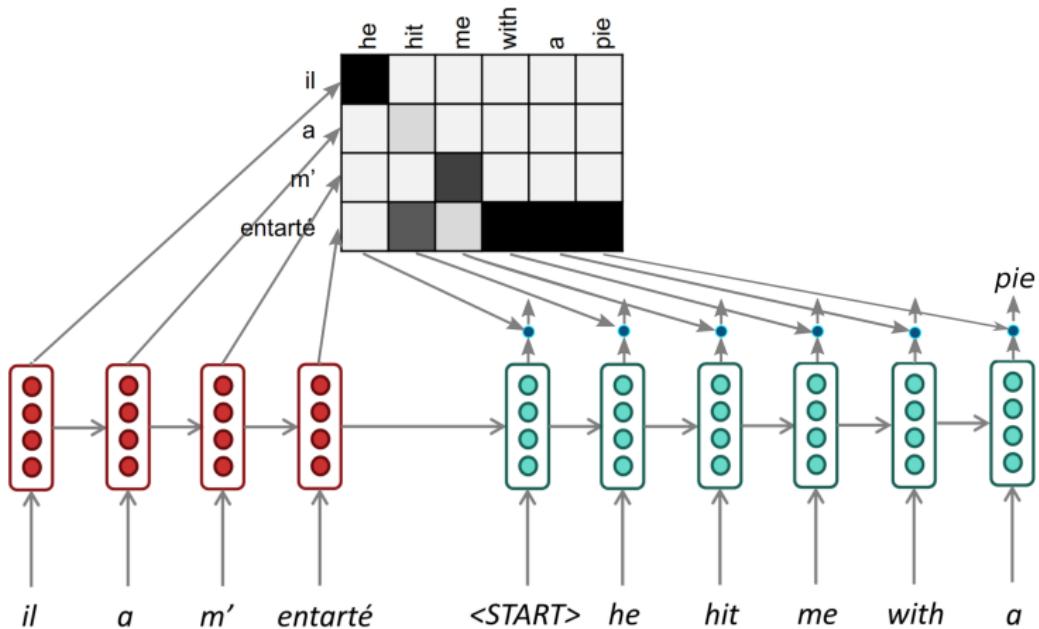
3 Architektura Long Short-Term Memory (LSTM)

4 Architektura Transformer

- Mechanizmus attention
- Architektura Transformer
- Pokročilé jazykové modely

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)

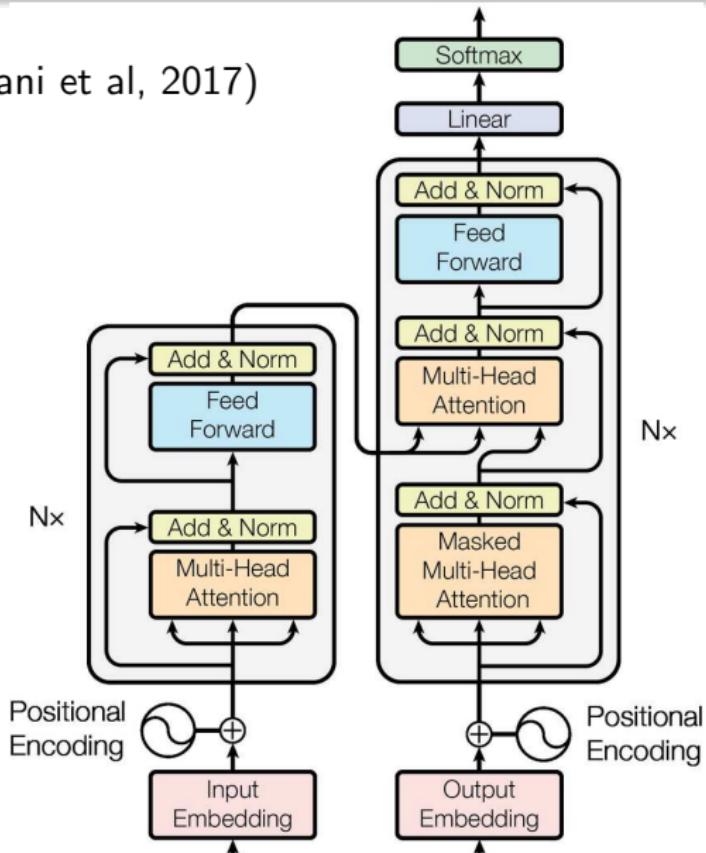


Architektura Transformer

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

architektura **transformer**:

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

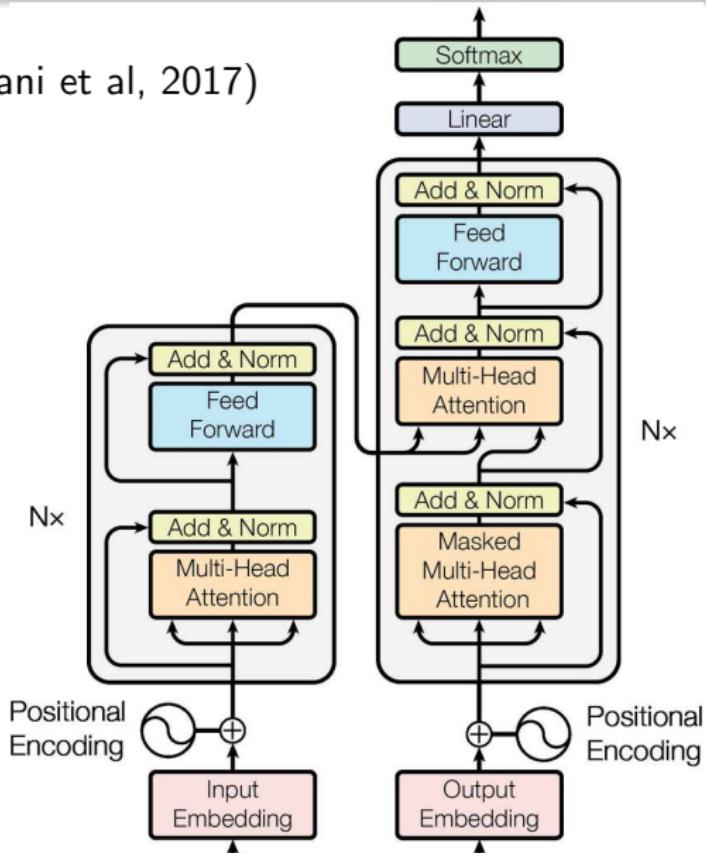


Architektura Transformer

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

architektura **transformer**:

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

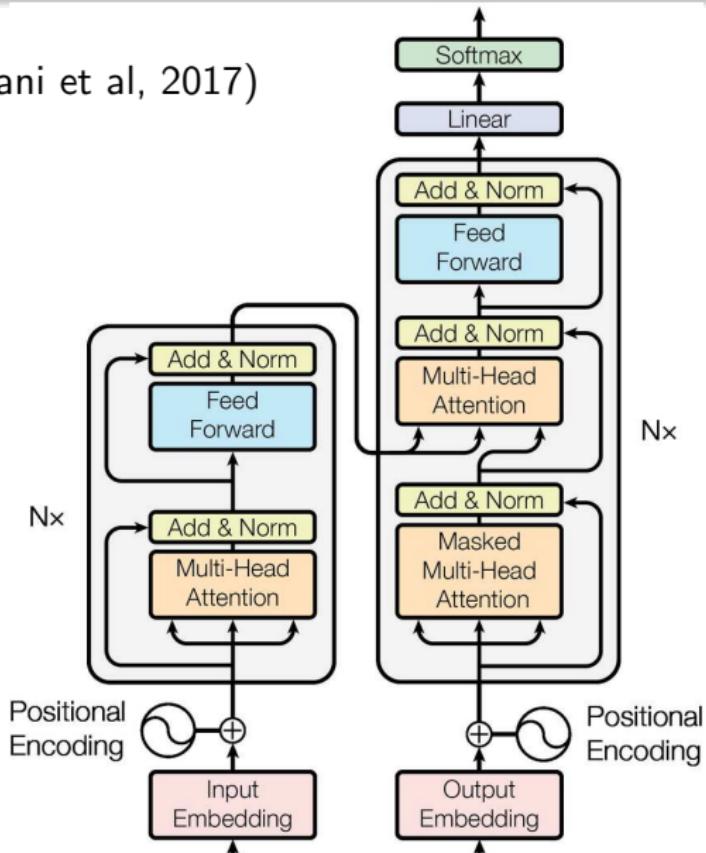


Architektura Transformer

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

architektura **transformer**:

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

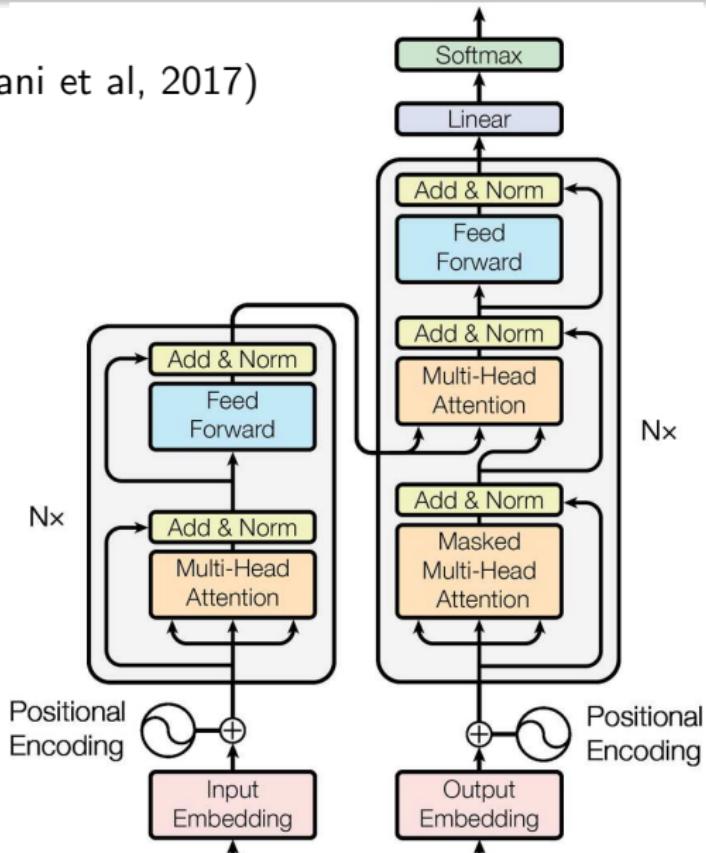


Architektura Transformer

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

architektura **transformer**:

- 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

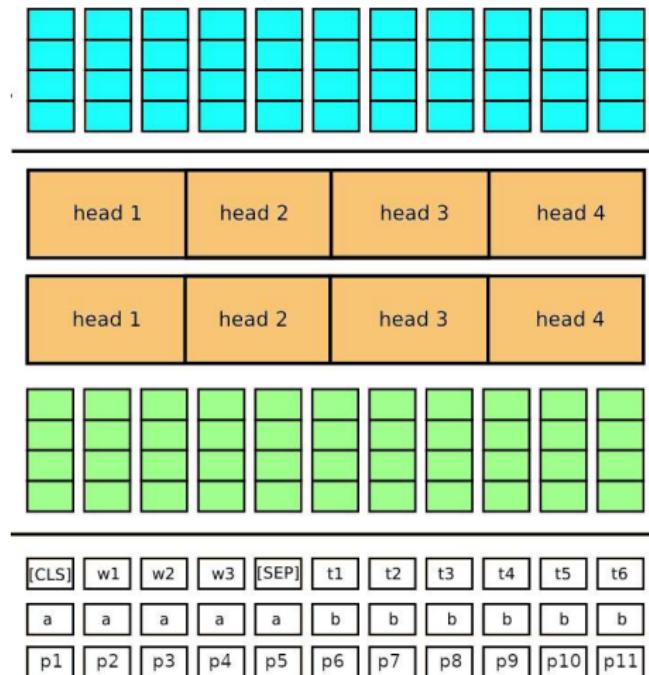
nevýhody:

- 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)

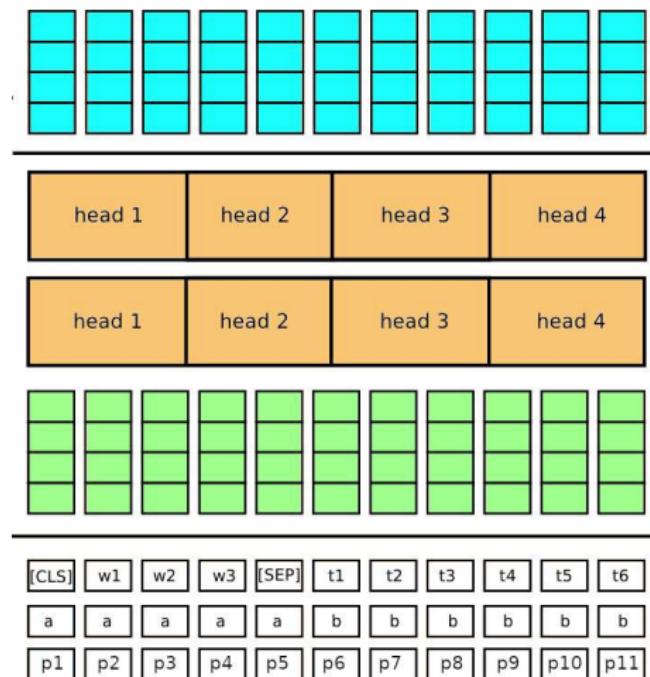
- jen enkodér
- symboly [CLS], [SEP] a [MASK]
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty
(*Next Sentence Prediction*)
- u ALBERT predikce pořadí vět
(*Sentence Order Prediction*)



BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

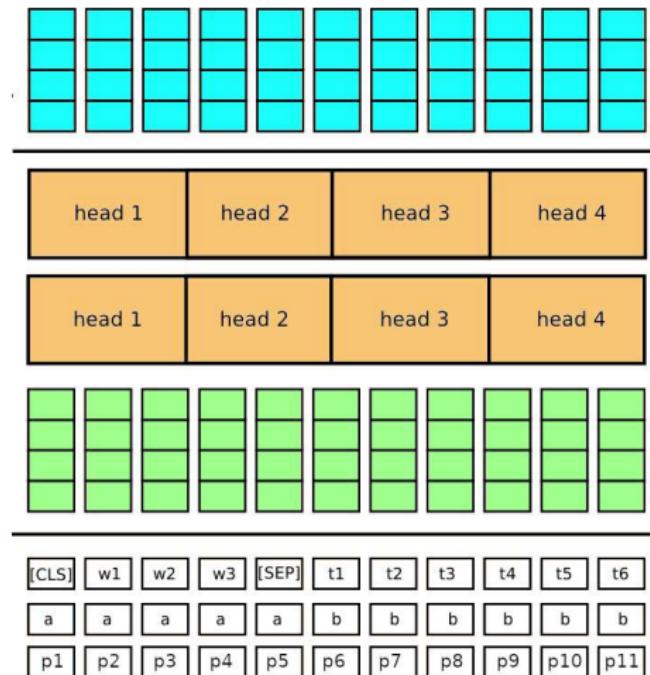
- jen enkodér
- symboly [CLS], [SEP] a [MASK]
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty
(*Next Sentence Prediction*)
- u ALBERT predikce pořadí vět
(*Sentence Order Prediction*)



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*)

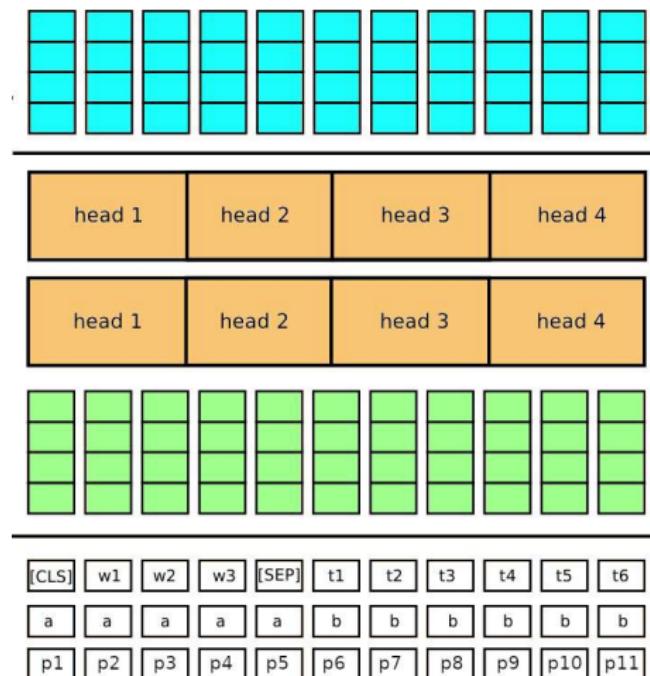


BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

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

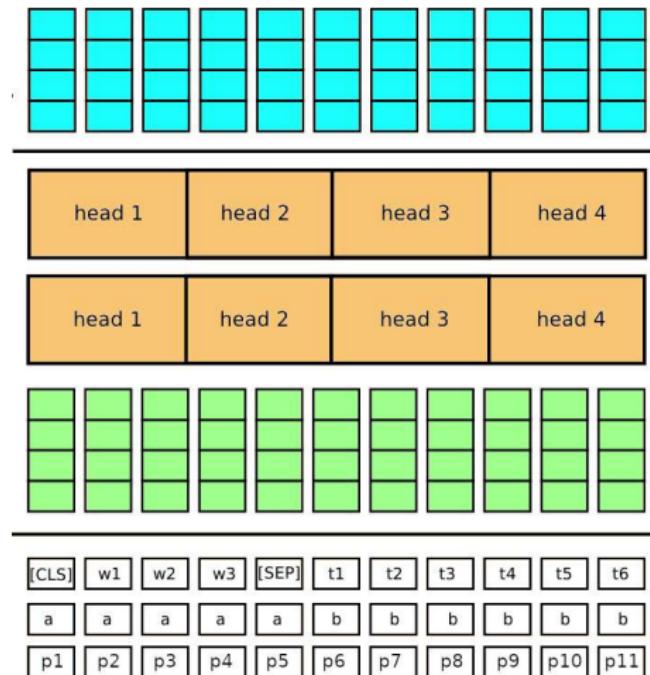
u ALBERT predikce pořadí vět
(*Sentence Order Prediction*)



BERT, ALBERT, RoBERTa

Bidirectional Encoder Representations from Transformers (BERT)

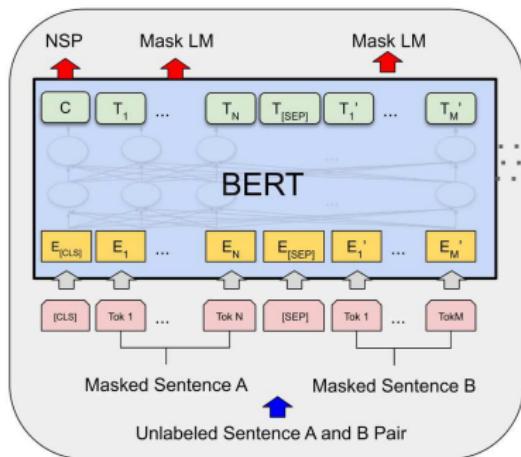
- jen enkodér
- symboly [CLS], [SEP] a [MASK]
- vektory segmentů
- maskovaný vstup
- úloha predikce následující věty
(*Next Sentence Prediction*)
- u ALBERT predikce pořadí vět
(*Sentence Order Prediction*)



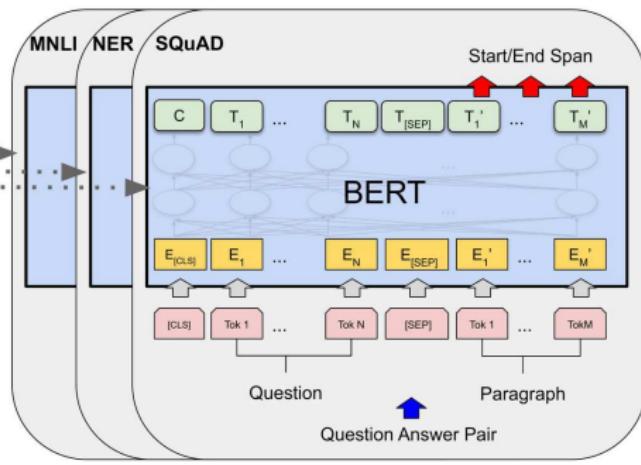
BERT – předtrénování a vyladění

pro většinu úloh se BERT trénuje ve dvou fázích:

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



Pre-training



Fine-Tuning

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

množství dalších **variant** architektury **transformer**

- doplnění **vstupních vektorů**
- technice **předtrénování**
- obsahu a velikosti textů pro trénování

většinou platí: **větší model → lepší výsledky**



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

množství dalších **variant architektury transformer**

- doplnění **vstupních vektorů**
- technice **předtrénování**
- obsahu a velikosti textů pro trénování

většinou platí: **větší model → lepší výsledky**



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

množství dalších variant architektury transformer

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

většinou platí: větší model → lepší výsledky



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

množství dalších variant architektury transformer

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

většinou platí: větší model → lepší výsledky

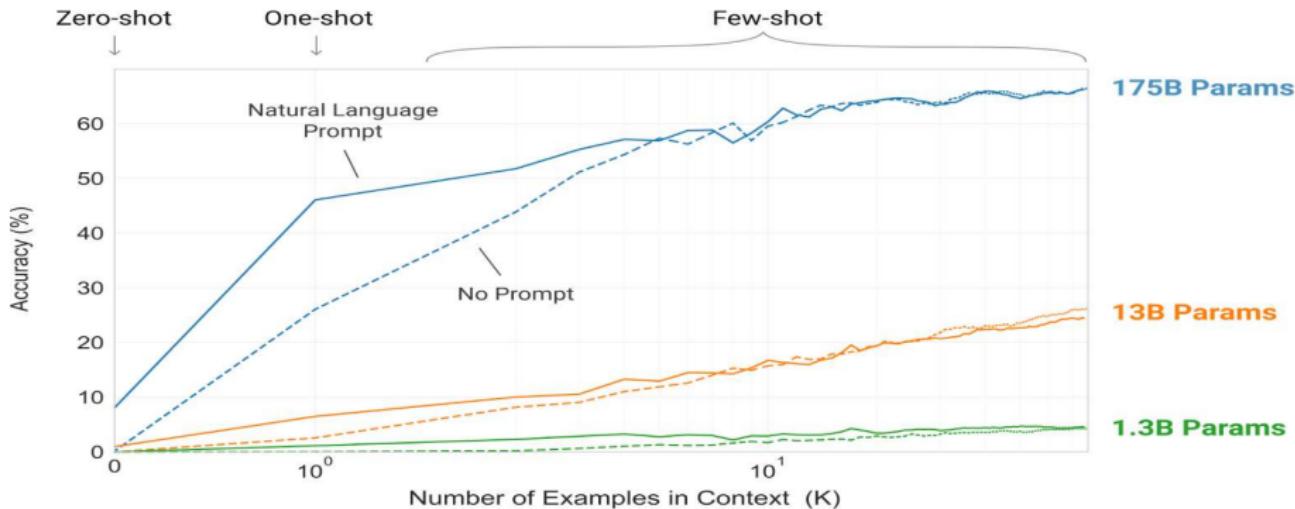


GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství dalších variant architektury transformer

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

většinou platí: větší model → lepší výsledky



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