

Hluboké učení pro zpracování jazyka

Aleš Horák

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

Obsah:

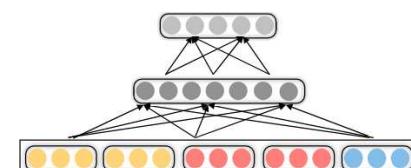
- ▶ Od klasických k hlubokým neuronovým sítím
- ▶ Neurální jazykové modely
- ▶ Architektura Long Short-Term Memory (LSTM)
- ▶ Architektura Transformer

Klasické neuronové sítě a text

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

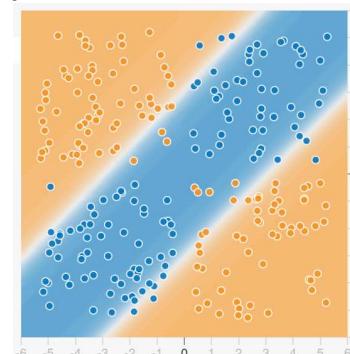
Klasické neuronové sítě a text

Neuronové sítě:

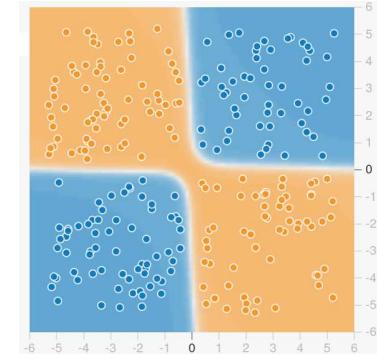
- ▶ od 1943 – McCulloch & Pitts – matematický **model neuronu**
- ▶ 1965 – první praktická **vícevrstvá dopředná síť**
- ▶ 1982 – praktická implementace **zpětného šíření chyby** pro **trénování vícevrstvých sítí**

praktické využití – **klasifikační úlohy**

jednovrstvá



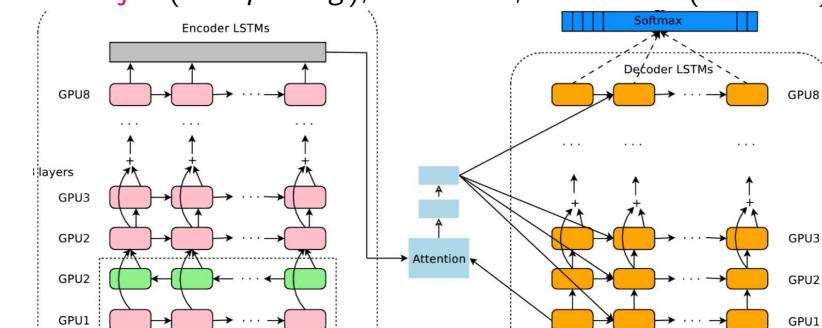
dvouvrstvá



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)**, ...



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

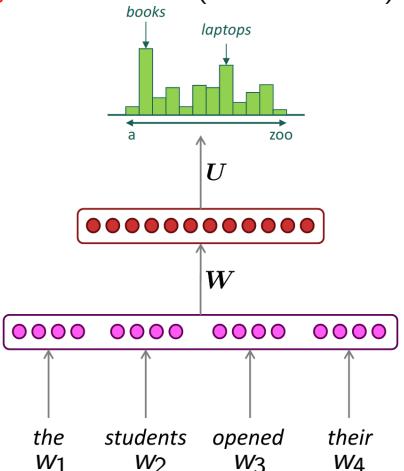
$$h = f(We + b_1)$$

řetězené vektory slov

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



Rekurentní jazykový model

výstupní **distribuce**

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

skryté stavy

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

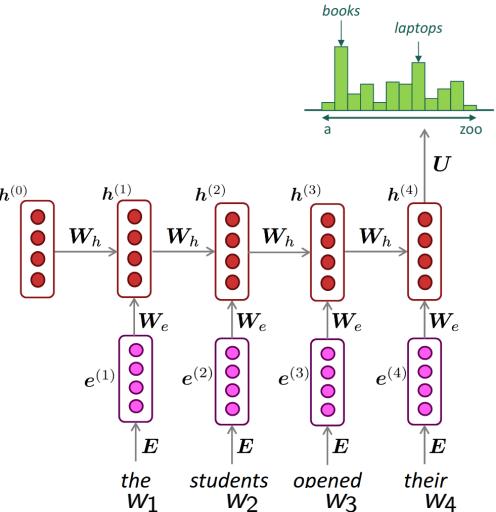
váhy W_h a W_e se aplikují opakováně

jednotlivé vektory slov

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



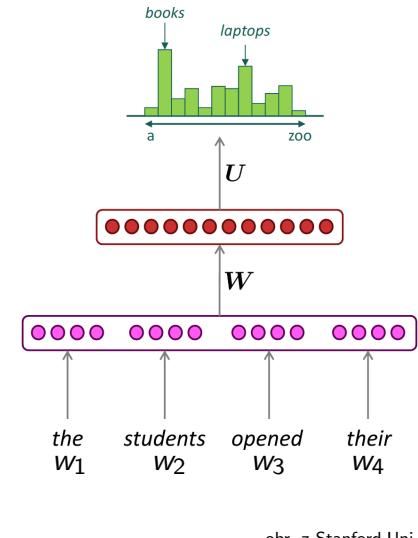
Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- ▶ není problém s **nene nalezenými 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



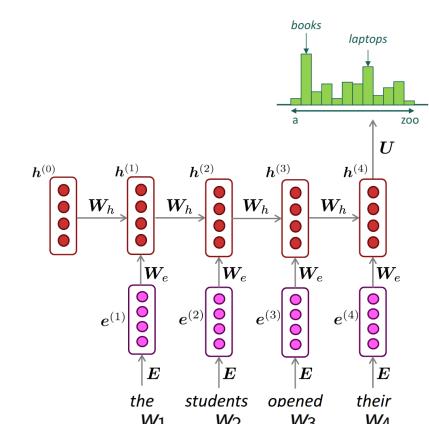
obr. z Stanford.Uni.

je potřebná neurální architektura pro **libovolně dlouhý vstup**

Rekurentní jazykový model

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** (“zmatenosť”):

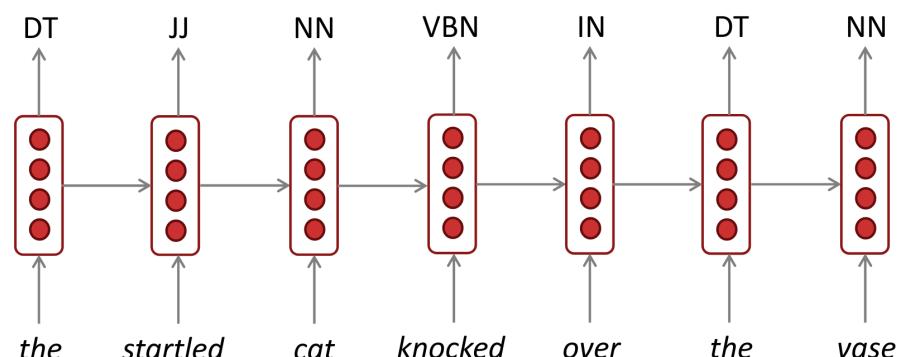
- ▶ srovnání na vybraném testovacím textu
- ▶ poměrově vyjadřuje z kolika slov se vybírá predikce
- ▶ nižší hodnota = lepší perplexita

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



Hyperparametry hlubokého učení

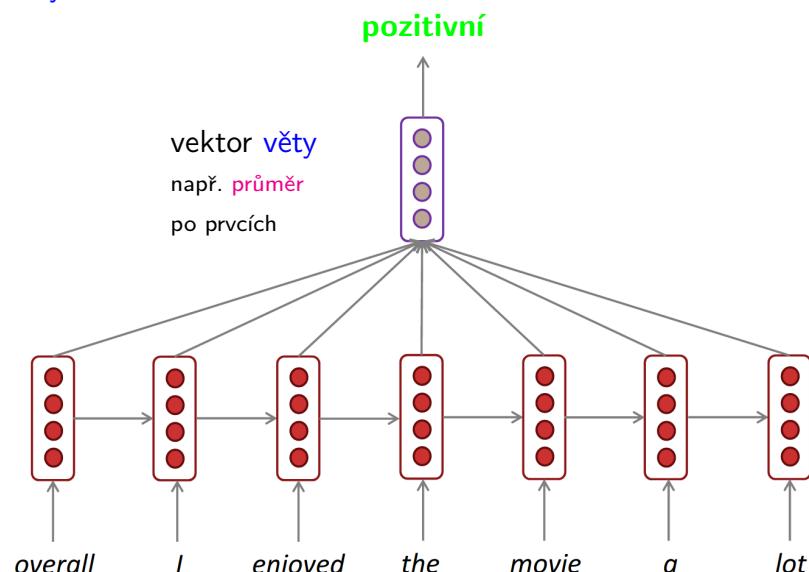
Hluboké učení – kromě architektury sítě i množství **hyperparametrů**:

- ▶ **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*) – 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 rychlosť učení obvykle funkce, jejíž hodnota se snižuje, např. $lr_0 e^{-kt}$ hodně závisí na optimalizační funkci



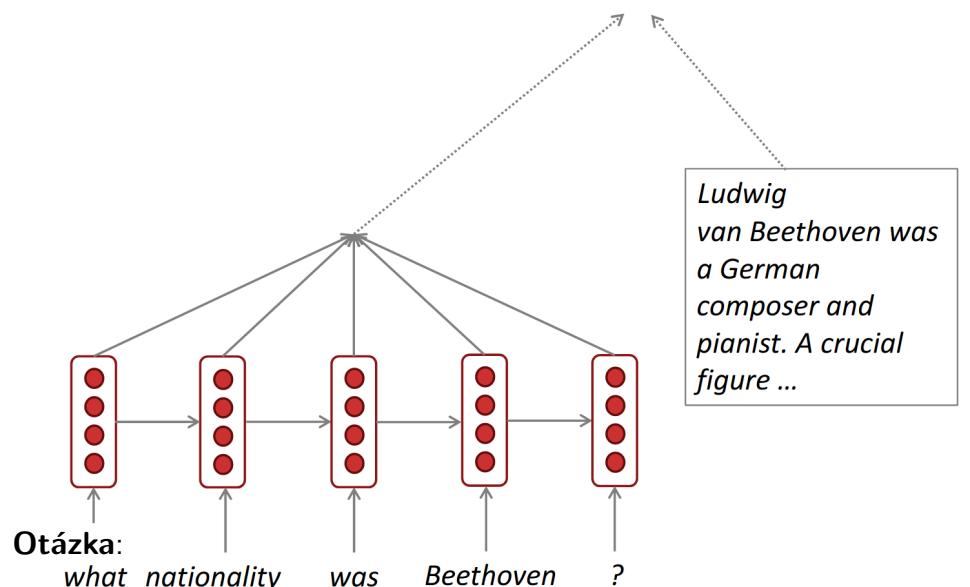
Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

Využití rekurentních sítí – klasifikace vět např. analýza sentimentu



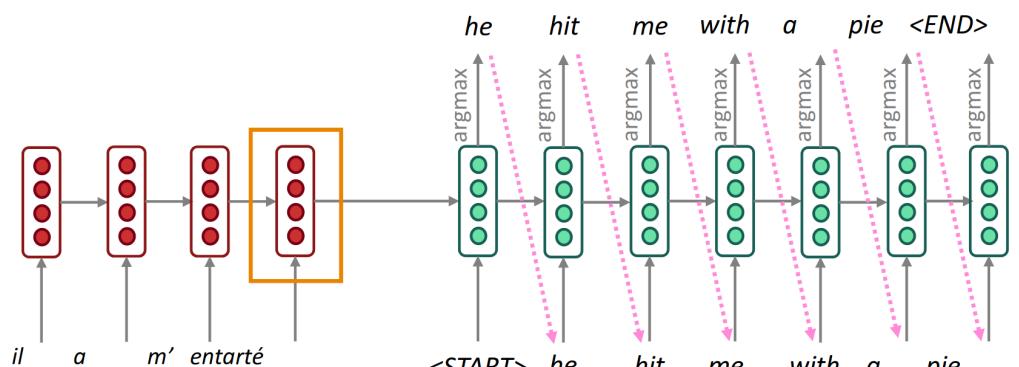
Využití rekurentních sítí – odpovídání na otázky

Odpověď: German



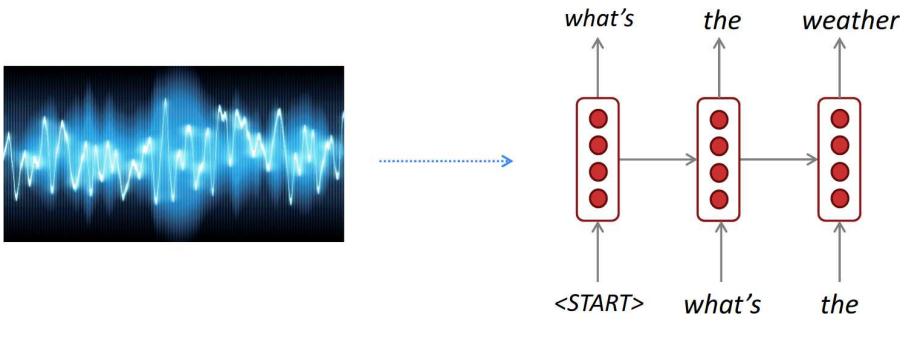
Využití rekurentních sítí – seq2seq

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



Využití rekurentních sítí – podmíněné generování

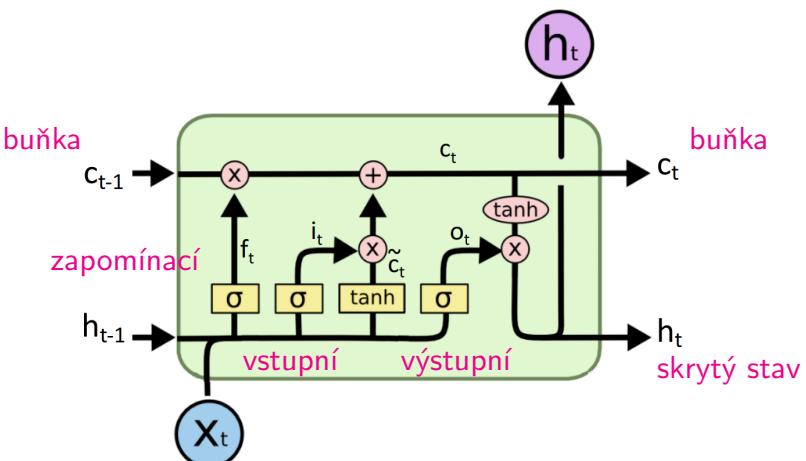
zapojení dalších sekvenčních podmínek – **syntéza řeči**, **strojový překlad**, **sumarizace**



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

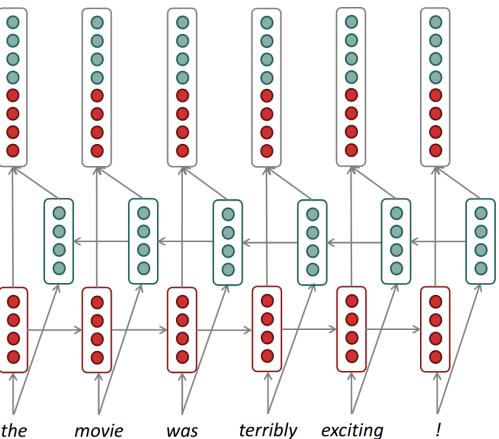


Architektura Long Short-Term Memory (LSTM)

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

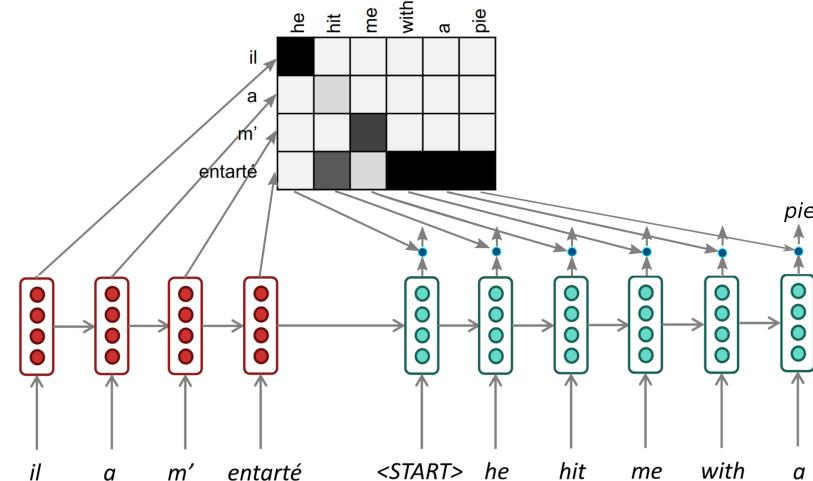
rekurence je **směrovaná** –
 zleva doprava
 ⇒ jiný důraz při průběhu
zprava doleva

obousměrné (bidirectional) BiLSTM
 spojení **dopředné** LSTM
 a **zpětné** LSTM
 výstupy se **spojují (concatenate)**
 do výsledních vektorů
 (2x dimenze)



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)

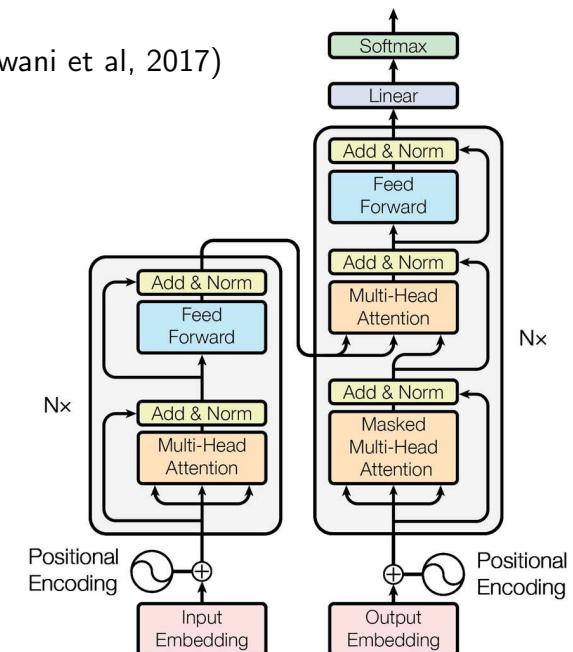


Architektura Transformer

"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

výhody:

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

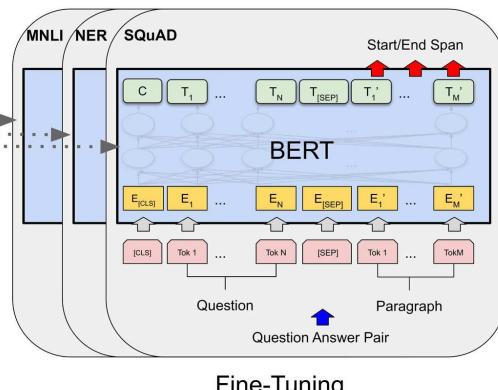
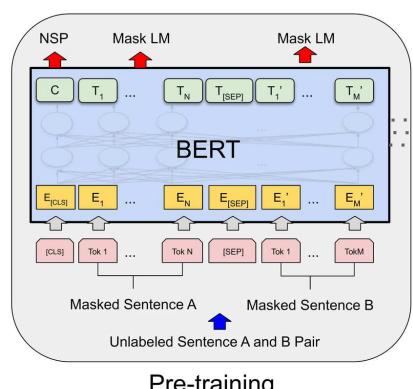
nevýhody:

- 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 – předtrénování a vyladění

pro většinu úloh se BERT trénuje ve dvou fázích:

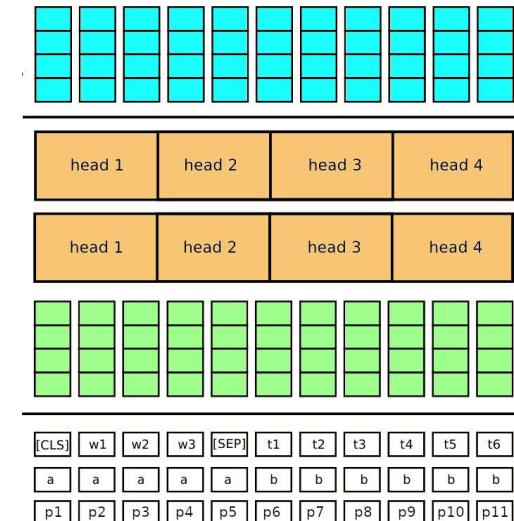
- předtrénování (*pre-training*) – na obecných velkých textech
- vyladění (*fine-tuning*) – dotrénování klasifikace pro konkrétní úlohu



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*)



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

