

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

Úvod do počítačové lingvistiky 12/12

1 / 25

Od klasických k hlubokým neuronovým sítím

Klasické neuronové sítě a text

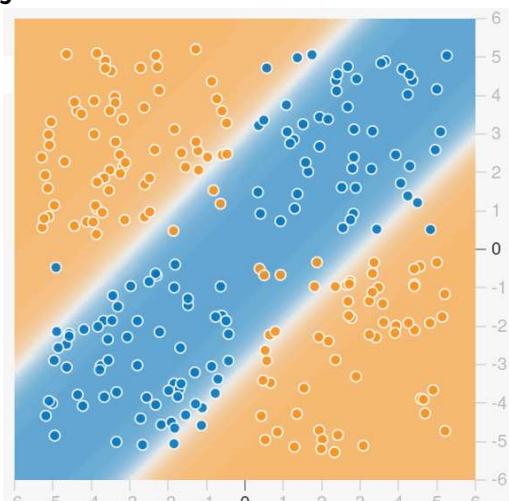
Klasické neuronové sítě a text

Neuronové sítě:

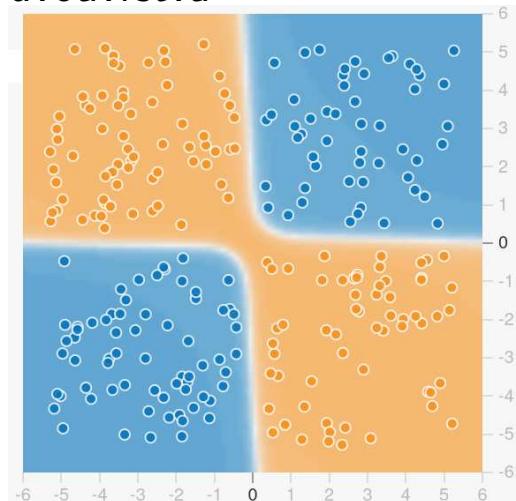
- ▶ od 1943 – McCulloch & Pitts – matematický model neuronu
- ▶ 1965 – první praktická vícevrstvá dopředná síť
- ▶ 1982 – praktická implementace zpětného šíření chyby pro trénování vícevrstvých sítí

praktické využití – klasifikační úlohy

jednovrstvá



dvouvrstvá



Úvod do počítačové lingvistiky 12/12

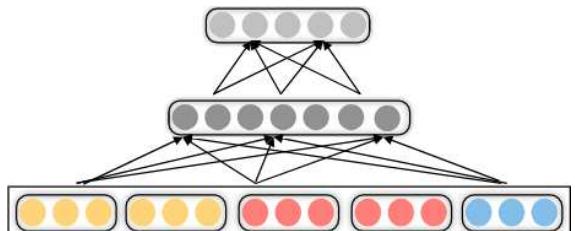
2 / 25

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



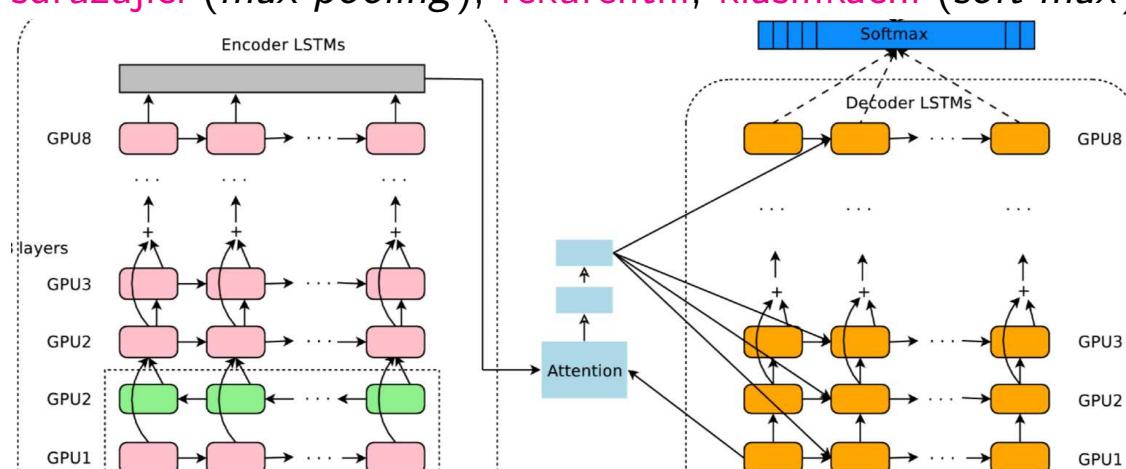
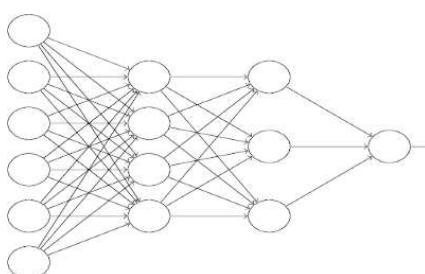
2. slova jako **slavní vektory** (*word embeddings*):

- stanovení pevné dimenze
- **předpočítání/předtrénování** na velmi velkých neanotovaných textech
⇒ **neurální jazykové modely**
- zachycení **sémantiky** – podobná slova sítě 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*), ...



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 sítě ke generalizaci
- ▶ **dimenze skryté vrstvy** (*hidden layer dimension*) – větší 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

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

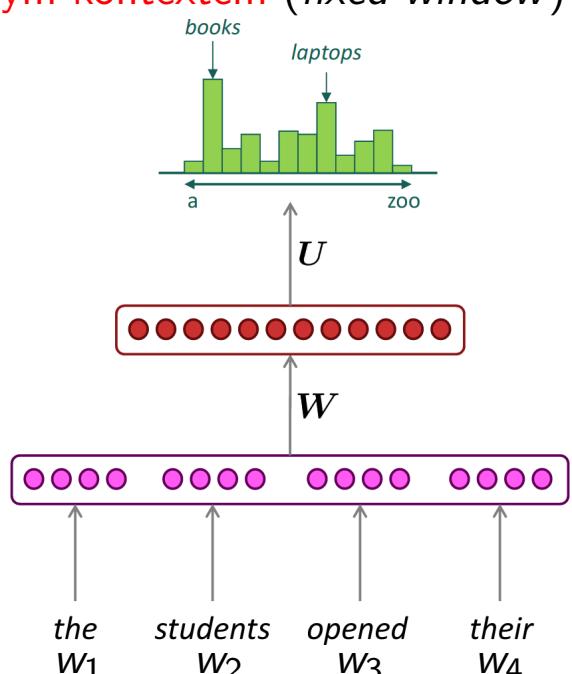
$$h = f(We + b_1)$$

řetězené **vektory slov**

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

slova na vstupu

$$W_1 W_2 W_3 W_4$$



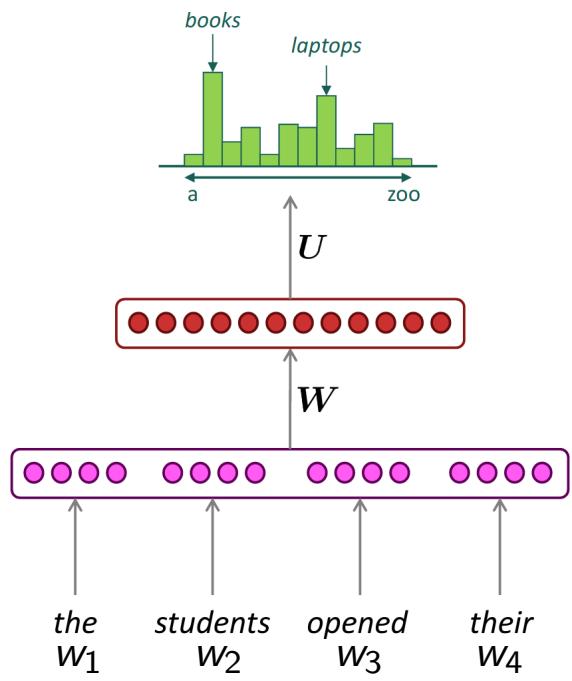
Neurální jazykový model s pevným kontextem

výhody proti n-gramovému modelu:

- ▶ není problém s **nenelezenými 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

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

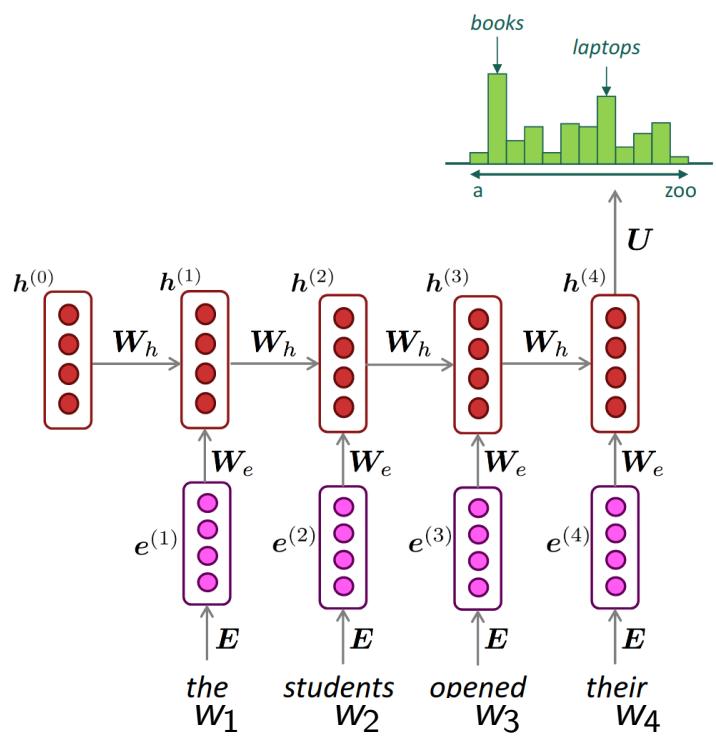
váhy W_h a W_e se aplikují **opakováně**

jednotlivé **vektory slov**

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



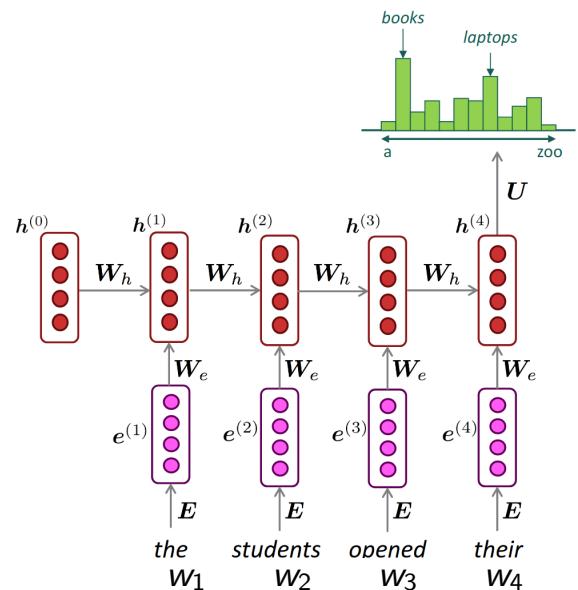
Rekurentní jazykový model

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



Kvalita jazykového modelu

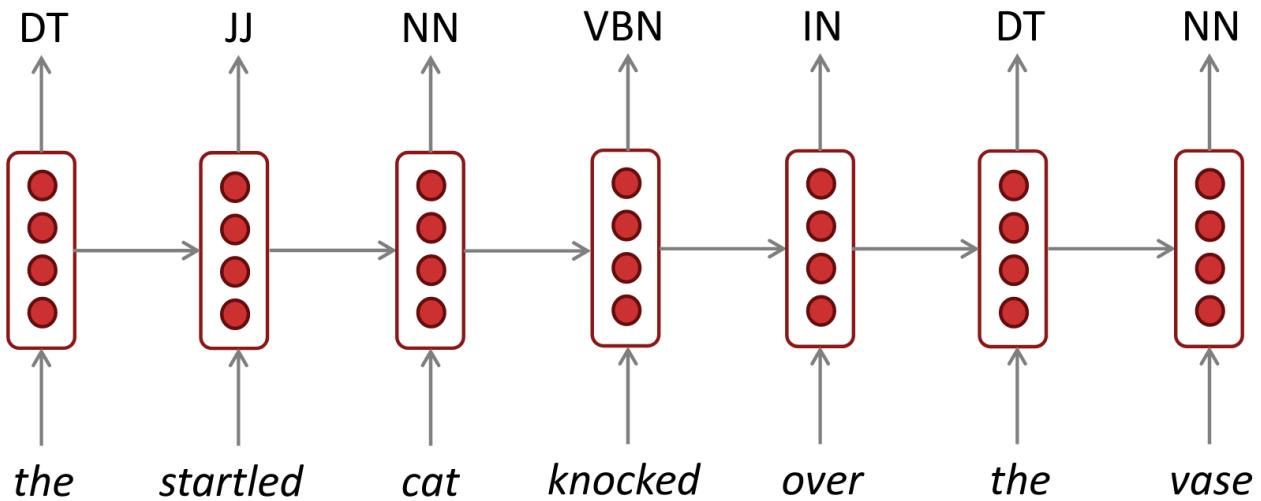
základní srovnávací metrika – perplexita (“zmatenosť”):

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

Rekurentní modely → zlepšení perplexity

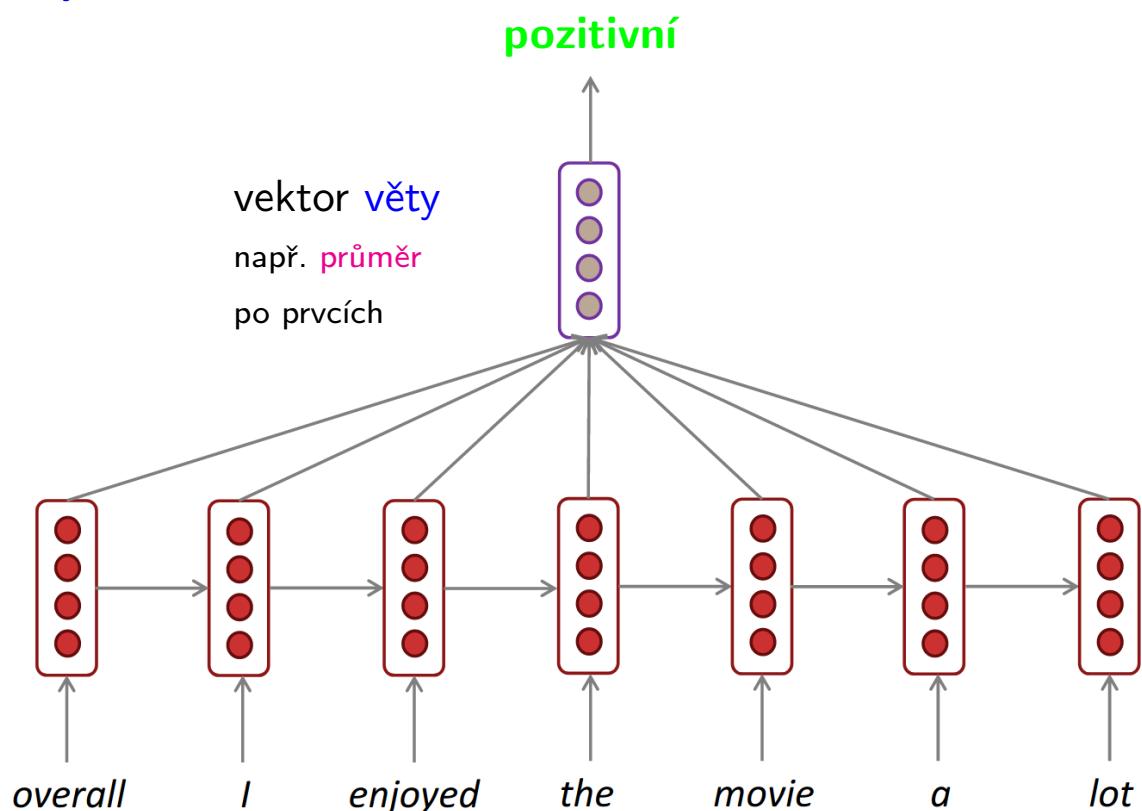
<i>n</i> -gramový model → rekur. ↓ modely	Model	Perplexita
	Interpolated Kneser-Ney 5-gram (Chelba et al., 2013)	67.6
	RNN-1024 + MaxEnt 9-gram (Chelba et al., 2013)	51.3
	RNN-2048 + Blackout sampling (Ji et al., 2015)	68.3
	Sparse Non-negative Matrix factorization (Shazeer et al., 2015)	52.9
	LSTM-2048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

Využití rekurentních sítí – značkování



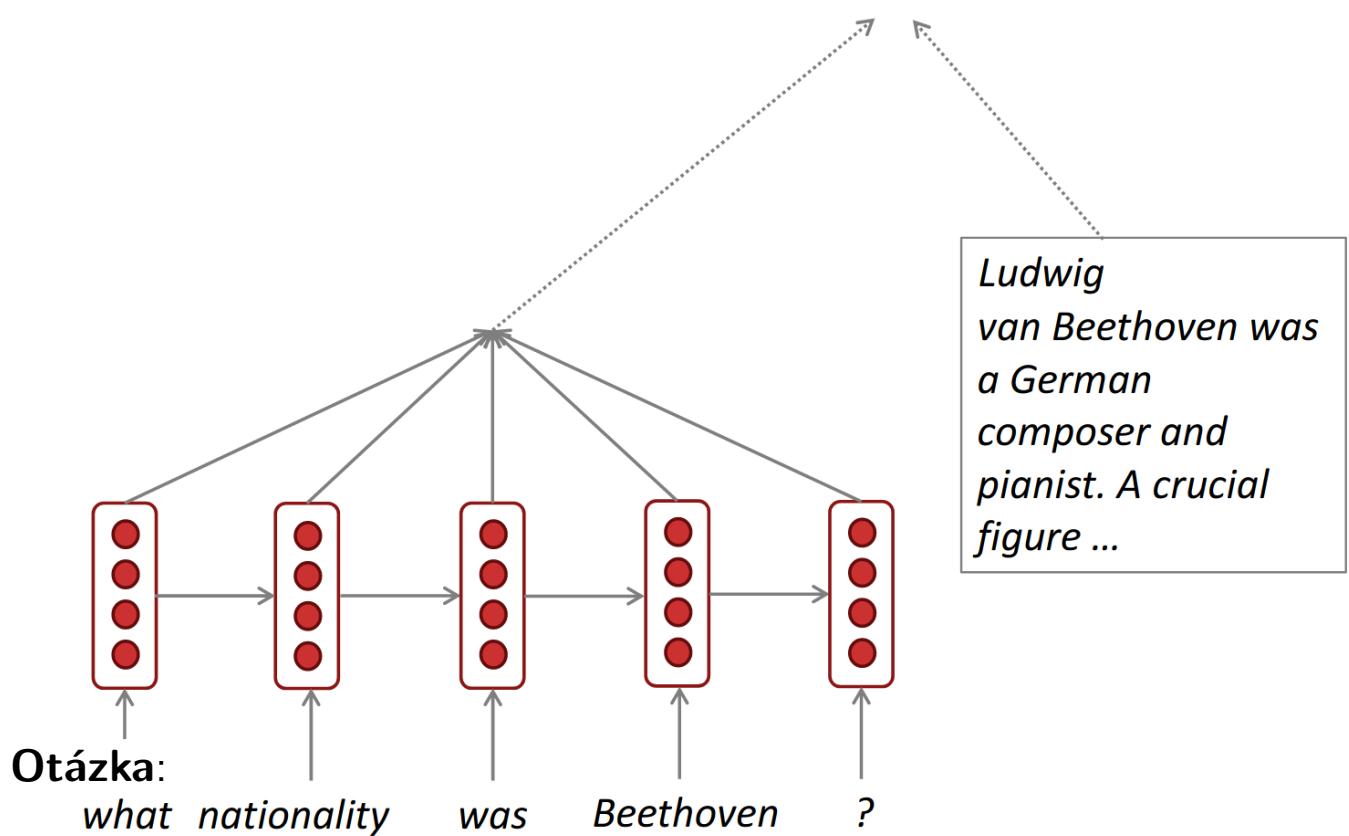
Využití rekurentních sítí – klasifikace vět

např. analýza sentimentu



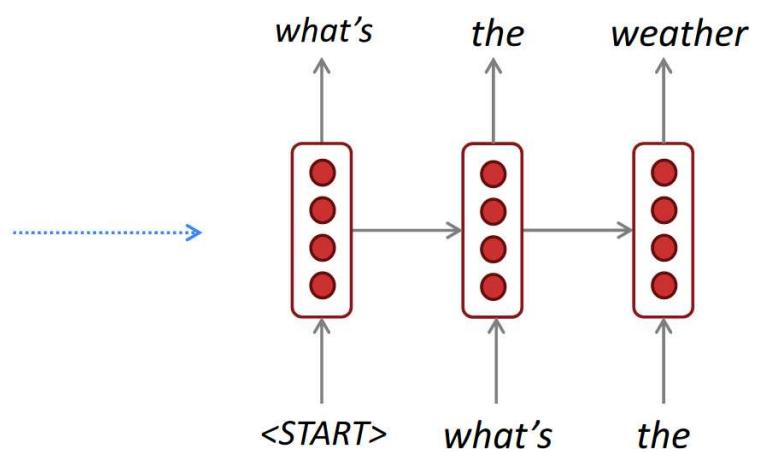
Využití rekurentních sítí – odpovídání na otázky

Odpověď: German



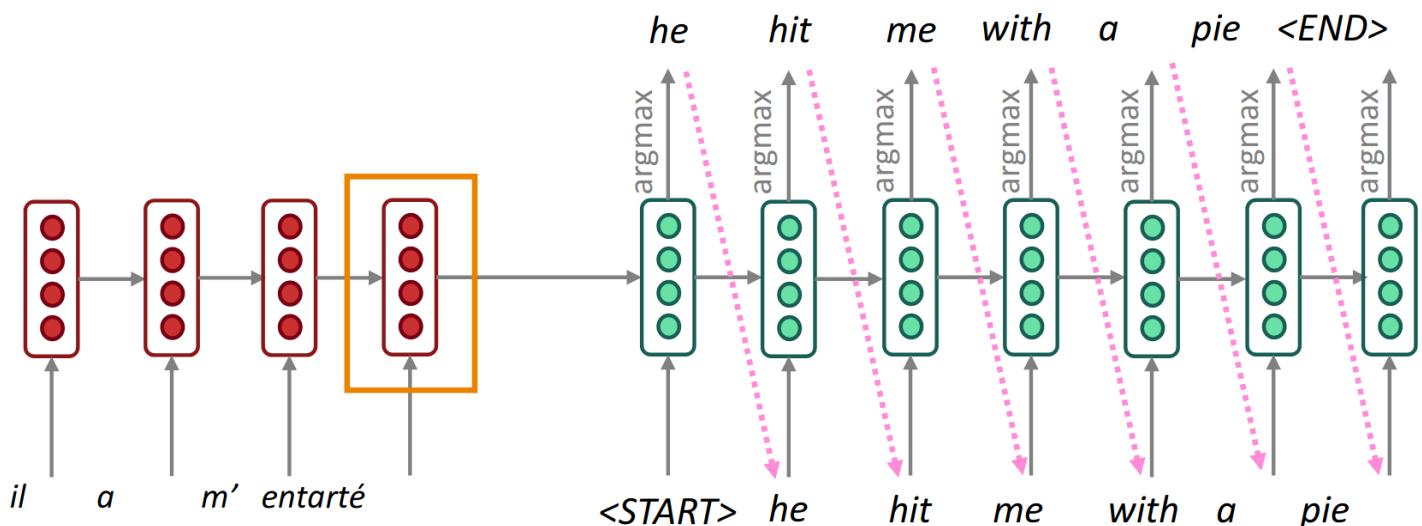
Využití rekurentních sítí – podmíněné generování

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



Využití rekurentních sítí – seq2seq

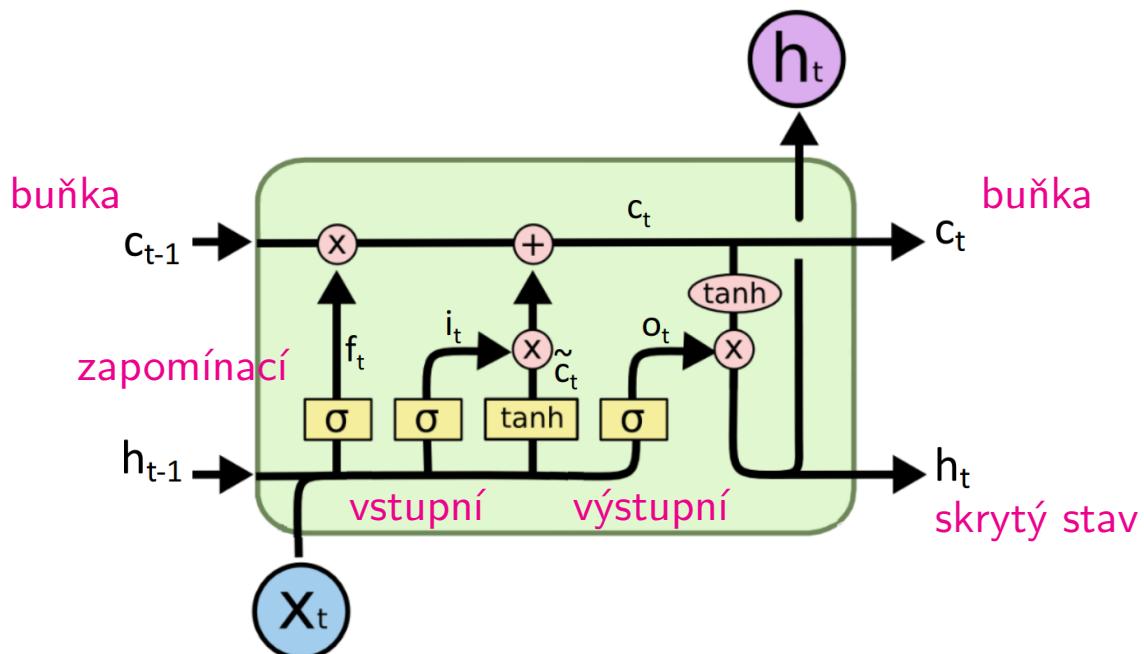
častá varianta – model **sequence-to-sequence** (seq2seq)
 dvě rekurentní sítě – **enkodér** a **dekodér**



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

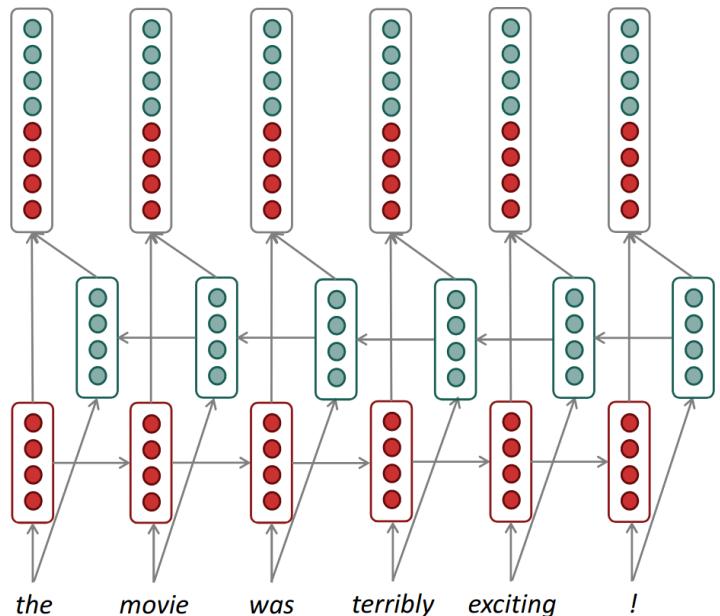


Architektura Long Short-Term Memory (LSTM)

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

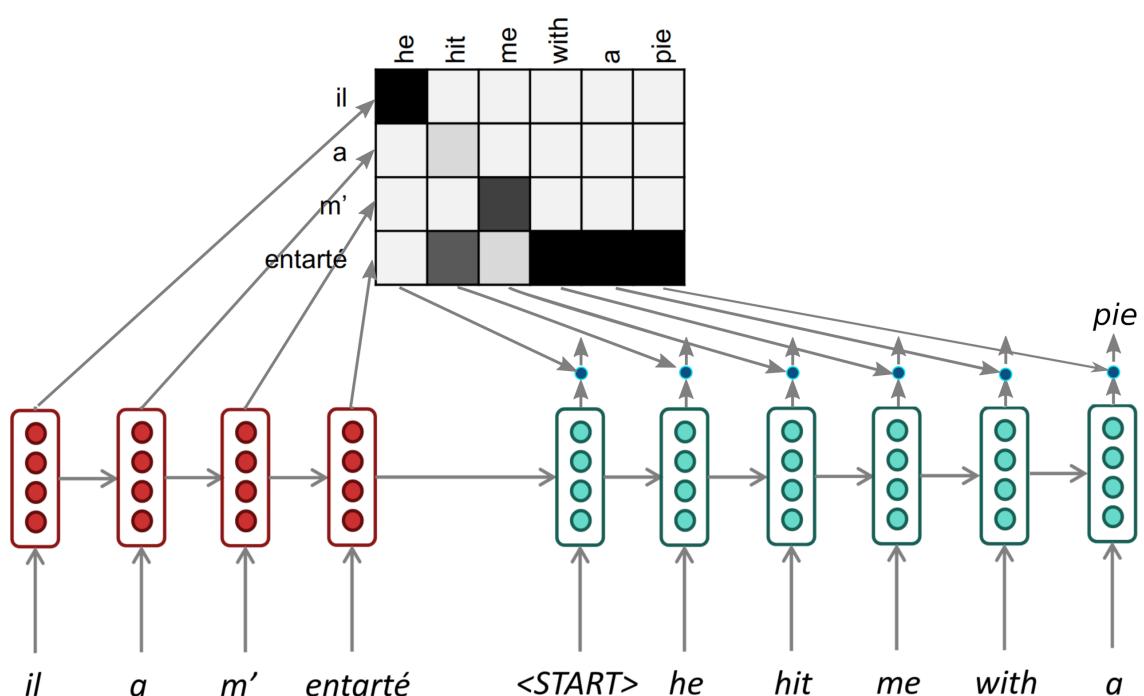
rekurence je **směrovaná** –
 zleva doprava
 ⇒ jiný důraz při průběhu
zprava doleva

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



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)

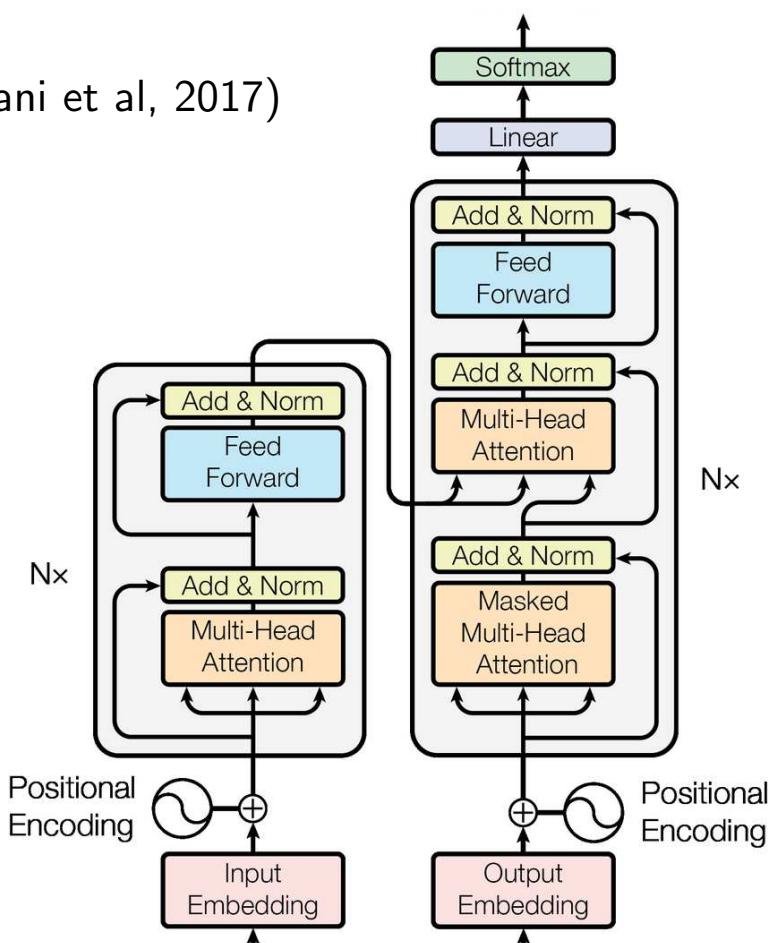


Architektura Transformer

“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

výhody:

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

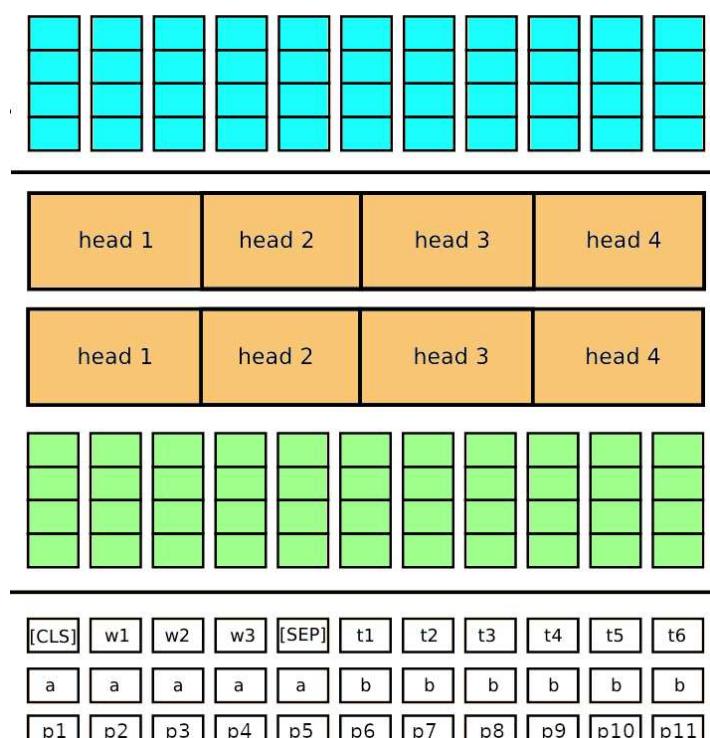
nevýhody:

- ▶ 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)

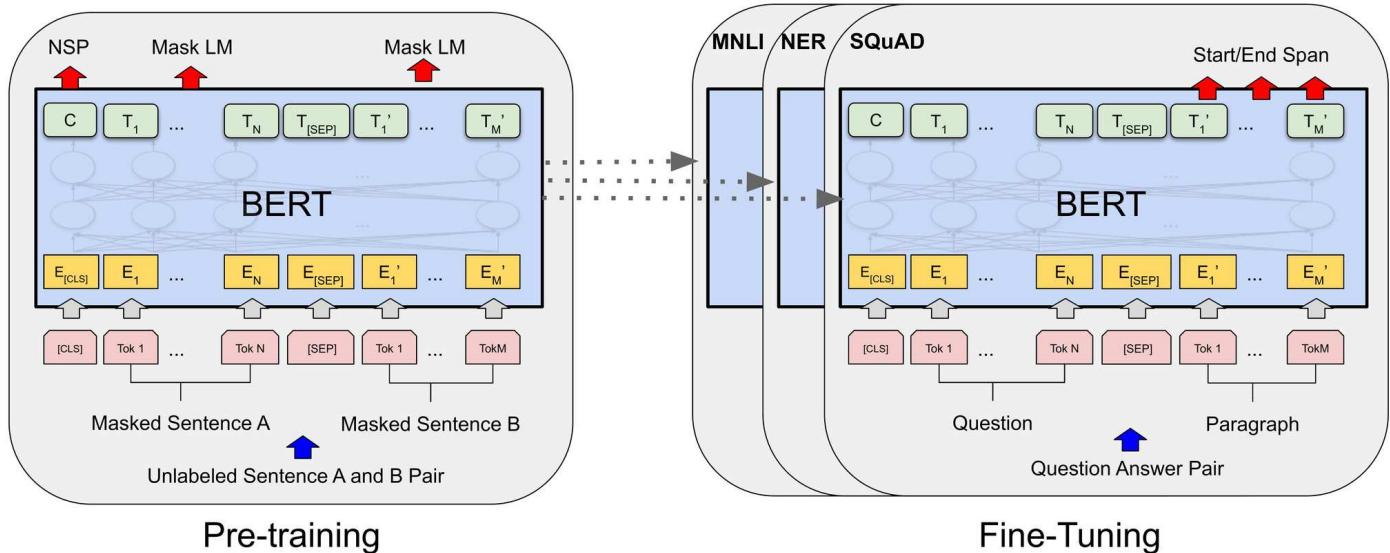
- ▶ jen enkodér
- ▶ symboly [CLS], [SEP] a [MASK]
- ▶ vektory segmentů
- ▶ maskovaný vstup
- ▶ úloha predikce následující věty (*Next Sentence Prediction*) u ALBERT predikce pořadí vět (*Sentence Order Prediction*)



BERT – 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**

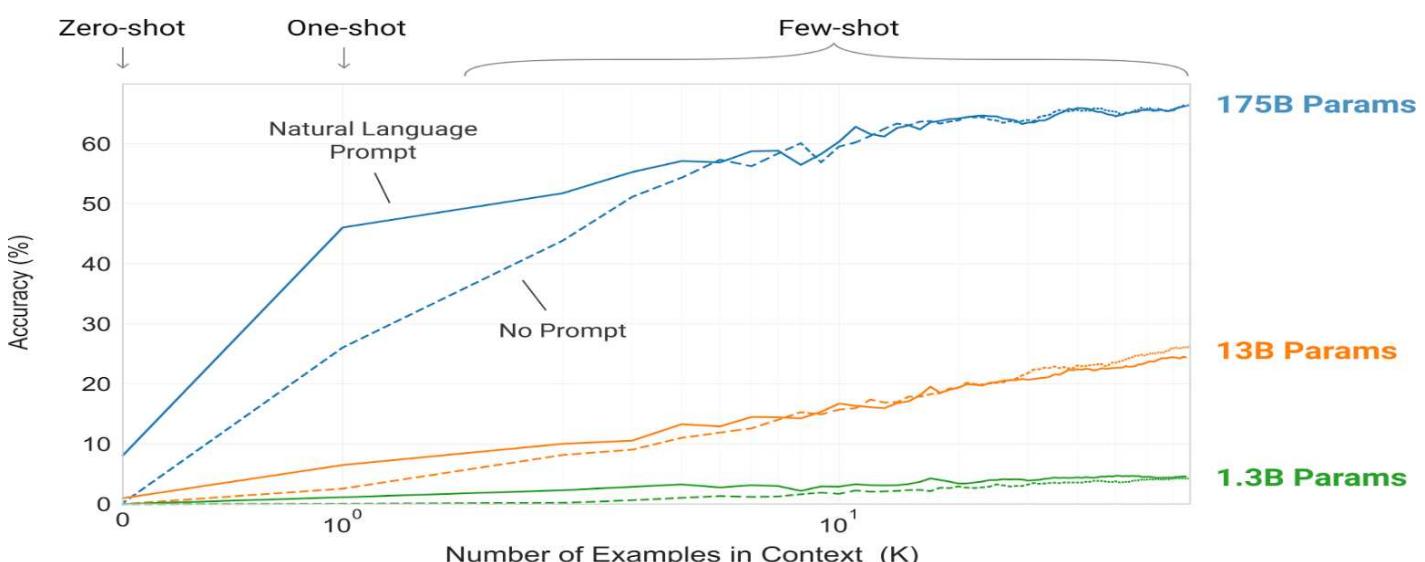


GPT, T5, ELMo, ERNIE, ELECTRA, ...

množství 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