

# Hluboké učení pro zpracování jazyka

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/nlp\\_intro/](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

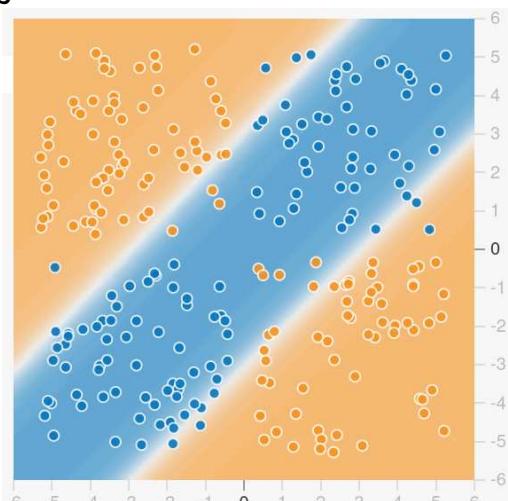
## Klasické neuronové sítě a text

### Neuronové sítě:

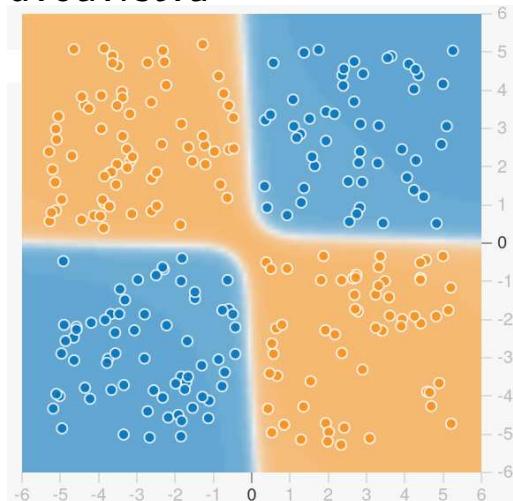
- ▶ od 1943 – McCulloch & Pitts – matematický model neuronu
- ▶ 1965 – první praktická vícevrstvá dopředná síť
- ▶ 1982 – praktická implementace zpětného šíření chyby pro trénování vícevrstvých sítí

praktické využití – klasifikační úlohy

jednovrstvá



dvouvrstvá

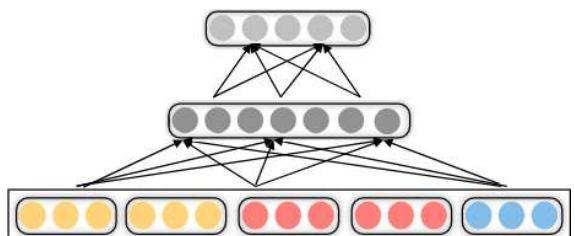


# Klasické neuronové sítě a text

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



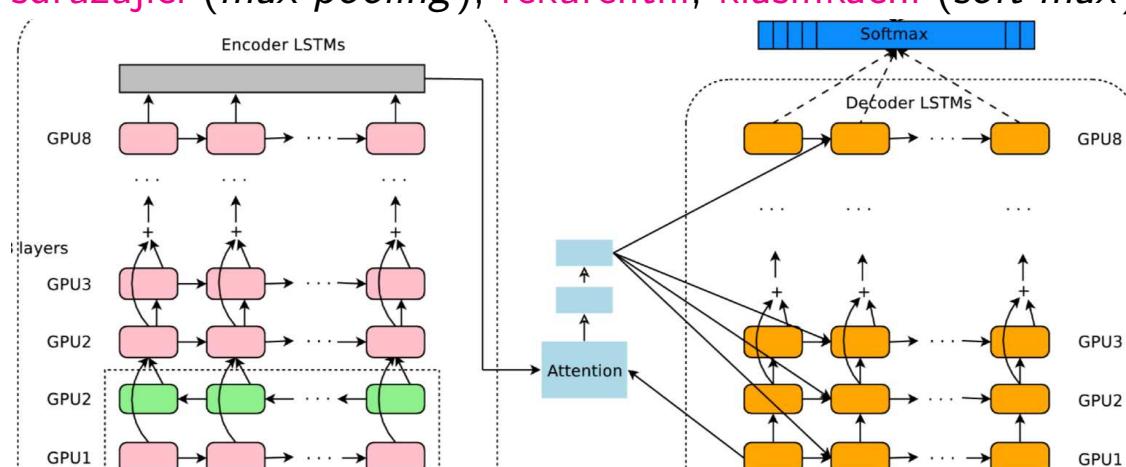
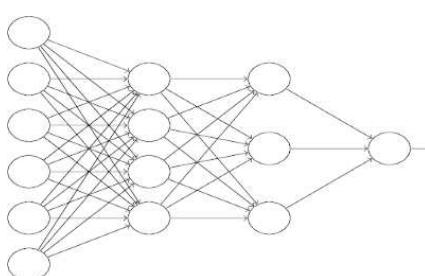
## 2. slova jako **slovní vektory** (*word embeddings*):

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

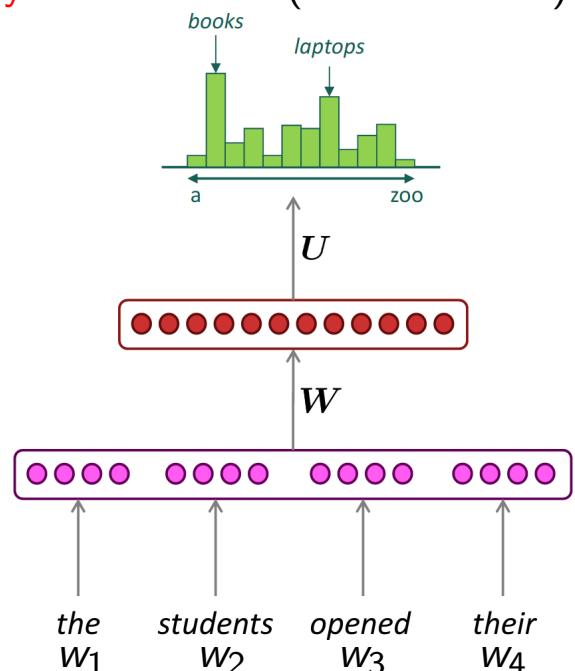
$$h = f(We + b_1)$$

řetězené **vektory slov**

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

**slova** na vstupu

$$w_1 w_2 w_3 w_4$$



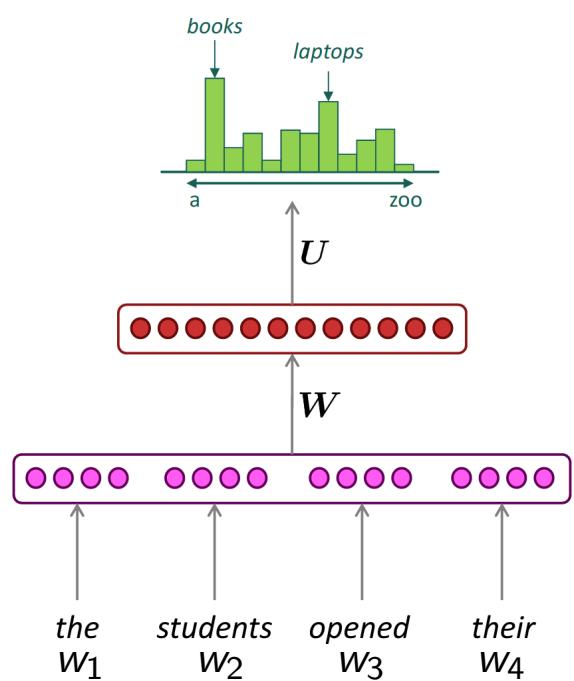
## Neurální jazykový model s pevným kontextem

**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  $w_2$



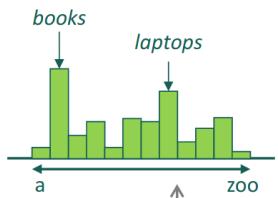
obr. z Stanford.Uni.

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

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

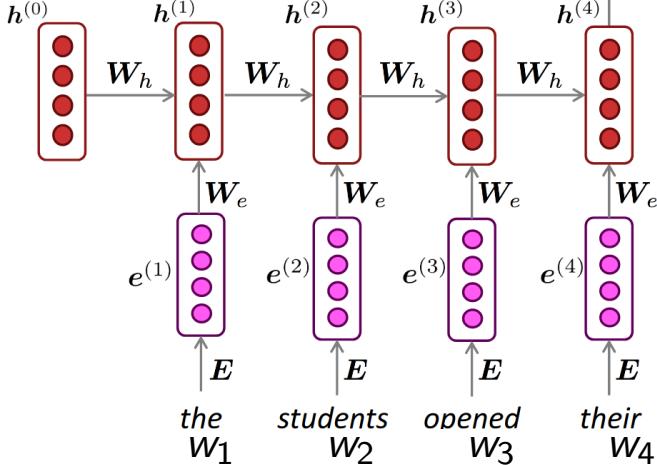
váhy  $W_h$  a  $W_e$  se aplikují opakováně

jednotlivé vektory slov

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

slova na vstupu

$$w_1 w_2 w_3 w_4$$



# Rekurentní jazykový model

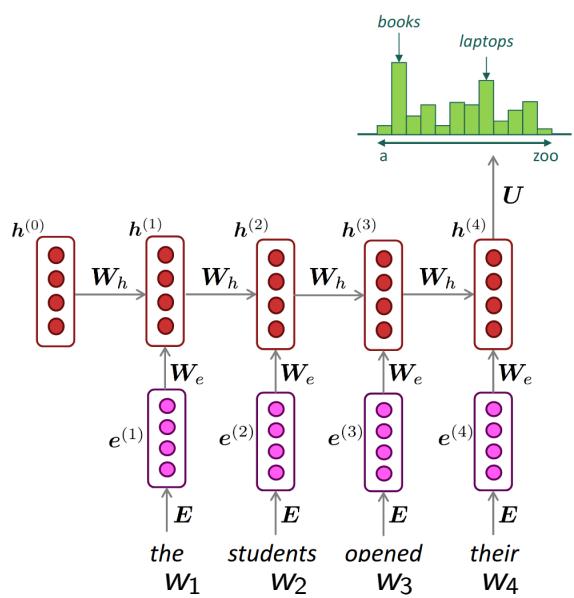
**výhody** rekurentního modelu:

- ▶ 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](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)	<b>67.6</b>
	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)	<b>30.0</b>

zdroj [research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words](https://research.fb.com/building-an-efficient-neural-language-model-over-a-billion-words)

## Hyperparametry hlubokého učení

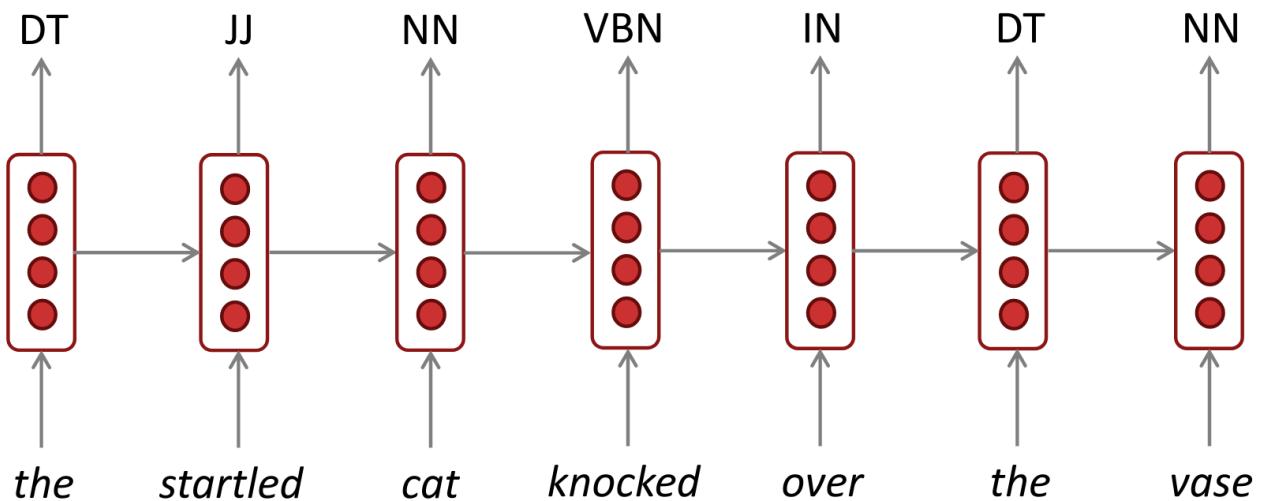
Hluboké učení – kromě architektury sítě i množství **hyperparametrů**:

- ▶ **regularizace** (např. L2-regularizace) – brání 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*) 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.  $I r_0 e^{-kt}$  hodně závisí na optimalizační funkci



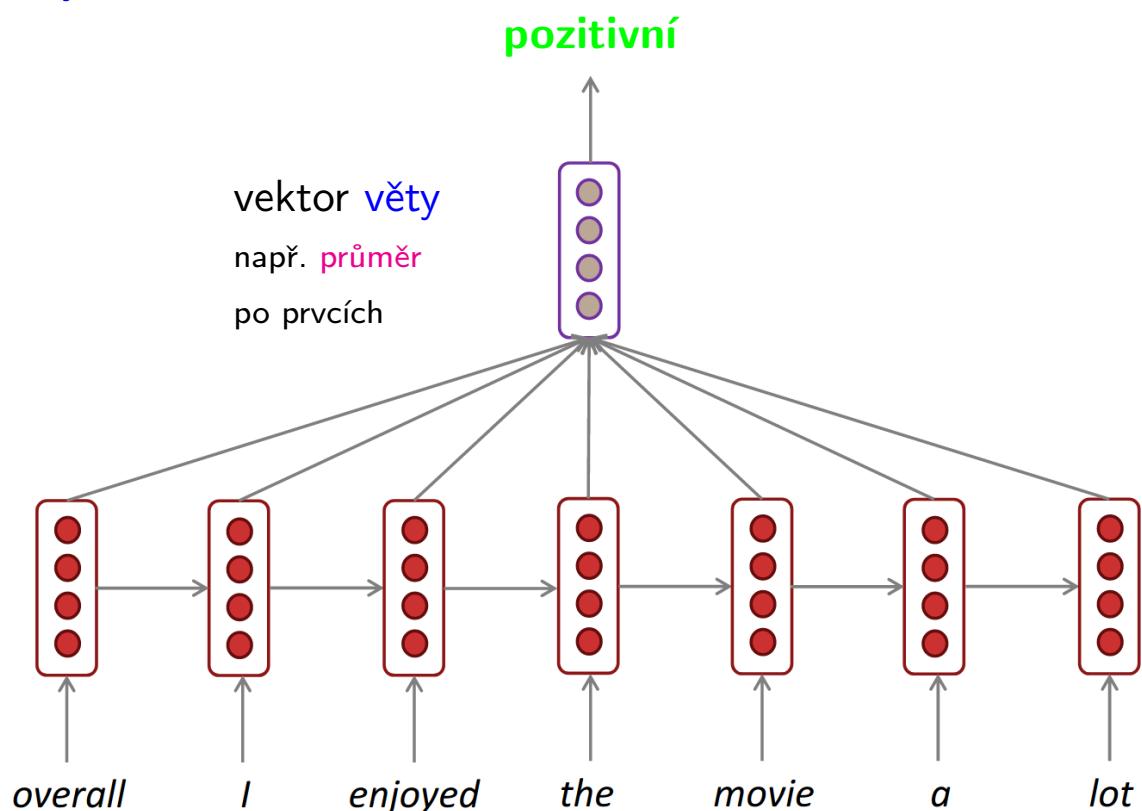
Hodnoty hyperparametrů se určují podle zkušeností nebo experimentálně

# Využití rekurentních sítí – značkování



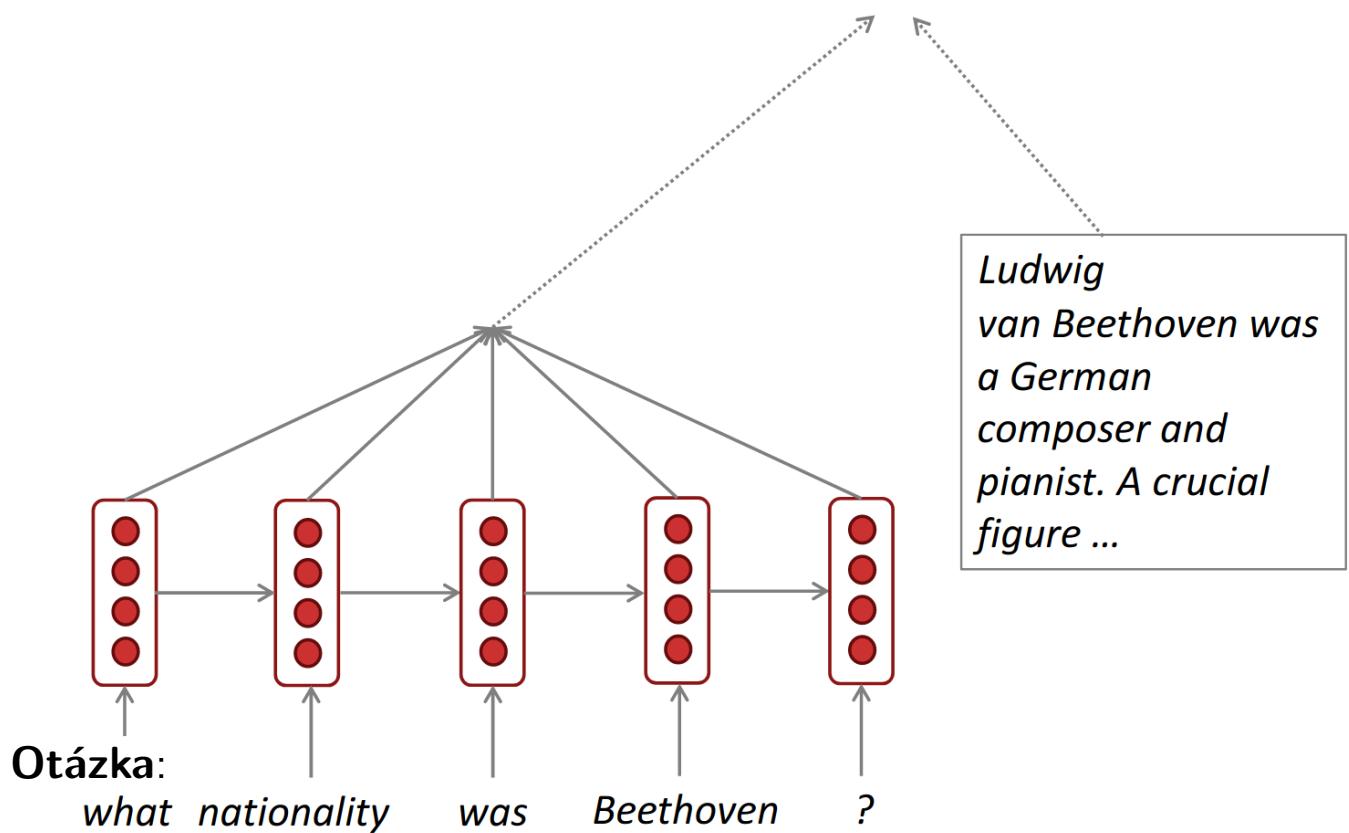
# Využití rekurentních sítí – klasifikace vět

např. analýza sentimentu



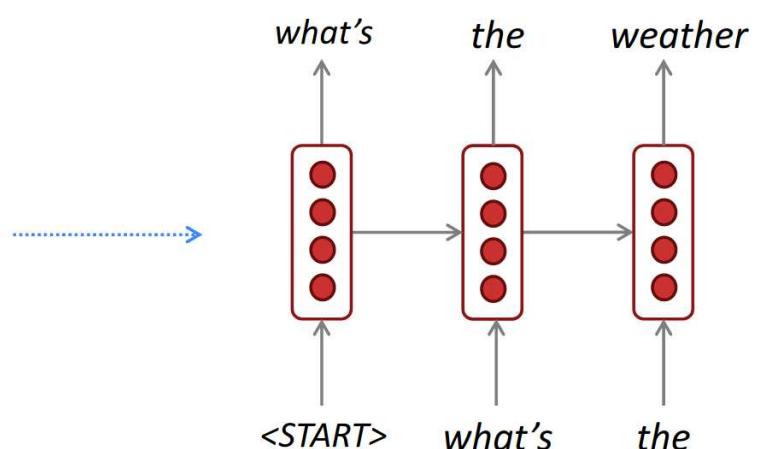
# Využití rekurentních sítí – odpovídání na otázky

Odpověď: German



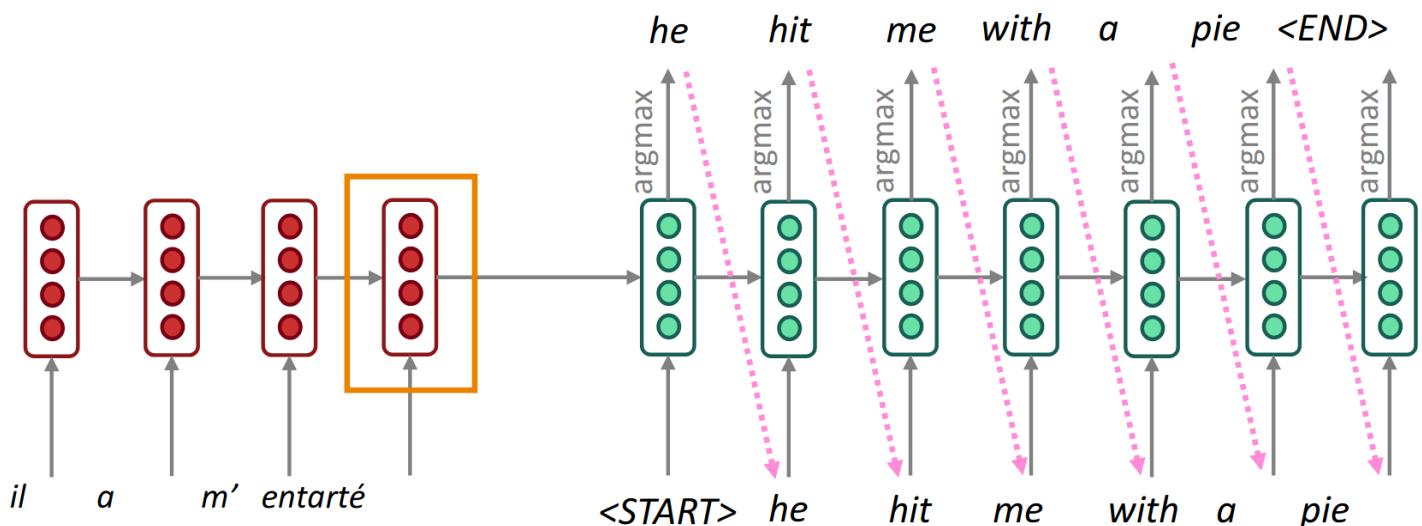
# Využití rekurentních sítí – podmíněné generování

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



# Využití rekurentních sítí – seq2seq

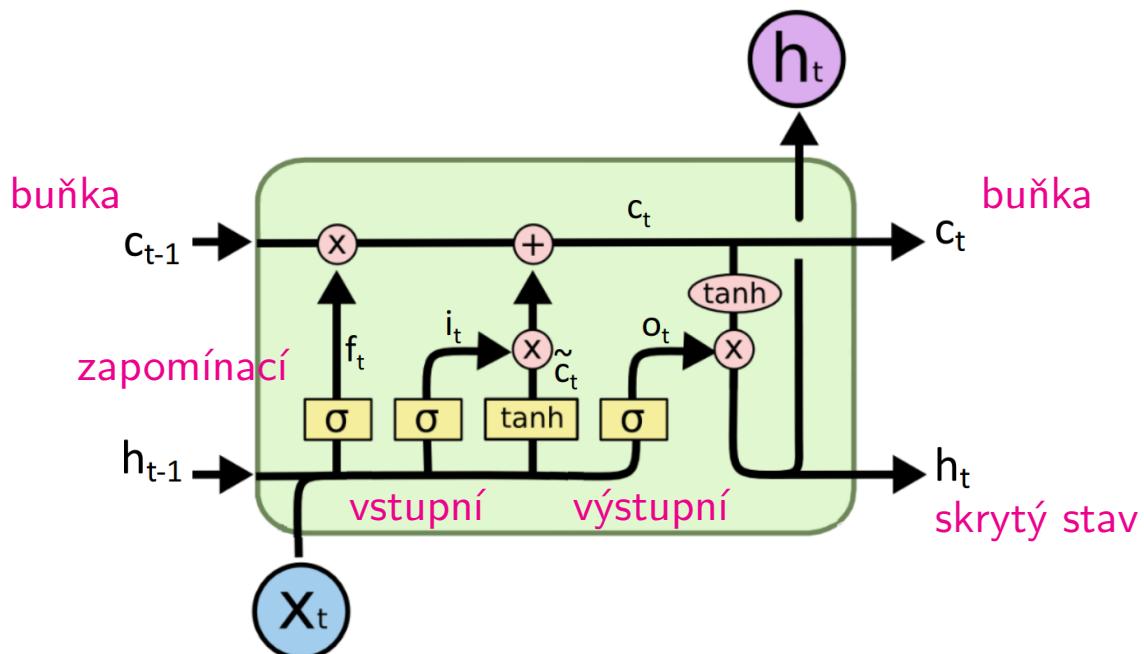
častá varianta – model **sequence-to-sequence** (seq2seq)  
 dvě rekurentní sítě – **enkodér** a **dekodér**



## 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

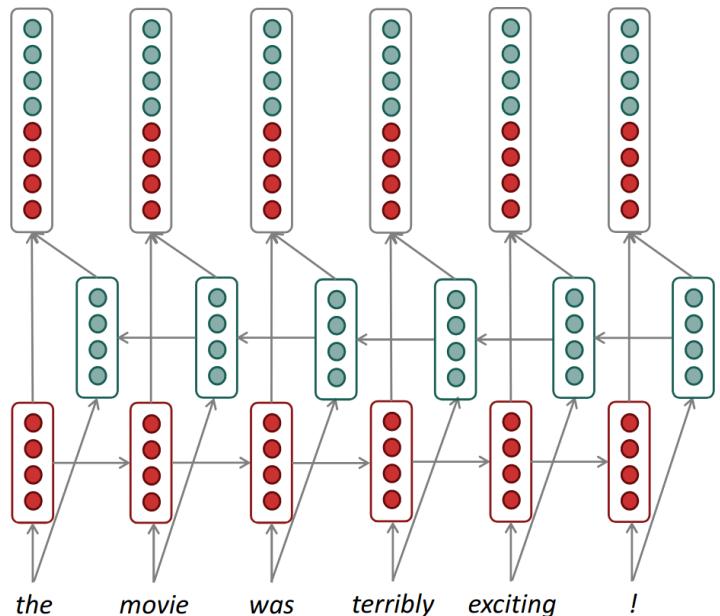


# Architektura Long Short-Term Memory (LSTM)

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

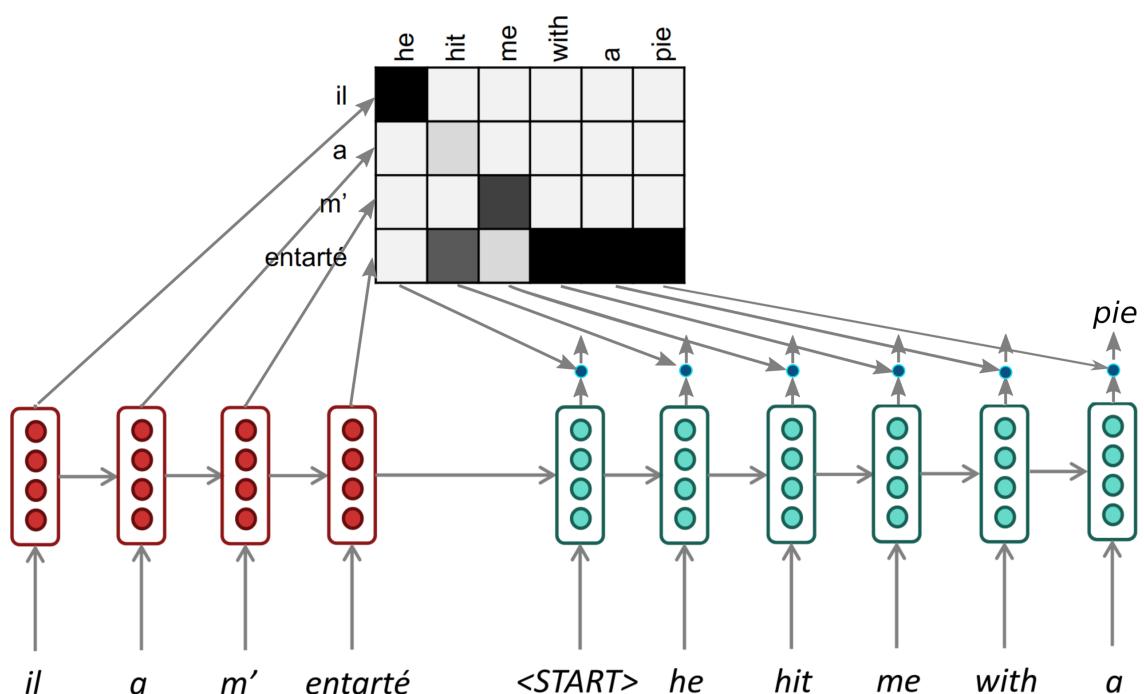
rekurence je **směrovaná** –  
 zleva doprava  
 ⇒ jiný důraz při průběhu  
**zprava doleva**

**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)

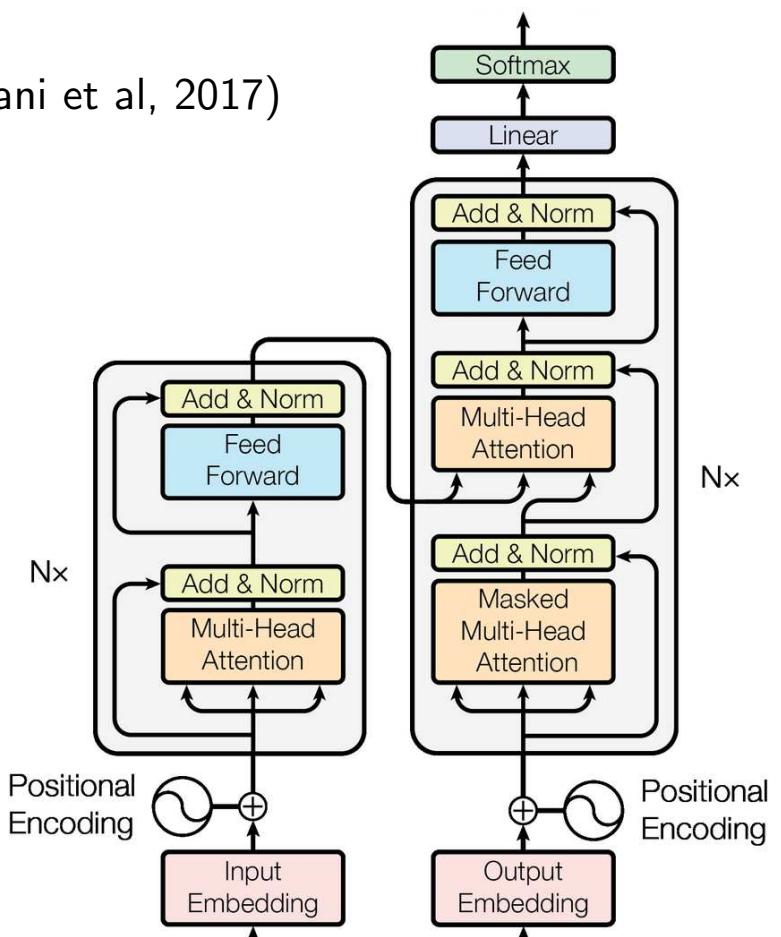


# Architektura Transformer

“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

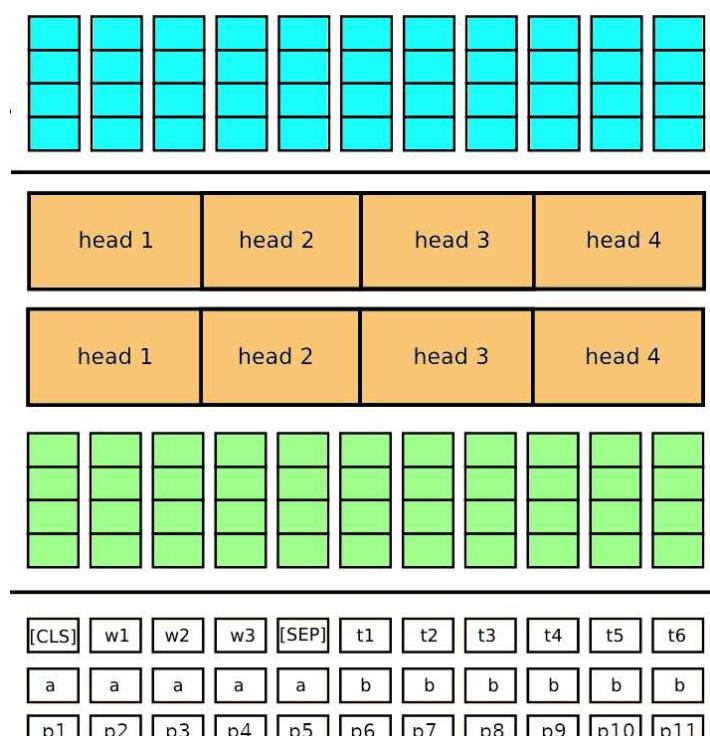
## nevýhody:

- ▶ 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)

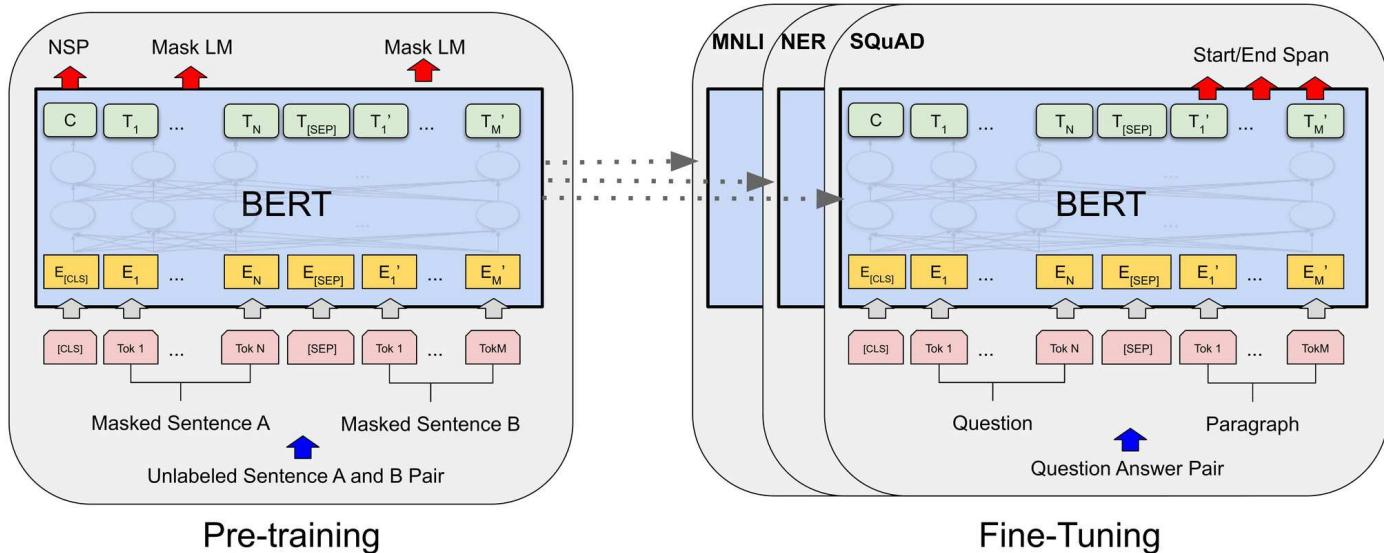
- ▶ jen enkodér
- ▶ symboly [CLS], [SEP] a [MASK]
- ▶ vektory segmentů
- ▶ maskovaný vstup
- ▶ úloha predikce následující věty (*Next Sentence Prediction*) u ALBERT predikce pořadí vět (*Sentence Order Prediction*)



# 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**

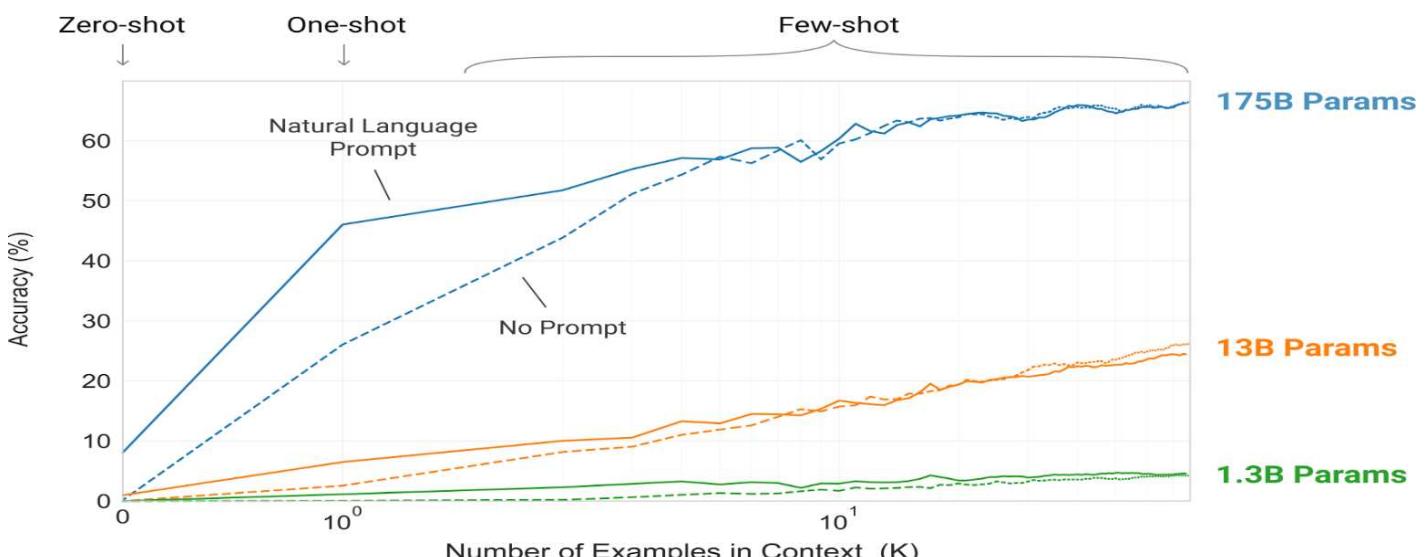


## GPT, T5, ELMo, ERNIE, ELECTRA, ...

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](https://beta.openai.com/examples)