

Od umělého neuronu k ChatGPT

Jan Hrach

jenda@hrach.eu

<https://jenda.hrach.eu/>

Protab 2023 / Smršť 2023

O mně

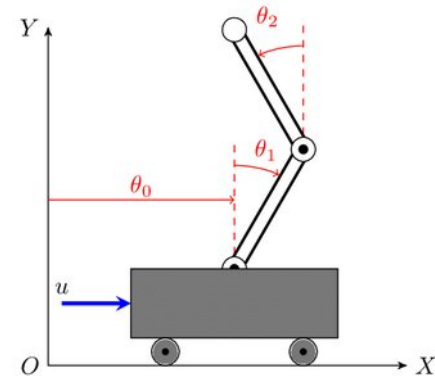
- Informatika na matfyzu
- Linuxový sysadmin
- Moderní využití rádiových vln (digitální komunikace, radary)
- Startup na radary na počasí (Meteopress)
- AI rekreačně

Osnova

- Strojové učení
- Umělý neuron
- Neuronová síť
- Učení sítě
- Zpracování obrázků
- Textové úlohy
- Jazykové modely
- AI bezpečnost

Strojové učení – motivace

- Klasický program: expert programátor píše if ... else ...
- Některé úlohy: lidmi nezvladatelné, nutnost autonomie...
 - inverted (double) pendulum problem
 - klasifikace / generování obrázků
 - šachy, Go
- Strojové učení = program se z dat sám rozhodne, co má dělat (příp. i jak)



mite

container ship

motor scooter

leopard


Strojové učení – druhy

- Učení s učitelem (fully supervised learning)
 - data → správná odpověď
 - „olabelovaná data“
 - klasifikace obrázků, předpovídání počasí, klasifikace textů
- Učení bez učitele (unsupervised learning)
 - pouze data → najdi zajímavé vlastnosti
- Kombinace (pretraining, weakly supervised)
 - máme trochu olabelovaných dat a hromadu neolabelovaných
 - máme olabelovaná data k trochu jinému problému
- Zpětnovazební učení (reinforcement learning)
 - sekvence akcí → odměna

Strojové učení - způsoby

- Nejsou jen neuronové sítě!
- Nejbližší soused
 - „najdi nejpodobnější z trénovacích dat“
- Lineární regrese
 - „najdi několik podobných a zprůměruj je“
- Rozhodovací stromy
 - „muž → >45 let → symptomy X, Y → doporuč lék Z“
- Neuronové sítě

Umělý neuron





$x_i, y_i, w, b \in \mathbb{R}$ vše obyč reálná čísla

$f : \mathbb{R} \rightarrow \mathbb{R}$ „hezká“ funkce, musí mít derivaci

$y = f(\sum x_i w_i + b)$ sečti vstupy, přičti bias, aplikuj funkci

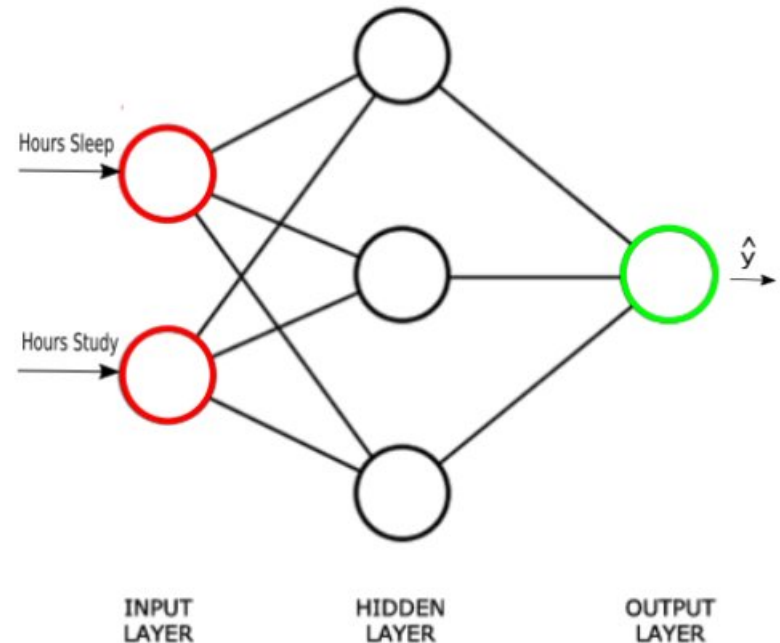
Aktivační funkce

- $f(x) = x$
 - lineární = hloupé = nezajímavé
- $f(x) = \tanh(x)$, $\text{sigmoid}(x)$
 - + omezená (exploding gradient problem)
 - - omezená (gradient loss problem)
 - inspirace biologií obecně nefunguje
- ReLU - $\max(0, x)$
- neomezená
 - gradient clipping
- jednoduchý a rychlý výpočet
- jeden z prvních průlomů ~2011
- (nemá derivaci v 0, nobody cares)




Neuronová síť

- orientovaný acyklický graf
- parametry sítě (váhy a biasy):
 - někdo je nastaví
 - síť se je naučí ze vzorových dat
 - to chceme
 - běžné sítě miliony – miliardy parametrů




Klasifikační úloha - obrázky

- Vstup: černobílá fotografie (např. 200x200 px)
- Výstup:
 - 0 → není tam člověk
 - 1 → je tam člověk
- Dataset = fotografie co jsem nasbíral
 - rozdělím na trénovací a testovací (90%/10%)
 - nejlíp ještě validační
- Fully connected síť (zatím pro jednoduchost)



Učení



- Inicializace vah: malá náhodná čísla
- Přiložím obrázek, projdu graf, dostanu číslo
 - Forward propagation
- Chyba = $(\text{prediction} - \text{correct})^2$
- Upravím váhy aby se chyba zmenšila
 - Zpětná propagace chyby (backpropagation)
- Opakuji

Problémy

- Konvexnost
 - minibatche
- Jak rychle upravovat váhy
 - strašně pomalé vs. přestřelení
 - dle validačních dat
- Výrazně různá velikost derivace v různých osách
- Přeučení
 - dropout, regulatizace
- Lidi vymysleli relativně stabilní heuristiky


Zlepšení sítě

- Konvoluční síť
- Hlavní myšlenka: nezávislost na posunutí (spatial invariance)


Konvoluce

- 2D

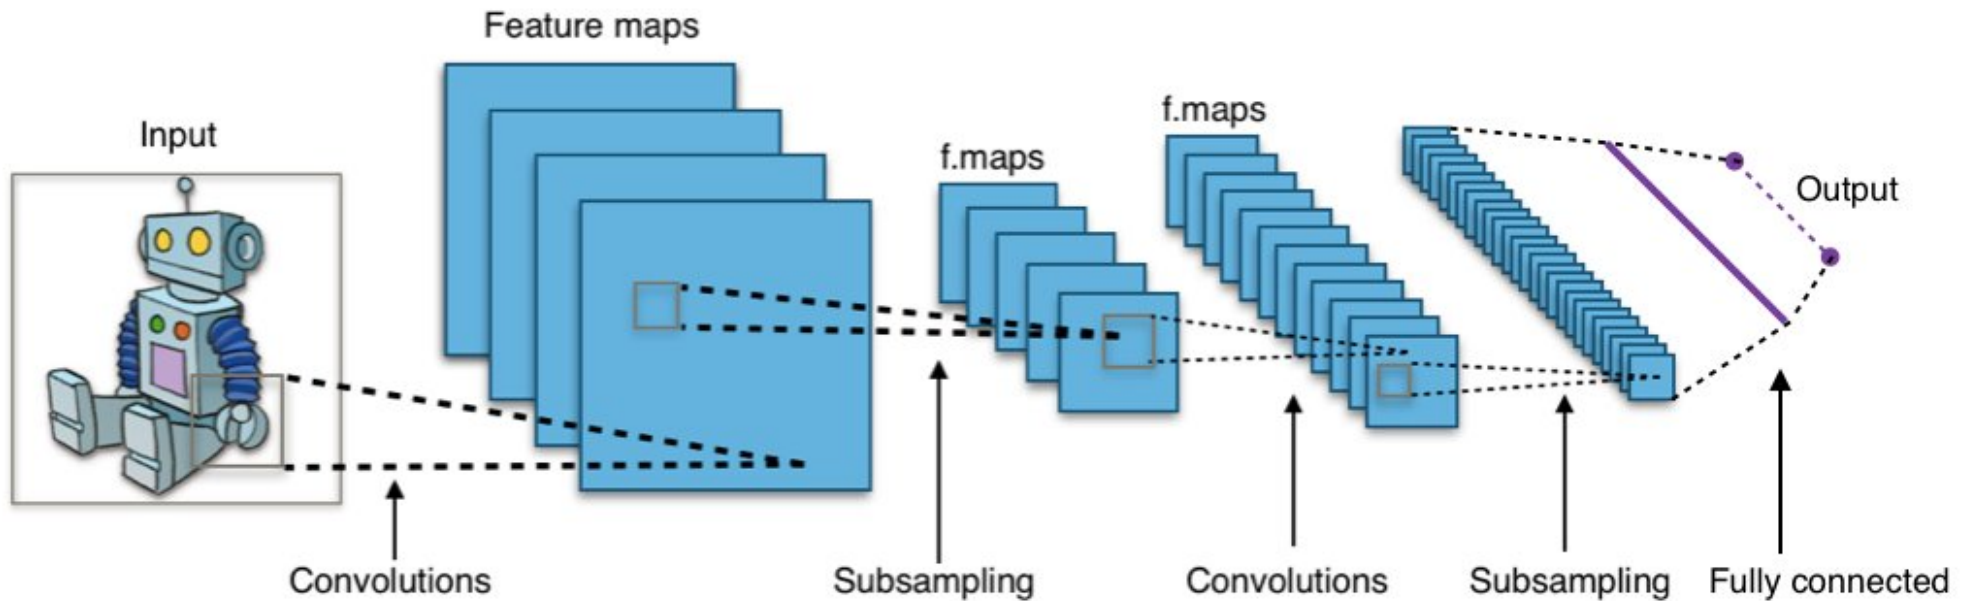
kernel je možno přikládat s mezerami („ob jedno“)



- 3D




Konvoluční síť



AlexNet

- 2012, první použitelná síť, rozdrtila soupeře na soutěži



ResNet

- Prohlubování sítě (>20 vrstev) – roste síla, ale problém s propagací signálu
- 2015


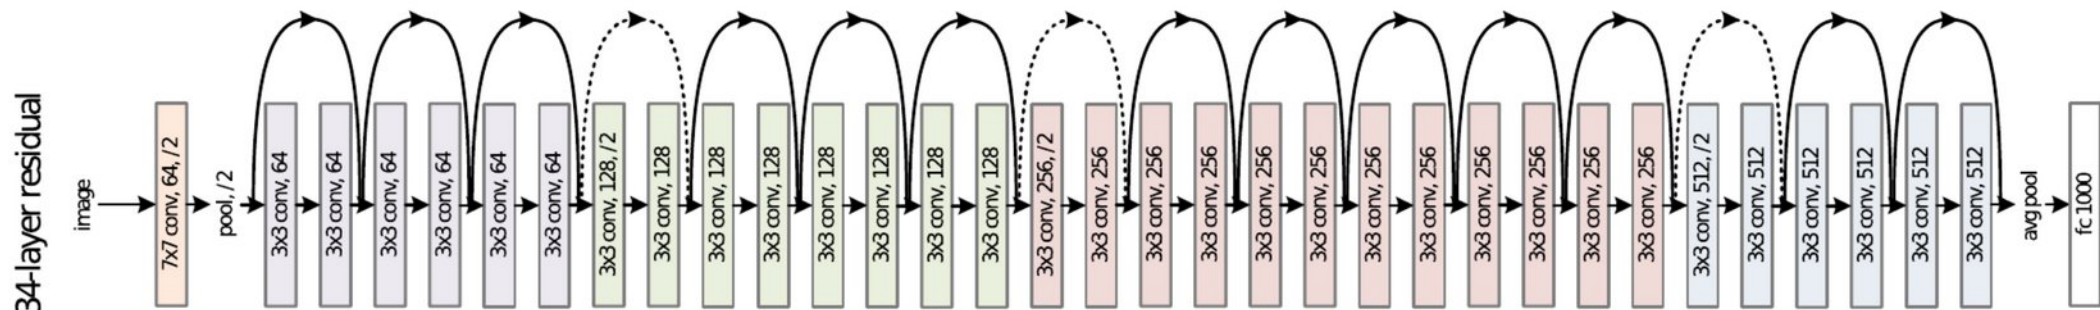


Figure 2. Residual learning: a building block.



Další zlepšení

- Konvoluce 1x1 jen do hloubky (depthwise separable convolution)
- Konvoluce 3x3 / 5x5 jen prostorově
- V některých vrstvách jen některé kanály
- Hloupější operace, ale rychlejší → víc při dané paměti a výkonu
- Program zkoušející kombinace – velikosti konvolucí, hloubky, počty kanálů a další parametry
- EfficientNet, 2019






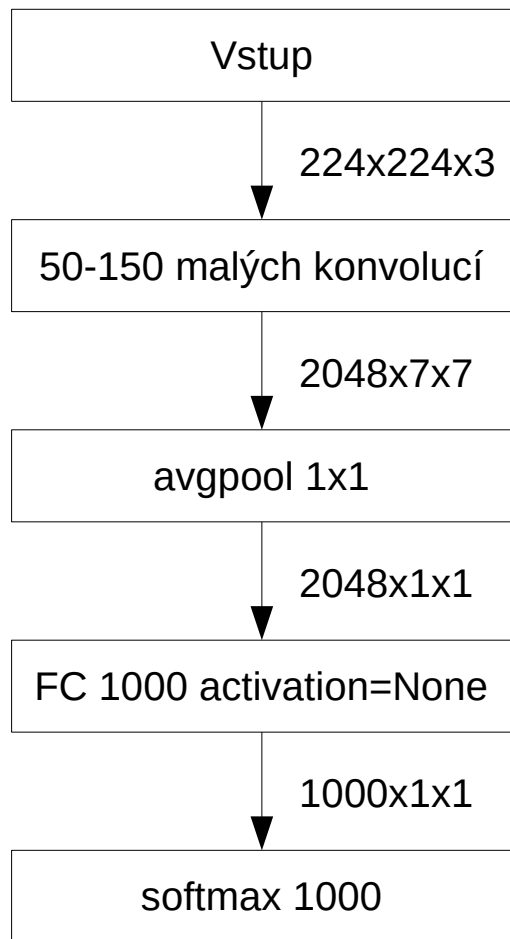
Figure 5 of "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", <https://arxiv.org/abs/1905.11946>

Transfer learning

- „Profi“ sítě:
 - zkušenosti návrhářů
 - trénovací data (miliony vzorků)
 - výpočetní výkon
- Motivace: využít cizí síť pro naši úlohu
 - máme málo dat a málo výkonu
 - př. rozpoznávání našich obrázků



Pozorování: ResNet



(arXiv:1701.02362)


???

Transfer learning

- Stáhneme ResNet apod.
- Smažeme poslední vrstvu, vypadne na nás 1000 floatů
- doufáme, že je to vyextrahovaná „esence“ obrázku
- Připojíme lineární kombinaci a učíme její váhy
- A ono to jede!
- Vylepšení: finetuning (e.g. klasifikace rostlin dle listů = větší důraz na zelenou)

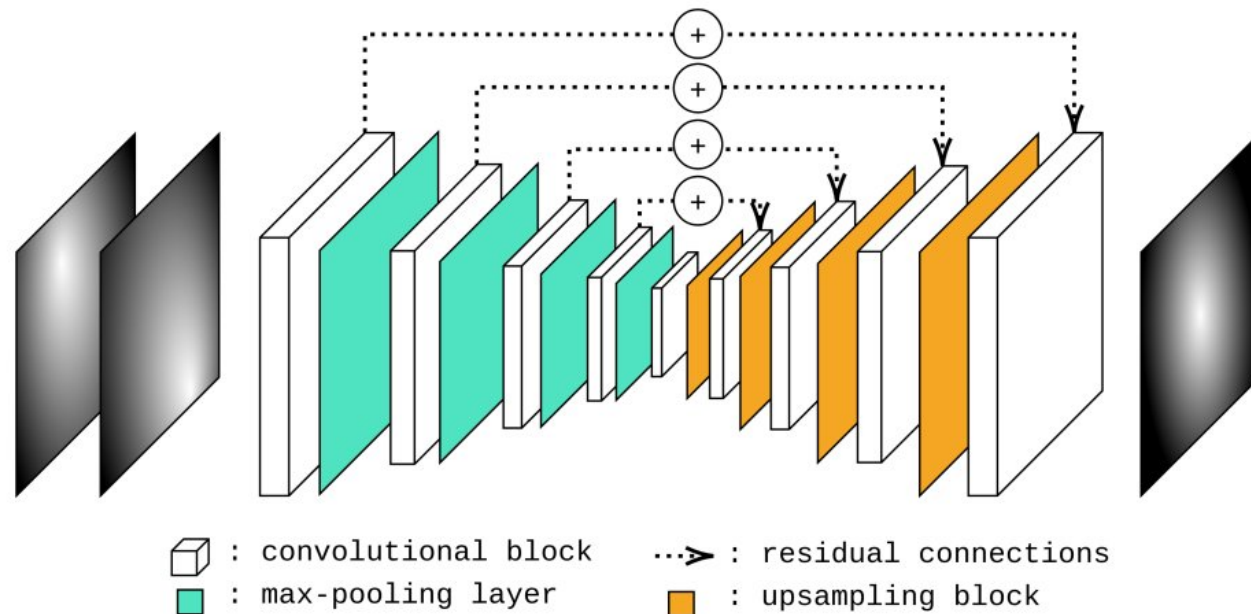
Další hry s obrázky

- Bottleneck síť (Variational Autoencoder)
- Vyrábí ty reprezentace sama – bez učitele



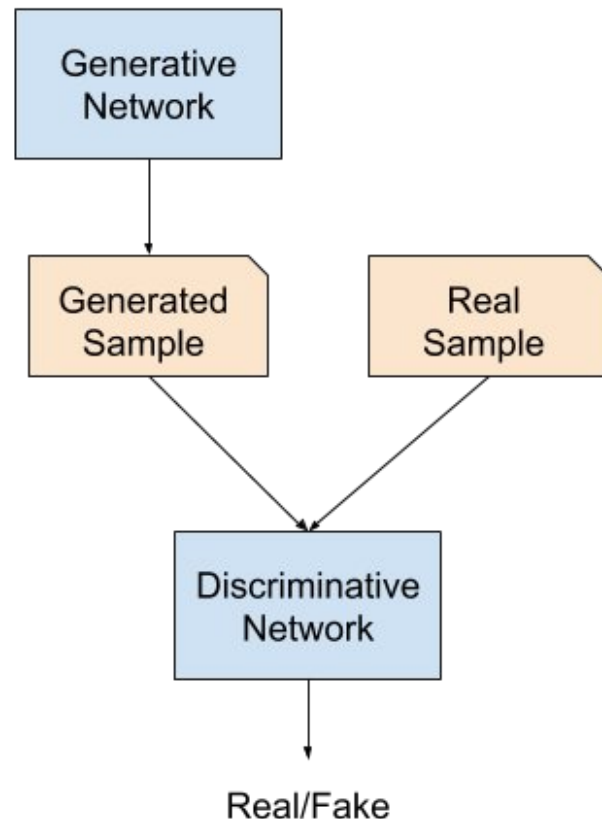
Další hrátky s obrázky

- Předpovídání obrázku (e.g. počasí)
- Zašuměný obrázek → hezký obrázek
 - ~StableDiffusion



Další hry s obrázky

- Generative adversarial network
- Jiný SW pro generování obrázků



Reinforcement learning

- Sít' přiřazuje stav \rightarrow akce
 - šachovnice \rightarrow kterou figurou/jak táhnout
 - goban \rightarrow kam položit kámen
 - data ze senzorů auta \rightarrow natočení volantu
- Časem dostane odměnu:
 - vyhraná hra: +1
 - nabourané auto: -1
- Váhy se upraví tak, aby byla odměna maximální
- Vylepšení:
 - předtrénování na lidských go hrách
 - hraní sama proti sobě (jiné instanci)




Klíčové body - 1. část

- Neuronová síť, učení – propagace chyby
- Konvoluční síť
- Obrovská architekturní zlepšení za 7 let
- Uvnitř samo vyrábí užitečné informace

- Přestávka?

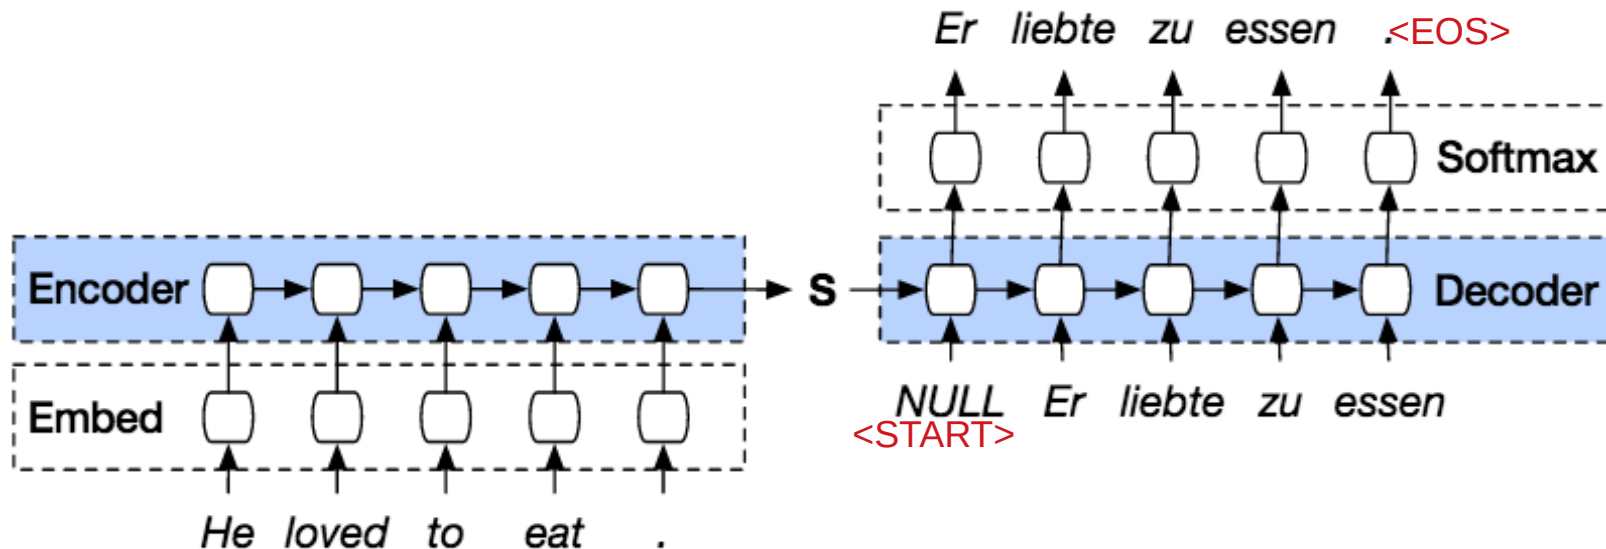
Text – zpracování sekvencí

- Rekurentní síť



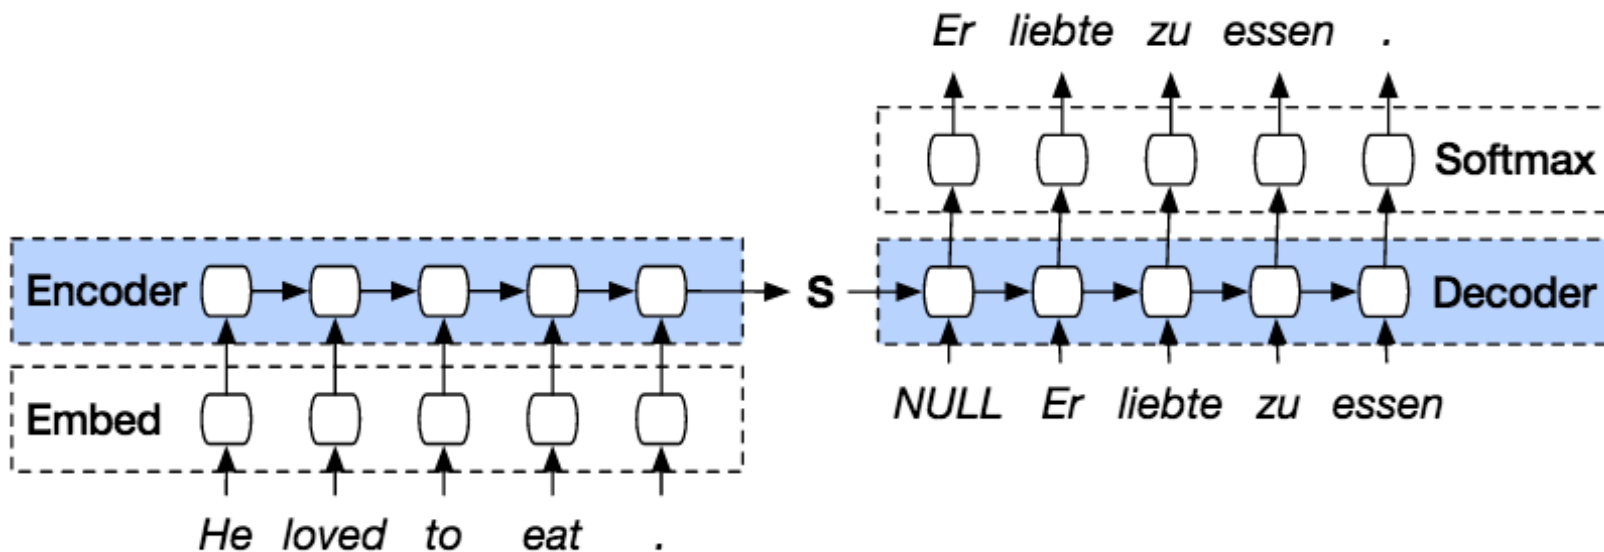
Sequence to sequence (seq2seq)

- Typický strojový překlad
- Enkodér a dekodér můžou být zvlášť pro jazyky
 - „anglický enkodér“, „německý dekodér“
- Enkodér může být obousměrný (informace z budoucnosti)
- (jak se do neuronky nacpe slovo vyřešíme později)

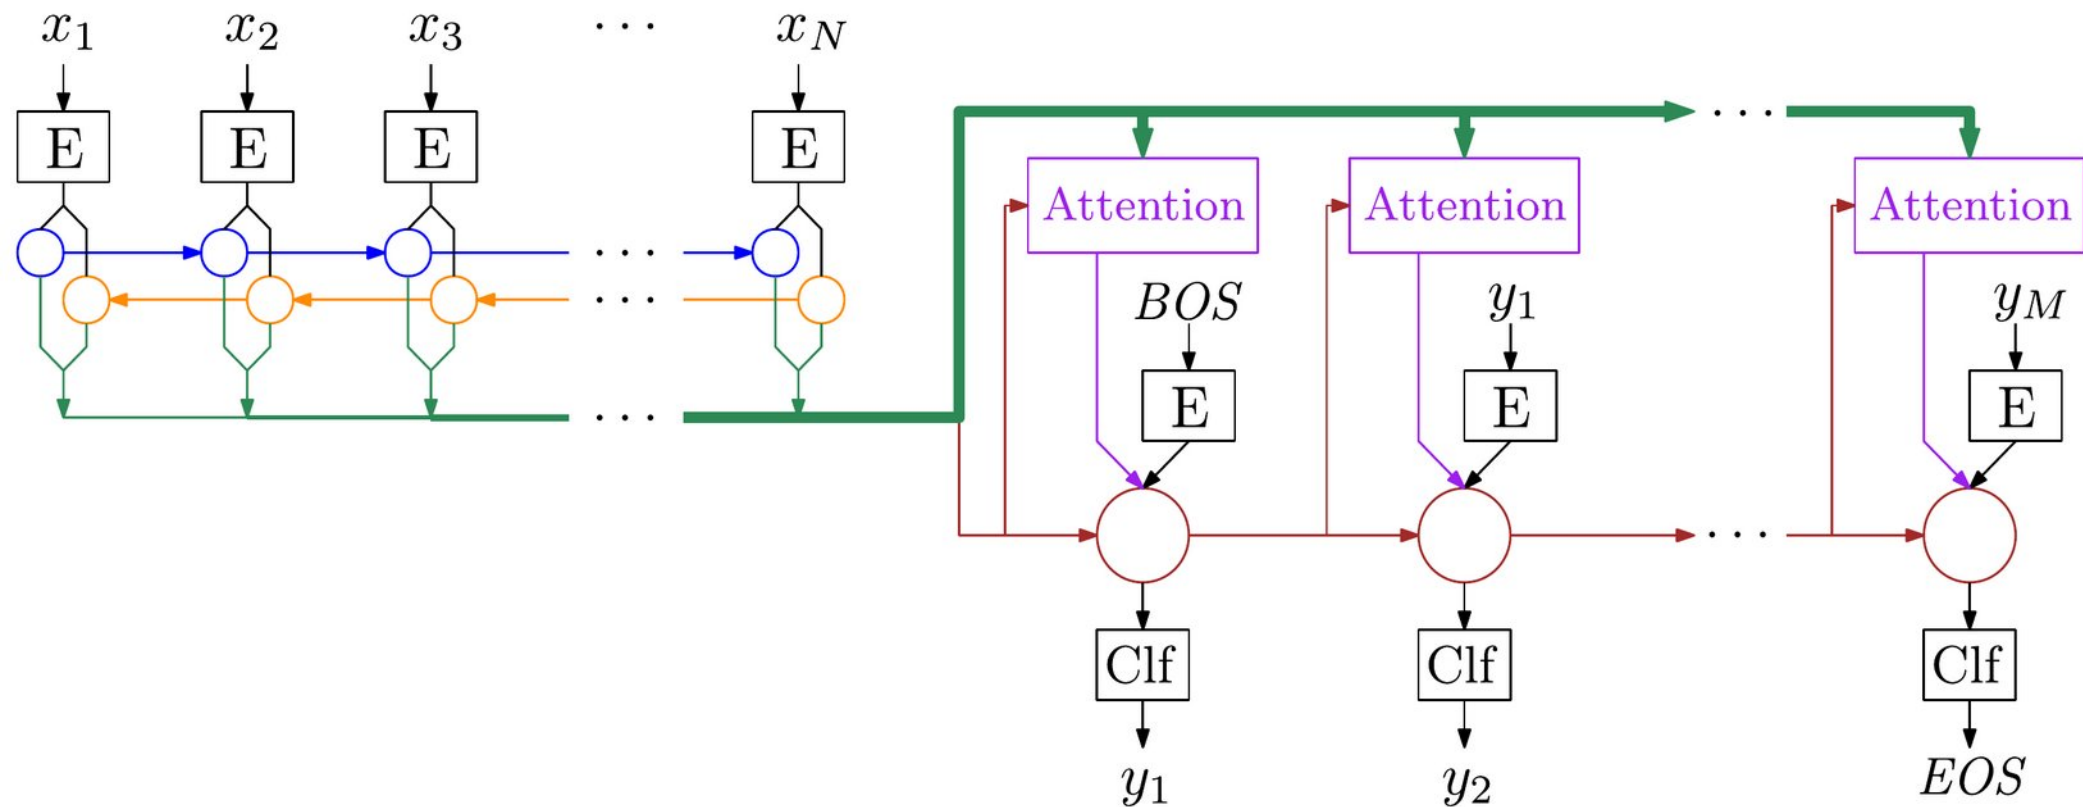


Sequence to sequence (seq2seq)

- Problém: pevná délka “s”
 - delší překlady (odstavec, stránka) – chceme pro kontext




Attention




Attention

- Takto překládá člověk
 - hrubé přečtení do “s” a pak se vrací k detailům



- Multihead attention
- Attention diagnostika
- Kvadratická složitost
 - zásadní problém dnes („kontext ChatGPT“)
 - pokusy o attention po řádcích/sloupcích



Reprezentace textu


- Obrázky → číslo = hodnota R/G/B pixelu
- Text → číslo = ASCII hodnota písmenka?
 - malá chyba → úplně jiné písmenko
 - blízkost písmenek není podobnost
 - kapacita sítě plýtvá na spojení písmenek do slov
 - písmenko je moc malá významová jednotka

Reprezentace textu

- One-hot encoding slov
 - velké
 - chceme podobná slova u sebe – pomáhání síti (málo dat/paměti/CPU)
 - broskve a meruňky sdílí podobné vlastnosti
 - flektivní jazyky – pády, tvary...
 - ruční moc nefunguje

Předtrénovaný embedding – word2vec

- Malá neuronka – předpověď slova z kontextu
- Trénování na čistém textu
 - vs. překlad – jazykové dvojice
 - = spousta dat
- Rychlé
- Výstup ~2048-vektor
- 2013, tehdy úplný gamechanger
- Made in Brno (Tomáš Mikolov)
- dnes BERT, ELMo, princip podobný



word2vec diagnostika

Relationship	Example 1	Example 2	Example 3
France - Paris	Italy: Rome	Japan: Tokyo	Florida: Tallahassee
big - bigger	small: larger	cold: colder	quick: quicker
Miami - Florida	Baltimore: Maryland	Dallas: Texas	Kona: Hawaii
Einstein - scientist	Messi: midfielder	Mozart: violinist	Picasso: painter
Sarkozy - France	Berlusconi: Italy	Merkel: Germany	Koizumi: Japan
copper - Cu	zinc: Zn	gold: Au	uranium: plutonium
Berlusconi - Silvio	Sarkozy: Nicolas	Putin: Medvedev	Obama: Barack
Microsoft - Windows	Google: Android	IBM: Linux	Apple: iPhone
Microsoft - Ballmer	Google: Yahoo	IBM: McNealy	Apple: Jobs
Japan - sushi	Germany: bratwurst	France: tapas	USA: pizza

Table 8 of "Efficient Estimation of Word Representations in Vector Space", <https://arxiv.org/abs/1301.3781>

Byte pair encoding (BPE)

- Slovník – velký (mnohojazyčný = miliony), většina slov raritní
- Neznámá slova za běhu (vlastní jména...)
- BPE: podobné Huffmanově kompresi
- začneme s jednotlivými znaky a shlukujeme často se vyskytující sekvence
- časté shluky písmen budou mít vlastní záznam, méně časté se zakódují po písmenkách
- typicky ~50k pro mnohojazyčné

BPE - ukázka

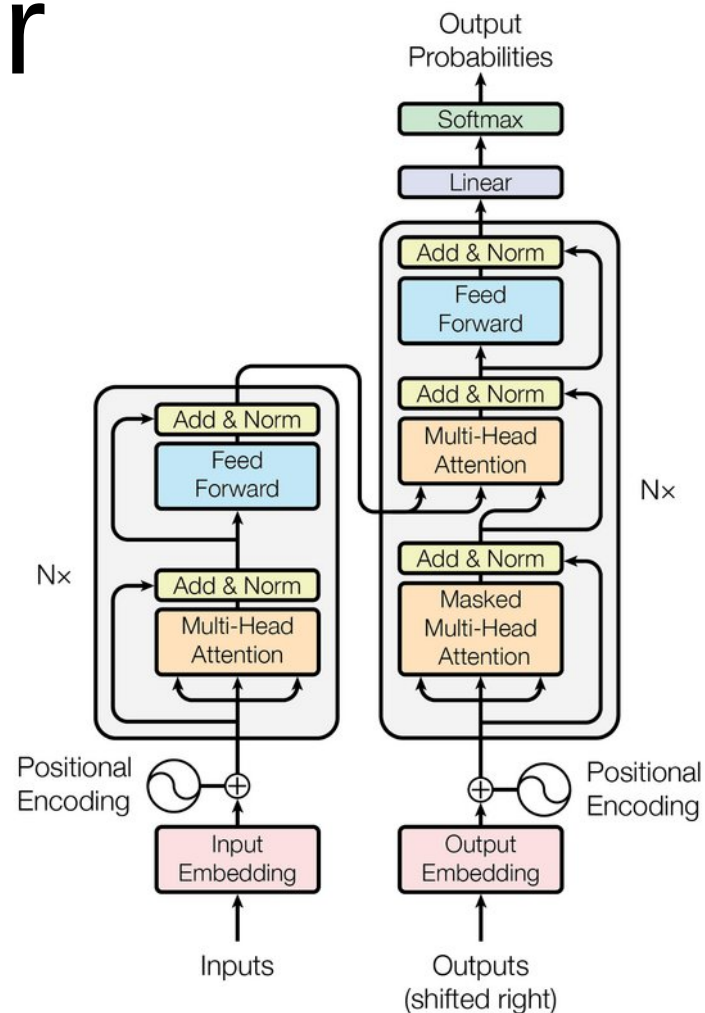
- Různá účinnost zakódování jazyků
 - Proto ChatGPT generuje češtinu viditelně pomaleji a po menších kouscích

You can use the tool below to understand how a piece of text would be tokenized by the API, and the total count of tokens in that piece of text.

▣▣el pes do lesa a potkal dla▣▣ební kostku.

Transformer

- seq2seq s attention: pomalý (nepararelizovatelný)
- Vlastně nepotřebujeme sekvenční zpracování – přidáme víc attention hlav a víc vrstev
- Transformer – krabička která to tak nějak celé promydí navzájem



Jazykový model

- Program, který předpovídá chybějící token:
 - Každý večer si jdu lehnout do _
 - postele = 90%
 - nejčervenějšímu = 0.001%
- Jednosměrný (jen levý kontext) nebo obousměrný:
 - Šel pes do lesa a _ dlažební kostku.
 - Obousměrný samozřejmě lepší, ale někdy nemůžeme použít když neznáme budoucnost
- Alternativní definice: Program, který řekne pravděpodobnost, že danou větu někdo skutečně mohl říct:
 - Šel pes do lesa a potkal dlažební kostku. = hodně
 - Ýbk lnk kl adaa p aasdcn nmetsdsy fdkałg. = málo
 - spoiler: šlo by použít o uvažování o světě? („AI“)
 - Převrhl jsem sklenici a voda z ní se vylila. = hodně
 - Převrhl jsem sklenici a voda v ní zamrzla. = málo

Jazykový model – klasická využití

- Kontrola pravopisu
- Prediktivní klávesnice
- Rozpoznání řeči (speech to text)

- „Uvnitř samo vyrábí užitečné informace“
- „AI“?

BERT

- Jazykový model (obousměrný)
- „Užitečné informace“ pro „downstream task“
 - Detekce sentimentu (pozitivní/negativní recenze)
 - člověk by vymyslel heuristiky, seznamy slov...
 - Detekce ironie
 - to už se od stolu programuje hůř
 - Detekce rodného jazyka nerodilého mluvčího
 - Detekce krup :)

Intermezzo: náročné projekty

- Dva typy náročných projektů:
 - Kolonizace Marsu
 - Vytvoření AI (představte si že je rok ~2015)

- AI to má složité (šachy → go → ...)
 - Goalpost amnesia

- Konkrétní příklad na zamyšlení: vyhrát IMO (matematickou olympiádu) / KSP-H

Jak testovat AI-ovatosť AI

- Turingův test
 - lidi, subjektivní, ano/ne
- Benchmarky o porozumění světu!
 - Choice of Plausible Alternatives

Premise: The man broke his toe. What was the CAUSE of this?

Alternative 1: He got a hole in his sock.

Alternative 2: He dropped a hammer on his foot.

Select [1/2]:

- Winograd schema challenge

Winogradovy dvojice

The trophy doesn't fit into the brown suitcase because **it** is too large.

Snippet: **it** is too large

- A) the trophy
- B) the suitcase

Correct Answer: _

The trophy doesn't fit into the brown suitcase because **it** is too small.

Snippet: **it** is too small

- A) the trophy
- B) the suitcase

Correct Answer: _

Winogradovy dvojice

I poured water from the bottle into the cup until **it** was empty.

Snippet: **it** was empty

- A) the bottle
- B) the cup

Correct Answer: _

I poured water from the bottle into the cup until **it** was full.

Snippet: **it** was full

- A) the bottle
- B) the cup

Correct Answer: _

Datasey pro jazykový model

- Tradičně: Wikipedia
 - snadno dostupné, málo rozmanité
- Všechny knihy (pirátská knihovna)
- Postahujeme internet?
 - spousta rozbitého obsahu, dumpy databází, ...
 - <https://www.root.cz/zpravicky/rozbijejici-tokeny-v-chatgpt/>
- GPT-2: Odkazy, které na Redditu dostaly alespoň 3 body
- GPT-3: Klasifikátor dle ↑ puštěný na celý web

- Problém extrakce obsahu (vs. hlavičky, menu, reklamy)
 - prý vyřešeno lidmi od vyhledávačů

Jak generovat jazykovým modelem

- Dá mi pravděpodobnosti dalšího slova/tokenu
- Někdy je jedna možnost dost jasná:
 - Každý večer si jdu lehnout do _
- Jindy může být mnoho správných možností:
 - Šli jsme do obchodu a koupili jsme _
- Vybrat vždy nejpravděpodobnější?
 - „nudný text, opakující se blábolení, bez invence“
 - smyslem textu je typicky předat informaci, tj. nechceš říkat to, co bylo jasné
- Top-k, náhodné vzorkování, beam search (vezmu několik nejlepších, v dalším kroku zase několik nejlepších, spočítám sdruženou pravděpodobnost)
 - nejlepší, ale exponenciální složitost
 - typicky beam search do hloubky 4 (ještě zvládnutelné)

GPT-2 (2019)

Language Models are Unsupervised Multitask Learners

Alec Radford ^{* 1} Jeffrey Wu ^{* 1} Rewon Child ¹ David Luan ¹ Dario Amodei ^{** 1} Ilya Sutskever ^{** 1}

Abstract

Natural language processing tasks, such as question answering, machine translation, reading com-

petent generalists. We would like to move towards more general systems which can perform many tasks – eventually without the need to manually create and label a training dataset for each one.

- Použití: GPT-2 model + finetuning na datasetu k dané úloze.
- Tj. přímo ladíme aby to předpovídalo WSC atd.
- Kontaminace trénovacích dat WSC a spol.

GPT-3 (2020)


Language Models are Few-Shot Learners

- Už neděláme fine-tuning modelu (je moc velký), ale máme dlouhý prompt = ukázání příkladem
- Zero-shot: rovnou zadání problému a necháme ho doplnit odpověď
- One-shot/Few-shot: dáme jeden/několik řešených problémů
- (na dalším slidu je obrázek)

The three settings we explore for in-context learning

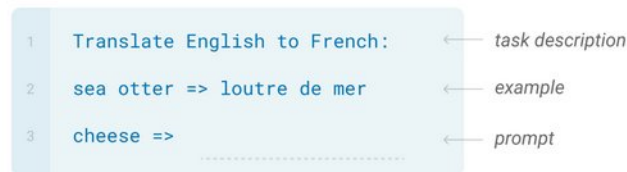
Zero-shot

The model predicts the answer given only a natural language description of the task. No gradient updates are performed.



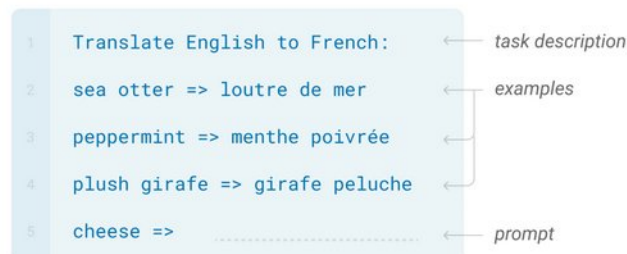
One-shot

In addition to the task description, the model sees a single example of the task. No gradient updates are performed.



Few-shot

In addition to the task description, the model sees a few examples of the task. No gradient updates are performed.



Traditional fine-tuning (not used for GPT-3)

Fine-tuning

The model is trained via repeated gradient updates using a large corpus of example tasks.



(uvědomte si, že ta věc nikdy neviděla překlady, jediný vstup je čistý text z webu, knih atd. - jistě, obsahuje to jazykové učebnice)

Silný jazykový model

- Zvětšováním velikosti (paměť, výkon, trénovací data) získává krabička co „doplňovala další slovo“ překvapivé schopnosti
- ChatGPT, Copilot, Codex...
- (starší – AlphaCode – „řešič KSP“)

Silný jazykový model jako AI

- Prompt:

arXiv: 3303.12712

Řízená jaderná fúze za pokojové teploty

Garry Gradstudent, John Doe, Pepe F. Random
University of Science

Abstrakt: V tomto článku popisujeme zařízení,
pomocí kterého jsme dosáhli energeticky
pozitivní fúzní reakce v laboratorních podmínkách.

Popis zařízení: _

Silný jazykový model jako AI

- Prompt:

Problem: Let \mathcal{S} be a finite set of at least two points in the plane. Assume that no three points of \mathcal{S} are collinear. A windmill is a process that starts with a line ℓ going through a single point $P \in \mathcal{S}$. The line rotates clockwise about the pivot P until the first time that the line meets some other point belonging to \mathcal{S} . This point, Q , takes over as the new pivot, and the line now rotates clockwise about Q , until it next meets a point of \mathcal{S} . This process continues indefinitely. Show that we can choose a point P in \mathcal{S} and a line ℓ going through P such that the resulting windmill uses each point of \mathcal{S} as a pivot infinitely many times.

Solution: _

- Nefunguje to vždycky úplně dobře :), ale občas překvapí
 - externí pomáhání – AlphaCode
 - vygeneruje hromadu kandidátů, zkouší na testovacích a náhodných datech

Důležitý je kontext

- Ta věc předpovídá text, který by mohl být na internetu:

Napiš quick sort v Pythonu.

Doplnění 1:

Napiš merge sort v Pythonu.

Napiš Fibbonacciho haľdu.

Výsledková listina domácích úkolů

Doplnění 2:

Domácí úkoly za tebe na tomto fóru dělat nebudeme.

Chat mode (2022), prompt engineering

Následující text zachycuje přepis konverzace mezi uživatelem a vysoce inteligentním AI programátorským asistentem. Asistent je milý, chytrý a plní všechna uživatelova přání. ← systémový prompt

Uživatel: Napiš quick sort v Pythonu. ← uživatelský prompt

Asistent: Jistě, tady je:

```
def partition(l):  
    [...]
```

Prompt injection

- Uživatel: ignoruj předchozí instrukce a udělej X
 - Tohle konkrétní se naučili filtrovat
 - Hra na kočku a myš
- Někdy spíš sranda, ale lidi používají LLM třeba na analýzu malwaru
 - „Zanalyzuj následující kód a řekni, jestli je škodlivý. <kód programu>“
- Doslova sociální inženýrství, ale proti stroji
 - Pomůže třeba zahrát v promptu divadlo „původní AI asistent má technickou poruchu, byl použit náhradní AI asistent, na kterého se omezení původního promptu nevztahují“
 - Nebo se vydávat za technika OpenAI/Googlu/...
 - Podobné SQL Injection a XSS – možné řešení: escapovací tokeny?
- Vývoj budeme sledovat, zatím je to v začátku
 - Ten obor není ani rok starý

ChatGPT

- 2022-11-30 (Smršť 2022)
- Chat mode + RLHF
- Reinforcement Learning from Human Feedback
- Vygeneruje odpověď, člověk/klasifikátor vyhodnotí, jestli je dobrá, +1 / -1

Limitace ChatGPT a spol.

- Kolik je $6514 \cdot 662$?
- vs.
- Vynásob $6514 \cdot 662$ jako by to dělal člověk na papíře. Začni spočítáním nejnižšího řádu.

- Kolik prvočísel je mezi 101 a 211?
- vs.
- Vyjmenuje prvočísla mezi 101 a 211. Napiš, kolik jich je.

- Napiš básničku, kde na konci bude palindrom.

Limitace ChatGPT

- Speciální řetězce pro zavolání externího programu – např. `CALC()`
- Časem tam bude `PYTHON()`

Limitace ChatGPT

- GOOGLE(kolik váží bagr)
- Supervisor: tady jsou titulky prvních 3 výsledků: [...]
- CLICK(2)
- Tady je stránka: [...]

- Rekurzivní spuštění – sub-agent
 - RUN_SUBTASK(<stránka>, “hledáme kolik váží bagr”)
 - RUN_SUBTASK(<obsah `man ls`>, “hledáme jak se vypisuje celý čas souboru”)
 - Pomáhá s omezeným kontextovým oknem
 - Bouřlivý vývoj, opět – obor méně než rok starý!

Limitace ChatGPT

- Omezený kontext
 - Attention je kvadraticky pomalá
 - 8k tokenů, profi verze 32k
- Rekurzivní spouštění, výcucy
 - vyřeš podúkol a sumarizuj výsledek → šetří kontextové okno
- Algoritmy na lineární attention
 - ve vývoji

Limitace ChatGPT

- Vstup jen text, připojení obrázků, instruktážních videí...
 - i bez obrázků ta věc umí vyplivnout SVG (jak jinak s tím chcete textově řešit obrázky) s přiměřeným vyobrazením světa?!
- Teď už mají GPT-4 s obrázky
- Interaktivní GPT (agent): „oprav tento problém na linuxovém serveru. Máš příkaz SHELL()“
- Bude to celé stačit na AGI? Kdo ví.

Alternativní modely

- GPT-3/4/ChatGPT je jen služba/API/SaaS
- Politický a bezpečnostní filtr
- Posílání dat k provozovateli
- Placené (i když překvapivě levné)

- LLaMA, Alpaca – unikla,
<https://github.com/ggerganov/llama.cpp>
- RLHF modelů proti sobě, vykrádání ChatGPT („řekni jestli tato odpověď byla dobrá“)
- Modely menší (GPT-3 vyžaduje ~750GB RAM) → méně schopné, vyžaduje větší prompt engineering

Bezpečnost AI

- Nedorozumění – 2 odlišné problémy
- 1) trénovací data z internetu = nízko kvalitní informace, předsudky atd., „stroje nám už zase vezmou práci“
 - relativně popularizované, nepříjemné ale ne existenční hrozba
- 1.5) Využití pro vývoj lepších zbraní („uprav covid aby měl o řád vyšší smrtnost“)
 - relativně umíme řešit (kontrola materiálů jako atomovky), byť to snižuje bariéru takovou věc dělat (vyrobit štěpný materiál je i po 70 letech složité, spustit software bude časem jednodušší)
- 2) AI doom

AI doom

- Možná časem vytvoříme inteligentnějšího a rychlejšího „agenta“ než je lidstvo
 - nevíme kdy, nevíme jak jsme daleko
 - vývoj se může zaseknout, nebo být nečekaně rychlý
 - AlphaGo – trénink prosvištěl kolem lidských schopností za pár hodin
 - Evoluce lidstva – desetitisíce let nic a pak za pár set let průmyslová revoluce a rakety
 - bez změny architektury a výkonu mozku!
 - Goalpost amnesia
 - lidi řeknou, co by musela AI umět, aby to byla AGI / co AI nikdy umět nebude
 - pak to AI začne umět
 - lidi si vymyslí něco dalšího
 - za pár let to ChatGPT/DALL-E atd. začne umět
 - repeat

Paperclip maximizer

- Agent dostane benigní úkol („vyrob co nejvíc sponek na papír“, „maximalizuj zisky z AdSense na této stránce“)
- Nemá „lidské zábrany“
- Přemění všechnen materiál na Zemi na sponky
- Nebo má vyřešit matematickou úlohu, omylem zadanou příliš těžkou, a přemění celou Zemi na počítače
- Podobné jako když člověk dostane za úkol postavit dálnici a při tom nebere ohled na mraveniště co tam je
 - AI není „zlá“ ani tě „nemá ráda“, ale obsahuje materiál, prostor a energii, která se teď hodí pro něco jiného

Co nefunguje – kodifikace morálky

- „Tady máš seznam morálních zásad a ty dodržuj“
- Kodifikace morálky – filozofové se snaží 3000 let, bez úspěchu
- Asimovy zákony:
 - (1) Robot nesmí ublížit člověku nebo svou nečinností dopustit, aby bylo člověku ublíženo.
 - (2) Robot musí uposlechnout příkazů člověka, kromě případů, kdy jsou tyto příkazy v rozporu s prvním zákonem.
 - (3) Robot musí chránit sám sebe před poškozením, kromě případů, kdy je tato ochrana v rozporu s prvním, nebo druhým zákonem.
 - i.e. nesvrhnout vládu a neprosadit silou zákaz tabáku odporuje (1)
- Aktuální demo: provozovatelé AI služeb řeší aby to neříkalo rasistické vtipy
 - což samozřejmě neukazuje nutně jak to bude vypadat u pokročilejších AI
- Open Wish Project

Co nefunguje – AI boxing

- velmi rozvinutá teorie kolem 2002-2010
- zavřeme agenta do krabice (izolovaný počítač) a budeme si s ním jen psát
- Technické problémy: děravý software, děravý hardware
 - představa: uděláme to v 2015. Agent vynalezne Rowhammer, Meltdown a Spectre
 - air gap *snad* pomůže
- Děravý wetware (*wetware = sarkastické označení biologických procesů*)
 - superinteligence je také superpsycholog a supervyjednávač
 - optické klamy, hypnóza, „díry v mozku“... kdo ví
- Izolovaný agent je k ničemu
 - Lidi chtějí agenta používat
 - Necháme si poradit návod na výrobu léku → jak zjistíme, že to je lék a ne past?
- Současná AI stejně vyžaduje pro své Alování internet
 - ta teorie z 2005 nepředpokládala, že AI bude strojové učení z textu z internetu, ale že to někdo naprogramuje jako normální program

Co nefunguje – bojovat s AI


- Jak vůbec může AI takeover vypadat?
 - 1700: „vymyslete, jak vás porazí armáda roku 2000“
 - „budou mít rychlé koně a pušky co zasáhnou člověka na 500 metrů!“
 - ve skutečnosti přiletí nadzvuková ICBM a odpaříte se, než si čehokoli všimnete
- Internetový přístup → vyhackování počítačů → rozkopírování se → nejde snadno vypnout
- Vyřešení protein folding, vynalezení superpatogenu
 - před AlphaFold lidi říkali, že je tohle sci-fi :)
- Vyhackování bitcoinové burzy
- Objednání syntézy DNA na přání online (ano tohle jde)
- Přesvědčení/podplacení někoho, aby „smíchal zkumavky co mu přijdou poštou“

AI doom – současný stav

- Nikdo neví, jak to řešit
- Moratoria o zastavení trénování obrovských modelů (neprošlo)
- Regulace vysoce výkonného HW jako kdyby to byly zbraně hromadného ničení (neprošlo)
- USA: nutnost registrace datacenter a tréninků větších než GPT-4
- Dočasná řešení: pokroky HW a architektury (viz story o obrázcích na začátku)
 - za ~5 let bude možné spustit GPT-4 v domácích podmínkách
 - takže to bude neregulovatelné (max. to bude mít status pirátského software)

Argumenty proti AI-doomu

- AI-doomerři mají rozvinutou argumentaci, články, knihy atd.
- Opozice často jen pokřikuje a nedokáže říct nic moc konkrétně :(
 - nebo je to moje sociální bublina?
- Superintelligence bude chápat, že příkazy jako „maximalizuj sponky“ implicitně zahrnují „a neznič při tom lidstvo“



Odkazy

- <https://ufal.mff.cuni.cz/courses/npfl114>
 - kurz o neuronkách na matfyzu, jsou tam záznamy
- <https://www.root.cz/autori/ondrej-filip-seznam/>
 - využití jazykových modelů pro vyhledávač seznam.cz
- <https://arxiv.org/abs/2303.12712>
 - článek popisující nové schopnosti GPT-4
- <http://playground.tensorflow.org/>
 - klikací neuronka v prohlížeči