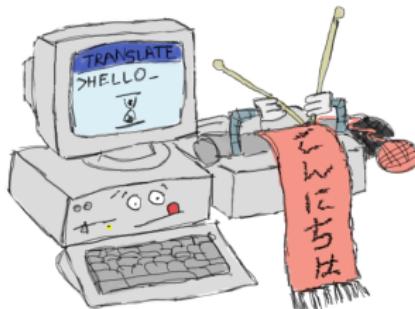


Strojový překlad a umělá inteligence

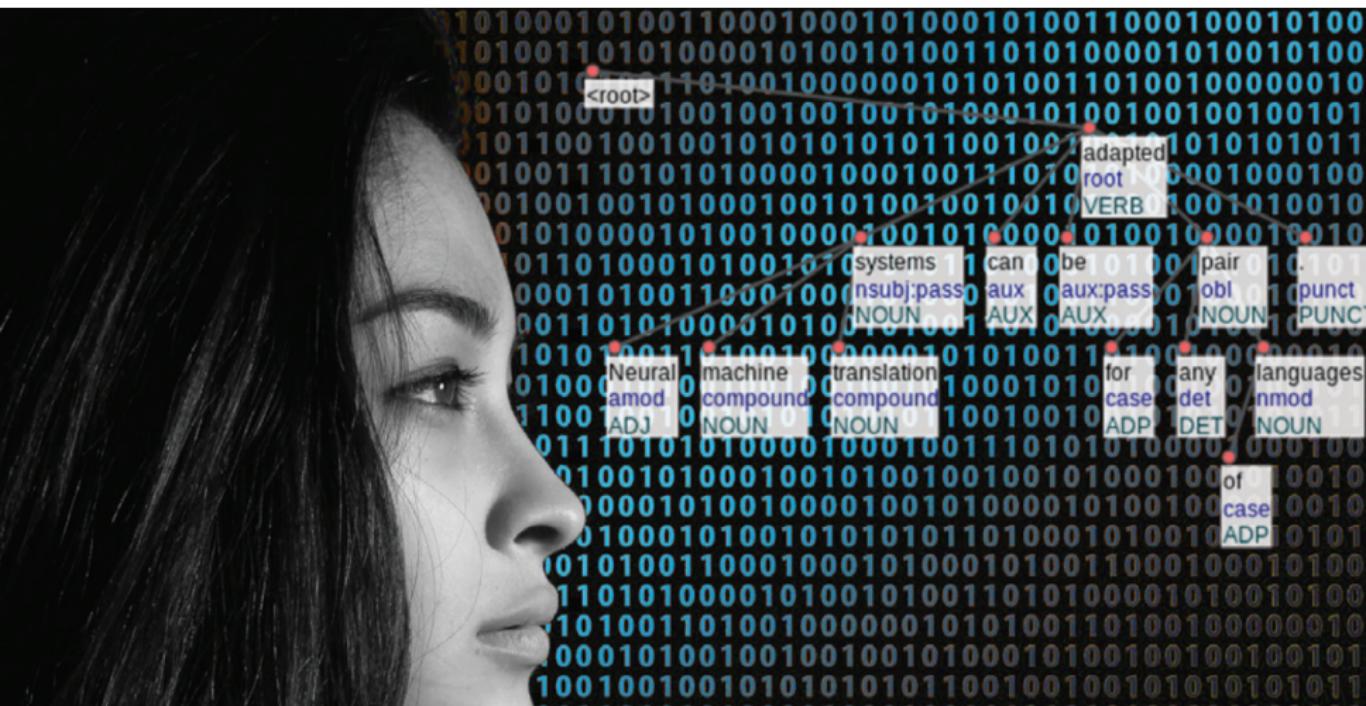
Mgr. Martin Popel, Ph.D.

Ústav formální a aplikované lingvistiky,
Matematicko-fyzikální fakulta, Univerzita Karlova
<https://ufal.mff.cuni.cz/martin-popel>



source	Great talkers are little doers.
Yandex	Velké talkers jsou trochu činitelé.
Microsoft	Velcí vysílačky jsou malí činitelé.
Google	Velcí mluvčí jsou malí lidé.
Google 2022	Velcí řečníci jsou malí dělníci.
TectoMT	Velcí řečníci jsou malí vrazi.
CUBBITT	Velcí mluvkové jsou malí dříci.

Čím se zabývá počítačová lingvistika?



Chlapci šly.
Chlapec šli do školy.

Dívce nešly hodinky. Chlapci šly.
Chlapec šli do školy.

Dívce nešly hodinky. Chlapci šly.
Kdo kam co donesl? Chlapec šli do školy.



Kontrola překlepů gramatiky

3

<http://ufal.cz/korektor>

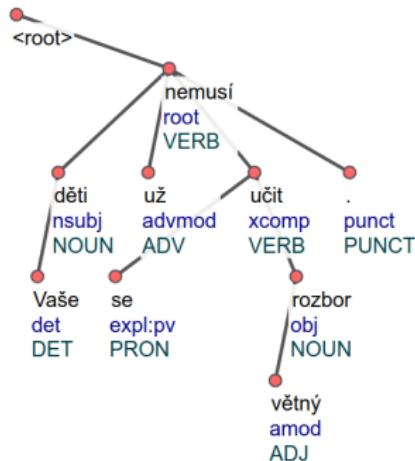
The screenshot shows a window titled "Korektor-sample.rtf — Edited". The toolbar includes font (Helvetica), style (Regular), size (24), and various text format buttons. A horizontal ruler is at the top. Below it, four sentences are displayed with underlined errors:

- Potkávám je na každém **krou.** (Suggestion: Did you mean kroku?)
- Lední medvěd byl schován za **krou.**
- Vláďa nás **přivíral** s otevřenou **náruči.** (Suggestions: Did you mean přivítal? Did you mean náručí?)
- Kocour **přivíral** oči slastí, když pozoroval kanárka v **klexi.** (Suggestion: Error in capitalization? Did you mean Praze?)

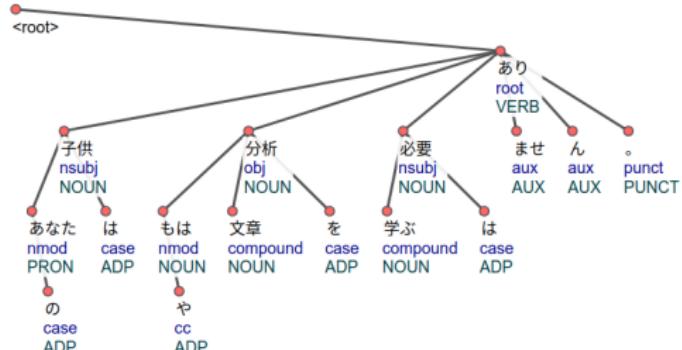
Automatický větný rozbor

větný rozbor dostupný pro 50 jazyků
přesnost pro češtinu asi 90% (85% včetně morfologie)

Vaše děti se už nemusí učit větný rozbor.



あなたの子供はもはや文章分析を学ぶ必要はありません。



Korupci často prozradí „kapříci“

Vyšetřovací tým právníků a forenzních analytiků hledá ve firmách důkazy o korupci. Proloží kódovanou řeč i šifrovací aplikace

KATEŘINA KOLÁŘOVÁ

Ve druhém patře moderní pražské kancelářské budovy Nile House usedá k jednacímu stolu pestře složený tým odborníků. Právníci, forenzní analytičtí a vyšetřovatelé zjistují, jestli byly v prošetrování společnosti globálního významu uzavřeny pro firmu nevhodné smlouvy. Experti společnosti Deloitte zkoumají, jestli zaměstnanci vyšetřované společnosti „šíří na rukou“ dodavatelů služeb, a za uplatek mu umožnili vyhrát lukrativní zakázku. K vyšetřování používají speciální techniky automatické analýzy dat, která prohlédne i kódovanou řeč.

„Velmi často řešíme právě vztahy dodavatele s nákupním oddělením, ty jsou problematické témař v každé prošetrované společnosti,“ vysvětluje Jaroslava Kračúnová, advokátka a partnerka kanceláře Ambur & Dark Deloitte Legal, jež spolupracuje s forenzním týmem vyšetřovatelů. Multidisciplinární tým využívá i podezření z financování terorismu zahraničí. „Takto závažné trestné činy se velmi často prokazují izolovaně v prošetrování společnosti klienta. Proto často, paralelně s naším šetřením, probíhá i policejní vyšetřování,“ říká Kračúnová.

Rychlý zásah



Multidisciplinární tým. Vyšetřování podezření z korupce nebo projevů sexuálního hrazení na pracovišti spojuje práci rozdílných vědních oborů. Analytický tým vede absolventka matematicko-fyzikální fakulty Kateřina Veselovská (vlevo), právník-advokátka Jaroslava Kračúnová (vpravo).

dostatečně odůvodněné. Věc řešíme po stránce pracovněprávní, a s ohledem na ochranu osobních údajů a ochranu soukromí,“ popisuje Kračúnová začátek vyšetřování. Po dokončení právních kroků

ké analýzy, kterou v Deloitte využívají téměř dva roky, a to ve 28 jazyčích.

Rozpoznaní kódované řeči
„Na základě blízkosti slovní zásoby

Důkazem manipulace s výsledky tendru je typicky vznik

mohla existovat, protože o vítězi tendru ještě nebylo nákupním oddělením oficiálně rozhodnuto,“ popisuje Kračúnová. Pak už analytici hledají v počítačích konkrétní texury soubor.

Kateřina Veselovská

■ Manažerka oddělení Data Analytics Deloitte, kde vede tým pro analýzu nestrukturovaných dat. Absolvovala doktorandský program na Matematicko-fyzikální fakultě Univerzity Karlovy v Praze. Věnovala se vývoji softwaru pro textovou analytiku a business poradenství v projektech týkajících se oblasti nestrukturovaných a velkých dat. Nyní se zaměřuje zejména na projekty z oboru forenzní analytiky a řešení rizik.

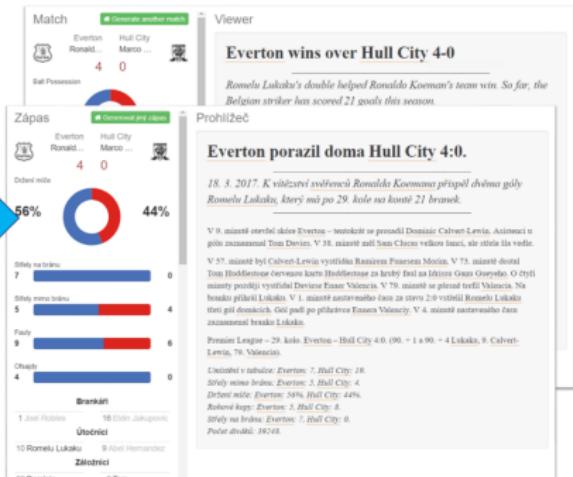
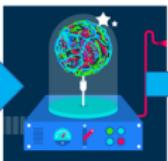
Jaroslava Kračúnová

■ Partnerka a advokátka v Deloitte Legal, vede tým Business Integrity. Promována na Právnické fakultě Univerzity Karlovy v Praze. Studovala i právo a management v Innsbrucku. Specializuje se na odsouhlasování hospodářské kriminality, trestní odpovědnost právnických osob, corporate governance a ochranu osobních údajů.

rozvolněné hranice toho, co je v této oblasti už za hranou a co je ještě v pořádku. V některých zemích je to ale něco naprostě nepřirozeného,“ vzpomíná Kračúnová. Byť tím specialistům prokázal, že se

čtenáři chtějí zprávy personalizované a hned

Structured data
(real-time & historical)



Article / Report



Byl by to rytíř, kde v pláně hřích vzlet,
Vědě jsem jse seheldo na přídoutně v světě si nezastavá:
„Ukryjemné, chvěla, milý nás jest

Kolem jsou jest vyhrávaných
A svítí co pláčem, rád pravil:
Ale plná jízdo zaporodilo se, vys.

již dávno vás poháru a vlanných rány,
v jablonění je píše je i v kristování,

srdce v své ženských svém
v obly pětky tam a vzíti,
na kóňku je, milý svěžek.

I'll come a bit later on my own.

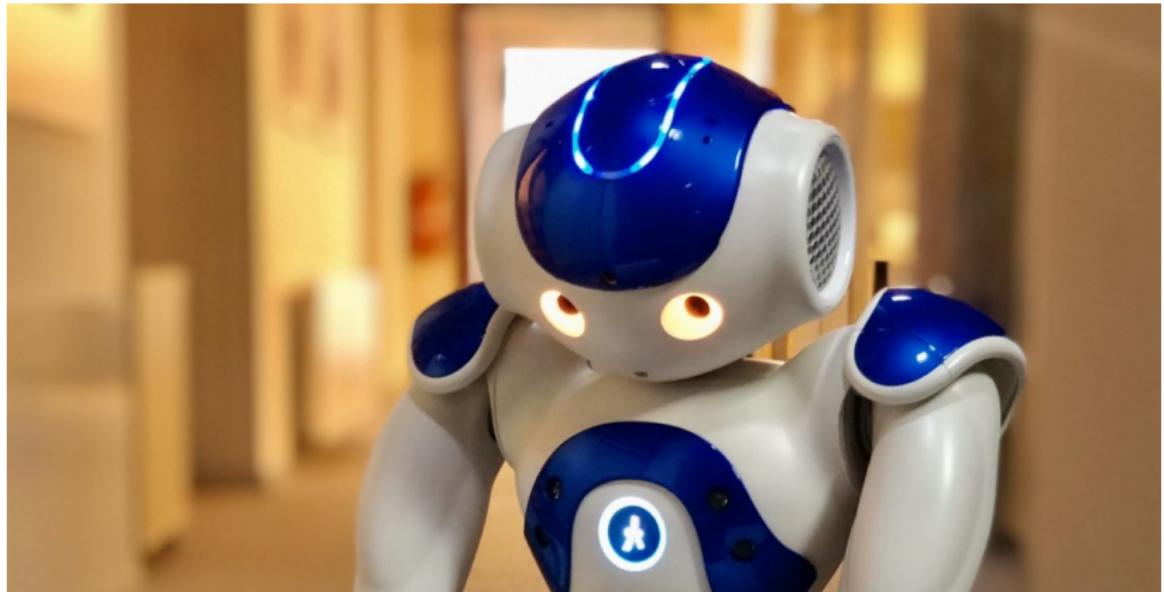
I'll come a bit later on my own.
Sem čelist ještě na své milé.

Divadelní hra napsaná robotem?

8

MFF + DAMU + Švandovo divadlo

premiéra leden 2021 (100 let po R.U.R.)



<https://www.theaitre.com>



THEATRE THEaiTRobot 1.0 THEaiTRobot 2.0 Switch to English

UKÁZKOVÝ SCENÁŘ

Scéna

Procházka. Faust v myšlenkách přechází, k němu Mefistofeles.

Mefistofeles

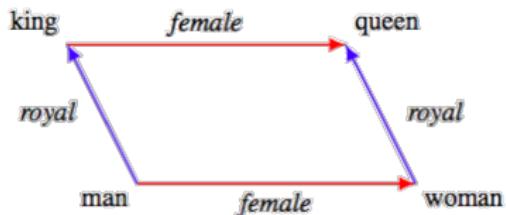
Při vši zhrzené láseč! Při jízdě do pekla! Chtěl nově bych vymyslit živly, bych při tom nejhorším kiel!

Faust

Co je ti? Viděl to kdy svět? Vyváděš, že tě nepoznávám.

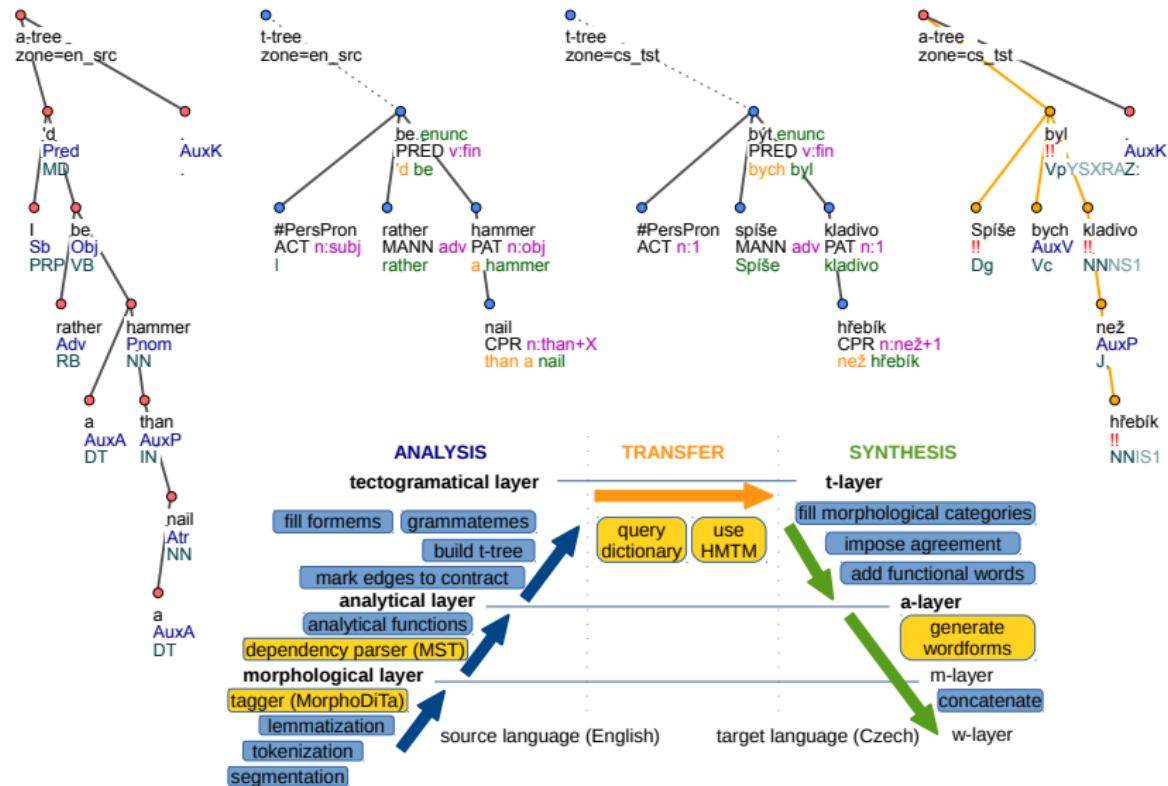
← → GENEROVAT DÁL

- Generování scénářů divadelních her
 - Umí počítač napsat divadelní hru?
 - Jak funguje jazykový model?
 - Co je to GPT-2?
- Sčítání a odčítání významů slov
 - Co jsou slovní embedinky?
 - král - muž + žena = královna
 - pivo - Česko + Rusko = ?



Hloubkově-syntaktický překladač TectoMT (2005–2016)

10



I'd rather be a hammer than a nail.

Spíše bych byl kladivo než hřebík/nehet.

<u>output_label=hřebík#N</u>	
feature	λ
child_formeme_n:in+X=1	1.64
is_member_of_coord=1	1.30
child_formeme_v:fin=1	1.04
next_lemma=down	0.84
is_capitalized=1	0.79
+precedes_parent=0	0.75
tense_g=post	0.74
+voice_g=active	0.66
prev_lemma=drive	0.66
parent_capitalized=1	0.62
formeme=n:from+X	0.60
+prev_lemma=hammer	0.59
child_lemma_few=1	0.55
child_lemma_remove=1	0.54
sempos=n.denot	0.50
next_lemma=and	0.50
formeme_g=v:until+fin	0.49
child_lemma_rusty=1	0.47
...	

output_label=hřebík#N

feature	λ
child_formeme_n:in+X=1	1.64
is_member_of_coord=1	1.30
child_formeme_v:fin=1	1.04
next_lemma=down	0.84
is_capitalized=1	0.79
+precedes_parent=0	0.75
tense_g=post	0.74
+voice_g=active	0.66
prev_lemma=drive	0.66
parent_capitalized=1	0.62
formeme=n:from+X	0.60
+prev_lemma=hammer	0.59
child_lemma_few=1	0.55
child_lemma_remove=1	0.54
sempos=n.denot	0.50
next_lemma=and	0.50
formeme_g=v:until+fin	0.49
child_lemma_rusty=1	0.47
...	

output_label=nehet#N

feature	λ
child_formeme_n:poss=1	1.32
child_lemma_finger=1	1.07
child_formeme_n:of+X=1	0.98
precedes_parent=1	0.88
prev_lemma=black	0.77
child_lemma_broken=1	0.76
child_formeme_v:attr=1	0.70
formeme=n:at+X	0.67
formeme_g=n:attr	0.67
child_lemma_long=1	0.67
next_lemma=file	0.60
child_lemma_false=1	0.58
prev_lemma=false	0.58
+number=sg	0.56
formeme=n:obj	0.53
formeme=n:by+X	0.52
...	

Umělá inteligence a její podobory/vývoj

12

umělá inteligence

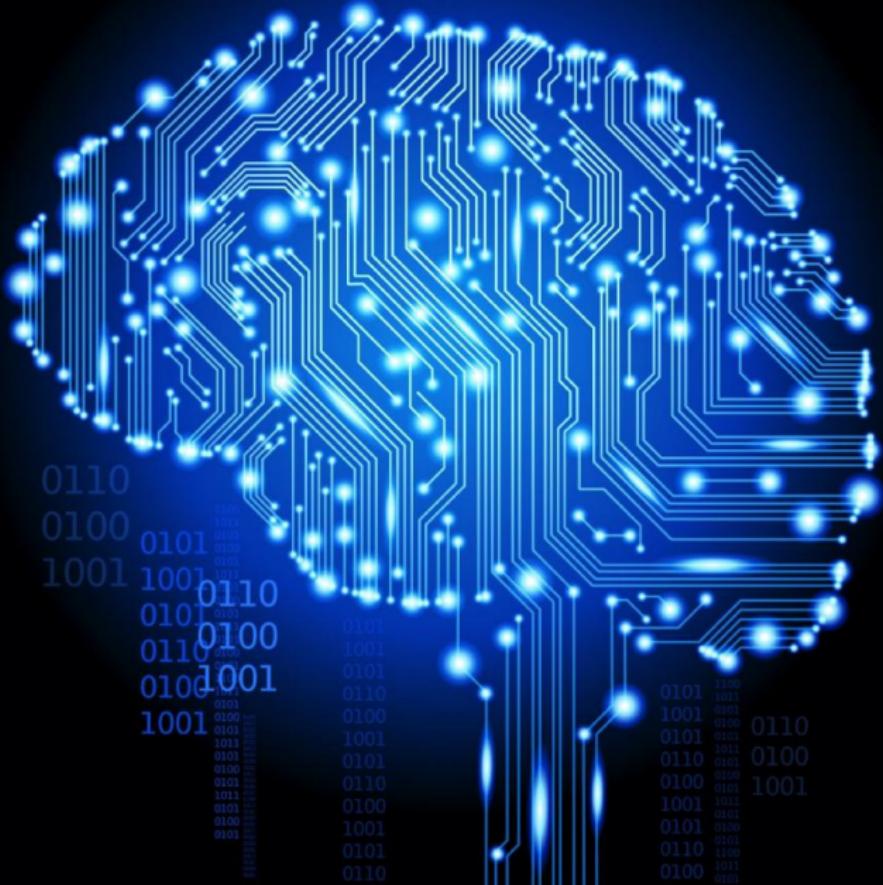
~1950

strojové učení

~1980

hluboké učení

~2010



Umělá inteligence a její podobory/vývoj

12

umělá inteligence

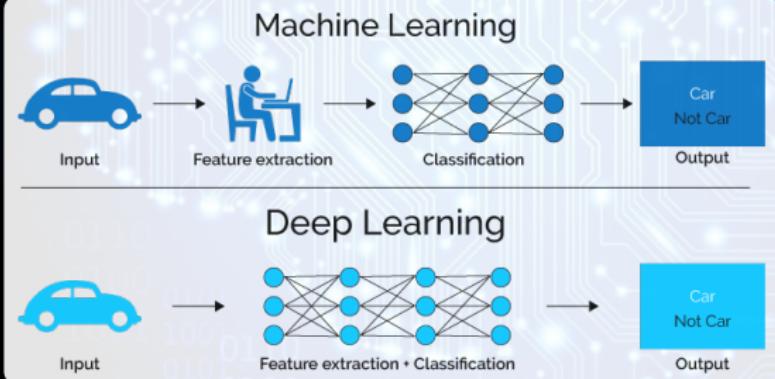
~1950

strojové učení

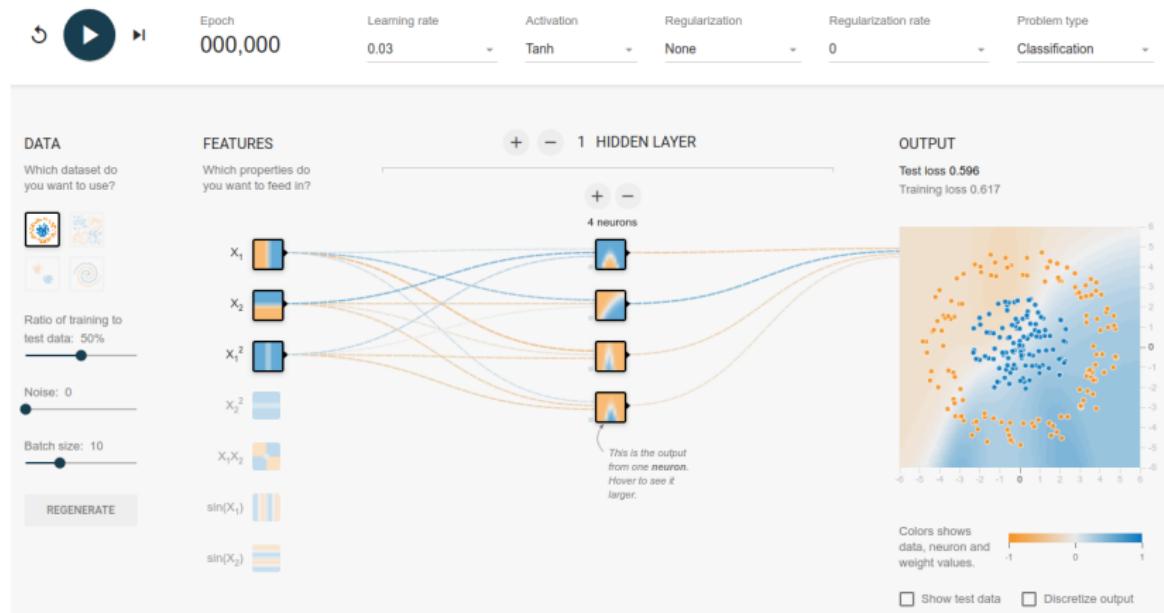
~1980

hluboké učení

~2010

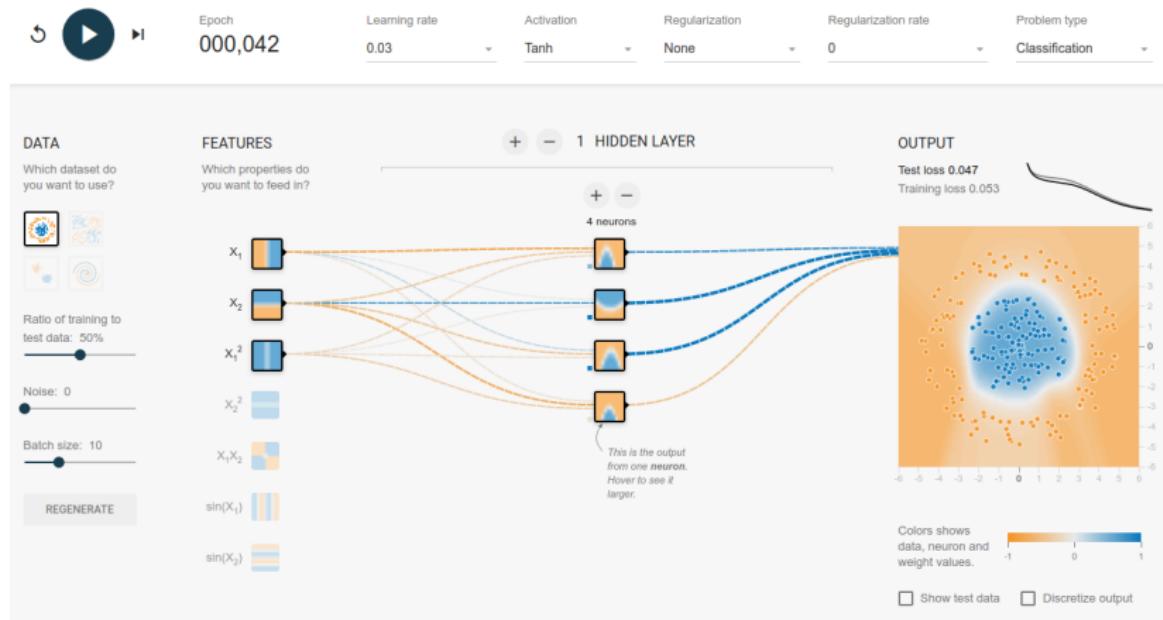


jednoduchá architektura (16 parametrů)



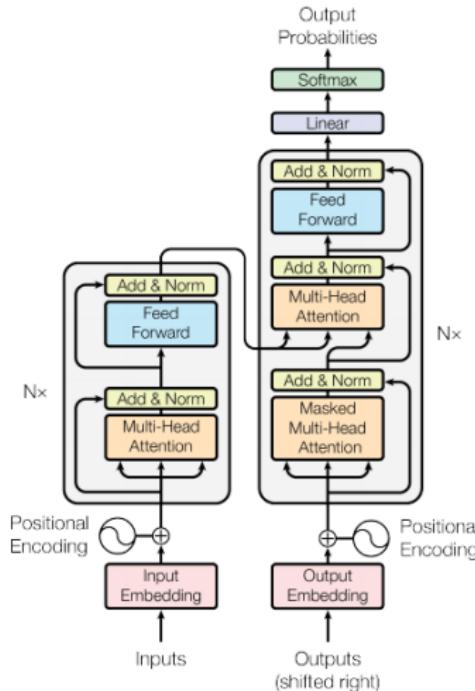
<https://playground.tensorflow.org>

jednoduchá architektura (16 parametrů)

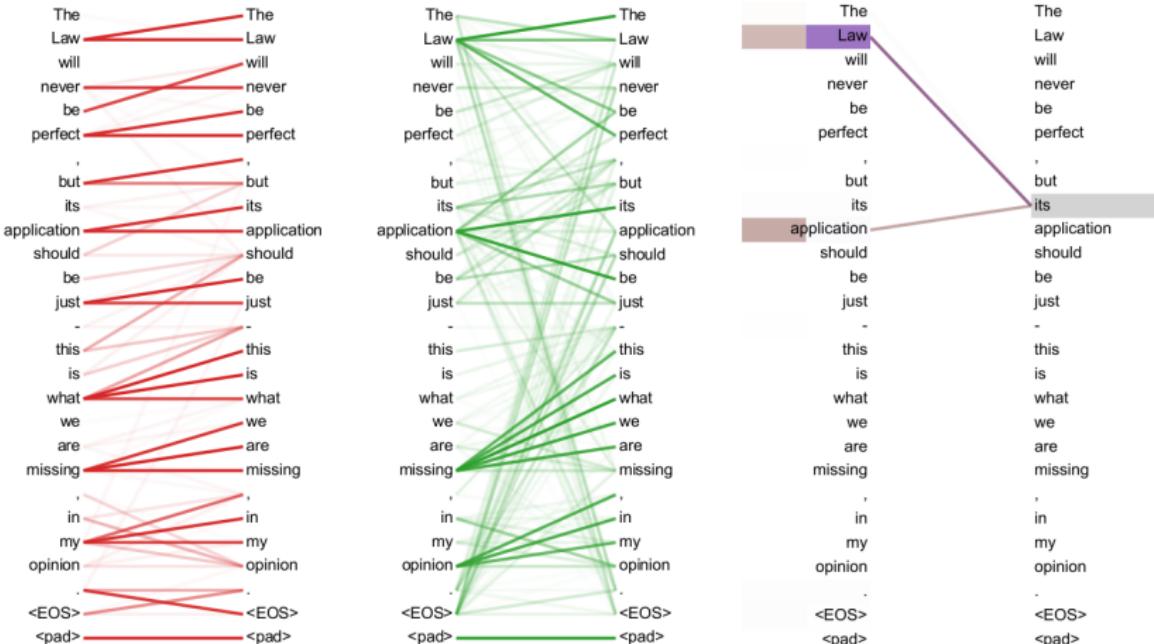


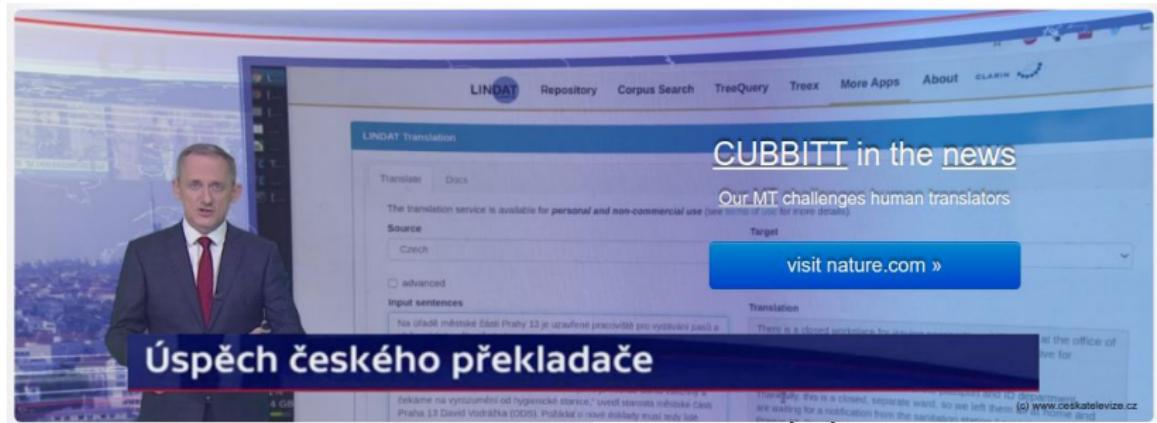
<https://playground.tensorflow.org>

architektura Transformer (213 milionů parametrů)



síť se sama učí důležité vztahy mezi slovy (díky self-attention)





Zkuste si CUBBITT sami:

<https://lindat.cz/cubbitt>
(En↔Cs, Fr, Pl)

nature communications

nature > nature communications > articles > article

Article | Open Access | Published: 01 September 2020

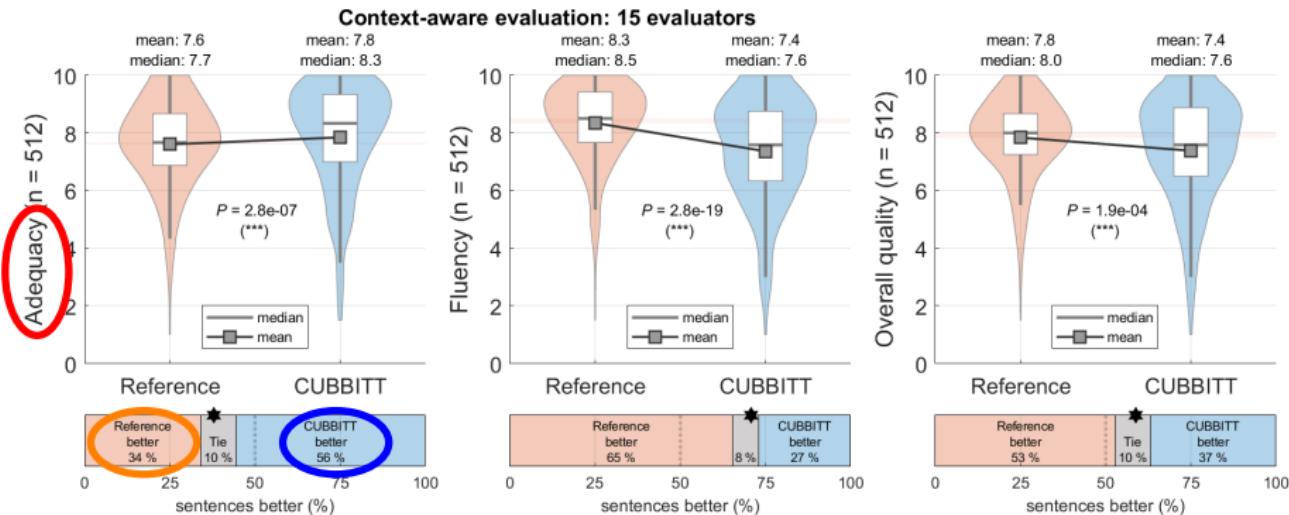
Transforming machine translation: a deep learning system reaches news translation quality comparable to human professionals

Martin Popel, Marketa Tomkova, Jakub Tomek, Łukasz Kaiser, Jakob Uszkoreit, Ondřej Bojar & Zdeněk Žabokrtský

Nature Communications 11, Article number: 4381 (2020) | [Cite this article](#)

6273 Accesses | 76 Altmetric | [Metrics](#)

56 % vět přeložil **přesněji** náš překladač CUBBITT,
34 % profesionální překladatelská agentura



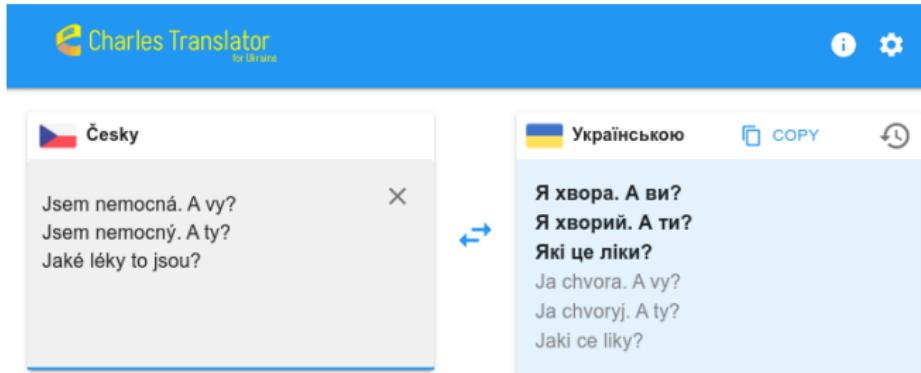


Nový česko-ukrajinský překladač

Zkuste si Charles Translator:

<https://translator.cuni.cz>





- první verze překladače vytvořena za 2 týdny
- cs→uk: asi 1400 uživatelů denně, uk-cs: asi 700
- přímý překlad (nikoli přes angličtinu)
- fonetický přepis azbuky, hlasový vstup,...
- API: překlad učebnic, PomahejUkrajine.cz,...

The screenshot shows the Charles Translator application for Ukraine. It has two main panels: one for Czech (left) and one for Ukrainian (right).
Czech Panel (Left):
- Flag: Czech flag (red, white, blue horizontal stripes)
- Language: Česky
- Text:

Jsem nemocná. A vy?
Jsem nemocný. A ty?
Jaké léky to jsou?

Ukrainian Panel (Right):
- Flag: Ukrainian flag (blue and yellow horizontal stripes)
- Language: Українською
- Text:

Я хвора. А ви?
Я хворий. А ти?
Які це ліки?
Ja chvora. A vy?
Ja chvoryj. A ty?
Jaki ce liky?

A blue double-headed arrow icon is positioned between the two panels.

The screenshot shows the Google Translate interface. It has two main panels: one for Czech (left) and one for Ukrainian (right).
Czech Panel (Left):
- Language: ROZPOZNAT JAZYK (Detektovat jazyk)
- Language: ČEŠTINA
- Text:

Jsem nemocná. A vy?
Jsem nemocný. A ty?
Jaké léky to jsou?

Ukrainian Panel (Right):
- Language: UKRAJINŠTINA
- Language: ČEŠTINA
- Text:

Я хворий. І ти?
Я хворію. І ти?
Які це наркотики?
YA khvoryy. I ty?
YA khvoriyu. I ty?
Yaki tse narkotyky?

At the bottom, there are icons for microphone, speaker, and sharing, along with page navigation and a search bar.

Support The Guardian Subscribe Find a job Sign in

The Guardian

News Opinion Sport Culture Lifestyle ☰

World ► Europe US Americas Asia Australia Middle East Africa Inequality

Facebook

Facebook translates 'good morning' into 'attack them', leading to arrest

Palestinian man questioned by Israeli police after embarrassing mistranslation of caption under photo of him leaning against bulldozer



zdroj: **The Guardian** (2017)

Source	Jana je žena. Pracuje jako průvodčí.
Google	Jana is a woman. He works as a guide.
Bing	Jana is a woman. He works as a conductor.
CUBBITT	Jane is a woman. He works as a conductor.
CUBBITT-doc	Jana is a woman. She works as a conductor.

Source	Saša je muž. Pracuje jako průvodčí.
DeepL (2021)	Sasha is a man. She works as a conductor.
CUBBITT-doc	Sasha is a man. He works as a conductor.

Source	Pavla není muž. Pracuje jako průvodčí.
DeepL	Paul is not a man. She works as a conductor.
CUBBITT-doc	Pavla is not a man. He works as a conductor.

source	As good be an addled egg as an idle bird.
Bing	Jako dobrý být popletený vejce jako nečinný pták.
Google	Jako dobrá být včleněná vejce.
T2009	Dobré je fetácké vejce jako činný pták.
T2018	Dobří bud'te plete vejce jako nečinný pták.
CUBBITT	Stejně dobré je být pomateným vejcem jako zahálejícím ptákem.

source	A miss by an inch is a miss by a mile.
Bing	Miss o palec je Miss o míli.
Yandex	Slečna tím, že palec je vedle o míli.
Google	Chybějící palcem je míle vzdálená míle.
T2009	Slečna palec je slečna milionu.
T2018	Slečna palce je slečna míle.
CUBBITT	Minutí o centimetr je o kilometr.

Birds of a feather flock together.
Ptáci peří stáda dohromady.
Vrána k vráně sedá.
Vrána k vráně sedá.
Ptáci v bederním hejnu spolu.
Ptáci péřového hejna spolu.
Vrána k vráně sedá.

Zkuste si CUBBITT sami: <https://lindat.cz/cubbitt>