


O strojovém překladu

Mgr. Martin Popel, Ph.D.

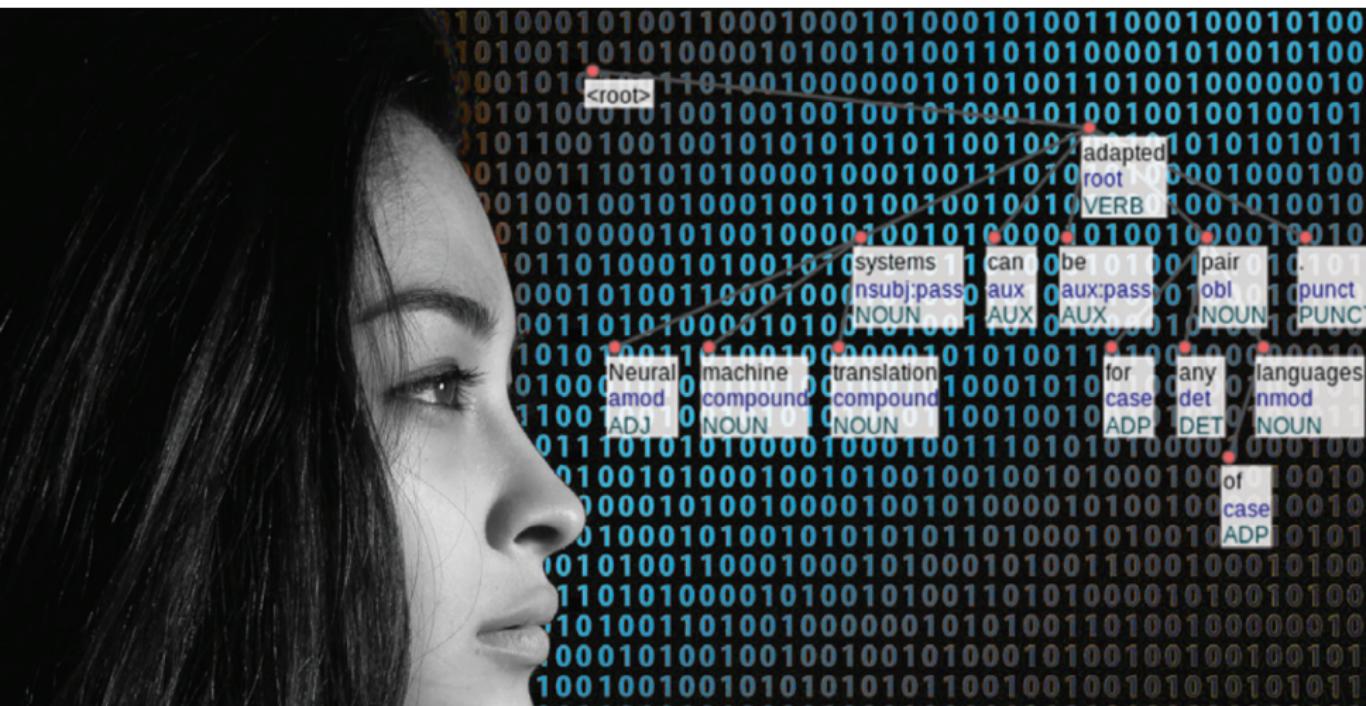
Ústav formální a aplikované lingvistiky,
Matematicko-fyzikální fakulta, Univerzita Karlova

<http://ufal.cz/martin-popel>



source	Great talkers are little doers.
Yandex	Velké talkers jsou trochu činitelé.
Bing	Velcí vysílačky jsou malí činitelé.
Google	Velcí mluvčí jsou malí lidé.
TectoMT	Velcí řečníci jsou malí vrazi.
CUBBITT	Velcí mluvkové jsou malí dříči.

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 editing icons. The main text area contains four sentences with underlined errors and corresponding suggestion boxes:

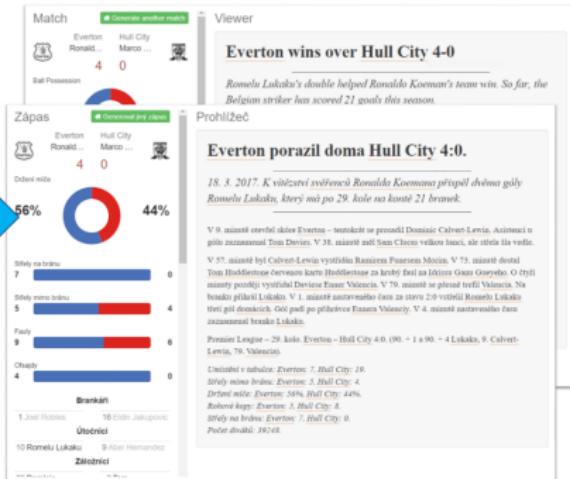

- Potkávám je na každém **krou**.
Did you mean krouku?
- Lední medvěd byl schován za **krou**.
Did you mean krou?
- Vláďa nás **přivíral** s otevřenou **náruči**.
Did you mean přivítal? Did you mean náručí?
- Kocour **přivíral** oči slastí, když pozoroval kanárka v **klexi**.
Did you mean přivítal?
- Tento víkend raději zůstaneme v **praze**.
Error in capitalization? Did you mean Praze?

Automatické generování zpráv

4

zpráv přibývá (FB, Twitter), novinářů ubývá, zisky klesají, 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.

Když robot píše (divadelní) hru

6

MFF + DAMU + Švandovo divadlo

premiéra 26. 2. 2021 (100 let po R.U.R.)



<https://www.theaitre.com>

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 dodavatelů 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 v 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 neprůchodziho,“ vzpomíná Kračúnová. Byť tím specialistům prokázal, že se

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。




Umíte sčítat a odčítat čísla?
A co slova a obrázky?

král - muž + žena = ?

král - muž + žena = královna

Tomáš Mikolov, 2012, word2vec





<https://projector.tensorflow.org/>


Word embeddings


9


Country and Capital Vectors Projected by PCA
















Hloubkově-syntaktický překladač TectoMT

11



I'd rather be a hammer than a nail.

Spíše bych byl kladivo než hřebík/nehet.

Co je to?

12



40 GPU (GeForce GTX 1080 Ti, 12 miliard tranzistorů)

12



Umělá inteligence a její podobory/vývoj

13

umělá inteligence


~1950

strojové učení

~1980

hluboké učení

~2010



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)



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



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, Lukasz Kaiser, Jakob Uszkoreit, Ondrej Bojar & Zdenek Žabokrtský

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

6273 Accesses | 76 Altmetric | Metrics

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

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 \(2017\)](#)

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 \(2017\)](#)

denně přes 100 miliard slov (Google, Microsoft, Baidu, Amazon,...)
velikost trhu za rok 2020: 650 milionů dolarů

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.
DeepL	Jana is a woman. She works as a conductor.

Source	Nikdo nedokáže pochopit, proč Pavla dělá to, co dělá. Pracuje jako průvodčí.
CUBBITT-doc	No one can understand why Pavla does what she does. She works as a conductor.
DeepL	No one can understand why Paul does what he does. She 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 buďte 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 miliónu.

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>