

# Jaká data se používají ve strojovém překladu

Ondřej Bojar

[bojar@ufal.mff.cuni.cz](mailto:bojar@ufal.mff.cuni.cz)

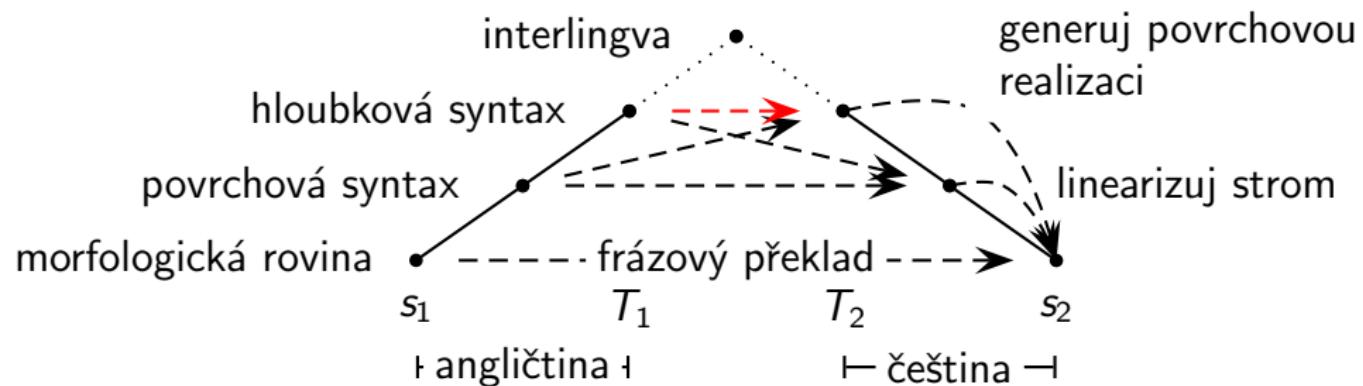
Ústav formální a aplikované lingvistiky  
MFF UK

ELRC Workshop, 14. duben 2016

# Osnova

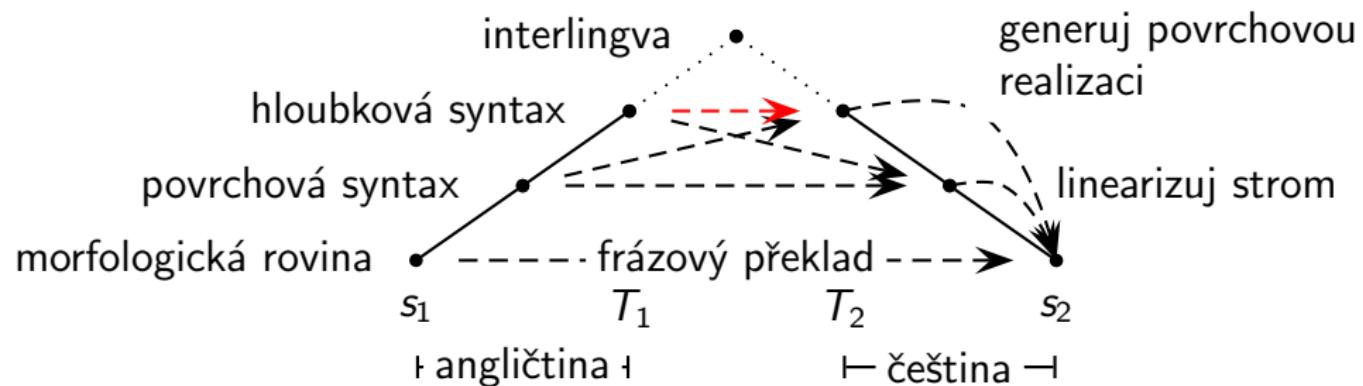
- ▶ Typy dat ve strojovém překladu.
- ▶ Kolik je potřeba?
- ▶ Absolutní minimum: paralelní korpusy.
  - ▶ Získávání paralelních textů z webu.
- ▶ Sdílení zdrojů.

# Přístupy ke strojovému překladu



- ▶ Pravidlový vs. statistický přístup:
  - ▶ Pravidlové systémy píší lingvisté-programátoři.
  - ▶ Statistické systémy se naučí samy podle dat.

# Přístupy ke strojovému překladu



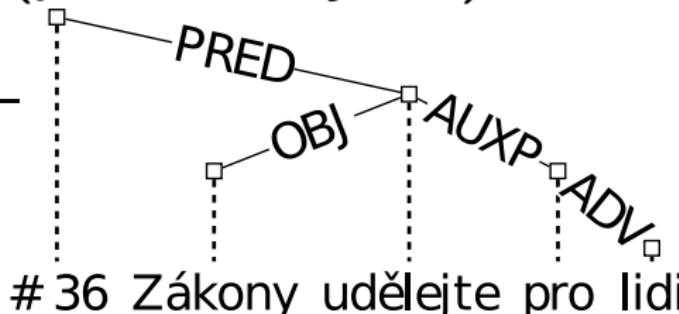
- ▶ Pravidlový vs. statistický přístup:
  - ▶ ~~Pravidlové systémy příši lingvisté programátoři.~~
  - ▶ Statistické systémy se naučí samy podle dat.

# Formální popis češtiny ⇔ Ruční anotace

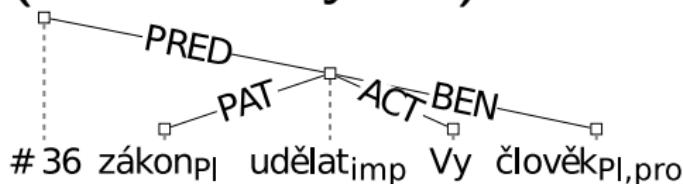
## Morfologická rovina:

Slovo	Lema	Morfologická značka
zákony	zákon	NNIP1----A---
zákony	zákon	NNIP4----A---
zákony	zákon	NNIP5----A---
zákony	zákon	NNIP7----A---
udělejte	udělat	Vi-P---2-A---
udělejte	udělat	Vi-P---3-A---4
pro	pro-1	RR--4-----
lidi	člověk	NNMP1----A---
lidi	člověk	NNMP4----A---
lidi	člověk	NNMP5----A---

## Analytická rovina (povrchová syntax):



## Tektogramatická rovina (hloubková syntax):



# Lingvistická data

- ▶ **Korpusy** jsou (velké) sbírky textů:
  - ▶ Texty typicky označkované nebo včetně větných rozborů.  
Pražský závislostní korpus (PDT): 1.5 mil. slov.
  - ▶ Pražský čj-aj závislostní korpus (PCEDT): 50 tis. vět.
  - ▶ Některé vícejazyčné: CzEng (15 mil. vět, 220 mil. slov, odpovídá ~50 metrům knih, ty tvoří však jen čtvrtinu).
- ▶ **Slovníky** strojově čitelné:
  - ▶ Morfologický slovník říká, že *kočka* je české slovo a *kočke* ne.
  - ▶ Valenční slovník říká, že:
    - Rodiče přijali Petra.* → je správně
    - Rodiče přijeli Petra.* → není správně
  - ▶ Slovník subjektivity obsahuje hodnotící výrazy.

⇒ Lze využít v programech (pravidlových i statistických).

# Data po frázový překlad (Moses, MT@EC)

- ▶ Překladové slovníky méně vhodné.
  - ▶ Překlad potřebuje vidět slova v kontextu.
- ▶ Terminologie a glosáře méně vhodné.
  - ▶ Současné metody mohou vynutit překlad jen velice tupě.
- ▶ Zásadní je paralelní korpus.
- ▶ Pro kvalitu důležité, aby texty byly z dané domény.
- ▶ Systém memoruje až desetice slov.
  - ⇒ Dlouhé termíny zachovány přesně.
  - ⇒ České tvarosloví a volný slovosled situaci komplikuje.

# Paralelní korpus

## GENESIS

### The Story of Creation

**1** In the beginning, when God created the universe,<sup>2</sup> the earth was formless and desolate. The raging ocean that covered everything was engulfed in total darkness, and the Spirit of God was moving over the water.<sup>3</sup> Then God commanded, "Let there be light" – and light appeared.<sup>4</sup> God was pleased with what he saw. Then he separated the light from the darkness,<sup>5</sup> and he named the light "Day" and the darkness "Night". Evening passed and morning came – that was the first day.

<sup>6</sup> Then God commanded, "Let there be a dome to divide the water and to keep it in two separate places" – and it was done. So God made a dome, and it separated the water under it from the water above it.<sup>7</sup> He named the dome "Sky". Evening passed and morning came – that was the second day.

<sup>8</sup> Then God commanded, "Let the water below the sky come together in one place, so that the land will appear" – and it was done.<sup>9</sup> He named the land "Earth", and the water which had come together he named "Sea". And God was pleased with what he saw.<sup>10</sup> Then he commanded, "Let the earth produce all kinds of plants, those that bear grain and those that bear fruit" – and it was done.<sup>11</sup> So the earth produced all kinds of plants, and God was pleased with what he saw.<sup>12</sup> Evening passed and morning

## GENÈSE

### Dieu crée l'univers et l'humanité

**1** Au commencement Dieu créa le ciel et la terre.

<sup>2</sup> La terre était sans forme et vide, et l'obscurité courrait l'océan primordial. Le souffle de Dieu se déplaçait à la surface de l'eau.<sup>3</sup> Alors Dieu dit: "Que la lumière paraisse!" et la lumière parut.<sup>4</sup> Dieu constata que la lumière était une bonne chose, et il sépara la lumière de l'obscurité.<sup>5</sup> Dieu nomma la lumière jour et l'obscurité nuit. Le soir vint, puis le matin; ce fut la première journée.

<sup>6</sup> Dieu dit encore: "Qu'il y ait une voûte, pour séparer les eaux en deux masses!"<sup>7</sup> Et cela se réalisa. Dieu fit ainsi la voûte qui sépare les eaux d'en bas de celles d'en haut.<sup>8</sup> Il nomma cette voûte ciel. Le soir vint, puis le matin; ce fut la seconde journée.

<sup>9</sup> Dieu dit encore: "Que les eaux qui sont au-dessous du ciel se rassemblent en un lieu unique pour que le continent paraisse!" Et cela se réalisa.<sup>10</sup> Dieu nomma le continent terre et la masse des eaux mer, et il constata que c'était une bonne chose.<sup>11</sup> Dieu dit alors: "Que la terre produise de la végétation: des herbes produisant leur semence, et des arbres fruitiers dont chaque espèce porte ses propres graines!" Et cela se réalisa.<sup>12</sup> La terre fit pousser de la végétation; des herbes produisant leur semence

# ~~~ Automatické zarovnání po větách

In my dream , there was a sycamore growing out of the ruins of the sacristy , and I was told that , if I dug at the roots of the sycamore , I would find a hidden treasure . But I ' m not so stupid as to cross an entire desert just because of a recurrent dream . " And they disappeared . The boy stood up shakily , and looked once more at the Pyramids . " It is I who dared to do so , " said the boy . This man looked exactly the same , except that now the roles were reversed . " It is I who dared to do so , " he

अपने सपने में मुझे एक गुलर का पेड़ दिखाई देता था और मुझे लगता था कि अगर मैं उस गुलर की जड़ें खोद डालूं तो मुझे छिपा हुआ खजाना मिल जाएगा । मगर मैं तुम्हारी तरह इतना बेवकूफ नहीं हूं कि महज बार - बार आने वाले एक सपने के कारण पूरे रेगिस्ट्रान को पार करूं । वे लोग , उसके बाद वहां से चले गए । लड़का लड़खड़ाता हुआ किसी तरह खड़ा हो गया । <5>एक बार फिर उसने पिरामिडों को देखा । " यह जुर्त मैंने की थी , " लड़के ने कहा । <5>उसे सेंटियागो मातमोरोस की वह प्रतिमा याद आई जिसमें वह घोड़े पर सवार था और उसके घोड़े के खुरों में कितने ही नास्तिक कुचले हुए पड़े थे । यह घुड़सवार भी बिलकुल वैसा ही था । यह बात और थी कि इनके किरदार बदले हुए थे । " मैंने ही ऐसा करने का साहस किया था , " लड़के ने दोहराया और अपनी गर्दन तलवार का बार सहने के लिए झुका दी । ' जिंदगी ने भी हमेशा मेरे साथ अच्छा बर्ताव किया । '

# ~~~ Automatické zarovnání po větách

In my dream , there was a sycamore growing out of the ruins of the sacristy , and I was told that , if I dug at the roots of the sycamore , I would find a hidden treasure .

But I ' m not so stupid as to cross an entire desert just because of a recurring dream .

And they disappeared .

The boy stood up shakily , and looked once more at the Pyramids .

“ It is I who dared to do so , ” said the boy .

This man looked exactly the same , except that now the roles were reversed .

“ It is I who dared to do so , ” he repeated , and he lowered his head to receive a blow from the sword .

“ Life was good to me , ” the man said .

“ When you appeared in my dream , I felt that all my efforts had been rewarded , because my son ' s poems will be read by man for generations to come .

I don ' t want anything for myself , ” said the boy .

But any father would be proud of the fame achieved by one whom he had cared for as a child , and educated as he grew up .

“ We ' re two very different things .

“ That ' s not true , ” the boy said .

“ I learned the secret of life from your son , ” the man said .

We were all made by the same hand , and we have the same soul .

You ' ll learn to love the desert , and you ' ll get to know every one of fifty thousand palms .

You ' ll watch them as they grow , demonstrating how the world is always changing .

And you ' ll get better and better at understanding others , because the desert is the best teacher there is .

“ Sometimes during the second year , you ' ll remember all about the treasure .

The omens will begin insistently to speak of you , and you ' ll try to ignore them .

“ Who told you that ? ” asked the boy , startled .

“ Makibin ” , said the old man .

And he put on the boy his blessing .

The boy went to his room and packed his belongings .

They filled three sacks .

As he was leaving , he saw , in the corner of the room , his old shepherd ' s pouch .

“ I want to see the greatness of Allah , ” the chief said , with respect .

“ I want to see how a man turns himself into the wind . ”

But he made a mental note of the names of the two men who had expressed their fear .

“ Tell them about the armies that are approaching .

“ They are men of the desert , and the men of the desert are used to dealing with omens .

“ Well , then , they probably already know .

“ They ' re not concerned with that right now .

It has happened many times before .

“ What about one-tenth of my treasure ? ” the old man said .

“ If you start out by promising what you don ' t even have yet , you ' ll lose your desire to work toward getting it .

The boy told him that he had already promised to give one-tenth of his treasure to the Gypsies .

“ Gypsies are experts at getting people to do that , ” sighed the old man .

The elder continued , “ When the pharaoh dreamed of cows that were thin and cows that were fat , this man ' t in speaking of reward .

From Egypt from him .

His name was Joseph .

He , too , was a stranger in a strange land , like you , and he was probably about your age .

He passed , and his eyes were closed , as if he were sleeping .

“ We , people ' s hearts , seldom say much about these treasures , because people no longer want to go in search of them .

We speak of them only to children . Later , we simply let life proceed , in its own direction , toward our own fate .

But he didn ' t need to worry about that right now .

What he had to be concerned about was his treasure , and how he was going to go about getting it .

The sale of his sheep had left him with enough money in his pouch , and the boy knew that in money there was magic .

Before long , maybe just a few days , he would be at the Pyramids .

And when two such people encounter each other , and there gives more , the part of the time is more . There is only that we are here to be given more , and the incredible certainty that everything under the sun has been written by one hand only .

It is the hand that eviles love , and creates a twin soul for every person in the world .

Without such love , one ' s dreams would have no meaning .

Makibin , thought the boy .

“ ... ” thought the boy .

The Englishman shook the boy : “ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

“ ... ” , and the boy did not understand what he was.

# Zarovnaný paralelní korpus (1658)

••••( 2 )••••

Invitatio.

Einleitung.



M. Veni, Puer!  
discē Sapere.

P. Quid hoc est,  
Supere?

M. Omnia,  
quæ necessaria,  
rectè intelligere,  
recte agere,  
rectè eloqui.

P. Quis me  
hoc docebit?

M. Ego,  
cum D E O.

L. Komm her/ Knab!  
lerne Weisheit.

S. Was ist das/  
Weisheit?

L. Alles/  
was nöhtig ist/  
rechte verstehen/  
recht thun/  
recht ausreden.

S. Wer wird mich  
das lehren?

L. Ich /  
mit Göttr.

## ↔ Automatické zarovnání po slovech

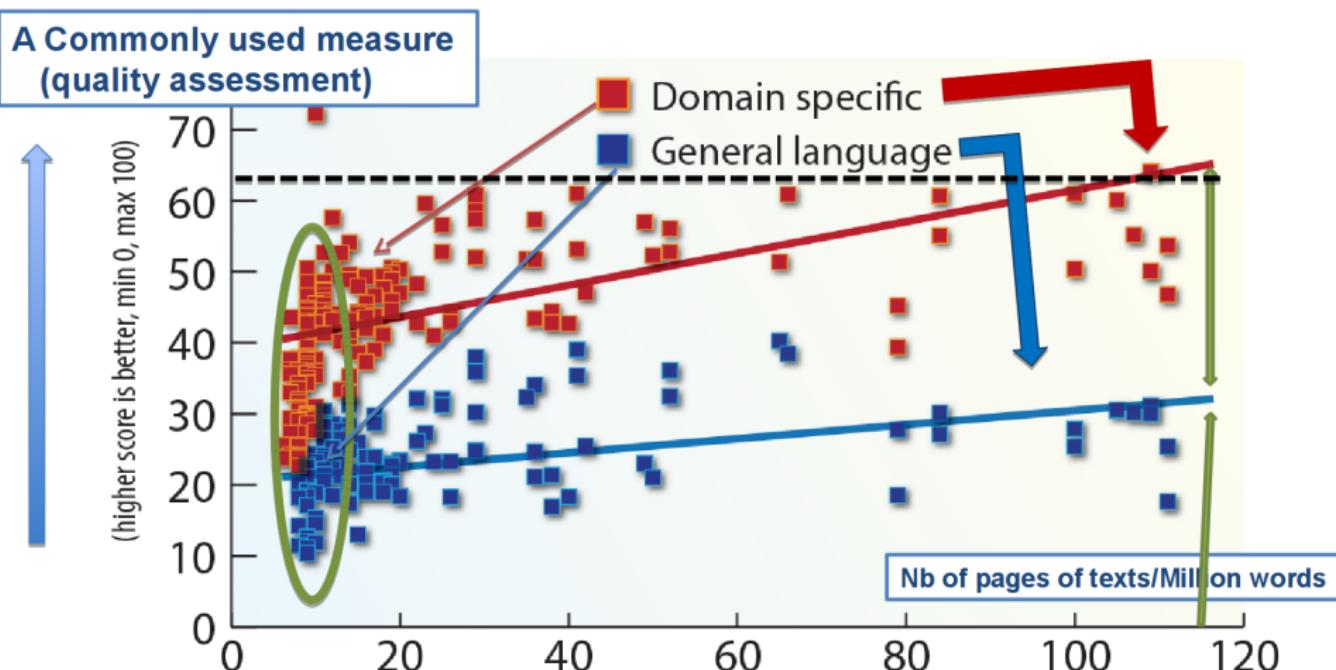
what  
is  
the  
length  
of  
the  
vector  
that  
is  
the  
sum  
of  
all  
of  
these  
?  
jaká vektoru součet  
je , že všech  
délka je těchto  
?

# Kolik textů je potřeba?

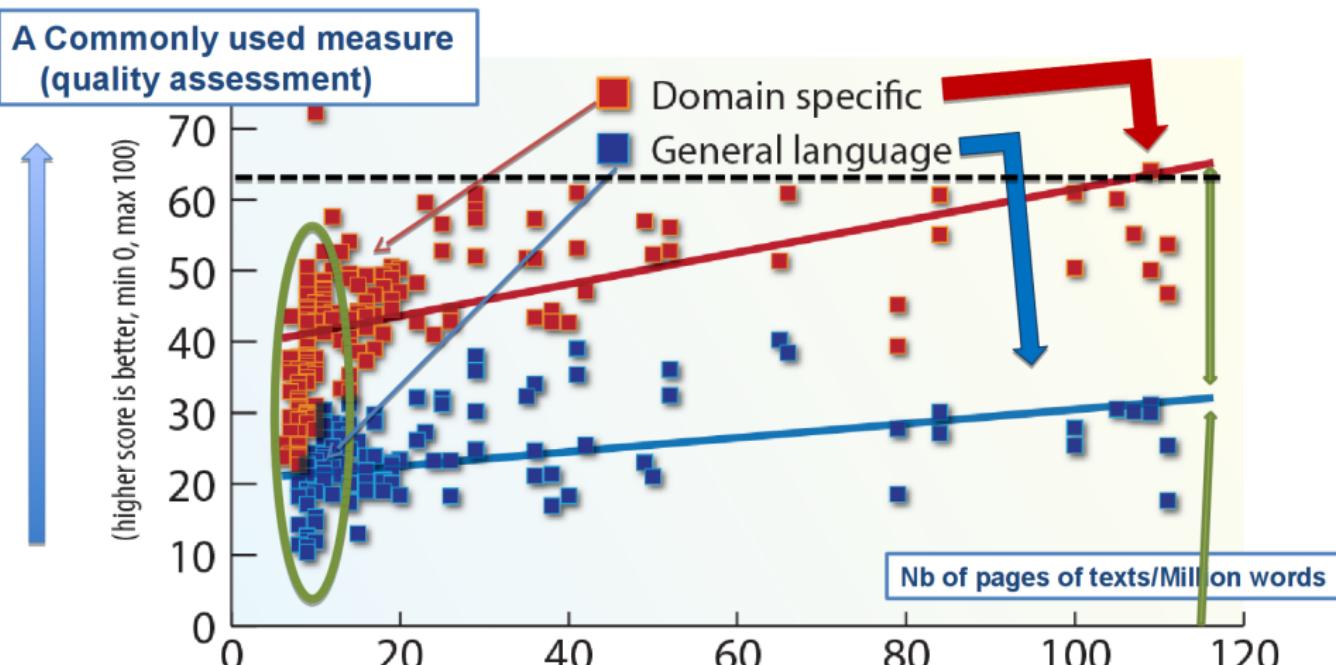
# Kolik textů je potřeba?

Víc.

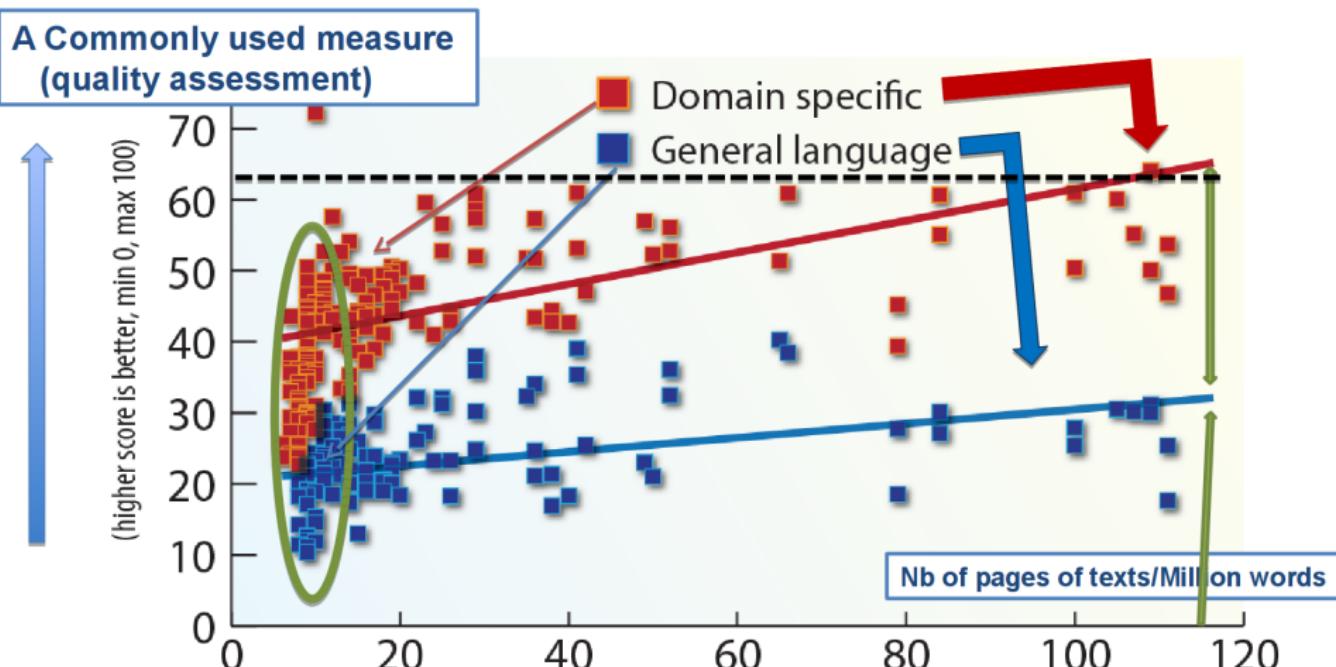
# Víc textů $\Rightarrow$ vyšší kvalita



# Texty v doméně $\Rightarrow$ rovnou lepší výstup

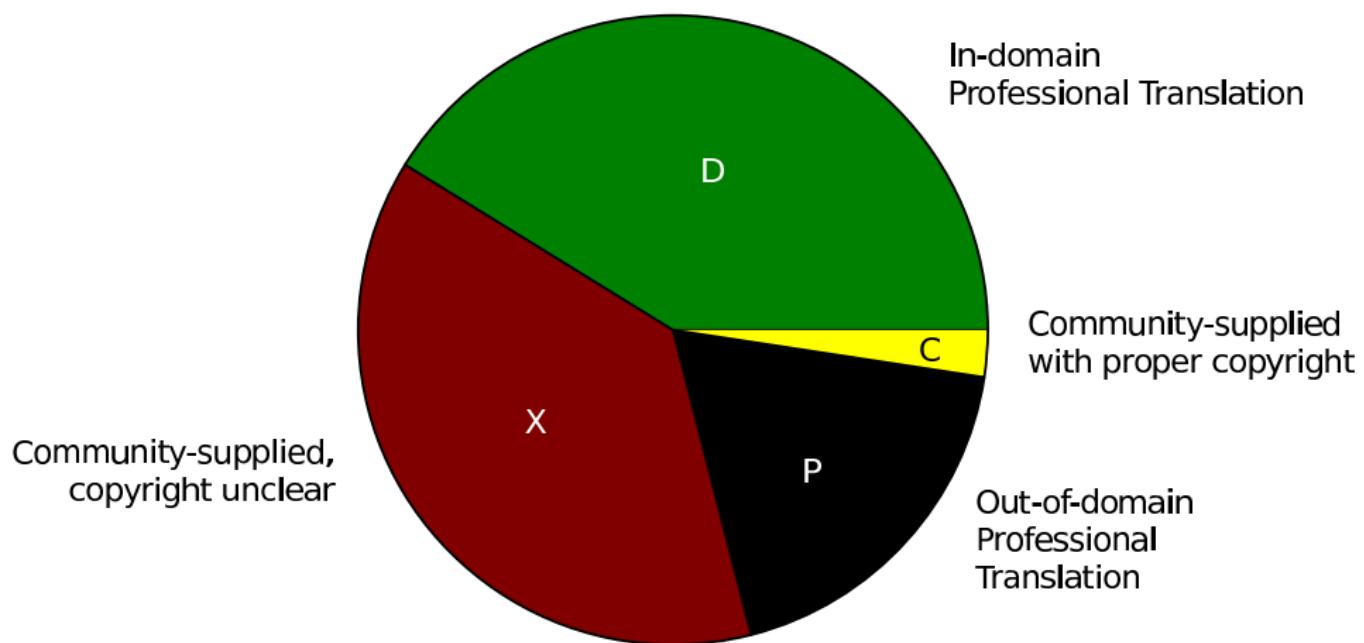


# Texty v doméně $\Rightarrow$ rychlejší zlepšení

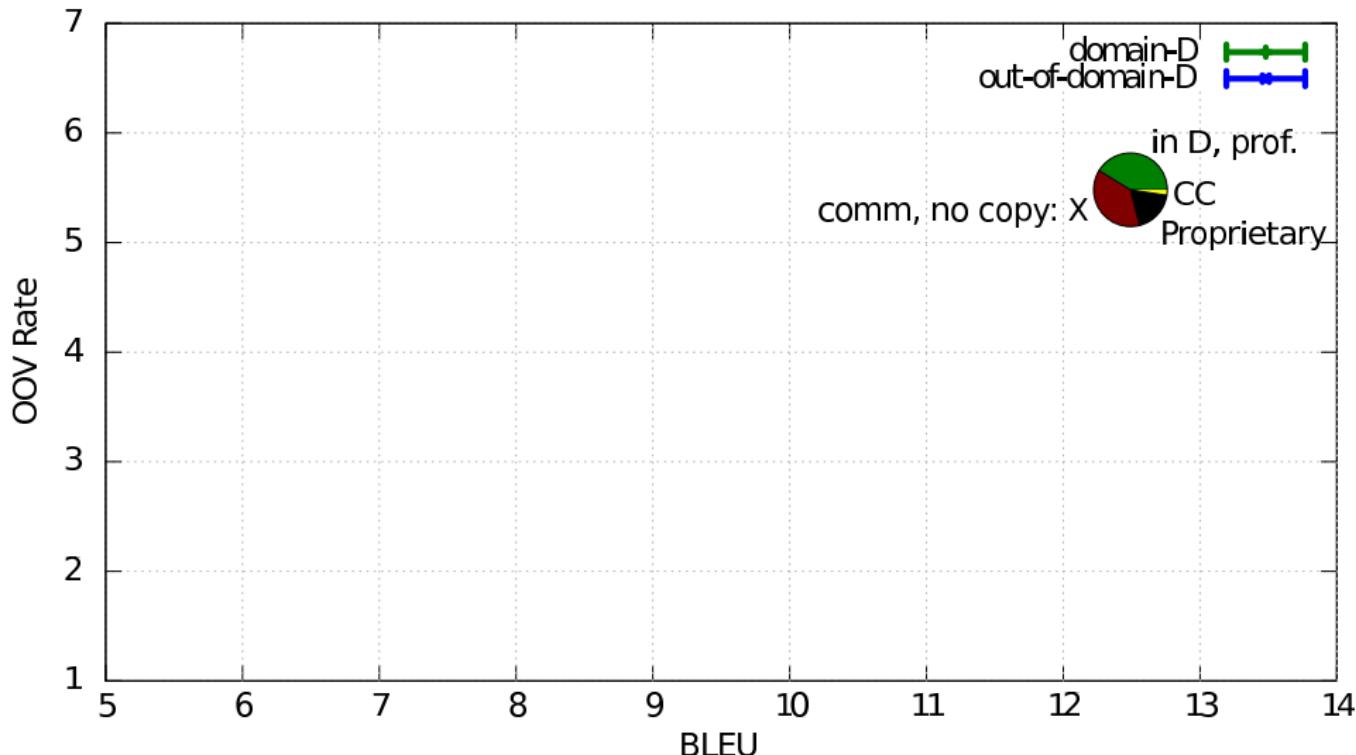


# Data pro aj→čj v roce 2008

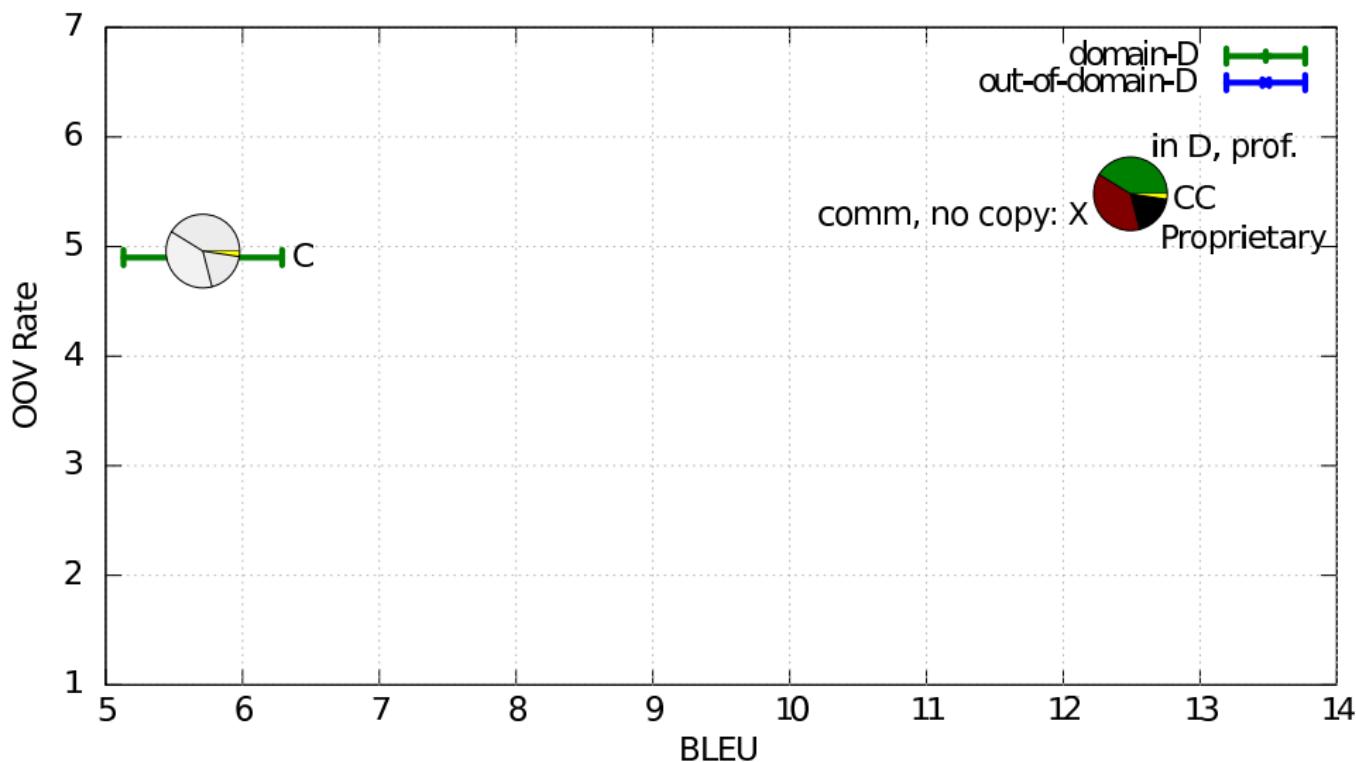
**Training Data Composition**



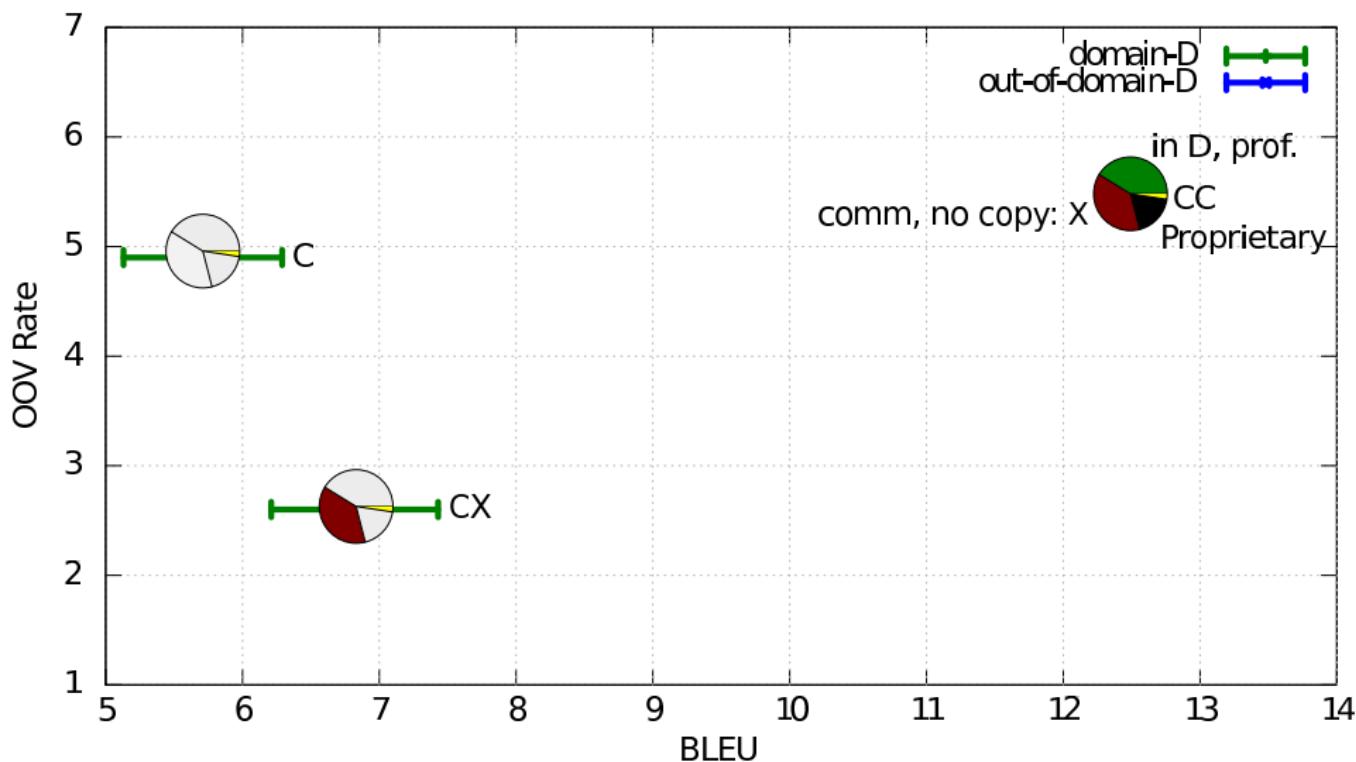
# Vliv dat na kvalitu a neznámá slova



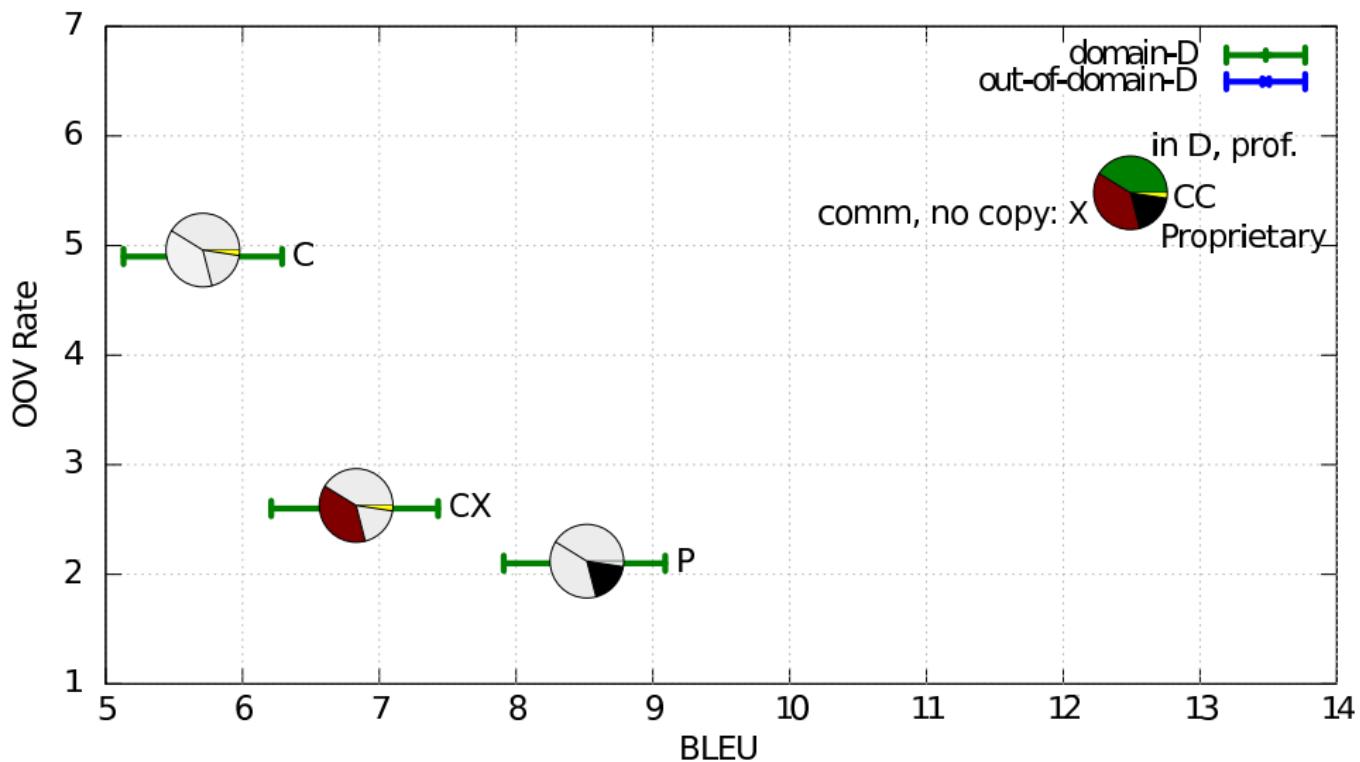
# Komunitní data mimo doménu



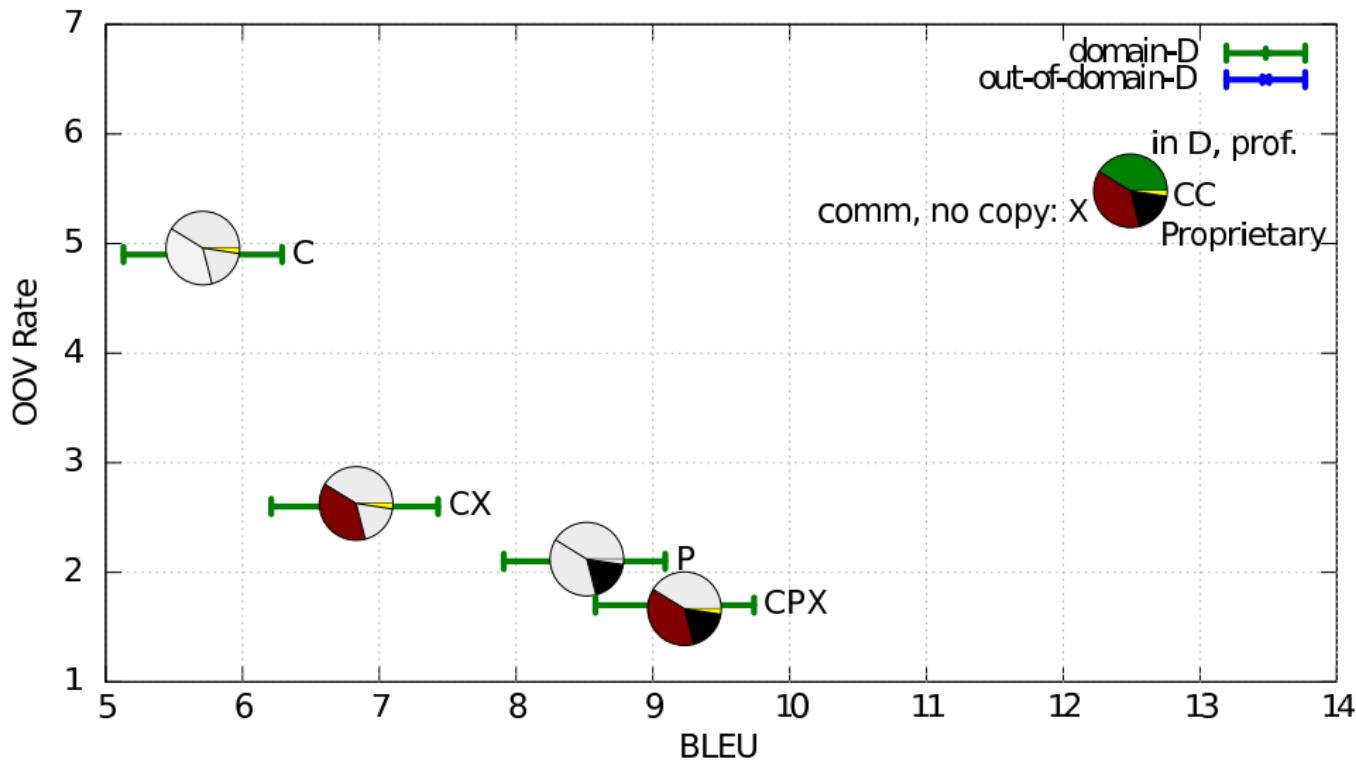
# Komunitní data mimo doménu



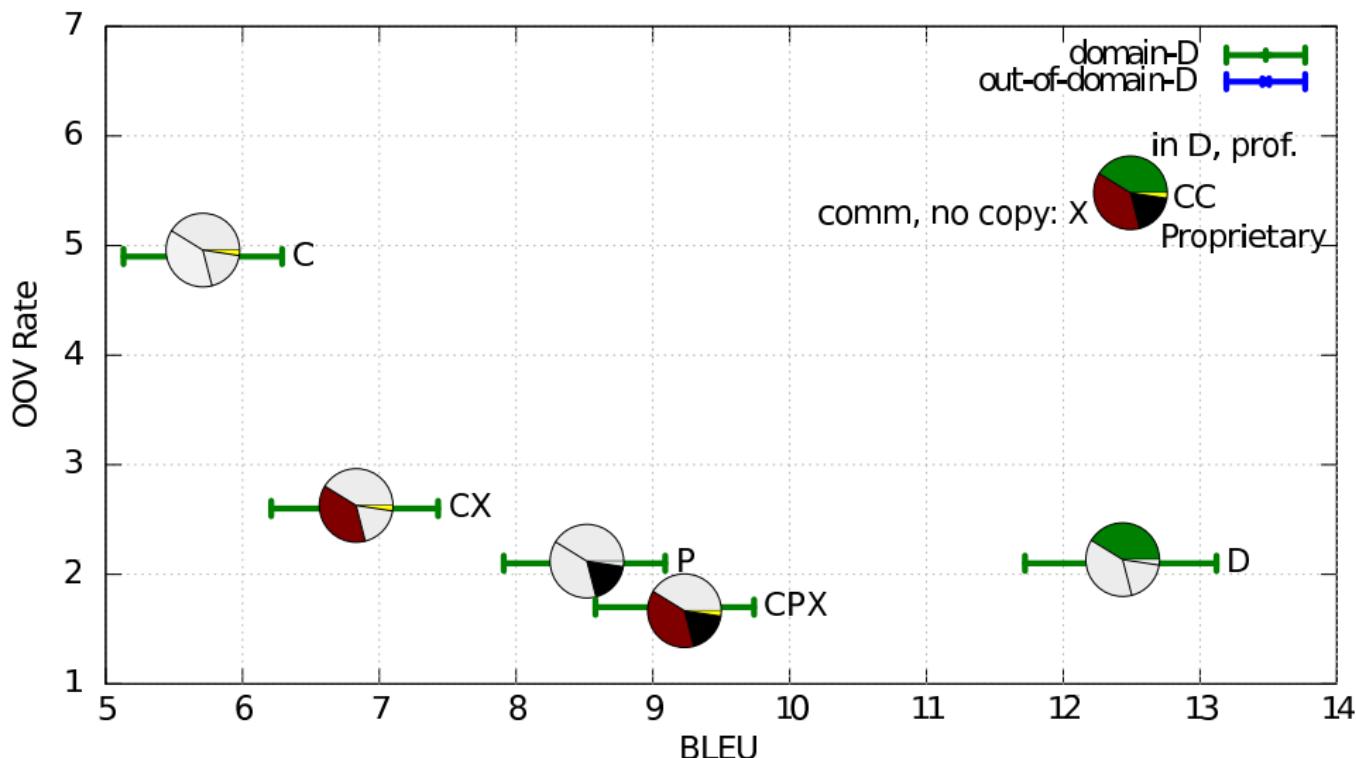
# Profesionální překlady mimo doménu



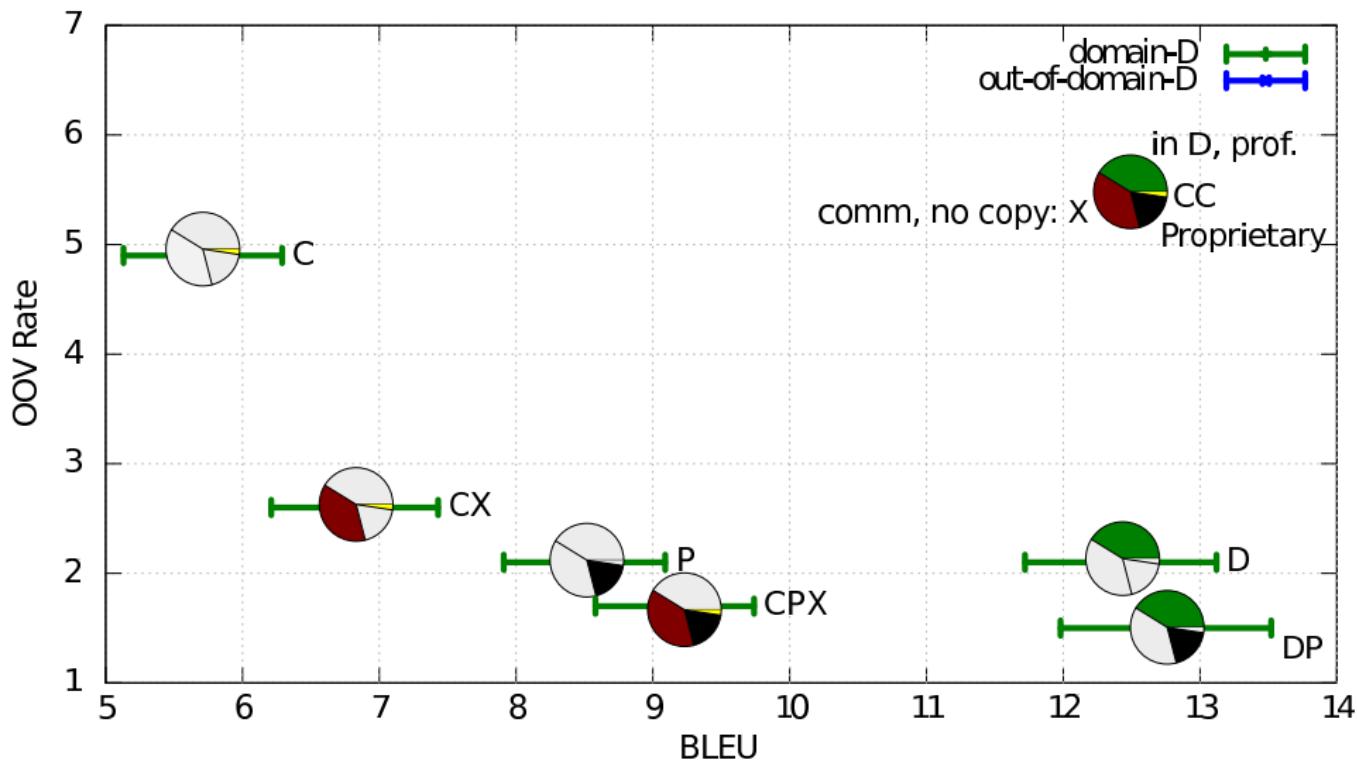
# Vše mimo doménu



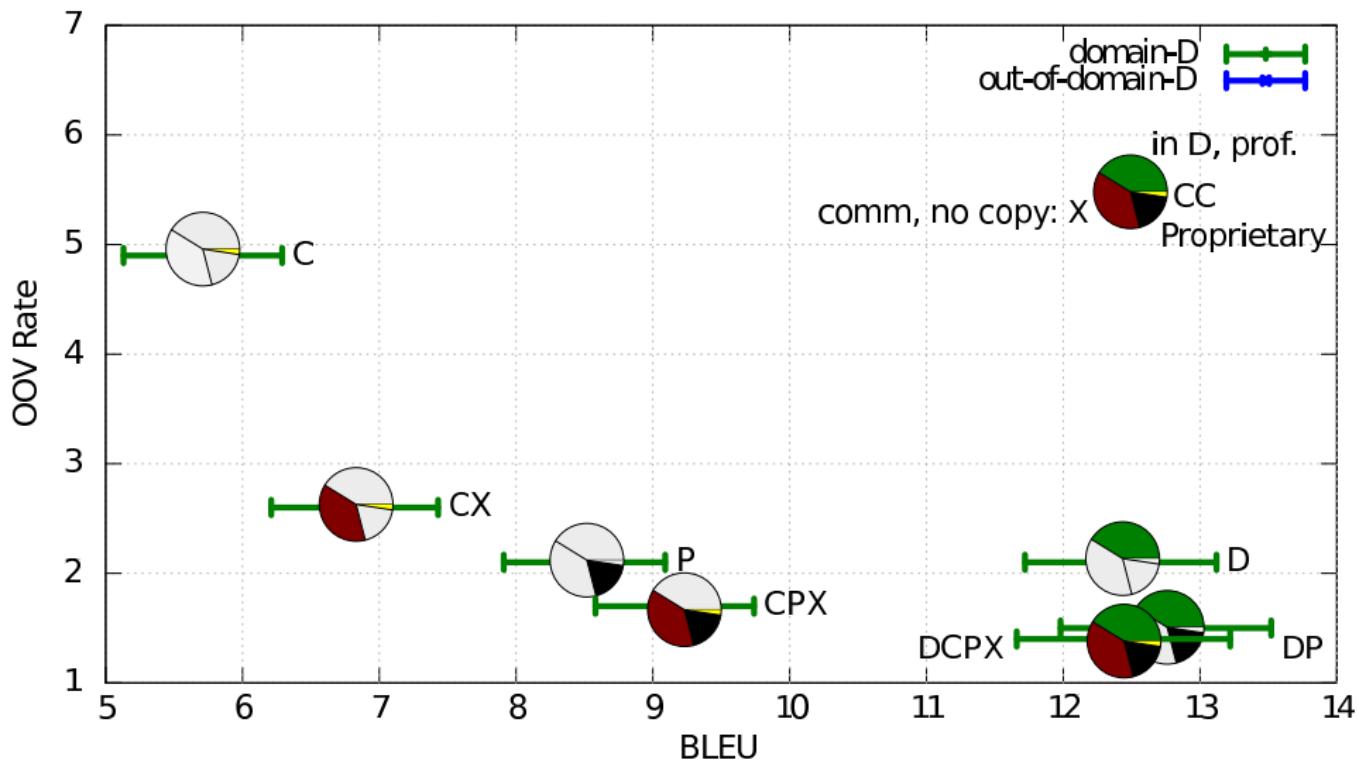
# Obdobný objem v doméně: mnohem lepší



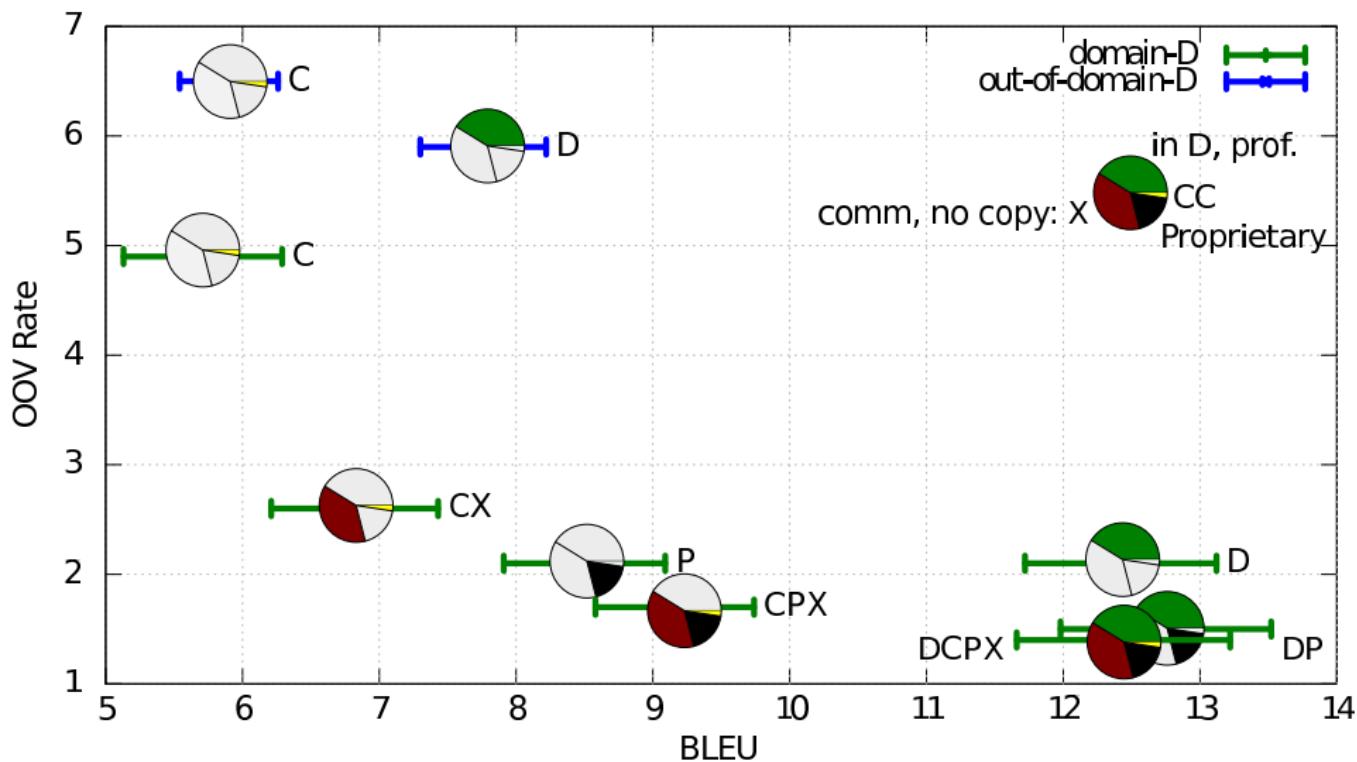
# Dodatečná data zlepší pokrytí



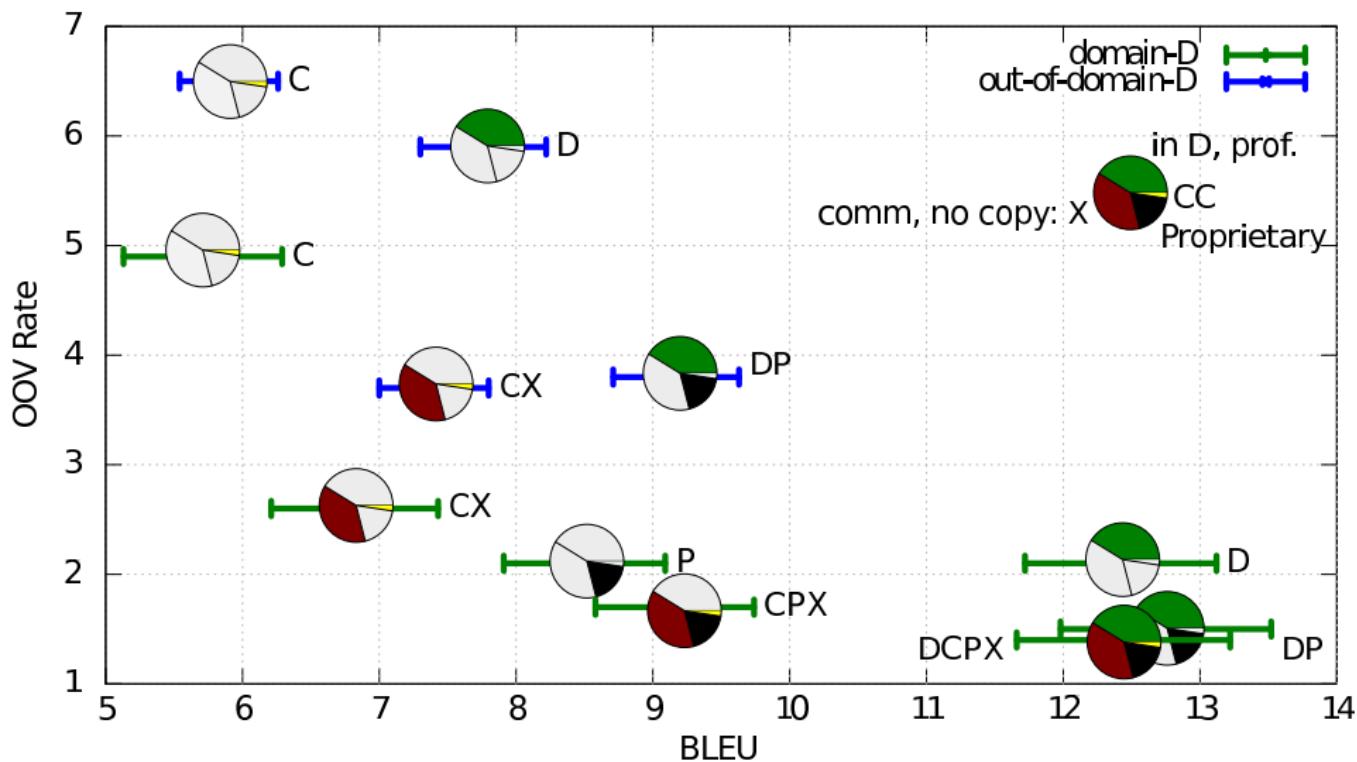
# ... ale mimo doménu mohou snížit kvalitu



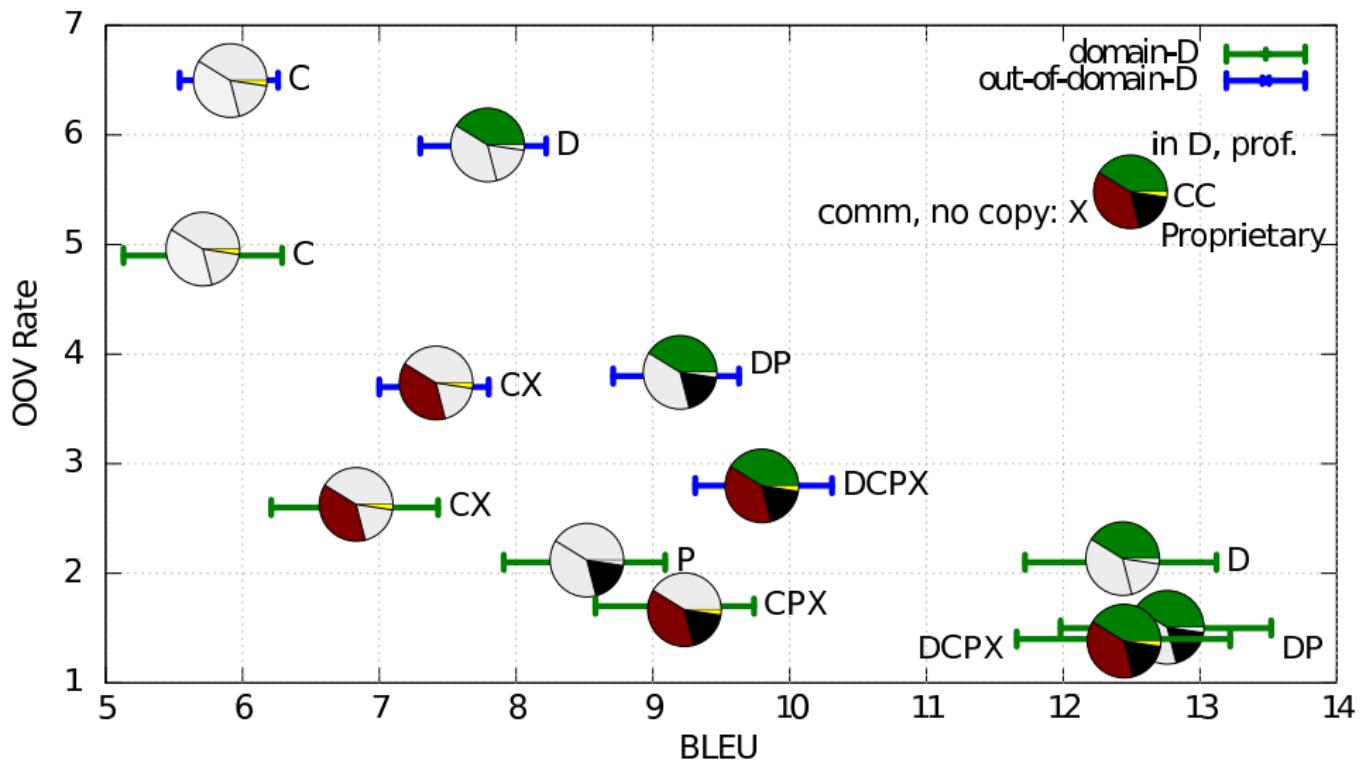
# Mimo doménu: kvalita i pokrytí horší



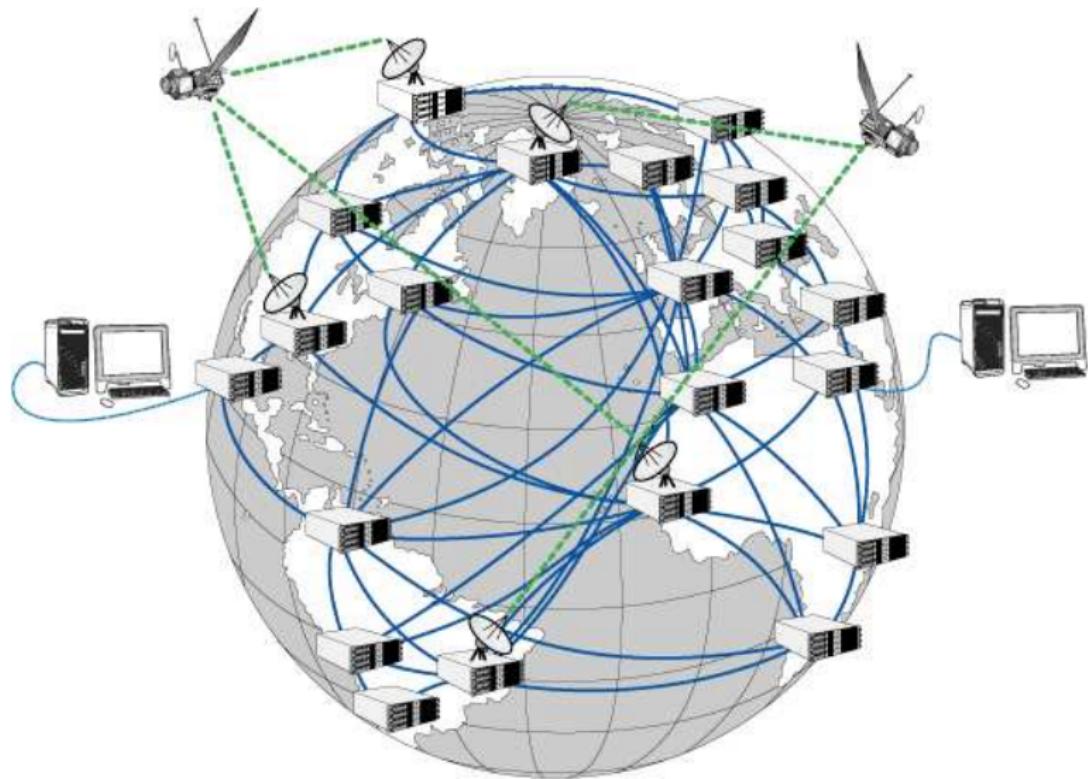
# ... víc dat zlepší pokrytí



# ... ale na moc kvalitu



# Data raději z webu než z papíru



# Paralelní webové stránky

File Edit View History Bookmarks Tile Tools Help

Travel to Norway - Official ... X Visit Greece | Meetings and... X Visit Greece | Συνεδριακος ... X

iGoogle Reading Groups Lit. Periodicals Recs GDT Οδηγία για το GDT Athens Google Map BIB EMTK MA2008 TrEd User's Manual

Greece of art and science

Greece is a place of culture, the arts and sciences. Its tradition of contribution to global cultural and scientific communities, combined with its outstanding natural beauty and excellent infrastructure, has made it an ideal place in which to hold **conferences**. Over the last few years, Greece has more and more frequently welcomed people of letters, sciences and the arts, who have participated in symposia, conferences and exhibitions. **Athens International Airport 'Eleftherios Venizelos'**, one of the most modern airports in the world in operation since 2001, greatly boosted the organization of international conferences.



Conference tourism is extremely interdependent: it requires of course a high level of background support from the host country, and at the same time it can actively contribute to improving the overall standard of services in the region. It is logical that a country chosen as a conference location should be involved in the cultural 'product', giving the public, both residents and visitors, the chance to experience **human achievement and innovative thought**.

The Greece of the pre-Socratic philosophers, of the great poets, of Pheidias the sculptor

Η Ελλάδα των τεχνών και της επιστήμης

Η Ελλάδα αποτελεί έναν χώρο πολιτισμού, τέχνης και επιστημών. Η μακραίωνη συμβολή της στο παγκόσμιο γίγνεσθαι, σε συνδυασμό με το μανοδικό φυσικό κάλλος και τις **όπτιες υπόδοσιές**, την καθιστούν ιδινόκιο τόπο διεξαγωγής συνεδριών. Τα τελευταία χρόνια, η ελληνική επικράτεια υποδέχεται όλο και συχνότερα ανθρώπους των γραμμάτων, των επιστημών και των τεχνών, οι οποίοι συμμετέχουν σε **συμπόσια, συνέδρια και εκθέσεις**. Ο **Διεθνής Αερολιμένας Αθηνών «Ελευθέριος Βενιζέλος»**, ένα από τα πλέον σύγχρονα αεροδρόμια παγκοσμίου, οποίος λειτουργεί από το 2001, έδωσε μεγάλη ώθηση στη διεργάστηκε διεθνών συνεδριών.

Ο συνεδριακός τουρισμός είναι άκρως αλληλεπιδραστικός: απαιτεί, βέβαια, ένα υψηλού επιπέδου υπόδειμα από τη χώρα υποδοχής, ταυτόχρονα όμως συμβάλλει ενεργά στην αναβάθμιση της συνολικής ποιοτήτας μιας περιοχής. Είναι λογικό, ένας χώρος ο οποίος προτιμάται για τη διεξαγωγή συνεδριών, να μετέχει προνομιακά στα πολιτιστικό «προϊόν», μιας και δίνει τη δυνατότητα σε κοινό, κατοικους και επισκέπτες, να έρθουν σε εποφή με τα ανθρώπινα επιτεύγματα και τις καινοτομίες.



# Podstatná část dat nedostupná

OPENTEXT

## The Deep Web

## The Public Web

Only 4% of Web content (~8 billion pages) is available via search engines like Google



7.9  
Zettabytes

## The Deep Web

Approximately 96% of the digital universe is on Deep Web sites protected by passwords

# Podstatná část dat nedostupná

## SURFACE WEB

Google

Wikipedia

Bing

Academic Information

Medical Records

Legal Documents

Scientific Reports

Subscription Information

## DEEP WEB

Multilingual Databases

Conference Proceedings

Government Resources

Competitor Websites

Organization-specific  
Repositories

Illegal Information

## DARK WEB

Drug Trafficking sites

# I dostupné texty nemusí být vytěžitelné

## Národní referenční laboratoře SVS ČR

### *National Reference Laboratories of the SVA CR*

Národní referenční laboratoř <i>National Reference Laboratory</i>	Sídlo <i>Address</i>
<b>I. NRL pro potraviny a krmiva / <i>NRL for Food and Feed</i></b>	
1. NRL pro mléko a mléčné výrobky / <i>NRL for milk and milk products</i>	Státní veterinární ústav Praha <i>State Veterinary Institute Prague</i> Sídelní 136/24 165 03 Praha 6 – Lysolaje
2. NRL pro salmonely / <i>NRL for Salmonellae</i>	Státní veterinární ústav Praha <i>State Veterinary Institute Prague</i> Sídelní 136/24 165 03 Praha 6 – Lysolaje
3. NRL pro Listeria monocytogenes / <i>NRL for Listeria monocytogenes</i>	Státní veterinární ústav Jihlava <i>State Veterinary Institute in Jihlava</i> Rantišovská 93 586 05 Jihlava

# A mnoho paralelních webů...

SVS - Chromium

eagri.cz/public/web/svs/portal

Veřejné zakázky Úřední deska SVS Tiskový servis Legislativa Kontakty E-podatelna Výsledky kontrol Česky English

 Státní veterinární správa

eAGRI ▶ Hledaný výraz Hledej Podrobné hledání ▶

Nejčastější dotazy

Přihlásit

Státní veterinární správa

► O Státní veterinární správě  
► Organizační útvary Státní veterinární správy  
► Zaměstnání  
► Zákazy a omezení  
► Zdraví zvířat  
► Pohoda zvířat - welfare  
► Veřejné zdraví  
► Laboratorní diagnostika  
► Farmářské trhy  
► Registrované subjekty  
► Potraviny s chráněným názvem  
► Formuláře ke stažení  
► Legislativa  
► Povinně zveřejňované informace dle zákona č. 106/1999 Sb.  
► Dokumenty a publikace  
► Odkazy  
► Obchodování s veterinárním zbožím  
► Nejčastější dotazy

**Státní veterinární správa**

Je orgánem státní správy v rezortu zemědělství a je zřízena podle zákona č. 106/1999 Sb.



Jejím úkolem je především ochrana spotřebitelů před případnými zdravotně závadnými produkty živočišného původu, monitorování a udržování příznivé nákazové situace zvířat, veterinární ochrana státního území České republiky, ochrana pohody zvířat a ochrana před jejich týráním.

Tisk stránky Poslat e-mailem

1 2 3 4 5 6 7 ► zobrazit po 10 20 50

Prodeje vánočních kaprů budou moći letos poprvé nahlašovat prodej také online 4.12.2015



Důležité informace

Infekční anemie koní  
Africký mor prasat  
Výroční zpráva Státní veterinární správy za rok 2014  
Vysocepatogenní avíární influenza  
Mista vstupu pro zvířata v zájmovém chovu  
Informace pro chovatele a obchodníky se skotem  
Dovoz potravin pro osobní cestující do České republiky



# ... je paralelních jen zčásti.

State Veterinary Administration (SVS) - Chromium

eagri.cz/public/web/en/svs/portal/

Press Service   Contacts   Česky   English

 State Veterinary Administration

eAGRI ▾ Words to search   Search   Advanced Search ▾ Log In

State Veterinary Administration

[About State veterinary administration](#)  
[Animal welfare](#)  
[Animal health](#)  
[BIP in the Czech Republic](#)  
[Registered subjects](#)  
[Laboratory diagnostics](#)  
[Published publications](#)  
[Public Health](#)  
[Trade with vet. commodities](#)

**State Veterinary Administration**



Is a public administration body under the Ministry of Agriculture of the Czech Republic and it was established according to the Veterinary Act No. 166/1999.

Its purpose is primarily the protection of consumers from products of animal origin likely to be harmful to human health, monitoring of animal health situation and maintaining it favourable, veterinary protection of the state territory of the Czech Republic, animal welfare and animal protection.

News

[Results of inspections in 2015](#)  
Jan 1, 2015  
[TRAVELLING WITH PET ANIMALS](#)  
[Contamination of Food Chain by Residues - Situation 2013](#)  
Jul 14, 2014

Print   Send by e-mail

# Postup

1. Najít dobré zdroje.
2. Získat surová data.
3. (Identifikovat a pojmenovat domény.)
4. Vyčistit.
  - ▶ Odstranit navigační prvky, reklamu, ...
  - ▶ Odstranit neparalelní části.
  - ▶ Odstranit jiné jazyky.
5. Zarovnat po dokumentech.
6. Zarovnat po větách.
7. Odstranit nekvalitně zarovnané části.
8. Zpřístupnit ostatním.  
⇒ Paralelní korpus CzEng.

<http://ufal.mff.cuni.cz/czeng>

## Šlo by to i lépe

- ▶ Můžete nám poradit dobré zdroje.
- ▶ Můžete nám pomoci s určením domény.
- ▶ Můžete nám přímo poskytnout své texty.

# Šlo by to i lépe

- ▶ Můžete nám poradit dobré zdroje.
- ▶ Můžete nám pomoci s určením domény.
- ▶ Můžete nám přímo poskytnout své texty.





YOUR DATA IS NEEDED!

# Shrnutí

- ▶ Lingvistické analýzy potřebují anotovaná data v doméně.
- ▶ MT potřebuje **paralelní texty** v doméně i mimo ni.
- ▶ Čím víc, tím líp.
- ▶ Čím podobnější vstupům, tím lepší.
- ▶ Jazykové zdroje je třeba sdílet.
  - ▶ I průmysl data sdílí (např. TAUS).
- ▶ Zveřejněné překlady vytěžujeme, netriviální úsilí.
  - ▶ Ideálně ne PDF, nejraději HTML s podobným URL.
- ▶ Mnohem lepší by byly primární zdroje
  - ▶ Vaše texty, překladové paměti.