



Setting

- similar languages (e.g. Slovak and Czech)
- no parallel data, no supervised source data



Goal

- simulate human-like crosslingual understanding
- perform machine translation without parallel data



Reasoning

- there are ~7000 languages in the world
- required data easy to get for ~100 languages

Method

Idea: translate each source word by the **most similar** target word

Assumptions: corresponding words:

- are string-wise similar
- have similar length
- have similar frequency

$$\text{sim}(s, t) = \text{sim}_{JW}(s, t) \cdot \text{sim}_{len}(s, t) \cdot \text{sim}_{freq}(s, t)$$

String-wise similarity

- based on Jaro-Winkler edit distance
- prefixes more important
- good for languages with word-final inflection
- also computed on ASCII transliterations
- also computed on devowelled words (strip AEIOUY)

$$\text{sim}_{JW}(s, t) = \text{sim}_{jw}(s, t) \cdot \text{sim}_{jwT}(s, t) \cdot \text{sim}_{jwD}(s, t) \cdot \text{sim}_{jwDT}(s, t)$$

Length similarity

- also computed on devowelled words

$$\text{sim}_{len}(s, t) = \frac{1}{1 + |\text{len}(s) - \text{len}(t)|}$$

Frequency similarity

- computed on available monolingual corpora
- normalization to account for differing corpora sizes

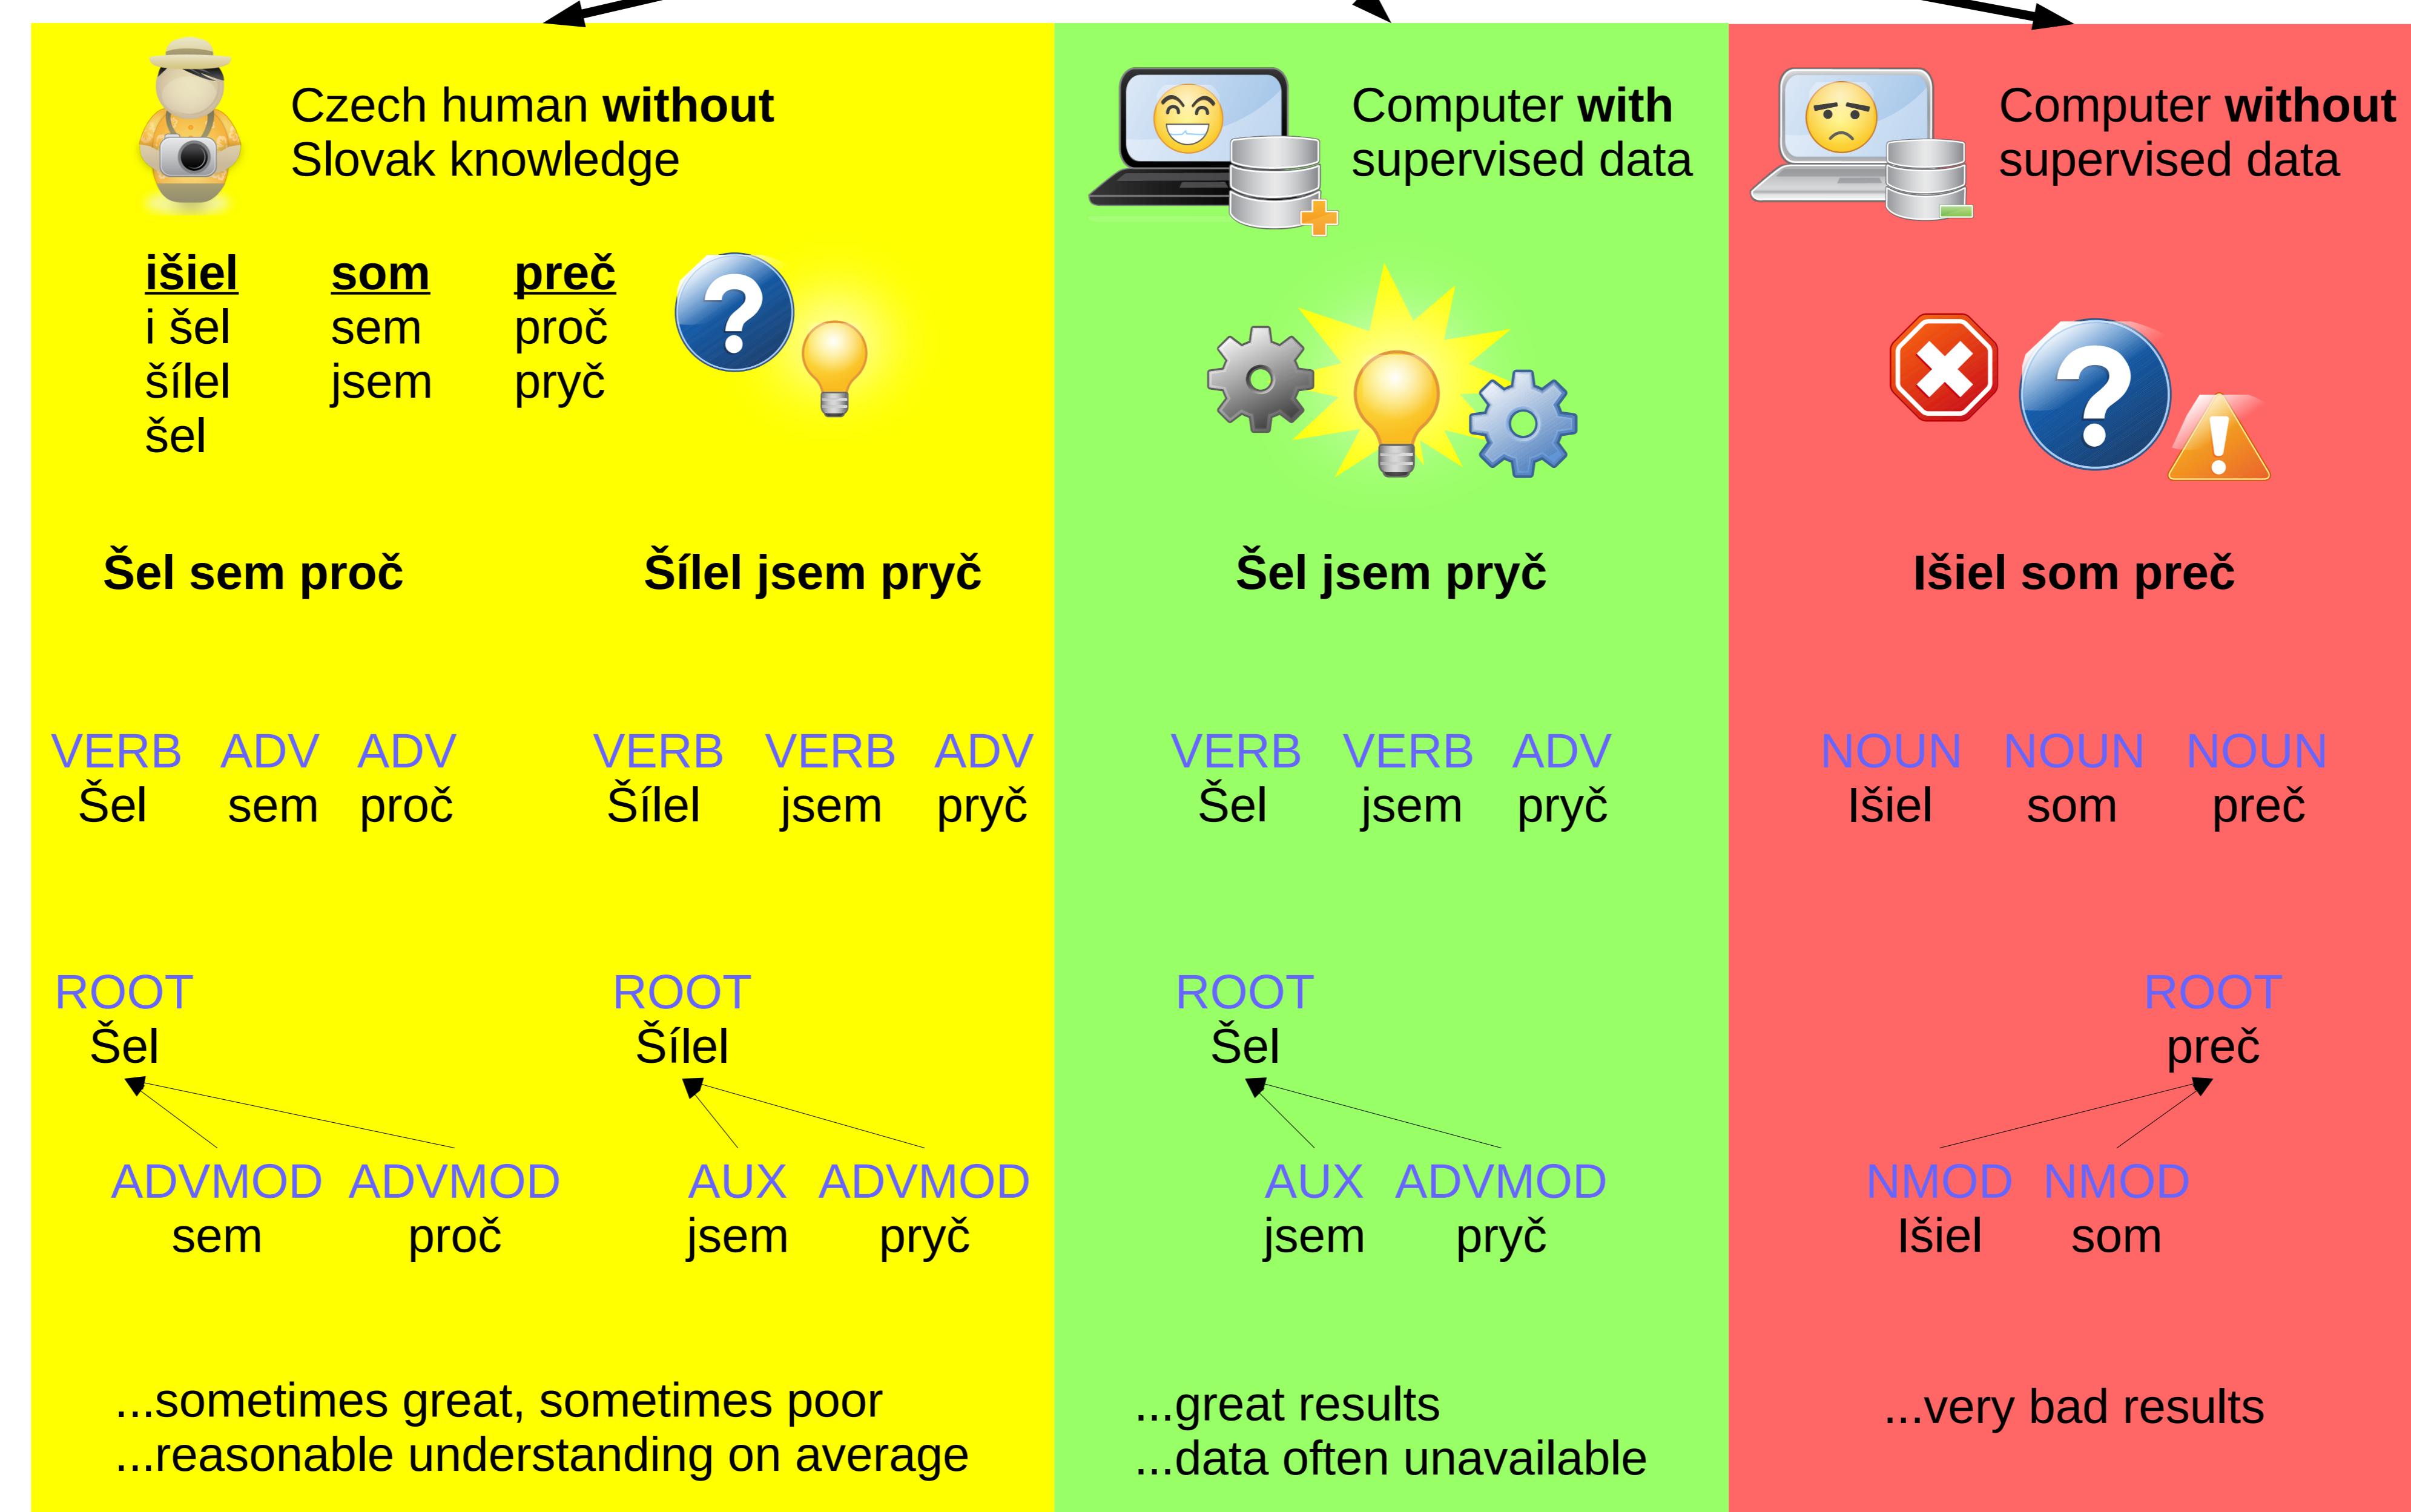
$$\text{sim}_{freq}(s, t) = \frac{1}{1 + |\log(\text{freq}(s)) - \log(\text{freq}(t))|}$$

Efficiency

- cannot go over all target words for each source word
- leads to e.g. 1 word/minute
- goal: e.g. 1 word/second
- early stopping
- start with frequent candidates
- stop once sim_{freq} is lower than current highest sim
- huge speedup
- limited capabilities: hard to add a language model
- word list partitioning
- source and target word must share first 2 consonants
- huge speedup
- introduces search errors, many translations not found
- e.g. "som" cannot be translated to "jsem"

Motivation

Input: Išiel som preč



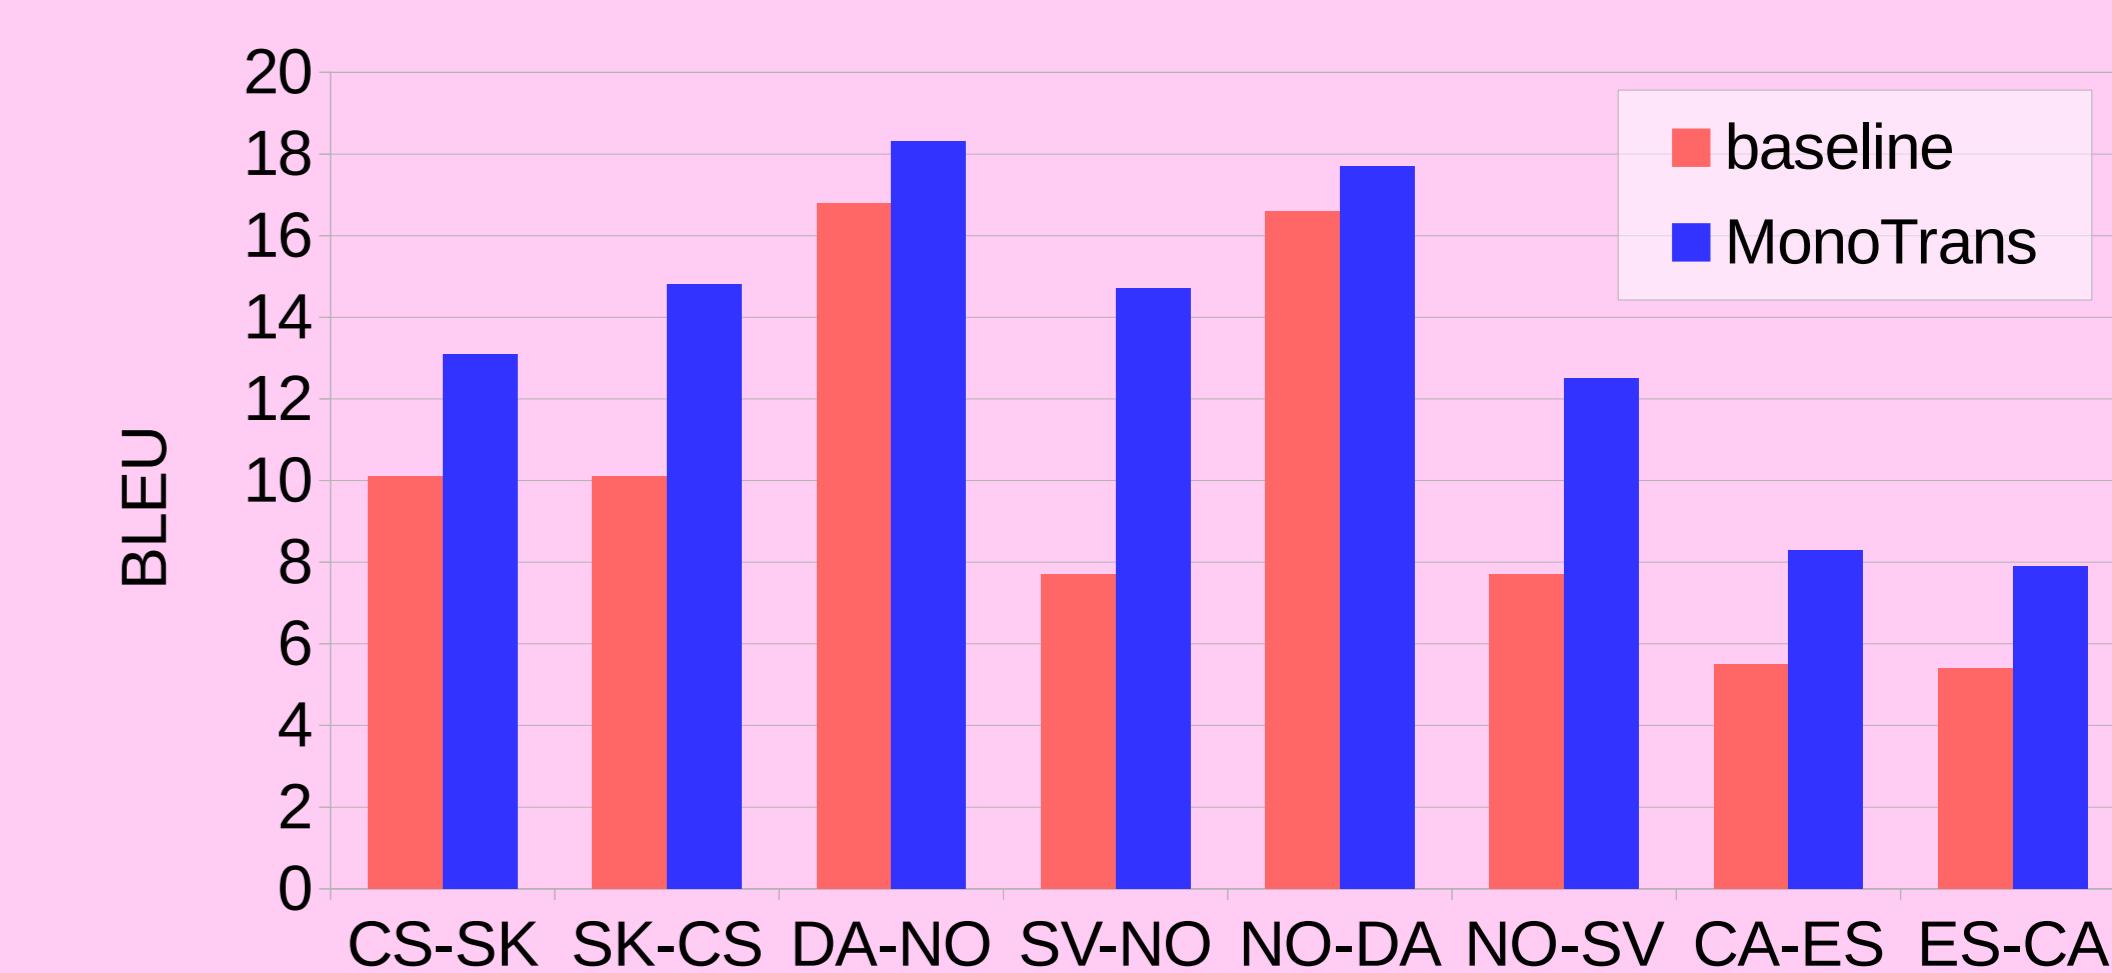
Sample outputs (SK-CS)

SK: Všetci sme počuli o tom, čo si urobil pre toho chlapca a je mi líto, že to nezvládol. CS: Všechn sem poučil o tom, čo si urobil pro toho chlapce a je mi líto, že to nezvládol.	SK: Navrhujem , aby si sa zase sústredil na hru. CS: Navrhují, aby si se zase sústredil na hru.
SK: Volá sa to vernošť. CS: Volá se to věrnost.	SK: Keď ma zrazil opitý vodič, ktorého uznali nevinným, bol to Doug, kto mi pomohol zaplatiť za štúdium práva. CS: Kde má zrazil opitý vodič, kterého uznali nevinnou, byl to Doug, který mi pomohl zaplatit za štúdium práva.
SK: Posledné, čo sa mi chce, je strčiť ti lopuť do ruky. CS: Poslední, čo se mi chce, je strčte ti lopaty do ruky.	SK: Zoznámim vás s priateľmi. CS: Zazvoním vás s parazitem.
SK: Môžem úprimne povedať, že som nikdy nemal piateľa, s ktorým by som sa cítil ako s tebou. CS: Môžeme promiňať povídať, že sem nikdy neměl přítelé, s kterým by sem se cítil jako s tebou.	SK: Počuj, asi som zaujatý, no toto je dokonalá svadba. CS: Počej, asi sem zajatý, no toto je dokonalý svatba.
SK: My sa môžeme povaľovať sa na pohovkách. CS: My se můžeme považovat se na pohádkách.	SK: Nie! Žiadne arašídrové maslo! CS: Ne! Žádné arašídrové myslí!
SK: Alebo povedať: Doug, podme na pivo. Alebo si pozrieme zápas. CS: Alebo povídaj: Doug, podle na pivo. Alebo si pozřeme zápas.	SK: Na našom treťom rande povedala, že si chce založiť rodinu, že je pripravená mať děti. CS: Na naším třetím rande povídala, že si chce založit rodinu, že je připravená mít děti.
SK: Historická pánska jazda s mojím najbližším priateľom. CS: Historický pánské jízdě s mojí nejbližším parazitem.	SK: Nekecraj. Myslís, že ja to nechcem? CS: Nekecjej. Myslís, že já to nechceš?
SK: Snažím sa bojovať so svojimi zbraňami každý deň, každý zápas, po celú dobu svojej kariéry. SK: Snažím se bojovat s svojich zbraniami každý den, každý zápas, po celé dobu svoje kariéry.	SK: Vyhlasujem vás za manželov. CS: Vyhlašujeme vás za manželku.
	SK: Nemal by som jej vravieť pravdu? CS: Neměl by sem jej vravit pravdu?

Evaluation

Intrinsic evaluation: translation quality

- data source: OpenSubtitles2016
- Czech (CS), Slovak (SK)
- Danish (DA), Norwegian (NO), Swedish (SV)
- Catalan (CA), Spanish (ES)
- data size: 10,000 sentences
- baseline: keep source text untranslated
- result: average **43% improvement** over baseline



Extrinsic evaluation: tagging and parsing

- treebank data: Universal Dependencies v1.4
- translate source UD treebank into target language
- train UDPipe tagger and parser
- evaluate on target UD treebank
- baseline: keep source TB untranslated
- supervised: use target TB for training
- result: average **23% error reduction**

