

PA153

Strojový překlad

Vít Baisa

Překlad

Překlad je převod textu ze zdrojového jazyka do jazyka cílového.

- ▶ odborný překlad × literární překlad
- ▶ přesná reprodukce × volná převodová parafráze

Maimonidés, 12. stol.

Pro překlad slova je rozhodující kontext.

Werner Winter

Každé slovo je element vytržený z celkového jazykového systému a jeho vztahy k jiným segmentům systému jsou v jednotlivých jazycích rozdílné.

Každý význam je element z celého systému segmentů, v němž mluvčí rozčleňuje skutečnost. V jazyce Mohave: otec ženy \neq otec muže

Otázky překladu

- ▶ Je vůbec přesný překlad mezi jazyky možný?
- ▶ Jak se pozná, že w_1 je překladový ekvivalent slova w_2 ?
- ▶ anglické typy větru, eskymácké typy sněhu, ...
- ▶ jak přeložit slova jako *alkáč*, *večerníček*, *telka*, *čoklbuřt*, *knížečka*, *ČSSD* ... ?

Strojový překlad I – definice

Strojový překlad

Obor počítačové lingvistiky zabývající se návrhem, implementací a aplikací automatických systémů (programů) pro překlad textů s minimálním zásahem člověka.

Např. používání elektronických slovníků při překladu nepatří do strojového překladu.

Strojový překlad II – předmět zájmu

Zejména:

- ▶ webové stránky
- ▶ technické manuály
- ▶ vědecké dokumenty
- ▶ prospekty, katalogy
- ▶ právníké texty
- ▶ obecně texty z omezených domén

Nuance na různých jazykových vrstvách v umělecké literatuře jsou mimo schopnosti současných nástrojů NLP.

Strojový překlad III

Ve skutečnosti je výstup z MT vždy revidován. Mluví se o *před-překladu* resp. o *post-editaci*.

Ta je někdy nutná i u člověka, ovšem systémy MT dělají zcela rozdílné chyby.

Pro člověka jsou typické chyby:

- ▶ špatné předložky (*I am in school*)
- ▶ chybějící členy (*I saw man*)
- ▶ špatné tvary slov: *mouses, breaked, . . .*

Pro počítač jsou typické zejména chyby významové: *Kiss me, honey.*


Metody přímého zlepšení kvality strojového překladu

- ▶ omezení vstupu na:
 - ▶ podjazyk (oznamovací věty)
 - ▶ doménu (informatika)
 - ▶ typ dokumentu (patentové dokumenty)
- ▶ pre-processing textu (např. ruční syntaktická analýza)

Klasifikace podle přístupu (approach)

- ▶ pravidlový (znalostní) strojový překlad
rule-based, knowledge-based – RBMT, KBMT
 - ▶ transferový
 - ▶ interlingua
- ▶ statistický strojový překlad
statistical machine translation – SMT
Example-based machine translation – EBMT
- ▶ hybridní strojový překlad
hybrid machine translation – HMT, HyTran

Vauquoisův trojúhelník



Klasifikace podle interakce s uživatelem

- ▶ (ruční překlad)
- ▶ ruční překlad s pomocí počítače
machine-aided human translation – MAHT
- ▶ automatický překlad s interagujícím překladatelem
human-aided machine translation – HAMT
- ▶ plně automatický překlad
fully automated high-quality (M)T – FAHQT

HAMT a MAHT někdy souhrnně označovány jako CAT – computer-aided translation.

Rané názory na strojový překlad

- ▶ překlad je často opakovaná činnost – věřilo se, že bude tuto proceduru možné počítačem napodobit
- ▶ úspěchy použití počítačů v kryptografii: vhodné i pro strojový překlad?

Warren Weaver

When I look at an article in Chinese, I say: This is really written in English, but it has been coded in some strange symbols. I will now proceed to decode.

Georgetown experiment

První funkční prototyp strojového překladu.

- ▶ 50 vět (zřejmě pečlivě vybraných)
- ▶ spolupráce s IBM
- ▶ slovník obsahoval 250 slov
- ▶ překlad z ruštiny do angličtiny
- ▶ gramatika pro ruštinu obsahovala 6 pravidel

Demonstrace systému vyvolala nadšení. MT bylo očividně možné. Následně odstartovalo mnoho nových projektů, hlavně v USA a Rusku.

Vývoj v 50. letech

- ▶ MT oblast podnítila rozvoj a výzkum na poli
 - ▶ teoretické lingvistiky (Chomsky)
 - ▶ počítačové lingvistiky
 - ▶ umělé inteligence (60. léta)
- ▶ s větším pokrytím kvalita strojového překladu klesala
- ▶ i nejlepší systémy (GAT, Georgetown, RU→EN) poskytovaly nepoužitelný výstup

Zklamání ze slabých výsledků

- ▶ i přes nevalné výsledky přetrvával optimismus
- ▶ Yehoshua Bar-Hillel píše v roce 1959 kritiku stavu strojového překladu
- ▶ tvrdí, že počítače nejsou schopné provádět lexikální desambiguaci
- ▶ fully automated high-quality translation (FAHQT) podle Bar-Hillela stěží dosažitelné

Yehoshua Bar-Hillel – příklad pro desambiguaci

Little John was looking for his toy box. Finally, he found it. The box was in the pen. John was very happy.

Výdaje na projekty strojového překladu se začaly snižovat.

ALPAC report

- ▶ Automatic Language Processing Advisory Committee
- ▶ organizace pod U.S. National Academy of Science
- ▶ analýzy a vyhodnocení kvality a použitelnosti systémů MT
- ▶ doporučila omezit výdaje na podporu strojového překladu
- ▶ vývoj strojového překladu v Evropě a Japonsku pokračoval nepřerušeně dál
- ▶ celých 15 let trvalo než MT v USA znovu získal vážnost a původní postavení

TAUM, METEO

TAUM

- ▶ Traduction Automatique à l'Université de Montréal
- ▶ Université de Montréal in 1965
- ▶ prototypy MT systémů: TAUM-73, TAUM-METEO
- ▶ jedny z prvních systémů provádějící automatický překlad přes analýzu zdrojového jazyka a syntézu cílového jazyka
- ▶ překlad z angličtiny do francouzštiny

METEO

- ▶ 1981–2001 používán pro překlad předpovědí počasí
- ▶ autor John Chandiou, Kanada

Systran

- ▶ jedna z nejstarších MT firem (1968)
- ▶ velmi populární překladový systém
- ▶ základ Yahoo Babel fish, do r. 2007 využíván v Google
- ▶ RBMT, od r. 2010 hybridní překlad
- ▶ od r. 1976 oficiální MT systém používaný Evropským hospodářským společenstvím

Strojový překlad v současnosti

- ▶ intenzivní sběr paralelních dat
- ▶ vývoj systémů vzhledem k hodnoticím metrikám
- ▶ USA: zájem o angličtinu jako TL
- ▶ EU: překlad mezi 23 úředními jazyky EU (EuroMatrix)
- ▶ korporace (Microsoft) zaměřeny na En jako SL
- ▶ SMT obohacována syntaxí
- ▶ velké páry (En↔Sp, En↔Fr): velmi dobrý překlad
- ▶ Google Translate jako gold standard
- ▶ morfologicky bohaté jazyky jsou opomíjeny
- ▶ En-* a *-En páry převažují

Motivace pro strojový překlad ve 21. století

- ▶ překlad webových stránek pro pochopení obsahu (gisting)
- ▶ metody pro výrazné urychlení překladatelské práce (překladové paměti)
- ▶ extrakce a vyhledávání informací mezi jazyky (cross-lingual IR)
- ▶ instantní překlad instantní komunikace
- ▶ překlad na mobilních zařízeních

EuroMatrix, 2006–2009

- ▶ překlad všech párů EU jazyků
- ▶ využití lingvistické znalosti ve statistickém MT
- ▶ vývoj a testování hybridních architektur
- ▶ každoroční vyhodnocování kvality MT
- ▶ open source: nástroje, software, data
- ▶ přehled stavu MT pro EU jazyky

Závěr úvodu

- ▶ strojový překlad patří mezi UI-kompletní problémy
- ▶ máme k dispozici obrovskou výpočetní sílu
- ▶ tržní potenciál je větší než kdy dřív
- ▶ statistické metody se aktuálně zdají vhodnější
- ▶ nové nápady jsou vítány! (BP, DP)



Rule-based Machine Translation – RBMT

- ▶ lingvistické znalosti formou pravidel
- ▶ pravidla pro analýzu
- ▶ pravidla pro převod struktur mezi jazyky
- ▶ pravidla pro syntézu
- ▶ Knowledge-based Machine Translation

Rozdělení systémů RBMT:

- ▶ přímý překlad
- ▶ systémy používající interlinguu
- ▶ transferové systémy

Interlingua vs. transferové KBMT



Proces analýzy

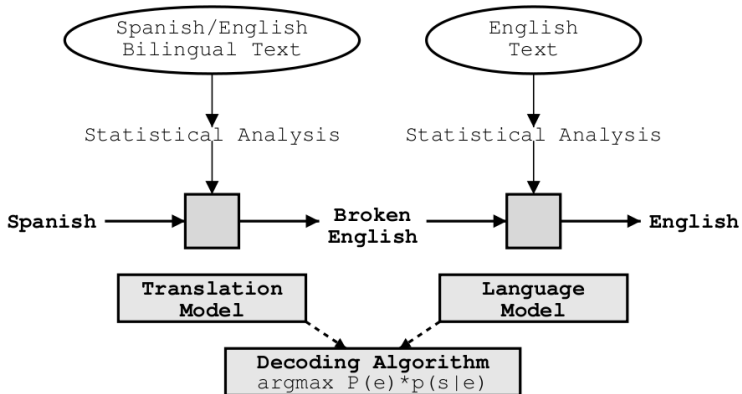
- ▶ tokenizace
- ▶ morfologická analýza (značkování)
- ▶ morfologická disambiguace (pravidlová, statistická)
- ▶ syntaktická analýza
- ▶ sémantická analýza: lexikální disambiguace

slovo	analýzy	disambiguace
Pravidelné	k2eAgMnPc4d1, k2eAgInPc1d1, k2eAgInPc4d1, k2eAgInPc5d1, k2eAgFnSc2d1, k2eAgFnSc3d1, k2eAgFnSc6d1, k2eAgFnPc1d1, k2eAgFnPc4d1, k2eAgFnPc5d1, k2eAgNnSc1d1, k2eAgNnSc4d1, k2eAgNnSc5d1, ... (+ 5)	k2eAgNnSc1d1
krmení	k2eAgMnPc1d1, k2eAgMnPc5d1, k1gNnSc1, k1gNnSc4, k1gNnSc5, k1gNnSc6, k1gNnSc3, k1gNnSc2, k1gNnPc2, k1gNnPc1, k1gNnPc4, k1gNnPc5	k1gNnSc1
je	k5eAalmlp3nS, k3p3gMnPc4, k3p3gInPc4, k3p3gNnSc4, k3p3gNnPc4, k3p3gFnPc4, k0	k5eAalmlp3nS
pro	k7c4	k7c4
správný	k2eAgMnSc1d1, k2eAgMnSc5d1, k2eAgInSc1d1, k2eAgInSc4d1, k2eAgInSc5d1, ... (+ 18)	k2eAgInSc4d1
růst	k5eAalmlF, k1gInSc1, k1gInSc4	k1gInSc4
důležité	k2eAgMnPc4d1, k2eAgInPc1d1, k2eAgInPc4d1, k2eAgInPc5d1, k2eAgFnSc2d1, k2eAgFnSc3d1, k2eAgFnSc6d1, k2eAgFnPc1d1, k2eAgFnPc4d1, k2eAgFnPc5d1, k2eAgNnSc1d1, k2eAgNnSc4d1, k2eAgNnSc5d1, ... (+ 5)	k2eAgNnSc1d1

Statistický MT

- ▶ pravidlové systémy motivovány lingvistikou
- ▶ SMT inspirován teorií informace a statistikou
- ▶ 50 miliónů stránek denně přeložených pomocí SMT
- ▶ **gisting**: stačí, má-li překlad nějaký užitek, nepotřebujeme přesný význam; nejčastější užití MT na internetu

Schéma SMT



Data pro SMT – (paralelní) korpusy

- ▶ Europarl: kolekce textů Evropského parlamentu
- ▶ OPUS: paralelní texty různého původu
- ▶ Acquis Communautaire: právní dokumenty Evropské unie (20 jazyků)
- ▶ volně dostupné jsou řádově 10 a 100 miliónů slov veliké
- ▶ vícejazyčné stránky (Wikipedie)
- ▶ srovnatelné korpusy (comparable corpora): texty ze stejné domény, ne přímé překlady: New York Times – Le Monde
- ▶ Kapradí – korpus překladů Shakespearových dramát (FI)
- ▶ InterCorp – ručně zarovnané beletr. texty (ČNK, FFUK)

SMT – princip noisy channel

Vyvinut Shannonem (1948) pro potřeby samoopravujících se kódů, pro korekce kódovaných signálů přenášených po zašuměných kanálech na základě informace o původní zprávě a typu chyb vznikajících v kanálu.

Příklad s OCR. Rozpoznávání textu z obrázků je chybové, ale dokážeme odhadnout, co by mohlo být v textu (jazykový model) a jaké chyby často vznikají: záměna l-1-l, rn-m apod.

$$\begin{aligned}e^* &= \arg \max_e p(e|f) \\ &= \arg \max_e \frac{p(e)p(f|e)}{p(f)} \\ &= \arg \max_e p(e)p(f|e).\end{aligned}$$

Jazykové modely

- ▶ LM pomáhají zajistit **plynulý výstup** (správný slovosled)
- ▶ LM pomáhají s **WSD v obecných případech**
- ▶ pokud má slovo více významů, můžeme vybrat nejčastější překlad (*pen* → pero)
- ▶ ve speciálních textech nelze použít, ale
- ▶ LM pomáhají s **WSD pomocí kontextu**
- ▶ $p_{LM}(i \text{ go home}) \geq p_{LM}(i \text{ go house})$

N-gramové modely

- ▶ n-gram je nejdůležitější nástroj ve zpracování řeči a jazyka
- ▶ využití statistického pozorování dat

Generování unigramy

To him swallowed confess hear both. Which. Of save on trail for
are ay device and rote life have Every enter now severally so,
let.

Generování trigramy

Sweet prince, Falstaff shall die. Harry of Monmouth's grave.
This shall forbid it should be branded, if renown made it empty.

Kvalita a srovnání jazykových modelů

Chceme být schopni porovnávat kvalitu různých jazykových modelů (trénovány na různých datech, pomocí jakých n-gramů, jak vyhlazených apod.).

Je možné použít 2 přístupy: vnější (extrinsic) a vnitřní (intrinsic) vyhodnocení.

Dobrý model by měl přiřadit dobrému textu vyšší pravděpodobnost než špatnému textu.

Pokud máme nějaký testovací text, můžeme spočítat pravděpodobnost, jakou mu přiřazuje zkoumaný LM. Lepší LM by mu měl přiřadit vyšší pravděpodobnost.

Vyhlazování jazykových modelů

Problém: pokud není v datech určitý n-gram, který se vyskytne v řetězci w , pro který hledáme pravděpodobnost, bude $p(w) = 0$.

Potřebujeme rozlišovat p i pro *neviděná data*. Musí platit

$$\forall w. p(w) > 0$$

Ještě větší je problém u modelů vyšších řádů.

Snaha o úpravu reálných počtů n-gramů na očekávané počty těchto n-gramů v libovolných datech (jiných korpusech).

Add-one, add-alpha, deleted estimation, Good-Turing vyhlazování

Interpolace

Předchozí metody zacházely se všemi neviděnými n-gramy stejně. Předpokládejme 3-gramy:

nádherná červená řepa

nádherná červená mrkev

I když ani jeden nemáme v trénovacích datech, první 3-gram by měl být pravděpodobnější.

Budeme využívat pravděpodobnosti n-gramů nižších řádů, u kterých máme k dispozici více dat:

červená řepa

červená mrkev

Velké jazykové modely – počet n-gramů

Kolik je různých n-gramů v korpusu?

řád	unikátní	singletony
unigram	86 700	33 447 (38,6 %)
bigram	1 948 935	1 132 844 (58,1 %)
trigram	8 092 798	6 022 286 (74,4 %)
4-gram	15 303 847	13 081 621 (85,5 %)
5-gram	19 882 175	18 324 577 (92,2 %)

Europarl, 30 miliónů tokenů.

Výpočet překladové pravděpodobnosti

Pro výpočet $p(\mathbf{e}, a|\mathbf{f})$ potřebujeme znát hodnotu funkce t pro všechna slova (věty).


K tomu budeme využívat základní zdroj pro SMT: **paralelní korpus** se zarovnanými větami.

Bohužel nemáme zarovnání slov mezi sebou. To je úkol tzv. **word-alignment**.

Ke slovu přichází **expectation-maximization (EM)** algoritmus.

Illustrate EM algorithmu

... la maison ... la maison blue ... la fleur ...



... the house ... the blue house ... the flower ...

... la maison ... la maison bleu ... la fleur ...



... the house ... the blue house ... the flower ...



$$p(\text{la}|\text{the}) = 0.453$$

$$p(\text{le}|\text{the}) = 0.334$$

$$p(\text{maison}|\text{house}) = 0.876$$

$$p(\text{bleu}|\text{blue}) = 0.563$$

...


Problémy se zarovnáním slov

	john	biss	ins	grass
john	■			
kicked		■	■	■
the		■	■	■
bucket		■	■	■

	john	wohnt	hier	nicht
john	■			
does		■		■
not				■
live		■		
here			■	

Frázový překladový model

State-of-the-art statistického strojového překladu. Nepřekládají se pouze samostatná slova. Když to jde, tak i celé sekvence slov.



Fráze nejsou lingvisticky motivované, pouze statisticky. Německé *am* se zřídka překládá jedním slovem *with*. Statistický významný kontext *spass am* pomáhá správnému překladu. Klasické fráze by se dělily jinak: (*fun (with (the game))*).

Výhody PBTM

- ▶ často překládáme $n : m$ slov, slovo je tedy nevhodný atomický prvek
- ▶ překlad skupin slov pomáhá řešit překladové víceznačnosti
- ▶ můžeme se učit překládat delší a delší fráze
- ▶ jednodušší model: neuvažujeme fertilitu, NULL token atd.

Automatické hodnocení překladu

- ▶ výhody: rychlost, cena; nevýhody: měříme opravdu kvalitu?
- ▶ gold standard: ručně připravené referenční překlady
- ▶ kandidát c se srovnává s n referenčními překlady r_j
- ▶ různé přístupy: n-gramová shoda mezi c a r_j , editační vzdálenost, . . .

Pokrytí a přesnost na slovech

Nejjednodušší způsob automatického hodnocení

SYSTEM A: Israeli officials responsibility of airport safety

REFERENCE: Israeli officials are responsible for airport security

- ▶ přesnost

$$\frac{\textit{correct}}{\textit{output-length}} = \frac{3}{6} = 50\%$$

- ▶ pokrytí

$$\frac{\textit{correct}}{\textit{reference-length}} = \frac{3}{7} = 43\%$$

- ▶ f-score

$$\frac{\textit{precision} \times \textit{recall}}{(\textit{precision} + \textit{recall})/2} = \frac{.5 \times .43}{(.5 + .43)/2} = 46\%$$

Pokrytí a přesnost – nedostatky



metrika	system A	system B
přesnost	50%	100%
pokrytí	43%	100%
f-score	46%	100%

Nepostihuje se nesprávný slovosled.

BLEU

- ▶ nejznámější (standard), nejpoužívanější, nejstarší (2001)
- ▶ IBM, Papineni
- ▶ n-gramová shoda mezi referencí a kandidáty
- ▶ počítá se přesnost pro 1 až 4-gramy
- ▶ extra postih za krátkost (**brevity penalty**)

$$\text{BLEU} = \min \left(1, \frac{\text{output-length}}{\text{reference-length}} \right) \left(\prod_{i=1}^4 \text{precision}_i \right)^{\frac{1}{4}}$$

BLEU – příklad

SYSTEM A: Israeli officials responsibility of airport safety
2-GRAM MATCH 1-GRAM MATCH

REFERENCE: Israeli officials are responsible for airport security

SYSTEM B: airport security Israeli officials are responsible
2-GRAM MATCH 4-GRAM MATCH


metrika	system A	system B
přesnost (1gram)	3/6	6/6
přesnost (2gram)	1/5	4/5
přesnost (3gram)	0/4	2/4
přesnost (4gram)	0/3	1/3
brevity penalty	6/7	6/7
BLEU	0 %	52 %

Další metriky

- ▶ NIST, NEVA
- ▶ WAFT
 - ▶ Word Accuracy for Translation
 - ▶ editační vzdálenost mezi c a r
 - ▶ $WAFT = 1 - \frac{d+s+i}{\max(l_r, l_c)}$
- ▶ TER
 - ▶ Translation Edit Rate
 - ▶ nejmenší počet kroků (smazání, přidání, prohození, změna)
 - ▶ $TER = \frac{\text{počet editací}}{\text{prům. počet ref. slov}}$
- ▶ METEOR
 - ▶ uvažuje synonyma (WordNet) a
 - ▶ morfologické varianty slov

Hodnocení hodnoticích metrik

Korelace automatického hodnocení s manuálním.



Hodnocení překladu podle jazykových párů

	Target language																					
	EN	BG	DE	CS	DA	EL	ES	ET	FI	FR	HU	IT	LT	LV	MT	NL	PL	PT	RO	SK	SL	SV
EN		40.5	46.8	52.6	50.0	41.0	35.2	34.8	38.6	50.1	37.2	30.4	39.6	43.4	39.8	52.3	49.2	55.0	49.0	44.7	50.7	52.0
BG	61.3		38.7	39.4	39.6	34.5	46.9	25.5	26.7	42.4	22.0	43.5	29.3	29.1	25.9	44.9	35.1	45.9	36.8	34.1	34.1	39.9
DE	53.6	26.3		35.4	43.1	32.8	47.1	26.7	29.5	39.4	27.6	42.7	27.6	30.3	19.8	50.2	30.2	44.1	30.7	29.4	31.4	41.2
CS	38.4	32.0	42.6		43.6	34.6	48.9	30.7	30.5	41.6	27.4	44.3	34.5	35.8	26.3	46.5	39.2	45.7	36.5	43.6	41.3	42.9
DA	37.6	28.7	44.1	35.7		34.3	47.5	27.8	31.6	41.3	24.2	43.8	29.7	32.9	21.1	48.5	34.3	45.4	33.9	33.0	36.2	47.2
EL	59.5	32.4	43.1	37.7	44.5		54.0	26.5	29.0	48.3	23.7	49.6	29.0	32.6	23.8	48.9	34.2	52.5	37.2	33.1	36.3	43.3
ES	60.0	31.1	42.7	37.5	44.4	39.4		25.4	28.5	51.3	24.0	51.7	26.8	30.5	24.6	48.8	35.9	57.3	38.1	31.7	33.9	43.7
ET	52.0	24.6	37.3	35.2	37.8	28.2	40.4		37.7	33.4	30.9	37.0	35.0	36.9	20.5	41.3	32.0	37.8	28.0	30.6	32.9	37.3
FI	49.3	23.2	36.0	32.0	37.9	27.2	39.7	34.9		29.5	27.2	36.6	30.5	32.5	19.4	40.6	28.8	37.5	26.5	27.3	28.2	37.6
FR	64.0	34.5	45.1	39.5	47.4	42.8	60.9	26.7	30.0		25.5	56.1	28.3	31.9	25.3	51.6	35.7	61.0	43.8	33.1	35.6	45.8
HU	48.0	24.7	34.3	30.0	33.0	25.5	34.1	29.6	29.4	30.7		33.5	29.6	31.9	18.1	36.1	29.8	34.2	25.7	25.6	28.2	30.5
IT	61.0	32.1	44.3	38.9	45.8	40.6	26.9	25.0	29.7	52.7	24.2		29.4	32.6	24.6	50.5	35.2	56.5	39.3	32.5	34.7	44.3
LT	51.8	27.6	33.9	37.0	36.8	26.5	21.1	34.2	32.0	34.4	28.5	36.8		40.1	22.2	38.1	31.6	31.6	29.3	31.8	35.3	35.3
LV	54.0	29.1	35.0	37.8	38.5	29.7	25.3	34.2	32.4	35.6	29.3	38.9	38.4		23.3	41.5	34.4	39.6	31.0	33.3	37.1	38.0
MT	72.1	32.2	37.2	37.9	38.9	33.7	48.7	26.9	25.8	42.4	22.4	43.7	30.2	33.2		44.0	37.1	45.9	38.9	35.8	40.0	41.6
NL	56.9	29.3	46.9	37.0	45.4	35.3	49.7	27.5	29.8	43.4	25.3	44.5	28.6	31.7	22.0		32.0	47.7	33.0	30.1	34.6	43.6
PL	60.8	31.5	40.2	44.2	42.1	34.2	46.2	29.2	29.0	40.0	24.5	43.2	33.2	35.6	27.9	44.8		44.1	38.2	38.2	39.8	42.1
PT	60.7	31.4	42.9	38.4	42.8	40.2	60.7	26.4	29.2	53.2	23.8	52.8	28.0	31.5	24.8	49.3	34.5		39.4	32.1	34.4	43.9
RO	60.8	33.1	38.5	37.8	40.3	35.6	30.4	24.8	26.2	46.5	25.0	44.8	28.4	29.9	28.7	43.0	35.8	48.5		31.5	35.1	39.4
SK	60.8	32.6	39.4	48.1	41.0	33.3	46.2	29.8	28.4	39.4	27.4	41.8	33.8	36.7	28.5	44.4	39.0	43.3	35.3		42.6	41.8
SL	61.0	33.1	37.9	43.5	42.6	34.0	47.0	31.1	28.8	38.2	25.7	42.3	34.6	37.3	30.0	45.9	38.2	44.1	35.8	38.9		42.7
SV	58.5	26.9	41.0	35.6	46.6	33.3	46.6	27.4	30.9	38.9	22.7	42.0	28.2	31.0	23.7	45.6	32.2	44.2	32.7	31.3	33.5	