

NEIRONU MAŠĪNTULKOŠANA MAZAJĀM VALODĀM – ATSKATS UZ 2018. GADU

Mārcis Pinnis



21.02.2019.

NEIRONU MAŠĪNTULKOŠANA **Tildē** ~~MAZAJĀM~~
~~VALODĀM~~ – ATSKATS UZ 2018. GADU



Mārcis Pinnis

21.02.2019.


Saturs

- Metodes
- Dalība Mašīntulkošanas konferences sacensībās
- Risināmās problēmas

Metodes




MT darbplūsmas (Tilde MT)




SMT	Kopš SMT ieviešanas
NMT	Kopš NMT ieviešanas
SMT NMT	Būtiska atšķirība/būtiski labojumi starp SMT un NMT
T	Nepieciešams tulkošanai
A	Nepieciešams apmācībai

MT darbplūsuma (Tilde MT)



MT darbplūsmas (Tilde MT) ar attulkošanu




Datu tīrīšana

Datu kvalitāte (tīrība) ir svarīga situācijās, kad ir vēlme iegūt lietojamu (konkurētspējīgu) rezultātu.

Filtru uzdevums - atrast un izdzēst:

- neparalēlus datus;
- datus nepareizās valodās;
- sabojātus datus.

Piemērs no vācu-angļu datu filtrēšanas uzdevuma WMT 2018




Neironu tīklu arhitektūras

2017. gadā - MLSTM
(multiplikatīvās garās
īstermiņa atmiņas
rekurentie neironu tīkli)

2018. gadā - Transformer
(jeb «pašuzmanības»
neironu tīkli.


*Piemērs no Tildes angļu-
igauņu WMT 2018
eksperimentiem*



NMT pielāgošana jomai

Attulkošana - efektīvākā
NMT sistēmu
pielāgošanas metode,
situācijās, kad jomas
paralēlo datu nav.

*Piemērs no Tildes angļu-
igauņu WMT 2018
eksperimentiem*



Kur valodu specifika?

2017. gadā mēs pētījām:


- morfoloģiski motivētu vārdu dalīšanu
- faktorētu datu izmantošanu

Ieguvumi - ~+1 BLEU

Tīrāku datu un attulkošanas (labākas pielāgošanas) ieguvums ir lielāks (≥ 5 BLEU)

Jaunāku modeļu ieguvums lielāks (≥ 2 BLEU)

Vispirms jāatrod labākās no valodām neatkarīgās metodes...



TILDE

Dalība Mašīntulkošanas konferences sacensībās



Sacensības

Uzdevums: izmantojot organizatoru sagatavotus datus (*ierobežotu datu scenārijs*) vai citus datus (*neierobežotu datu scenārijs*), izstrādāt mašīntulkošanas sistēmu ziņu tulkošanai, ar kuru ir jāpārtulko novērtēšanas datu kopa; pārtulkotā datu kopa ir jāiesniedz vērtēšanai.

Dalībnieki: mašīntulkošanas jomas pētnieki un izstrādātāji no pētniecības centriem un uzņēmumiem no visas pasaules

Sacensības

Vērtēšana: Tulkojumi tiek vērtēti, izmantojot:

- 1) *automātiskas vērtēšanas metodes,*
- 2) *manuālas vērtēšanas metodes, iesaistot cilvēkus* (tulkotājus, redaktorus, valodu ekspertus, kā arī «pūli»).

Cilvēkvērtējums tiek uzskatīts par uzticamāku vērtējumu!


The screenshot shows the WMT 2018 Appraise interface. At the top, there is a navigation bar with 'Appraise' and 'Dashboard' links, and a user identifier 'engest5011'. Below this, a status bar indicates '0/10 blocks, 10 items left in block' and 'WMT18RefDA #611:Segment #1891'. The main content area displays two text blocks: 'Source text' and 'Candidate translation'. The source text is in Estonian: 'Ilmselt ikka selleks, et rikkamad kliendid ei peaks end lihtsurelikena tundma, kes mingite odavate kottidega ringi promeneerivad.' The candidate translation is also in Estonian: 'Pole kahtlust, et jõukamad kliendid ei pea tundma, et nad kogu telefoni esipaneeli, kaotatud on odava kotiga ringi liiguvad.' Below the translations is a slider for evaluating the accuracy of the candidate translation. The slider ranges from 'Not at all (left)' to 'Perfectly (right)'. The current position of the slider is approximately 25% towards 'Perfectly'. At the bottom, there are 'Reset' and 'Submit' buttons.

Attēls no WMT 2018 mašintulkošanas sistēmu vērtēšanas sistēmas (<http://wmt18.appraise.cf>)



Sacensības

Mēs sacensībās piedalījāties:

- 2017. gadā, izstrādājot **angļu-latviešu** mašīntulkošanas sistēmas ziņu jomai
- 2018. gadā, izstrādājot **angļu-igauņu** mašīntulkošanas sistēmas ziņu jomai





Vislabākās angļu↔latviešu neironu mašintulkošanas sistēmas WMT 2017 sacensībās



Mašintulkošanas sistēmas apmācītas ar tā laika spējīgākajiem neironu tīklu modeļiem mašintulkošanā - uzmanībās balsītiem rekurentiem neironu tīkliem ar multiplikatīvās garās īstermiņa atmiņas šūnām rekurentajos slāņos.

Vislabākās angļu↔igauņu neironu mašintulkošanas sistēmas WMT 2018 sacensībās



Mašintulkošanas sistēmas apmācītas, izmantojot 2018. gada spējīgākos modeļus - Transformer modeļus.

(Dažas) problēmas

**...jeb aktuālas tēmas šogad
un tuvākā nākotnē**



Retu vārdu/frāžu pareizāka tulkošana: **nosauktās entitātes**

Latviešu	Angļu
Google NMT (2019. gada 20. februāris)	
Šuplinska solīja, ka algas [...]	Šuplinska promised to pay [...]
[...] priekšsēdētāja Inga Vanaga.	[...] President Inga Vanaga.
Rīgas domes priekšsēdētājs Nils Ušakovs (S) [...]	Riga City Council Chairman Nils Ushakov (S) [...]
Ansis Ansbergs (LA) interesējās,	Ansis Ansberg (LA) was interested in
[...] izpildītājs Emīls Jakrins atbildēja [...]	[...] Emperor Yakrins answered [...]
Tilde NMT (WMT 2018)	
Šuplinska solīja, ka algas [...]	Shuplinska promised that wages [...]
[...] priekšsēdētāja Inga Vanaga.	[...] Chairman Inga Vanaga.
Rīgas domes priekšsēdētājs Nils Ušakovs (S) [...]	Riga City Council Chairman Nils Ushakov (S) [...]
Ansis Ansbergs (LA) interesējās,	Ansis Ansbergs (LA) was interested,
[...] izpildītājs Emīls Jakrins atbildēja [...]	[...] performer Emile Yakrin replied [...]



Retu vārdu/frāžu pareizāka tulkošana: **terminoloģija**


Latviešu	Angļu
Google NMT (2019. gada 20. februāris)	
The corncrake , corn crane or landrail is a bird in the rail family .	Kukurūzas , kukurūzas krējums vai krastmala ir putns dzelzceļa ģimenē .
Tilde NMT (WMT 2018)	
The corncrake , corn crane or landrail is a bird in the rail family .	Kukurūzas krakšķis , kukurūzas krakšķis vai zemūdene ir putnu dzimtas putns .

corncrake, corn crane, landrail
bird
rail family

grieze
putns
dumbrvistiņu dzimta



Pielāgošana jomai - pašpielāgojošas NMT sistēmas



Sākotnējie rezultāti liecina, ka plašas jomas sistēmām, ieviešot pašpielāgojošas NMT sistēmas iespējas, tulkojumu kvalitāti var palielināt **no +2** (ja līdzīgu datu tulkošanas atmiņā nav daudz) **līdz pat +50** (ja līdzīgi jomas dati ir tulkošanas atmiņā sastopami) **BLEU**

Kā gūt labumu no (daudz) datiem?

Tulkošanas virziens	Datu kopapjoms (teikumu pāri milj.)	BLEU	Tiešā vērtējuma vidējais svērtais rezultāts
Angļu-igauņu (WMT 2018)	3,65	23,54	61,6
	63,07	24,35	64,9
Igauņu-angļu (WMT 2018)	3,73	29,46	69,9
	67,91	30,94	73,3
Angļu-latviešu (WMT 2017)	6,19	20,18	51,1
	46,04	20,71	54,4
Latviešu-angļu (WMT 2017)	6,19	20,81	71,0
	45,71	23,02	76,2



Pašpielāgojošas NMT sistēmas?

Paldies!

