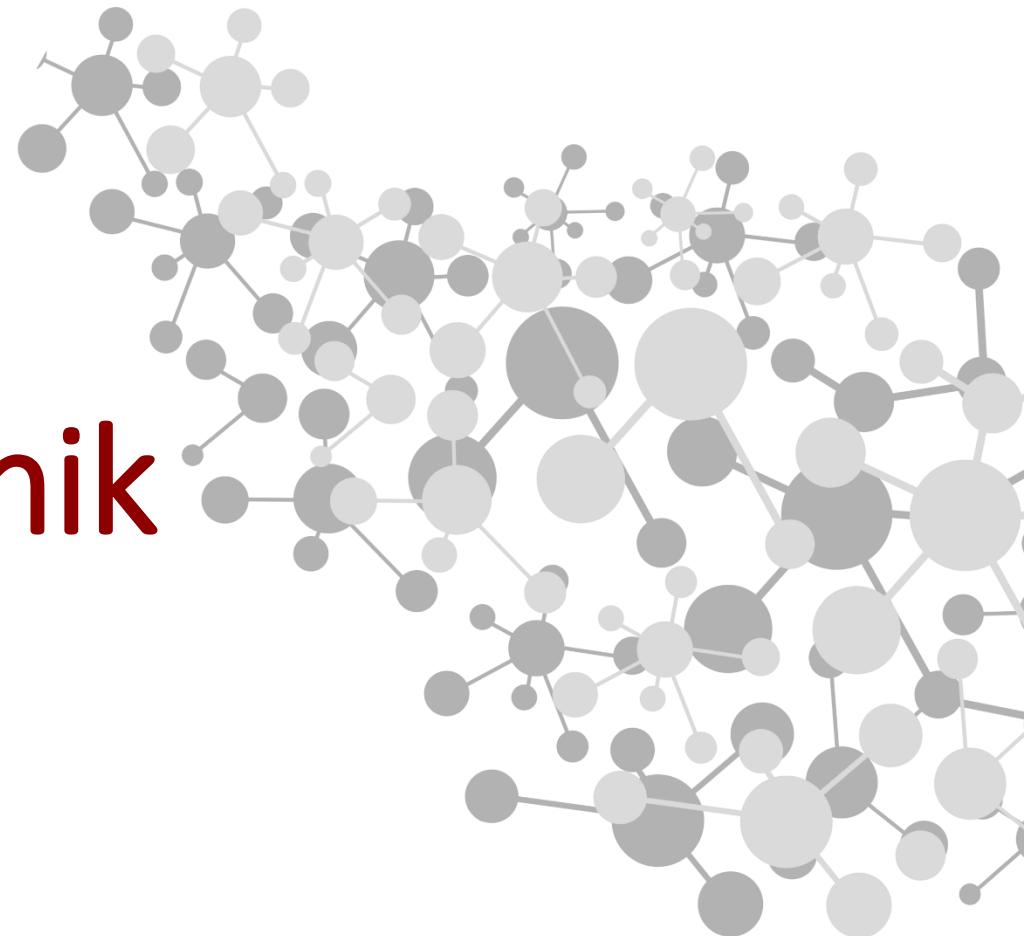




Nevronski prevajalnik Ang <→> Slo

Matjaž Rihtar
AI Lab, Institut Jožef Stefan

Ljubljana, 24. april 2018





Nevronski prevajalnik: Namen

- Do sedaj: na osnovi pravil in statističnih metod (Moses)
- Z nevronskimi prevajalniki dosežemo boljše rezultate
 - ‘Google translate’ preklopil novembra 2016
- Pogoji:
 - velik korpus
 - dobra strojna oprema (obvezno grafične kartice z veliko pomnilnika)



Nevronski prevajalnik: Korpusi

- Angleško-slovenski korpusi na sistemu Opus (prost dostop):
 - OpenSubtitles2018 (21.1 M stavkov, 172.9 M pojavnic)
 - OpenSubtitles2016 (11.8 M stavkov, 144.2 M pojavnic)
 - DGT (3.2 M stavkov, 71.7 M pojavnic)
 - Europarl (0.6 M stavkov, 16.9 M pojavnic)
 - EMEA (1.1 M stavkov, 11.7 M pojavnic)
 - ~~EUbookshop (0.4 M stavkov, 17.1 M pojavnic)~~



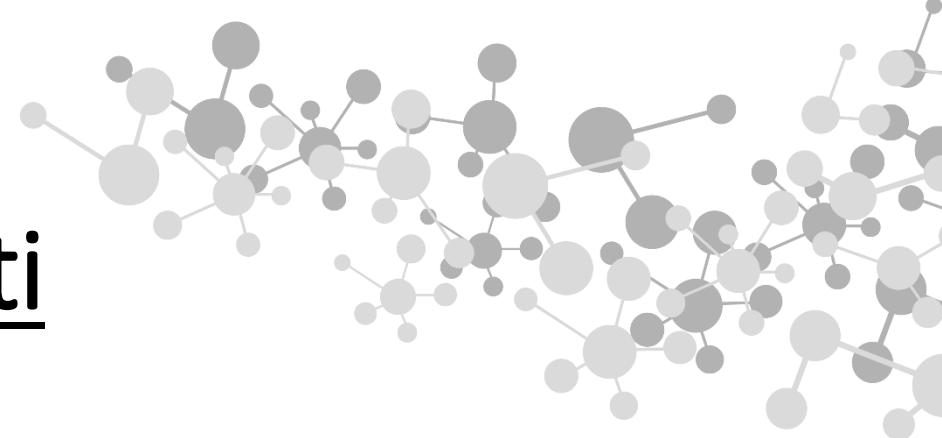
Nevronski prevajalnik: Korpusi

- Skupaj:
 - 37.8 M stavkov, 417.4 M pojavnic
 - Še vedno premalo!
 - Primer – angleško-nemški korpus na sistemu Opus:
 - 95.4 M stavkov, 1354.4 M pojavnic



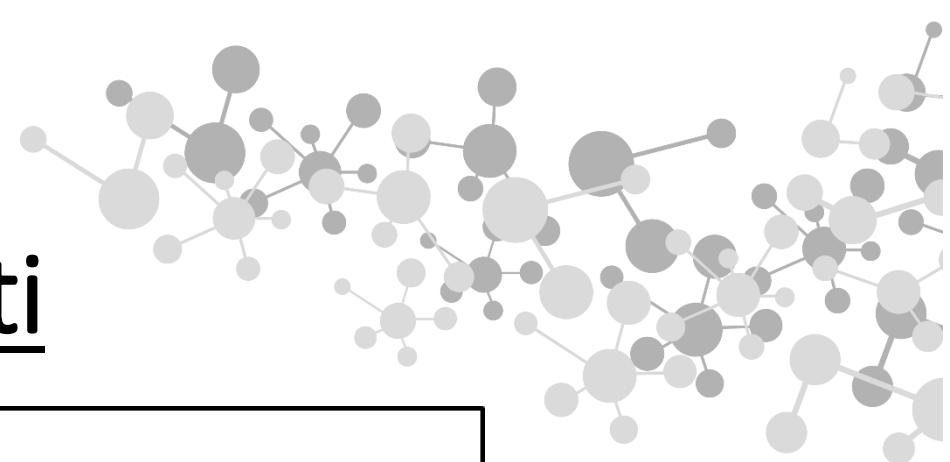
Nevronski prevajalnik: Orodja

- Nematus (python, Theano)
 - Univerza v Edinburghu
- Marian (C++)
 - Univerza Adam Mickiewicz, Poznań
- Strojna oprema:
 - Unix, 2x Xeon, 128 GB RAM, 2x NVIDIA GeForce GTX 1080 Ti (11 GB RAM)

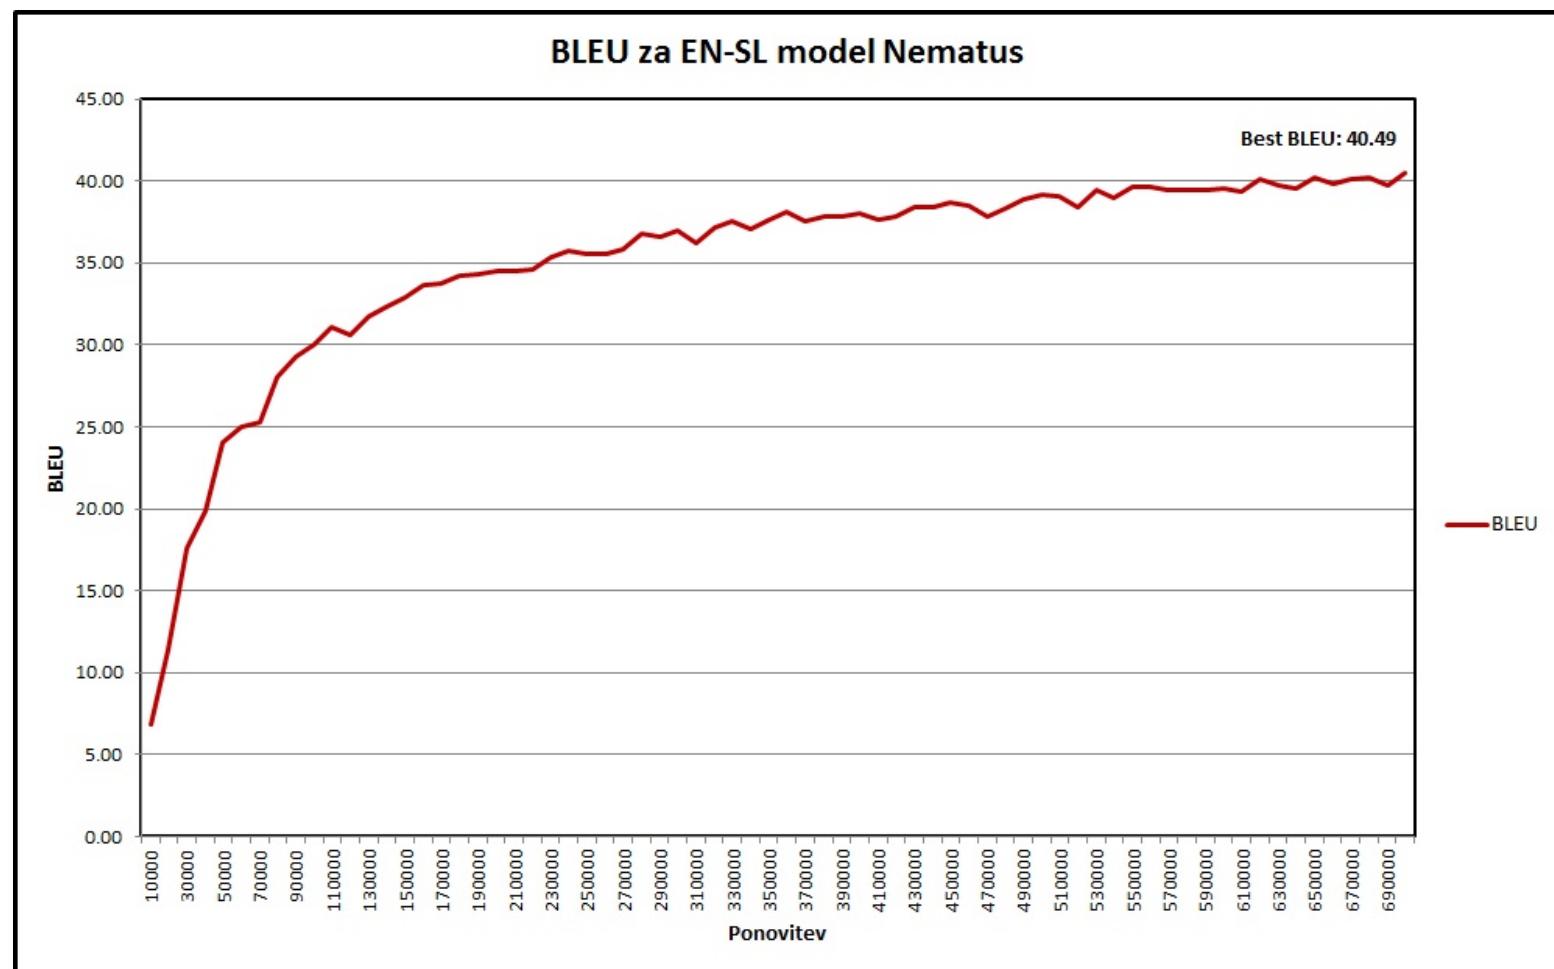


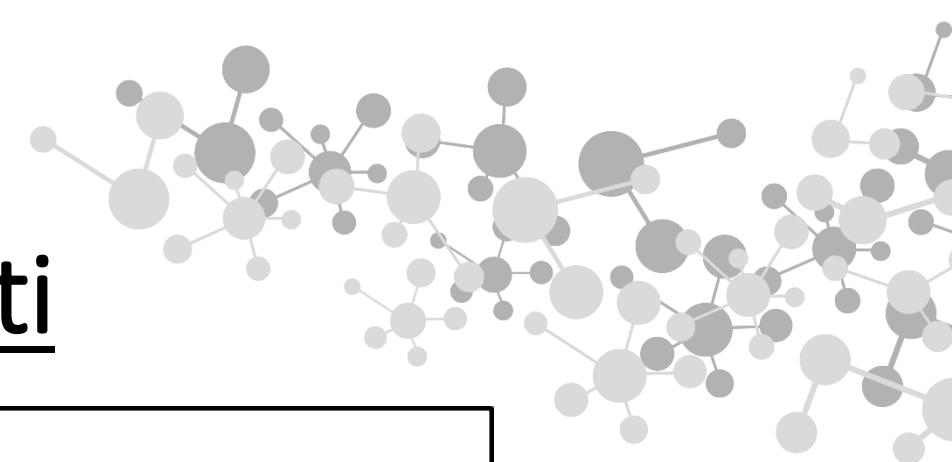
Nevronski prevajalnik: Rezultati

- Ustvarjanje modelov
 - 10 dni na eni grafični kartici za model
- Izboljšave modelov
 - Dodatni visoko-kvalitetni korpusi (lahko manjši)
 - Domenska specializacija

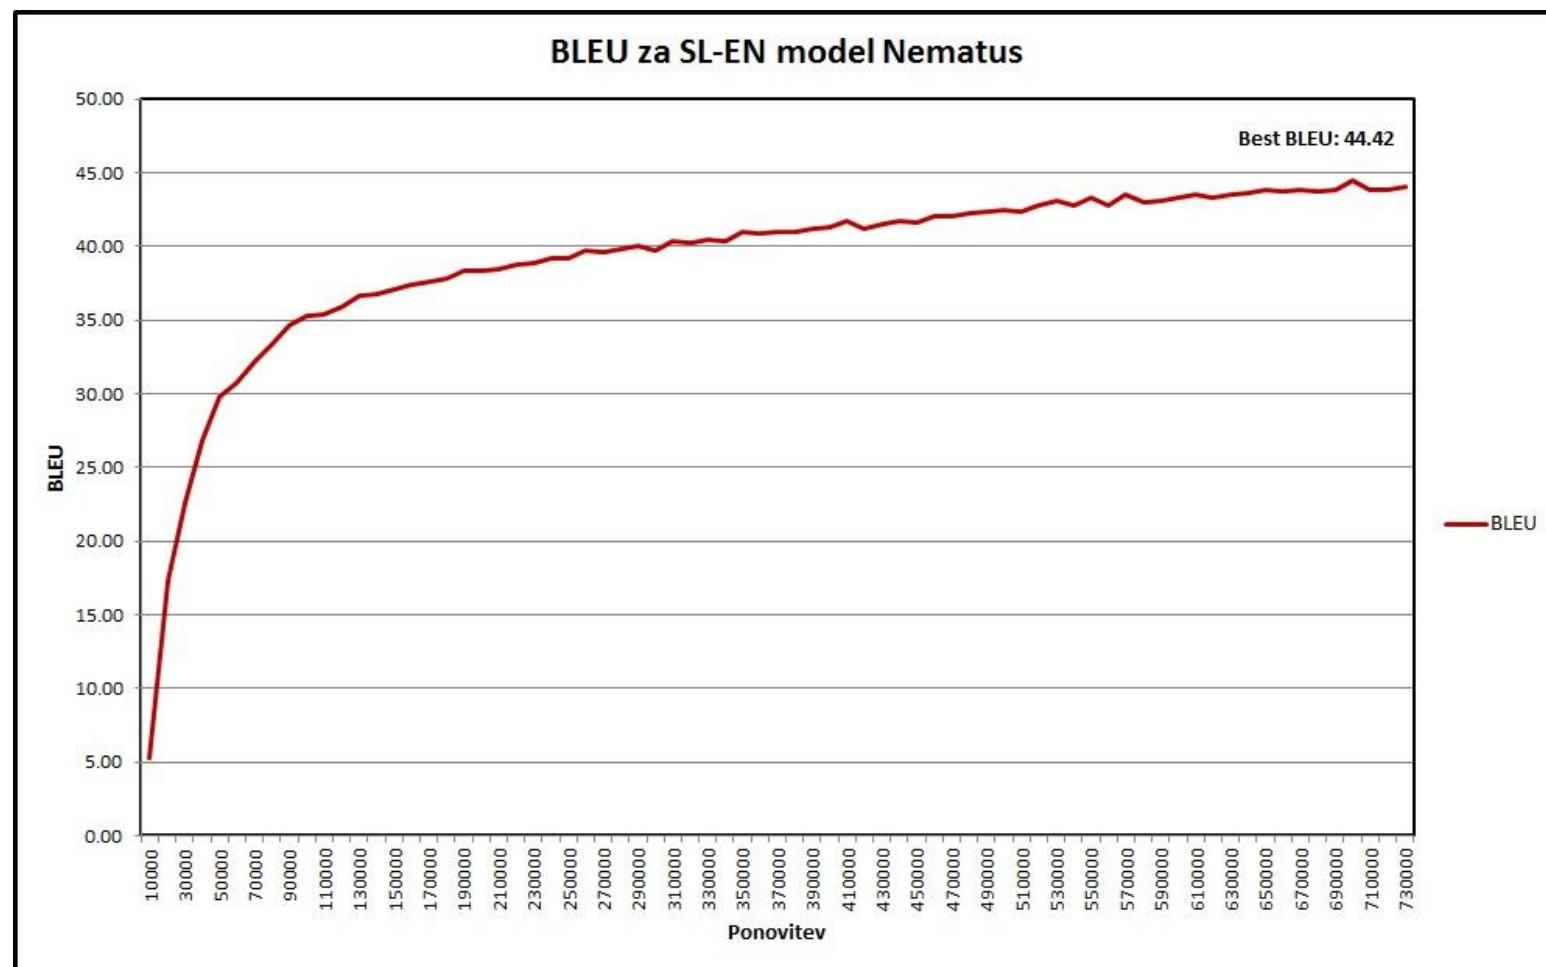


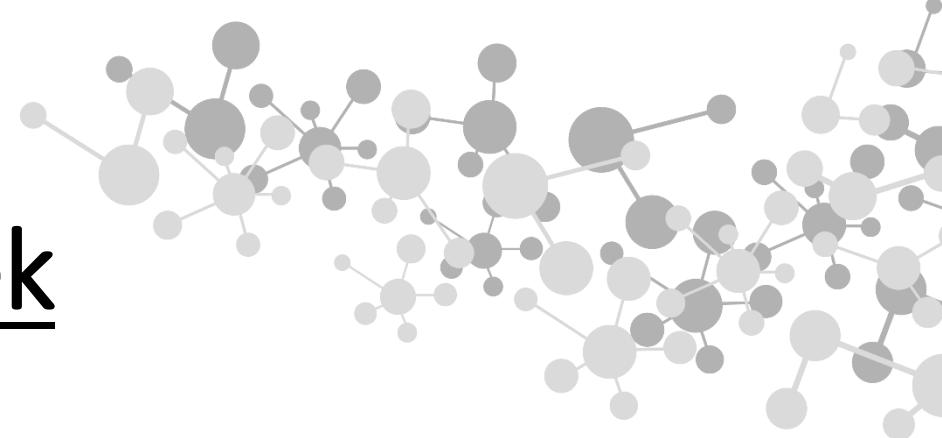
Nevronski prevajalnik: Rezultati





Nevronski prevajalnik: Rezultati





Nevronski prevajalnik: Povzetek

- Dober začetek!
- Potrebujemo več visoko-kvalitetnih korpusov