


# Latviešu valodas sapratne un tekstrate cilvēka-datora komunikācijas modelēšanā

Inguna Skadiņa




**FLPP**

FUNDAMENTĀLIE UN  
LIETIŠĶIE PĒTĪJUMU  
PROJEKTI



Mākslīgā intelekta laboratorija  
LU MII

# Prāts pret mašīnu



Tjūringa tests (1950)

# Prāts pret mašīnu



B. Kristians. Prāts pret mašīnu, Rīgas Laiks

<https://www.rigaslaiks.lv/zurnals/prats-pret-masinu-1162>

# Prāts pret mašīnu

Braitona, Anglija, 2009. gada septembris. Es pamostos viesnīcas numurā astoņtūkstoš kilometrus no savām mājām Sietlā. Pēc brokastīm izeju sāļajā āra gaisā un dodos pastaigāt gar jūras krastu. Es esmu zemē, kura izgudrojusi manu valodu, taču izrādās, ka man nav saprotama liela daļa ceļā ieraudzīto uzrakstu. *LET AGREED*, acīs krītošiem, lieliem burtiem vēsta viens no tiem. Man tas neko neizsaka.

Es apstājos un brīdi truli veros jūrā, domās vēl un vēlreiz analizējot mīklaino paziņojumu. Parasti mani intrigē šādas lingvistiskas dīvainības un kultūru atšķirības; šodien tās drīzāk gan vieš manī bažas. Nepilnu divu stundu laikā man vajadzēs apsēsties pie datora un iesaistīties virknē piecminūšu virtuālo sarunu ar vairākiem man pilnīgi nepazīstamiem cilvēkiem. Mani neredzami sarunu biedri būs psihologs, lingvists, datorzinātnieks un populāra tehnoloģijas jautājumiem veltīta britu televīzijas raidījuma vadītājs. Visi kopā šie cilvēki veidos tiesnešu grupu, kas vērtēs manu spēju tikt galā ar vienu no dīvainākajiem uzdevumiem, kādu savā mūžā esmu saņēmis.

Man vajadzēs viņus pārliecināt, ka es esmu cilvēks.

# Virtuālie sarunu biedri ir realitātē

- Virtuāli sarunu biedri un «gudrās» iekārtas - Apple Siri, Microsoft Cortana, Google Assistant, Amazon Echo, Google Home,
- Virtuālie palīgi:
  - aviolīnijām
  - bankām
  - apdrošināšanai
  - utt.



✈ Thu May 25 ✈ Thu Jun 01

14:05 RIX 13:05 VCE

1 stops 1 stops

23h 15m 23h 20m

HSBC  Virtual Assistant

☰ 3:25<sup>+1</sup> RIX >  ...



Frequently Asked Questions

Type your question here

Send

92 characters remaining

You:

what are the documents needed to open an account


# Daži piemēri Latvijā




**TELE2** leva no Tele2  
77 people like this  
Rekrutētājs

Sveiki! Prieks Tevi šeit redzēt. Es esmu Tele2 karjeras asistente – robots leva 😊


11.02 Vai vēlies uzzināt par darba iespējām Tele2? Spied uz atbildi zemāk 🗨️



# Rīki un platformas



**Microsoft Bot Framework**



**ManyChat**



## **Amazon Lex**

Conversational interfaces for your applications powered by the same deep learning technologies as Alexa

# Virtuālie sarunu biedri


## Chit-Chat



## Task-Oriented



# Gartner Hype Cycle for Emerging Technologies, 2018



As of August 2018


Plateau will be reached:

- less than 2 years
- 2 to 5 years
- 5 to 10 years
- ▲ more than 10 years
- ⊗ obsolete before plateau

© 2018 Gartner, Inc.

# Bet


- Vai pašreizējie risinājumi sarunājas «mazajās» valodās?
- Vai dators saprot valodu?
- Kāds ir labākais risinājums, lai «saprastu» izteikumu un jēgpilni atbildētu?
  - Mašīnmācīšanās?
  - Zinību bāzes?
  - Hibrīdi risinājumi?



**FLPP**


FUNDAMENTĀLIE UN  
LIETIŠĀIE PĒTĪJUMU  
PROJEKTI

# Dialogsistēmu arhitektūra



# Mūsu piedāvājums: valodas sapratne

Radīt metodes un rīkus semantiskai parsēšanai, kas «mācās» no manuāli un automātiski marķētiem datiem (UD, Framenet, PropBank un AMR)



*Full Stack of Language Resources for Natural Language Understanding and Generation in Latvian*



# Iestrādes: NLP-pipe

Šajā mācību gadā Aizkraukles novada ģimnāzijas 8. klasē mācījās Marisa Butnere no Amerikas.

Go

tokenizer ×

morpho ×

parser ×

ner ×



NER



CONLL




JSON

INDEX	FORM	LEMMA	UPOSTAG	XPOSTAG	FEATS	HEAD	DEPREL
#text=Šajā mācību gadā Aizkraukles novada ģimnāzijas 8. klasē mācījās Marisa Butnere no Amerikas .							
1	Šajā	šis	DET	pd3msln	Skaitlis=Vienska	3	det
2	mācību	mācība	NOUN	ncfpg4	Skaitlis=Daudzsl	3	nmod
3	gadā	gads	NOUN	ncmsl1	Skaitlis=Vienska	9	obl
4	Aizkraukles	Aizkraukle	PROPN	npfsg5	Skaitlis=Vienska	5	nmod
5	novada	novads	NOUN	ncmsg1	Skaitlis=Vienska	6	nmod
6	ģimnāzijas	ģimnāzija	NOUN	ncfsg4	Skaitlis=Vienska	8	nmod
7	8.	8.	ADJ	xo	Reziduāļa_tips=l	8	amod
8	klasē	klase	NOUN	ncfsl5	Skaitlis=Vienska	9	obl
9	mācījās	mācīties	VERB	vmyis_330an	Laiks=Pagātnelk	0	root
10	Marisa	Marisa	PROPN	npfsn_	Skaitlis=Vienska	9	nsubj
11	Butnere	Butnere	PROPN	ncfsn5	Skaitlis=Vienska	10	flat:name
12	no	no	ADP	spsg	Skaitlis=Vienska	13	case
13	Amerikas	Amerika	PROPN	npfsg4	Skaitlis=Vienska	10	nmod
14	.	.	PUNCT	zs	Galotnes_nr=209	9	punct

Šajā mācību gadā Aizkraukles novada ģimnāzijas organization 8. klasē mācījās Marisa Butnere person no Amerikas GPE .

# Mūsu piedāvājums: tekstrade

Plūstoša un jēgpilna tekstrade no mašīnlasāmas nozīmes reprezentācijas, apvienojot datus balstītu un gramatikā balstītu pieeju



*Full Stack of Language Resources for Natural Language Understanding and Generation in Latvian*


# Mūsu piedāvājums: tekstrade

- Abstraktās sintakses izveide GF
- Konkrētās sintakses izveide jomas lietojumam latviešu un angļu valodai

*“20080500 the International Atomic Energy Agency stated that Iran possessed 3500 centrifuges in operations.”*



```
(s / state-01
:ARG0 (o / organization
:wiki "International Atomic Energy Agency"
:name (n / name
:op1 "International" :op2 "Atomic" :op3 "Energy" :op4 "Agency"))
:ARG1 (p / possess-01
:ARG0 (c / country
:wiki "Iran"
:name (n2 / name :op1 "Iran"))
:ARG1 (c2 / centrifuge
:quant 3500
:ARG1-of (o2 / operate-01)))
:time (d / date-entity :year 2008 :month 5))
```



*“International Atomic Energy Agency states in May 2008 that Iran possesses 3,500 centrifuges that are operated.”*

# The Second Conversation Intelligence Challenge (ConvAI2)

<http://convai.io/>

## Human Evaluation Leaderboard

Rank	Creator	Rating	Persona detect
1 🍌👉	Lost in Conversation <a href="#">[code]</a>	3.11👉	0.9
2 🍌🍎🍎🍎	😊 (Hugging Face)	2.68	0.98
3 🍌	Little Baby(AI/小奶娃)	2.44	0.79
4 🍌	Mohd Shadab Alam	2.33	0.93
5 🍌	Happy Minions	1.92	0.46
6 🍌	ADAPT Centre	1.6	0.93
<a href="#">KV Profile Memory</a>	ParlAI team	2.44	0.76
Human	MTurk	3.48	0.96

## Automatic Evaluation Leaderboard (hidden test set)

Rank	Creator	PPL	Hits@1	F1
1 🍌	😊 (Hugging Face)	16.28🍎	80.7🍎	19.5🍎
2 🍌	ADAPT Centre	31.4	-	18.39
3 🍌	Happy Minions	29.01	-	16.01
4 🍌	High Five	-	65.9	-
5 🍌	Mohd Shadab Alam	29.94	13.8	16.91

# DSTC7

Dialog System Technology Challenges

*Honolulu, Hawaii, USA, January 27, 2019*



## DSTC8

---

### SUBMITTED TRACK PROPOSALS

- [End-to-end Task Completion Dialog Challenge](#) - Microsoft Research & Tsinghua University
- [Multi-Domain Human-to-Human Dialog Understanding, a machine reading approach](#) - Naver Labs Europe & Adobe Research
- [Dialog State Tracking for Conversational Image Editing](#) - Adobe Research
- [NOESIS II: Predicting Responses, Identifying Success, and Managing Complexity in Task-Oriented Dialogue](#) IBM & University of Michigan
- [Audio Visual Scene-Aware Dialog Track](#) - MERL & CMU
- [Scalable Schema-Guided Dialogue State Tracking](#) - Google

# SQuAD2.0

Stanford Question Answering Dataset (SQuAD) is a reading comprehension dataset, consisting of questions posed by crowdworkers on a set of Wikipedia articles, where the answer to every question is a segment of text, or *span*, from the corresponding reading passage, or the question might be unanswerable.

Rank	Model	EM	F1
	Human Performance Stanford University (Rajpurkar & Jia et al. '18)	86.831	89.452
1 Jan 15, 2019	BERT + MMFT + ADA (ensemble) Microsoft Research Asia	85.082	87.615
2 Jan 10, 2019	BERT + Synthetic Self-Training (ensemble) Google AI Language <a href="https://github.com/google-research/bert">https://github.com/google-research/bert</a>	84.292	86.967
3 Dec 13, 2018	BERT finetune baseline (ensemble) Anonymous	83.536	86.096
4 Dec 16, 2018	Lunet + Verifier + BERT (ensemble) Layer 6 AI NLP Team	83.469	86.043
4 Dec 21, 2018	PAML+BERT (ensemble model) PINGAN GammaLab	83.457	86.122
5 Jan 10, 2019	BERT + Synthetic Self-Training (single model) Google AI Language <a href="https://github.com/google-research/bert">https://github.com/google-research/bert</a>	82.972	85.810

<https://rajpurkar.github.io/SQuAD-explorer/>

# ELMO: Deep contextualized word representations

ELMo is a deep contextualized word representation that models both

(1) complex characteristics of word use (e.g., syntax and semantics)

and

(2) how these uses vary across linguistic contexts (i.e., to model polysemy).

ELMo representations are *Contextual*: The representation for

Task	Previous SOTA		Our baseline	ELMo + Baseline	Increase (Absolute/Relative)
SQuAD	SAN	84.4	81.1	85.8	4.7 / 24.9%

# BERT: Bidirectional Encoder Representations from Transformers

## SQuAD1.1 Leaderboard

Rank	Model	EM	F1
	Human Performance <i>Stanford University</i> <a href="#">(Rajpurkar et al. '16)</a>	82.304	91.221
1 <span>Oct 05, 2018</span>	BERT (ensemble) <i>Google AI Language</i> <a href="https://arxiv.org/abs/1810.04805">https://arxiv.org/abs/1810.04805</a>	87.433	93.160
2 <span>Sep 09, 2018</span>	nlnet (ensemble) <i>Microsoft Research Asia</i>	85.356	91.202
3 <span>Jul 11, 2018</span>	QANet (ensemble) <i>Google Brain &amp; CMU</i>	84.454	90.490

<https://ai.googleblog.com/2018/11/open-sourcing-bert-state-of-art-pre.html>


**“Messenger is growing as a platform and chatbots provide a unique way to connect,” said Krista Neher, bestselling author and CEO of Boot Camp Digital. “What I expect in 2019 is that the hype of chatbots will die down and businesses will be more strategic in how they actually use them. Marketers will shift from ‘we need a chatbot’ to ‘how do we use this strategically as a communications tool?’”**



Search Engine Journal

169 tūkst. people like this

Mediju/Ziņu uzņēmums



**FLPP**

FUNDAMENTĀLIE UN  
LIETIŠĶIE PĒTĪJUMU  
PROJEKTI

Paldies par uzmanību!