

# Automaatne süntaktiline analüüs

Kaili Müürisep  
Tartu Ülikool  
Arvutiteaduse instituut

# Süntaksianalüüsил põhinev keeletarkvara ning selle arendamiseks vajalikud keeleressursid 2006-2008

Eesmärgid:

- Luua keeletarkvara prototüübид grammatikakorrektoriga ja automaatsele sisukokkuvõtete tegijale
- Luua selleks vajalikud keeleressursid

# Pindsüntaktiliselt märgendatud korpus

Loodud ligikaudu poole miljoni sõnaline süntaktiliselt märgendatud tekstikorpus:

- Ilukirjandus
- Tõlkekirjandus
- Ajakirjandus
- Seadus
- Verbirektsioonidega lihtlaused
- Suuline keel (argivestlus, infodialoog)
- Murre

# Pindsüntaktiliselt märgendatud korpus

\$<s>

See

see+0 // \_P\_ dem sg nom #cap // \*\*CLB @SUBJ

oli

ole+i // \_V\_ main indic impf ps3 sg ps af #Intr // @+FMV

osa

osa+0 // \_S\_ com sg nom // @PRD

vihkamise

vihka=mine+0 // \_S\_ com sg gen #mine // @NN>

nädala

nädal+0 // \_S\_ com sg gen // @ADVL

eelsest

eelne+st // \_A\_ pos sg el // @AN>

kokkuhoiukampaaniast

kokku\_hoiu\_kampaania+st // \_S\_ com sg el // @<NN

\$.

\$. // \_Z\_ Fst //

\$</s>

# Suulise keele süntaktilisest märgendamisest

T: ja noh tähendab `mina sellest `aru ei saa sest=noh mina  
`lõikangi `vasaku `käega [`kääride]ga, mul=ei ma=ei tuld  
`selle `pealegi=t võib mingi `erinevus olla. (.) [ma]=aint  
`mõtsin need on `õutselt `mugavad. [(0.8) et=nad]

L: [mh] [((naerab))]

T: `niigi sobivad `kätte. [(0.5) `põid]la ja [kõik on] `tehtud.=

# Kõnekonarused

K ####

\$<s>

muna muna+0 //\_S\_ com sg nom // \*\*CLB @SUBJ

noh noh+0 //\_B\_ // @B |

see see+0 //\_P\_ dem sg nom // @<NN

siiia siiia+0 //\_D\_ // @ADVL

asemele asemele+0 //\_D\_ // @ADVL

tuleks tule+ks //\_V\_ main cond pres ps3 sg ps af #FinV #Intr // @+FMV

leida leid+a //\_V\_ main inf #NGP-P // @OBJ

midagi miski+dagi //\_P\_ indef sg part // @OBJ

muud muu+d //\_P\_ indef sg part // @<NN

ma mina+0 //\_P\_ pers ps1 sg nom // \*\*CLB-C @SUBJ

soovitaks soovita+ks //\_V\_ main cond pres ps1 sg ps af // @+FMV

hapukoort hapu\_koor+t //\_S\_ com sg part // @OBJ

\$. . //\_Z\_ Fst //

\$</s>

# Murdetekst

\$.\$\$.

\$. // \_Z\_ Fst //

siss [ADVL]

siis+0 // \_D\_ // \*\*CLB @ADVL

nakkatti [+FMV]

nakka+0 // \_V\_ main imps indic impf #FinV #Intr #All // @+FMV

mullõ [ADVL]

mina+0 // \_P\_ pers ps1 sg all // @ADVL

õks [B]

iks+0 // \_B\_ // @B

`palkka [OBJ]

palk+0 // \_S\_ com sg part // @OBJ

ka [B]

ka+0 // \_B\_ // @B

`masma [-FMV]


maks+0 // \_V\_ main sup ill // @-FMV @ADVL

# Puudepank


Kogu käsitsi märgendatud puudepank koosneb hetkel:

- 388 liikumisverbiga lihtlauset Rätsepa korpusest.
- 732 liikumisverbiga lauset eesti frameneti testkorpusest
- 175 lauset Arboresti korpusest
- 20 lauset suulise keele korpusest

# Puudepank



# Puudepank



# Grammatikad

- Teisendati T. Puolakaineni loodud (Puolakainen 2001) morfoloogilise ühestaja reeglid uue VISL parseri formaatti (1509 reeglit).
- Teisendati pindmise süntaksianalüsaatori reeglid uue VISL parseri formaatti (1130 reeglit).
- Loodi sõltuvusstruktuuri ehitav grammatika (50 reeglit), mille abil on võimalik leida enamiku lausete osalist puustruktuuri.
- Loodi lihtsamate fraasitüüpide analüüsimiseks fraasisstruktuurigrammatika, mis siiski ei sobi keerulisemate infiniittarinditega lihtlausete ja liitlausete analüüsiks.

# Sõltuvusseosed

"<Kuigi>"

  "kuigi" <kuigi+0> J sub <cap> @J #1->3

  "kuigi" <kuigi+0> D <cap> @ADVL #1->3

"<president>"

  "president" <president+0> S com sg nom @SUBJ #2->3

"<andis>"

  "and" <and+is> V main indic impf ps3 sg ps af <FinV> <NGP-P> <InfP>  
  @FMV #3->11

"<stuudiosse>"

  "stuudio" <stuudio+sse> S com sg ill @ADVL #4->5

"<saabudes>"

  "saabu" <saabu+des> V main ger <Intr> <III> @ADVL #5->3

"<oma>"

  "oma" <oma+0> P det pos refl sg gen @NN> #6->7


"<rivaalile>"

  "rivaal" <rivaal+le> S com sg all @ADVL #7->3

"<kätt>"

  "käsi" <käsi+tt> S com sg part @OBJ #8->3

# Windowsi parser



The screenshot shows the same "Document - EstCGParser" application window. The sentence "Noorus olevat alati hukas." is present. The parse tree output is identical to the one on the left, but certain words are highlighted in red or green, indicating specific grammatical categories or entities identified by the parser.

```
$LAS
// // OL
Noorus
  noorus+0 //Nimis ainsus nim // OL Alus
olevat
  ole+vat //Teguss põhi kaudne olevik isikuline jaatav // Öeldis
alati
  alati+0 //Määrs // Määrus
hukas
  hukas+0 //Omaduss algv // Öeldistäide
  hukas+0 //Määrs // Määrus
$.
  . //Kvm punkt //
$LLS
// //
```

Ready

# Sisukokkuvõtja

- <http://math.ut.ee/~kaili/estsum/2009/estsumframe.cgi>

# Grammatikakorrektor

- Tugineb morfoloogilise ühestaja ja süntaksianalüsaatori väljundile
- Esimese sammuna lisatakse kaks märgendit, @ERR ja @OK, vastavalt vigase ning korrektse koha märgendamiseks, kõigile sidesõnadele ja verbi pöördelistele vormidele.
-

# Näide

Kasutades kitsenduste grammatika analüsaatori mootorit märgendada kahtlased sõnad märgendiga "korrektne" või "vigane"

"<Soovitan>" "soovita" <soovita+n> V main indic pres ps1 sg ps af .NGP-P .InfP \*\*CLB **+FMV**

"<kõikidel>" "kõik" <kõik+del> P det pl ad **ADVL**

"<kes>" "kes" <kes+0> P inter rel pl nom \*\*CLB-C SUBJ OBJ **@ERR**

"<sellist>" "selline" <selline+t> P dem sg part **NN>**

"<teed>" "tee" <tee+d> S com sg part **OBJ**

"<näinudki>" "näge" <näge+nudki> V main partic past ps .Part-P .InfP **-FMV**

"<pole>" "ole" <ole+0> V aux indic pres ps neg .FinV .Intr **+FCV**

"<,>" ",," <,> Z Com

# Grammatikakorrektori reeglid

- Kui sõnale *siis* järgneb vahetult sõna *kui*, siis nõuda nende vahele koma. Nt *Tulen siis, kui tahan.*
- Kui sõnale *siis* eelneb lauses sõna *kui* ning järgneb võimalik öeldis, siis juhul, kui sõnade *kui* ja *siis* vahel leidub võimalik öeldis, nõuda *siis* ette koma. Nt *Kui teha, siis teha hästi.* Vastasel juhul koma mitte panna. Nt *Ja kui siis hakkas sadama.*
- Kui järjest esinevad sõnad *kui*, *siis* ja küsisõna, siis nõuda *siis* ette koma. Nt *Ja kui, siis mida?*

# Tulemused

- Korrektelt tuvastatud komavigade osakaal kõigist grammatikakorrektori poolt antud komavigade märgenditest ehk grammatikakorrektori täpsus testkorpusel on 93,8%.
- Saagis ehk leitud komavigade suhe korpuses leidunud (ja käsitsi märgendatud) komavigadesse on 94,1%.
- 30 lause hulgas oli 27 komaveaga, neist leiti 24

# Projektiga seotud magistritööd

- Aivi Kaljuvee. Määriste ja täiendite eristamine statistiliste meetoditega. Tartu Ülikool, Arvutiteaduse instituut. 2008
- Krista Liin. Reeglipõhine komavigade tuvastaja eestikeelsetele tekstidele. Tartu Ülikool, Arvutiteaduse instituut. 2008
- Pilleriin Mutso. Knowledge-poor Anaphora Resolution System for Estonian. Tartu Ülikool, Arvutiteaduse instituut. 2008
- Kadri Kajaste. *Morfoloogilisest ühestamisest*. 2009

Eesti keele sõltuvusgrammatika  
arendamine ja osaliselt mittekorrektse  
eestikeelse teksti morfoloogiline  
ühestamine ja süntaktiline analüüs  
2009-2010

# Eesmärgid

Projekti eesmärgiks on olemasolevale morfoloogilisele ühestajale ja pindsüntaktilisele analüsaatorile tuginedes luua:

1. Grammatikakorrektori tööversioon
2. Suulise keele süntaksianalüsaatori arendamine.
3. Murdetekstide süntaktiline analüüs
4. Interneti keele (ue meedia keele) süntaktiline analüüs
5. Õppijakeele süntaktiline analüüs
6. Sügavamate sõltuvusseoste tuvastamine