

Süntaksipuud

Kaili Müürisep
25.04.08

Ajaloost

- Puudepank – süntaktiliselt märgendatud korpus
 - moodustajate struktuur
 - funktsionaalne struktuur
 - kompromiss
- Esimesed tekkisid 30 a tagasi
- Tuntuim Penn Treebank

Fraasistruktuuriga puudepank

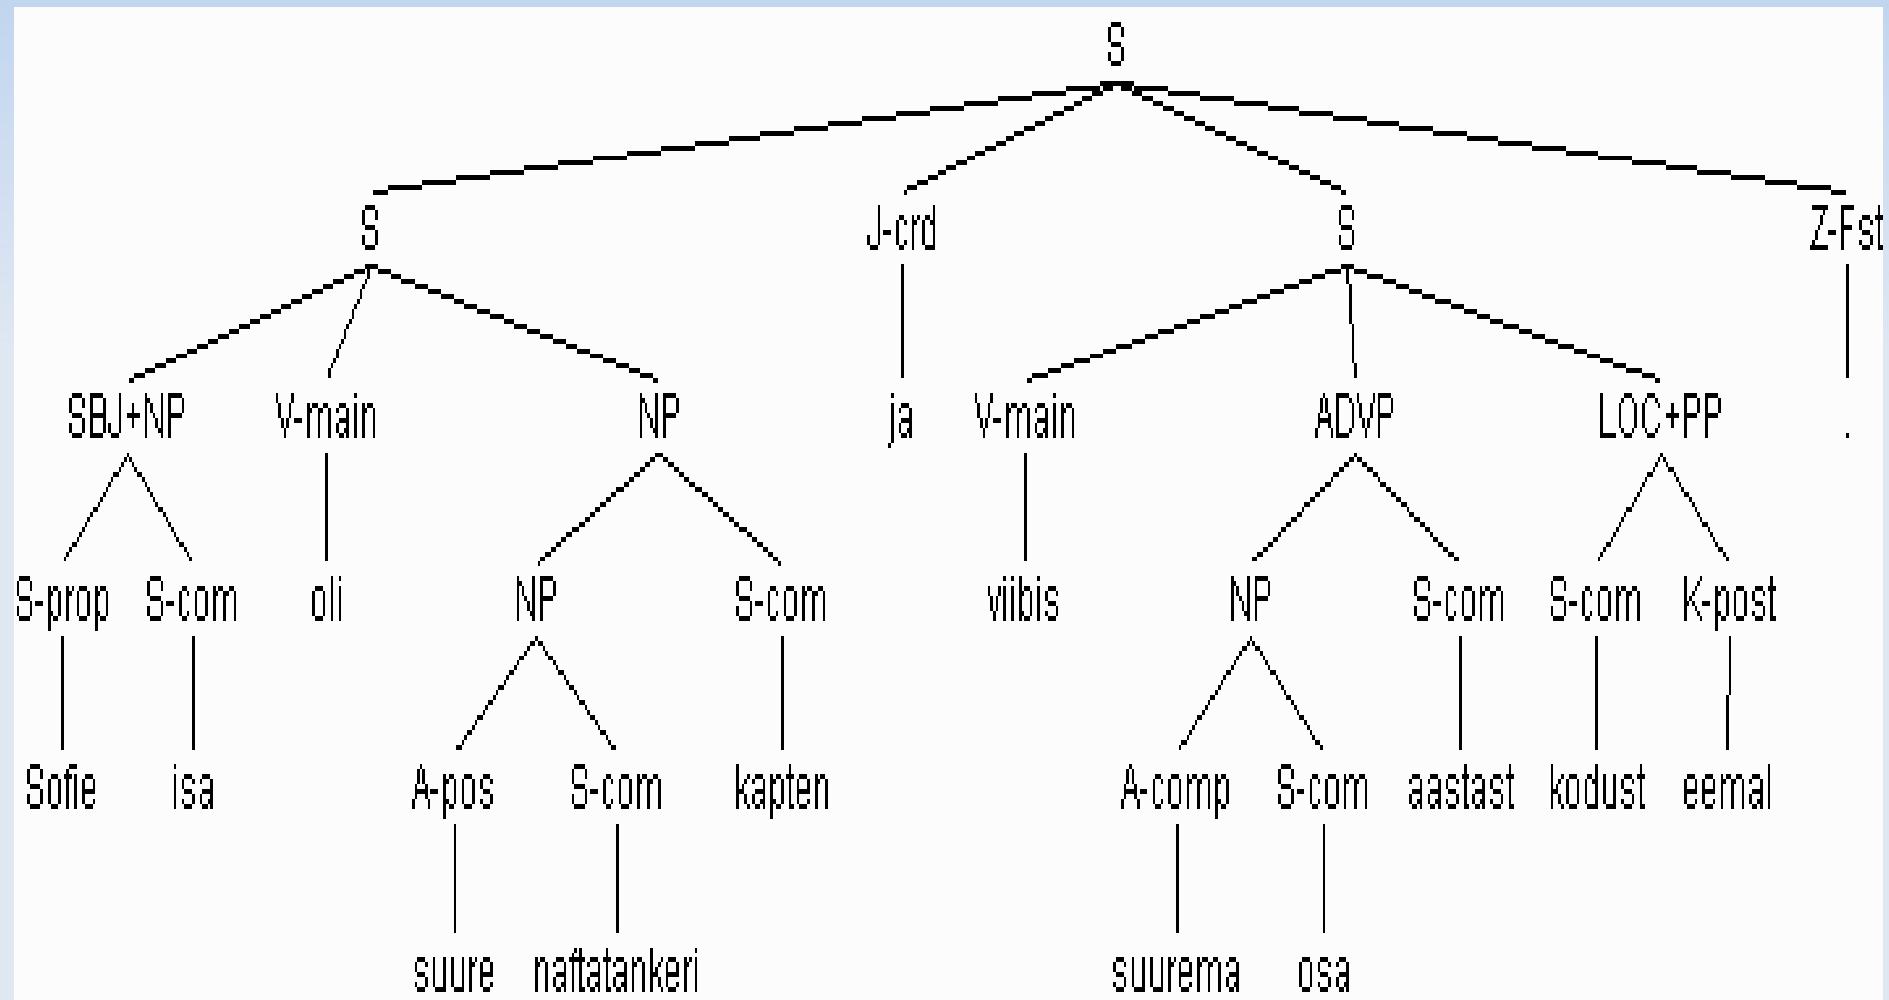
- Tuntuim esitusviis on suluesitus:
 - Lancaster Parsed Corpus

```
[S[N Nemo_NP1 ,_, [N the_AT killer_NN1 whale_NN1 N]
,_, [Fr[N who_PNQS N] [V 'd_VHD grown_VVN [J too_RG
big_JJ [P for_IF [N his_APP$ pool_NN1 [P on_II [N
Clacton_NP1 Pier_NNL1 N]P]N]P]J]V]Fr]N] ,_, [V
has_VHZ arrived_VVN safely_RR [P at_II [N his_APP$
new_JJ home_NN1 [P in_II [N Windsor_NP1
[ safari_NN1 park_NNL1 ]N]P]N]P]V] ._. S]
```

- Penn Treebank (ajalooline)

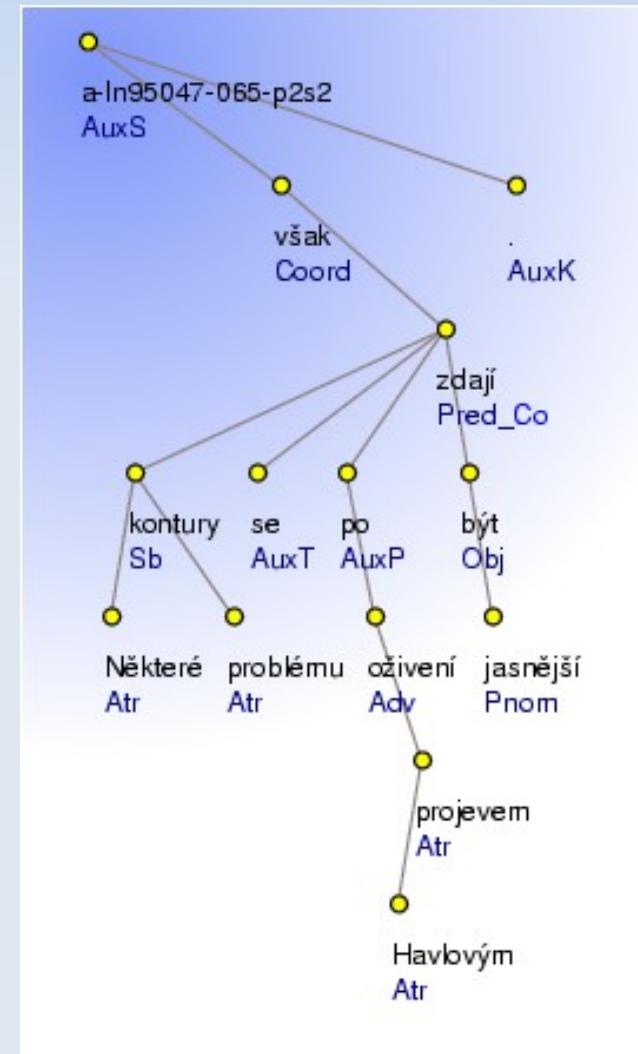
((S
 (NP Martin Marietta Corp.)
 was
 (VP given
 (NP a \$ 29.9 million Air Force contract
 (PP for
 (NP low-altitude navigation and targeting equipment))))
)

Puuesitus



Sõltuvuspuude pangad

- Suurim Praha puudepank – 1,5 miljonit sõna süntaktilise analüüsiga
- Některé kontury problému se však po oživením Havlovým projevem zdají být jasnější .
- Some contours problem (gen) reflexive pronoun though after resurgence (instr) Havel's speech (instr) they-seem to-be clearer .
- Some contours of the problem seem to be clearer after the resurgence by Havel's speech.



TIGER Treebank

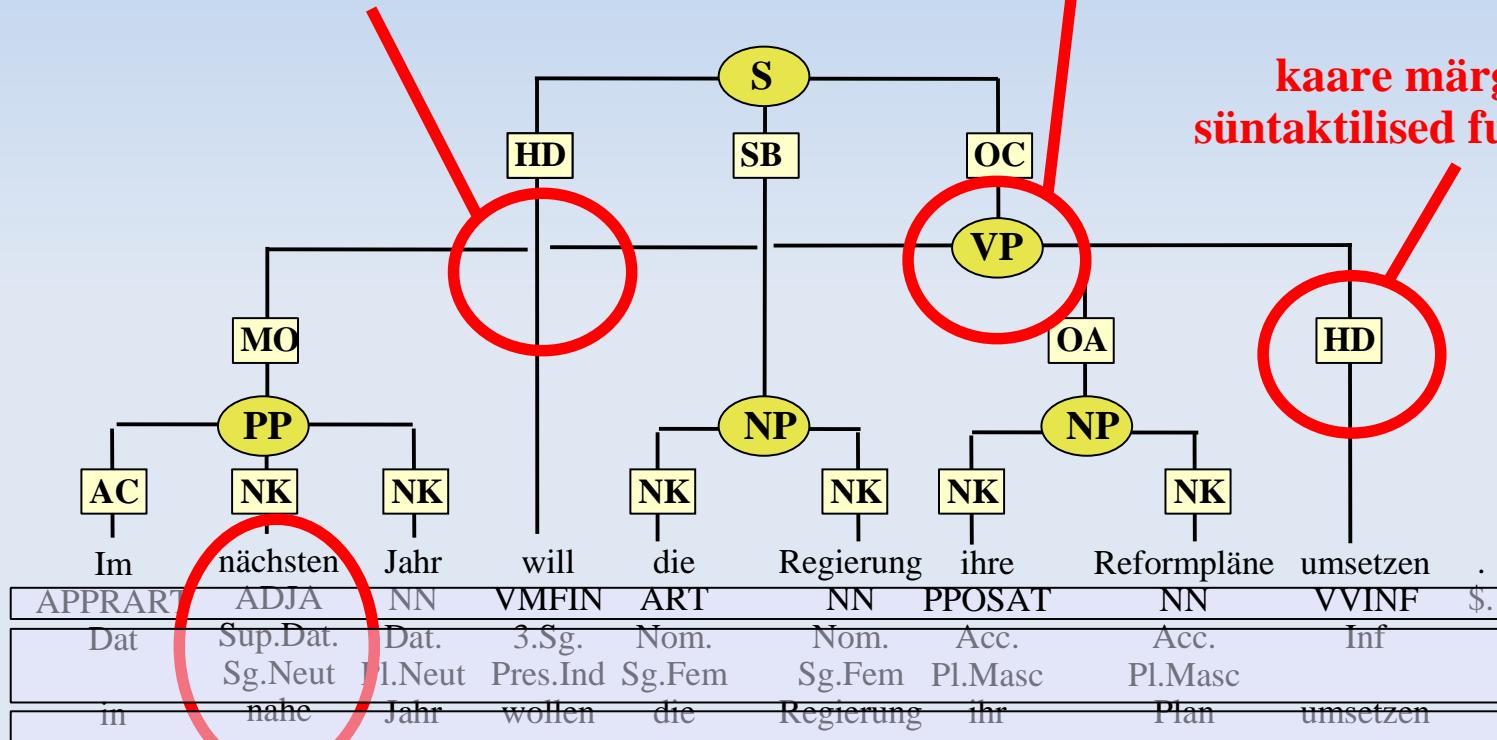
- TIGER saksa keele puudepank – 50000 lauset (900000 sõna), koos NEGRA korpuse 20000 lausega võrreldav Penn Treebankiga (1.5 milj sõna)
- **TIGER**: Linguis**Tic** Interpretation of a **GER**man Corpus

TiGer: märgendus

ristuvad kaared

tipu märgendid:
fraasistruktuur

kaare märgendid:
süntaktilised funktsioonid



sõna tasandil märgendus:
sõnaliik, morfoloogiline info
lemma

VISL treebanks

- Arboretum (Danish treebanks)
- Floresta sintá[c]tica (Portuguese treebanks)
- L'Arboratoire (French treebanks)
- Arborest (Estonian treebanks)

Arborest

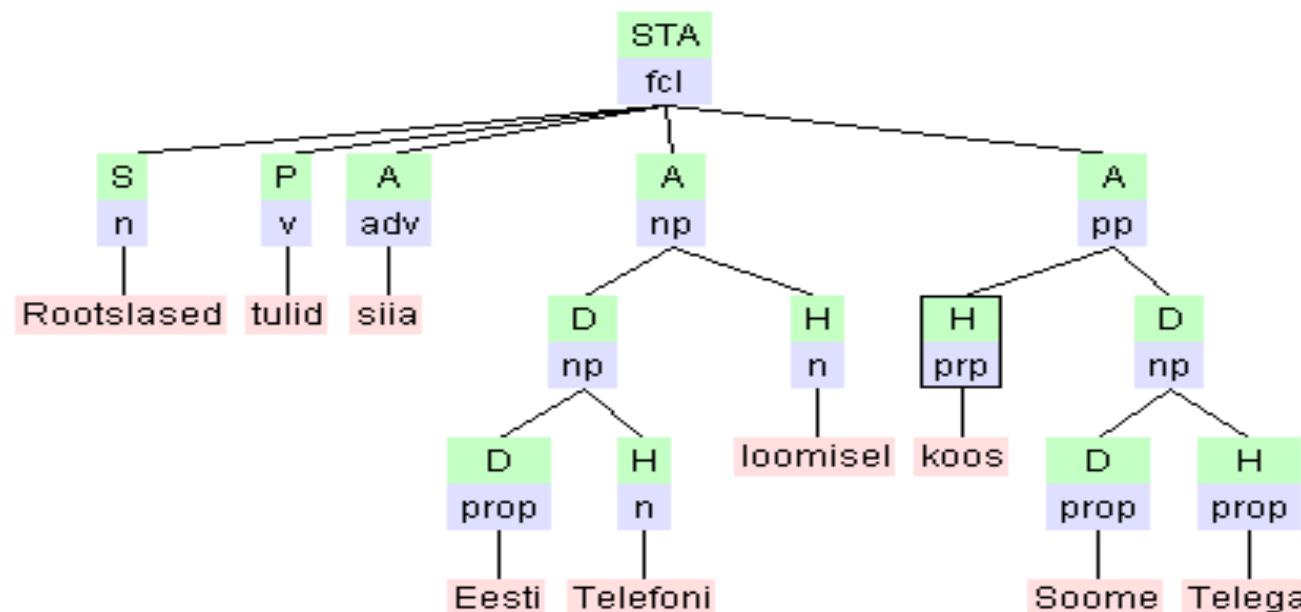
Syntax Learning

Language Settings Tools Help

Rootslased tulid siia Eesti Telefoni loomisel **koos** Soome Telega

Op As Ao Cs Co fA fApass fC fCsta fCvoc H DN DNc DNapp DA DAcom DP Dfoc P Vm Vaux Vp
v-fin v-inf v-pcp1 v-pcp2 art pron adj adv prp num conj-s conj-c intj infm np ap pp vp fcl icl acl pa

head preposition ("koos+0" pre %kom)



Arborest puu formaat

SOURCE id='est-125'

ID='est-125' Rootsased tulid siia Eesti Telefoni loomisel koos Soome Telega.

A1/2

STA:fcl

S:n("rootslane+d" com pl nom .cap) Rootsased

P:v("tule+id" main indic impf ps3 pl ps af .FinV .Intr) tulid

A:adv("siiia+0")siiia

A:np

=D:np

==D:prop("Eesti+0" prop sg gen .cap) Eesti

==H:n("telefon+0" com sg gen .cap) Telefoni

=H:n("loomis+l" com sg ad) loomisel

A:pp

=H:prp("koos+0" pre .kom) koos

=D:np

==D:prop("Soome+0" prop sg gen .cap) Soome

==H:prop("Tele+ga" prop sg kom .cap) Telega

Eestikeelsed süntaktiliselt märgendatud korpused

- EstCG korpus – pindmine sõltuvusmärgendus, 350000 sõna
- Sofie paralleelpuudepank – fraasistruktuurimärgendus, 50 lauset
- Arborest – VISL-märgendusega puudepank, 150 lauset

EstCG korpus

<S>

Mitmekesisus

mitme_kesi=sus+0 // _S_ com sg nom #cap // **CLB @SUBJ
on

ole+0 // _V_ main indic pres ps3 sg ps af #FinV #Intr // @+FMV
elu

elu+0 // _S_ com sg gen // @NN>
vaieldamatu

vaieldamatu+0 // _A_ pos sg nom // @AN>
omapära

oma_pära+0 // _S_ com sg nom // @PRD
\$.

. // _Z_ Fst //

</S>

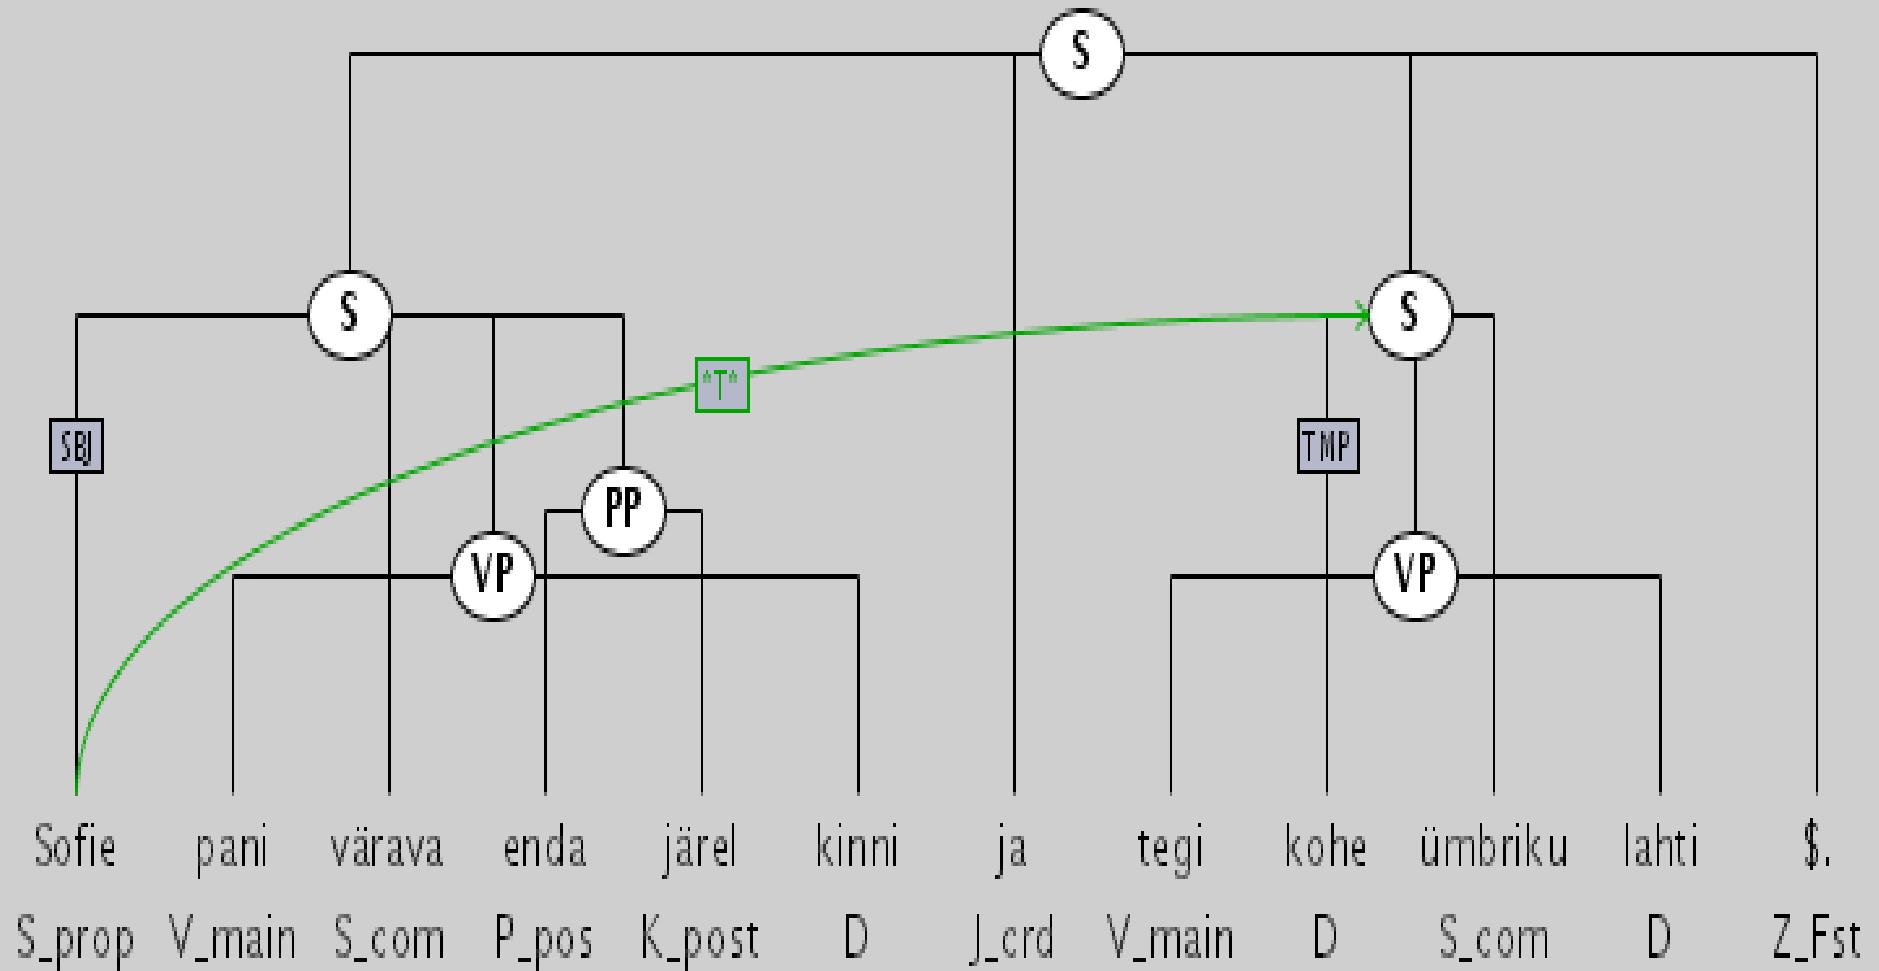
EstCG2

"<Samas>"
 "samas" <samas+0> D cap @ADVL
"<mõistis>"
 "mõist" <mõist+is> V main indic impf ps3 sg ps af FinV #NGP-P InfP @FMV
"<Rasmus>"
 "Rasmus" <Rasmus+0> S prop sg nom cap @SUBJ
"<jahmatusega>"
 "jahmatus" <jahmatus+ga> S com sg kom @ADVL
"<,>"
 "," <,> Z Com <clb>
"<et>"
 "et" <et+0> J sub @J
"<seda>"
 "see" <see+da> P dem sg part @NN>
"<nägu>"
 "nägu" <nägu+0> S com sg part @OBJ
"<oli>"
 "ole" <ole+i> V aux indic impf ps3 sg ps af FinV Intr @FCV **@C-OBJ**
"<ta>"
 "tema" <tema+0> P pers ps3 sg nom @SUBJ
"<näinud>"
 "näge" <näge+nud> V main partic past ps #Part-P InfP @IMV
"<ennegi>"
 "ennegi" <ennegi+0> D @ADVL

Sofie puudepank

- Nordic Treebank Network project
- Jostein Gaarderi novellil "Sopfe maailm" 1. peatükk.
- Roots, norra, saksa, taani, islandi, fääri, eesti keeled
 - taani keel: Discontinuous Grammar dependency treebank ja VISL-style phrase structure treebank
 - Swedish: dependency treebank
 - German: NEGRA-style treebank
 - Norwegian: phrase structure treebank
 - Estonian: Penn-style phrase structure treebank.
- Ühine ja paralleelistatud esitus TIGER XML kujul
- Eesti osa loodud kätsi.

Eesti Sofie



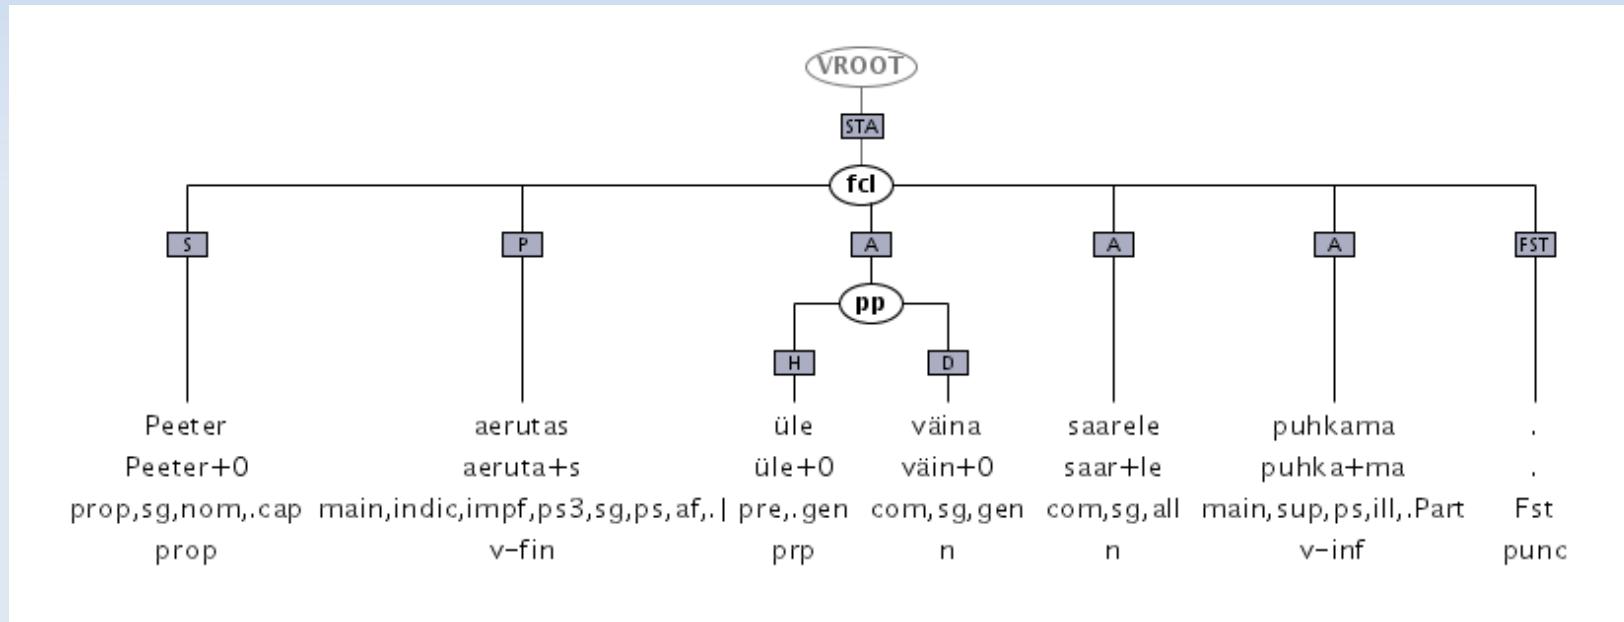
Arborest

- Heli Uibo ja Eckhard Bick
- <http://corp.hum.sdu.dk/arborest.html>
- EstCG korpus konverteeriti VISLPSG reeglite abil funktsionimärgenditega fraasistruktuuripuudeks
- Märgendus

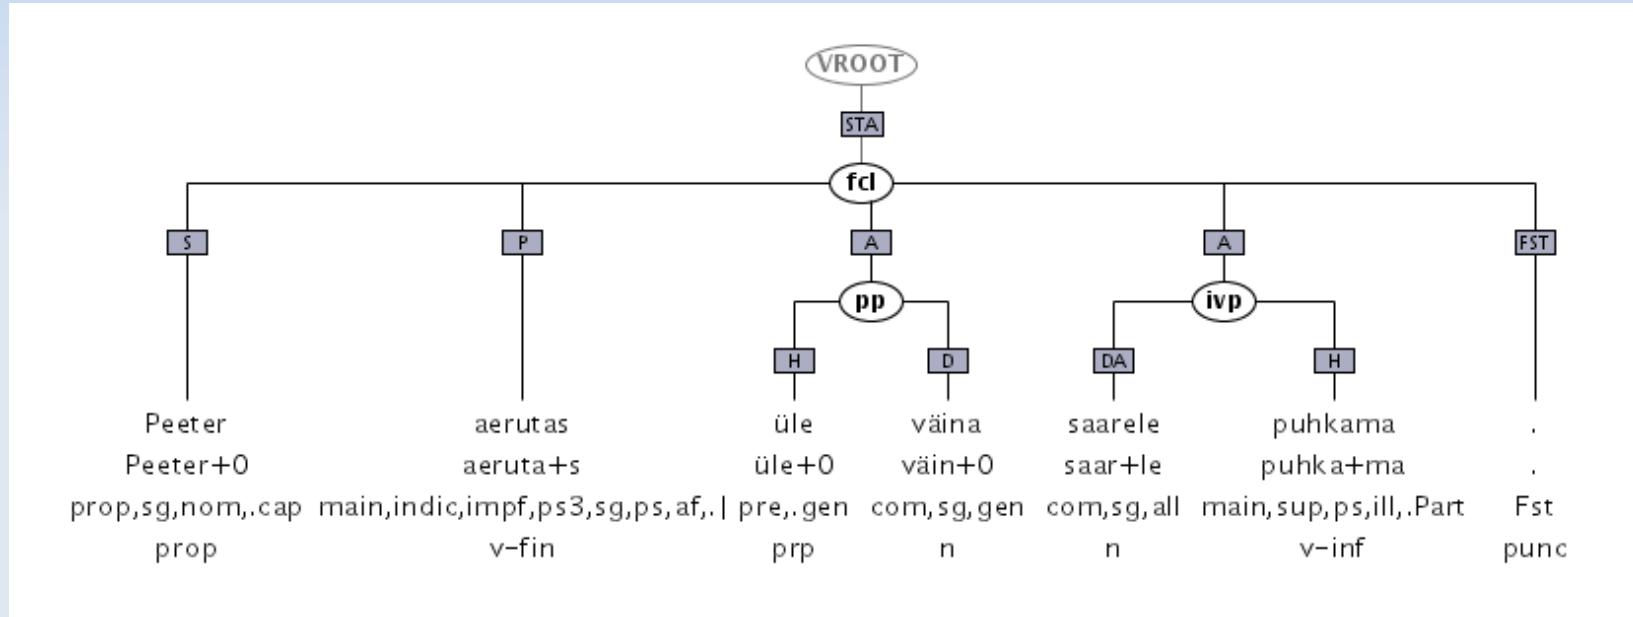
Arborest-2

- Töö käik
- Lihtlaused
 - ESTCG-formaat teisendada VISLpsg formaati
 - rakendada VISLpsg reegleid
 - parandada käsitsi
- Liitlaused
 - ESTCG teisendada ESTCG2
 - ESTCG2 grammatika
 - ESTCG2 teisendada VISLpsg
 - parandada käsitsi

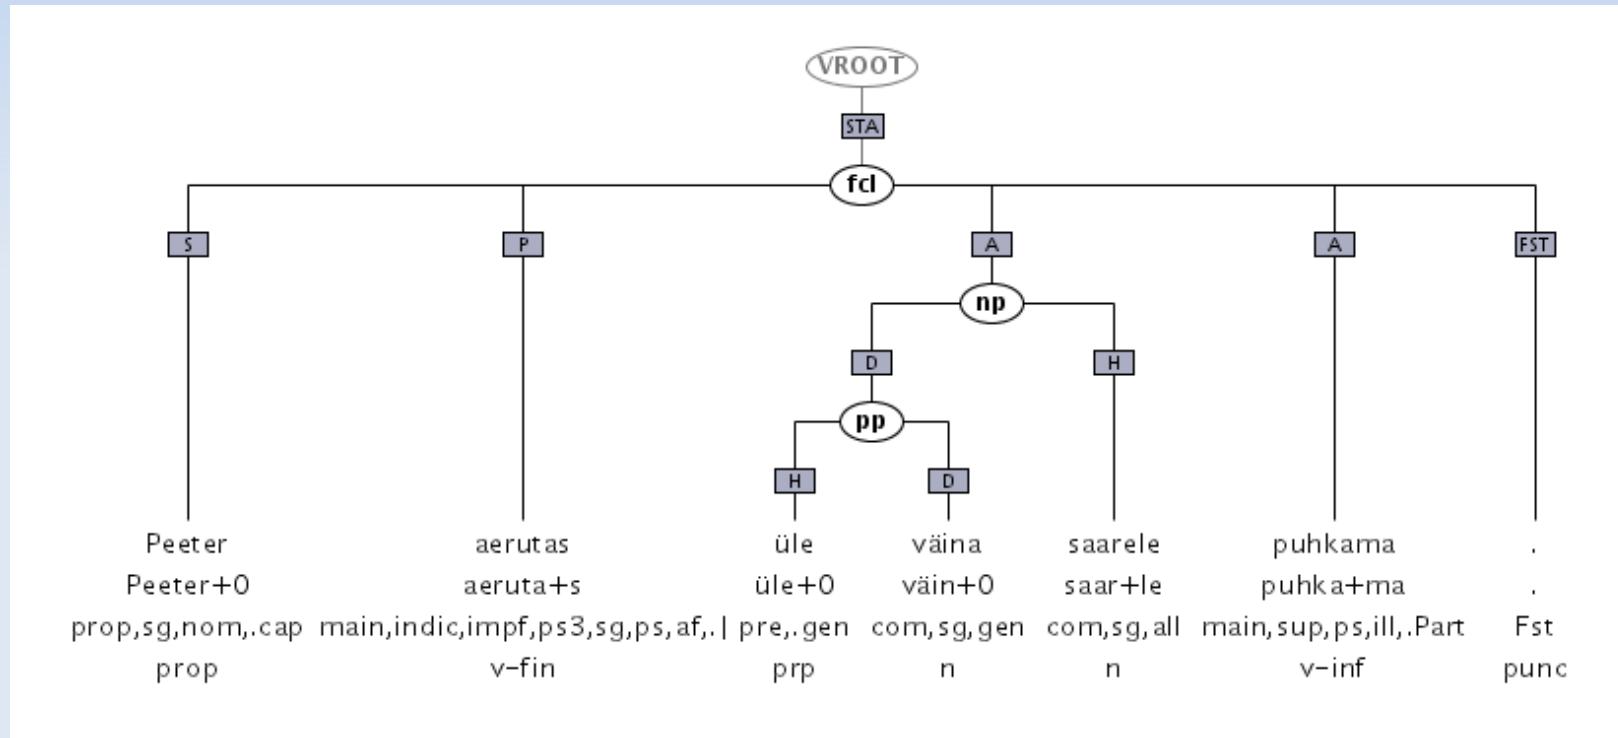
Puu nr 1



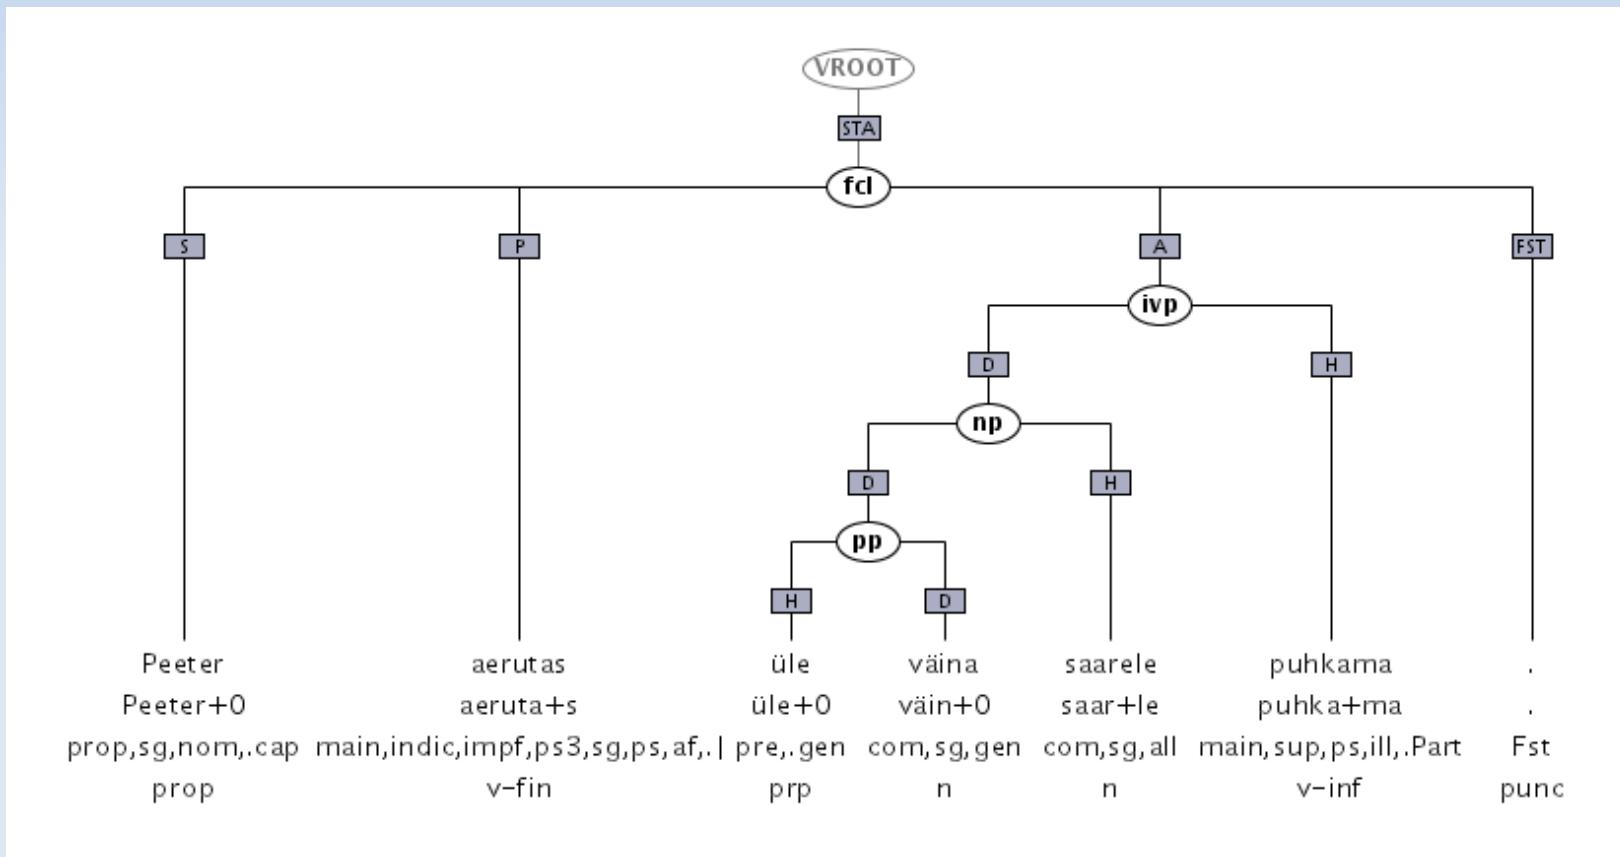
Puu nr 2



Puu nr 3



Puu nr 4



Vislpsg sisend

\$<s> "\$<s>" x @SS

Tol "too" ('too+l',dem,sg,ad,.cap) pron-dem @NN>

põuasel "põuane" ('põuane+l',pos,sg,ad) adj @AN>

suvel "suvi" ('suvi+l',com,sg,ad) n @A

elas "ela" ('ela+s',main,indic,impf,ps3,sg,ps,af,.FinV) v-fin @P

Smerdjakov "Smerdjakov" ('Smerdjakov+0',prop,sg,nom,.cap) prop @S

hulk "hulk" ('hulk+0',com,sg,nom) n @A

aega "aeg" ('aeg+0',com,sg,part) n @<Q

Tallinnas "Tallinn" ('Tallinn+s',prop,sg,in,.cap) prop @A

\$. "()." ('.\$.',Fst) punc @FST

\$</s> "\$</s>" x @SE

Reeglid

- ADJP:ap = ADVL[→D]:adv AN>[→H];
- ATRNP:np = {AN>,ADJP}[→D] NN>[→H];
- S:np = {AN>,ADJP,NN>,ATRNP}+[->D] S[→H];
- S:np = S[→H] <NN[→D];
- O:np = {AN>,ADJP,NN>,ATRNP}[→D] O[→H];
- C:np = {AN>,ADJP,NN>,ATRNP}[→D] C[→H];
- A:np = {AN>,ADJP,NN>,ATRNP}[→D] A[→H]:{n,num,prop,p-pers,p-dem};
- A:np = A:num[→H] <Q[→D];

Vislpsg väljund

A1

STA:fcl

A:np

=D:pron-dem('too+l',dem,sg,ad,.cap) Tol

=H:np

--=D:adj('põuane+l',pos,sg,ad) põuasel

--=H:n('suvi+l',com,sg,ad) suvel

P:v-fin('ela+s',main,indic,impf,ps3,sg,ps,af,.FinV) elas

S:prop('Smerdjakov+0',prop,sg,nom,.cap) Smerdjakov

A:np

=H:n('hulk+0',com,sg,nom) hulk

=D:n('aeg+0',com,sg,part) aega

A:prop('Tallinn+s',prop,sg,in,.cap) Tallinnas