

# Süntaksiteooriad ja -mudelid

## MTAT.06.031

4. loeng

Kaili Müürisep  
kaili.muurisep@ut.ee

ATI

30. september 2010

- 1 Kontekstivabade grammatikate kokkuvõte
- 2 Tunnusstruktuurid
  - Unifitseerimine
- 3 HPSG
  - Suur leksikoni osatähtsus
  - Konstruktsioonid
- 4 Võrdlus GB-ga
- 5 Märgi struktuur
  - PHON ja SYNSEM
  - Sõna ja fraas
  - LOCAL
  - CATEGORY
  - SUBCAT
  - Näited VAL kohta leksikonist: he, book, sends
- 6 Lause esitus HPSG-s
  - Fraasid
  - Lause näide: Kim walks.
  - Subkategorisatsiooni printsiip
  - Põhja tunnuse printsiip

# KVG probleemid

- 1 Reeglitel ei ole kitsendusi.  $NP \rightarrow Adv AP$
- 2 Pole üldiseid reegleid
- 3 Ühildumist ja subkategorisatsiooni pole võimalik mõistlikult edasi anda.

$S \rightarrow NP-SG VP-SG;$

$VP-SG \rightarrow TV-SG NP-SG;$

$VP-SG \rightarrow TV-SG NP-PL;$

...

# Head küljed

- Lihtne formalism, mis suudab genereerida lõpmatut hulka keeli ja omistada neile mõistliku lingvistilise struktuuri.
- Lingvistilised nähtused, mida ei saa KVG abil kirjeldada, on haruldased.
- Arvutuslikult lihtne ja head meetodid on välja töötatud.

# Atomaarsed vrs strukturaarsed kategooriad

Siiani esitati grammatilist kategooriat atomaarsena, millel puudus igasugune sisemine struktuur.

Erand oli DCG:

# Atomaarsed vrs strukturaarsed kategooriad

Siiani esitati grammatilist kategooriat atomaarsena, millel puudus igasugune sisemine struktuur.

Erand oli DCG:

## DCG

$np(K,A) \rightarrow ap(K,A), np(K,A).$

See on samaväärne:

$np(\text{kääne: } K, \text{ arv: } A) \rightarrow ap(\text{kääne: } K, \text{ arv: } A), np(\text{kääne: } K, \text{ arv: } A).$

# Tunnusstruktuurid

Tunnusstruktuur koosneb tunnus-väärtus-paaridest.

## Tunnusstruktuur

$$\left[ \begin{array}{ll} \text{FEATURE}_1 & \text{VALUE}_1 \\ \text{FEATURE}_2 & \text{VALUE}_2 \\ \dots & \\ \text{FEATURE}_N & \text{VALUE}_N \end{array} \right]$$

## Näide

$$\left\langle \text{lind}, \left[ \begin{array}{ll} \text{POS} & \text{noun} \\ \text{NUM} & \text{sg} \end{array} \right] \right\rangle$$

# Tunnuste tüübid

Kui me vaatame keelt analüüsidest mõisteid fraas, sõna, kategooria jne, siis tüübid kirjeldavad neile vastavaid tunnusstruktuure.

# Tunnuste tüübid

Kui me vaatame keelt analüüsidest mõisteid fraas, sõna, kategooria jne, siis tüübid kirjeldavaid neile vastavaid tunnusstruktuure.

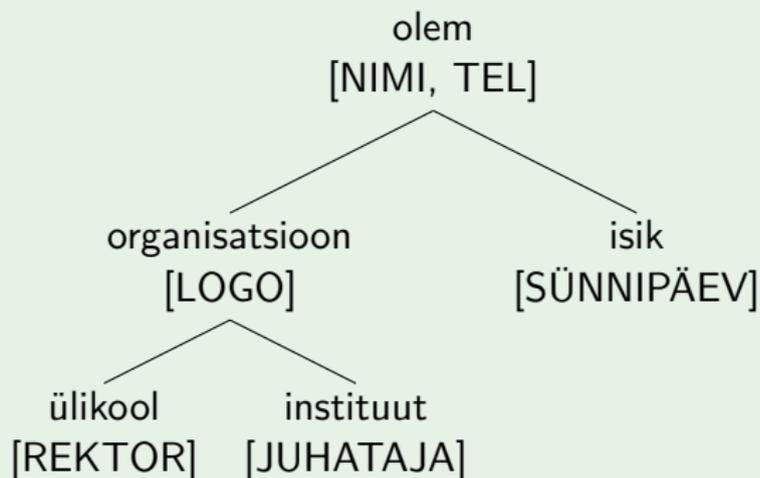
## Tartu ülikool

- [ NIMI TARTU ÜLIKOOL  
TEL 737 5100 ]
- [ NIMI ARVUTITEADUSE INSTITUUT  
TEL 737 5 ]
- [ NIMI KAILI MÜÜRISSEP  
TEL 737 5 ... ]

# Tunnuste tüübid

Kui me vaatame keelt analüüsisid mõisteid fraas, sõna, kategooria jne, siis tüübid kirjeldavad neile vastavaid tunnustruktuure.

## Tüübihierarhia



# Tunnuste tüübid

Kui me vaatame keelt analüüsidest mõisteid fraas, sõna, kategooria jne, siis tüübid kirjeldavaid neile vastavaid tunnusstruktuure.

## Tüübid

- [ ülikool  
NIMI TARTU ÜLIKOOL  
TEL 737 5100  
REKTOR ALAR KARIS ]
- [ instituut  
NIMI ARVUTITEADUSE INSTITUUT  
TEL 737 5445  
JUHATAJA TIIT ROOSMAA ]
- [ isik  
NIMI KAILI MÜÜRISSEP  
TEL 737 5 ...  
SÜNNIPÄEV 06.03.1986 ]

# Tunnuste tüübid

Kui me vaatame keelt analüüsisid mõisteid fraas, sõna, kategooria jne, siis tüübid kirjeldavaid neile vastavaid tunnustruktuure.

ülikool		
NIMI	TARTU ÜLIKOOL	
TEL	737 5100	
	isik	
REKTOR	NIMI	ALAR KARIS
	TEL	...
	SÜNNIPÄEV	...

# Rekursiivsed tunnusstruktuurid

## Genealoogia

isik		
EESNIMI	ANU	
PEREKONNANIMI	TAMM	
SÜNNIAEG	06.03.08	
ISA		
	isik	
	EESNIMI	JAAN
	PEREKONNANIMI	TAMM
	SÜNNIAEG	06.03.68
	ISA	...

# Tunnusstruktuur

Tunnusstruktuur (feature structure) on tunnuste e atribuutide ja väärtuse list.

Neid esitatakse atribuut-väärtusmaatriksitena (attribute-value matrice, AVM).

Enamasti on väärtustel tüübid, et vältida juhtumeid nagu CASE:SG.

# Komplekssed tunnusstruktuurid

Eristatakse atomaarseid ja kompleksseid tunnusstruktuure. Kompleksses tunnusstruktuuris võib väärtusena esineda tunnusstruktuur.

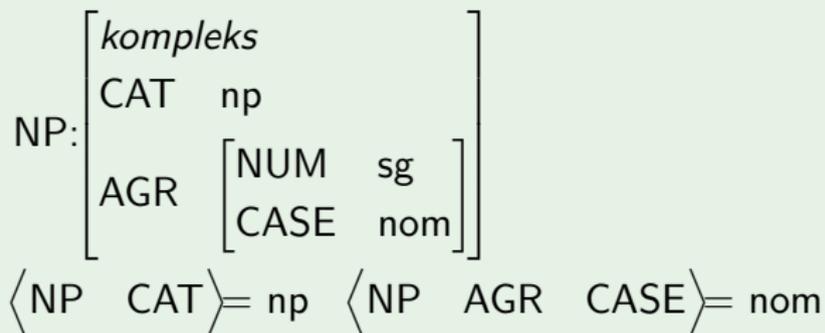
## Atomaarne vrs Kompleksne tunnusstruktuur

$$\left[ \begin{array}{l} \textit{atom} \\ \text{CAT} \quad \text{np} \\ \text{NUM} \quad \text{sg} \\ \text{CASE} \quad \text{nom} \end{array} \right]$$
$$\left[ \begin{array}{l} \textit{kompleks} \\ \text{CAT} \quad \text{np} \\ \text{AGR} \quad \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \\ \text{CASE} \quad \text{nom} \end{array} \right] \end{array} \right]$$

# Tunnuste rada

Tunnuste rada e *feature path* näitab konkreetse tunnuse väärtust struktuuris.

## Tunnuste rada



# Tunnusstruktuurid grammatikas

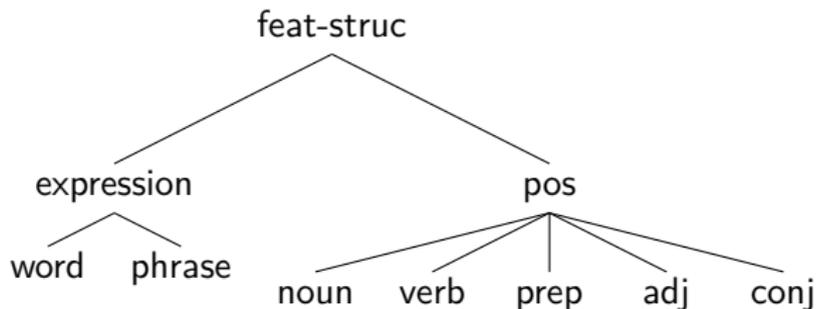
## Fraas ja Sõnad leksikonis

$\left[ \begin{array}{l} \textit{phrase} \\ \text{HEAD noun} \end{array} \right] \left\langle \textit{bird}, \left[ \begin{array}{l} \textit{word} \\ \text{HEAD noun} \end{array} \right] \right\rangle$

# Tunnusstruktuurid grammatikas

## Fraas ja Sõnad leksikonis

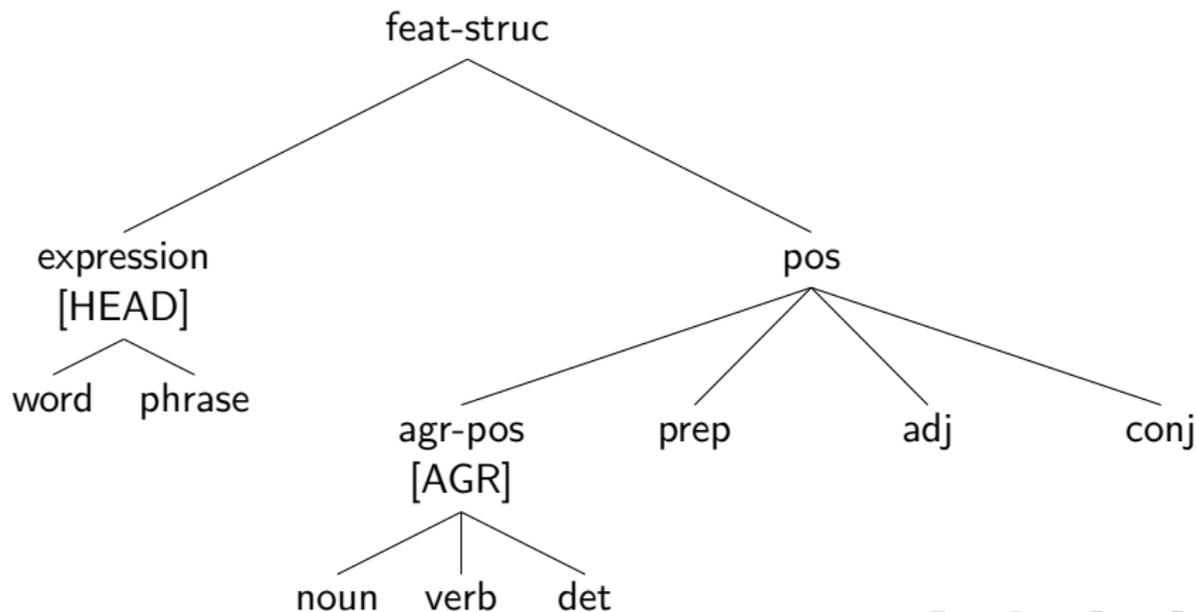
$\left[ \begin{array}{l} \textit{phrase} \\ \text{HEAD noun} \end{array} \right] \left\langle \textit{bird}, \left[ \begin{array}{l} \textit{word} \\ \text{HEAD noun} \end{array} \right] \right\rangle$



# Tunnusstruktuurid grammatikas

## Fraas ja Sõnad leksikonis

$\left[ \begin{array}{l} \textit{phrase} \\ \text{HEAD noun} \end{array} \right] \left\langle \textit{bird}, \left[ \begin{array}{l} \textit{word} \\ \text{HEAD noun} \end{array} \right] \right\rangle$



## Veel tunnuste struktuuridest: subsumptsioon

- FS1:  $\left[ \text{CAT} \quad \text{np} \right]$
- FS2:  $\left[ \right]$
- FS3:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \quad \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \\ \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$
- FS4:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \quad \left[ \text{NUM} \quad \text{sg} \right] \end{array} \right]$

## Veel tunnuste struktuuridest: subsumptsioon

- FS1:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \end{array} \right]$
- FS2:  $\left[ \right]$
- FS3:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \quad \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \\ \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$
- FS4:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \quad \left[ \text{NUM} \quad \text{sg} \right] \end{array} \right]$

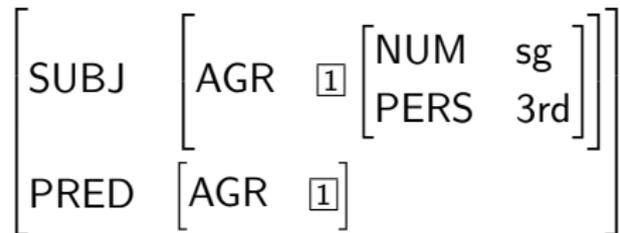
$FS2 \sqsubseteq FS1 \sqsubseteq FS4 \sqsubseteq FS3$

### Definitsioon

*Tunnuste struktuur B subsumeerib tunnuste struktuuri A ( $B \sqsubseteq A$ ), kui B sisaldab informatsiooni, mis on alamhulk A informatsioonist.*

# Struktuuri jagamine

Kaks või enam erinevat atribuuti võivad omada üht ja sama tunnuste struktuuri



# Unifitseerimine

- Tunnuste struktuurid võivad sisaldada erinevat, kuid siiski ühilduvat informatsiooni

▶ FS5:  $\left[ \begin{array}{l} \text{CAT} \qquad \qquad \text{np} \\ \text{ARG} \left[ \text{NUM} \quad \text{sg} \right] \end{array} \right]$

▶ FS6:  $\left[ \begin{array}{l} \text{CAT} \qquad \qquad \text{np} \\ \text{ARG} \left[ \text{PERS} \quad \text{3rd} \right] \end{array} \right]$

# Unifitseerimine

- Tunnuste struktuurid võivad sisaldada erinevat, kuid siiski ühilduvat informatsiooni
- Aga ka erinevat ja mitteühilduvat informatsiooni

▶ FS7:  $\left[ \begin{array}{ll} \text{CAT} & \text{np} \\ \text{ARG} & \left[ \text{NUM sg} \right] \end{array} \right]$

▶ FS8:  $\left[ \begin{array}{ll} \text{CAT} & \text{np} \\ \text{ARG} & \left[ \text{NUM pl} \right] \end{array} \right]$

# Unifitseerimine

- Tunnuste struktuurid võivad sisaldada erinevat, kuid siiski ühilduvat informatsiooni

▶ FS5:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \end{array} \right] \end{array} \right]$

▶ FS6:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$

- Aga ka erinevat ja mitteühilduvat informatsiooni
- Kui kaks struktuuri ühilduvad, siis leidub kolmas, mida nad mõlemad laiendavad.

▶ FS9:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \\ \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$

# Unifitseerimine

- Tunnuste struktuurid võivad sisaldada erinevat, kuid siiski ühilduvat informatsiooni

▶ FS5:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \end{array} \right] \end{array} \right]$

▶ FS6:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$

- Aga ka erinevat ja mitteühilduvat informatsiooni
- Kui kaks struktuuri ühilduvad, siis leidub kolmas, mida nad mõlemad laiendavad.

▶ FS9:  $\left[ \begin{array}{l} \text{CAT} \quad \text{np} \\ \text{ARG} \left[ \begin{array}{l} \text{NUM} \quad \text{sg} \\ \text{PERS} \quad \text{3rd} \end{array} \right] \end{array} \right]$

# Head-driven Phrase Structure Grammar

- Pollard and Sag 1987, 1994
- Sag and Wasow 1999
  
- Leksikaliseeritud
- Pindmised struktuurid
- Ühetasandiline
- Hierarhiline organiseeritus
- Tüpiseeritud tunnuste struktuurid (leksikon, morfoloogia, fraasid, printsiibid)
- Unifitseerimine/Pärimine
- Fonoloogia, süntaks, semantika ühendatud

- HPSG-s on enamik informatsiooni leksikonis
- Leksikoni kirjed sisaldavad informatsiooni ortograafia, sõnaliigi, ühildumise, valentsi, semantika ja argumentide liitmise kohta.
- Kasutatakse rohkesti supertüüpe, nii et tegelik kirje määrab vaid sõna tüübi, ortograafia ja võtmerelatsioonid
- Leksikaalsed reeglid seovad leksikoni baaskirjed teiste kirjetega (mitmus, passiivivorm jne)

# Konstruksioonid

Väga üldised fraasistruktuurireeglid teevad enamuse tööst:

- põhi-määratleja e *head-specifier*
- põhi-argument e *head-complement*
- põhi-alus e *head-subject*
- põhi-täitja e *head-filler*
- põhi-laiend e *head-modifier*

Üksikud konstruktsioonid vajavad eraldi reegleid:

- Relatiivlauseid
- Noun-noun compounds
- Lisand

ERGi on 105 reeglit

# Võrdlus GB-ga

- Sarnasused

- ▶ Kontekstivabad grammatikad
- ▶ Mõlemad kasutavad üldisi printsiipe
- ▶ Reeglite osakaal väike
- ▶ Leksikonil suur osakaal
- ▶ Mitmed printsiibid on väga sarnased

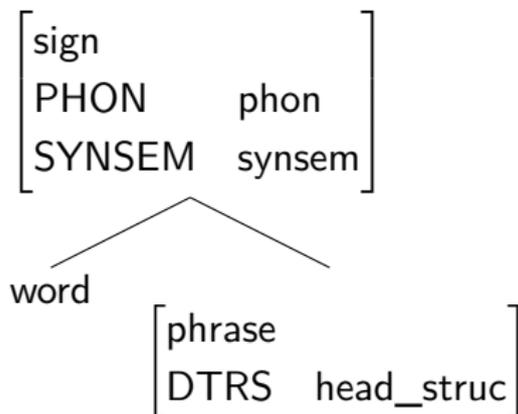
- Erinevused

- ▶ Puudub igasugune transformatsiooni mõiste
- ▶ Tasandid on teisiti jaotatud
- ▶ 'radical nonautonomy' - ükski grammatilise teadmiste tasand pole privilegieeritud seisuses
- ▶ HPSG on andmetele orienteeritud, GB teooriale orienteeritud.

# Märgi struktuur

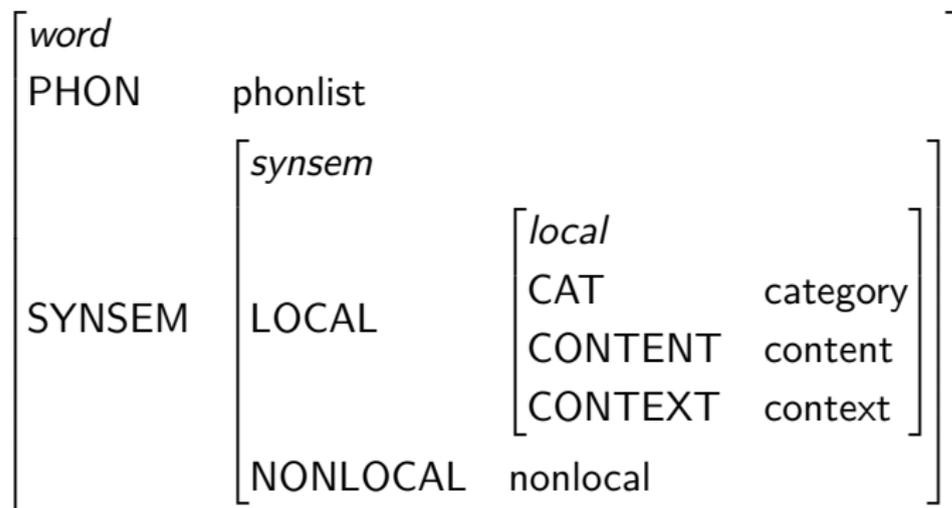
- Märk *Sign* - lause, sõna, fraas, mitmelauselised diskursused (analüüsiühik).
- Märk - vormi ja tähenduse paar *ehk*
- Märk on struktuur, mis sisaldab fonoloogilist, süntaktilist, semantilist, diskursuse ja fraasistruktuuri informatsiooni.
- Märgil on vähemalt kaks atribuuti:
  - ▶ PHON - kirjeldab märgi foneetilist sisu;
  - ▶ SYNSEM - kirjeldab süntaktilist ja semantilist informatsiooni. Jaguneb omakorda:
    - ★ LOCAL (LOC)-CATEGORY, CONTENT, CONTEXT
    - ★ NONLOCAL (NONLOC) -kasutatakse määramata liikumiste kirjeldamisel

## Märgi struktuurist veel



Kõik objektid tüüpi *sign* peavad olema kas tüüpi *word* või tüüpi *phrase*.  
Kõik objektid tüüpi *sign* on atribuutidega PHON ja SYNSEM, ja lisaks on tüüpi *phrase* objektidel atribuut DTRS.

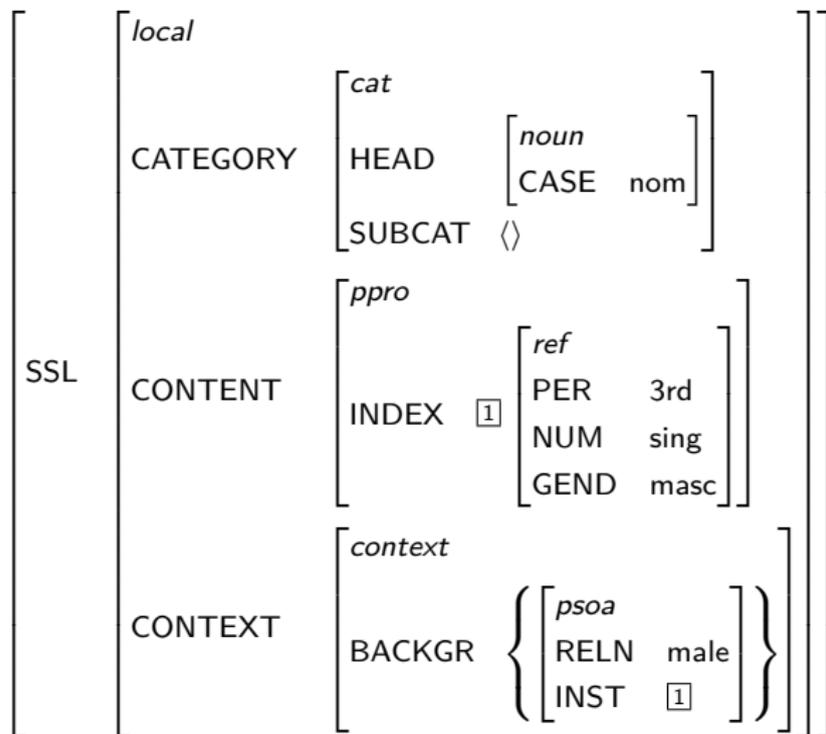
# Üldine pilt



# LOCAL

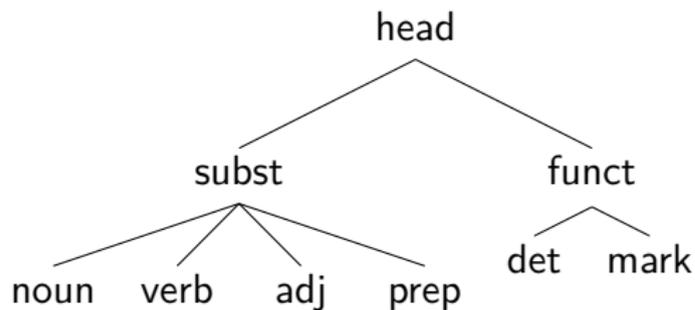
- CATEGORY tunnusel on 2 atribuuti: HEAD ja SUBCAT
- SUBCATi asemel kasutatakse ka kolme valentsitunnust: SUBJ (subject), COMPS (complements) ja SPR (specifier).
- SUBCAT on uuemal ajal ARG-S
- CONTENT kannab semantilist informatsiooni
- CONTEXT sisaldab kontekstitundlikku lingvistilist informatsiooni

# LOCAL informatsioon asesõnale *he*



# CATEGORY

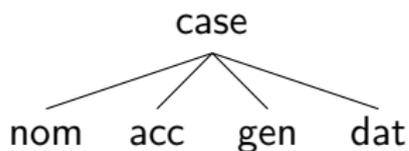
HEAD tunnus näitab sõnaliiki. Tüübistruktuur:



# NOUN

[CASE case]

Käände tüübi jagunemine (inglise k)



HEAD informatsioon asesõnale *he*

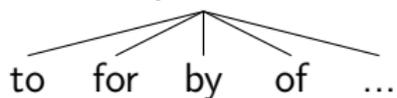


# PREPOSITION

[PFORM pform]

Inglise keele eessõna jagunemine:

pform

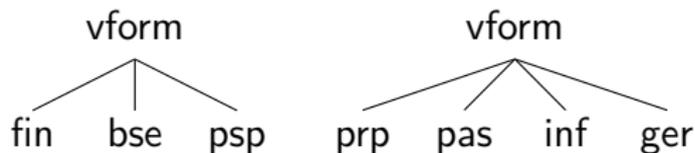


Verb *depend* vajab eessõna *on*:

[PFORM on]

# VERB

VFORM	vform
AUX	boolean
INV	boolean



Verbivorm *gives*

HEAD	<table><tr><td>verb</td></tr><tr><td>VFORM</td><td>fin</td></tr><tr><td>AUX</td><td>-</td></tr></table>	verb	VFORM	fin	AUX	-
verb						
VFORM	fin					
AUX	-					

Verbivorm *has*

HEAD	<table><tr><td>verb</td></tr><tr><td>VFORM</td><td>fin</td></tr><tr><td>AUX</td><td>+</td></tr><tr><td>INV</td><td>boolean</td></tr></table>	verb	VFORM	fin	AUX	+	INV	boolean
verb								
VFORM	fin							
AUX	+							
INV	boolean							

# SUBCAT

- SUBCAT on tunnus CATEGORY väärtuses

# SUBCAT

- SUBCAT on tunnus CATEGORY väärtuses
- subkategorisatsioon on spetsifikatsioon, mis näitab selle märgiga seotud teiste elementide arvu ja vormi. Eesti keele grammatikaraditsioonis rektsioon + ...

magab: SUBCAT⟨NP[nom]⟩

armastab: SUBCAT⟨NP[nom], NP[part]⟩

mõtleb: SUBCAT⟨NP[nom], NP[elat] | PP [üle] | S [et]⟩

# SUBCAT

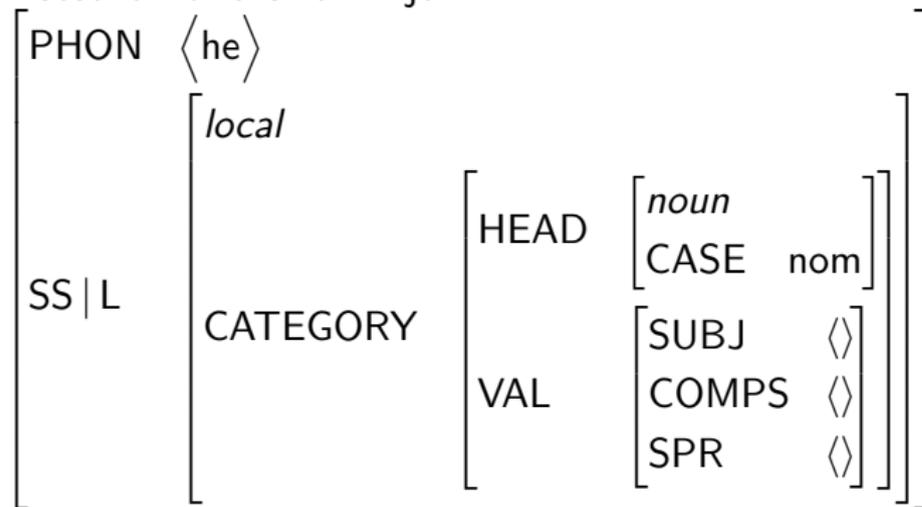
- SUBCAT on tunnus CATEGORY väärtuses
- subkategorisatsioon on spetsifikatsioon, mis näitab selle märgiga seotud teiste elementide arvu ja vormi. Eesti keele grammatikatraditsioonis rektsioon + ...
- Elementide järjekord freimis väljendab grammatiliste seoste olulisust, mitte pindmist laiendite järjekorda

SUBJECT ⇒ DIRECT OBJECT ⇒ INDIRECT OBJECT ⇒ OBLIQUES ⇒  
GENITIVES ⇒ OBJECTS OF COMPARISON

# SUBCAT

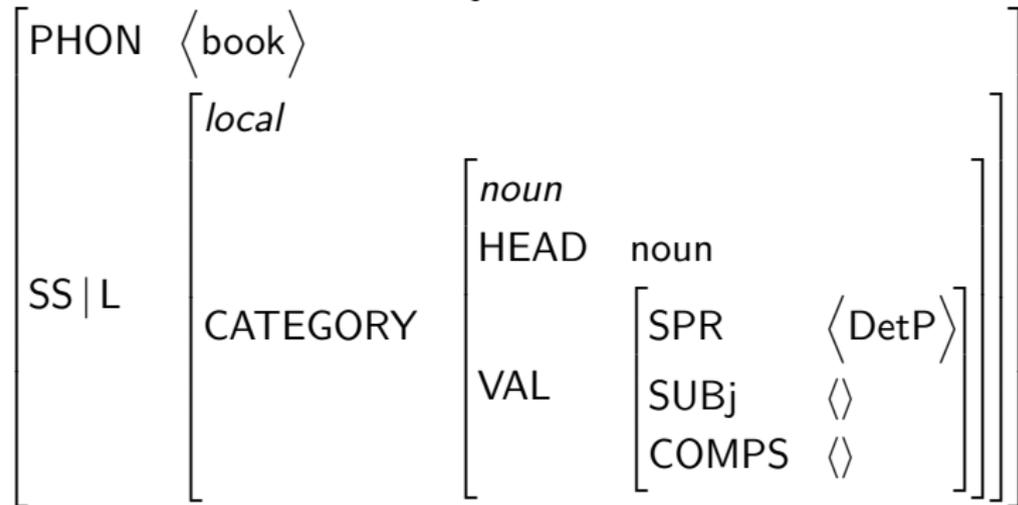
- SUBCAT on tunnus CATEGORY väärtuses
- subkategorisatsioon on spetsifikatsioon, mis näitab selle märgiga seotud teiste elementide arvu ja vormi. Eesti keele grammatikaraditsioonis rektsioon + ...
- Elementide järjekord freimis väljendab grammatiliste seoste olulisust, mitte pindmist laiendite järjekorda
- Hiljem SUBCAT tunnus asendati kolme valentsi tunnusega SUBJ, COMP ja SPR. See lubab paremini kirjeldada kategooriaid, mis vajavad laiendit, kuid mitte alust.  
Määratlejad eristatakse alusest sest nad võivad mõlemad esineda sama põhja juures (öeldistäitega lausetes).

Asesõna *he* leksikonikirje



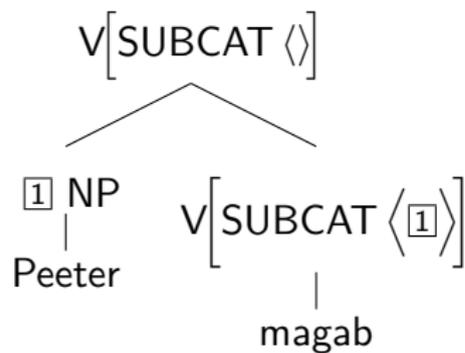
# book

Nimisõna *book* leksikonikirje

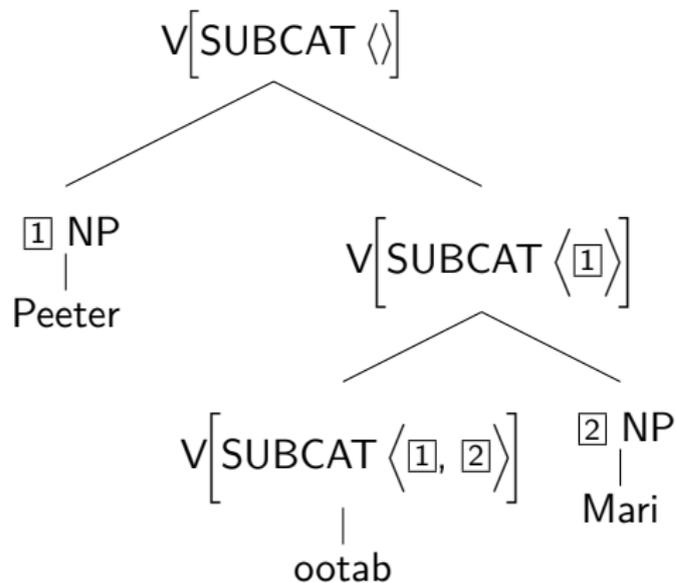




# Eestikeelsed näited



# Transitiivne verb



# Valentsireeglid HPSGs

- Spetsiifiline reegel verbi põhi-argumentseose kohta:

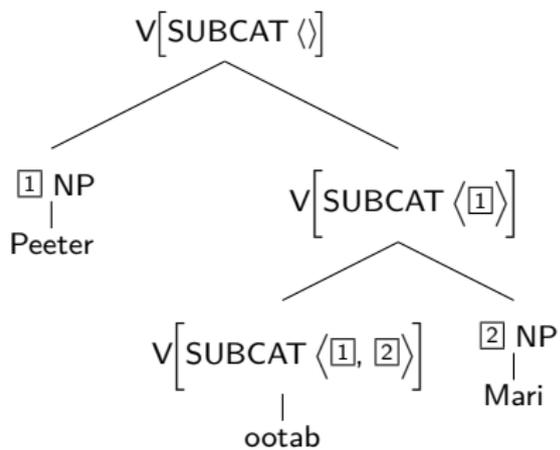
$$V[\text{SUBCAT } \boxed{A}] \rightarrow \boxed{A}, V[\text{SUBCAT } \boxed{A} \oplus \langle \boxed{B} \rangle]$$

- kus  $\oplus$  on otsekorrutis:

$$(a) \oplus (b) = (a, b)$$

$$$(a, b) \oplus () = (a, b)$$$

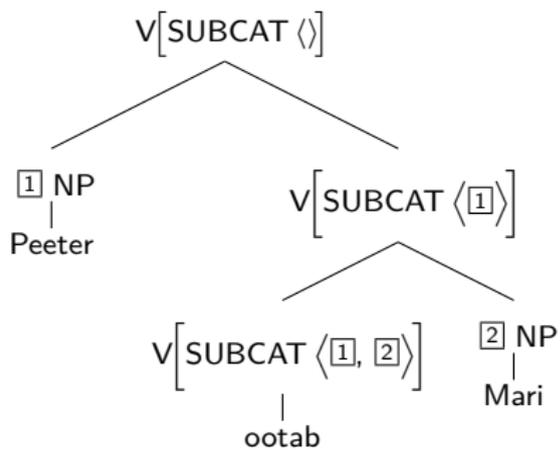
# Põhi-argumentreeglite näide



$VP2 \Rightarrow NP, VP$

$$V[\text{SUBCAT } \boxed{A}] \rightarrow \boxed{A}, V[\text{SUBCAT } \boxed{A} \oplus \langle \boxed{B} \rangle] \quad \boxed{A} = (), \boxed{B} = \boxed{1}$$

# Põhi-argumentreeglite näide



## VP- $\rightarrow$ V NP

$$V[\text{SUBCAT } \boxed{A}] \rightarrow \boxed{A}, V[\text{SUBCAT } \boxed{A} \oplus \langle \boxed{B} \rangle] \quad \boxed{A} = \boxed{1}, \boxed{B} = \boxed{2}$$

# Põhi-argumentreeglite üldistamine

$$\begin{aligned}V[SUBCAT \ A] &\rightarrow \boxed{A}, V[SUBCAT \ A \oplus \langle \boxed{B} \rangle] \\A[SUBCAT \ A] &\rightarrow \boxed{A}, A[SUBCAT \ A \oplus \langle \boxed{B} \rangle] \\N[SUBCAT \ A] &\rightarrow \boxed{A}, N[SUBCAT \ A \oplus \langle \boxed{B} \rangle] \\P[SUBCAT \ A] &\rightarrow P[SUBCAT \ A \oplus \langle \boxed{B} \rangle], \boxed{A} \\H[SUBCAT \ A] &\rightarrow H[SUBCAT \ A \oplus \langle \boxed{B} \rangle], \boxed{A}\end{aligned}$$

# Fraasid

Fraaside tunnusstruktuuril on atribuut DAUGHTERS (DTRS), mille väärtuseks on struktuur tüübist *constituent-structure* (*con-struct*), mis esitab fraasi vahetuid allujaid.

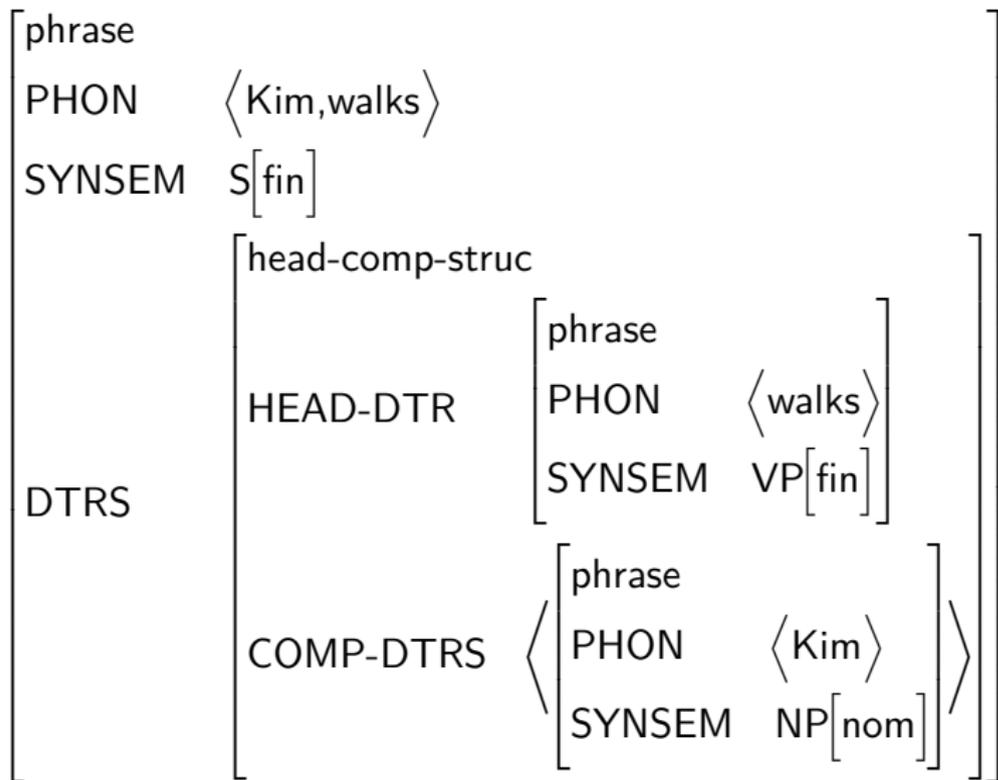
*con-struct* tüübil on palju alamtüüpe erinevat liiki tütartippude kirjeldamiseks.

Olulisim neist on *headed-structure* (*head-struct*), mida kasutatakse kõigis põhjaga konstruktsioonides.

- **HEAD-DAUGHTER** (HEAD-DTR)
- **COMPLEMENT-DAUGHTERS** (COMP-DTRS)
- ADJUNCT-DAUGHTER
- FILLER-DAUGHTER
- MARKER-DAUGHTER

[	head-struct		]
	HEAD-DTR	(a sign)	
	COMP-DTRS	(a list of signs)	

# Lause näide



# Subkategorisatsiooni printsiip

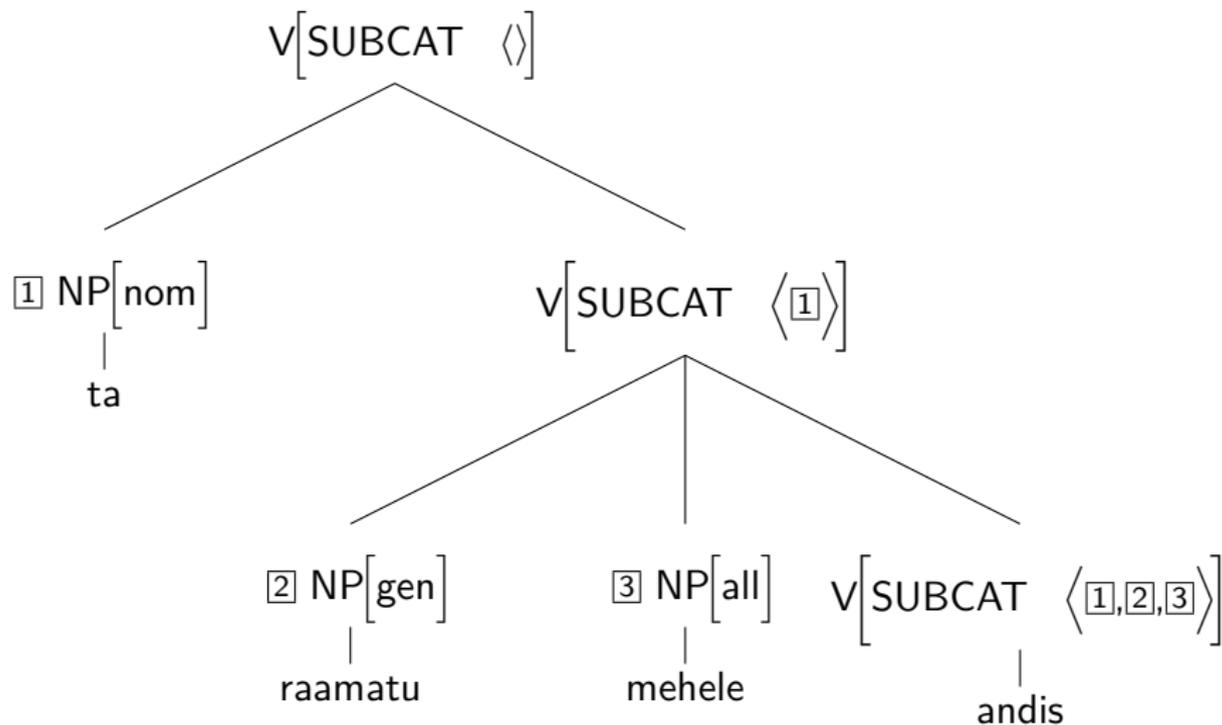
## Printsiip

*In headed phrase (i.e. a phrasal sign whose DTRs value is of sort head-struct), the SUBCAT value of the head daughter is the concatenation of the phrase's SUBCAT list with the list of SYNSEM values of the complement daughters.*

$$H[\text{SUBCAT } \boxed{A}] \rightarrow H[\text{SUBCAT } \boxed{A} \oplus \langle \boxed{B} \rangle], \boxed{A}$$

$$\left[ \begin{array}{l} \text{SUBCAT} \quad \boxed{1} \\ \text{HEAD-DTR} \quad \left[ \text{SUBCAT } \boxed{1} \oplus \langle \boxed{2} \rangle \right] \\ \text{COMPS} \quad \left[ \text{SUBCAT } \langle \boxed{2} \rangle \right] \end{array} \right]$$

# Ta andis mehele raamatu



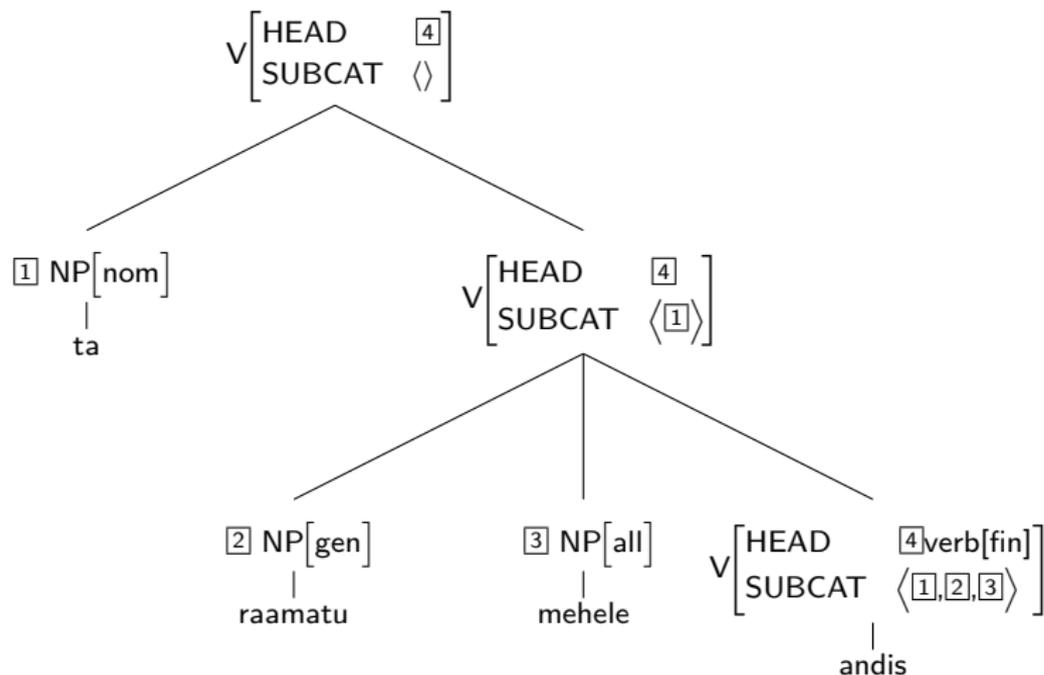
# Põhja tunnuse printsiip (HFP)

## Printsiip

*The HEAD value of any headed phrase is structure-shared with the HEAD value of the head daughter.*

head-argument-structure					
HEAD	[1]				
SUBCAT	[2]				
HEAD-DTR	[ <table><tr><td>HEAD</td><td>[1]</td></tr><tr><td>SUBCAT</td><td>[2⊕3]</td></tr></table> ]	HEAD	[1]	SUBCAT	[2⊕3]
HEAD	[1]				
SUBCAT	[2⊕3]				
COMPS	⟨[3]⟩				

# Näide põhjaprintsiibist ja subkategorisatsioonist



# Kokkuvõte

- KVG: Kogu info, mis ühes sõlmes vaja oli, tulenes otseselt reeglist.
- FSG: Nii reeglid, leksikon kui printsiibid kirjeldavad grammatikat osaliselt
- Tunnusstruktuurid on keeleüksuste mudelid, mis kirjeldavad täielikult antud üksust. Konkreetne kirjeldus võib olla poolik.
- Grammatika on hea, kui tunnusstruktuurid vastavad reaalse maailma üksustele.
- Esitusviisid: tunnusväärtusmaatriksid (AVM), kastdiagramm
- Grammatika ülesanne: kuidas leksikoni üksused on seotud sõna tunnusstruktuuriga; kuidas väiksematest üksustest saab kokku panna suuremaid
- Põhja, alamkategoriate ja tunnusstruktuuri abil saadud grammatika on võrreldes KVGga abstraktsem ja üldistavam.