

TARTU ÜLIKOOL
MATEMAATIKA-INFORMAATIKATEADUSKOND
Arvutiteaduse instituut
Tarkvarasüsteemide õppetool

Natalia Tomassova
**Grammatika-põhine
konverteriarendus**

Väitekiri *magister scientiarum* kraadi taotlemiseks
informaatika erialal

Juhendaja: prof. Jüri Kiho

TARTU 2005

Sisukord

Sissejuhatus	4
1 Konverteerimine ja konverteriarendus	7
1.1 Konverteerimise mõiste määratlus	7
1.2 Konverteerimise süsteemide näiteid	8
1.2.1 <i>DEL</i>	8
1.2.2 <i>XFlat</i> ja <i>XML Convert</i>	12
1.2.3 <i>LinkGrammar</i>	15
1.3 Konverterite loomise automatiseerimisest	18
1.3.1 Probleemi püstitus	18
1.3.2 Grammatika-põhise konverteriarenduse printsiip	18
2 Süsteem <i>Amadeus</i> kui konverteriarenduse platvorm	20
2.1 Süsteemi <i>Amadeus</i> üldiseloostus	20
2.2 Skeemteksti mudel ja skeemtöötlus	21
2.3 Skeemistamine ja tekstualiseerimine	24
3 Grammatika-põhine skeemisti loomine	27
3.1 Näiteülesanne	27
3.2 Grammatika esmane spetsifitseerimine	28
3.3 Grammatika spetsifitseerimine <i>JJTree</i> sisendi kujul	31
3.4 Uue baaskeeke lisamine	35
3.5 Skeemkonversiooni mudel	40
3.6 Kokkuvõte	42

4	Baaskeelte käitlemise ja skeemisti loomise automatiseerimine	50
4.1	Süsteemi <i>Amadeus</i> kataloogi ülesehitus	50
4.1.1	Algsätingute fail	52
4.2	Projekti mõiste süsteemis <i>Amadeus</i>	53
4.3	Uue baaskeele automaatne lisamine	58
4.4	Baaskeele automaatne kustutamine	62
4.5	Baaskeele automaatne taastamine	65
4.6	Baaskeele grammatika käitlemise tugi	67
4.7	Süsteemi <i>AmadeusJSN</i> testimine	69
4.7.1	Baaskeel <i>PSE</i> lisamine	69
4.7.2	Keelte <i>VSE</i> ja <i>PSE</i> vastastikune konverteerimine . . .	70
4.8	Kokkuvõtteks	71
	Kokkuvõte	77
	Resümee (inglise keeles)	79
	Kirjandus	80
	Indeks	83
	Lisad	84

Sissejuhatus

Proloog

Tänapäeval puututakse tihti kokku erinevate arvutitekstidega (tekstilisel kujul tarkvaraga), mida soovitakse mingil viisil töödelda, kas siis redigeerida, lugeda, teisendada vms. Arvutitekstid võivad omada erinevat süntaktilist struktuuri ning nende töötlemine võib nõuda spetsiifiliste funktsioonide olemasolu. Eritoimetite "algusest peale" loomine või olemasolevate "valmis" süsteemide kohandamine/integreerimine on enamasti kulukas. Üheks alternatiiviks on skeemtehnoloogia ja sellel baseeruv skeemtoimeti *Amadeus* [1].

Käesolev töö keskendub arvutitekstide teisendamise teatavale eriliigile – konverteerimisele. Konverteerimise all mõistetakse arvutitekstide "kergekaalulist" transleerimist, mille juures põhirõhk asetub just tekstide vormi teisendamisele. Näitena võib nimetada mingi programmeerimiskeele lähtekoodi viimist *XML* kujule.

Üha suurenev vajadus erinevate tüüpi konverterite järele on tõstatanud loomuliku küsimuse, kuidas automatiseerida konverterite loomist. Muidugi on soovitatav luua võimalikult üldist tüüpi konvertereid.

Süsteemile *Amadeus* on konverteerimine seesmiselt omane. Toimetatavaid tekste käsitletakse alati spetsiaalsel sisekujul, nn. skeemkujul ehk skeemtekstidena. Sidepidamiseks "lihttekstide maailmaga" peavad aga süsteemis leiduma võimalused lihttekstide teisendamiseks (konverteerimiseks) skeemtekstideks ja vastupidi. See asjaolu teebki võimalikuks vaadelda süsteemi *Amadeus* sobiva platvormina mitmesuguste eriotstarbeliste konverterite arendamiseks.

Selleks, et süsteem *Amadeus* töötaks konverterina mingist lähtekeelest

LK süsteemi skeemkeelde SK , peab olema süsteemi integreeritud lähtekeelele vastav nn. baaskeel. Integreerimine tähendab muuhulgas nii skeemistuskonverteri (ehk skeemisti) $LK \rightarrow SK$ kui ka vastupidise, $SK \rightarrow LK$ konverteri, nn. tekstualiseerija realiseerimist. Kui viimane on suhteliselt kergesti teostatav, siis skeemistuskonverteri "käsitsi" loomine on ülimalt töömahukas protsess. Selle juures on paratamatult vaja lähtuda konverteeritava keele LK formaalsest grammatikast.

Käesolev väitekiri

Käesolevas töös keskendutaksegi just skeemistuskonverterite loomise automatiseerimisele – küsimusele, kuidas uue baaskeele LK korral võimalikult efektiivselt välja töötada vastav skeemistamise meetod, mis realiseeriks konverteri tüüpi $LK \rightarrow SK$ (lähtekeel $\rightarrow$ skeemkeel). Töö tulemusena loodud, vastavate automatiseerimisvahenditega täiendatud süsteemi *Amadeus* uus versioon nimetusega *AmadeusJSN* [3] kujutab endast juba küllaltki efektiivset konverteriarenduse tarkvara. Automatiseeritud on uue baaskeele lisamine (ka baaskeele kustutamine ning taastamine). Skeemistuskonverteri loomiseks tuleb kasutajal vaid vajalikul kujul kirjeldada lähtekeele grammatika. Tulemusena saab süsteemi kasutada $LK \rightarrow SK$ tüüpi konverterina, ja seda hõlpsasti varieeritavate teisenduseeskirjade (skeemkonversiooni mudelite) alusel.

Märgime, et üldist tüüpi $LK \rightarrow TK$ konverteri realiseerimiseks tuleb süsteemi integreerida nii lähtekeel LK kui ka tulemuskeel TK , kusjuures viimase jaoks pole skeemistuskonverterit vaja luuagi.

Käesolev väitekiri koosneb neljast peatükist.

Esimeses peatükis tutvustatakse erinevaid olemasolevaid konverteerimise süsteeme: selliseid nagu *DEL*, *LinkGrammar*, *XML Convert*. Selgitatakse tarkvara konverteerimise mõistet. Püstitatakse ja konkretiseeritakse konverterite loomise automatiseerimise probleem ning esitatakse selle lahendamise üldine idee.

Väitekirja teises peatükis esitatakse süsteemi *Amadeus* määratlus ja tutvustatakse selle põhifunktsioone. Antakse ülevaade skeemteksti mudelist ja skeemtöötluse eesmärgist.

Kolmandas peatükis kirjeldatakse üldist põhimõtet, kuidas süsteemis *Amadeus* mingi antud lähtekeele *LK* jaoks luuakse skeemisti, st. konverter keelest *LK* skeemkeelde *SK*, lähtudes keele *LK* grammatikast. Lihtsa näitekeele – metsa vasaku suluesituse keele (*VSE*) – najal kirjeldatakse uue baaskeele lisamise protsessi, eeskätt spetsifitseeritakse kaasnevad tegevused ning nende järjekord.

Väitekirja neljandas peatükis esitatakse ülevaade peamistest süsteemile *AmadeusJSN* omastest, uude versiooni lisandunud tehnilistest lahendustest. Selgitatakse, kuidas on automatiseeritud baaskeeltega manipuleerimine (uue baaskeele lisamine, olemasoleva kustutamine, kustutatud baaskeele taastamine). Grammatikafaili iteratiivse arendamise toeks spetsifitseeritakse vastav projektikirjeldus. Peatüki lõpus tutvustatakse lähemalt uue süsteemiversiooni testimist näitekeelte *VSE* ja *PSE* (metsa parem suluesitus) baasil.

Lisades paiknevad mitmesugused skeemkujul koodiosad ning muud tehnilisemat laadi andmed. Viimases lisas (CD andmekandjal) leidub kogu uus süsteem *AmadeusJSN* koos käesoleva magistritöö e-koopiaga.

Väitekirja on kirjutatud ja vormistatud süsteemide *Amadeus* ja L^AT_EX abil.

Peatükk 1

Konverteerimine ja konverteriarendus

Käesolevas peatükis selgitatakse tarkvara konverteerimise mõistet. Tutvustatakse mõningaid olemasolevaid konverteerimise süsteeme. Püstitatakse ja konkretiseeritakse konverterite loomise automatiseerimise probleem ning esitatakse selle lahendamise üldine idee.

1.1 Konverteerimise mõiste määratlus

Kõige üldisemas mõttes tähendab tarkvara konverteerimine mingitele tarkvaralistele lähteobjektidele uue vormi andmist. Antud töös piirdume tekstiliste objektidega, nn. arvutitekstidega [1]. Seega konverteeritavateks olemiteks on tekstid mingis lähtekeeles (LK) ja tulemusteks tekstid mingis sihtkeeles (SK). Konkreetne, teatud liiki konverteerimine on funktsioon $LK \rightarrow SK$. Konverteerimine (kui eeskätt vormi muundamine) on transleerimine kitsamas tähenduses: teisendatakse ainult teatavaid kõrgema taseme struktuure (programmeerimise keele puhul nt. juhtimiskonstruktsioonide kuju), jättes primitiivsemad konstruktsioonid (nt. avaldised) muutmata.

Konverteerimise liigi ehk tüübi määrab vastav reeglistik. Lähtekeele teksti (teatavat liiki) konverteerimine tähendab selle teisendamist teise vormi vastavalt (teatavale) konverteerimisreeglite hulgale. Konverteerimisreeglid defineerivad, kuidas ja kus kohas sihttekstis paigutuvad lähteprimitiivid. On mõist-

lik vaadelda iga konverteerimisreeglite hulka (vastavat liiki) konverteerimise mudelina. Seega konverteerimise meetod on määratud lähtekeele, sihtkeele ja konverteerimise mudeliga. Kuna konverteerimine tähendab lihtsalt formaadi/kuju muutmist, siis mõlematel, nii lähte- kui ka sihtkeelel, on ühed ja samad primitiivid. Mõnel juhul defineerib mudel kahepoolse konverteerimise: nii lähtekeelest sihtkeelde kui ka vastupidi.

Käesoleval ajal on üheks populaarsemaks konverteerimise liigiks tekstide teisendamine *XML* kujule (üldnimetus ingl. k. *Some-to-XML*): ühe või teise keele tekste "kodeeritakse" *XML* konstruktsioonidena (näiteks *Java-to-XML* [11], *Flat-to-XML* [9]). Efektivsemad konverterid töötlevad grammatiliselt keerukamaid lähtekeeli. Mõned lihtsamad konverterid aga seavad lähtekeelele küllaltki suuri kitsendusi; tüüpnäiteks võib tuua nõude, et lähteandmed oleksid kujutatud nn. *CSV* (*comma separated*) väärtuste väljadena. Ilmselt sellised piirangud ei ole vastuvõetavad paljude tavaliste tarkvarastruktuuride korral.

Some-to-XML tüüpi konverteerimine kombinatsioonis *XML-to-Some* tüüpi konverteerimisega annab konverteerimise tüüpi *Some-to-Some*. Tuleb tähele panna, et just *XML* kasutamine vahepealse sihtkeelena mõnedes *Some-to-Some* konverterites ei ole hädavajalik. Alternatiivselt võib *XML* asemel kasutada ka mõnda muud "vahekeelt" või loobuda üldse vahekeelest ning vahetult realiseerida vajalik *Some-to-Some* konverter.

Leidub ka *Any-to-Some* tüüpi konverteerimise süsteeme, mis on võimelised töötama mitme erineva lähtekeelelega.

1.2 Konverteerimise süsteemide näiteid

1.2.1 *DEL*

Korporatsioonis *Republica Corp.* on välja töötatud *Any-to-XML* konverteerimise tehnoloogia, mille aluseks on spetsiaalne andmete ekstraheerimise keel *DEL* (*Data Extraction Language*) [10]. Keel *DEL* on *XML*-põhine ning kirjeldab andmete konverteerimise protsessi teistest andmeformaatidest *XML* kujule. *DEL* skript spetsifitseerib, kuidas paigutada ja eraldada sisendandmete fragmente ja kuhu kohta on neid vaja lisada *XML* tulemusfailis. *DEL* protses-

sori *DEL* skriptile rakendamise tulemusel ekstraheeritakse lähtetekstist andmeid, mida võib kasutada nii uue *XML* dokumendi loomiseks kui ka juba olemasoleva *XML* dokumendi modifitseerimiseks. Uued elemendid ja atribuudid lisatakse kohtadesse, mis on määratud *XPath*¹ avaldistega. *DEL* skript koos algandmetega antakse ette *DEL* protsessorile, mis teeb tegeliku andmete konverteerimise vastavalt skriptile. *DEL* protsessori väljundiks on trimmis (*well-formed*) [15] *XML* dokument, mis sisaldab soovitud viisil paigutatud algandmete (lähteteksti) fragmente. Andmefragmentide paigutamine tulemusse võib toimuda ka mallide otsimise ja regulaaravaldiste sobitamise teel. Väljaeraldatud andmefragmendid paiknevad ajutiselt *DEL* protsessori registrites (magasinides), neid saab kas kustutada või võimalusel uuesti kasutada otsimismallina. Üldiselt loetakse aga andmed registritest ja paigutatakse vastavatesse asukohtadesse *XML* tulemusdokumendi *DOM*² puusse. *XML* dokumendi andmete paigutamise kirjeldamist hõlbustab kursori funktsioon (jooksva positsiooni lokaliseerimiseks).

Järgnevas esitame *DEL* skripti kasutamise näite. Olgu antud reeglistik (punkt 1 alljärgnevas) ekstraheerimaks andmeid tavalisest *HTML* dokumendist (2). Sel korral saadakse tulemuseks *XML* fail (3).

1. *DEL* skript sisaldab järgmisi elemente:

- *DEL* skripti juurelemendiks on element nimega *wrapper*.
- Järgmised *map* elemendid loovad juurelemendi nimega *root* ja alamelemendi *description*. Kolmas element *map* lisab veel alamelemendi *Extracted data*.

```
<map maptype="createDocument" node="root"/>
<map maptype="createElement" node="description"/>
<map maptype="createTextNode" node="Extracted data"/>
```

- Järgmine element *extract* eraldab sisendandmetest andmeid alates elemendist *<table>*

¹*XPath* põhiline eesmärk on *XML* dokumendi osade adresseerimine [10].

²*Document Object Model* – programmeerimise rakendusliides valiidses *HTML* ja trimmis *XML* dokumentide jaoks, mis defineerib dokumendi loogilise struktuuri ning dokumendi manipuleerimise ja ligipääsu võtted [10].

- ```
<extract exptype="over" expression="< table >"/>
kuni elemendini </table>.
```
- ```
<extract exptype="upto" expression="&lt;/table &gt; ">
```
- Element *repeat* kordab *DEL* skripti sisemisi elemente nii palju kor-
di, kui on võimalik.

```
<repeat times="*">
```
 - Järgmisena element *extract* eraldab sisendandmetest andmeid
esialgu üle *<tr>*, siis üle *<td>* kuni " < ". Kolmas element salves-
tab eraldatud andmeid magasinini.

```
<extract exptype="over" expression="&lt; tr &gt;"/>
<extract exptype="over" expression="&lt; td &gt;"/>
<extract exptype="upto" expression="&lt; " save="stack"/>
```
 - Pärast seda esimene *map* element liigub kursori juurelemendile
(*/root*) ja loob elemendi *row* ja *field1* ning sisu paigutatakse ma-
gasini.

```
<map maptype="moveCursor" node="/root"/>
<map maptype="createElement" node="row"/>
<map maptype="createElement" node="field1"
content="stack"/>
```
 - *Map* element nihutab jooksva kursori positsiooni ühe taseme võrra
ülespoole.

```
<map maptype="moveCursor" node=".." />
```
 - Esimene element *extract* eraldab sisendandmetest andmeid, alates
" <td> " kuni " < ". Teine element salvestab eraldatud andmeid re-
gistrisse *reg1*.

```
<extract exptype="over" expression="&lt;td&gt;"/>
<extract exptype="upto" expression="&lt; " save="reg1"/>
```
 - Järgmine *map* element loob elemendi *field2* ja paneb registri 1 sisu
sinna

```
<map maptype="createElement" node="field2"
content="reg1"/>.
```

- *Test* element kontrollib väärtuse "4" võrdsust registri 1 väärtustega. Kui väärtused on võrdsed, siis *map* element loob uue atribuudi nimega *test* ja väärtusega "*success*".

```
<test testtype="equal" value1="4" value2="reg1">
  <map maptype="createAttribute" node="test"
    content="success"/>
</test>
</repeat>
</extract>
</wrapper>
```

2. Lihtsa *HTML* dokumendi näide:

```
<html>
<body>
<p>Test Material</p>
<table>
<tr><td>Some numbers</td><td>Other numbers</td></tr>
<tr><td>1</td><td>2</td></tr>
<tr><td>3</td><td>4</td></tr>
</table>
</body>
</html>
```

3. *XML* väljund 2. punkti *HTML* dokumendi korral vastavalt 1. punkti *DEL* skripti reeglitele:

```
<?xml version="1.0" encoding="ISO-8859-1"?>
<root>
<description>Extracted data</description>
<row> <field1>Some numbers</field1>
<field2>Other numbers</field2>
</row>
<row>
<field1>1</field1>
<field2>2</field2>
</row>
```

```

<row>
<field1>3</field1>
<field2 test="success">4</field2>
</row>
</root>

```

Kokkuvõttes, keel *DEL* on sisuliselt konverterite programmeerimise (küllaltki keeruline) keel. Iga uue konkreetse lähtekeele/mudeli korral tuleb koostada vastav konverteerimise eeskiri *DEL* skripti kujul.

1.2.2 *XFlat* ja *XML Convert*

XML vorm on muutumas prevaleerivaks mitmesuguste rakenduste andmete saatmisel brauseritesse ja ärirakendustesse. Rõhutatakse (nt. [9]), et *XML* on selleks väga sobiv, sest *XML* dokumendid on isekirjelduvad (*self-describing*); nende parsimine¹ on lihtne, samas aga saab sel viisil kirjeldada väga keerulise struktuuriga andmeid. Loomulikult peab *XML*-põhise andmevahetuse (*interchange*) korral saatja-rakendus olema võimeline *XML* dokumendi eksportimiseks ja saaja-rakendus olema võimeline *XML* dokumendi importimiseks. Paljud vanemad rakendused aga kasutavad andmete eksportimiseks ja importimiseks nn. lamefaile (*flat* faile). Nende liidestamisel *XML*-oriendatud rakendustega tekib vajadus lamefailide konverteerimiseks *XML* dokumentideks, ja vastupidi.

***Flat* failid**

Flat failis (ehk lamefailis) on andmed organiseeritud kindla lihtsa andmesituse grammatika kohaselt, kusjuures andmed on harilikult kodeeritud üksnes prinditavate märkide (nn. tärkide) abil.

Lamefail koosneb tavaliselt kirjade ehk ridade seeriast, kus iga kirje on väljade järjend. Väli sisaldab atomaarseid (edasiselt struktureerimata) andmeid. Nii kirjed kui ka väljad eraldatakse üksteisest spetsiaalsete tärkidega – eraldajatega.

Lamefaili näiteks võib tuua isikuandmete *flat* faili, mis sisaldab ühe või mitme isiku andmeid. Iga kirje esitab järgmisi andmeid:

¹Käesolevas kasutame termini *süntaksanalüüs* asemel ka lühemat sünonüümi *parsimine*.

- isikukood;
- isiku täisnimi jutumärkides (eesnimi on eraldatud perenimest komaga ja sellele järgneva tühikuga);
- isiku palk.

Üks konkreetne isikute lamefail võiks siis välja näha järgmiselt:

```
41212122233, "Carr, Lisa", 10000.00
36012122233, "Barr, Clark", 15000.00
47712122233, "Breaks, Tony", 7100.00
```

Iga kirje sisaldab ühe isiku andmeid. Antud juhul on tegemist nn. *CSV* formaadis andmetega, kuna kirjete eraldajaks on reavahetus ja väljade eraldajaks on koma (kui tühikut mitte arvestada).

Lamefaili struktuur ei pruugi alati olla *CSV*-tüüpi. Keerulisem näide lamefailist: faili struktuur määratletakse sarnaselt *Windows* konfigureerimis-
sättingute failiga (nt. fail *win.ini*). Järgnev näitefail esitab kontaktide nimekirja:

```
[contact]
name=Lisa Carr
email=lisa.carr@hotmail.com
phone=(+372) 555-9328
[contact]
email=barr.clark@yahoo.com
name=Clark Barr
[contact]
phone=(+372) 555-3249
name=Tony Breaks
email=tonyb@bluesuburbanskies.com
```

Iga kontakti kirje algab võtmesõnaga `[contact]` ja sisaldab kolm mitte-kohustuslikku parameetrit:

- `name = <isiku nimi>`

- `email` = <isiku e-posti aadress>
- `phone` = <isiku telefoninumber>

Kirjete eraldajaks on reavahetus. ”Lamedus” antud kontekstis tähendab seda, et fail ei ole indekseeritud ja puudub kirjete hierarhiline struktuur (kirje ei saa paikneda kirjes).

Lamefailide formaadivalik ei piirdu kaugeltki kahe ülaltooduga. Lamefaili soovikohaseid formaate defineeritakse *XFlat* keele abil.

***XFlat* keel**

XFlat on *XML*-põhine keel lamefailide formaati kirjeldavate skeemide (*XML schemas*) defineerimiseks. *XFlat* skeem on *XML* dokument, mis on vastavuses *XFlat* keelega ja kirjeldab *flat* failide klassi formaati. *XFlat* skeemiga saab defineerida sellise lamefaili klassi struktuuri ja süntaksi, mis ise ei sisalda *XML* andmeid. Samuti defineerib *XFlat* skeem *XFlat* isendite klassi struktuuri ja süntaksi. *XFlat* isend on *XML* dokument, mille struktuur on sama, mis *flat* failis ja mille andmed on samad, mis on *flat* faili andmed. *XML* konverter (*XML Convert*), mis on loodud firmas *Unidex*, kasutab *XFlat* skeeme *flat* failide teisendamiseks *XFlat* isenditeks ja vastupidi.

XFlat skeem sisaldab vajalikku informatsiooni vastavas formaadis lamefaili konverteerimiseks *XML* kujule ja vastupidi. *XFlat* on deklaratiivne keel, seetõttu isegi mitteprogrameerija, kes on tuttav *flat* failidega, võib samuti *XFlat* skeeme luua.

Ülaltoodud isikute lamefaili struktuuri kirjeldus *XFlat* skeemina on esitatud joonisel 1.1, kus

`XFlat` on (kohustuslikuks) juurelemediks,
`SequenceDef` on objektide jada näitamiseks,
`RecordDef` on kirjete defineerimiseks,
`FieldDef` on väljade defineerimiseks.

XML Convert

XML Convert on *Java* rakendus, mis kasutab *XFlat*-keelseid skeeme lamefailide konverteerimiseks *XML* dokumentideks (ja vastupidi), teisendades lamefaile ühest formaadist teise. *XML Convert* toetab suurt hulka andme-

```

<?xml version="1.0" ?>
- <XFlat Name="employees_schema" Description="Schema for CSV flat file">
- <SequenceDef Name="employees" Description="employees flat file">
- <RecordDef Name="employee" FieldSep="," RecSep="\n" MaxOccur="0">
  <FieldDef Name="ssn" NullAllowed="No" MinFieldLength="9"
    MaxFieldLength="11" DataType="Integer" MinValue="0"
    QuotedValue="Yes" />
  <FieldDef Name="name" NullAllowed="No" QuotedValue="Yes" />
  <FieldDef Name="salary" NullAllowed="No" DataType="Float" MinValue="0"
    QuotedValue="Yes" />
</RecordDef>
</SequenceDef>
</XFlat>

```

Joonis 1.1: Isikute lamefaili struktuuri kirjeldus keeles *XFlat*.

formaate, selliseid nagu *CSV*, fikseeritud pikkusega kirjed ja väljad, kirjete grupp, pesastatud grupid jm. *XML Convert* sooritab ka valiidsuskontrolli: enne tegelikku konverteerimist tehakse kindalaks lähtefaili andmete struktuuri ja väljade tüüpide vastavus *XFlat* skeemile. Kui fail ei läbi sellist kontrolli edukalt, siis konverteerimist ei sooritata (lähtefail lükatakse tagasi). Sellise kontrolliga minimiseeritakse võimalus, et vale struktuuriga/andmetega *XML* dokument saadetakse/importitakse rakendustesse.

Kasutades *XFlat* skeemi (joonisel 1.1) konverteerib *XML Convert* ülalpool toodud konkreetse isikute lamefaili *XML* dokumendiks, mis on toodud joonisel 1.2.

Süsteemi *XML Convert* rakendatavus piirdub kirje-väli tüüpi struktuuriga lähtetekstidega.

1.2.3 *LinkGrammar*

Link grammatika (*LinkGrammar*, *LG*) [12] on *Carnegie Mellon*i ülikoolis välja töötatud formalism, milles lause süntaktiline struktuur esitatakse seoste huljana (*linkage*). *Link* grammatika koosneb sõnade hulgast (grammatika terminaalised sümbolid), kus igaühel on olemas seose nõue (*linking requirement*). Sõnade jada on *LG* keele lause siis, kui sõnade vahel on võimalik joonistada seoseid (*links*) nii, et oleksid rahuldatud järgmiseid nõuded:

```

<?xml version="1.0" ?>
- <employees>
- <employee>
  <ssn>123456789</ssn>
  <name>Carr, Lisa</name>
  <salary>100000.00</salary>
</employee>
- <employee>
  <ssn>444556666</ssn>
  <name>Barr, Clark</name>
  <salary>87000.00</salary>
</employee>
- <employee>
  <ssn>777227878</ssn>
  <name>Parr, Jack</name>
  <salary>123000.00</salary>
</employee>
- <employee>
  <ssn>998877665</ssn>
  <name>Charr, Lee</name>
  <salary>92000.00</salary>
</employee>
</employees>

```


Joonis 1.2: *XML Convert* töö tulemuse näide.

1. Planaarsus. Seosejooned ei lõiku, kui need joonistada sõnade kohale.
2. Sidusus. Seosed ühendavad kõiki sõnu omavahel.
3. Sobivus. Kõik sõnad lauses rahuldavad omavahel ühendumist piiravaid kitsendusi.

Lause võib olla *LG* jaoks ka mitmene – juhul, kui leidub rohkem kui üks tingimusi täitev seoste hulk. Sellise olukorra tekitab näiteks asjaolu, kus ühte sõna on võimalik tõlgendada nii verbi kui noomenina ja mõlemal puhul on seostetingimused täidetud.

Näide:

Toodud näites esinevad D-, S- ning O-tüüpi seosed. Igaüks ühendab parajasti kahte sõna:



1. D-seos ühendab artikleid nimisõnadega.
2. S-seos ühendab nimisõnu finiitsete verbidega.
3. O-seos ühendab transitiivseid verbe laienditega.

Seose tüüpi täpsustavad väiketähed. Näiteks s ja p näitavad nimisõna-verbi ühildumist (vastavalt ainsus ja mitmus), c märgib loendatavust.

LG olulisem komponent on sõnastik (*Dictionary*), mis peale sõnade esitab ka sõnade ühildumist kirjeldavad kitsendused. Reeglistikus on esitatud sõna koos seostega, mida ta võib luua kas vasakule (-) või paremale (+). Näiteks nimisõna *cat* tohib olla D-seose paremal pool ja S-seose vasakul pool, aga mitte O-seose vasakul pool. Tabelis on sõnadele antud ka seose esinemise tingimu-

sõna	Seosed
a the	D+
ran	S-
Mary John	O- or S+
chased	S- & O+
snake cat	D- & (O- or S+)

sed, samuti on tähistatud see, kas mingi seose esinemine on kohustuslik või mitte. *LG*-s on suuremad sõnagrupid koondatud nn. *words*-failidesse, seoste komplekt antakse kogu faili kohta. Nii näiteks moodustavad omaette failid transitiivsed verbid, intransitiivsed verbid, loendatavad nimisõnad, loendamatud nimisõnad. Antud formalismi raames töötava süsteemi grammatika kirjeldamise ja loomise lihtsus lubab teda kasutada reaalsete süsteemide prototüüpide loomiseks.

Konverteerimine tähendab siin iga antud *LG*-lause puuks teisendamist, kus sõnade kui lehtede kohale on ehitatud vastav seoste hierarhia. Antud juhul on tegemist konverteerimise näitega, kus vormiliselt lihtsa teisenduse taga peitub väga keerukas (lingvistiline) töötlus.

1.3 Konverterite loomise automatiseerimisest

1.3.1 Probleemi püstitus

Üha suurenev vajadus erinevat tüüpi konverterite järele on tõstatanud loomuliku küsimuse, kuidas automatiseerida konverterite loomist. Muidugi on soovitatav luua võimalikult üldist tüüpi konvertereid. Kõige ideaalsem oleks üks universaalne konverter tüüpi *Any-to-Any*. Nii üldisel kujul püstitatud ülesanne oleks ilmselt lahendamatu, kuid peale probleemi mõistlikku kitsendamist saab astuda olulisi reaalseid samme konverteriarenduse automatiseerimiseks.

Probleemi võib sõnastada järgmiselt: on antud lähtekeel, sihtkeel ja konverteerimise mudel, ülesandeks on automaatselt genereerida vastav konverter.

Käesolevas aga piirdume tegelikult veelgi enam lihtsustatud ülesandega – sellisega, kus sihtkeel on fikseeritud. Osutub, et sel juhul polegi vaja iga lähtekeele jaoks oma konverterit. Lähtekeelte (grammatikate) teatavale eeltöötlusele tuginedes saab piirduda vaid ühe konverteriga, mis vastavalt mudelile teisendab suvalise lähtekeelse teksti vajaliku kujuga sihtkeelseks tekstiks.

Käesolevas töös välja töötatud lähenemisviis on küll piiratud sihtkeele fikseeritusega, kuid teiselt poolt iseloomustab seda universaalsus lähtekeelte pere osas: ainsaks nõudeks lähtekeelele on selle formaalse grammatika olemasolu.

1.3.2 Grammatika-põhise konverteriarenduse printsiip

Olgu SK fikseeritud sihtkeel ja $LK_1, LK_2, \dots, LK_n$ mingi lähtekeelte pere, mille jaoks on tarvis konvertereid $LK_i \rightarrow SK (i = 1, 2, \dots, n)$.

Põhimõtteliselt tuleb kõne alla (suhteliselt ebaefektiivne) tee: iga i ja mudeli M_i korral ($i = 1, 2, \dots, n$) luua (programmeerida) konverter $convert_i()$:

$$convert_i(LK_i tekst) \rightarrow SK tekst$$

või siis pisut üldisem $convert'_i()$, kus antakse lähtekeelne tekst koos mudeliga:

$$convert'_i(LK_i tekst, M_i) \rightarrow SK tekst.$$

Nii või teisiti, loodavad konverterid peavad sisaldama ka keele LK_i tekstide süntaksanalüüsi moodulit. Tegelikult oleks praktikas ka vajalik ühe baaskeele korral käsitleda mitte ühte vaid mitmeid varieeritud mudeleid.

Käesolevas töös välja töötatud konverteriarenduse süsteemi aluseks on idee, et tarvilik on vaid üks, teatavas mõttes universaalne konverter. Nimelt, kui fikseerida antud lähtekeelte pere korral süntaksanalüüsi puude (ehk parsipuude) esitamise keel PK , siis ainsaks tarvilikuks konverteriks osutub konverter tüüpi $PK \rightarrow SK$, mis suvalise parsipuu teisendab sihtkeelseks tekstiks vastavalt etteantud mudelile. Mudel on loomulikult sõltuv konkreetsest lähtekeelest (LK_i), esitades konkreetse konverteerimise reeglistiku. Iga lähtekeele LK_i jaoks peab olema loodud vastav süntaksanalüsaator $Parser_i()$:

$Parser_i(LK_i tekst) \rightarrow parsipuu.$

Lakooniliselt võib siis kirjeldatud konverteerimise protsessi esitada kujul

- - - $t \in LK_i$

$parsipuu := Parser_i(t)$

$t' := converter(parsipuu, M)$

- - - $t' \in SK$; t' on teksti t konverteerimise tulemus vastavalt mudelile M

Niisuguse lähenemise eelised on järgmised.

1. Lähtekeelte pere on avatud. Uue lähtekeele kasutusele võtmiseks on vaja luua vaid selle keele süntaksanalüsaator ehk parser. Viimane tegevus on automatiseeritav, nõudes ainult grammatika piisavalt täpset kirjeldamist.
2. Võimalike lähtekeelte valik on väga lai, kuna ainukeseks nõudeks on formaalselt kirjeldatud grammatika olemasolu.
3. Uue lähtekeele lisamine ei nõua programmeerimistööd (konverteri programmeerimist). Vajalik on esitada vaid mudeli(te) kirjeldus(ed).
4. Mudelite kirjeldamine on lihtne, võimaldades kasutajal hõlpsasti katsetada paljude mudelivariantidega ühe ja sama lähtekeele korral.

Uue lähtekeele lisamisel osutub kõige töömahukamaks lähtekeele grammatika viimine parseri genereerimiseks nõutavale kujule. Selle juures võib lihtkasutajal tarvis minna vastava spetsialisti abi.

Peatükk 2

Süsteem *Amadeus* kui konverteriarenduse platvorm

2.1 Süsteemi *Amadeus* üldiseloostus

Amadeus [1][3] on *Java* keelel põhinev mitmevaateline, mitmekeelne, üldotstarbeline süsteem arvutitekstide¹, näiteks programmitextide, L^AT_EX dokumentide, *HTML* ja *XML* tekstide ning teiste tarkvaradokumentide käsitlemiseks. Projekti *Amadeus* algseks eesmärgiks oli nii tekstilise kui ka graafilise toimetamise ühendamine programmkoodi käsitlemiseks. Uuematesse versioonidesse on lisandunud mitmeid üldisemaid võimalusi.

Amadeus toetab arvutitekstide graafilist esitamist ja nende toimetamist. Toimetatavad tekstid esitatakse nn. skeemtekstidena, milles primitiivsemad (lihttekstilised) osad on ühendatud nn. skeemidesse. Skeemid kuvatakse kasutajaekraanile graafiliste konstruktsioonidena. Viimaste tegeliku graafilise "väljanägemise" määrab parajasti kasutatav vaade (mis on kasutaja poolt valitav). Süsteemi graafilisus tähendab eeskätt seda, et on võimalik toimetada mitte ainult lihttekstilist osa, vaid ka suuremaid terviklikke graafilisi konstruktsioone. Niisiis, käsitletava teksti jämedstruktuur kirjeldatakse plokkidena (skeemidena), mis sisaldavad primitiividena ka tekstilisi elemente, nagu lihtsad andmed, kommentaarid, lihtsamad laused, avaldised ja tingimused.

¹Arvutiteksti (tarkvaradokumendi) all mõistame sellist teksti-põhist infot, mida käsitlevad nii inimesed kui ka arvutid.

Amadeus töötab nii *Windows* kui ka *Unix* platvormidel. Suhtlemiseks saab valida inglise, eesti või vene keele. Järgnevates näidetes kasutatakse siiski inglisekeelseid menüüvalikute nimetusi.

2.2 Skeemteksti mudel ja skeemtöötlus

Skeemtöötluse eesmärgiks on viia süntaktiliselt erinevad arvutitekstid ühisele alusele – üldisele skeemmodelile. Skeemteksti mudel annab teatava meetodika arvutiteksti struktuuri konstrueerimiseks, kasutades lihtsamaid tekstiüksusi elementaarsete ehitusplokkidena. Sel moel konstrueeritud teksti nimetatakse *skeemtekstiks*. Suvaline skeemtekst saadakse tekstiüksuste korraldamisel puukujuliseks struktuuriks, mida nimetatakse *skeempuuks* ning milles teksti lihtsamad osad esinevad puu tippude tekst-atribuutidena.


Täpsemalt, *skeempuu* on paar $\langle T, A \rangle$, kus A on noolte hulk ja T on mittetühi puu järgmiste omadustega:

- on olemas kolme liiki tipp: skeemtipp ehk skeem (*sketch*), harutipp ehk haru (*branch*) ja primitiivitipp ehk primitiiv (*primitive*);
- T juureks on skeem;
- skeemi järglasteks võivad olla harud, harude järglasteks on primitiivid või skeemid ning primitiividel ei ole järglasi;
- igal skeemil on päis (*head*) – primitiivpäiste (*primitive head*) ehk elementaarpäiste järjend (erijuhul tühi).

Ühe haruga skeemi nimetatakse *monoskeemiks*.

Joonisel 2.1 on toodud näide, kuidas võiks välja näha abstraktne skeempuu ning vastava struktuuriga skeemtekst. Kõrvuti tavapärase puuvaatega (a) on kasutatud skeemvaadet (b). Viimane on intuitiivselt küllaltki hästi arusaadav ja ka toimetamise seisukohast ning paigutuse poolest mugavam kui puuvaade.

Süsteemis *Amadeus* esitatakse jooksvad arvutitekstid skeemtekstidena, kusjuures algteksti lihtsasad on skeemteksti puu tippude atribuutideks. Need



Joonis 2.1: Skeempuu graafileine esitus (a) ja esitus skeemides (b).

tekstiüksused ei ole piiratud puhttekstilise kujuga, põhimõtteliselt võimaldatakse ka piltide või omakorda skeemtekstide kasutamist reasümbolitena.

Joonis 2.2 kirjeldab BNF (*Backus-Nauri* notatsiooni) abil skeemteksti täpsemat süntaksit.

Skeemteksti vaade (kuvakuju) ei ole jäigalt fikseeritud: seades vastava atribuudi, saab skeemtekstile omistada suvalise vaate olemasolevate vaadete hulgast. Süsteemis *Amadeus* on skeemtekst *WYSIWYG*-toimetatav igas vaates. Kõrvuti tavalise teksti toimetamisteisendustega (primitiivide jaoks) toetab *Amadeus* ka toimetamistegevusi skeemide ja primitiivide käsitlemiseks (lisamine, kustutamine, tüübi muutmine jne.) tervikuna.

Kuvatava teksti baaskeel määratakse skeemtekstide korral vastava atribuudi abil. *Baaskeel* on keel, mille grammatika kirjeldab skeemtekstile vastavat lihtteksti.

```

skeemtekst :: = skeem »
kavand :: = skeem | haru»
skeem :: = skeemi_keha kavandi_atribuudid»
skeemi_keha :: = (haru)»
haru :: = haru_keha kavandi_atribuudid»
haru_keha :: = (liige)*»
liige :: = skeem | primitiivliige»
primitiivliige :: = primitiiv | nool»
primitiiv :: = tüüp primitiivtekst»
nool :: = primitiiv lõputase»
lõputase :: = non-negative_integer»
tüüp :: = non-negative_integer»
primitiivtekst :: = (rida)* kommentaar»
kommentaar :: = rida»
rida :: = (rea_element)»
rea_element :: = sümbol | hüpersümbol»
sümbol :: = character font color»
hüpersümbol :: = pilt | hüperelement»
pilt :: = ikoniseeritus image»
hüperelement :: = skeemtekst»
kavandi_atribuudid :: = tüüp kommentaar päis
ikoniseeritus view base_language »
päis :: = (primitiiv_päis)*»
primitiiv_päis :: = primitiiv»
ikoniseeritus :: = true| false»

```

Joonis 2.2: Skeemteksti süntaksi kirjeldus.

Võrreldes tavatoimetitega pakub süsteem *Amadeus* arvutitekstide mugavama, skeemkujul toimetamise võimaluse. Muuseas on loomuliku funktsioonina kasutatav ka teksti voltimine (*code folding* – programmide korral). Suvalist skeemi saab vabalt valida (hiire vasakpoolsele nupule klõpsates) ja ikoniseeri-

da/deikoniseerida (hiire parempoolsele nupule klõpsates). Samuti on lubatud valitud skeemi aktiivses aknas skeemistada, tekstualiseerida või redutseerida, kasutades vastavaid meetodeid, mis sõltuvad valitud baaskeelest.

Käesolevas vaadeldava konverteerimisküsimuse seisukohalt on väga oluline, et süsteemile *Amadeus* on seesiselt omane tekstide teisendamise protsess. Tegelikult kuulub süsteemi mitte üks skeemisti, vaid iga aktsepteeritava baaskeelega jaoks leidub vastav spetsiifiline skeemisti. Sama kehtib ka tekstualiseerijate kohta (vt. joonis 2.3). Süsteemi *Amadeus* kui multitoimeti seisukohalt on skeemistid ja tekstualiseerijad hädavajalikud vahendid "lihttekstide maailmaga" sideme pidamiseks.

Nii skeemistid kui ka tekstualiseerijad on sisuliselt eriotstarbelised konverterid. Selles mõttes võib süsteemi *Amadeus* vaadelda teatava konverteerimisplatvormina. Näiteks saame konverteri keelest $L1$ keelde $L2$, kui lisame süsteemi *Amadeus* skeemisti

$$L1 \rightarrow \{skeemtekst\}$$

ja tekstualiseerija


$$\{skeemtekst\} \rightarrow L2.$$

Lisaks säilib mugav võimalus toimetada "vahekuju" – skeemteksti.

2.3 Skeemistamine ja tekstualiseerimine

Süsteemi *Amadeus* kõik need funktsioonid, mis sõltuvad jooksva (toimetatava) skeemteksti baaskeelest, on koondatud menüüvaliku *Tools* alla. Alamvalikute loetelu on järgmine:

- Skeemistamine (*Tools + Sketchify*) – jooksva lihtteksti (reastruktuuriga teksti) viimine skeemkujule ja tulemuse kuvamine uues aknas.
- Parsimine (*Tools + Parse*) – jooksva lihtteksti parsimine; tulemuseks on parsipuu skeemkujul (uues aknas).
- Tekstualiseerimine (*Tools + Textualize*) – jooksva skeemteksti teisendamine lihttekstiks (uues aknas).
- Redutseerimine (*Tools + Reduce*) – jooksva skeemteksti eriteisendus jooksvas aknas.



Joonis 2.3: Teksti töötlemine tavatoimetiga (a) ja skeemtoimetiga (b).

- Normaliseerimine (*Tools + Normalize*) – jooksva skeemteksti eriteisendus uude aknasse.
- Trükivalmistus (*Tools + Prepare TeX*) – jooksva skeemteksti ettevalmistamine (uude aknasse) $\text{\TeX}$ või $\text{\LaTeX}$ abil printimiseks, peamiselt erisümbolite asendamine vastavate $\text{\TeX}$ -fragmentidega.

Funktsioonide ülaltoodud selgitused on pisut lihtsustatud: üldiselt teisendatakse jooksva skeemteksti (hiireklõpsuga) valitud osa, selgitustes on aga eeldatud, et valitud on kogu jooksev skeemtekst. Parsimise funktsioon on lisatud *Amadeus* lähteversioonile käesoleva töö käigus. Eriteisenduste tähendus ei ole fikseeritud, nende spetsiifikat võib iga baaskeeles suvaliselt määrata.

Märgime, et jooksev lihttekst kujutub *Amadeus* aknas monoskeemina, mille ainukese haru kõik liikmed on (kommenteerimata tekstiga) primitiivid. Lihttekst sisestatakse tavalisest tekstifailist menüükäsuga *File + Read text* ja salvestatakse tavafaili menüükäsuga *File + Write text*.

Süsteemis *Amadeus* realiseeritakse iga baaskeel *Java* klassina, mis pärineb ülemklassist *BaseLanguage* ja realiseerib muuhulgas selle (abstraktsed)

meetodid *sketchify()* ning *textualize()*. Nimetatud meetodid rakenduvad vastavate menüüvalikute käivitamisel, nende poolt sooritatavad tegevused on aga sisuliselt konverteerimised.

Kui nt. klass *BaseLanguageLK_i* realiseerib baaskeeke LK_i , siis selle meetod *sketchify()* on konverter tüüpi $LK_i \rightarrow SK$, kus SK on skeemtekstide esitamise keel, ja meetod *textualize()* on konverter tüüpi $SK \rightarrow LK_i$. Mõlemate puhul on konverteerimise mudel nõ. sisse ehitatud (fikseeritud).

Süsteemi *Amadeus* lähteversioonis (nimetusega *AmadeusJS*) olid juba realiseeritud nt. keeled *Java*, *HTML*, *LATEX*, mille konversioonimudelid on täpsemalt kirjeldatud artiklis [2]. Nende keelte konverterid loodi nõ. käsitsi, seejuures eriti töömahukaks osutus skeemistamise meetodi (*sketchify*) realiseerimine. Käesolevas töös keskendutaksegi just skeemistuskonverterite loomise automatiseerimisele – küsimusele, kuidas uue baaskeeke LK korral võimalikult efektiivselt välja töötada vastav skeemistamise meetod, mis realiseeriks konverteri tüüpi $LK \rightarrow SK$. Vastavate automatiseerimisvahenditega täiendatud süsteemi *Amadeus* uus versioon (nimetusega *AmadeusJSN*) kujutab endast juba küllaltki efektiivset konverteriarenduse tarkvara.

Peatükk 3

Grammatika-põhine skeemisti loomine

Käesolevas peatükis kirjeldatakse üldist põhimõtet, kuidas süsteemis *Amadeus* mingi antud lähtekeele *LK* jaoks luuakse skeemisti, st. konverter keelest *LK* skeemkeelde *SK*, lähtudes keele *LK* grammatikast.

3.1 Näiteülesanne

Skeemisti loomise protsessi illustreerimiseks kasutame lähtekeele rollis väga lihtsat puu/metsa esitamise keelt *VSE*. Iga puu või mets kirjutatakse selles keeles nn. vasaku sulusesitusena [5]. Tippude nimedeks on identifikaatorid, eraldajateks aga ümarsulud ning komad.


Metsa vasak sulusesitus on

- tühi, kui mets on tühi,
- vastasel korral aga ümarsulgudesse võetud metsa puude vasakute sulusesituste loetelu (komadega eraldatult).

Mittetühja puu vasak sulusesitus koosneb juurest ja selle järgnevast juure alampuude metsa vasakust sulusesitusest.

Näiteks $(A(B,C(D,E),F),X(Y))$ on metsa vasak sulusesitus, mille graafiline esitus skeemvaates on toodud joonisel 3.1.

Ülesandeks on **luua skeemisti** – **konverter tüüpi** $VSE \rightarrow SK$, mis suvalise metsa vasaku sulusesituse teisendab skeemkujule.



Joonis 3.1: Metsa graafiline esitus.

Vaadeldud näitemetsa korral võiks skeemistamise soovitud tulemuseks olla skeemtekst joonisel 3.2. Teisendamise reegel ehk konverteerimise mudel (sõnalises vormis) olgu järgmine:

metsa iga puu T kujutatakse ühe haruga moodulskeemina¹, mille päises asub puu juur ja mille haru liikmeteks on puu T alampuid kujutavad skeemid.

Märgime, et joonisel 3.2 kujutatud struktuuriga skeemteksti saab süsteemis *Amadeus* hõlpsasti kuvada ka joonisel 3.3 näidatud viisil. Selleks tuleb vaid vaateks valida (*View + Set*) puuvaade *STree*.

3.2 Grammatika esmane spetsifitseerimine

Kui lähtekeel on valitud ja konverteerimise eemärk esialgse mudelina selgeks tehtud, järgneb lähtekeele grammatika täpsustamine. Eesmärgiks on koostada grammatika selline kirjeldus, mille alusel saaks automaatselt genereerida lähtekeele parseri. Parseri ülesandeks on lähtekeele tekstide jaoks analüüsipuude ehk parsipuude ehitamine. Kuna parseri genereerimiseks kasutatakse süsteemi *JJTree/JavaCC*, siis tuleb grammatika lõppude lõpuks esitada *JJTree* [8] sisendtekstina. Süsteem *JJTree/JavaCC* ja selle kasutusvõimalused süsteemi *Amadeus* kontekstis leiavad üksikasjalikku valgustamist A. Reitsaka magistritöös [6].

Grammatika spetsifitseerimise aluseks võetakse reeglina lähtekeele *BNF*-


¹Erinevalt lihtskeemist kuvatakse moodulskeem paksemat skeemijoont kasutades.



Joonis 3.2: Metsa esitus skeemtekstina (skeemvaates).

grammatika². Tõsi küll, üksikutel juhtudel õnnestub alustada paremast startipaigast – juba *JavaCC* vormis olevast grammatikast. Nt. mõningate tuntud keelte (enamuses – programmeerimiskeelte) *JavaCC*-grammatikad leiduvad

²Tegelikult kasutatakse küll *BNF* laiendatud vormi, kus on lubatud nt. meta-avaldised $()^*$, $()^+$, $()^?$, $[]$.



Joonis 3.3: Metsa esitus skeemtekstina (puuvaates).

vastavas repositooriumis [7] ja neid saab kasutada alusena vajaliku *JJTree*-grammatika väljatöötamisel või siis eeskujuna (struktuurilt repositooriumist saaduga sarnaneva lähtekeele korral).

Näitena vaadeldava lähtekeele *VSE* üldine *BNF*-grammatika on muidugi väga lihtne:

```
s ::= metsaVSE
metsaVSE ::= "(" puuVSE ("," puuVSE)* ")"
puuVSE ::= juur (metsaVSE)?
juur ::= IDENTIFIER
```

See spetsifikatsioon täpsustab muuhulgas ka tühja metsa küsimuse. Antud grammatika (teise produktsiooni) kohaselt ei saa mets olla tühi, selles peab leiduma vähemalt üks puu.

3.3 Grammatika spetsifitseerimine *JJTree* sisendi kujul

Grammatika spetsifitseeritakse sellisel kujul tekstifailina – nn. grammatikafailina, millest töötlusvahendite *JJTree* ja *JavaCC* järjestikuse rakendamisel, saadakse parser lähtekeele jaoks.

Loodav grammatikafail koosneb kahest osast. Esimene osa on standardne (vaadeldavas kontekstis) ja kujutab endast parseri töö üldist *Java* vormis esitatud algoritmi. Teine osa on grammatika kirjeldus *JJTree/JavaCC* vormis [6], mis struktuurilt on samuti väga lähedane *Java*-tekstide keelele. Teiselt poolt, lähtegrammatikas sisalduvad produktsioonid esituvad grammatikafailis küllaltki *BNF*-produktsioonidega sarnaneval kujul.

Järgnevalt (lk. 32 - 35) on esitatud meie näitekeele *VSE* grammatikafaili (skeemkujul). Tänu sellele, et süsteemi *Amadeus* on juba integreeritud vastav baaskeel (nimetusega *JavaCC*), ei pruugi grammatikafaile arendada lihttekstidena. Grammatikafaile saab toimetada süsteemis *Amadeus* ülevaatlikumal skeemkujul ja hõlpsasti väljastada lihttekstidena nende edasiseks kasutamiseks töötlussüsteemis *JJTree/JavaCC*. Sama grammatikafaili lihttekstiks teisendatuna leidub Lisas 1.

Grammatikafaili esimene osa (skeemid *options* ja *PARSER*, lk. 32) on standardne ning selle võib iga uue lähtekeele jaoks lihtsalt kopeerida. Muuta tuleb (kolmes kohas) vaid parserinimi. Ka teise osa alguses määratletud leksilised detailid, nagu tühemikud, eraldajad ja identifikaatorid, on tavaliselt üsna sarnased siinses näites toodutele.

Küll aga tuleb konverteerimisel tulemusse ülekantavate lekseemide jaoks kirjeldada lisaproduktsioonid. Antud juhul on ülekantavaks vaid üks lekseem, nimelt juure nimi – identifikaator. Iga ülekantava lekseemi (siin näites: `<IDENTIFIER>`) jaoks tuleb kasutusele võtta uus mitteterminal (siin on selleks võetud `tIdentifier`) ja kirjeldada vastav produktsioon (siin: skeem päisega `void tIdentifier`). Algsetes grammatika produktsioonides tuleb iga sellise ülekantava lekseemi (siin: `<IDENTIFIER>`) asemel kirjutada vastav mitteterminal (siin `tIdentifier()`), vt. viimane skeem päisega `void juur`, lk. 35).

```

- - - JJTREE SKEEM-GRAMMATIKA
- - - Metsa esitamise keel VSE (Vasak Suluesitus)
- - - ----- Sisendfaili esimene osa: parser

[ options
[ JAVA_UNICODE_ESCAPE = true; STATIC = false;
[ PARSER
[ VSEParser - - - vabalt valitav parserinimi
[ import java.io.* ;
[ public class VSEParser - - - valitud parserinimi
[ static Token t ;
[ static Sketch parse(String inputFileName)
[ throws ParseException , FileNotFoundException
[ VSEParser parser =
[ new VSEParser(new FileReader(inputFileName));
[ SimpleNode t = parser.Start( );
[ Sketch parsipuu = BaseLanguageParseTree.toSketch(t,
[ VSEParserTreeConstants.jjtNodeName);
[ - - - eelmises reas prefiks: valitud parserinimi
[ ← parsipuu
[ PARSER
[ Sisendfaili teine osa: grammatika*
[ ■ leksilised detailid
[ ■ tulemusse ülekantavad lekseemid
[ ■ SimpleNode Start ( ) :
[ ■ Token metsaVSE ( ) # void :
[ ■ void puuVSE ( ) :
[ ■ void juur ( ) :
[ Sisendfaili teine osa: grammatika*

```


leksilised detailid

SPECIAL_TOKEN:

tühemikud

" " | "\t" | "\n" | "\r" | "\f"

TOKEN :

identifikaator

< IDENTIFIER : < LETTER > (< LETTER> | <DIGIT >)* >

|

< # LETTER : ["A"– "Z", "_", "a"– "z"] >

|

< # DIGIT : ["0"– "9"] >

TOKEN :

eraldajad

< LPAREN : "(">

|

< RPAREN : ")">

|

< COMMA : ",">

TOKEN:

muu

< ANYTHING_ELSE: (~[]) >

leksilised detailid

```

tulemusse ülekantavad lekseemid
[
  void tIdentifier ( ) :
  [
    t = <IDENTIFIER>
    [
      jjtThis.setText(t.image);
    ]
  ]
]
tulemusse ülekantavad lekseemid

SimpleNode Start ( ) : - - - grammatika lähtesümbol
[
  metsaVSE()
  <EOF>
  [
    ← jjtThis - - - tagastatakse JJTree poolt loodud puu juure viit
  ]
]

Token metsaVSE ( ) # void :
[
  Token t = getToken(1);
  "("puuVSE() ("puuVSE())* ")"
  [
    ← t
  ]
]

void puuVSE ( ) :
[
  juur() [ metsaVSE() ]
]

```

```

[ void juur ( ) :
[
[ tIdentifier()

```

Grammatika sisuline osa kirjeldatakse *produktsooniskeemidena* (antud juhul neli viimast skeemi), millest kaks esimest on üsnagi standardsed, tagastades vastavalt `SimpleNode` ja `Token` tüüpi väärtuse. Ülejäänud produktsoonide tagastustüübid määratakse vastavalt vajadusele. Lihtsamates grammatikates need produktsoonid reeglina midagi ei tagasta. Ka vaadeldava näite kahes viimases produktsoonis on tagastustüübiks ainult tühitüüp `void`.


Koostatud grammatikafail silutakse: vastav lihttekstifail (laiendiga `.jjt`) töödeldakse *JJTree/JavaCC/javac* abil (vt. joonis 3.4). Kui selle töötluse käigus ilmneb vigu, siis korrigeeritakse grammatikafail ja töödeldakse uuesti. Õnnestunud töötluse tulemusena saadaksegi antud lähtekeele parser. Vaadeldava näite korral esitub parser *Java* klassina *VSEParser.class*.

Selleks, et parserit kasutada lähtekeele tekstide parsimiseks ja skeemistamiseks tuleb esiteks süsteemile *Amadeus* lisada lähtekeelele vastav baaskeel. Nimelt luuakse grammatikafailis kirjeldatud parseri töö (vt. joonis 3.5) tulemusena parsitava lähteteksti parsipuu skeemkujul. Selle edasine käitlemine toimub juba süsteemi *Amadeus* vahenditega.

Parsipuu struktuuri selgitatakse järgmise jaotise lõpus. Märkime vaid, et parsipuusse ei tule nendele mitteterminalidele vastavaid tippe, mille skeemproduktsooni päisele *JJTree* grammatikas on lisatud piiritleja `#void`. Antud näitegrammatikas on elimineeritavaks kuulutatud seega mitteterminal `metsaVSE`.

3.4 Uue baaskeele lisamine


Baaskeele lisamiseks luuakse uus baaskeele klass ja korrigeeritakse baaskeelte ühine ülemklass *BaseLanguage*. Lähtekeelele *LK* vastava uue baaskeele klassi nimi koostatakse kujul *BaseLanguage<LK>*. Seega siin vaadeldava lihtsa näitekeele puhul oleks baaskeele klassi nimeks *BaseLanguageVSE*.



Joonis 3.4: Parseri valmistamine *JTree* vormis grammatika alusel.

Joonisel 3.6 on esitatud mingit baaskeelt realiseeriva klassi üldine ülesehitus. Baaskeeke klassi loomine toimub järkjärgult. Lähtekohaks on vastav mall (vt. Lisa 2). Esiteks realiseeritakse ainult baaskeeke klassi parseri osa, jättes teised osad (*SKETCHIFY*, *REDUCE*...) tühjaks. Seega mallist baaskeeke klassi esimese versiooni saamiseks tuleb malli tekstis teha vaid neli asendust. Näiteks keele *VSE* baaskeeke klassi saame mallist, asendades seal neljas kohas "LK" → "VSE".

Uue baaskeeke süsteemi integreerimiseks tuleb modifitseerida ülemklass. Lisas 3 esitatud klassi *BaseLanguage* struktuuris on välja toodud kõik täienda-



Joonis 3.5: Grammatikafailis kirjeldatud parseri andmevoo diagramm.

mist vajavad kohad (baaskeeke *VSE* lisamise näitel). Vajaduse korral saab meetodisse *prepareSourceTextFile* lülitada veel lähtetekstide täiendava eeltötluse.

Kui ülemklass (*BaseLanguage*) on modifitseeritud ja uue baaskeeke klassi (nt. *BaseLanguageVSE*) esimene versioon ülalkirjeldatud viisil loodud, siis saab süsteemi *Amadeus* juba kasutada parseri edasisel sisulisel testimisel. Sisestanud (*File + Read text*) mingi lähtekeelse (*VSE*) lihtteksti, nt.

$(A(B, C(D, E), F), X(Y))$

saame selle baaskeekeks omistada (*Base + Set*) keele *VSE* ja rakendada parsimist (*Tools + Parse*). Tulemuseks on antud teksti parsipuu (vt. joonis 3.9) uues aknas.

Järgnevalt toimub baaskeeke klassi edasine täiustamine, selle järgmiste osade välja arendamine. Konverteriarenduse seisukohalt on kõige olulisem skeemistamise osa (*SKETCHIFY*, joonis 3.6) realiseerimine. Viimasega seo-

```

import java.util.*;
import java.io.*;

class BaseLanguageKEEL extends BaseLanguage

static AmFrame frame; - - - käideldava vaate aken
■ konstruktor
■ PARSE
■ SKETCHIFY
■ REDUCE
■ TEXTUALIZE
■ NORMALIZE
■ PREPARE TEX
■ Edit controls

```

Joonis 3.6: Baaskeelt (KEEL) realiseeriva klassi struktuur.


tud küsimused leiavad käsitlemist järgmises jaotises.

Antud lähtekeele parsimistegevus (käivitatakse vastava baaskeele klassi osas *PARSER*) seisneb grammatikafaili alusel saadud parseri rakendamises ja tulemuse skeempuuks teisendamises (vt. joonis 3.5). Skeempuuks teisen- damise sooritab meetod *toSketch* klassis *BaseLanguageParseTree*. Viimane on eriotstarbeline baaskeele klass, milles on realiseeritud osa *REDUCE*, kus leiduv meetod *reduce* võimaldab lihtsustada skeemkujul parsipuid.

Parsipuu skeemkujus on iga mitteterminal (parsipuu sõlm ehk sisetipp) esitatud skeemina, mis sisaldab kõiki temale alluvaid mitteterminale (st. neid kujutavaid alamskeeme). Mittetermini nimi varustatakse prefiksiga ⁰ ja pai- gutatakse skeemi kommentaari kohale. Antud näites (joonisel 3.9) esindavad mitteterminale skeemid kommentaaridega ⁰*puuVSE* ja ⁰*juur*.


Terminalid (parsipuu lehed) on kujutatud primitiividena, mille tekstiks on vastav lekseem. Antud näites esinevad terminalid tekstidega "A", "B", "C", "D", "E", "F", "X", "Y".

Mittetermini, millel pole mitteterminaalseid järglasi, s.t. on ainult ter- minaalsed järglased, nimetatakse *primitiivseks mitteterminali*ks. Primitiivse mittetermini (nimega *omistamisdirektiiv*) näide leidub joonisel 3.7.



Joonis 3.7: Primitiivne mitteterminal parsipuu.

Lähteteksti parsimise vahetuks tulemuseks on redutseerimata parsipuu (baaskeelega *Parse tree*) *Amadeus* aknas. Sellele saab rakendada (menüü-
käsuga *Tools + Parse*) redutseerimise funktsiooni – käivitada ülalmainitud
redutseerimise meetod. Redutseerimine seisneb primitiivsete mittetermina-
lide skeemide lihtsustamises järgmisel viisil. Iga primitiivse mitteterminali
skeem parsipuu asendatakse primitiivliikmega, mille kommentaariks on an-
tud skeemi kommentaar (⁰ ja mitteterminali nimi) ning mille tekstiks on
skeemis esinevate primitiivliikmete tekstide järjend (sümboliga ¹ eraldatult).
Joonisel 3.7 kujutatud skeempuu redutseeritakse kujule joonisel 3.8. Näitena
vaadeldava keele *VSE* tekstide parsipuudes on kõigil primitiivsetel mitte-
terminalidel (⁰*juur*) parajasti üks alluv, seega konkreetse näiteteksti parsi-
puu (joonisel 3.9) redutseerimise tulemuses (vt. joonis 3.10) eraldajat ¹ vaja
ei lähe.



Joonis 3.8: Redutseeritud primitiivne mitteterminal.

3.5 Skeemkonversiooni mudel

Pärast lähtekeele (LK) jaoks uue baaskeele klassi parsimise osa valmimist ja testimist piisava arvu lähtetekstide parsimise katsetamise teel, on süsteem juba praktiliselt valmis töötama skeemkonverterina $LK \rightarrow SK$. Tuleb vaid pisut täiendada süsteemi programmikoodi ja kirjeldada soovitava skeemkonversiooni mudel. Baaskeele (joonis 3.6) skeemistamise ossa *SKETCHIFY* kopeeritakse mall (joonis 3.11), milles muudetakse ainult üks rida. Selles fikseeritakse faili nimi, kust süsteem leiab skeemkonversiooni (skeemistamise) mudeli. Vajaduse korral saab skeemistamise osa meetodisse *postprocessResult* lülitada veel skeemistamise tulemuse täiendava järeltöötluse.

Järgnevas tutvustatakse lähemalt skeemkonversiooni mudeli mõistet.

Skeemkonversiooni mudel (edaspidi: mudel) süsteemis *Amadeus* kujutab endast sisuliselt parsipuu skeemtekstiks teisendamise eeskirja. Mudeliga määratud teisenduse teostab klassi *BaseLanguage* meetod

sketchifyParseTree(Sketch s, Sketch m),

mis teisendab antud parsipuu s skeemtekstiks, tehes seda vastavalt antud mudelile m . Sisuliselt teostab meetod konversioone tüüpi $LK \rightarrow SK$: kui s on keele LK mingi lähteteksti t parsipuu, siis tulemuseks on skeemtekst $s' \in SK$ – skeemkujule konverteeritud lähtetekst t . Meetod eeldab, et mudel ise on esitatud skeemkujul. Väga oluline on meetodi töö sõltumatus konverteeritavast lähtekeelest: meetod on muutmatul kujul rakendatav suvalise baaskeele tekstide parsipuude teisendamiseks.

Lähtekeele LK mudeliks süsteemis *Amadeus* on skeemtekst, milles leiduvaid skeeme ja primitiive kasutatakse mallidena keele LK parsipuude teisendamisel sihtskeemtekstideks. Eeldatakse, et teisendatavad parsipuud on esitatud redutseeritud kujul (redutseerimise tähendust selgitati eelmises jaotises). Mudeli ja parsipuu elemendid seostatakse mitteterminalide nimede kaudu. Nii nagu parsipuu, nii ka mudelis on mitteterminalide nimed varustatud prefiksiga ⁰.

Üldiselt, kui mitteterminal ⁰ mt leidub mudelis mingi skeemi SM kommentaaris, siis parsipuu iga skeem kommentaariga ⁰ mt (skeem SP) konverteeritakse skeemiks, millel on samad atribuudid nagu skeemil SM . Skeemi SP selliselt muudetavateks (skeemist SM pärinevateks) atribuutideks on skeemi

tüüp, baaskeel, ikoniseeritus ja skeemi kommentaar. Viimane tähendab seda, et skeemi *SP* kommentaariks omistatakse skeemi *SM* kommentaari teksti algusosa, mis eelneb mitteterminali nimele 0mt . Nt. kui mudelis leidub skeem kommentaariga *abc* 0Key , siis iga skeem kommentaariga 0Key parsipuu konverteeritakse skeemiks kommentaariga *abc*.

Peale skeemide konverteeritakse ka parsipuu esinevad primitiivsed mitteterminaalid. Nagu selgitatud eelmises jaotises, esitub primitiivne mitterterminal 0pmt skeemi liikmena kujul

`lehttipude1lekseemide1järjend - - - ${}^0pmt$ .`

Taolise liikme *PP* konverteerimise määrab mudelis leiduv primitiivliige (või primitiivpääs) *PM*, mille tekstis sisaldub selle mitteterminali nimi 0pmt . Nimele omistatakse liikmele *PP* primitiivi *PM* tüüp ning primitiivi tekstis asendatakse eraldajad ¹ tühikutega. Kui konverteerimist määrav *PM* asub mudelis mingi skeemi pääses, st. on primitiivpääseks, siis primitiiv *PP* paigutatakse konverteeritavas parsipuu ümber lähima hõlmava skeemi pääsesse. Primitiivpääse teksti ette lisatakse veel primitiivi *PM* teksti algusosa, mis eelneb mitteterminali nimele 0pmt , ja lõppu lisatakse primitiivi *PM* teksti lõpuosa, mis järgneb mitteterminali nimele 0pmt .

Mudel joonisel 3.12 kirjeldab käesoleva peatüki algul kirjeldatud konversiooni $VSE \rightarrow SK$, eeldusel, et grammatika on spetsifitseeritud ja uus baaskeel lisatud eelmistes jaotistes kirjeldatud viisil. Kui see mudel on koostatud ja salvestatud, siis suvalise *VSE*-keelse teksti (mingi konkreetse metsa vasku suluesituse) konverteerimiseks nõutud skeemkujule tuleb see tekst vaid sisestada (*File + Read text*), omistada talle baaskeeleks *VSE* (*Base + Set*) ja skeemistada jooksev tekst (*Tools + Sketchify*). Tulemus kuvatakse uues aknas.

Parsipuu ülal esitatud teisendusmoodus lubab mudelit ehitada üsna mitmel moel. Tähtis on vaid see, et mudelis esinevad skeemid ja primitiivid määraksid soovitud konversiooni. Muidugi on loomulik püüda mudel esitada võimalikult informatiivsena, näidates selles võimalikke skeemide (ja primitiivide) tüüpilisi vastastikuseid asendeid/sisalduvust. Lisaks on lubatud mudelis iga mitteterminali nime lõppu lisada veel tärn, mis konverteerimist kuidagi ei mõjuta. Seda võimalust saab kasutada näitamaks mõnede mudelielementide (vastete) võimalikku kordumist sihttekstis.

Mudeliga joonisel 3.12 samaväärne, kuid informatiivsem mudel leidub joonisel 3.13. Võimalik konstruktsioonide kordumine sihttekstis on näidatud täringiga vastava mitteterminaali nime lõpus.

Esialgse mudelis võib hõlpsasti saada mingist konkreetsest redutseeritud parsipuust, milles leiduvad kõik mitteterminaalid. Selleks, on vaja lihtsalt muuta parsipuud (muuta see mudeliks) ja salvestada nagu süsteemi *Amadeus* suvaline teine skeemtekst.

Mudelite koostamine on lihtne, eriti võrreldes nt. erikonverterite programmeerimisega või modifitseerimisega. Seetõttu on väga kerge katsetada mitmeid sisuliselt erinevaid mudeleid.

Joonisel 3.14 on esitatud mudel metsa vasaku suluesituse konverteerimiseks skeem-XML kujule. Selles leiduvad ka tulemusse kanduvad päise tekstifragmendid. Mudelis on skeemide baaskeeleks määratud XML. Viimane on üks süsteemi *Amadeus* varem integreeritud baaskeeli. Näiteteksti konverteerimise tulemus selle mudeli järgi on toodud joonisel 3.15. Paneme ka tähele, et erinevalt eelmistest konverteerimise näidetest, esituvad nüüd puud (selle mudeli kohaselt) lihtskeemidena, mitte moodulskeemidena. Antud juhul on tegemist konverteerimisega tüüpi $VSE \rightarrow \textit{skeem-XML}$.

Kuna baaskeelele XML vastav baaskeele klass realiseerib ka konverteerimise tüüpi $\textit{skeem-XML} \rightarrow XML$ (st. tekstualiseerimise), siis kokkuvõttes on nüüd süsteem *Amadeus* kasutatav ka konverterina tüüpi $VSE \rightarrow XML$. Nt. saab konverteerimise tulemusele joonisel 3.15 rakendada XML-tekstualiseerimist (*Base + Set ... XML ja Tools + Textualize*), mis annab tulemuseks XML teksti joonisel 3.16.

3.6 Kokkuvõte


Skeemkonverteri arendamiseks süsteemi *Amadeus* kasutades tuleb spetsifitseerida lähtekeele grammatika ja integreerida vastav uus baaskeel. Viimasel tuleb realiseerida vähemalt parsimise ning skeemistamise osad. Skeemkonverteri kasutamiseks peab eelnevalt veel konkretiseerima konversiooni mudeli.

Taolist moodust vahetult kasutades on koostöös juhendaga J. Kiho loodud konverter *JJTree/JavaCC* kujul kirjutatud lihttekstiliste grammatikafailide

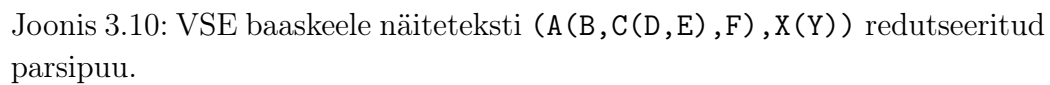
viimiseks skeemkujule. Vastavalt lisati uus baaskeel nimega *JavaCC*. Parserit kirjeldava grammatikafaili struktuur on esitatud Lisas 7, konversioonimudel aga Lisas 8. Grammatikafail arendati välja lihtteksti vormis, lähtudes repositooriumis [7] leiduvast grammatikast. Selle skeemkuju (Lisas 7) on aga juba saadud loodud konverteri rakendamise tulemusena.

Praktilist skeemkonverteri arendusprotsessi iseloomustab iteratiivsus. Nimmelt ei õnnestu (ega pole ka vajalik) kohe luua lõplikult vastuvõetav grammatikafail. Esimese sammuna luuakse esialgne "töötav" grammatika, mida hakatakse järkjärgult modifitseerima sihiga saada selliste omadustega parsipuud, mille jaoks osutub lihtsaks nende soovitud skeemkujule teisendamise kirjeldamine, st. konverteerimismudeli spetsifitseerimine. Peamisteks muudatusteks grammatikas on ebavajalike mitteterminalide parsipuudesse ülekandumise keelamine. Nagu eespool selgitatud, reguleeritakse seda lisapiiritlejaga `#void` skeemproduksioonide päistes. Märkime, et tegelikult osutub iteratiivseks ka mudeli loomine: sobivaima mudeli leidmiseks tuleb katsetada mitmete erinevate mudelivariantidega.

Grammatika sobivale kujule viimine on protsessi sisuline, loomingulisem külg. Sellega kaasneb aga üsnagi palju rutiinset tööd. Ka algatuslikus osas (esialgse grammatika loomine ja uue baaskeeke lisamine) tuleb arendajal kokkuvõttes teha (ja korrata) rohkesti lihtsaid, tehnilisi üksiktegevusi. Konverteriarendusel vajalike, kuid rutiinsete tehnilist laadi tööde automatiseerimise küsimustele ongi pühendatud järgmine peatükk.



Joonis 3.9: VSE baaskeelee näiteteksti $(A(B,C(D,E),F),X(Y))$ parsipuu.




```

import java.util.*;
import java.io.*;


class BaseLanguageKEEL extends BaseLanguage
{
    ...
    SKETCHIFY
    skeemistamise osa
    {
        public boolean sketchify(
            SketchyText skt0, - - - main = source
            SketchyText skt1, - - - main = new
            AmFrame dialogTargetFrame)
        {
            ■
            importida konkreetse nimega mudel
            {
                ■
                - - - ainus muudetav koht skeemistamise osa koodis:
                skt.file.name = Default.modelsDirectory +
                "LKmudel.html"; - - - skeemistamismudeli faili nimi
                ■
            }
            importida konkreetse nimega mudel
            ■
        }
        ■ private void postprocessResult(SketchyText skt1)
    }
    SKETCHIFY
    ...
}

```


Joonis 3.11: Baaskeeke klassi skeemistamise osa mall.




Joonis 3.12: *VSE* skeemkonversiooni mudel (I).



Joonis 3.13: *VSE* skeemkonversiooni mudel (II).



Joonis 3.14: *VSE* skeemkonversiooni mudel (III).



Joonis 3.15: *VSE* näiteteksti konverteerimise tulemus mudeli III (joonis 3.14) järgi.


```

<tree root='A '>
  <tree root='B '>
    </tree>
  <tree root='C '>
    <tree root='D '>
      </tree>
    <tree root='E '>
      </tree>
    </tree>
  <tree root='F '>
    </tree>
  </tree>
<tree root='X '>
  <tree root='Y '>
    </tree>
  </tree>

```

Joonis 3.16: *VSE* näiteteksti *XML* kujule konverteerimise tulemus.

Peatükk 4

Baaskeelte käitlemise ja skeemistiloomise automatiseerimine

Käesoleva töö praktiliseks tulemiks on süsteemi *Amadeus* uus versioon *AmadeusJSN*. Viimane on saadud lähteversioonist *AmadeusJS* konverteerimise teel. Automatiseeritud on baaskeelte manipuleerimine (uue baaskeele lisamine, olemasoleva kustutamine, kustutatud baaskeele taastamine). Grammatikafaili iteratiivse arendamise toeks on spetsifitseeritud vastav projektikirjeldus.

Antud peatükis esitatakse ülevaade peamistest süsteemile *AmadeusJSN* omastest, uude versiooni lisandunud tehnilistest lahendustest.

4.1 Süsteemi *Amadeus* kataloogi ülesehitus

Kuna süsteemis leidub väga palju erinevat liiki ja erineva otstarbega faile, siis on loomulik need grupeerida mitmetesse kataloogidesse (ehk kaustadesse). Süsteemi kodukataloogil on kindel ülesehitus, mille üldine struktuur on toodud joonisel 4.1.

Alamkataloogide otstarve on järgmine:

1. **class**: objektide klassid (*Java* klassifailid), samuti *Amadeus.properties* fail (määrab süsteemi sättingud algkäivitusel, lähemalt vt. allpool) ja



Joonis 4.1: Süsteemi *AmadeusJSN* kataloogi struktuur.

(soovitavalt) eriotstarbeline standardne fail *amadeus.tex* – trükimakrod skeemtekstide T_EX/L^AT_EX kujul väljastamiseks;

2. ***docHtml***: süsteemi enda lähtekood, *Amadeus* salvestusformaadis (*html* või *xml*) failidena;
3. ***gif***: süsteemi poolt kasutatavad pildid (*collapsed.gif* – ikoniseeritud skeemi pildi fail);
4. ***grammars***: *JJTree* kujul grammatikafailid (laiendiga *.jjt*); skeemkujul grammatikafaile (laiendiga *html* või *xml*) hoitakse selle kataloogi alamkataloogis ***grammarsSK***;
5. ***java***: süsteemi lähtekoodi *java*-tekstid (tekstualiseeritud kataloogist ***docHtml***) ja baaskeelte grammatikafailid *JavaCC* kujul laiendiga *.jj* (saadud kataloogi ***grammars*** failidest);
6. ***JavaCC***: alamsüsteem *JJTree/JavaCC*;

7. **macros**: toimetamismakrod (*edit-macros* [1]). Makrode kasutamine lihtsustab kasutaja tööd, sest makrode failis saab defineerida lühendeid tihti kasutatavate skeemide, tekstide jms. tarbeks.
8. **models**: grammatikate/keelte spetsiifilised skeemkonversiooni mudelid *Amadeus* salvestusformaadis (*html*) failidena.
9. **patterns**: koodiosade šabloonid süsteemi *Amadeus* arendajale; nt. tsükliid skeempuu läbimiseks jmt.;
10. **Personal**: kasutaja isiklik kataloog; peamine otstarve hetkel on kasutaja poolt kustutatud baaskeelega seotud failide säilitamine alamkataloogis ***BL_repository*** (baaskeele võimalikuks taastamiseks edaspidi);
alamkataloogi ***BL_repository*** otstarve:
baaskeele kustutamisel (jaotis 4.4) luuakse selles alamkataloogis vasta-va baaskeele nimeline alamkataloog, milles luuakse omakorda järgmised alamkataloogid:
 - (a) *docHtml*: baaskeele klassi jaoks
 - (b) *grammars*: baaskeele grammatikafaili jaoks
 - (c) *Portfolio*: baaskeele projektikirjelduse jaoks
11. **Portfolio**: projektikirjeldused¹ *Amadeus* salvestusformaadis (*html*) failidena;
12. **temp**: suvalised ajutised failid (varukoopiad jmt.).

4.1.1 Algsätingute fail

Kõige esimene asi, millest peab kasutaja alustama, kui hakkab süsteemiga *Amadeus* töötama, on vajalike süsteemsete parameetrite sätestamine. Korrastada tuleb algsätingute fail *Amadeus.properties*, mis asub reeglina süsteemi *class* kataloogis. Konkreetne näide (reanumbrid on lisatud kommenteerimise huvides):

¹Projekti mõistet selgitatakse jaotises 4.2

- (1) AmadeusDirectory=D:\\AmadeusJSN\\
- (2) iconImageFileName=D:\\AmadeusJSN\\gif\\collapsed.gif
- (3) modelsDirectory=D:\\AmadeusJSN\\models
- (4) JavaJSDK=C:\\j2sdk1.4.2_05\\bin
- (5) Backup=D:\\AmadeusJSN\\BackupN\\
- (6) defaultFont=Times New Roman, 1, 12
- (7) defaultOpenDirectory=D:\\AmadeusJSN\\Portfolio

Selles failis peab kasutaja korrigeerima kataloogiteed süsteemi *AmadeusJSN* kodukataloogini (1), ikoniseeritud skeemi pildi failini (2), mudelite kataloogini (3), *Java* kodukataloogini (4), varukoopiate kataloogini (5) ning lisaks veel määrama ekraanil kuvatavate skeemtekstide kirjastiili ja kirja suuruse (6). Võimalik on määrata ka kataloog (7), millest soovitakse alustada avatava (projekti) faili otsimist.

4.2 Projekti mõiste süsteemis *Amadeus*

Projekt süsteemis *Amadeus* on failinimede hulk, kus iga failinimega on seotud toimetamise eel- ja järeltegevuste sooritamiseks vajalikud andmed ehk atribuudid [13][14]. Projektiga grupeeritud faile nimetatakse projekti failideks.

Atribuudid jagunevad kolme liiki – *Paths*, *Open-script* ja *Save-script* atribuudid:

- *Paths*: projekti failide kataloogiteed. *Path* liiki atribuutide peamine eesmärk on anda lühinimed füüsilistele kataloogiteedele muutmaks projekti failidele viitamise sõltumatumaks konkreetsest keskkonnast.
- *Open-script*: tegevused/funktsioonid, mida rakendatakse failidele nende avamisel. Reeglina on üheks tegevuseks projekti faili importimine (avamine).
- *Save-script*: tegevused/funktsioonid, mida rakendatakse failidele nende salvestamisel. Reeglina on üheks tegevuseks projekti faili eksportimine (salvestamine).

Projektiga (projekti all) töötamisel kuvatakse iga (avatud) projekti fail eraldi spetsiaalses aknas, kus *File* menüüs on aktiivsed ka valikud *Open* ja *Save* (tavaaknas, st. mitte projekti faili aknas pole need valikud aktiivsed). Menüükäsk *File+Open* sellises aknas initsieerib tegevuste jada, mis on defineeritud selle projekti *Open*-skriptis. Menüü käsk *File+Save* initsieerib tegevuste jada, mis on defineeritud projekti *Save*-skriptis.

Projekti enda struktuur ja sisu esitatakse skeemtekstina, mida nimetatakse *projektikirjelduseks* (seda sisaldavat faili aga projektifailiks). Nõuded projektikirjelduse skeemtekstile on järgmised:

1. Projektikirjeldus esitatakse moodulskeemina, millel on üks elementaarpäis ja kaks haru.
2. Projektis võib olla alamprojekte. Alamprojekti kanduvad pärimise teel ülemprojekti kõik atribuudid, mis alamprojektis pole määratud.
3. Projekti failinimed peavad olema unikaalsed kogu projektikirjelduses, kaasaarvatud alamprojektide projektikirjeldused.
4. Projektikirjelduse elementaarpäise tekstiks on projekti nimi; seda ei tohi tühjaks jätta. Projekti nimi kuvatakse iga projekti faili akna ülaosas.
5. Projektikirjelduse esimeses harus asub 0 või enam projekti atribuudirühma. Projekti *atribuudirühm* kujutatakse ühe elementaarpäisega üheharulise lihtskeemina.

Projektikirjelduse skeemteksti struktuuri näide on toodud joonisel 4.2.

projektikirjeldus (moodulskeem kahe haruga)

1.haru; atribuudid

Paths - - - path-atribuutide grupp

märgis: väärtuste paar

- - - üldine kuju:

L:X - - - L - kasutaja poolt valitud märgis; X - väärtus

- - - näited:

DOC:d:\dir

JAVA:d:\myJava

Backup:c:\temp

JSDK:C:\"Program Files"\Java\j2sdk1.5.0\bin\

Open-script - - - avamise skripti atribuutide grupp

tegevus: parameetrite paar

- - - näide: importida(avada) fail kataloogist d:\dir

Import: path=DOC - - - tegelikult: Import: path=d:\dir

Save-script - - - salvestamise skripti atribuutide grupp

tegevus: parameetrite paar

- - - eksportida (salvestada) liht-HTML kujul faili d:\dir\jooksev.a:

Export plain-HTML: path=DOC

- - - tekstualiseerida ja tulemus kirjutada faili d:\myJava\jooksev.java:

Textualize+Write text: path=JAVA ext=java

- - - käivitada protsess javac käsurealt - javac jooksev.java:

Process:{JDSK}javac path=JAVA ext=java

2. haru; projekti failide nimed, alamprojektide kirjeldused

fail1.a - - - projekti fail

fail2.a - - - projekti fail

■ alamprojekti kirjeldus

projektikirjeldus (moodulskeem kahe haruga)


Joonis 4.2: Projektikirjelduse näide.

Põhioperatsioonid projektikirjeldusega ja projekti failidega:

1. Projektikirjelduse loomine/avamine: *File + Import Project* (avaneb aken valitud projektikirjeldusega ja tühja projektifaili aknaga).
2. Projektikirjelduse sulgemine: kasutada süsteemseid vahendeid.
3. Projektikirjelduse salvestamine: nagu tavalise skeemteksti salvestamine, st. *File + Export-plain HTML*.
4. Projekti failide avamine: hiirega kolmik-klõps või projektifaili akna menüüst valida *File + Open*.
5. Projekti faili sulgemine: kasutada süsteemseid vahendeid.
6. Projekti faili salvestamine: projekti faili akna menüüst valida: *File + Save*.

Atribuudirühmades *Open-script* ja *Save-script* näidatakse soovitavad tegevused menüükäskudena, mida igal avamisel ja salvestamisel tuleb sooritada. Olulise iseärasusena tuleb märkida võimalust *Save-script* rühmas kasutada *Process* funktsiooni (joonis 4.3). Selles kirjeldatakse käsurealt käivitavad (salvestamisjärgselt sooritamisele tulevad) operatsioonid. Kui käsureas on ette nähtud mitu järjestikust operatsiooni, siis on soovitatav need eraldada && abil (mitte aga eraldajaga |). Sellega tagatakse parem veadiagnostika (veaga lõppenud operatsiooni järel). Veateated väljastatakse *Amadeus* uues aknas. *Process* käsu projektikirjelduses defineerimisel ongi parameetriks käsurea tekst, kuid käsurea teksti defineerimisel saab kasutada *Path* rühma atribuute. *Process* käsu parameetrite *path* ja/või *ext* ilmumise kohale paigutatakse moodustatud faili nimi. Looksulud koos atribuudi märgendiga asendatakse vastava (*Path* rühma) atribuudi väärtusega.

Nt. olgu jooksva projekti faili nimeks *BaseLanguage* ja projektikirjelduses atribuudirühmad sellised, nagu näidatud joonisel 4.3. Siis selle jooksva faili sulgemisel sooritatakse ka *Save* rühma lõpus kirjeldatud *Process* käsk. *Path* rühmas määratletud atribuute arvestades tuleb aga tegelikult täitmisele järgmine käsutada:



Joonis 4.3: *Process* funktsiooni kasutamise näide.

```

C:\j2sdk1.4.2_03\bin\javac
-sourcepath "C:\AmadeusJSN\java"
-classpath "C:\AmadeusJSN\class" -d "C:\AmadeusJSN\class"
C:\AmadeusJSN\java\BaseLanguage.java &&
C:\j2sdk1.4.2_03\bin\java -cp C:\AmadeusJSN\class Amadeus


```

Käesolevas vaadeldava skeemkonverteri loomise probleemi kontekstis on projektikirjeldus tähtis just arenduse iteratiivse osa jaoks. Jaotises 4.6 spetsifitseeritakse projekt grammatikafaili töötlemiseks, mille all on mugavam ja kiirem arendustöid teha.

4.3 Uue baaskeele automaatne lisamine

Süsteemi *Amadeus* on täiendatud uue funktsiooniga, mis käivitub menüüvalikuga *Base + Add new language*. Selle funktsionaalsuse realiseerimiseks on loodud klass *Item12Listener*, mille struktuur on toodud Lisas 4.

Baaskeele lisamiseks peab kasutaja avama uue *Amadeus* akna (*Frame + New*) ja selles uue skeemteksti (*File + New*), seejärel märgistama tekkinud skeemi ja valima *Base + Add new language*. Ilmub dialoogiaken, mis on toodud joonisel 4.4. Dialoogiaknasse sisestatakse lisatava baaskeele nimi.



Joonis 4.4: Uue baaskeele lisamise dialoogiaken

Nupu *OK* vajutamisel toimub esiteks uue baaskeele nime valideerimine, mille käigus kontrollitakse, kas antud nimega baaskeel on juba kasutusel või kunagi kasutusel olnud (passiivne). Kui antud nimega baaskeel on hetkel kasutusel, siis antakse kasutajale vastav veateade (*Antud nimega baaskeel juba eksisteerib!*). Kui aga antud nimega baaskeel ei ole kasutatavate keelte loetelus, kuid leidub kunagi kasutusel olnud baaskeelte loetelus, siis antakse kasutajale võimalus baaskeele taastamiseks (vt. jaotis 4.5). Pärast baaskee-
le (edukat) valideerimist toimub uue baaskeele automaatne lisamine, mille käigus sooritatakse järgmised tegevused.

1. Luuakse uue baaskeele projektikirjelduse fail, mis kirjeldab grammatikafaili töötlemise tegevusi (täpsemalt vt. jaotis 4.6). Projektikirjelduse faili nimeks on uue baaskeele nimi (laiendiga *.html*). Näiteks, kui kasutaja soovis lisada baaskeele nimega *ABC*, siis saab loodud projektikirjelduse faili nimeks *ABC.html*. Projektikirjelduse fail salvestatakse automaatselt *Amadeus* süsteemi kataloogi *Portfolio*. Projektikirjelduse kõik *Path* parameetrid hangitakse failist *Amadeus.properties*, nii et

kasutajal pole vaja midagi juurde lisada ega muuta.

Järgnevates tegevustes kirjeldustes eeldatakse, et lisatava baaskeeke nimiks on *ABC*.

2. Luuakse uus klassi *BaseLanguage* alamklass *BaseLanguageABC* joonisel 3.6 esitatud malli kohaselt, tehes selles baaseele nimega seotud muudatused. Eeldatakse, et malli fail (*BaseLanguageKEEL.html*) paikneb kataloogis *docHtml*. Uus alamklass *BaseLanguageABC.html* salvestatakse samuti süsteemi kataloogi *docHtml*.

Analoogilise protseduuriga valmistatakse ka vastav *java*-fail *BaseLanguageABC.java*, mis salvestatakse aga süsteemi kataloogi *java*.

3. Failis *BaseLanguage.html* (ja vastavalt samuti failis *BaseLanguage.java*) muudetakse uue baaskeelega seotud parameetrid (vt. jaotis 3.4). Muudetavate kohtade täpsem nimekiri:
 - Süsteemis kasutatavad baaskeelte konstandid ja nende konstantide tähised. Siin esinevad ainult aktiivsete baaskeelte konstandid. Loetelu lõppu lisatakse järjekordne konstandi kirjeldus
`final static byte ABC = a;`
kus *a* on kõikide baaskeelte arv (koos lisatava baaskeelega).
 - Aktiivsete baaskeelte nimede loetelu, eelmisele (konstantide) loetelule vastavas järjekorras. Sõnedemassiivi
`static String[ ] items`
algväärtustuse lõppu lisatakse uus element `"ABC"`.
 - Dialoogis kuvatavate baaskeelte nimekirja kuuluvate keelte konstantide loetelu. Tavaliselt sisaldab kõigi aktiivsete keelte konstandid (kuid võib olla ka vaid osa nendest). Määrab, milliste aktiivsete keelte nimed dialoogis üldse kuvatakse ja mis järjekorras seda tehakse. Konstantidemassiivi
`static byte[ ] currentSetOfBL`
algväärtustuse lõppu lisatakse uueks elemendiks `ABC`.
 - Kõikide, nii aktiivsete kui ka passiivsete baaskeelte nimede loetelu. Sõnedemassiivi

```
static String[ ] useditems
algväärtustuse lõppu lisatakse uus element "ABC".
```

- Täiendus baaskeelte ülemklassis (*BaseLanguage*). Meetodisse

```
static BaseLanguage newBaseLanguage(byte type)
```

(vt. ka Lisa 3) lisatakse variant

```
case ABC:
return new BaseLanguageABC();
```

4. Luuakse uue baaskeele grammatikafaili lihttekstiline mall (laiendiga *.jjt*), mis salvestatakse süsteemi kataloogi *grammars*. Kui nt. lisatava baaskeele nimeks on *ABC*, siis luuakse fail *ABC.jjt*. Mall korrigeeritakse baaskeele nime osas, selle üldine struktuur on kujutatud joonisel 4.5.

```
BaseLanguage grammar file
■ options
■ PARSER_BEGIN
■ import section
■ class KEELParser
  public class KEELParser
    static Token t;
    ■ static Sketch parse(String inputFileName)
  class KEELParser
  ■ PARSER_END
  ■ SPECIAL_TOKENS
  ■ LITERALS
  ■ IDENTIFIERS
  ■ SEPARATORS
  ■ tIdentifier
  - - - THE GRAMMAR SPECIFICATION STARTS HERE
  ■ SimpleNode Start() :
  ■ someToken()
  ■ Token someToken() #void :
BaseLanguage grammar file
```

Joonis 4.5: Grammatikafaili malli struktuur

5. Failide automaatne töötlemine (failinimede ette on veel lisatud süsteemi kataloogi nimetus).

- Grammatikafaili teisendamine:
$$jjtree : grammars\ABC.jjt \rightarrow java\ABC.jj$$
Protsessori *jjtree* poolt genereeritakse (ja paigutatakse kataloogi *java*) ka failid
ABCTokenManager.java,
ABCTreeConstants.java,
ABCParserConstants.java,
JJTABCParserState.java
- Parseri lähtefaili genereerimine:
$$javacc : java\ABC.jj \rightarrow java\ABCParser.java$$
- Parseri kompileerimine:
$$javac : java\ABCParser.java \rightarrow class\ABCParser.class$$
Koos sellega genereeritakse (ja paigutatakse kataloogi *class*) ka failid
ABCTokenManager.class,
ABCTreeConstants.class,
ABCParserConstants.class,
JJTABCParserState.class
- Ülemklassi *BaseLanguage* kompileerimine:
$$javac : java\BaseLanguage.java \rightarrow class\BaseLanguage.class$$
- Lisatava baaskeelega klassi *BaseLanguageABC* kompileerimine:
$$javac : java\BaseLanguageABC.java \rightarrow class\BaseLanguageABC.class$$

Pärast ülalkirjeldatud tegevuste sooritamist ongi süsteemi *AmadeusJSN* lisatud uus baaskeel (*ABC*). Vastavat baaskeelega klassi ja uue keele grammatikafaili saab nüüd kasutaja oma vajaduste kohaselt muuta. Esmajoones tuleb muidugi hakata tegelema grammatikafailiga, sest süsteemi poolt on loodud vaid grammatikafaili mall. Baaskeelega lisamise protseduuri lõpuks kuvabki süs-

teem uue akna, avades selles grammatikafaili projekti. Viimase all töötades on kasutajal mugav oma keele grammatikat järkjärgult välja arendada.

4.4 Baaskeele automaatne kustutamine

Juhul, kui aktiivsete baaskeeelte nimekiri kasvab ülemäära pikaks, on mõistlik mõningad mittevajalikud baaskeeled ära kustutada. Seda arvestades sai süsteemile *Amadeus* lisatud uus funktsioon, mis käivitatakse menüüvalikuga *Base + Remove language*. Selle funktsiooni realiseerimiseks on loodud klass *Item13Listener*, mille struktuur on toodud Lisas 5, ning klassi *BaseLanguage* lisatud uus meetod *userRemoveLang* (samuti Lisas 5).

Baaskeele kustutamiseks peab kasutaja avama uue *Amadeus* akna (*Frame + New*) ja selles uue skeemteksti (*File + New*), seejärel märgistama tekkinud skeemi ja valima *Base + Remove language*. Ilmub momendil aktiivsete baaskeeelte loetelu, millest saab kasutaja valida baaskeelega, mida ta soovib kustutada.

Nupu *Select* vajutamisel toimub kustutatava baaskeelega valideerimine: kontrollitakse, et kasutaja ei kustutaks *Amadeus* töö jaoks vajalikke baaskeeli (*XML*, *Java*, *LaTeX* ja *None*). Juhul kui kasutaja on valinud näiteks *XML*, antakse talle vastav veateade (*Antud nimega baaskeelt kustutada ei ole soovitatav*). Kui kasutaja aga soovib kustutada mõnda muud baaskeelt, kontrollitakse, kas tegemist on aktiivsete baaskeeelte nimekirjas oleva viimase baaskeelega. Juhul, kui kustutatav baaskeel on viimane, antakse kasutajale võimalus baaskeelega lõplikult kustutamiseks süsteemist *Amadeus* (*Kas soovite antud baaskeelt lõplikult kustutada?*).

Nupu *YES* vajutamisel kustutataksegi süsteemist *Amadeus* baaskeel lõplikult. Selleks sooritatakse järgmised tegevused (järgnevalt oletame, et kustutava baaskeelega nimi on *ABC*):

1. Kustutakse baaskeelega projektikirjelduse fail *Portfolio\ABC.html*.
2. Kustutatakse baaskeelega grammatikafail *grammars\ABC.jjt* ja kõik selle töötlemise tulemusena loodud failid (süsteemi kataloogides *java* ja *class*).

3. Kustutatakse baaskeeke *BaseLanguage* alamklass
docHtml\BaseLanguageABC.html,
 samuti ka *java\BaseLanguageABC.java*
 ning *class\BaseLanguageABC.class*.
4. Muudetakse *BaseLanguage* klass (nii *BaseLanguage.html* kui ka
BaseLanguage.java), eemaldades kustutatava baaskeelega seotud para-
 meetrid:
 - Süsteemis kasutatavad baaskeelte konstandite ja nende tähiste loe-
 telu lõpust kustutatakse baaskeelega seotud konstandi kirjeldus
`final static byte ABC = a;`
 - Aktiivsete baaskeelte nimede loetelust (sõnedemassiivist)
`static String[ ] items` kustutatakse element "ABC".
 - Dialogis kuvatavate baaskeelte nimekirja kuuluvate keelte konstan-
 tide loetelust (konstantidemassiivist)
`static byte[ ] currentSetOfBL`
 kustutatakse element ABC.
 - Kõikide, nii aktiivsete kui ka passiivsete baaskeelte nimede loete-
 lust (sõnedemassiivist)
`static String[ ] usedItems` kustutatakse element "ABC".
 - Baaskeelte ülemklassist (*BaseLanguage*)
 meetodist *static BaseLanguage newBaseLanguage(byte type)*
 kustutatakse variant
`case ABC:`
`return new BaseLanguageABC();`
5. Kompileeritakse uuesti ülemklass *BaseLanguage.java*.

Nupu *NO* vajutamine¹ jätab aga kasutajale võimaluse tulevikus baas-
 keel taastada. Antud juhul baaskeeke kustutamine süsteemist *Amadeus* ei
 tähenda täielikku/lõplikku baaskeeke eemaldamist süsteemist, vaid tegelikult

¹ Järgnevalt kirjeldatud tehnoloogiat kasutatakse samuti mittevii-
 masena lisatud) baaskeeke kustutamiseks.'

selle nõ. passiivseks muutmist. Kõik selle baaskeelega seotud failid tõstetakse ümber baaskeelte repositooriumi (*Personal\BL_repository*) vastavatesse kataloogidesse, millest vajadusel on võimalik seda keelt taastada (vaadeldakse järgmises jaotises). Kustutamise protsessi jooksul sooritatakse järgmised tegevused:

1. Tõstetakse ümber baaskeelega projektikirjelduse fail *Portfolio\ABC.html* kataloogi *Personal\BL_repository\ABC\Portfolio*.
2. Tõstetakse ümber baaskeelega grammatika fail *grammars\ABC.jjt* kataloogi *Personal\BL_repository\ABC\grammars*.
3. Kustutatakse kõik baaskeelega grammatikafaili *grammars\ABC.jjt* töötlemise tulemusena loodud failid (süsteemi kataloogides *java* ja *class*).
4. Tõstetakse ümber baaskeelega *BaseLanguage* alamklass *docHtml\BaseLanguageABC.html* kataloogi *Personal\BL_repository\ABC\docHtml*.
5. Muudetakse *BaseLanguage* klass (nii *BaseLanguage.html* kui ka *BaseLanguage.java*), eemaldades kustutatava baaskeelega seotud parameetrid:
 - Süsteemis kasutatavad baaskeelte konstandite ja nende tähiste loetelu lõppust kustutatakse baaskeelega seotud konstandi kirjeldus
`final static byte ABC = a;`
 - Aktiivsete baaskeelte nimede loetelust (sõnedemassiivist)
`static String[ ] items` kustutatakse element "ABC".
 - Dialogis kuvatavate baaskeelte nimekirja kuuluvate keelte konstantide loetelust (konstantidemassiivist)
`static byte[ ] currentSetOfBL` kustutatakse element ABC.
 - Baaskeelte ülemklassi (*BaseLanguage*) meetodist
`static BaseLanguage newBaseLanguage(byte type)`
 kustutatakse variant
`case ABC:`
`return new BaseLanguageABC();`

6. Kompileeritakse uuesti ülemklass *BaseLanguage*.

Pärast ülalkirjeldatud tegevuste sooritamist ongi süsteemist *AmadeusJSN* lõplikult (või mittelõplikult) kustutatud baaskeel (*ABC*). Kasutajale avatakse süsteemi *Amadeus* üldine projektikirjeldus, kus ta võib tööd jätkata, kuid nüüd juba ilma kustutatud baaskeeleta.

4.5 Baaskeelega automaatne taastamine

Süsteemile *Amadeus* on lisatud uus funktsioon, mis käivitatakse menüüvalikuga *Base + Restore language*. Selle funktsionaalsuse realiseerimiseks on loodud klass *Item14Listener*, mille struktuur on toodud Lisas 7. Baaskeelega taastamise protsess on sarnane baaskeelega lisamise protsessiga. Vahe on selles, et vajalikud failid on juba olemas baaskeelte repositooriumis (*Amadeus* süsteemi *Personal\BL_repository* kataloogis) ja need lihtsalt tõstetakse ümber vastavatesse kataloogidesse.

Baaskeelega taastamiseks peab kasutaja avama uue *Amadeus* akna (*Frame + New*) ja selles uue skeemteksti (*File + New*), seejärel märgistama tekkinud skeemi ja valima *Base + Restore language*. Ilmub aktiivsete ja passiivsete baaskeelte loetelu, millest saab kasutaja valida taastatava baaskeelega,

Peale nupu *Select* vajutamist toimub baaskeelega nime valideerimine:

1. kui valitud baaskeel on juba aktiivne ja kasutusel, antakse kasutajale hoiatus (*Antud nimega baaskeel on juba aktiivne*);
2. kui baaskeel eksisteeris, kuid oli eemaldatud enne käesoleva süsteemi rakendamist, antakse kasutajale hoiatus (*Antud nimega baaskeelt taastada ei ole võimalik*).

Pärast baaskeelega nime (edukat) valideerimist toimub taastatava baaskeelega automaatne lisamine süsteemi *AmadeusJSN*, mille käigus sooritatakse järgmised tegevused (järgnevalt eeldame, et taastame baaskeelt *ABC*):

1. Projektikirjelduse faili kopeerimine baaskeelte repositooriumist
Personal\BL_repository\ABC\Portfolio\ABC.html
kataloogi *Portfolio\ABC.html*

2. Grammatikafaili *ABC.jjt* kopeerimine baaskeelte repositooriumist
Personal\BL_repository\ABC\grammars\ABC.jjt
 kataloogi (*grammars\ABC.html*)
3. *BaseLanguage* klassi alamklassi *BaseLanguageABC* kopeerimine baas-
 keelte repositooriumist
Personal\BL_repository\ABC\docHtml\BaseLanguageABC.html
 kataloogi *docHtml\BaseLanguageABC.html*.
4. Failis *BaseLanguage.html* taastatava baaskeelega seotud parameetrite
 muutmine (täpselt samuti, nagu uue baaskeelega lisamisel, vt. jaotis 4.3).
5. Failide automaatne töötlemine. Järgnevas tegevuste loetelus on eelda-
 tud, et lisatava baaskeelega nimeks on *ABC*. Failinimede ette on veel
 lisatud vastava süsteemi kataloogi nimetus.
 - Grammatikafaili teisendamine:

$$jjtree : grammar\ABC.jjt \rightarrow java\ABC.jj$$
 Protsessori *jjtree* poolt genereeritakse (ja paigutatakse kataloogi
java) ka failid
ABCTokenManager.java,
ABCTreeConstants.java,
ABCParserConstants.java,
JJTABCParserState.java
 - Parseri lähtefaili genereerimine:

$$javacc : java\ABC.jj \rightarrow java\ABCParser.java$$
 - Parseri kompileerimine:

$$javac : java\ABCParser.java \rightarrow class\ABCParser.class$$
 Koos sellega genereeritakse (ja paigutatakse kataloogi *class*) ka
 failid
ABCTokenManager.class,
ABCTreeConstants.class,
ABCParserConstants.class,
JJTABCParserState.class

- Ülemklassi *BaseLanguage* kompileerimine:
`javac :
 java\BaseLanguage.java → class\BaseLanguage.class`
- Lisatava baaskeelega klassi *BaseLanguageABC* kompileerimine:
`javac :
 java\BaseLanguageABC.java → class\BaseLanguageABC.class`

Lõpuks avatakse kasutajale taastatud baaskeelega projektikirjeldus, kus võib ta jätkata tööd taastatud baaskeelega.

4.6 Baaskeelega grammatika käitlemise tugi

Käesolevas jaotises spetsifitseeritakse baaskeelega projekt, mis on mõeldud eeskätt grammatikafaili töötlemiseks.

Jaotises 3.4 oli kirjeldatud uue baaskeelega lisamise protsess. Viimane, aga ka sellele järgnev grammatikafaili iteratiivse muutmise protsess, on selgelt väga töömahukad. Kasutajal tuleb grammatikafaili ja baaskeelega klassi muutmisel töötada paljude failidega, mida peale iga muudatust on vaja salvestada ja kompileerida/töödelda.

Probleemi lahendamiseks sai otsustatud, et kohe juba baaskeelega lisamisel on mõistlik luua baaskeelega projekt, kus kasutajal oleks mugav ja lihtne grammatikafailiga ning baaskeelega klassiga töötada. Baaskeelega projektikirjelduse struktuur (joonis 4.6) on standardne ja sisaldab järgmist:

1. projekti nimi, tavaliselt baaskeelega nimi;
2. *Path*, *Save-script* ja *Open-script* rühma; neis olevad atribuutide süsteemsed kirjeldused võetakse *Amadeus.properties* failist;
3. projekti jaoks vajalike failide haru, mis jaguneb omakorda kolmeks:
 - Failid *BaseLanguage.html* ja *BaseLanguageKEEL.html*.
 - Baaskeelega grammatikafaili ja parseri *Path*, *Save-script* ja *Open-script* rühmade atribuutide kirjeldused ning failide nimed. Kõige olulisem on *KEEL.jjt*, mida tuleb kasutajal muuta/täiendada vajaduste kohaselt.

- Projekti failid – projekti KEEL all kasutaja poolt loodavad näitefailid.

Nagu eelnevalt öeldud, avatakse kasutajale (uue baaskeelega automaatsel lisamisel) uue baaskeelega projektikirjeldus, kus võib ta oma tööd (peamiselt grammatikafailiga) jätkata.

Meenutame, et grammatikafaili muutmiseks kaasneb kolme faili töötlemine:

- baaskeelega grammatikafaili *KEEL.jjt* teisendamine failiks *KEEL.jj*;
- parseri lähtefaili genereerimine: *KEEL.jj* $\rightarrow$ *KEELParser.java*;
- parseri kompileerimine: *KEELParser.java* $\rightarrow$ *KEELParser.class*.

Selleks peaks kasutaja failid eraldi avama ja kompileerima toodud järjekorras: esialgu *KEEL.jjt*, siis *KEEL.jj* ja lõpuks *KEELParser.java*.

Võib oletada, et selline grammatikafaili muutmise protsess osutub väga tülikaks. Probleemi lahendab projektikirjelduse sobivalt defineeritud atribuutide osa. Nimelt on baaskeelega projektikirjelduse faili alamprojekti *Grammatikad* (joonis 4.7) *Path* ja *Save-script* rühmad konstrueeritud järgmiselt:

- *Path-script* atribuutides leiduvad kaks parameetrit, millega defineeritakse parseri lähtefaili (*JAVACC*) ja selle (*JAVAPARSER*) kompileerimise eeskirjad
- *Save-script Process* atribuut oli täiendatud eelmises punktis kirjeldatud *JAVACC* ja *JAVAPARSER* parameetritega

Tänu sellistele atribuutidele toimubki *KEEL.jjt* faili salvestamisel iga kord eelpool kirjeldatud failide automaatne kompileerimine:

KEEL.jjt $\rightarrow$ *KEEL.jj* $\rightarrow$ *KEELParser.java* $\rightarrow$ *KEELParser.class*.

Kokkuvõttes, grammatikafaili iteratiivse muutmise tülikuse probleem on lahendatud baaskeelega projektikirjelduse loomisega ning selle täiendamise-
ga lisaatribuutidega, et võimaldada grammatikafaili automaatset kompileerimist.

4.7 Süsteemi *AmadeusJSN* testimine

Süsteemi *AmadeusJSN* esialgse testimise aluseks oli töö kahe "mängu-keelega". Lähtekeelena kasutati eespool kirjeldatud metsa vasaku suluesituse keelt (*VSE*) ja analoogilist, metsa parema suluesituse keelt *PSE*. Katsetati vastavate baaskeelte lisamist, kustutamist, taastamist. Mõlema keele korral realiseeriti autori poolt nii skeemistid (grammatika-põhiselt) kui ka tekstualiseerijad ("käsitsi").

Reaalseks praktiliseks (juhendaja poolt teostatud) testjuhuks on programmeerimiskeele *Java vers.1.5* edukas integreerimine süsteemi *AmadeusJSN*. Vastav skeemistismudel leidub Lisas 9. Integreerimise tulemusena saab nüüd süsteemi nt. kasutada selle programmeerimiskeele lähtekoodi skeemikujul vaatlemiseks [3].

Käesolevas jaotises vaatleme mõningaid esialgse testimisega (keeltega *VSE* ja *PSE*) seotud küsimusi.

4.7.1 Baaskeel *PSE* lisamine

Metsa parema suluesituse keel *PSE* on väga sarnane keelega *VSE*. Alljärgnevas selgitame selle keele automaatse lisamise käiku üksikute sammude kaupa.

1. Keele *PSE BNF* grammatika:

```
metsaPSE ::= "("puuPSE "(", "puuPSE)* ")"
puuPSE ::= [metsaPSE] juur
juur ::= IDENTIFIER
```

Märgime, et selle kohaselt näeks töö kolmandas peatükis (joonisel 3.1) näitena toodud metsa esitub kirjena $((B, (D, E)C, F)A, (Y)X)$. Erinevalt vasakust suluesitusest paikneb puu juur oma alampuude metsa järel.

2. Süsteemi lisatakse baaskeel nimega *PSE*, kasutades *AmadeusJSN* automaatseid vahendeid (*Base + Add new language*). Selle tulemusena luuakse nii antud baaskeelega seotud projekt kui ka kõik muud seonduvad failid.

3. Töötades projekti all arendatakse *PSE* keele grammatikafail *BNF* grammatikast lähtudes. Antud juhul ei kasutatud grammatika skeemkuju, vaid *JJTree*-grammatika koostati lihtteksti failina (Lisa 10).
4. Grammatikafaili töötlemisel (projekti all toimetetava grammatikafaili salvestamisel, *File + Save*) luuakse automaatselt *PSE* baaskeeke parser.
5. Lähtudes konkreetse näitemetsa (redutseeritud) parsipuust (joonis 4.8) koostatakse keele *PSE* skeemkonversiooni mudel (joonisel 4.9). Nagu näha, osutub see täiesti analoogiliseks varem tutvustatud mudeliga keele *VSE* jaoks.
6. Programmeeriti klassi *BaseLanguagePSE* meetod *textualize*. Selle meetodi kood on päris lihtne ja lühike (vt. Lisa 11).

Sel teel, keele *PSE* eduka integreerimisega, sai veelkord testitud uue baaskeeke automaatse lisamise funktsioon uues süsteemis.

4.7.2 Keelte *VSE* ja *PSE* vastastikune konverteerimine

Pärast seda, kui mõlema uue baaskeeke jaoks olid realiseeritud nii skeemistamine kui ka tekstualiseerimine, sai testimise eemärgil katseatud uut süsteemi kui konverterit tüüpi $PSE \rightarrow VSE$. Konverteerimise protsess on kujutatud joonisel 4.10.

Oletame, et on olemas lähtekeeke *PSE* lihttekst, nt $((E, (D, C)B)A, (Y)X)$, mida soovitatakse konverteerida sihtkeeke *VSE* lihttekstiks. Antud näite korral oleks siis oodatavaks korrektseks tulemuseks $(A(E, B(C, D)), X(Y))$.

Konverteerimine süsteemi *AmadeusJSN* abil on väga kerge. Esiteks tuleb avada uus aken (*Frame + New*) ja selles kujutada konverteeritav lähtetekst. Viimase võib otse tippida klaviatuurilt uuena avatud (*File + New*) tühja skeemteksti või siis sisestada olemasolevast lihtteksti failist (*File + Read text*). Konverteeritava teksti baaskeekeks tuleks omistada *PSE* (*Base + Set ... PSE*). Seejärel sooritatakse skeemkonversioon $PSE \rightarrow SK$ (*Tools + Sketchify*), uues aknas kuvatakse lähtetekstis esitatud mets hierarhilisel skeemkujul. Kui viimasele omistada nüüd baaskeekeks *VSE* (*Base + Set ...*

VSE) ja rakendada tekstualiseerimist (*Tools + Textualize*), saadaksegi uues aknas selle sama metsa vasak suluesitus.


Tulemus lähteteksti $((E, (D, C)B)A, (Y)X)$ korral on kujutatud joonisel 4.11. Vertikaalne kuju on määratud meetodiga *textualize* klassis *BaseLanguageVSE*, mis lisab tulemusse reavahetusi ja eeltühikuid metsa struktuuri paremaks väljatoomiseks. Meenutame, et grammatika kohaselt tühemikke (nagu reavahetuse ja tühiku sümbolid) ignoreeritakse.

Süsteemi on testimise eesmärgil katsetatud ka konverterina tüüpi $VSE \rightarrow PSE$. Sellesuunalise konverteerimise käik on ülalkirjeldatuga täiesti sümmeetriline.


4.8 Kokkuvõtteks

Töö põhitulemuseks on süsteemi *Amadeus* uus versioon *AmadeusJSN*, millele on lisatud automatiseerimise tehnilised lahendused baaskeeltega manipuleerimiseks: uue baaskeelte lisamine, olemasoleva kustutamine ja kustutatud baaskeele taastamine. Samuti on kirjeldatud süsteemi kataloogi *Amadeus* üldine ülesehitus ja antud ülevaade *Amadeus.properties* failist, kust võetakse erinevad parameetrid süsteemi *Amadeus* korrektseks töötamiseks. Lugejale tutvustatakse süsteemi *Amadeus* projekti mõiste. Grammatikafaili iteratiivse arendamisetoeks on spetsifitseeritud vastav baaskeele projektikirjeldus. Töö üks eesmärkidest oli muuta kasutaja töö mugavamaks ja lihtsamaks baaskeeltega manipuleerimisel süsteemis *Amadeus*.

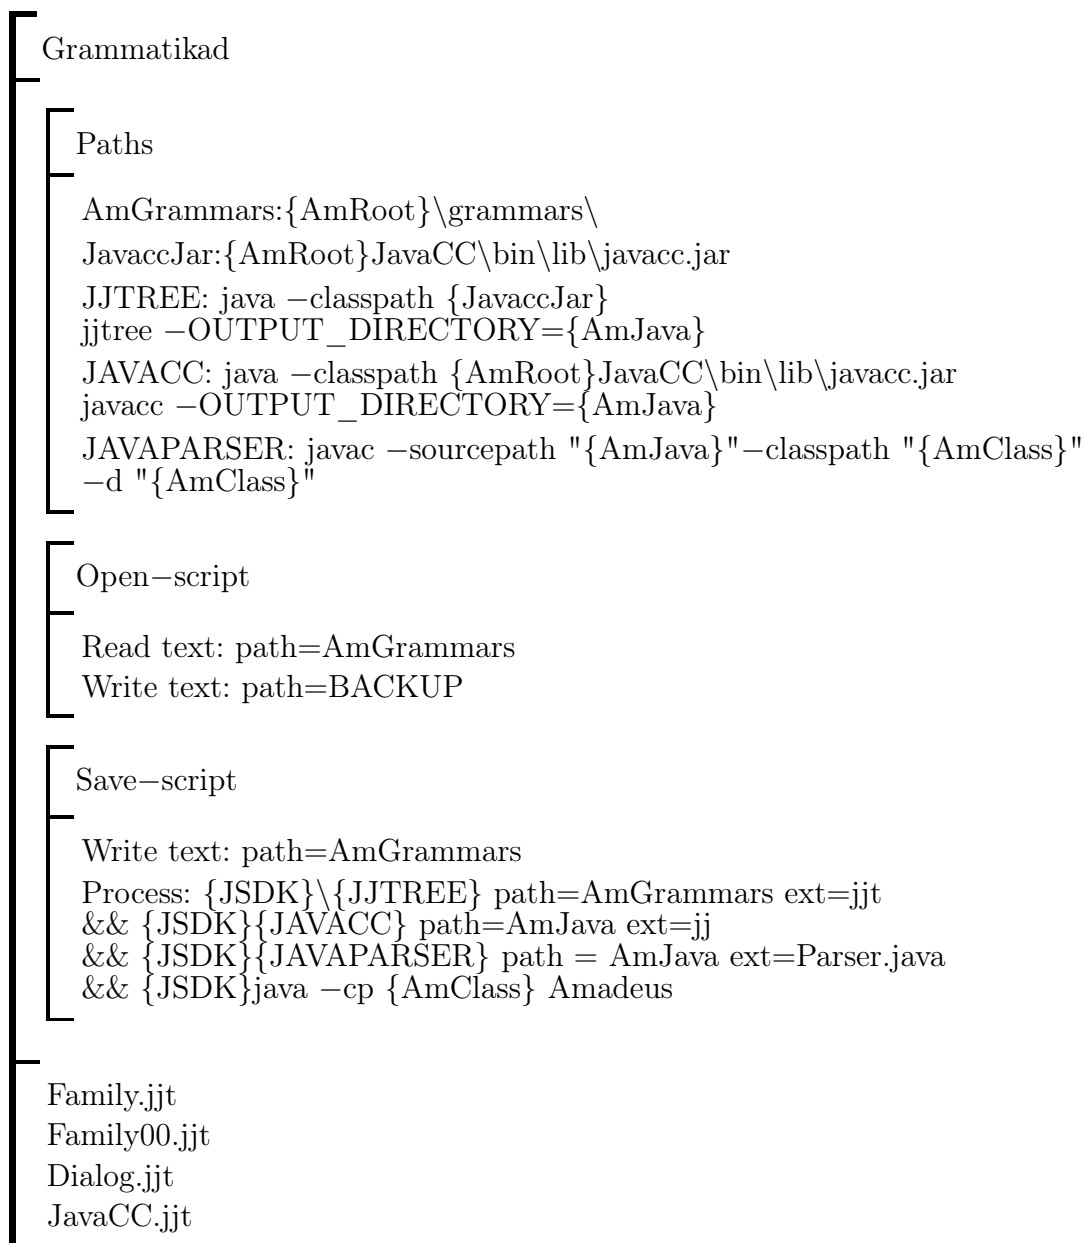
Loodud versioon on testitud lihtsate lähtekeelte (metsa vasaku/parema suluesituse keelte) integreerimise teel. Samuti on süsteemi juba reaalselt rakendatud programmeerimiskeele *Java (vers.1.5)* skeemisti loomiseks.




Grammatikad ja parserid



Joonis 4.6: Baaskeelee projektikirjeldus



Joonis 4.7: Alamprojekti *Grammatikad* atribuudirühmad *Path-script* ja *Save-script*.



Joonis 4.9: Baaskeele *PSE* skeemmudel



Joonis 4.10: *PSE*-keelse teksti konverteerimine *VSE*-keelseks tekstiks.

This sketchy text is generated by AMADEUS

```
(
  A
  (
    E
    ,
    B
    (
      D
      ,
      C
    )
  )
  ,
  X
  (
    Y
  )
)
```

This sketchy text is generated by AMADEUS

Joonis 4.11: *PSE*-keelse teksti konverteerimistulemus *VSE*-keelseks tekstiks.

Kokkuvõte

Aktuaalseks küsimuseks arvutikeelse info pideva suurenemise tõttu on eriotstarbeliste arvutikeelte teisendajate, sh. konverterite loomine. Enamasti on aga eriteisendaja loomine väga kulukas. Töös keskendutakse just konverteriarendamise probleemile.

Üha suurenev vajadus erinevat tüüpi konverterite järele on tõstatanud loomuliku küsimuse, kuidas oleks võimalik automatiseerida konverterite loomist. Muidugi on soovitav luua võimalikult üldist tüüpi konvertereid. Kõige ideaalsem oleks üks universaalne konverter tüüpi *Any-to-Any*. Nii üldisel kujul püstitatud ülesanne oleks ilmselt lahendamatu, kuid peale probleemi mõistlikku kitsendamist saab teha olulisi reaalseid samme konverteriarenduse automatiseerimiseks. Probleemi võib sõnastada järgmiselt: on antud lähtekeel, sihtkeel ja konverteerimise mudel, ülesandeks on automaatselt genereerida vastav konverter. Töös selgitatakse konverteriarenduse võimalusi süsteemi *Amadeus* platvormil.

Käesolevas töös välja töötatud lähenemisviis võib näida esmapilgul küll piiratud, eeskätt sihtkeele (milleks on skeemkeel) fikseeritust arvestades, kuid samas iseloomustab seda universaalsus lähtekeelte pere osas: ainasaks nõudeks lähtekeelele on selle formaalse grammatika olemasolu. Pealegi on väljatöötatud süsteemis võimalik arendada ka üldist tüüpi konvertereid, kasutades skeemkeelt konverteermise vahekeele rollis.

Antud väitekirja põhitulemuseks on süsteemi *Amadeus* uus versioon *AmadeusJSN*, mis on saadud lähteversioonist *AmadeusJS* konverteriloomet toetavate erisuste lisamise teel, ning kus on võimalik skeemkonverterite kiire arendamine. Põhiliseks võtmeküsimuseks on sealjuures uue baaskeele integreerimine süsteemi ning baaskeeltega töötamine ja grammatikafaili re-

digeerimine, samuti skeemistamise ja tekstualiseerimise meetodite efektiivne realiseerimine.

Skeemkonverteri arendamiseks süsteemis *Amadeus* tuleb spetsifitseerida lähtekeele grammatika ja integreerida vastav uus baaskeel. Viimases tuleb realiseerida vähemalt parsimise ning skeemistamise osad. Skeemkonverteri kasutamiseks tuleb eelnevalt veel konkretiseerida konversiooni mudel. Taolist moodust vahetult kasutades on koostöös juhendaga (J. Kiho) loodud konverter *JJTree/JavaCC* kujul kirjutatud lihttekstiliste grammatikafailide viimiseks skeemkujule. Vastavalt lisati uus ka baaskeel nimega *JavaCC*.

Automatiseeritud on baaskeeltega manipuleerimine (uue baaskeele lisamine, olemasoleva kustutamine, kustutatud baaskeele taastamine). Baaskeele grammatikafaili iteratiivse arendamise toeks on spetsifitseeritud vastav projektikirjeldus, millega töötades on kasutaja töö mugav ja efektiivne.

Loodud versioon on testitud lihtsate lähtekeelte (metsa vasaku/parema suluesituse keelte) integreerimise teel. Samuti on süsteemi juba reaalselt rakendatud programmeerimiskeele *Java* (*vers.1.5*) skeemisti loomiseks.

Grammar-based software converter development

Master work

Natalia Tomassova

Abstract

The software conversion process is understood as a lightweight translation of computer texts, focused on changing the outer form of texts. Currently, one of the most popular conversion types is $Some \rightarrow XML$, where texts in some data or program description language are re-formatted into certain *XML* format.

The aim of this thesis is to investigate possibilities of automation of converter development processes.

Overviews of some examples of existing converters (*DELL*, *XFlat*, *LinkGrammar*) are presented. The notion of software converter is refined. The main features of the existing multi-editor *AmadeusJS* are introduced. It uses a special hierarchical (sketchy) form for texts under processing. Therefore, the conversion tasks ($Some \rightarrow SketchyText$, and *vice versa*) are inherent for *AmadeusJS*, and it can naturally be considered as a framework for converter development.

A language, incorporated into *Amadeus* is called the base language. For any base language LK , the converters of types $LK \rightarrow SketchyText$ and $SketchyText \rightarrow LK$ are implemented. So, to get a converter $LK' \rightarrow LK''$, the both languages, LK' and LK'' are to be incorporated. After that, the sys-

tem is ready to perform needed conversion by sequentially applying $LK' \rightarrow SketchyText$ and $SketchyText \rightarrow LK''$, provided that necessary conversion model is defined.

The thesis results in creating the new version of *Amadeus* system – *AmadeusJSN*. It enables to incorporate automatically new base languages: the user has only to define the grammar in the *JJTree* form. Also, it supports iterative developing and debugging of new grammars. For that purpose, the project facility of *Amadeus* is applied. Additional base language operations, such as new base language addition, base language removing and restoration of removed early base language, are also implemented in *AmadeusJSN*.

Kirjandus

- [1] J.Kiho. *SKM. Sketchy Modeling of Computer Texts*. 18th January 2000, 64 p.
- [2] J.Kiho, R.Ustitch, M.Tudre. *Designing Computer Texts with AMADEUS*. In: J.Penjam (Ed.) *Software Technology. Proceedings of the Fenno-Ugric Symposium FUSST'99. Technical Report CS 104/99. Institute of Cybernetics at Tallinn Technical University*. Tallinn 1999, 151-162.
- [3] J.Kiho, *Amadeus-Jasovi-5*.
<http://www.cs.ut.ee/~kiho/Amadeus-Jasovi-5/>
- [4] K.Heero, *Parsigeneraator JavaCC ja skeemmodelleerimine*. Magistritöö. TÜ, 2002, 93 lk.
- [5] J.Kiho. *Algoritmid ja andmestruktuurid*. Kolmas, parandatud ja täiendatud trükk. TÜ, 2003, 147 lk.
- [6] A.Reitsakas, *Analüüsivahend JJTree/JavaCC ja selle rakendamine toimetiarenduses*. Magistritöö. TÜ, 2003, 69 lk.
- [7] *JavaCC: Grammar Files*.
<https://javacc.dev.java.net/doc/javaccgrm.html>
- [8] *JavaCCTM: JJTree Reference Documentation*.
<https://javacc.dev.java.net/doc/JJTree.html>
- [9] *Overview of XML Convert and XFlat*.
<http://www.unidex.com/overview.htm>

- [10] *W3C, DEL-Data Extraction Language.*
<http://www.w3.org/TR/data-extraction>
- [11] *X-FETCH PERFORMERTM. Fast Application Development in Java and XML Environments.* <http://www.x-fetch.com/performer.html>
- [12] *Link Grammar.* <http://www.link.cs.cmu.edu/link/>
- [13] J.Kiho, S.Solopova. *Heterogeneous File Projects in the Sketchy Modeling Environment. The Tenth Nordic Workshop on Programming and Software Development Tools and Techniques.* IT-University, Copenhagen, August 18-20, 2002, pp. 71-79
- [14] S.Golovko, *Projekti mõiste ja teostus süsteemis Amadeus.* Magistritöö, TÜ, 2004, 72 lk.
- [15] *Extensible Markup Language (XML),*
<http://www.riik.ee/xml/trans/REC-xml-19980210-ee.html>

Indeks

CVS, Comma Separated Values, 13
DEL, Data Extraction Language, 8
LinkGrammar, 15
XFlat keel, 14
flat file, lamefail, 12

Amadeus, 20

algsätingud, 52

baaskeel, 22

elementaarpäis, 21

grammatikafail, 31

haru, 21

kataloogi struktuur, 51
konverteerimise mudel, 8
konverteerimise mõiste, 7
konverteerimise tüüp, 7
kuvakuju, 22

lamefail, 12

lisaproduksioon, 31

lähtekeel, 7

metsa vasak suluesitus, 27

monoskeem, 21

moodulskeem, 28

parsipuu redutseerimine, 39
parsipuu skeemkuju, 38
primitiiv, 21
primitiivne mitteterminal, 38
primitiivpäis, 21
produksiooniskeem, 35
projekt, 53
projektifail, 54
projektkirjeldus, 54
puuvaade, 28

sihtkeel, 7

skeemi päis, 21

skeemistamine, 24

skeemkonversiooni mudel, 40

skeempuu, 21

skeemtekst, 21

skeemteksti mudel, 21

skeemvaade, 29

teksti volimine, 23

tekstualiseerimine, 24

vaade, 22

vasak suluesitus, 27

Lisad

- Lisa 1. Keele *VSE JJTree*-grammatika lihtteksti kujul
- Lisa 2. Baaskeele klassi mall
- Lisa 3. Ülemklass *BaseLanguage*
- Lisa 4. Klassi *Item12Listener* struktuur
- Lisa 5. Klass *Item13Listener* ja meetod *userRemoveLang*
- Lisa 6. Klassi *Item14Listener* struktuur
- Lisa 7. JavaCC grammatikafail
- Lisa 8. *JavaCC* skeemmudel
- Lisa 9. *Java5* skeemmudel
- Lisa 10. Keele *PSE JJTree*-grammatika lihtteksti kujul
- Lisa 11. Klass *BaseLanguagePSE*
- Lisa 12. *AmadeusJSN* ja käesoleva magistritöö e-koopia

Lisa 1.

Keele *VSE JJTree*-grammatika lihtteksti kujul

```
options { JAVA_UNICODE_ESCAPE = true; STATIC = false; }

PARSER_BEGIN(VSEParser)

import java.io.*;

public class VSEParser {
    static Token t;
    static Sketch parse(String inputFileName) throws ParseException,
    FileNotFoundException {
        VSEParser parser = new VSEParser(new FileReader(inputFileName));
        SimpleNode t = parser.Start();
        Sketch parsipuu = BaseLanguageParseTree.toSketch
        (t, VSEParserTreeConstants.jjtNodename);
        return(parsipuu);
    }
}

PARSER_END(VSEParser)

SPECIAL_TOKEN : {
    " "
    | "\t"
```

```

| "\r"
| "\f"
| "\n"
}

/* IDENTIFIERS */
TOKEN :
{
< IDENTIFIER: <LETTER> (<LETTER> | <DIGIT>)* >
| < # LETTER: [ "A-"Z", "_", "a"- "z"] >
| < # DIGIT: [ "0"- "9"] >
}

/* SEPARATORS */
TOKEN : {
< LPAREN: "(" >
| < RPAREN: ")" >
| < COMMA: "," >
}

TOKEN :
{
< ANYTHING_ELSE: ( ~ [ ] ) >
}

/*productions-produktsioonid*/
void tIdentifier(): {}{
t = <IDENTIFIER>
{jjtThis.addText(t.image);}}

/** THE GRAMMAR SPECIFICATION STARTS HERE **/
SimpleNode Start() : {} // algussümbol
{
metsaVSE()

```

```

<EOF>
{ return jjtThis; }
}
Token metsaVSE() #void:
{
Token t = getToken(1);
}
{
"("puuVSE() (","puuVSE())* ")"
{ return t;}
}
void puuVSE():
{}
{
juur() [metsaVSE()]
}
void juur() :
{}
{
(tIdentifier())
}

```

Lisa 2.

Baaskeele klassi mall


```

import java.util.*;
import java.io.*;

class BaseLanguageLK extends BaseLanguage - - - asendada LK !

static AmFrame frame;

BaseLanguageLK() - - - asendada LK !
- konstruktor
type = LK; - - - asendada LK !

PARSE
■ public boolean parse(SketchyText skt0,
static boolean oliViga;

    public Sketch parse(String fnimi0, SketchyText skt0)
    - failist fnimi0, kus on väljaviidud skt0 (viimane: veateate jaoks)
    Sketch s = null;

    !!
    - parser: fnimi0 ==> Sketch s
    oliViga = false;
    s = LKParser.parse(fnimi0); - - - asendada LK !
    ■ (FileNotFoundException e)
    ■ (ParseException e)
    - - - s on nüüd parsipuu lihtskeem (või veateade)
    ← s

    ■ private String prepareSourceTextFile(SketchyText skt0)
    ■ public static Sketch errorMsgSketch(SketchyText skt0, String viga)

PARSE
■ SKETCHIFY
■ REDUCE
■ TEXTUALIZE
■ NORMALIZE
■ PREPARE TEX
■ Edit controls

```

Lisa 3.

Ülemklass *BaseLanguage*

```

import java.awt.*;
import java.awt.event.*;
class BaseLanguage
  abstract class BaseLanguage - - - baaskeelte ülemklass

  LIIDES
    - - - väljastavad ainult veateate:
    ■ public boolean sketchify(SketchyText skt0,
    ■ public boolean textualize(SketchyText skt0,
    ■ public boolean normalize(SketchyText skt0,
    ■ public boolean parse(SketchyText skt0,
    ■ void reduce(Sketch s)
    ■ void prepareTex(Sketch s)
    - - - valmis meetodid, võib ka üledefineerida:
    ■ byte nextPrimitiveMemberType(byte prev)
    ■ byte nextSchemeType(Scheme s)
    ■ byte typeForBranchHead(Sketch s)
    ■ byte nextPrimitiveHeadType(Scheme s, byte prev)

  LIIDES
  MUUDETAVAD*
    ■ KEELTE KONSTANDID
    ■ KEELTE NIMED
    ■ KASUTATAVATE KEELTE LOETELU
    ■ KÕIGI KASUTATUD KEELTE NIMED
    ■ newBaseLanguage
  MUUDETAVAD*
    ■ KLASSIVÄLJAD JA -MEETODID
class BaseLanguage


```

MUUDETAVAD

```

- KEELTE KONSTANDID
- ★ static final byte
-
-   JAVA = 0;
-   LATEX = 1;
-   ...
-   VSE = 13;
-   - - - uus konstant lisatakse loetelu lõppu
- KEELTE KONSTANDID
- KEELTE NIMED
- static String[] items =
-
-   [
-     "Java"
-     , "LaTex"
-     ...
-     , "VSE"
-     - - - uus nimi lisatakse loetelu lõppu
-   ]
- ;
- KEELTE NIMED
- KASUTATAVATE KEELTE LOETELU
- kasutatavate keelte konstandid (suvalises järjekorras)
- static final byte[] currentSetOfBL =
-
-   [
-     JAVA
-     , LATEX
-     ...
-     , VSE
-   ]
- ;
- KASUTATAVATE KEELTE LOETELU
- KÕIGI KASUTATUD KEELTE NIMED
- static String[] useditems =
-
-   [
-     "Java"
-     , "LaTex"
-     ...
-     , "VSE"
-   ]
- ;
- KÕIGI KASUTATUD KEELTE NIMED

```



Lisa 4.

Klassi *Item12Listener* structuur

```
import java.awt.*;
import javax.swing.*;
import java.io.*;
import java.lang.*;

class Item12Listener
class Item12Listener implements ActionListener
{
    AmFrame frame;;
    String title;;
    ■ Item12Listener(AmFrame fr)
    ■ public void createLangProjectFile(String title)
    ■ public static int lang_exists(String title)
    ■ public static int returnMaxLangNo()
    ■ public static boolean lang_inwork(String title)
    ■ public void createLangFiles(String title)
    ■ public void actionPerformed(ActionEvent event)
class Item12Listener
```

```

BaseLanguage klassi meetod userRemoveLang
static boolean userRemoveLang(Frame frame)

String defDir = Default.AmadeusDirectory;
String proj_dir=defDir+"Portfolio\\";
  ■ küsib baaskeele kasutajalt
int bli = -999; - - - kompilaatorile
  dialoogi tulemuse töötlemine
  ??d.getTulemus()
  ? AmDialog.CANCEL:
← false
  ? AmDialog.SELECT:
    bli = list.getSelectedIndex();
    //BaseLanguage bl= new BaseLanguage(bli);
    todayItem = items[bli];
    String proj_path =defDir+"Portfolio\\"AmadeusProjekt.html";
    baaskeele valideerimine
    Item13Listener.langValidation(todayItem)==0 ?
      AmDialog d1 = new AmDialog(frame, AmLocale.Alert(),
      AmDialog.B_OK, AmLocale.Base_language_delete());
    ←
      ■ baaskeele kustutamine*
      baaskeele valideerimine
    ←
    dialoogi tulemuse töötlemine
  ← true
BaseLanguage klassi meetod userRemoveLang


```

Lisa 5. Klass *Item13Listener* ja meetod *userRemoveLang*

```
import java.awt.*;
import javax.swing.*;
import java.io.*;
import java.lang.*;

class Item13Listener implements ActionListener

static AmFrame frame;;
String title;;
    ■ Item13Listener(AmFrame fr)
    ■ public static void removeLangProjectFile(String title)
    ■ public static int langValidation(String title)
    ■ public static void backupDir(String path,String title)
    ■ public static void backupDirCreate(String path)
    ■ public static boolean deleteDirectory(File path)
    ■ public static void copyFile(String kust, String kuhu)
    ■ public static void deleteFile(String kust)
    ■ public static void openProjectFile(String proj_path)
    ■ public static void removeLangFiles(String title)
    ■ public static void removeLangFilesFinal(String title)
    ■ public void actionPerformed(ActionEvent event)
```

Lisa 6.

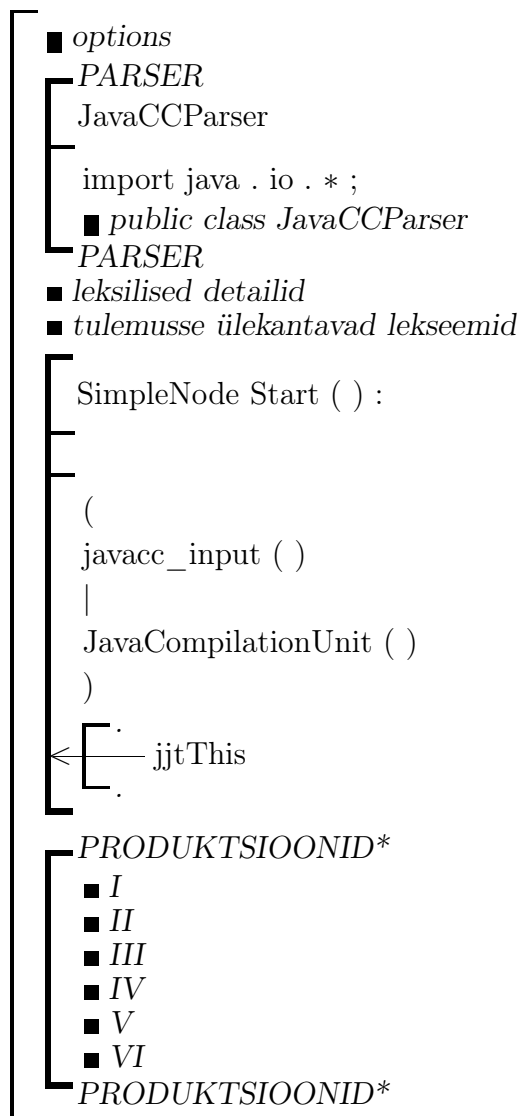
Klassi *Item14Listener* structuur

```
import java.awt.*;
import java.awt.event.*;
import javax.swing.*;
import javax.swing.event.*;
import java.io.*;
import java.lang.*;

class Item14Listener implements ActionListener - - - Restore BaseLanguage
{
    AmFrame frame;;
    String title;;
    ■ Item14Listener(AmFrame fr)
    ■ public static void restoreLangFiles(String title)
    ■ public static int lang_nr(String title)
    ■ public static boolean lang_inwork(String title)
    ■ public static void rcopyFile(String kust, String kuhu)
    ■ public static int lang_restore(String fdir)
    ■ public static void removeLangFiles(String title)
    ■ public void actionPerformed(ActionEvent event)
```

Lisa 7.

JavaCC grammatikafail



PRODUKTSIOONID

I

- - - JJTree/JavaCC-spetsiifilised:

- Token javacc_input () :
- void parser () :
- void parseriNimi () :
- void javacc_options () :
- void javacc_options_list () :
- void option_binding () :
- void production () :
- void javacode_production () :
- void javacode_productionPäis () :
- void bnf_production () :
- void bnfproductionBlock () :
- void bnfproductionExpansion () :
- void bnfproductionPäis () :
- void regular_expr_production () :
- void rep_prefiks () :
- void rep_kind () :
- void rep_specification () # void :
- void token_manager_decls () :
- void regexpr_spec () :
- void regexpr_specBlock () :
- void expansion_choices () :
- void expansion () :
- void local_lookahead () # void :
- void expansion_unitBlock () :
- void expansion_unit () :
- void regular_expression () :
- void complex_regular_expression_choices () # void :
- void complex_regular_expression () # void :

I

II

- void complex_regular_expression_unit () # void :
- void character_list () # void :
- void character_descriptor () :
- void identifier () :
- void node_descriptor () # void :
- JAVACODE void node_descriptor_expression ()
- JAVACODE Token readTokens ()
- void JavaIdentifier () # void :
- void ShiftOps () :
- void OtherAssignmentOps () :
- void CompilationUnit () # void :
-
- - - Java-spetsiifilised:
- Token JavaCompilationUnit () :
- void PackageDeclaration () :
- void ImportDeclaration () :
- void TypeDeclaration () # void :
- void ClassDeclaration () :
- void piiritlejad () :
- void UnmodifiedClassDeclaration () # void :
- void klassiPäis () :
- void ClassBody () :
- void NestedClassDeclaration () :
- void piiritlejadNested () :
- void ClassBodyDeclaration () :
- void MethodDeclarationLookahead () :
- void InterfaceDeclaration () :
- void NestedInterfaceDeclaration () :
- void UnmodifiedInterfaceDeclaration () :
- void InterfaceMemberDeclaration () :

II

III

- void *FieldDeclaration* () :
- void *VariableDeclarator* () # void :
- void *VariableDeclaratorId* () # void :
- void *VariableInitializer* () # void :
- void *ArrayInitializer* () :
- void *Massiivialgati* () :
- void *MethodDeclaration* () :
- void *MethodBlock* () :
- void *MethodDeclarationPäis* () :
- void *MethodName* () :
- void *MethodDeclarationModSpec* () :
- void *MethodDeclarationSpecificator* () :
- void *MethodDeclarationModifier* () :
- void *MethodDeclarator* () :
- void *FormalParameters* () # void :
- void *FormalParameter* () # void :
- void *ConstructorDeclaration* () :
- void *ConstructorPäis* () :
- void *ConstructorBlock* () :
- void *ExplicitConstructorInvocation* () :
- void *Initializer* () :
- void *InitializerNonStatic* () :
- void *InitializerStatic* () :
- void *Type* () # void :
- void *PrimitiveType* () # void :
- void *ResultType* () # void :
- void *Name* () # void :

III

IV

- void NameList () # void :
- void Expression () # void :
- void AssignmentOperator () # void :
- void ConditionalExpression () # void :
- void ConditionalOrExpression () # void :
- void ConditionalAndExpression () # void :
- void InclusiveOrExpression () # void :
- void ExclusiveOrExpression () # void :
- void AndExpression () # void :
- void EqualityExpression () # void :
- void InstanceOfExpression () # void :
- void RelationalExpression () # void :
- void ShiftExpression () # void :
- void AdditiveExpression () # void :
- void MultiplicativeExpression () # void :
- void UnaryExpression () # void :
- void PreIncrementExpression () # void :
- void PreDecrementExpression () # void :
- void UnaryExpressionNotPlusMinus () # void :
- void CastLookahead () :
- void PostfixExpression () # void :
- void CastExpression () # void :
- void PrimaryExpression () # void :
- void PrimaryPrefix () # void :
- void ClassBodyOptional () :
- void PrimarySuffix () # void :

IV

V

- *void Literal () # void :*
- *void BooleanLiteral () # void :*
- *void StringLiteral () # void :*
- *void IntegerLiteral () # void :*
- *void NullLiteral () # void :*
- *void Arguments () # void :*
- *void ArgumentList () :*
- *void AllocationExpression () :*
- *void ArrayDimsAndInits () # void :*
- *void Statement () # void :*
- *void LabeledStatement () :*
- *void märgend () :*
- *void Label () # void :*
- *void Block () :*
- *void BlockStatement () :*
- *void LocalVariableDeclaration () # void :*
- *void EmptyStatement () :*
- *void StatementExpression () # void :*
- *void SwitchStatement () :*
- *void SwitchPäis () :*
- *void SwitchVariant () :*
- *void SwitchLabel () :*

V

VI

- *void IfStatement () :*
- *void IfHaru () :*
- *void ElseHaru () :*
- *void IfStatementCondition () :*
- *void IfStatementBlock () :*
- *void IfStatementElse () :*
- *void WhileStatement () :*
- *void WhileStatementCondition () :*
- *void WhileStatementBlock () :*
- *void DoStatement () :*
- *void DoSabatingimus () :*
- *void ForStatement () :*
- *void ForPäis () :*
- *void ForStat () :*
- *void ForInit () # void :*
- *void StatementExpressionList () :*
- *void ForUpdate () # void :*
- *void BreakStatement () :*
- *void BreakStatementBlock () :*
- *void ContinueStatement () :*
- *void ContinueStatementBlock () :*
- *void ReturnStatement () :*
- *void ReturnStatementBlock () :*
- *void ThrowStatement () :*
- *void SynchronizedStatement () :*
- *void SynchronizedPäis () :*
- *void TryStatement () :*
- *void TryBlock () :*
- *void TryCatch () :*
- *void TryCatchPäis () :*
- *void TryFinally () :*
- *void AssertStatement () :*

VI

Lisa 8. *JavaCC* skeemmudel

MUDEL

JavaCC/JJTree ja Java vers.< 5 tekstide skeemistamiseks.
Natalia Tomassova ja Jüri Kiho. 2005. a.

Java tekstid ei tohi sisaldada identifikaatoritena
JavaCC/JJTree võtmesõnu, sh. näiteks sõna option.

Tulemus esitub redutseeritud kujul.

Sellele saab rakendada BaseLanguageJava tekstualiseerijat.

⁰*javacc_options*

options

- - - ⁰*option_binding*

⁰*javacc_options*

*

■ *PARSER*⁰*parser*

■ ⁰*bnf_production*

■ ⁰*javacode_production*

■ ⁰*regular_expr_production*

■ ⁰*ClassDeclaration*


*

```

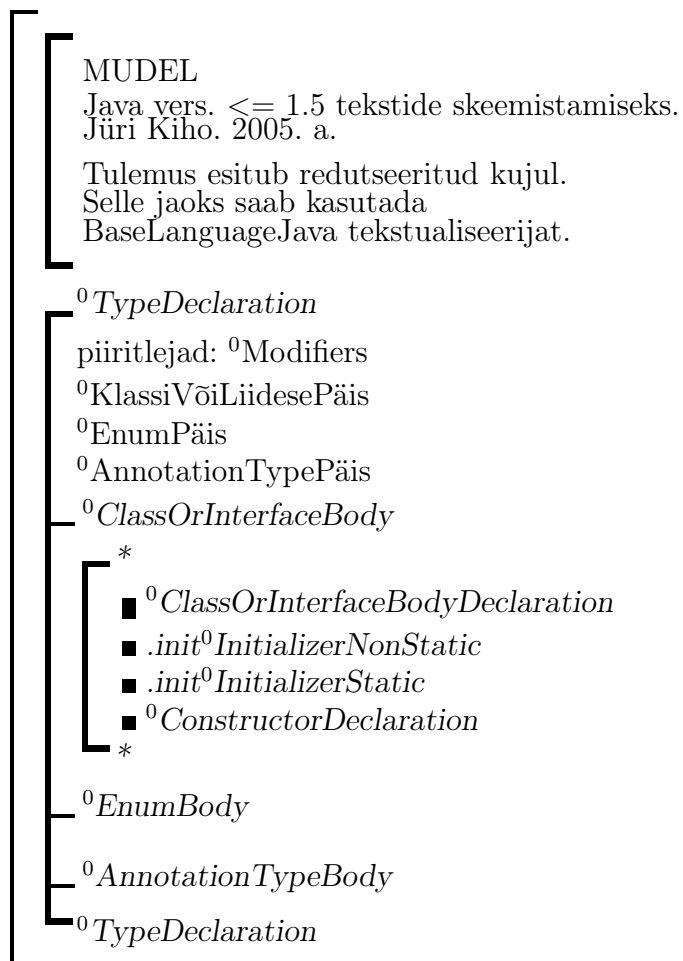
PARSER0parser
┌
└ 0parseriNimi

See skeem avatakse enne BaseLanguageJava
tekstualiseerija rakendamist.
Peab olema kommentaariga "PARSER" ja asuma
esimesel tasemel
(ei või olla hõlmatud nt. kommentaarskeemiga).
PARSER0parser
┌
└ 0bnf_production
┌
└ 0bnfproductionPäis :
┌
└ 0bnfproductionBlock
┌
└ 0bnfproductionExpansion
┌
└ 0expansion_unitBlock
┌
└ 0expansion_unitBlock
┌
└ 0bnf_production
┌
└ 0javacode_production
┌
└ JAVACODE 0javacode_productionPäis
┌
└ 0javacode_production
┌
└ 0regular_expr_production
┌
└ 0rep_prefiks
┌
└ 0rep_kind
┌
└ 0regexpr_spec*
┌
└ resb0regexpr_specBlock*
┌
└ resb0regexpr_specBlock*
┌
└ 0regular_expr_production

```



Lisa 9. *Java5* skeemmudel




```

[.init0InitializerNonStatic
  Ühe punktiga algav lihtskeemi kommentaari
  kasutatakse avamise keelamiseks redutseerimisel.
[.init0InitializerNonStatic
[.init0InitializerStatic
  static
[
[.init0InitializerStatic
[0ConstructorDeclaration
[0ConstructorPäis
[0ConstructorBlock
[0ConstructorDeclaration

```


Lisa 10.

Keele *PSE JJTree*-grammatika lihtteksti kujul

```
options { JAVA_UNICODE_ESCAPE = true; STATIC = false; }

PARSER_BEGIN(PSEParser)

import java.io.*;

public class PSEParser {
    static Token t;
    static Sketch parse(String inputFileName) throws ParseException,
    FileNotFoundException {
        PSEParser parser = new PSEParser(new FileReader(inputFileName));
        SimpleNode t = parser.Start();
        Sketch parsipuu = BaseLanguageParseTree.toSketch
        (t, PSEParserTreeConstants.jjtNodename);
        return(parsipuu);
    }
}

PARSER_END(PSEParser)

SPECIAL_TOKEN : {
    " "
    | "\t"
```

```

| "\r"
| "\f"
| "\n"
}

/* IDENTIFIERS */
TOKEN :
{
< IDENTIFIER: <LETTER> (<LETTER> | <DIGIT>)* >
| < # LETTER: [ "A-"Z", "_", "a"- "z"] >
| < # DIGIT: [ "0"- "9"] >
}

/* SEPARATORS */
TOKEN : {
< LPAREN: "(" >
| < RPAREN: ")" >
| < COMMA: "," >
}

TOKEN :
{
< ANYTHING_ELSE: ( ~ [ ] ) >
}

/*productions-produktsioonid*/
void tIdentifier(): {}{
t = <IDENTIFIER>
{jjtThis.addText(t.image);}}

/** THE GRAMMAR SPECIFICATION STARTS HERE **/
SimpleNode Start() : {} // algussümbol
{
metsaPSE()

```

```

<EOF>
{ return jjtThis; }
}
Token metsaPSE() #void:
{
Token t = getToken(1);
}
{
"("puuPSE() (","puuPSE())* ")"
{ return t;}
}
void puuPSE():
{}
{
[ metsaPSE()] juur()
}
void juur() :
{}
{
(tIdentifier())
}

```

Lisa 11.

Klass *BaseLanguagePSE*

```

import java.util.*;
import java.io.*;

class BaseLanguagePSE extends BaseLanguage
{
    static AmFrame frame;
    ■ BaseLanguagePSE()
    ■ PARSE
    ■ SKETCHIFY
    ■ NORMALIZE
    ■ TEXTUALIZE
    {
        * static
        {
            String nimi="";
        }
        ■ public boolean textualize *
        ■ private void textualize(Sketch sk)*
        ■ private String textualizeHead(Sketch sk)*
        {
            private void writeLine(String str)*
            {
                private void writeLine(String str)
                {
                    Text newT = new Text();
                    newT.rows.removeElementAt(0);
                    newT.rows.addElement(new Row(taane + str, Default.foregroundColor));
                    br1.body.addElement(new PrimitiveMember(Primitive.SIMPLE, newT));
                }
            }
        }
        private void writeLine(String str)*
    }
    ■ TEXTUALIZE
    ■ prepareTex
    ■ nextPrimitiveHeadType
}

```

```

public boolean textualize
public boolean textualize(SketchyText skt0, SketchyText skt1,
AmFrame dialogTargetFrame)

    taane = ";
    frame = dialogTargetFrame;
    Sketch sNew = skt1.main;
    Sketch s = skt0.main;
    sNew.baseLanguage = new BaseLanguageVSE();
    sNew.branch(0).baseLanguage = new BaseLanguageVSE();
    Branch br = s.branch(0);
    br1 = sNew.branch(0);
    br1.body.removeElementAt(0);
    writeLine("(");

    [
    * int i = 0; i < br.body.size(); i++
    [
        Object o = br.member(i);
        o instanceof PrimitiveMember ? - - - komma jaoks
        writeLine(((PrimitiveMember)o).text.toString().trim());
        <-----
        textualize((Sketch)o);
    ]
    [?(i!= br.body.size()-1) writeLine(",");
    ]
    writeLine(")");
    ← true
public boolean textualize

```

```

private void textualize(Sketch sk)
private void textualize(Sketch sk)
int loeRidu = 0;
[
  ★ int i = 0; i < sk.body.size(); i++
  [
    Branch br = ((Branch)(sk.member(i)));
    [?(br.body.size() != 0) writeLine("(");
    [
      ★ int j = 0, n = br.body.size(); j < n; j++
      [
        Object o = br.member(j);
        o instanceof Sketch ?
        textualize((Sketch)o);
        [?(j != n - 1) writeLine(",");
      ]
    ]
    [?(br.body.size() != 0) writeLine(")");
    loeRidu++;
  ]
]
String nimi = textualizeHead(sk);
writeLine(nimi);
private void textualize(Sketch sk)

```

```

private String textualizeHead(Sketch sk)
private String textualizeHead(Sketch sk)
String nimi = "";
int n = sk.head.size();
String nimi1="";
int loeRidu = 0;
    * int i = 0; i < n; i++
    nimi1=nimi1+sk.primitiveHead(i).text.toString().trim();
nimi=nimi1;
← nimi
private String textualizeHead(Sketch sk)

```


Lisa 12. *AmadeusJSN* ja käesoleva magistritöö e-koopia

Köitele lisatud CD sisaldab järgmisi faile:

1. *AmadeusJSN.zip* – süsteemi *Amadeus* viimane versioon (mai 2005).
2. *MagToo.zip* – käesoleva magistritöö e-koopia.
3. *readme.txt* – täiendav abi-info CD kasutajale.