

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTA

ZAVRŠNI RAD br. 828

**SUSTAV ZA AUTOMATSKO
PREPOZNAVANJE IZGOVORA MATIČNOG
BROJA STUDENTA**

Antonio Kolak

Zagreb, lipanj 2009

Zahvala:

Zahvaljujem svom mentoru prof.dr.sc. Davoru Petrinoviću na strpljenju i pomoći pri izradi ovog završnog rada, te vodstvu kroz preddiplomski studij. Srdačnu zahvalu također upućujem i Branimiru Dropuljiću, dipl.ing., na susretljivosti i ustupljenim materijalima.

Jedno hvala upućujem i prijateljima: Marinu Hercegu, Nikoli Repcu na posudbi glasova pri izradi akustičkih modela.

Najveće hvala mojim roditeljima na razumijevanju i podršci tokom preddiplomskog studija.

1 Sadržaj

2 Uvod	5
3 Teorija prepoznavanja govora metodom HMM-a	6
3.1 Osnove HTK alata	6
3.2 Metoda prepoznavanja izoliranih riječi.....	8
3.2.1 Matematika Markovljevih modela (na primjeru).....	9
3.2.2 Parametri modela prema Baum-Welch algoritmu.....	10
3.2.3 Prepoznavanje izoliranih riječi	14
3.2.4 Sažetak metode prepoznavanja izoliranih riječi.....	16
3.2.5 Primjer prepoznavanja metodom izoliranih riječi.....	17
3.3 Metoda prepoznavanja slijednog govora.....	17
3.3.1 Računanje parametara (adaptirani Baum-Welch algoritam).....	18
3.3.2 Sažetak metode prepoznavanja slijednog govora.....	21
4 Opis HTK i Matlab funkcija	22
4.1 HParse	22
4.2 HDMan	24
4.3 HSGen.....	25
4.4 HLEd.....	26
4.5 HCopy	27
4.6 HCompV	29
4.7 HHed.....	29
4.8 HERest	30
4.9 HVite.....	31
4.10 Rjecnik.m.....	32
4.11 Recenice.m	33
5 Ugradnja pravila transkripcije hrvatskog jezika u sustav za automatsko prepoznavanje izgovora matičnog broja studenta	35
5.1 Općenito o transkripcijama.....	35
5.2 Pravila za izradu transkripcije.....	36
6 Gradnja sustava za automatsko prepoznavanje izgovora matičnog broja studenta-korak po korak.....	40
6.1 Preduvjeti za korištenje HTK alata	40
6.2 Ručno korištenje alata-koraci.....	40
6.3 Shematski prikaz sustava	41
6.4 Priprema podataka.....	41

6.4.1	Priprema podataka za trening.....	42
6.4.2	Priprema podataka za test	44
6.5	Treniranje sustava i prepoznavanje željenih uzoraka	48
7	Automatizirana verzija HTK alata	50
7.1	Snalaženje unutar strukture mape <i>HTK_prepoznavanje_govora</i>	50
7.2	Priprema za automatizaciju.....	51
7.2.1	Priprema za automatizaciju-trening.....	51
7.2.2	Priprema za automatizaciju-test	51
7.3	Snimanje uzorka za trening	54
7.4	Snimanje uzorka za test.....	54
7.5	Prepoznavanje.....	55
8	Analiza rezultata sustava za automatsko prepoznavanje matičnog broja studenta.....	57
8.1	Analiza zavisnosti o količini trening materijala	57
8.2	Analiza zavisnosti o broju govornika	58
8.3	Analiza zavisnosti o koeficijentu p	58
9	Zaključak.....	61
10	Literatura.....	62
11	Sažetak	63
11.1	Sustav za automatsko prepoznavanje izgovora matičnog broja studenta	63
12	Abstract	64
12.1	System for automatic identification of pronunciation of students' identification number	
	64	
13	Privitak.....	65
13.1	Privitak -trainprompts.txt.....	65
13.2	Privitak trainprompts.txt/testprompts.txt-trening rečenice ciljane namjene	70
13.3	Privitak-grammar.txt	72
13.4	Privitak-rječnik uz pripadajuće transkripcije-dict_te(PT-1).txt	73

2 Uvod

Danas postoji više metoda koje se primjenjuju u sustavima za prepoznavanje govora. Svaka od njih raspolaže sa vlastitim dobro uhodanim algoritmima. Bez obzira na to, niti jedna od njih ne daje 100 % zadovoljavajuće rezultate za široku primjenu. Uglavnom se radi o jako uskoj specijalizaciji odnosno namjeni sustava. Nakon što su zahtjevi na sustav postavljeni i njegova namjena određena, pokušavaju se optimirati brojni parametri kako bismo zadovoljili postavljane kriterije uz što bolje rezultate.

Metoda korištena u ovom radu je HMM (*eng. Hidden Markov Model-skriveni markovljevi modeli*). Ova metoda je implementirana na naš sustav prepoznavanja govora koristeći se gotovim HTK alatima (*eng. HMM Toolkit*).

HTK alat je napravljen tako da je iznimno prilagodljiv sustavu kojeg se izgrađuje što korisniku ostavlja veliku slobodu u konfiguraciji, ali zahtjeva i veliku količinu interakcije s korisnikom. Samo neke od opcija koje možemo koristiti primjenom HTK alata su: prepoznavanje metodom izoliranih riječi, prepoznavanje metodom vezanog govora, treniranje sa označenim ili neoznačenim govornim iskazima, sa ili bez pripadne transkripcije itd.

Cilj ovog završnog rada je izrada akustičkog modela sustava, kao i pripadajućih transkripcija i gramatike za prepoznavanje matičnih brojeva studenata, te njihovih ocjena i pripadajućeg broja bodova.

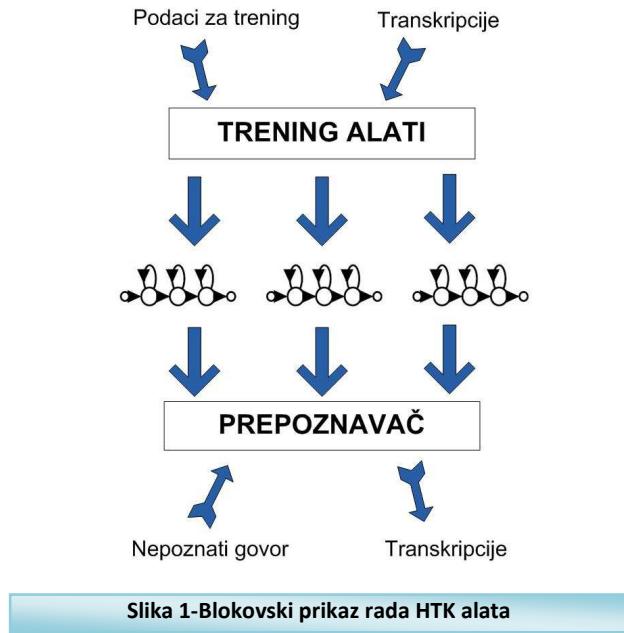
Kako je HTK alat jako opširan te se pojedini koraci opetovano ponavljaju, sustav je automatiziran pomoću odgovarajućih funkcija u matlabu. Uloga matlaba je višeznačajna, od automatizacije treninga i testa do prilagodbe na hrvatski jezik tj. izrade rječnika transkripcija. Sami sustav automatizacije te način izrade rječnika transkripcija je preuzet iz knjiga i radova navedenih u literaturi.

U nastavku rada razrađeni su sljedeće cjeline:

- teorija prepoznavanja govora pomoću skrivenih markovljevih modela (*eng. HMM*)
- uvid u HTK i matlab funkcije, gradnja sustava korak po korak
- prilagodba sustava na hrvatski jezik
- analiza rezultata prepoznavanja

3 Teorija prepoznavanja govora metodom HMM-a

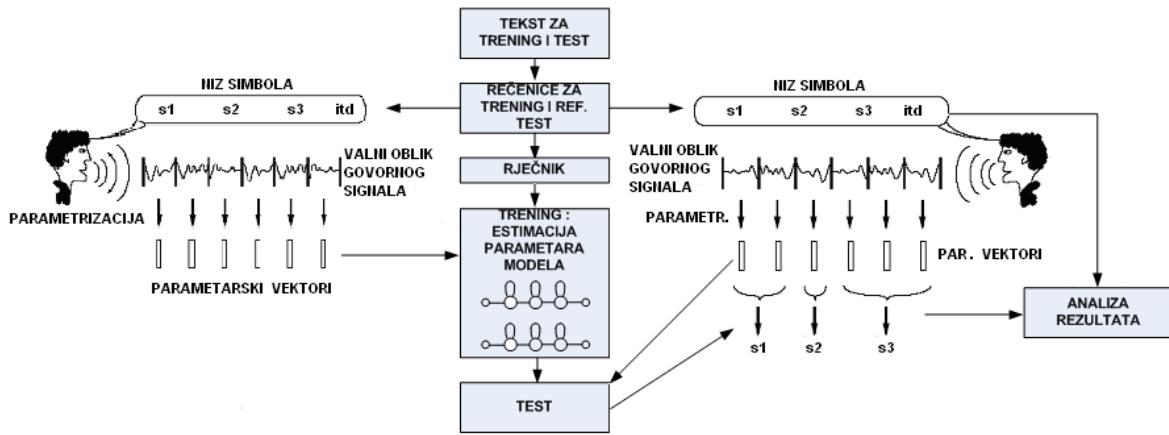
3.1 Osnove HTK alata



Alat HTK (HMM toolkit) je u općem slučaju namijenjen izgradnji i modeliranju skrivenih markovljevih modela. Najširu primjenu nalazi upravo u sustavima za prepoznavanje govora. Sami alat je iznimno složen i konfigurable, a osnovni princip rada tog alata se može objasniti u par koraka. Kao što je prikazano (*slikom 1*), vidljivo je da postoje dva osnovna procesa koji se odvijaju slijedno. To su trening i prepoznavanje. Da bismo mogli pokrenuti te procese važno je prije svega napraviti odgovarajuću pripremu podataka. Iz ovog opisa dobivamo slijedeće korake.

Koraci:

- **priprema podataka**— snima se materijal za trening i test i prave se njihove transkripcije (ako je neoznačen govor), definira se vokabular koji se koristi u prepoznavanju, izradi se rječnik transkripcija na temelju vokabulara materijala za trening i test, i izvrši se parametrizacija govornog signala (u ovom slučaju *.wav u *.mfc)
- **treniranje**—definiraju se modeli – vrsta modela ovisi o načinu treniranja (metoda izoliranih riječi ili metoda slijednih riječi), na kojima se onda vrši višestruka estimacija njihovih parametara na temelju trening uzorka i njihovih transkripcija
- **prepoznavanje**—nakon što su modeli izgrađeni i estimirani kako je zamišljeno, pomoću njih, i pomoću pravila definiranih gramatikom (mogući redoslijed riječi), vrši se transkripcija nepoznatih izgovora namijenjenih za test, te analiza rezultata

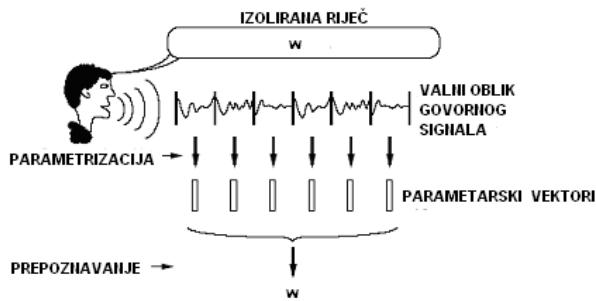


Slika 2-Osnovni princip prepoznavanja govora

Sustavi za prepoznavanje govora općenito prepostavljaju da se govorni signal može predstaviti kao poruka kodirana nizom simbola. Da bismo mogli napraviti reverzibilnu operaciju tj. izvršiti prepoznavanje govora potrebno je govorni signal predstaviti kao niz jednak razmakašnih vektorskih parametara, pri čemu je razmak uzorkovanja takav da se signal može smatrati stacionarnim (10 ms). Uloga alata za prepoznavanje bi u tom slučaju bila povezati vektorske parametre sa pripadnim simbolima (*slika 2*).

Uloga sustava za prepoznavanje je pravilno mapiranje simbola tj. pravilno određivanje korespondencija između govornog signala i parametarskih vektora. Dva problema čine ovo jako teškim. Prvo mapiranje iz simbola u govor nije operacija jedan na jedan zato što različiti simboli mogu dati sličan valni oblik odnosno parametarsku sekvencu. Da bi stvar bila teža, sami valni oblik tako varira ne samo o promjeni govornika, već i o samom raspoloženju govornika i njegovom načinu izgovora. Drugo, granice između simbola ne mogu biti eksplicitno definirane na osnovu valnog oblika. Sukladno zahtjevima imamo više postupaka prepoznavanja. Svaki postupak prepoznavanja ima svoje prednosti i nedostatke, pa odabir ovisi o našim prioritetima. Ukratko : Ako želimo izbjegći probleme vezane uz granice simbola, a ne koristimo neki preveliki vokabular, dobro je odabrati jednostavniju metodu – metodu prepoznavanja izoliranih riječi. A ukoliko želimo koristiti praktički neograničen vokabular, tada nam usprkos problemima vezanim uz granice, više odgovara metoda prepoznavanja slijednog teksta.

3.2 Metoda prepoznavanja izoliranih riječi



Slika 3-Prepoznavanje izoliranih riječi

Da bismo vršili prepoznavanje prvo govorni signal (wav) pretvaramo u parametarski zapis (mfc) i od niza parametara vršimo prepoznavanje (*slika 3*). Neka je svaka izgovorena riječ predstavljena nizom parametarskih vektora opservacija O ,

$$O = o_1, o_2, \dots, o_T \quad (1)$$

Gdje je o_t vektor u trenutku t , tada se problem prepoznavanja svodi na traženje riječi w_i (*gdje je i indeks mogućih riječi*) koja ima najveću vjerodostojnost (*eng. log likelihood*) za danu opservaciju :

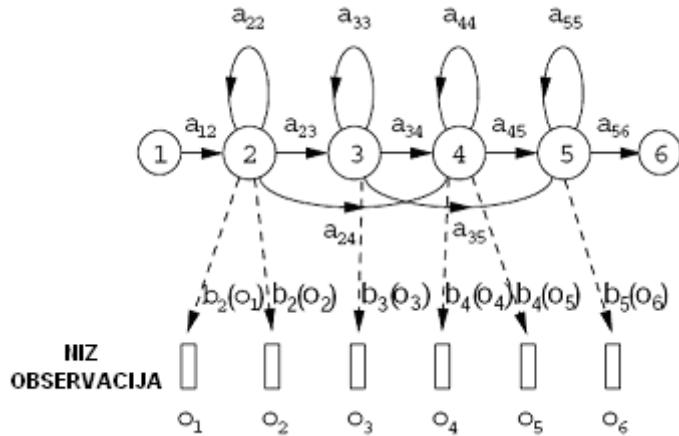
$$\arg \max_i \{P(w_i|O)\} \quad (2)$$

Kako $P(w_i|O)$ nije moguće direktno izračunati, jer matematički gledano, riječi i opservacije nisu ista stvar, mora se uvesti Bayes-ovo pravilo,

$$P(w_i|O) = \frac{P(O|w_i)P(w_i)}{P(O)} \quad (3)$$

koje omogućava izračun $P(w_i|O)$ preko $P(O|w_i)$ i $P(w_i)$. Upravo $P(O|w_i)$, koja se raspisuje preko $P(o_1, o_2, \dots | w_i)$, razlog je korištenja Markovljevih modela. Ako pretpostavimo da je svaka riječ definirana jednim modelom (*ako se radi o slijednom govoru, onda je to puno složenije*), tada se na dosta lakši način može izračunati relativno složena vjerodostojnost $P(O|w_i)$.

Ako pogledamo jedan primjer Markovljevog modela (*slika 4.*),



Slika 4-Markovljev model M

tada možemo zaključiti da se radi o automatu s konačnim brojem stanja, koja su slijedna, s time da prvo i zadnje stanje nisu emitirajući. Iz slike je vidljivo da model na izlazu daje opservacije O (koje su vremenski slijedne), što je suprotno od onog što nam zapravo treba u relaciji (2). To je još jedan razlog korištenja Bayes-ovog pravila. Jedna od važnih prepreka je i da se kod prepoznavanja radi bez podatka o prijelazu iz stanja u stanje (*modeli se nazivaju - skriveni*), što dodatno komplificira stvari i daje složeniju matematiku.

Dakle, kad se prepoznaće govor, jedini poznati podatak su nam opservacije dobivene parametrizacijom govornog signala, parametri modela (koji će biti kasnije detaljno objašnjeni) su izrađeni i estimirani treningom, prijelazi stanja za dani govor nam nisu poznati, a vjerodostojnost svakog modela (u ovom slučaju svake riječi), za dan niz O se traži. Prepoznata riječ je ona koja daje maksimalnu vjerodostojnost. Kako se traži $P(w_i|O)$, preko Bayes-ovog pravila se koristi matematička ideja Markovljevih modela, koji na izlazu daju opservacije po koracima t , za ulazni podatak o promjeni stanja (X), koji je u našem slučaju (a i u većini slučajeva) skriven.

3.2.1 Matematika Markovljevih modela (na primjeru)

Markovljevom modelu odgovara automat sa konačnim brojem stanja, gdje se prijelazi iz stanja i u stanje j odvijaju u definiranim vremenskim koracima t s nekom vjerojatnošću a_{ij} . Odgovarajući prijelazi su popraćeni opservacijama o_t nastalim iz gustoće vjerojatnosti $b_j(o_t)$.

Prepostavimo prijelaz stanja $X = 1,2,2,3,4,4,5,6$, ukupna vjerojatnost da je niz opservacija O generiran prolaskom modela M kroz niz stanja X, se jednostavno računa kao produkt:

$$P(O, X|M) = a_{12}b_2(o_1)a_{22}b_2(o_2)a_{23}b_3(o_3) \dots \quad (4)$$

Pošto se pri praktičnoj primjeni ne zna prijelaz stanja X tada govorimo o Skrivenom Markovljevom modelu (HMM), sa izračunom vjerojatnosti popraćenim sljedećim izrazom:

$$P(O|M) = \sum_X a_{x(0)x(1)} \prod_{t=1}^T b_{x(t)}(o_t) a_{x(t)x(t+1)} \quad (5)$$

gdje $x(0)$ obilježava ulazno stanje modela, a $x(T + 1)$ izlazno stanje.

Pojednostavljenje izraza omogućuje aproksimacija vjerojatnosti sa najvjerojatnijim nizom stanja:

$$\hat{P}(O|M) = \max_X \left\{ a_{x(0)x(1)} \prod_{t=1}^T b_{x(t)}(o_t) a_{x(t)x(t+1)} \right\} \quad (6)$$

te zaključak da set modela M_i odgovara skupu riječi w_i ,

$$P(O|w_i) = P(O|M_i) \quad (7)$$

Estimacijom parametara $\{a_{ij}\}$ i $\{b_j(o_t)\}$, koju izvršimo putem treninga, smo u stanju vršiti prepoznavanje.

3.2.2 Parametri modela prema Baum-Welch algoritmu

Da bismo odredili parametre tokom treninga prvo je potrebno napraviti grubu inicijalizaciju istih, a nakon toga višestruko izvršiti re-estimaciju parametara. Određivanje parametara modela se vrši na temelju opservacija (parametarskih vektora). Za svako tako određeno stanje u modelu se formira jedinična gaussova razdioba sa svojom srednjom vrijednošću i varijancom. To si možemo predložiti kao prostor od D dimenzija, pri čemu je D veličina parametarskih vektora. Pri prepoznavanju govora obično se radi o njih 13. Nulti koeficijent koji postavlja energiju, te idućih 12. U takvom prostoru su razmještene gaussove vjerojatnosti za svako stanje.

Tokom procesa se prvo „ugrubo“ određuju parametri (*inicijalizacijom*) , a nakon toga se polako izmjenjuju estimacijom. Određivanje parametara zahtjeva poznavanje srednje vrijednosti i varijance za svako od stanja. Tako parametar $\{b_j(o_t)\}$ određujemo pomoću sljedeće relacije:

$$b_j(o_t) = \frac{1}{\sqrt{(2\pi)^n |\Sigma_j|}} e^{-\frac{1}{2}(o_t - \mu_j) \Sigma_j^{-1} (o_t - \mu_j)} \quad (8)$$

Ako bismo imali takav model, koji bi posjedovao samo jedno stanje, srednje vrijednosti i varijance bi se računale iz sljedećih izraza:

$$\hat{\mu}_j = \frac{1}{T} \sum_{t=1}^T o_t \quad (9)$$

$$\widehat{\Sigma}_j = \frac{1}{T} \sum_{t=1}^T (o_t - \hat{\mu}_j)(o_t - \hat{\mu}_j)^T \quad (10)$$

Primarni problem se krije u tome što se u skrivenim markovljevim modelima ne znaju stanja kroz koja se prolazi u nekom trenutku. Iz toga proizlazi da se ne može izvesti direktno povezivanje opservacijskih vektora sa određenim stanjima, a samim time niti izračunati relacija (8). Stoga se problem određivanja parametara svodi na povezivanje opservacijskih vektora i stanja modela, koje bi omogućilo korištenje izraza (9) i (10) prilikom računanja (8).

3.2.2.1 Inicijalizacija

Inicijalizacija parametara se radi pomoću HTK-ove funkcije **Hinit**, i za cilj joj je početno približiti opservacije stanjima. Kroz inicijalizaciju se provodi okvirno određivanje parametara koji se trebaju estimirati.

Algoritam Hinit

1. Opservacijski se vektori dijele jednoliko među stanjima i računaju se početne srednje vrijednosti i varijance za svako stanje na temelju opservacija dodijeljenih tom stanju, pomoću izraza (9) i (10), i na temelju njih se odrede početni parametri.

2. Primjeni se Viterbijev algoritam za računanje niza stanja s najvećom vjerojatnošću, i prema njemu se dodjeljuju opservacije stanjima. Događa se pomak srednjih vrijednosti, varijanci i parametara.
3. Ponavlja se drugi korak sve dok estimacija parametara ne konvergira.

3.2.2.2 *Estimacija*

Estimaciju vršimo pomoću Forward-Backward algoritma. Njegova glavna razlika u odnosu na Viterbijev algoritam je što računa ukupno vjerojatnost, a ne samo vjerojatnost najvjerojatnijeg niza. To je ujedno i razlog zašto daje bolje rezultate u pogledu točnosti kao i lošije u pogledu složenosti i dužine izvođenja.

U ovom slučaju imamo situaciju da će svaki opservacijski vektor sa vjerojatnošću da je model bio u baš tom stanju kad je zaprimljen vektor o_t , doprinositi svakom stanju, a ne samo dodijeljenom. Ovim postupkom dovodimo do pomicanja parametara srednje vrijednosti i varijance u D -dimenzionalnom prostoru u odnosu na prethodni iznos. Svaka nova estimacija rezultira točnjim parametrima u odnosu na prethodnu, a samim time dolazi i do potrebnog pomaka.

Prethodno utvrđene relacije poprimaju nešto drugačiji oblik:

$$\hat{\mu}_j = \frac{\sum_{t=1}^T L_j(t) o_t}{\sum_{t=1}^T L_j(t)} \quad (11)$$

$$\widehat{\sum_j} = \frac{\sum_{t=1}^T L_j(t) (o_t - \mu_j)(o_t - \mu_j)}{\sum_{t=1}^T L_j(t)} \quad (12)$$

Gdje je $L_j(t)$ definirana kao okupacija stanja – vjerojatnost da je u trenutku t model u stanju j , $L_j(t)$ se određuje pomoću Forward-Backward algoritma.

Forward-Backward algoritam

Ukupna vjerojatnost da je zaprimljeno prvih t vektora i da je model M sa N stanja u trenutku t u stanju j je definirana kao :

$$\alpha_j(t) = P(o_1, \dots, o_t, x(t) = j | M) \quad (13)$$

pa iz toga slijedi da se može izračunati prema rekurziji:

$$\alpha_j(t) = \left[\sum_{i=2}^{N-1} \alpha_i(t-1) \alpha_{ji} \right] b_j(o_t) \quad (14)$$

i zove se unaprijedna vjerojatnost. Iz rekurzivne formule je vidljivo da se vjerojatnost stanja j u trenutku t , računa kao zbrajanje unaprijednih vjerojatnosti za sva prethodna stanja pomnožena sa vjerojatnostima prijelaza a_{ij} , uz konačni umnožak sa trenutnom vjerojatnošću $b_j(o_t)$. S tim je pokrivena cijelokupna dinamika sustava, jer su obuhvaćeni i prijelazi među stanjima. Pošto stanja 1 i N nisu emitirajuća, tj. iz prvog stanja se u trenutku 1 sa vjerojatnošću 1 prelazi u drugo stanje, dok se u zadnje stanje može ući isključivo u trenutku T , tada je i suma na relaciji rekurzije definirana od 2 do $N-1$.

Početne vrijednosti:

$$\alpha_1(1) = 1 \quad (15)$$

$$\alpha_1(1) = a_{1j}(o_1) \text{ za } 1 < j < N \quad (16)$$

Završni uvjet:

$$\alpha_N(T) = \sum_{i=2}^{N-1} \alpha_i(T) a_{iN} \quad (17)$$

Ukupna vjerojatnost da je dani niz opservacija generiran modelom M može se definirati kao :

$$P(O|M) = \alpha_N(T) \quad (18)$$

Unazadna vjerojatnost u algoritmu služi za poboljšanje dinamike sustava, jer se gleda od zadnjeg trenutka prema prvom, a računa se na način kao i unaprijedna, samo sa obrnutim indeksima.

Definicija:

$$\beta_j(t) = (o_{t+1}, \dots, o_t | x(t) = j, M) \quad (19)$$

Rekurzija:

$$\beta_j(t) = \sum_{i=2}^{N-1} a_{ij} b_j(o_{t+1}) \beta_j(t+1) \quad (20)$$

$$\beta_j(T) = a_{iN} \quad (21)$$

Završni uvjet:

$$\beta_1(1) = \sum_{j=2}^{N-1} a_{1j} b_j(o_1) \beta_j(1) \quad (22)$$

Da se primijetiti da je α definirana kao ukupna vjerojatnost, a β kao uvjetna,

$$\alpha_j(t)\beta_j(t) = P(O, x(t) = j|M) \quad (23)$$

S ciljem da se njihov produkt može iskoristiti za izračun ukupne zaposjednutosti stanja:

$$L_j(t) = P(x(t) = j|O, M) = \frac{P(O, x(t) = j|M)}{P(O|M)} = \frac{1}{P} \alpha_j(t) \beta_j(t) \quad (24)$$

Ovime smo predočili proces estimacije putem Baum-Welch algoritma koji za estimaciju koristi Forward-Backward algoritam. U HTK alatu estimacija kod prepoznavanja izoliranih riječi se vrši pomoću funkcije **HRest**.

Baum-Welch algoritam (HRest)

1. Alocira se memorija (akumulator) za svaki parametar kojeg je potrebno re-estimirati (za njegov brojnik i nazivnik) – relacije (11) i (12).
2. Računa se α i β za sva stanja t u svim trenutcima j .
3. Za svaki j i t iskoristiti se trenutni $L_j(t)$ i trenutna opservacija da se obnovi akumulator za to stanje.
4. Dobivene vrijednosti iz akumulatora koriste se za izračun novih vrijednosti parametara.
5. Ako je iznos vjerodostojnosti $P(O|M)$ za trenutnu iteraciju veći od iznosa za prošle, ponavljaju se gornji koraci uz korištenje re-estimiranih parametara, a ako je manji – zaustavlja se proces.

U praksi se često za re-estimaciju koristi više izgovora jedne riječi (modela), u tom slučaju je za svaki novi opservacijski niz potrebno ponoviti korake 2 i 3. Također, za izračun α i β potrebno je višestruko množenje vjerojatnosti, što rezultira jako malim brojevima. Zbog toga se u Baum-Welch algoritmu koristi logaritamska aritmetika.

3.2.3 Prepoznavanje izoliranih riječi

Metoda prepoznavanja govora je definirana kao odabir modela koji daje najveću vjerodostojnost za neki dotični niz opservacija. Kao algoritam koji nam služi za

prepoznavanje je moguće koristiti ili Viterbijev algoritam ili Forward-Backward algoritam. Forward-Backward algoritam je dobar za prepoznavanje izoliranih riječi, gdje se riječi sa modelima odnose jedan na jedan, u općem slučaju je bolji Viterbijev algoritam. Ova činjenica je nevezana o tome da li se radi o slijednom govoru ili izoliranim riječima. Viterbijev algoritam radi prepoznavanje na temelju maksimalne vjerodostojnosti optimalnog puta. Njegova implementacija nije sprovedena kao zasebna HTK funkcija već se nalazi unutar funkcije **HVite**.

Računanje rekurzije se obavlja na sličan način kao i računanje unaprijedne vjerojatnosti kod Forward-Backward algoritma. Razlika je u tome što se ovdje uzima maksimalana vjerojatnost, a ne suma svih vjerojatnosti prethodnih koraka:

$$\phi_j(t) = \max_i \{\phi_i(t-1)a_{ij}\} b_j(o_t) \quad (25)$$

Početni uvjeti:

$$\phi_1(1) = 1 \quad (26)$$

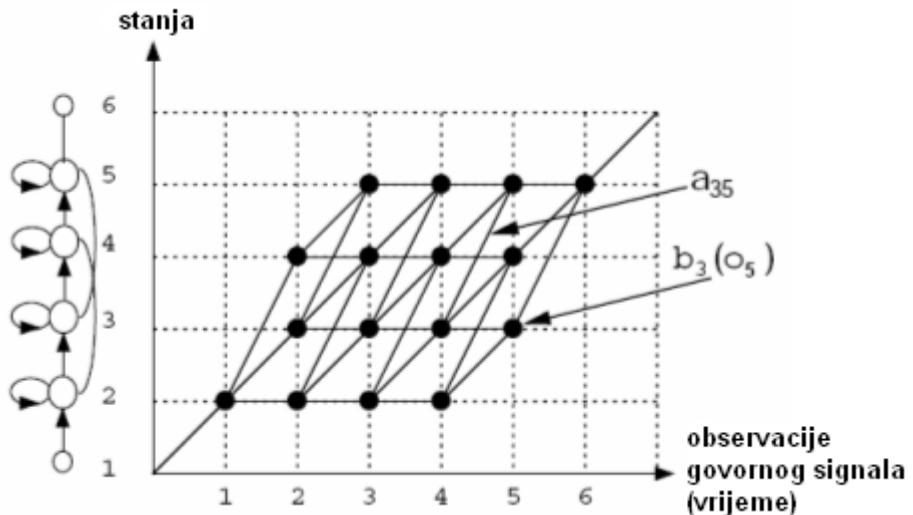
$$\phi_j(1) = a_{1j} b_j(o_1) \text{ za } 1 < j < N \quad (27)$$

$\hat{P}(O|M)$ se računa prema:

$$\phi_N(T) = \max_i \{\phi_i(T)a_{iN}\} \quad (28)$$

I u ovom slučaju se zbog već prije pojašnjeno razloga koristi logaritamska aritmetika:

$$\psi_j(t) = \max_i \{\psi_i(t-1) + \log(a_{ij})\} + \log(b_j(o_t)) \quad (29)$$



Slika 5-Svi mogući putevi kroz stanja modela

Kao što je i predočeno na *slici 5* ordinata obilježava stanja modela, dok sun na apscisu naneseni uzorci govora u vremenu. Svaki presjek koordinata odnosno svaka obilježena točka predstavlja logaritamsku vjerojatnost da u stanju j zaprimi o_t . Nacrtane poveznice predstavljaju logaritamsku vjerojatnost prijelaza. Za svaki trenutak t je poznat parcijalni put $\psi_i(t - 1)$ za sva stanja i , pa je relaciju (29) lako moguće izračunati.

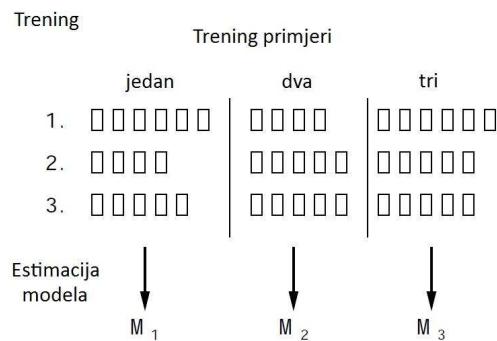
3.2.4 Sažetak metode prepoznavanja izoliranih riječi

Kod prepoznavanja metodom izoliranih riječi gradi se sustav u odnosu jedan na jedan, tj. svaka riječ iz baze za trening ima svoj model. Pošto jedan govorni iskaz predstavlja jednu riječ, nema potrebe za ručnim označavanjem materijala, već se koriste pripadne transkripcije.

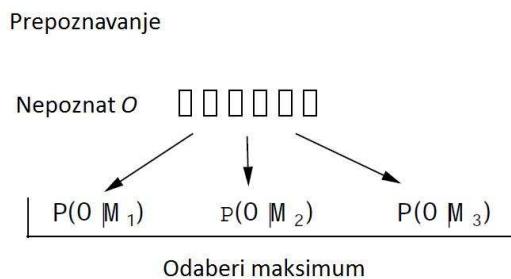
HTK funkcije koje se koriste pri ovoj proceduri su **Hinit** za inicijalizaciju te **HRest** za re-estimaciju. Kada gradimo sustav sa jako malim brojem podataka za trening bolje rezultate možemo postići sa modelima kojima su sve varijance izjednačene s globalnom, a to postižemo prethodnom inicijalizacijom pomoću **HCompV**. Samo postupak prepoznavanja je prepušten HTK funkciji **HVite**.

3.2.5 Primjer prepoznavanja metodom izoliranih riječi

Za primjer možemo uzeti vokabular od tri izgovorena broja. Neka se radi o riječima: jedan, dva i tri. Pri treniranju sustava modeli se treniraju sa više primjeraka svake riječi jedan po jedan. Dok se proces prepoznavanja zasniva na odabiru najveće vjerodostojnosti da se radi upravo o toj riječi. Da bismo se mogli odlučiti za maksimalnu vjerodostojnost potrebno je prethodno izračunati vjerodostojnosti da je dotična riječ generirana od pojedinog modela.



Slika 6-Primjer prepoznavanja metodom izoliranih riječi-trening



Slika 7-Primjer prepoznavanja metodom izoliranih riječi-test

3.3 Metoda prepoznavanja slijednog govora

Ulančavanje modela je princip koji se koristi kod prepoznavanja slijednog govora. Prema vrsti modela možemo izvršiti podjelu u dvije grupe:

- *prepoznavanje kontinuiranog govora*—prepoznavanje se provodi ulančavanjem modela dijelova riječi.
- *prepoznavanje vezanog govora*—prepoznavanje se provodi ulančavanjem modela riječi

Gore spomenuti modeli se vežu u lanac preko ne-emitirajućih stanja.

Da bismo modelirali sustav za kontinuirano prepoznavanje govora potrebni su nam kontinuirano izgovoreni iskazi odnosno materijali za trening.

U dotičnim materijalima najveći problem nam predstavlja određivanje granica među dijelovima. Pošto su nam potrebne veće količine trening materijala za kvalitetno prepoznavanje, ručno označavanje nije praktično te kao takvo ne dolazi u obzir. Pored velike količine materijala koju bi trebalo ručno označiti potrebno je da dotična radnja bude i precizna što uglavnom nije zadovoljeno, pa samim time dolazimo još jednom do zaključka o nepraktičnosti ručnog označavanja.

Kako bismo riješili spomenuti problem određivanja granica pribjegli smo već ranije spomenutom principu ravnomjerne inicijalizacije (eng. flat start), koja ne zahtjeva ručno označene materijale.

Prema ovom načelu inicijalizacija varijanci i srednjih vrijednosti svih stanja u svim modelima se sprovodi po principu da im se dodjeljuje iznos globalne srednje vrijednosti i varijance koji je izračunat na osnovu ukupnog materijala za trening.

3.3.1 Računanje parametara (adaptirani Baum-Welch algoritam)

Kao i u slučaju određivanja parametara za metodu izoliranih riječi i ovdje se koristi Baum-Welch algoritam međutim razlika u odnosu na prijašnji postupak je u tome što se ovdje provodi paralelno nad svim modelima.

Baum-Welch algoritam (za modele dijelova riječi)

1. Alokacija i anulacija akumulatora za sve parametre svih modela.
2. Učitavanje novog govornog iskaza.
3. Ulančavanje onih modela koji odgovaraju transkripciji govornog iskaza u suženi model.
4. Izračun α i β složenog modela, (ovdje je potrebna adaptacija u matematici s obzirom na algoritam za izoliranu riječ, zbog vezanja modela preko ne-emitirajućih stanja - detalji se mogu pogledati u literaturi).
5. Iskoristiti α i β za izračun zaposjednutosti stanja $L_j(t)$ za svaki t .
6. Ponavljati postupak od koraka 2 za svaki novi govorni iskaz.
7. Iskoristiti akumulatore za re-estimaciju parametara svih modela.

Navedeni postupak se ponavlja onoliko puta koliko je potrebno da estimacija parametara konvergira. Obično je dovoljno dva do pet prolazaka da bismo dobili kvalitetnu estimaciju parametara.

Da bismo sproveli ovakav trening potrebna nam je simbolična transkripcija govornih iskaza, kako bismo znali niz simbola od kojih je sačinjena riječ, međutim, točne granice među simbolima nisu potrebne.

Do nešto drastičnijih promjena dolazimo u postupku prepoznavanja, dok je postupak re-estimacije gotovo pa identičan. Tako više za prepoznavanje nije moguće koristiti Viterbijev algoritam, već se primjenjuje Token passing algoritam, čiji je opis dan u nastavku.

Token passing algoritam

- Tokenom se naziva parcijalni put kroz mrežu, koji se širi od trenutka 0 do trenutka t.
- U trenutku $t = 0$ token se dodjeljuje svakom mogućem početnom čvoru.
- U svakom idućem trenutku tokeni prelaze preko mogućih prijelaza. Tamo gdje postoji više izlaza iz jednog čvora token se kopira, tako da su svi mogući putovi istraživani paralelno.
- Kako tokeni prolaze kroz prijelaze i čvorove, njihov logaritam vjerojatnosti raste za logaritam vjerojatnosti prijelaza $\log(a_{ij})$ ili logaritam vjerojatnosti dotičnog emitirajućeg stanja da generira odgovarajuću opservaciju $\log(b_j(t))$.
- Pošto svaki čvor u mreži može imati samo N tokena, u svakom koraku se odbacuju svi osim N najboljih.

Pri prolasku kroz mrežu svaki token pamti svoj put. Ako govorimo o prepoznavanju riječi tada token pamti prijelaze iz čvorova koji označavaju krajeve riječi (*eng. word-end notes*). Općenito možemo reći da količina podataka koju token treba pamtiti ovisi o zadatku prepoznavanja.

Sasvim je razumljivo da u ovakvima primjenama mreža može doseći enorman broj čvorova iz čega proizlazi da bi navedeno čuvanje svih tokena kao i vrijeme potrebno za izvršavanje dovelo do vrlo velike neefikasnosti. Stoga se vrši ubrzanje procesa po principu da se odbacuju svi oni tokeni koji nemaju šanse biti pobjednici. Spomenuti mehanizam je ostvaren na način da se pamti podataka o najboljem tokenu, te se definira širina snopa kao raspon koliko najlošiji token smije biti lošiji od najboljeg. Oni tokeni koji ne ulaze u

navedeni interval biti će odbačeni. Takav mehanizam odbacivanjima nazivamo (*eng. pruning*).

Ovakvo odbacivanje se može provoditi na razini stanja i na razini modela.

Ako situaciju promatramo na razini stanja tada se svaki token koji ispadne izvan definiranog snopa zamjenjuje nultim tokenom. Ako pak pričamo na razini modela, dolazi do deaktivacije onih modela koji ni u jednom emitirajućem stanju nemaju token koji je unutar zadanog raspona. Takvi modeli se mogu ponovno aktivirati, u slučaju da im u neko od stanja dospije token unutar zadanog raspona.

Vidljivo je da je ovakvo odbacivanje efikasnije provoditi na razini modela, jer odbacivanje na razini stanja, u slučaju da smo definirali preusku širinu snopa, može dovesti do toga da se najvjerojatniji put odbaci prije nego što njegov token dođe do kraja govornog iskaza. U tom slučaju bismo imali neželjenu pogrešku (*eng. search error*).

Iz svega navedenog vidljivo je da je širinu snopa potrebno tako optimizirati da se izbjegnu pogreške, a da prepoznavanje ipak bude najbrže moguće.

3.3.2 Sažetak metode prepoznavanja slijednog govora

Definiranje modela ovom metodom se provodi ili na razini riječi ili na razini fonema. Ako se radi o razini riječi ogovorimo o vezanom govoru, a ako se pak radi o razini fonema tada govorimo o kontinuiranom govoru.

Pri treniranju sustava na raspolaganju nam stoje dva pristupa obradi materijala. Prvi način se primjenjuje kada radimo sa manjim količinama materijala te ih je tada donekle pogodno ručno označiti. Drugi način je rad sa neoznačenim materijalima. Zavisno o odabranom načinu i inicijalizacija će se razlikovati. Prvi način koristi inicijalizaciju pomoću HTK-ovih funkcija **Hinit** i **HRest**, kao što je bio i slučaj sa metodom izoliranih riječi, dok se u drugom slučaju koristimo sa već ranije opisanim flat startom, pomoću funkcije **HCompV**.

Metoda prepoznavanja sa kontinuiranim govorom je najraširenija u sustavima za prepoznavanje govora, jer omogućuje neograničeni vokabular za trening na temelju ograničenog broja modela (fonemi).

HERest kao i do sada služi za re-estimaciju, dok s prepoznavanje i dalje radi sa **HVite** samo se sada primjenjuje token passing algoritam.

4 Opis HTK i Matlab funkcija

4.1 HParse

Funkcija HParse iz gramatike, tj. iz datoteke grammar.txt, generira mrežu riječi u SLF formatu. Pravila za izradu gramatike su objašnjena na primjeru u dalnjem tekstu, pod poglavljem o gradnji sustava. Pri generiranju mreže funkcijom HParse automatski se obavlja i optimizacija mreže, na način da se u mrežu ubacuju takozvani **!NULL** čvorovi. Ovim se smanjuje broj prijelaza, a samim time i veličina mreže, što kao krajnju posljedicu ima povećanje efikasnosti prepoznavanja.

Aktivacijom opcije –l, pri pohrani u SLF (eng. Standard Lattice Format) format, sprema se podatak o vjerodostojnosti, koja će biti ukomponirana u proces prepoznavanja, a izračunata je na osnovu dane gramatike. SLF nam dozvoljava da pohranimo podatke o spomenutim vjerojatnostima pa će tako češći prijelazi imati veću vjerojatnost, rjeđi manju, a nemogući nultu. Ovim postupkom dobivamo leksički model koji je nastao na osnovu gramatike a definira nam skup rečenica koji je dozvoljen dotičnom gramatikom.

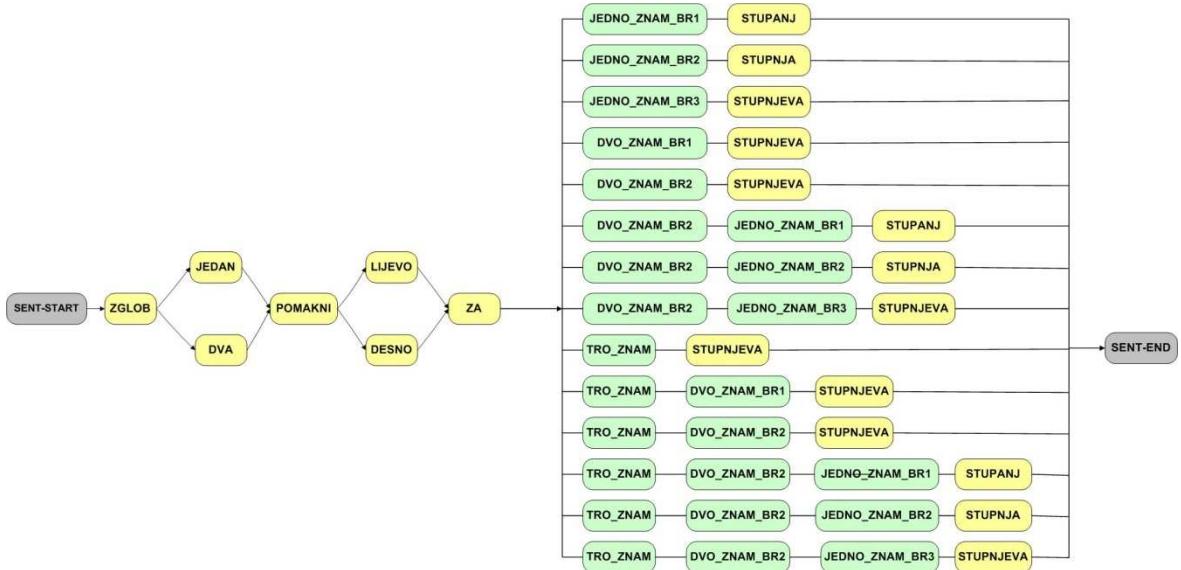
Sami SLF zapis sadrži običnu mrežu sa sljedećim stavkama:

- Statističko zaglavlje sa općim podatcima o mreži, kao što su broj prijelaza i broj čvorova
- Definicije čvorova
- Definicije prijelaza

Primjer poziva funkcije **HParse**:

```
>HParse (lista opcija) netFile latFile
```

Primjer gramatike i rada funkcije **HParse** možemo prikazati na primjeru glasovnog upravljanja robotskom rukom. Gramatika je konstruirana na način da se prvo odabire zglob robotske ruke(jedan ili dva), zatim pomak u lijevo ili desno te se na kraju izgovara željeni broj stupnjeva za koje treba pomaknuti ruku. Vizualno je to prikazano na *slici 8*.

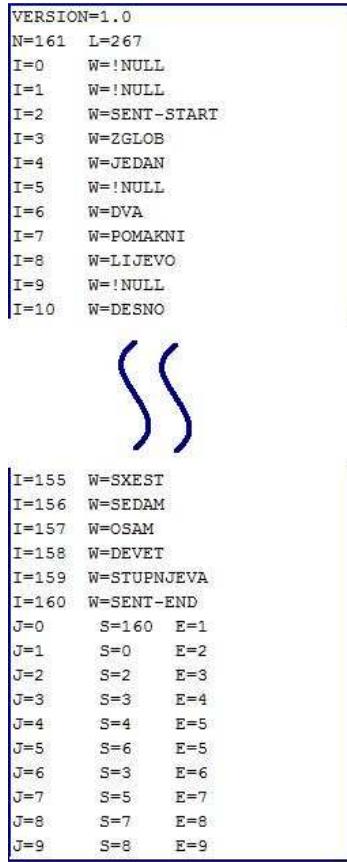


Slika 8-Vizualni prikaz mreže za upravljanje robotskom rukom

Primjer gramatike i isječak iz SFL datoteke dani su na slikama 8 i 9.

```
$jednoznam_br1 = JEDAN;
$jednoznam_br2 = DVA | TRI | CXETIRI;
$jednoznam_br3 = PET | SXEST | SEDAM | OSAM | DEVET;
$dvvoznam_br1 = DESET | JEDANAEST | DVANAEST | TRINAEST | CXETRNAEST | PETNAEST | SXESNAEST | SEDAMNAEST | OSAMNAEST | DEVETNAEST;
$dvvoznam_br2 = DVADESET | TRIDESET | CXETRDESET | PEDESET | SXEZDESET | SEDAMDESET | OSAMDESET | DEVEDESET;
$troznam_br = STO;
$smjer = LJUEVO | DESNO;
(SENT-START ZGLOB (JEDAN | DVA) POMAKNI $smjer ZA (
    ($jednoznam_br1 STUPANJ)
    | ($jednoznam_br2 STUPNJA)
    | ($jednoznam_br3 STUPNJEVA)
    | ($dvvoznam_br1 STUPNJEVA)
    | ($dvvoznam_br2 STUPNJEVA)
    | ($dvvoznam_br2 $jednoznam_br1 STUPANJ)
    | ($dvvoznam_br2 $jednoznam_br2 STUPNJA)
    | ($dvvoznam_br2 $jednoznam_br3 STUPNJEVA)
    | ($troznam_br STUPNJEVA)
    | ($troznam_br $dvvoznam_br1 STUPNJEVA)
    | ($troznam_br $dvvoznam_br2 STUPNJEVA)
    | ($troznam_br $dvvoznam_br2 $jednoznam_br1 STUPANJ)
    | ($troznam_br $dvvoznam_br2 $jednoznam_br2 STUPNJA)
    | ($troznam_br $dvvoznam_br2 $jednoznam_br3 STUPNJEVA)
) SENT-END)
```

Slika 9-Primjer gramatike za upravljanje robotskom rukom



Slika 10-Isječak mreže riječi za upravljanje robotskom rukom

Unutar mreže riječi karakteristične su oznake sa slovima **N, L, I, J, S i E**. **N** označava broj čvorova, **L** broj prijelaza, **I** je oznaka čvora a **J** oznaka prijelaza (luka). **S** i **E** su sinonimi za početak i kraj luka, tj. definira se početni čvor i krajnji čvor koji povezuje luk. Pored lukova moguć je i zapis o vjerodostojnosti. Ako je zapisana tada je ona izražena logaritamski, te nula na primjer označava maksimalni iznos, dok bi nemogući prijelaz bio označen sa $-\infty$.

4.2 HDMan

HDMan koristimo za pripremu rječnika sa izgovorima. Kao ulaz funkcija zaprima listu riječi čije izgovore je potrebno naći i jedan ili više već gotovih rječnika. Za svaku riječ sa ulazne liste traži se izgovor u predanim rječnicima, te se na osnovu toga formira izlazni rječnik u koji se zapisuje svaka ulazna riječ sa pripadajućim izgovorom preuzetim iz nekog od rječnika.

Prema standardnim postavkama **HDMAn** uzima samo jedan izgovor svake riječi bez obzira što se ona može nalaziti u više rječnika. U tome slučaju se uzima izgovor iz prvog rječnika u kojem se nađe dotična riječ.

- Aktivacijom opcije – **m** se postiže uzimanje svih mogućih izgovora dotične riječi iz svih rječnika.
- Aktivacijom opcije – **b wordboundary** se definira granica između riječi.
- Aktivacijom opcije – **n phonelist** se omogućava ispis svih fonema korištenih u transkripciji riječi s liste.

Opis ostalih funkcionalnosti HDMAn funkcije je moguće dobiti pozivom funkcije iz Command prompta odnosno shella.

Izlazni rječnik je moguće urediti upisivanjem niza naredbi u edit skriptu global.ded.

Tablica 1-Naredbe za skriptu global.ded

MP X A B	Stapanje (eng. merge) svakog niza fonema A i B i preimenovanje u X.
RC [X]	Pretvara sve foneme u desno – kontekstno ovisne. Ako je zadan X, zadnji fonem u svakoj riječi se mijenja u z+X, inače ostaje nepromjenjen.
RP X A B	Svaku pojavu fonema A ili B zamjenjuje sa X.
RS system	Uklanja se oznaka naglaska. Trenutno jedini podržavani naglasak je onaj korišten u rječnicima Carnegie Mellon University-a (system=cmu).
RW X A B	Svaka pojava riječi A ili B se zamjenjuje sa X.
SP X A B	Fonem X se rastavlja na niz A B ...
TC [X[Y]]	Pretvara monofone u trifone. Ako je zadan X, prvi fonem (a) u riječi se pretvara u X – a + b, inače se ne mijenja. Ako je zadan Y, zadnji fonem (z) se pretvara u y – z + Y, inače, ako je zadan X se pretvara u y – z + X, a ako nije zadan, ni X se ne mijenja.
UP	Pretvara sve foneme u velika slova.
UW	Pretvara sve riječi u velika slova.

4.3 HSGen

Ovom funkcijom obavljamo nasumično generiranje rečenica prema zadanoj gramatici. Što može biti upotrebљeno ili kao test materijal ili kao trening u slučaju da vršimo trening upravo sa željenim uzorcima izgovorenih rečenica.

Opcije:

- **-I** numeracija rečenica
- **-n N** odabir broja rečenica koje želimo generirati

Poziv:

>HSGen [lista opcija] wdnet dictfile

4.4 HLED

Da bismo izvršili editiranje datoteka sa transkripcijom primjenjujemo **HLED** funkciju, sa naredbama izmjena zapisanim u edit skripti (*ekstenzija *.led*). HLED nam daje novu datoteku s labelom uređenom prema naredbama iz edit skripte.

Pravilo pisanja edit skripte nalaže da svaka naredba mora biti zapisana u svome retku.

Naredbe dijelimo u dvije skupine:

- naredbe koje se primjenjuju na zasebne labele (tablica)
- naredbe koje se primjenjuju na cijeli set labele tj. na cijelu datoteku s transkripcijom – MLF (tablica)

Tablica 2-Naredbe zasebnih labela kod HLED

CH X A Y B	Zamijeni Y, u kontekstu A_B, sa X. Blok ovih komandi se izvršava u paraleli tako da se kao kontekst gleda ono što je bilo prije izvođenja bloka.
DC A B C ..	Definiraj kontekst A kao set labela B C itd.
DE A B ..	Obriši svaku pojavu labela A ili B ili ..
FI A Y B	Nađi svaki Y u kontekstu A_B i broji broj pojavljivanja.
ME X A B ..	MERGE svaku pojavu niza A B .. u X.
ML N	Pomakni na razinu N.
RE X A B ..	Svaku pojavu labela A ili B ili .. zamijeni labelom X.

Tablica 3-Naredbe za cijeli set labela (MLF) kod HLED

DL [N]	Obriši sve labele na trenutnom nivou.
EX	Proširi sve labele naprimjer, s razine riječi na monofone ili monofone na trifone, koristeći rječnik.
FG X	Označi sve nelabelirane segmente ulaznog file-a dulje od T _g sa X. T _g je obično 50000, ali mu se vrijednost može promjeniti s -g opcijom. Ova naredba se uglavnom koristi za labeliranje tištine između riječi u ulaznim podacima u kojima je transkribiran samo čisti govor.
IS A B	Umetni A na početak svake transkripcije i B na kraj. Obično se koristi za umetanje oznaka za tišinu i kratku pauzu.
IT	Ignoriraj kontekst trifona u CH i FI naredbama.
LC [X]	Pretvori sve fonemske labele u lijevo – kontekstno ovisne. Ako je X zadan, prva labela a postaje X – a, inače ostaje nepromjenjena.
NB X	Labela X (tipično kratka pauza) se treba ignorirati na granicama riječi kad se koriste kontekstne naredbe LC, RC i TC.
RC [X]	Pretvori sve fonemske labele u desno – kontekstno ovisne. Ako je X zadan, zadnja labela z postaje z + X, inače ostaje nepromjenjena.
SB X	Definiraj labelu X da bude oznaka granice između rečenica.
SO	Sortiraj sve labele po vremenskom redoslijedu.
SP	Razdijeli transkripciju s više razina (rijeci, monofoni, trifoni) na više alternativnih labela.
TC [X Y]]	Pretvori sve fonemske labele u trifonske. Ako je zadan X, prva fonemska labela (a) u riječi se pretvara u X – a + b, inače se ne mijenja. Ako je zadan Y, zadnja fonemska labela (z) se pretvara u y – z + Y, inače, ako je zadan X se pretvara u y – z + X, a ako nije zadan, ni X se ne mijenja.
WB X	Definiraj labelu X da bude oznaka granice između riječi. Ova naredba utječe na naredbe vezane za kontekst – LC, RC, TC. Proširenje labela je blokirano svaki put kad se nađe na granicu riječi.

Primjer poziva:

```
>HLEd -l * -d rjecnik -i novi.mlf edit.led stari.mlf
```

- **-l** opcija služi da se i u izlaznoj datoteci generira * umjesto imena pod-direktorija, što omogućava da se isti mlf podatak koristi za više različitih snimljenih izgovora istih rečenica.
- **-d** opcija učitava rječnik iz datoteke dict.
- **-i** opcija podržava zapis rezultata u mlf formatu.

4.5 HCopy

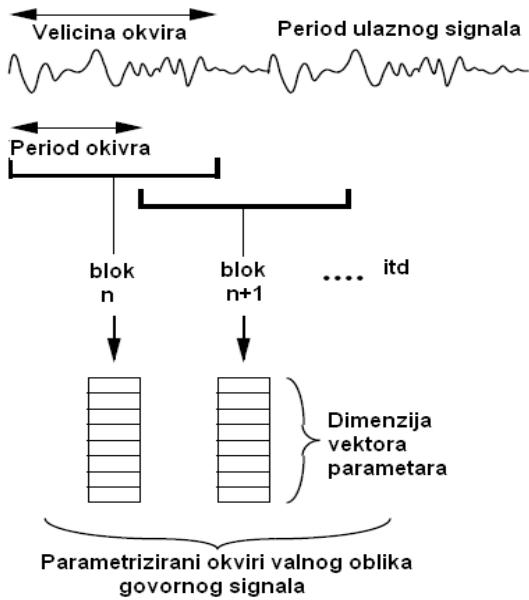
Da bismo obavili prepoznavanje potrebno je ulazni zvučni signal prebaciti u neki od parametriziranih oblika. Upravo tome nam služi funkcija **HCopy**. Unutar konfiguracijske datoteke se odabiru postavke parametrizacije (*ako se radi o mfc parametrizaciji*):

- SOURCEFORMAT ⇒ format snimljenog materijala
- TARGETKIND ⇒ ciljani parametri
- TARGETRATE ⇒ period okvira (HTK koristi jedinice od 100ns)
- WINDOWSIZE ⇒ veličina okivra
- USEHAMMING ⇒ (T/F) koristi li FFT analiza koristi Hammingov otvor
- PREEMCOEF ⇒ koeficijent prednaglašavanja signala
- NUMCHANS ⇒ broj kanala u filterskoj banci
- NUMCEPS ⇒ broj MFCC koeficijenata

Primjer poziva:

```
>HCopy -T 1 -C hcopy.conf -S codetr.txt
```

- **-T 1** označava zastavicu praćenja
- **-C hcopy.conf** –konfiguracijsku datoteku
- **-S codetr.txt** –datoteku sa zapisima lokacija audio i parametarskih podataka

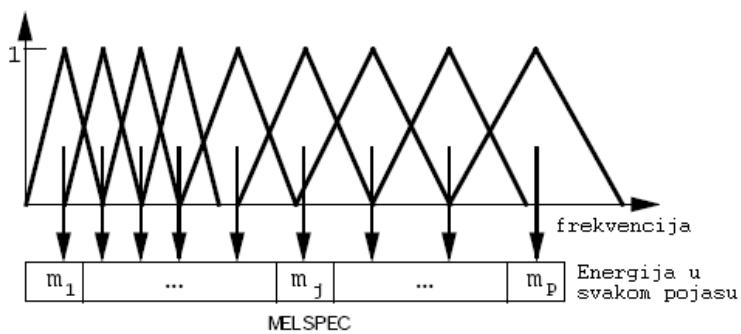


Slika 11-Parametrizacija valnog oblika govornog signala

Iako HTK podržava više različitih vrsta parametrizacije (linearna predikcija, Fourierova transformacija), za našu primjenu odabrana je parametrizacija metodom MFCC (*eng. Mel Frequency Cepstral Coefficient*). Metodom MFCC signal se parametrizira onako kako ga čuje ljudsko uho. Naime, ljudsko uho je daleko osjetljivije na niskim frekvencijama. Tako na primjer ćemo kako dobro razaznati razliku u promjeni sa 400Hz na 500Hz, dok će promjena sa 15500Hz na 15600Hz proći skoro pa ne zamjetno. Upravo to je razlog pohrane signala u mel skali, koja se prema frekvencijskoj odnosi prema sljedećoj relaciji:

$$Mel(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (30)$$

Prebacivanje signala u *mel* skalu radi se na način da se filtri prikazani u frekvencijskoj skali (slika 12), rasporede u takvu skalu, gdje će svi bili jednake širine. Drugim riječima, frekvencijska os se modelira prema relaciji (30).



Slika 12-Raspored filtra za dobivanje mel skale

4.6 HCompV

Za dobivanje globalne srednje vrijednosti i varijance iz podataka za trening koristimo funkciju **HCompV**. Već u prijašnjem tekstu je navedeno kako nam funkcija **HCompV** služi za takozvani „flat start“ pri treningu. Dakle, pomoću nje se obavlja inicijalizacija u kojoj se svakom stanju, u svakom modelu monofona, dodjeljuju globalne srednje vrijednosti i varijance.

Pri zadavanju opcija također je moguće odrediti donju granicu iznosa varijance, što je korisno za slučaj kad se veliki set modela trenira na osnovu male količine podataka za trening. Bez ograničenja varijance, a zbog nedostatka podataka, došlo bi do krive estimacije.

Primjer poziva:

```
>HCompV -C hcompv.conf -f 0.01 -m -S mfc_lokacija.txt -M hmm_novi  
proto
```

- -f 0.01- označava da je donja granica vrijednosti varijanci jednaka stotini globalne varijance
- -train.txt- sadrži listu putova do materijala za trening
- -proto-sadrži prototip modela
- -u direktorij *hmm0* se spremaju inicijalizirani modeli **hmmdefs.mmf** i makro naredbe **macro**

4.7 HHed

HHED učitava set modela i edit skriptu (*nastavak *.hed*) s nizom naredbi na osnovu kojih provodi transformacije nad nekim modelom ili setom modela.

Pri konstrukciji ovog dijela sustava prolazimo kroz sljedeća stanja:

- Kopiranje modela da bi se dobio kontekstno ovisni set
- Povezivanje (dijeljenje) parametara
- Principi odlučivanja koja stanja će dijeliti parametre - raspoređivanje u razrede (klastering)
 - Raspoređivanje u razrede na osnovu podataka za treniranje
 - Raspoređivanje u razrede na osnovu binarnog stabla
- Dodavanje ili uklanjanje prijelaza među stanjima

Za detaljnije informacije o gradnji gore navedenih dijelova sustava i transformacijama koje se unutar njih provode može se pogledati u navedenu literaturu [2] i [1].

Primjer poziva :

```
>HHEd -H macros -H hmmdefs.mmf -M hmm_novi algoritam.hed  
lista_modela
```

4.8 HERest

Kao što je već prije spomenuto funkcijom HERest provodimo jednostruku re-estimaciju parametara cijelog seta modela na principu Baum-Welch algoritma. Iz svake trening rečenice s pripadnom transkripcijom koju HERest zaprima kao ulazni parametar, ulančavaju se modeli fonema koji odgovaraju fonemima na listi te se formira jedan komponirani model. Nad novo formiranim modelom provodi se forward-backward algoritam i sakupljaju statistike o okupaciji stanja, srednjim vrijednostima i varijancama za svaki model u lancu. Da bismo dobili ukupne statistike koje bismo kasnije primijenili na re-estimaciju parametara modela moramo obraditi sve uzorke. Re-estimaciju je dovoljno provesti dva do pet puta. Sve preko toga je neefikasno te rezultira lošim karakteristikama. Razlog se krije u činjenici da sustav postaje toliko dobro utreniran na vokabular za trening da se ne može prilagoditi na nove riječi pri testiranju.

O mehanizmu pruninga je već ranije bilo spomena pri analizi algoritama. Ponovimo još jednom da se radi o odbacivanju nedovoljno dobrih, tj. nepotrebnih uzoraka. Sami mehanizam je ugrađenu unutar Forward-Backward algoritma, kako bi se ubrzao proces re-estimacije. Pri provedbi Forward-Backward algoritma prvo se računaju unazadne vjerojatnosti $\beta_j(t)$, a unaprijedne vjerojatnosti $\alpha_j(t)$ se računaju samo za one j i t za koje ukupna „log likelihood“ koja je definirana produktom $\alpha_j(t)\beta_j(t)$, ne pada ispod ukupne „log likelihood“ $P(O|M)$ više od određene širine snopa. Ovakav pruning nema negativan utjecaj na točnost modela pa ga provodimo uvijek.

Pruning je moguće vršiti i pri prolasku unatrag ali tu nailazimo na problem da se ne možemo orijentirati prema produktu $\alpha_j(t)\beta_j(t)$, jer još nemamo $\alpha_j(t)$, stoga je potrebno postaviti veću širinu snopa kako bismo izbjegli neželjene pogreške. Ovakav način pruninga je opcionalan, te korisnik može proizvoljno namještati širinu snopa pomoću opcije **-t**.

Transkripcije su nam potrebne samo kako bismo definirali točan niz fonema u svakom uzorku, dok informacija o granici fonema nije potrebna.

Primjer poziva:

```
>HERest -c herest.conf -I transkripcija.mlf -t 250 150 1000 -S  
mfc_lokacija.txt -H macros -H hmmdefs.mmf -M hmm_novi lista_modela
```

Iz primjera je vidljivo kako pruning iznosi 250, ako na bilo kojem podatku re-estimacija ne uspije, pruning će se povećati za 150, te će se izvršiti ponovna estimacija. Povećanje pruninga će se odvijati sve dok se estimacija uspješno ne izvrši, ili dok se ne dosegne gornja granica koja je za navedeni primjer definirana kao 1000.

4.9 HVite

HVite je krajnja funkcija cijelog sustava, a služi nam za prepoznavanje.

Primjer poziva:

```
>HVite -c hvite.conf -H macros -H hmmdefs.mmf -S lokacija_mfc.txt  
-l * -i rezultat.mlf -w mreza_rijeci -p -60 -s 5 rjecnik  
lista_modela
```

- **rjecnik**-sadrži izgovore korištenih riječi
- **hmmdefs.mmf**-utrenirana verzija trifonskih modela (*potrebno da se pomoći izgovora u riječniku, mreža na razini riječi, raspiše na mrežu modela trifona*)
- **rezultat.mlf**- HVite, parametrizirani govor (*rečenicu po rečenicu*) provlači kroz mrežu modela, i računajući najvjerojatniji put, prema token passing algoritmu ispisuje transkripciju.
- **-p** postavlja fiksnu vrijednost koja se dodaje svakom tokenu kad prelazi s kraja jedne riječi na početak druge (*eng. word insertion penalty*).
- **-s** definira koeficijent s kojim se skalira vjerojatnost jezičnog modela prije nego se dodaje tokenu koji prelazi s kraja jedne riječi na početak druge (*eng. grammar scale factor*).
- **-t** definira pruning, ako je uključena, i na temelju njega odbacuje nepotrebne (loše) rezultate.
- **-n** odabir ispisa N najboljih puteva, te favoriziranje rezultata u ovisnosti o vjerodostojnostima, napravljenih na temelju leksičkog modela

Parametri **-p** i **-s** imaju značajan utjecaj na uspješnost prepoznavanja stoga je potrebno obratiti posebnu pažnju na njihovo određivanje.

4.10 Rjecnik.m

Alati sustava HTK nisu prilagođeni hrvatskom jeziku, od tuda i potreba da se razviju zasebne funkcionalnosti koje bi hrvatske riječi i izgovor prilagodile HTK-u. Jedna od temeljnih funkcija koja se bavi navedenom problematikom je rjecnik.m.(*preuzeto iz literature [2]*). Ova funkcija u suradnji sa ostalim funkcijama razvijenim u matlabu pravi rječnik transkripcija na osnovu nekog ulaznog teksta.

Kao ulaz funkcija prima:

- tekst (*koji može sadržavati bilo što, uključujući zareze, crtice, navodnike..., jedino što je bitno, je da ne sadrži ne-hrvatska slova – jer tada neće ispravno raditi*)
- željenu lokaciju za pohranu rječnika
- podatak da li se želi raditi transkripcija na temelju pravila hrvatske gramatike (*koja su objašnjena u ovom radu u dalnjem tekstu*), ili prema relaciji – fonem = grafem
→ PT = 1 – pravila uključena , PT = 0 – pravila isključena

Kao izlaz funkcija ima mogućnost da proslijedi:

- broj riječi koje se nalaze u rječniku
- statistiku fonema koji se nalaze u ukupnom tekstu od kojeg se radi trening
- lista riječi-dakle rječnik bez transkripcija

Za detaljan opis rada funkcije te dobivanja odgovarajućih izlaznih veličina mogu se pogledati detaljni komentari u implementaciji.

Primjer poziva:

```
> fp=fopen('tekst1.txt','r');
tekst1=fread(fp,inf,'uint8=>uint8');
fclose(fp);
fp=fopen('tekst2.txt','r');
tekst2=fread(fp,inf,'uint8=>uint8');
fclose(fp);
tekst=[tekst1; tekst2];
rjecnik(tekst,'rjecnik',1);
```

Funkcija rjecnik.m radi svoju transformaciju ulaznog teksta u nekoliko koraka:

1. Prvo se zamjenjuju svi posebni znakovi hrvatskog jezika poput (č, č, đ, š, ž) sa proizvoljno odabranim znakovima (cx, cy, dzx, dy, sx, zx). Ovo je napravljano isključivo zbog nemogućnosti matlaba da barata sa takvim znakovima.
2. Zatim slijedi upis u matricu svih riječi iz ulaznog teksta te njihovo sortiranje uz izbacivanje duplikata.

3. Iz tako stvorene matrice stvaraju se dvije nove matrice, koje uzimaju redom riječi iz već konstruirane matrice, i na njih primjenjuju, ili ne primjenjuju, pravila transkripcije. Ovo se odvija pozivom funkcije transkripcija.m
4. Na kraju se napravi statistika fonema

4.11 Recenice.m

Da bismo konstruirali akustične modele potrebne za prepoznavanje, moramo imati odgovarajući tekst koji će biti korespondentan tim modelima. Prilikom snimanja trening i test materijala potrebno je da svaka od tih rečenica bude konstruirana po istim pravilima. Ovime olakšavamo posao izrade trening i test materijala. Funkcija recenice.m svodi ulazni tekst nekog nedefiniranog oblika, na strogo definirani oblik, pomoću algoritma u 5 koraka.

Funkcija prima sljedeće argument:

- lokacija teksta
- lokacija željenih rečenica
- maksimalni broj znakova u rečenici (**max_r**)
- maksimalni broj rečenica (**br_r**)
- argument odabira da li se radi o treningu ili testu ('S' ili 'T')

Oblik rečenica nastalih na osnovu preinaka koje radi funkcija recenice.m, na nekom ulaznom tekstu, se može pogledati u privitku 12.1 za trening rečenice i 12.2 za test rečenice. Dužina generiranih rečenica kao i njihov broj ovise o argumentima **max_r** i **br_r**.

Primjer poziva:

```
> recenice('lokacija_tekst', 'lokacija_prompts.txt', 75, 'T', 50)
```

Preinake do konačnog oblika teksta, vidljivog u privitcima, se mogu opisati u nekoliko koraka:

Prvi korak je micanje svih nepotrebnih znakova, te zamjena svih slova hrvatske abecede sa slovima engleske abecede. Postupak preinake znakova sa kvačicom je već opisan u funkciji rjecnik.m

Algoritam provedbe

1. traženje prvog i zadnjeg slova u tekstu i brisanje svega izvan toga
2. svi znakovi među tekstrom (.?! .), dakle višestruki razmaci sa točkama, uskličnicima ili upitnicima, pretvaraju se u (.) sa slovima iza i ispred (bez praznina), a sve višestruke praznine u jednostrukе
3. izrada matrice rečenica sa maksimalno **max_r** znakova po rečenici, visak se prebacuje u novu rečenicu
4. izrada vektora dužina novih rečenica u matrici
5. ako su dvije ili više slijednih rečenica u matrici manje od **max_r**, spajaju se u jednu

Nakon tako formiranih rečenica koje su ograničene sa **max_r** znakova po rečenici, vrši se upisivanje u prompts.txt. Broj rečenica koje će biti upisane ovisi o argumentu **br_r**. U slučaju da broj rečenica generiranih algoritmom prelazi broj **br_r**, doći će do odbacivanja viška te će biti zapisano maksimalno **br_r** rečenica.

5 Ugradnja pravila transkripcije hrvatskog jezika u sustav za automatsko prepoznavanje izgovora matičnog broja studenta

5.1 Općenito o transkripcijama

Pod pojmom transkripcije mislimo na fonemski¹ zapis riječi u nekom jeziku. Dakle, radi se o zapisu izgovora neke riječi na nekom jeziku. Primjere razlike u zapisu izgovora i zapisu same riječi češće pronalazimo u stranim jezicima nego u hrvatskom. Razlog se krije u tome što je Hrvatski jezik zapravo većinom grafemski. To znači da se riječi čitaju onako kako se pišu, pa fonemi zapravo odgovaraju grafemima. Kod drugih jezika to uglavnom nije slučaj. Kao primjer možemo uzeti engleski jezik gdje imamo situaciju da nam je izgovor u potpunosti drugačiji od zapisa riječi. Iz ovoga je vidljivo kako svaki jezik ima svoje foneme. Tako na primjer u hrvatskom jeziku postoji 32 fonema, dok ih engleski broji 46.

Primjer transkripcija hrvatskog i engleskog jezika:

- cow—/k aw/
- hrvatska—/h r v a c k a/

Da bismo mogli napraviti rječnik transkripcija potrebno je objediniti pravila po kojem se transformacija događa. Složenost postupka leži upravo u tim pravilima. Što jezik više teži grafemskom, to je za očekivati da će broj pravila biti manji, kao i da će ona biti jednostavnija. Takav sustav pravila bi u većini rezultirao pravilnom transkripcijom. Međutim, to nije slučaj i sa jezicima gdje je transkripcija potpuno drugačija od zapisa. Tu bismo se suočili sa neobujmljivim problemom sažimanja svih pravila i iznimki. Što se slobodno može proglašiti nemogućim zadatkom. U takvom slučaju puno je jednostavnije svaku riječ takvog jezika proglašiti iznimkom, i jednostavno ručno pokušati konstruirati rječnik transkripcija. Takav ručno izgrađeni rječnik već postoji za engleski jezik. Nažalost, za hrvatski jezik takav rječnik još nije izrađen, a ta činjenica se brani tezom da se radi uglavnom o grafemskom jeziku.

Funkcionalnost HTK-ove funkcije **HDMan**, koja od sveukupnog vokabulara korištenog za trening i test, pravi konačni rječnik sa transkripcijama, nije moguće iskoristiti zbog

¹ Fonem-označava najmanju jezičnu jedinicu koja sama po sebi nema značenje međutim pri spajanju sa drugim fonemima formira riječ.

nedostatka rječnika transkripcija za hrvatski jezik. Tu funkciju nadomješta funkcija rjecnik.m koja poziva funkciju transkripcija.m ,a koja na osnovu pravila hrvatskog jezika koja su ugrađena u nju, pravi rječnik transkripcija za predane joj ulazne podatke.

5.2 Pravila za izradu transkripcije

Za početak je potrebno definirati foneme u hrvatskom jeziku. Već prije je rečeno kako ih ima 32. Radi se o svim slovima hrvatske abecede plus dva glasa koja su izdvojena i smatraju se fonemima. To su slogotvorno r – /rr/ i dvoglasnik /ie/ .Prvi najčešće dolazi između dva suglasnika i ima ulogu samoglasnika (*npr. prst- p rr s t*), dok drugi zamjenjuje niz **ije** u riječima (*npr. lijep – l ie p*). Pored fonema postoje i mnogi alofoni, ali razlike u njihovom izgovoru ne bi smjele značajnije utjecati na točnost rezultata, pa se oni ne obrađuju zasebno.

Tablica 4- Fonemi hrvatskog jezika

FONEMI HRVATSKOG JEZIKA			
1.	a	17.	lj
2.	b	18.	m
3.	c	19.	n
4.	cx	20.	nj
5.	cy	21.	o
6.	d	22.	p
7.	dzx	23.	r
8.	dy	24.	s
9.	e	25.	sx
10.	f	26.	t
11.	g	27.	u
12.	h	28.	v
13.	i	29.	z
14.	j	30.	zx
15.	k	31.	ie
16.	l	32.	rr

Transkripcija se provodi provlačenjem riječi kroz funkciju transkripcija.m. U slučaju da je uključena opcija o pravilima transkripcije (*PT=1*), provodi transkripcija po pravilima, te svaka riječ prolazi kroz algoritam sačinjen od 6 koraka. U suprotnom transkripcija je čisto grafemska. Ovime smo osigurali da većina riječi ima pravilnu transkripciju, samo neke od iznimaka neće biti obuhvaćene, ali njihov broj je zanemariv.

Prije objašnjenja algoritma pretvorbe prikazane su tablice sa samoglasnicima, glasnicima i zvučno bezvučnim parovima suglasnika.

Tablica 5-Samoglasnici hrvatskog jezika

SAMOGLASNICI				
a	e	i	o	u

Tablica 6-Glasnici hrvatskog jezika

GLASNICI							
j	l	lj	m	n	nj	r	v

Tablica 7-Suglasnici hrvatskog jezika

SUGLASNICI											
zvučni	b	d	g	dž	đ	-	v	z	ž	-	
bezvučni	p	t	k	č	ć	c	f	s	š	h	

Algoritam transkripcije

1. Micanje **t** i **d** iz **st**, **sxt**, **zd** i **zxd** ako je iza njih neki od suglasnika, osim **v**, **j** ili **r**.
2. Promjena niza suglasnika u zvučne / bezvučne parove, ovisno o tome da li je posljednji suglasnik u nizu zvučan / bezvučan.
3. Stavljanje fonema **j** između para dvaju suglasnika od kojih je barem jedan **i** ili **e**.
4. Micanje svih duplih slova.
5. Primjena posebnih pravila.
6. Primjena slogotvornog **r** u posebnim situacijama.

1. korak algoritma

Micanje **t** i **d** iz **st**, **sxt**, **zd** i **zxd** ako je iza njih neki od suglasnika, osim **v**, **j** ili **r**.

Iako se ovo pravilo odnosi na većinu slučajeva ipak postoje iznimke, pa se tako u nekim slučajevima **t** i **d** čitaju a u nekima ne. Za primjenu u algoritmu odabrana je verzija koja pokriva više slučajeva, a to je da se krati sve što nije skraćeno.

Slučajevi koji ne pokrivaju ovu situaciju: (*npr. istlačiti, istkati*)

Slučajevi pokrića situacije:

- riječi stranog porijekla (rostfraj, azbestni..)
- imenica ženskog roda izvedenih od imenica muškog roda na koje završavaju na **ist** (**feministkinja...**)
- slučajeva na prijelazu kod riječi nastalih stapanjem (**postdiluvijski...**)

2. korak algoritma

Promjena niza suglasnika u zvučne / bezvučne parove, ovisno o tome da li je posljednji suglasnik u nizu zvučan / bezvučan.

Pri normalnom govoru nemam brzih izmjena iz zvučnog u bezvučno. Niz od više suglasnika se kompletno izgovara kao zvučni ili bezvučni niz ovisno o zadnjem fonemu niza. Ovo se odvija neovisno o tome kako je riječ napisana (*robstva→r o p s t v a, i ropstva→r o p s t v a*). Načini promjene fonema iz zvučnog u bezvučni su slijedeći:

- ako imamo **dc**, tada **d** prelazi u svoj bezvučni par **t**, pa je zamjena **tc**
- ako je niz od više njih, svi prelaze u verziju zadnjega
- iznimke su kad je **v** zadnji u niz, tad se on ponaša kao glasnih pa se zvučnost ne mijenja, te kad su **c i h** na mjestu prvog tad oni takvi jer ne postoji njihov zvučni par

3. korak algoritma

Stavljanje fonema **j** između para dvaju suglasnika od kojih je barem jedan **i** ili **e**.

Ovo je u biti alofon fonema **j**, ali alofoni nisu uzeti u obzir. Dakle, i u slučaju kad postoji **j**, i kad ga nema, čita se na jednak način - alofonom **j** tj., **j**.

Postoji posebno pravilo (5. korak) koje **ije** mijenja sa fonemom **ie**, što je nadogradnja ovom pravilu

Primjeri:

- matee→m a t e j e
- matea→m a t e j a
- maria→m a r i j a
- mie→m i j e →m ie (*objašnjeno u koraku 5*)

4. korak algoritma

Micanje svih duplih slova

Pošto je nemoguće prirodnim izgovorom izgovoriti dupla slova koja se nekad pojavljuju u riječi, tada je logično da budu uklonjena transkripcijom. (*npr. najjacxi→n a j a c x i...*)

5. korak algoritma

Primjena posebnih pravila

Tablica 8-Posebna pravila

PRAVILO	PRIMJER
1. $t c \rightarrow c$	bitci → b i c i
2. $t s \rightarrow c$	predstava (2.korak) → p r e t s t a v a → p r e c t a v a
3. $t cx \rightarrow cx$	mlatcxe (od mlatac) → m l a c x e
4. $t cy \rightarrow cy$	odcyarlijati (2.korak) → o t c y a r l i j a t i → o c y a r l i j a t i
5. $t sx \rightarrow cx$	predsxkolski (2.korak) → p r e t s x k o l s k i → p r e c x k o l s k i
6. $d z \rightarrow c$	ovo je slučaj zbog niza npr. 't s b' koji prelazi u 'd z b', a taj 'd z' je u biti alofon od 'c'
7. $d zx \rightarrow dzx$	kad bi se našlo npr. 't sx b', to bi prešlo u 'd zx b', pa treba naknadno pretvoriti u 'dzx'
8. $d dzx \rightarrow dzx$	sladoleddzxija → s l a d o l e d z x i j a
9. $d dy \rightarrow dy$	poddjakon → p o d y a k o n
10. $s sx \rightarrow sx$	uzsxetati (2.korak) → u s s x e t a t i → u s x e t a t i
11. $z zx \rightarrow zx$	razzvakati → r a z x v a k a t i
12. $s cx \rightarrow sx cx$	rascxlaniti → r a s x c x l a n i t i
13. $s cy \rightarrow sx cy$	rassxtrkati → r a s x t r k a t i
14. $z dzx \rightarrow zx dzx$	ovo nisam našao u primjerima ali mi je logično
15. $z dy \rightarrow zx dy$	razdyakoniti → r a z x d y a k o n i t i
16. $n p \rightarrow m p$	jedanput → j e d a m p u t
17. $n b \rightarrow m b$	stanben → s t a m b e n
18. $n m \rightarrow m$	našao sam primjer samo kod spoja riječi (jedan mu → jedamu), ali važilo bi i kod jedne riječi
19. $c cx \rightarrow cx$	ovo nisam našao u primjerima ali mi je logično
20. $c cy \rightarrow cy$	ovo nisam našao u primjerima ali mi je logično
21. $i j e \rightarrow ie$	nadogradnja za 3.korak algoritma (lijep → l i e p)

6. korak algoritma

Primjena slogotvornog **r** u posebnim situacijama.

Slogotvorno **r** – /rr/ dolazi u slučajevima kad je :

- /r/ na početku rečenice, a iza njega suglasnik
- /r/ na kraju rečenice, a ispred njega suglasnik
- /r/ u sredini rečenice kad su i ispred njega i iza njega suglasnici, osim kad se ispred njega nalazi **j**, **I**, **Ij**, **n**, **nj**, **cy**, **dzx** ili **dy**, a uključuje slučaj kad se iza njega nalazi **o**

Primjeri :

- **prst** → p rr s t
- **zxanr** → z x a n rr
- **istro** → i s t rr o

Postotak prepoznavanja bi primjenom transkripcija u odnosu na čisti grafemski zapis trebao porasti. Zbog prirodnijeg odnosa korespondencije zapisa riječi s prirodnim izgovorom.

6 Gradnja sustava za automatsko prepoznavanje izgovora matičnog broja studenta-korak po korak

Već smo u samome uvodu rekli kako je HTK alat veoma konfigurabilan i složen, te da zahtjeva veliku razinu interakcije sa korisnikom. U ovom poglavlju ćemo proći korake ručne izgradnje sustava za automatsko prepoznavanje matičnog broja studenta kao i još nekih podataka.

6.1 Preduvjeti za korištenje HTK alata

Prije korištenja potrebno je okolini operacijskog sustava omogućiti pristup HTK-ovim izvršnim datotekama, kako bismo ih mogli pozivati iz komandne linije. To ćemo napraviti tako da ćemo dodati varijabli okoline naziva „Path“, vrijednosti „C:\HTK_prepoznavanje_govora\htk3.3“

Također pošto HTK u nekim od svojih transformacija nad znakovnim nizovima koristi funkcije Perla. Biti će potrebno i njega instalirati.
[\(http://www.activestate.com/Products/activeperl/\).](http://www.activestate.com/Products/activeperl/)

6.2 Ručno korištenje alata-koraci

Da bismo dočarali konfigurabilnost HTK alata za početak možemo promotriti popis opcija koje će biti birane tokom izrade ovog sutava:

- odabir broja uzoraka za trening i test
- format u kojem se snimaju govorni signali, uz frekvenciju otipkavanja, i broj bitova po uzorku
- način parametrizacije govornih signala
- gramatiku
- konfiguracijske datoteke
- redoslijed funkcija (*sustav se gradi proizvoljno na način da korisnik sam odabere koju funkciju želi koristiti i kad – ne moraju, čak, ni ne mogu sve funkcije biti iskorištene*)
- opcije funkcija
- način treninga i prepoznavanja (*da li je riječ o prepoznavanju izoliranih rečenica, ili slijednog izgovora*)
- odabir korištenja označenih govornih signala, odnosno neoznačenih (*tada su obavezne transkripcije*)

Pri gradnji sustava postoje tri osnovne faze. To su :

1. **Priprema podataka**
2. **Treniranje sustava**
3. **Prepoznavanje željenih uzoraka**

6.3 Shematski prikaz sustava

Kao dodatak gradnji sustava korak po korak, u dodatku završnog rada je priložena i shema A2 formata, na kojoj su skicirani pojedini koraci gradnje sustava. Za lakše praćenje gradnje, pogodno je uz čitanje teksta, pratiti vizualno shemu, sa koje se mogu očitati svi relevantni podatci o ulazima i izlazima, za pojedine funkcije koje se koriste u određenim koracima gradnje sustava.

6.4 Priprema podataka

Gradnju našeg sustava krećemo od slijedećih datoteka:

1. tekst na hrvatskom jeziku – `tekst_hr.txt`
2. hrvatski rječnik (bez transkripcija) – `hr_rjecnik.txt`
3. konfiguracijske datoteke - `hcopy.conf` i `hcopytest.conf`

tekst_hr.txt- je proizvoljan tekst preuzet iz nekog digitalnog izvora. Znači dozvoljena je pojava svih hrvatskih i interpunkcijskih znakova. Ono što tekst ne bi smio sadržavati jesu riječi stranog podrijetla kao ni brojeve ili slične tvorevine koje nisu u zapisu oblika riječi. Tekst koji je odabran za konkretan primjer se može donekle rekonstruirati iz primitka. Tamo se nalaze trening rečenice konstruirane po tome tekstu. Međutim, zbog potrebe prilagodbe tako proizvoljnog teksta te rečenice ne odgovaraju u potpunosti preuzetom tekstu.

hr_rjecnik.txt- je rječnik 15000 najčešćih hrvatskih riječi dobiven preko materijala koji su slučajnim odabirom uzeti s interneta. To je jedan stupac riječi koji sadrži i stane riječi – ali samo one koje sadrže samo hrvatske grafeme (*one ne smetaju, ali ni ne koriste ako ih nema u uzorcima za trening, odnosno test*).

`hcopy.conf` i **`hcopytest.conf`**-su konfiguracijske datoteke koje definiraju podatke o valnome obliku u kojem se nalazi snimljeni signal za trening i test kao i on načinima parametrizacije. Izgled jedne takve datoteke je predložen na *slici 13*

```

SOURCEFORMAT      = WAV
TARGETKIND        = MFCC_0
TARGETRATE         = 100000
SAVECOMPRESSED    = TRUE
SAVEWITHCRC       = TRUE
WINDOWSIZE        = 250000.0
USEHAMMING        = TRUE
PREEMCOEF         = 0.97
NUMCHANS          = 26
CEPLIFTER         = 22
NUMCEPS           = 12
ENORMALISE        = FALSE

```

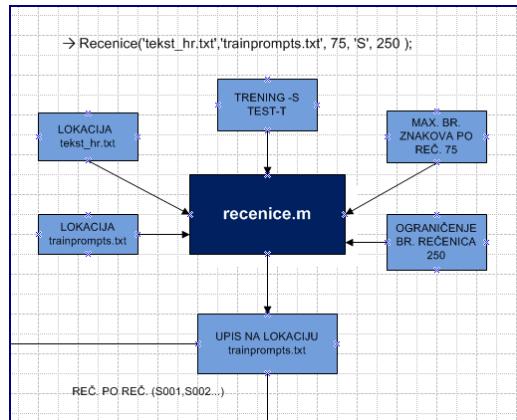
Slika 13-Primjer izgleda hcopy.conf

6.4.1 Priprema podataka za trening

Da bismo napravili podatke za trening, prvo moramo izgenerirati strogo oblikovane rečenice po čijim uzorcima ćemo snimiti akustične materijale. To obavljamo pomoću ranije opisane funkcije **recenice.m**. Sve opcije koje su navedene pri opisu funkcije se i ovdje primjenjuju. Pa se tako u konkretnom primjeru gradnje ovog sustava koristilo 300 rečenica maksimalne dužine 75 znakova.

Primjer poziva je isti kako u djelu gdje se opisuje funkcija uz napomenu da je potrebno navesti absolutne staze u koje se zapisuje i sa kojih se čita.

```
> recenice('STAZA/tekst_hr.txt', 'STAZA/trainprompts.txt', 75, 'S', 300);
```



Slika 14-Vizualni prikaz korištenja funkcije recenice.m

Kao izlaz se dobiju rečenice sljedećeg oblika:

```

S0210 BIO JE JEDAN OD NAJPERSPEKTIVNIJIH OKULISTA NOVOG ZELANDA A CXESTO JE
S0211 PUTOVAO U KINU I JAPAN
S0212 ODMAH NA ULAZU U CENTAR DOCXEKAO GA JE KOLEGA IZ ISTRAZIVACKOG TIMA S

```

Kompletna datoteka trainprompts.txt (300 rečenica) se nalazi u primitku.

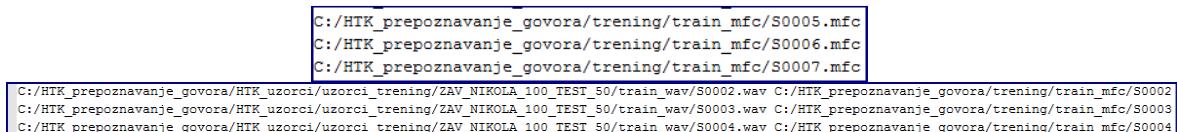
Sad kad imamo rečenice konstruirane po strogo definiranim pravila potrebno je da snimimo njihov izgovor u nekome od audio programa. Za gradnju sustava automatskog prepoznavanja matičnog broja studenta je korišten program audacity.

Bitne postaveke za dobivanje audio datoteka:

- Svaka rečenica se čita kao zasebna i sprema u wav format
- Postavke otiskavanje su 16kHz, 16-bit, mono

Navedeni podatci moraju biti usklađeni sa konfiguracijskom datotekom hcopy.conf. Svaka od snimljenih rečenica mora biti snimljena pod imenom 'SXXXX', gdje XXXX označava redni broj rečenice (*npr. prva je S0001.wav itd.*).

Da bismo mogli izvršiti parametrizaciju kao i re-estimacije kasnije, moramo znati putanje do svakog pojedinog audio zapisa. Ti podatci se nalaze u datotekama codetr.txt i train.txt. Dio putanja tih datoteka je vidljiv na *slici 15*.



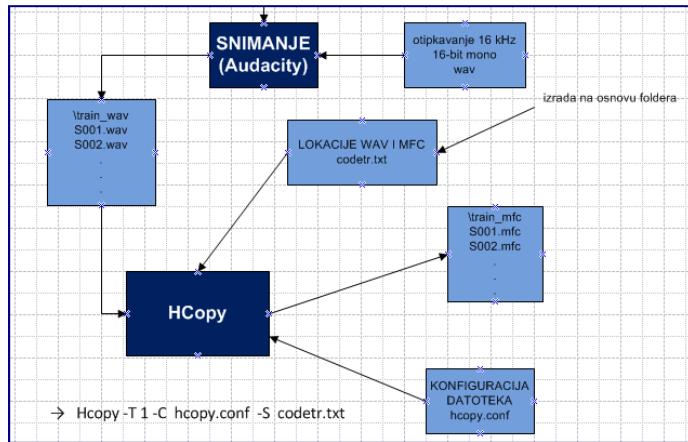
```
C:/HTK_prepoznavanje_govora/trening/train_mfc/S0005.mfc
C:/HTK_prepoznavanje_govora/trening/train_mfc/S0006.mfc
C:/HTK_prepoznavanje_govora/trening/train_mfc/S0007.mfc
C:/HTK_prepoznavanje_govora/HTK_uzorci/uzorci_trening/ZAV_NIKOLA_100_TEST_50/train_wav/S0002.wav C:/HTK_prepoznavanje_govora/trening/train_mfc/S0002
C:/HTK_prepoznavanje_govora/HTK_uzorci/uzorci_trening/ZAV_NIKOLA_100_TEST_50/train_wav/S0003.wav C:/HTK_prepoznavanje_govora/trening/train_mfc/S0003
C:/HTK_prepoznavanje_govora/HTK_uzorci/uzorci_trening/ZAV_NIKOLA_100_TEST_50/train_wav/S0004.wav C:/HTK_prepoznavanje_govora/trening/train_mfc/S0004
```

Slika 15-Primjer dijela codetr.txt i dijela train.txt

Vidjeti ćemo kasnije kako se ti podatci zapravo automatski generiraju pri korištenju sustava automatizacije. Međutim, ono što je bitno naglasiti je da se zapravo radi o običnoj tekstualnoj datoteci koju je moguće i ručno sastaviti ako na primjer baratamo sa manjim brojem rečenica. Kao što je vidljivo iz gore navedene staze sve audio datoteke se stavljaju u mape train_wav, a mfc datoteke u train_mfc.

Finalna faza u pripremi podatak za trening je pretvorba iz wav oblika u mfc naredbom

Hcopy.



Slika 16-Vizualni prikaz korištenja funkcije HCopy

6.4.2 Priprema podataka za test

Pošto sustava za automatsko prepoznavanje matičnog broja studenta ima svojstvene karakteristike tj. moguće je odrediti točni konstrukcijski izgled rečenice koja će biti nosilac podataka o pojedinom studentu. Tada je poželjno izgraditi gramatiku koja bi to opisivala, jer ćemo na taj način osigurati znatno bolje karakteristike sustava za razliku od korištenja nulte gramatike.

Sintaksna pravila za pisanje gramatike su slijedeća:

- | →operator „ili“, označava alternativu
- [] →opcionalni izrazi
- { } →nula ili više ponavljanja
- <> →jedno ili više ponavljanja
- «» →kontekstno ovisne petlje

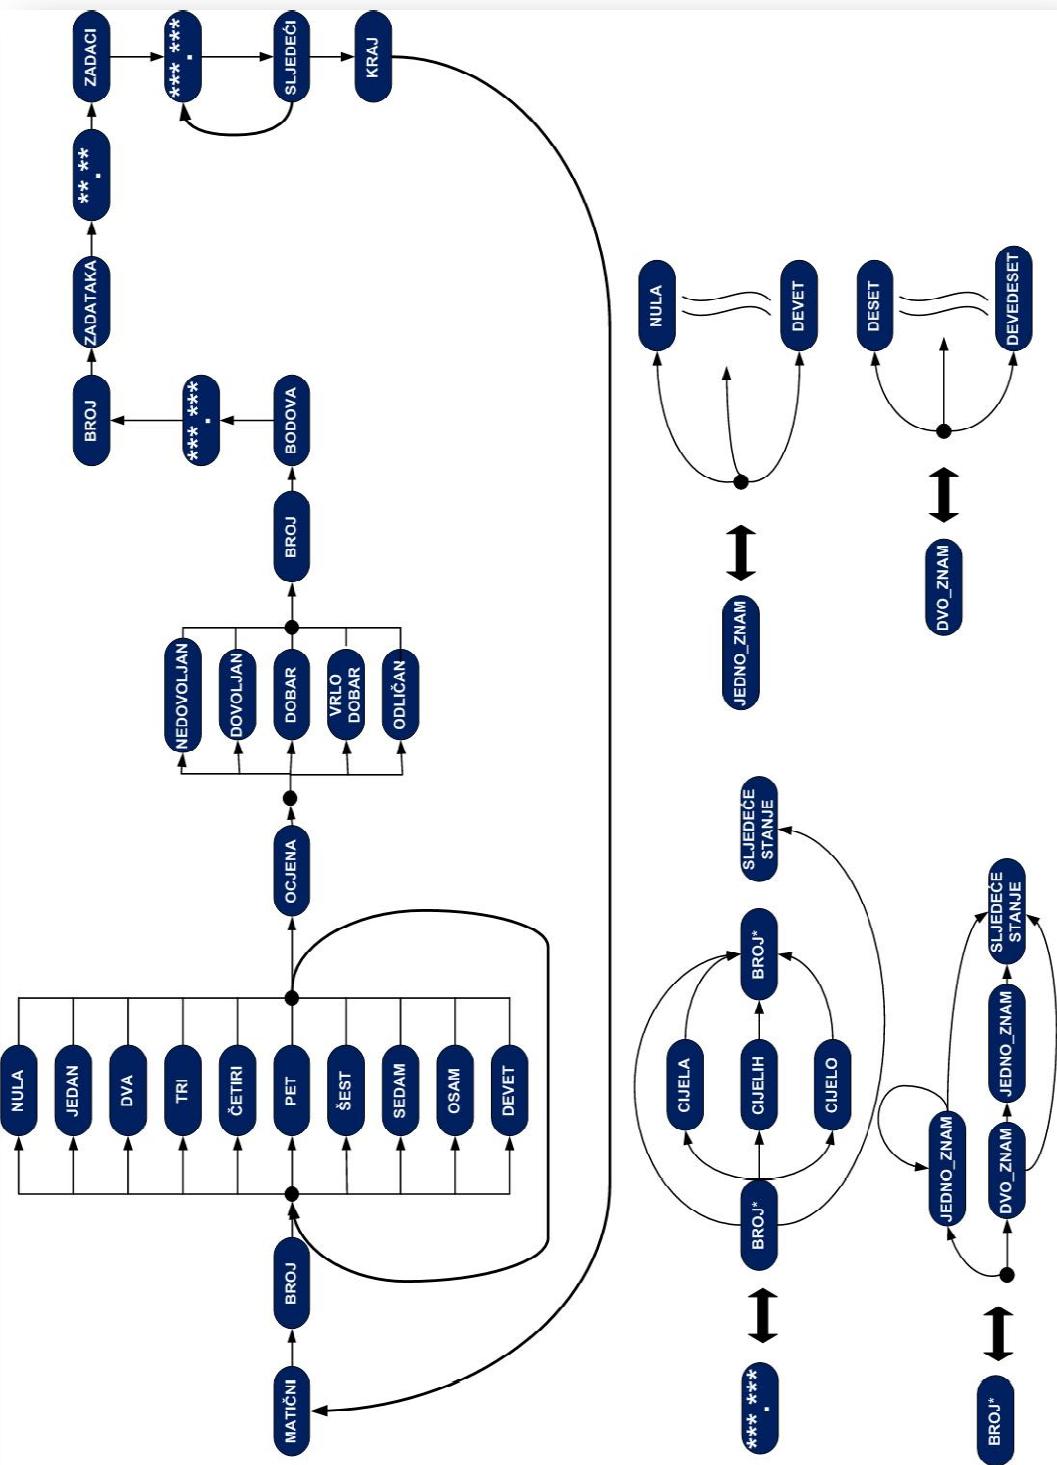
Na osnovu tih pravila izgrađena je i gramatika sustava za automatsko prepoznavanje matičnog broja studenta. Dio gramatike je vidljiv na *slici 17*, a cijelokupna se nalazi u privitku.

```
$mbr_rijec = (MATICXNI BROJ);
$mbr= NULA | JEDAN | DVA | TRI | CXETIRI | PET | SXEST | SEDAM | OSAM | DEVET;
$jednoznam= JEDAN | DVA | TRI | CXETIRI | PET | SXEST | SEDAM | OSAM | DEVET;
```

Slika 17-Dio gramatike sustava za automatsko prepoznavanje matičnog broja studenta

Iz zapisa je vidljivo kako oznaka „\$“ predstavlja varijablu koja u kasnijim izrazima zamjenjuje vrijednosti koje varijabla posjeduje sa desne strane znaka jednakosti.

Cijelokupna vizualizacija gramatike za sustav automatskog prepoznavanja matičnog broja studenta dana je na *slici 18*.

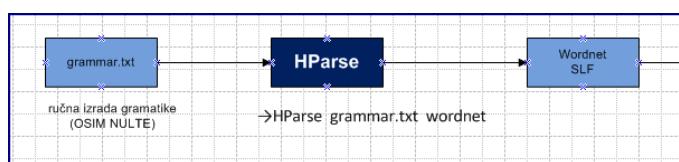


Slika 18-Grafički prikaz gramatike za sustav automatskog prepoznavanja matičnog broja studenta

Prikazani zapis unutar grammar.txt datoteke služi samo kao pomoć korisnicima za konstrukciju gramatike. HTK, zapis gramatike zahtjeva u SLF (*eng. Standard Lattice Format*) obliku. Pretvorbu iz grammar.txt, u wordnet (*SLF*), radimo pomoću funkcije *HParse*. Neke od prijelaza i stanja je moguće vidjeti na *slici 19*.

VERSION=1.0	
N=236	I=514
I=0	W=SENT-END
I=1	W=KRAJ
I=2	W=SLJEDECYI
I=3	W=DEVET
I=4	W!=NULL
I=5	W=OSAM
I=6	W=SEDAM
I=7	W=SXEST
I=8	W=PET
I=9	W=CXETIRI
I=10	W=TRI
I=11	W=DVA
I=12	W=JEDAN
I=13	W=DEVEDESET
I=14	W!=NULL
I=15	W=OSAMDESET

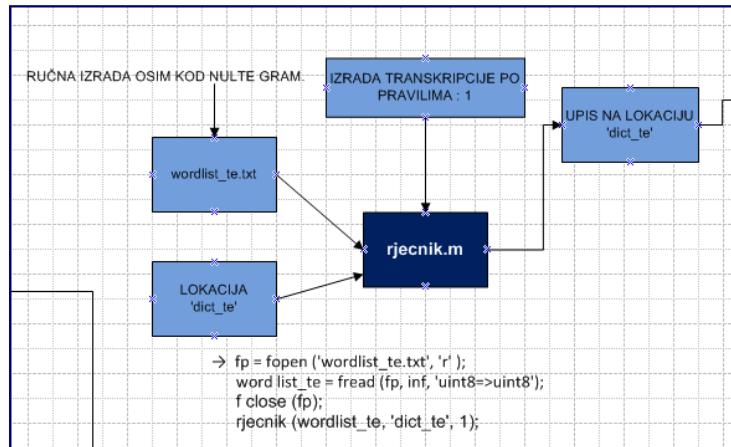
Slika 19-Isječak iz wordnet



Slika 20-Grafički prikaz korištenja funkcije HParse

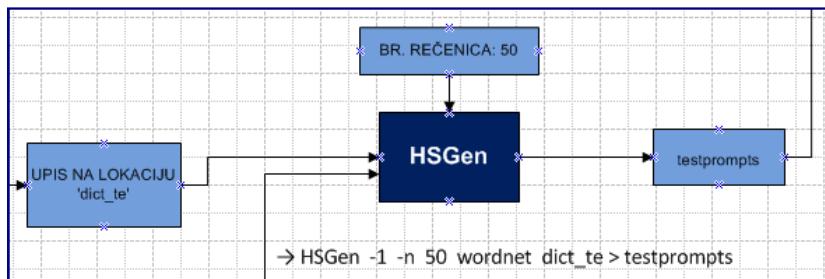
Pored gramatike za treniranje i testiranje sustava trebat će nam i listu riječi koje koristimo pri prepoznavanju. Listu riječi pod nazivom wordlist_te.txt izrađujemo ručno na način da svaku riječ navedemo jednu ispod druge te pored standardnih riječi uključimo još i stanja starta i kraja (*sent-start, sent-end*).

Nakon što imamo listu riječi, potrebno je nad tim riječima obaviti i pripadajuće transkripcije. Za to nam služi funkcija rjecnik.m. Pomoću nje konstruiramo rječnik transkripcija dict_te(PT=1). Ovim dijelom razdvajamo pripremu podataka za test od cjeline pripreme rječnika. Inače potrebno je napraviti cijelokupan rječnik, i od materijala za test, i od materijala za trening, te njega koristiti za izradu rečenica. Grafički prikaz zajedno sa primjerom poziva prikazan je *slikom 21*.



Slika 21-Grafički prikaz korištenja funkcije rjecnik.m

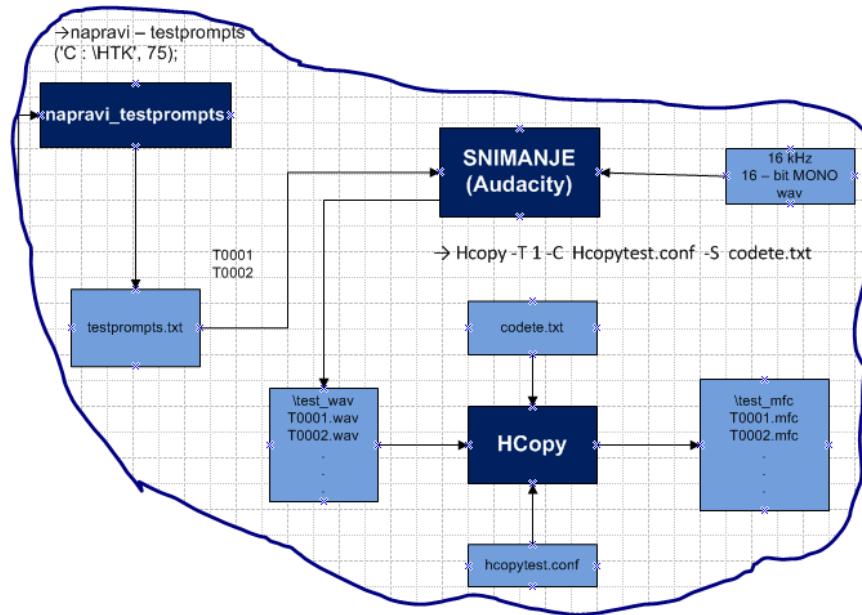
Sad kad imamo gramatiku i korištene riječi, možemo pokrenuti automatsko generiranje rečenica na osnovu kojih ćemo snimiti uzorke za test. Naravno ovo nije nužno, već se konstrukcija takvih rečenica može obaviti i ručnim upisivanjem. Kao nasumični generator rečenica po definiranim pravilima nam služi HTK-ova funkcija **HSGen**. Primjer poziva kao i ulazno izlaznih parametara prikazan je grafički na *slici 22*.



Slika 22-Grafički prikaz korištenja funkcije HSGen

Ovako izgenerirane rečenice još nisu pogodne za daljnju obradu tj. snimanje. Potrebno je napraviti izmjenu u zapisu tako da svaka rečenica počinje sa 'TXXXX', te je potrebno sprovesti skraćivanje svih rečenica na neku definiranu duljinu. Ovaj zahvat možemo napraviti pomoću funkcije napravi_testprompts.m

Sad nakon što imamo pravilno konstruiranu datoteku testprompts.txt, možemo krenuti sa snimanjem materijala putem audacy-a. Procedura je ista kao i za trening. Dakle, svi uzorci moraju biti pravilo obilježeni i spremljeni u odgovarajuće mape (*test_wav* i *test_mfc*). Konfiguracijske datoteke moraju biti podešene prema parametrima korištenim u snimljenim materijalima. Grafički prikaz opisanih radnji pokazuje *slika 23*.



Slika 23-Grafički prikaz od testprompts do pretvorbe u mfc

6.5 Treniranje sustava i prepoznavanje željenih uzoraka

U gornjim koracima su objašnjeni postupci pripreme podataka za trening i test. Kad imamo tako pripremljene podatke možemo krenuti sa treniranjem sustava. Postupak ručnog treninga sustava ovdje neće biti obrađen korak po korak. Razlog tome je činjenica da za takvo što već postoji automatizacija (*pogledati literaturu [2]*), dok bi ručna gradnja sustava bila odviše složena i vremenski neefikasna. Koraci ručnog treninga sustava se ipak nalaze na shematskom prikazu kao i u gore navedenoj literaturi. Kao uvid u ručno treniranje sustava, samo ćemo nabrojati korake kroz koje moramo proći:

- Priprema transkripcija
 - Obavlja se pretvorba rečenica tranprompts.txt u mlf oblik (*skriptom prompts2mlf*)
 - Rastav riječi na transkripcije u mlf formatu funkcijom **HLED** pomoću rječnika **dict** i skripte **mkphones0.led**
- Inicijalizacija modela u sustavu
 - Definiranje modela principom flat start pomoću prototipa proto i konfiguracijske skripte **hcompv.conf** naredbom **HCompV**
 - izrada definicije modela u skripti **hmmdefs.mmf** i makro naredbi **macros** u mapi **hmm0**
 - niz od tri re-estimacije parametara monofonskih modela naredbom **HERest**

- Uvođenje modela kratke pauze i nadogradnja modela tišine
 - Dodavanje novog modela kratke pauze među riječima – ***sp***
 - Nadogradnja modela tišine — ***sil***
 - Povezivanje centralnih stanja modela ***sp*** i ***sil***
 - Nova transkripcija na razini monofona, sa uključenim modelom ***sp*** pomoću ***HLED***
 - Dvostruka re-estimacija modela funkcijom ***HERest*** nakon uvođenja modela ***sp***
- Kreiranje kontekstno ovisnih trifonskih modela
 - Izrada trifonskih transkripcija ***wintri.mlf*** i liste svih trifona korištenih u tekstu—***tripphones1***—pomoću naredbe ***HLED*** i skripte ***mktri.led***
 - Gradnja kontekstno ovisnih trifonskih modela, na temelju monofonskih, te povezivanje matrica prijelaza, pomoću naredbe ***HHEd*** i skripte ***mktri.hed***
 - Dvostruka re-estimacija kontekstno vezanih trifonskih modela funkcijom ***HERest*** nakon povezivanja matrica prijelaza
 - Izrada liste svih trifona u hrvatskom jeziku u ***fullist*** pomoću naredbe ***HDMAn*** i skripte ***global_tri.ded***
 - Vezanje stanja u trifonskim modelima pomoću naredbe ***HHEd***

Nakon što smo uspješno završili trening, potrebno je pokrenuti prepoznavanje. Pošto su svi podatci već unaprijed pripremljeni i spremni za prepoznavanje, sve što moramo učiniti je pokrenuti funkciju ***HVite***. Nakon što je prepoznavanje obavljeno, pomoću funkcije ***HResults*** možemo dobiti analizu točnosti i cijelokupnu statistiku prepoznavanja. Dakle koraci prepoznavanja su:

- Prepoznavanje govora pomoću funkcije ***HVite***
- Priprema referentnog teksta test uzorka pomoću skripte ***prompts2mlf***
- Analiza rezultata pomoću ***HResults***

Grafički prikaz je dan na shematskom dijagramu.

7 Automatizirana verzija HTK alata

Dosadašnja izgradnja sustava se zasnivala na ručnom pokretanju HTK funkcija u command promptu ili shellu. Pri takvom načinu gradnje količina interakcije sa korisnikom je velika, a gradnja sustava jako dugo traje. Motivacija automatizacije je savladavanje navedenih nedostataka. U automatizaciji preuzetoj iz literature [2], automatizirane su samo neke od opcije. Sposobnost konfigurabilnosti je ostavljena pri izboru testa dok se metoda treninga ne može birati, tj. uvijek se koristi metoda slijednog govora sa neoznačenim govornim materijalom. Sve što nam je potrebno za automatiziranu verziju HTK alata se nalazi u mapi *HTK_prepoznavanje_govora*, grafičko sučelje sustava se poziva naredbom *HTK_gui.m*.

Napomene o uvjetima korištenja vrijede od prije, pri čemu je od sada nužnost i matlab koji je prije bio uključen samo indirektno za rad pojedinih funkcija, a sad se sustavno koristi već pri samom pokretanju sučelja.

7.1 Snalaženje unutar strukture mape *HTK_prepoznavanje_govora*

Krenuti ćemo od popisa funkcionalnosti podmappa:

- htk.3.3 - sadrži sve HTK funkcije verzije 3.3
- matlab - sadrži sve potrebne matlabove funkcije osim glavne
- trening – mapa u kojoj se radi treniranje modela
- test – mapa u kojoj se testira
- HTK_uzorci – mapa s uzorcima za trening i test, u kojoj se vrši sva potrebna priprema prije pokretanja sustava za trening, odnosno prepoznavanja

Pokretanje sustava se odvija pozicioniranjem pokazivača u matlabu unutar glavne mape i pozivom grafičkog sučelja *HTK_gui.m*.

Unutar mape trening i test odvijaju se svi međurezultati za pojedini trening odnosno test. Ove mape pri svakom pokretanju treninga odnosno testa se prethodno moraju inicijalizirati, brišući rezultate prethodnog treninga, odnosno, testa. Svi trening i test materijali iz mapa *trening* i *test*, bivaju pohranjeni u za to predviđene mape unutar mape *HTK_uzorci*.

Funkcionalnost alat je zamišljen kroz tri moda rada:

- Snimanje uzoraka za test
- Snimanje uzoraka za trening
- Prepoznavanje govora

7.2 Priprema za automatizaciju

U ručnoj gradnji sustava je proces pripreme podataka objašnjen korak po korak. Razlog tome leži u činjenici da i pri korištenju automatizacije veći dio pripreme podataka mora ipak biti obavljen ručno ili pri gradnji iziskuje neke od promjena koji na taj način moraju biti ubaćene. Priprema za trening i test pri korištenju automatizirane verzije je objašnjena u sljedeća dva poglavlja.

7.2.1 Priprema za automatizaciju-trening

Pretpostavimo da želimo raditi sa potpuno novim podatcima koji još nisu snimljeni. Prvi korak u gradnji novih akustičkih modela koji će nastati na osnovu novog trening materijala je konstrukcija nove mape proizvoljnog imena unutar mape *uzorci_trening*. Unutar kreirane mape postavljamo već prije spomenuti proizvoljni tekst pod nazivom **tekst_hr.txt**. (*Pravila o tome što tekst smije, a što ne smije sadržavati, dana su u poglavlju ručne izgradnje sustava*). Da bismo sustavu automatizacije dojavili kako postoje novi trening materijali, potrebno je u datoteku **mape_sn_tr.txt**, koja se nalazi u mapi *uzorci_trening*, upisati ime proizvoljne mape koju smo kreirali, a u kojoj se nalazi proizvoljni tekst.

7.2.2 Priprema za automatizaciju-test

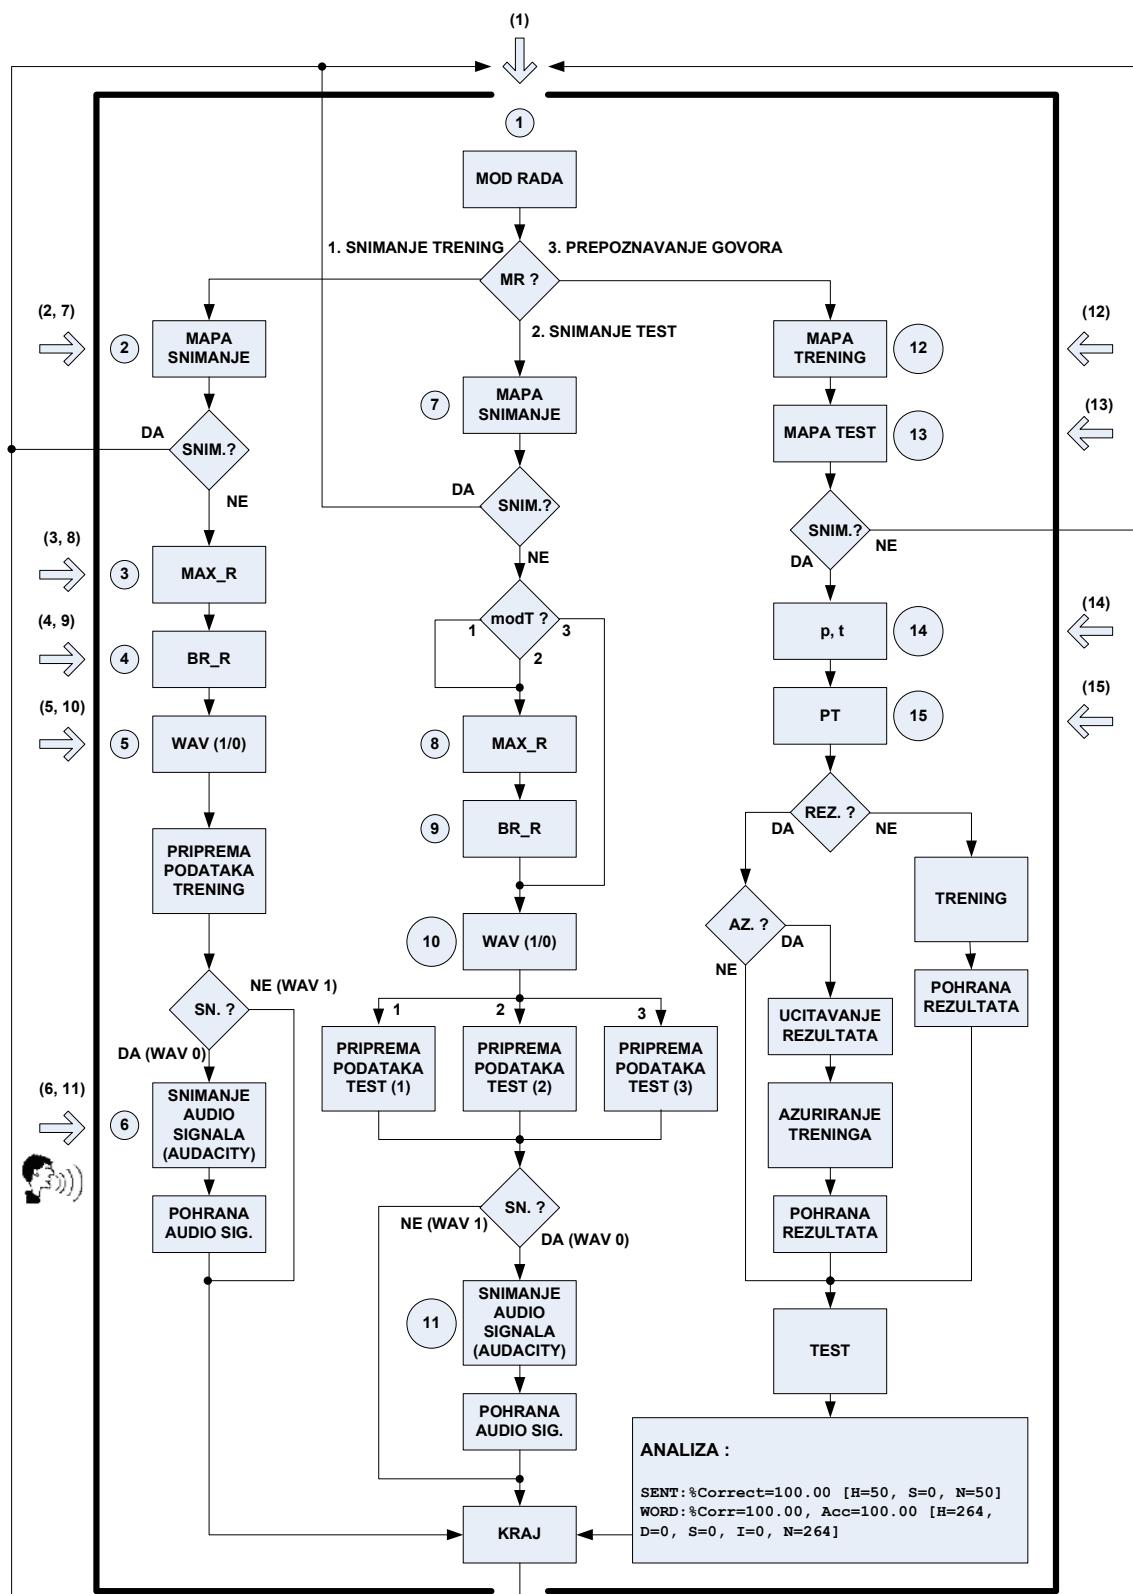
Zbog veće konfigurabilnosti testa, situacija pripreme podataka je nešto komplikiranija, odnosno više stvari je potrebno napraviti ručno pa tek onda koristiti sustav automatizacije. Test je osmišljen tako da postoje tri različita slučaja. Prvi slučaj je testiranje sustava na temelju podataka konstruiranih prema gramatici. (*Ovo je slučaj koji nas zanima pri gradnji sustava za automatsko prepoznavanje matičnog broja studenta*). Kao i priprema treninga, priprema testa također iziskuje pravljenje proizvoljne mape, samo ovaj puta unutar mape *uzorci_test*. Unutar tako konstruirane mape postavljamo željenu gramatiku naziva **grammar.txt**. Pored gramatike, potrebna je i ručna izrada

cjelokupnog vokabulara korištenog u gramatici. Vokabular gramatike se izrađuje na način de se svaka riječ gramatike upiše u novi red datoteke **wordlist_te.txt**, a pored toga se još dodaju stanja *sent-start* i *sent-end*.

U slučaju da želimo testiranje sustava napraviti na nekom proizvoljnom tekstu koji nema definiranu gramatičku konstrukciju, tada u mapu dodajemo dotični tekst spremlijen u datoteku pod nazivom **tekst_te.txt**. I u ovome slučaju je potrebno imati cjelokupni vokabular teksta tj. potrebno je ponovno konstruirati datoteku **wordlist_te.txt**. Međutim, ovog puta se radi o nultoj gramatici pa se sustav za to zna sam pobrinuti. Ono što mi moramo osigurati je postojanje datoteke **wordlist_te**, a njezin sadržaj se ostavlja prazan. To je slučaj kad želimo da sustav prepoznae samo vokabular naveden u testu. Međutim, tako konstruiran vokabular možemo i značajno proširiti, na način da u **wordlist_te.txt** dodamo sve riječi za koje mislimo da bi se mogle pojaviti prilikom testiranja sustava. Gledano općenito, ako želimo dobiti sustav koji je u stanju vršiti prepoznavanje bilo kojeg teksta tada je potrebno unijeti cjelokupni vokabular hrvatskog jezika. To možemo donekle postići tako da kao rječnik postavimo datoteku koja sadrži 15000 najčešće korištenih hrvatskih riječi. Dakle **hr_rjecnik.txt** prekopiramo u **wordlist_te.txt**.

Treća opcija testiranja predviđa već definirane rečenice **testprompts.txt** ali bez gramatike. Moguće je da već postoje snimljeni uzorci tih rečenica. Ova opcija je zamišljena za testiranje već gotovih izgovora neke gramatike, ali na temelju nulte gramatike, kako bismo mogli napraviti usporedbu rezultata, tj. definirati koliko gramatika poboljšava efikasnost sustava. Procedura postavljanja datoteka je ovdje ista kao u prva dva slučaja samo što se sada direktno postavlja datoteka **trainprompts.txt**, a ne vrši se njezina konstrukcija iz ostalih podataka.

Kao i kod pripreme za trening i ovdje je na neki način potrebno sustavu automatizacije javiti da postoje novi podatci za test. To radimo na način da u datoteku **mape_sn_te.txt** koja se nalazi u mapi **test_uzorci**, upišemo naziv proizvoljne mape u koju smo pohranili sve gore navedene datoteke zavisno o jednoj od tri opcije testa koju smo odabrali. Sustav automatizacije će sam, automatski, prema postojećim datoteka unutar te proizvoljne mape zaključiti o kojem se testu radi.



Slika 24-Grafički prikaz automatizacije-(preuzeto iz literature [2])

7.3 Snimanje uzorka za trening

Snimanje uzorka za trening se pokreće odabirom prvog moda rada. Ponuđeni uzorci za snimanje će se zasnivati na zapisima koji se nalaze unutar datoteke **mape_sn_tr.txt**. Već je rečeno da se unutar te datoteke nalazi popis svih novo napravljenih mapa čiji trening materijali još nisu obrađeni ni napravljeni. Sljedeće dvije opcije koje su ponuđene pri izradi trening materijala se odnose na datoteku **trainprompts.txt**. Sustav automatizacije nas pomoću opcija **max_r** i **br_r** pita koliko riječi smije maksimalno sadržavati jedna rečenica te koliko takvih rečenica želimo konstruirati unutar datoteke **trainprompts.txt**. Na osnovu tih rečenica ćemo morati snimiti audio materijale koji će se koristiti pri treniranju sustava. U slučaju da materijale već imamo snimljene, tada stavljamo kvačicu na zadnju opciju, a ako ne, tada pokrećemo Audacity ili neki drugi program za snimanje i pravimo audio datoteke pridržavajući se pravila zapisanih u postavkama HTK funkcija, koje primjenjujemo pri parametrizaciji (*otipkavanje 16kHz, 16-bit, mono*). Nakon što smo snimili tražene materijale, imenujemo ih prema sustavu opisanom ranije (*SXXXX.wav*) i stavljamo unutar mape *train_wav*. Sustav automatizacije će samostalno kreirati datoteke poput **codetr.txt** i **train.txt**, koje nam govore o lokacijama audio i parametriziranih datoteka nad kojima će se vršiti parametrizacije i višestruka estimacija.

7.4 Snimanje uzorka za test

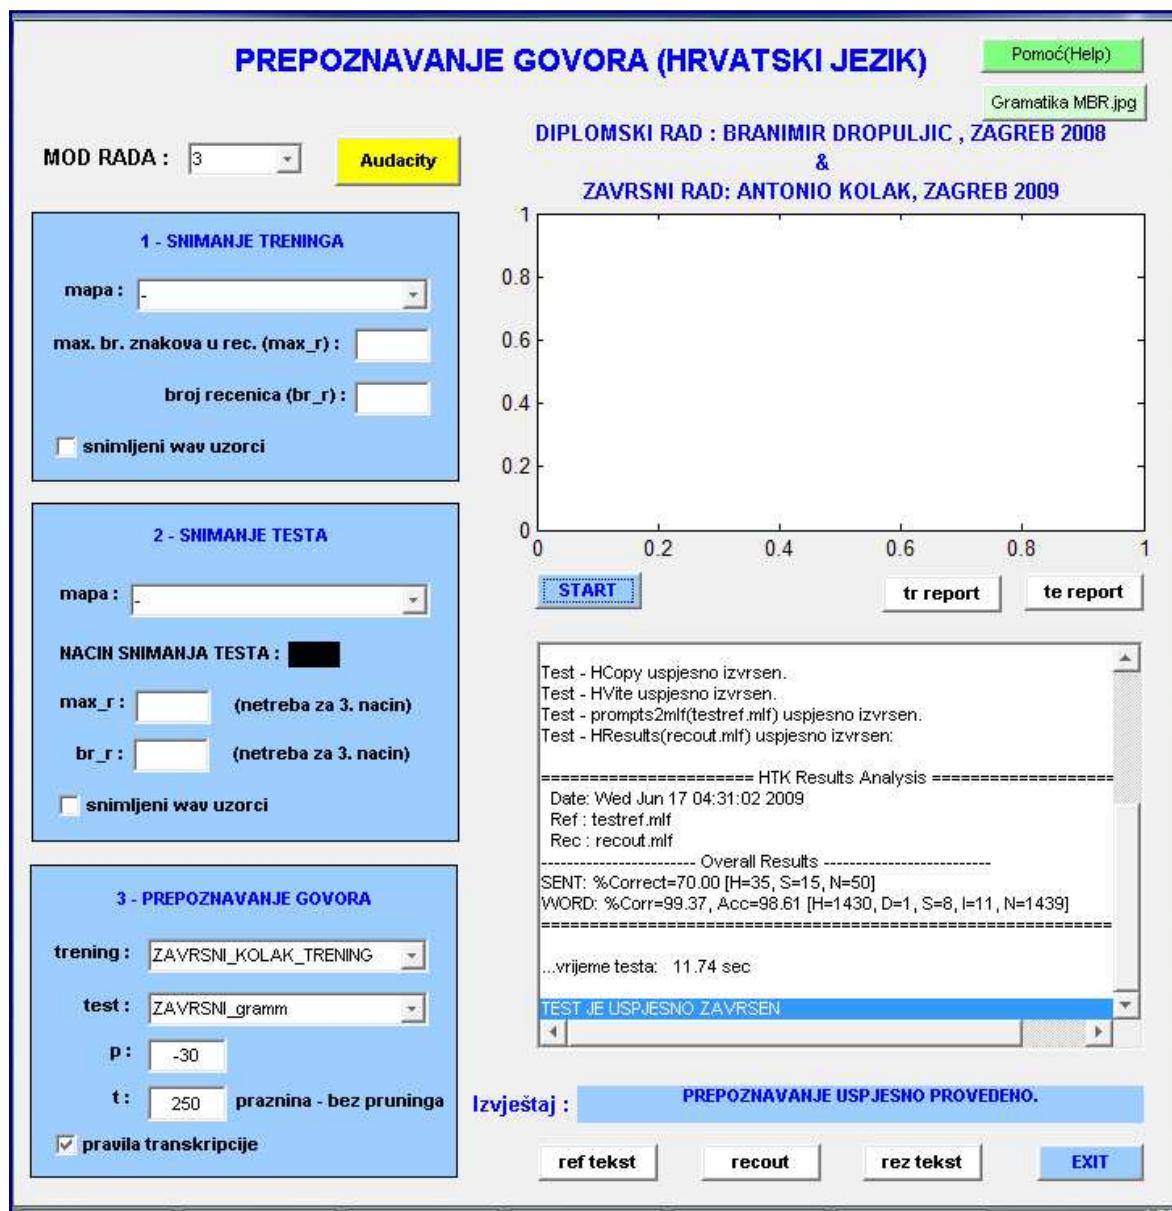
Drugi mod rada pokriva snimanje uzorka za test. Već u samoj pripremi podataka rekli smo da razlikujemo tri slučaja kod izrade uzorka za test. Nas zanima slučaj 1, kad vršimo testiranje sustava na osnovu gramatike. Što se tiče ponuđenih opcija, stvar je ista ko i sa snimanjem uzorka za trening. Dakle, opet nam je ponuđen odabir mape unutar koje se nalaze željeni test uzorci, te odabir konfiguracije datoteke **testprompts.txt**, tj. koliko maksimalno riječi smije sadržavati pojedina rečenica, i koliko ćemo takvih rečenica imati u testu. Sustav će samostalno na osnovu priložene gramatike konstruirati mrežu riječi (**wordnet**) i pripadne riječnike transkripcija **dict_te(PT-0)** i **dict_te(PT-1)**. Funkcija HSGen će izgenerirati **testprompts**, a funkcija **napravi_testprompts.m** će ih prilagoditi na strogo oblikovanu formu definirano odabirom opcija **max_r** i **br_r**. Putanje do parametriziranih i audio datoteka će također biti izgenerirane od strane sustava (**codete.txt** i **test.txt**).

Nakon što imamo sve potrebne datoteke, otvara se testprompts.txt te možemo pokrenuti Audacity i započeti snimanje test materijala.

Gotovo pa identičan slijed aktivnosti se odvija kod slučaja dva i tri, samo što su neke od datoteka unaprijed konstruirane. Pošto nam nisu od značaja za izučavanje pri gradnji sustava automatskog prepoznavanja matičnog broja studenta, tada ih nećemo niti detaljno opisivati.

7.5 Prepoznavanje

Treći mod rada je prepoznavanje. Da bismo vršili prepoznavanje potrebno je da odaberemo dvije primarne opcije. To su pripadajuća trening baza i odgovarajući test koji želimo primijeniti na tu bazu. Dodatne opcije koje je moguće konfigurirati, ako je značajno utječu na performanse prepoznavanja, su parametri (**p-word insertion penalty**) i (**t-pruning**). Također tu je i opcija o tome da li se radi primjenom pravila transkripcije ili ne. Svi rezultati dobiveni tokom prepoznavanja se pohranjuju u odgovarajuće mape. Preciznije, rezultati testa s odgovarajućim akustičkim modelima se pohranjuju u mapu dotičnog testa, dok se rezultati treninga pohranjuju u mapu dotičnog treninga. Jedan te isti test može biti ispitivan sa više trening baza. Ovakav način pohrane rezultata nam omogućuje da pri korištenju istog treninga, za neki drugi test, samo dohvativimo već gotove rezultate, te izvršimo testiranje. Dodatna objašnjenja o tome kada ne možemo upotrijebiti već gotove rezultate se mogu pronaći u literaturi [2].



Slika 25-Grafičko sučelje HTK_gui

8 Analiza rezultata sustava za automatsko prepoznavanje matičnog broja studenta

Svrha ove analize je provjera karakteristika dobivenih pri konstrukciji sustava za automatsko prepoznavanje matičnog broja studenta. U tu svrhu provedena su testiranja materijala, na temelju različite utreniranosti sustava (*parametri sustava kao i test uzorci pri ovom testu ostaju ne promijenjeni*). Pored toga testiranja napravljeno je i testiranja u ovisnosti o broju govornika, pri čemu su test uzorci od samo jednog govornika. Od značajnih parametara koji utječu na rezultate prepoznavanja ispitivanja su provedena sa izmjena koeficijenta **p** i pruninga **t**. Dani su tablični odnosi promjene kvalitete sustava u zavisnosti o promjeni jedne od tih veličina. I kao krajnji cilj testa provedena je analiza uspješnosti prepoznavanja u slučaju da se sustav trenira stvarnim rečenicama kakve i generira.

8.1 Analiza zavisnosti o količini trening materijala

Cilj ove analize je pokazati zavisnost kvalitete prepoznavanja sustava o količini trening materijala. Za ovu analizu korišteni su akustički materijali od prije, pa je za očekivati da rezultati prepoznavanja budu lošiji pošto ovakvi sustavi dosta zavise o govorniku. Razlog se naravno krije u testu koji se sastoji od 50 rečenica drugog govornika, pošto ovaj sustav ima specifičnu gramatiku te nisu mogli biti upotrijebljeni stari testni primjeri.

Tablica 9-Resultati analize zavisnosti o količini trening materijala

TRENING – nevezani tekst, 1 govornik TEST – gramatika dotičnog sustava 50 rečenica – 1 govornik(različit od treninga) PT = 1 , p = -30				
BROJ REČENICA TRENINGA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEĆI (D)	ZAMIJENJENIH RIJEĆI (S)	UMETNUTIH RIJEĆI (I)
500	96.53	9	27	14
400	93.12	16	61	22
300	94.86	9	43	22
200	95.76	6	33	22
100	91.66	26	70	24

8.2 Analiza zavisnosti o broju govornika

Tablica 10- Rezultati analize zavisnosti o broju govornika

TRENING – nevezani tekst, 500 rečenica TEST – gramatika dotičnog sustava, 50 rečenica – 1 govornik(različit od treninga) PT = 1 , p = -30				
BROJ GOVORNIKA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
1	96.53	9	27	14
10	96.80	0	13	33

Povećanje broja govornika pozitivno je utjecalo na sustav kako je to vidljivo iz tablice. Razlog je bolja pokrivenost sustava neovisnog o govorniku. Pošto je testni materijal napravljen na akustičkom modelu čiji glas nije pokriven niti jednim od ova dva treninga.

8.3 Analiza zavisnosti o koeficijentu p

Tablica 11- Rezultati analiza zavisnosti o koeficijentu p

TRENING – nevezani tekst, 300 rečenica, 3 govornik TEST – gramatika dotičnog sustava, 50 rečenica – 1 govornik(različit od treninga) PT = 1				
P	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
0	75.96	2	128	216
-10	80.19	8	116	161
-20	82.84	13	109	125
-30	84.36	23	101	101
-40	85.75	33	99	73
-50	86.73	38	95	58
-60	87.49	43	91	46
-70	88.33	49	87	32
-80	88.88	53	85	22
-90	88.88	60	82	18
-100	89.37	61	82	10

Pri ovoj analizi primarni cilj nije generalno promatranje točnosti sustava već njezina promjena u odnosu na varijacije koeficijenta p . Općenito govoreći točnost prepoznavanja ovog primjera je znatno manja nego kod ostalih slučajeva. Razlog tome su trening i test materijali snimljeni od različitog govornika, a pri čemu akustički model nije kreiran kao neovisan o govorniku.

Iz tablice je vidljivo kako povećanjem koeficijenta p (*ne gledajući predznak*) raste točnost prepoznavanja. Najveća odstupanja se zamjećuju kod umetnutog broja riječi. Broj obrisanih riječi raste, a broj zamijenjenih riječi pada.

8.4 Analiza utjecaja pravila transkripcije

TRENING – nevezani tekst, 350 rečenica TEST – gramatika dotičnog sustava, 50 rečenica – 1 govornik, sudjeluje i u treningu $p = -30$				
PRAVILA TRANSKRIPCIJE	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
1	98.26	0	19	6
0	98.82	0	11	6

Pošto je hrvatski jezik ipak grafemski, tada ni odstupanja ovoga testa neće biti velika. Razlog tome je što sva pravila koja su uključena u sustav transkripcije, statistički gledano zahvaćaju oko 5 % vokabulara hrvatskog jezika. Sukladno tome slijede i rezultati. Ono što je zanimljivo je da smo u ovoj analizi za specifični sustav, automatskog prepoznavanja izgovora matičnog broja studenta, dobili nešto bolje rezultate za isključena pravila transkripcije. Objasnjenje se krije u specifičnoj gramatici odnosno njezinom vokabularu koji se primjenjuje pa tako rezultati ispadaju bolji kada se primjeni čista grafemska transkripcija.

8.5 Analiza zavisnosti brzine prepoznavanja o prunu

Iznos širine snopa (t)	Točnost na razini riječi(%)	Vrijeme preozn. (s)
-	98.75	127.61
350	98.61	13.44
300	98.61	12.58
250	98.61	11.74
200	98.61	10.83
150	98.47	9.90
100	97.21	9.04

Analiza nam pokazuje kako smanjenjem širine snopa možemo značajno ubrzati proces prepoznavanja a da pri tome značajno ne izgubimo na točnosti. Ovakvo smanjenje širine i ubrzanje sustava je moguće sve dok ne dođe do zamiranja putova. U tome slučaju ćemo imati pogrešku pri prepoznavanju jer takve rečenice uopće neće biti prepoznate.

8.6 Analiza ovisno o trening materijalu

TRENING – nevezani tekst, 3 govornik TEST – gramatika dotičnog sustava 50 rečenica – 1 govornik PT = 1 , p = -30				
BROJ REČENICA TRENINGA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
300	98.75	0	7	11

TRENING – nevezani tekst, 3 govornik+50 rečenica sustava TEST – gramatika dotičnog sustava 50 rečenica – 1 govornik (isti kao i za 50 rečenica sustava) PT = 1 , p = -30				
BROJ REČENICA TRENINGA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
350	99.03	0	4	10

TRENING – nevezani tekst, 1 govornik TEST – gramatika dotičnog sustava 50 rečenica – 1 govornik(različit od treninga) PT = 1 , p = -30				
BROJ REČENICA TRENINGA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
100	84.36	23	101	101

TRENING – nevezani tekst, 1 govornik+50 rečenica sustava TEST – gramatika dotičnog sustava 50 rečenica – 1 govornik(isti kao i za 50 rečenica sustava) PT = 1 , p = -30				
BROJ REČENICA TRENINGA	TOČNOST PREPOZNAVANJA (%)	OBRISANIH RIJEČI (D)	ZAMIJENJENIH RIJEČI (S)	UMETNUTIH RIJEČI (I)
150	99.10	0	5	8

Iz ove analize je vidljivo kako sustav pokazuje bolje performanse pri treniranju sa vlastitim rečenicama (tj. onakvim rečenicama kakve proizlaze iz sustava), jer odgovaraju stvarnoj namjeni pa su i modeli bolji. Pri sustavu od tri govornika pomak je minimalan jer je utreniranost sustava već jako dobra. Međutim, kod sustava kod kojeg je utreniranost lošija i čiji je akustički modeli treninga i testa ne poklapaju po pitanju govornika, razlika postaje znatno uočljivija, iz čega možemo zaključiti kako bi ovakve sustave specifične namjene trebalo trenirati upravo sa rečenicama koje se primjenjuju za prepoznavanje.

9 Zaključak

Rezultati analize pokazuju kako metoda prepoznavanja govora pomoću skrivenih markovljevih modela daje zadovoljavajuće rezultate. Za karakterističnu primjenu kakva je razmatrana u ovome završnome radu (*Sustav za automatsko prepoznavanje izgovora matičnog broja studenta*), rezultati prepoznavanja u svim ispitivanjima prelaze 91%, što je zadovoljavajuće s obzirom da je to najlošiji rezultat, u kojem imamo sustav s malom količinom trening materijala, a test s govornikom ne utreniranim na taj model. Relativno visoki postotak prepoznavanja sa, i bez, ovisnosti sustava o govorniku, možemo zahvaliti specifičnosti sustava, tj. primjenjene gramatike, koja znatno podiže performanse prepoznavanja. Također rezultati analize pokazuju kako već akustički model od 300 rečenica zadovoljava zahtjeve na sustav neovisan o govorniku i daje prepoznavanje od oko 99%. Još bolje performanse sustav je pokazao pri treniranju sa vlastitim rečenicama, koje su rezultat ove specifične namjene.

Daljnji razvoj bi trebalo usmjeriti na razvoj online sustava putem ATK (*eng. An Application Toolkit for HTK*) zasnovanog na ovako izgrađenim modelima. Time bismo dobili direktnu povratnu vezu u vidu korekcije pogrešaka koje bi mogle nastati čitanjem odnosno greškom sustava.

10 Literatura

- [1] S. Young i ostali, The HTK Book (for HTK Version 3.3), Cambridge University Engineering Department, Cambridge, 2005.
- [2] B. Dropuljić, Postupci razvoja akustičkog i leksičkog modela sustava za automatsko prepoznavanje govora za hrvatski jezik, diplomski rad, ZESOI, FER, Zagreb, 2008.
- [3] S. Young, ATK An Application Toolkit for HTK version 1.6, Machine Intelligence Laboratory, Cambridge University Engineering Dept, Cambridge, 2007.
- [4] S. Babić i ostali, Glasovi i oblici hrvatskoga književnoga jezika, Velika hrvatska gramatika, Zagreb, 2007.
- [5] Barić, Hrvatska Gramatika, Zagreb, 1997.
- [6] S. Babić, Hrvatski Pravopis, Zagreb 1995.
- [7] Težak, S. Babić, Gramatika hrvatskog jezika, Zagreb, 2000.
- [8] L.Rabiner, B.H. Juang, Fundamentals of Speech Recognition, Prentice Hall, New Jersey, 1993.
- [9] M. Žagar, Otvoreno računarstvo, predavanja, Zagreb, 2009.
- [10] H.Schildt, Java™ J2SE 5:Kompletan priručnik, Beograd,Mikro knjiga, 2006.
- [11] M. Čupić, Java, <http://java.zemris.fer.hr/materials.jsp?lang=hr>,2008.
- [12] R. Mlinarec, Tkači snova,
http://www.elektronickeknjige.com/mlinarec_robert/tkaci_snova/index_page_000.htm,
- [13] Perl, <http://www.activestate.com/Products/activeperl/>
- [14] Full Product Family Help Release 14 with Service Pack 3, Matlab Help, 2006.

11 Sažetak

11.1 Sustav za automatsko prepoznavanje izgovora matičnog broja studenta

Završni rad se bavi izgradnjom sustava za automatsko prepoznavanje izgovora matičnog broja studenta. Kao temelj sustava koristi se HTK alat (*eng. HMM Toolkit*) za kojeg su razvijene određene programske prilagodbe, sukladno navedenoj namjeni. Unutar rada se objašnjavaju teoretske osnove i principi rada sustava zasnovanog na Markovljevim modelima, kao i izgradnja dotičnog sustava korak po korak. Za potrebe rada razvijeni su akustički modeli hrvatskog jezika, te su primijenjeni na treniranje sustava. Pored akustičkih modela konstruirana je i pripadajuća gramatika kao i pripadajući rječnik transkripcija. U konačnici sustav je utreniran sa modelima proizašlim iz stvarnih rečenica ovog zadatka koje su definirane pripadnom gramatikom, te je obavljena analiza rezultata u kojoj se evaluira da li je sustav postigao zadovoljavajuću točnost za dotičnu primjenu.

Ključne riječi:

- Automatsko prepoznavanje govora
- HTK (*eng.HMM ToolKit*)
- Markovljevi modeli
- Matični broj
- Transkripcije
- Akustički modeli
- Gramatika
- Monofoni
- Trifoni
- Automatizacija
- Treniranje
- Test
- Estimacija
- HParse
- HDMan
- HSGen
- HLEd
- HCopy
- HCopmV
- HHEd
- HERest
- HVite

12 Abstract

12.1 System for automatic identification of pronunciation of students' identification number

Final paper is about building-out a system for automatic identification of pronunciation of students' identification number. HMM Toolkit is used as a basis for the system for which certain programme adjustments are developed, according to induced purpose. The paper explains theoretical fundamentals and working principles of the system based on Markov's models, as well as building the system step by step. For paper purposes, acoustic models of Croatian language are developed and applied on training of the system. Apart from acoustic models a related grammar is constructed, as well as related transcription dictionary. Finally, the system is trained with the models that came out from the real sentences of this task, which are defined by pertaining grammar, and the result analysis, where is evaluated whether the system has obtained the satisfying precision for induced purpose, is issued.

Key words:

- Automatic identification of pronunciation
- HMM ToolKit
- Markovljev's models
- Identification number
- Transcriptions
- Acoustic models
- Grammar
- Monophones
- Triphones
- Automatization
- Training
- Test
- Estimation
- HParse
- HDMan
- HSGen
- HLEd
- HCopy
- HCopmV
- HHEd
- HERest
- HVite

13 Privitak

13.1 Privitak -trainprompts.txt

S0001 AJDE IDEMO DA KARTAMO UPORAN JE BIO KISX
S0002 GOSPODINE GABRIELE OVAKO GLUP POTEZ OD VAS NISAM OCXEKIVAO S VISOKA JE
S0003 REKAO JOSIP PRATITE KARTE I UZ MALO MATEMATIKE
S0004 CXUJTE GOSPODINE PROGANJANI OVDJE SMO RADJ ZABAVE I DRUZHENJA
S0005 NE IGRAMO ZA NOBELOVU NAGRADU PJENIO SE BRANIMIR PA NEKI SU JE DOBILI
S0006 ODVRACYA JOSIP
S0007 MA IDI CXOVECXE GLEDAJ KARTE I CUCLAJ TONIK REZIGNIRANO SE UMIJESXAO KISX
S0008 DIJELILE SU SE KARTE A SRECYA JE BILA PROMJENJIVA
S0009 MLADICYI VRIJEME JE ZA KAVU MADAM MOLIM VAS
S0010 NIJE GA CXULA MADAM DREKNUO JE STARI DOBRI NO ZAJEDLJIVI KNUT JOSX PET KAVA
S0011 HVALA JA BIH RADJE KONJACXICY ZAMOLI DANILU I JA KAZAH
S0012 KNUT HAMSUN JE DEFINITIVNO PIO PREVISXE KAVE I STALNO KUKAO O MALIM
S0013 HONORARIMA NECYEMO O NOVCU ZAMOLI JOSIP A O CXEMU CYEMO
S0014 O LOSXOJ PROBAVI REUMI BOLU U LEDYIMA TERAPIJAMA ZXENAMA
S0015 OVO ZADNJE NAKESI SE OPSTIPACIJA INSOMNIJA
S0016 ZANIMLIVE RIJECXI ZA NESRANJE I NESPAVANJE DODA KNUT KISX PREVRNE OCXIMA
S0017 IDEMO PISXATI KAKVA CXAST KISX I JA IDEMO PISXATI
S0018 TO JE BILO PRVI PUT DA SAM BIO NASAMO S VELIKIM JUZNOSLAVENSKIM PISCSEM
S0019 UF KONACXNO PRICXAMO PO NASXEM RAZUMIYESX VRIJEME JE DA SE NESXTO POJEDE
S0020 NISAM OKA SKLOPIO SINOCY A I NOCYAS CYE BITI JEBENO
S0021 DA STVARNO JE VRIJEME ZA VECXERU
S0022 VALJDA STARI NECYE ZAPETI ZA HAMBURGER KAO ONAJ PUT
S0023 MA TI SKANDINAVCI UVIEK NESXTO POLUHLADNO I BRZO MI SMO ZA NJIH KULTURA
S0024 TAKVE SU IM I ZXENE JEDNOM SEDMICXNO ILI MJSESECXNO UVRH GLAVE
S0025 TAKVI SU KAD ZXIVE BLIZU SANTI LEDA GOSPODINU HAMSUNU SE SIGURNO SXTUCA
S0026 PISXALI SMO DUGO DOK PLAVU BOJU DEZINFEXCIJSKOG SREDSTVA U PISOARIMA NISMO
S0027 PRETVORILI U ZELENU
S0028 POKUSXAO SAM PROCXITATI ZXIG NA KERAMICI KAKO BIH SAZNAO TKO JE
S0029 PROIZVODYACX TIH PISOARA NO NIJE MI USPJELO
S0030 UTVRDYIVANJE PORIJEKLA PISOARA POSTAO JE MOJ TAJNI HOBI ONOGA DANA KADA
S0031 SAM SHVATIO DA SU SVI PISOARI U JEDNOJ ZEMLJI KOJA VISXE NE POSTOJI
S0032 PROIZVEDENI U KERAMICI MLADEVAC MOZXA JE ZATO ZEMLJA I PROPALA
S0033 IDEMO ZA STOL TROJKA ZA STOLOM SLATKO SE SMIJALA
S0034 MIRKO JE PRICXAO VICEVE O INDIJSKIM DJEVICAMA EGZOTIKA
S0035 OZBILINO JE SHVATIO DA TREBA PRICXATI O ZXENAMA
S0036 HOCYEMO LI U SALU PREKO DA PORUCXIMO NEKO JELO
S0037 UMIREM OD GLADI DODAO JE KISX
S0038 ALKOHOL JE KALORICXAN NE MORAMO JOSX I JESTI KROZ SMIJEH IZUSTI JASENKO
S0039 NO DAJTE I MENI DUPLI RUM ORASPOLOZXI SE JOSIP A VJERA PITA KNUT
S0040 VJERA U SEBE A DRUGE KAO JEBE GOSPODICXNA MENI PIVCE DANSKO
S0041 POJMA VI NEMATE GOSPODINE KNUT
S0042 PA CXESXKO PIVO JE BAREM TRI PUTA BOLJE OD DANSKOG DODA KISX
S0043 MA SXTO TI ZNASX
S0044 STALNO PIJESX KONJAKE I VINO A PRODAJESX SE ZA EKSPERTA ZA PIVO
S0045 KAKAV SI TI STRUCXNJAK ZA PIVO KAO I TVOJE PREZIME MALI
S0046 VIDI MALOG DUHOVIT JE NASMIJE SE STARI JARAC SXTO NECYEMO VECXERATI
S0047 UPORAN JE BIO DANILU KISX MOGLI BI ONU HRENOVKA U TIJESTU
S0048 NE SAMO TO NE ZAVAPILI SU REDOM KISX I JOSIP
S0049 KAKO SAM BIO TEK RELATIVNO FRISXKO MRTAV NISAM IMAO PRAVO POLEMIZIRATI O
S0050 NICXEMU
S0051 PO DEFINICIJI FRISXKO MRTAV PISAC JE ONAJ KOJI JE MRTAV MANJE OD PEDESET
S0052 GODINA A SXTO ZNACXI DA SE ZA NJEGOVA DJELA JOSX UVIEK PLACYAJU AUTORSKA
S0053 PRAVA MLINAREC SXTO SI TAKO TIH NISAM CXUO DA SI ZVAO RUNDU VECXERAS
S0054 PREKORI ME LOSOS
S0055 KISX MI SXAPNE ISPOD GLASA NECYEMO DA BUDEMO PIZDE I DA SAMI JEDEMO

S0056 ZABORAVIMO HRANU VECXERAS OVI SU SE VECY OBLILI
S0057 DRAGA GOSPODO SVECXANO JE ZAPOCXEO KNUT HAMSUN SADA CYEMO POPITI PO PICYE
S0058 NA MOJ RACXUN I HEJ PROGONjeni SXTO CYESX TI PIVO CXESXKO TAKO TREBA
S0059 KLIKNUO JE DANilo I NARUCXIO ZA SEBE BOCU NEKOG FRANCUSKOG VINA
S0060 JA CYU RUM MRMLIAO JE ARKANDYE ZAR I TI SINE GABRIJELE
S0061 ZACXUDI SE KNUT KOJI JE MLATIO RUM DUPLICYE
S0062 DAJTE MLINCU ZLATOROG ISPRAVI SE PROGONjeni
S0063 GOSPODINE JOSIP ZAR VAS NIJE SRAMOTA OBRATITI MI SE KAO STARIJEM KOLEGI S
S0064 TAKVIM GADOSTIMA OTKUD VAM IDEJA DA SAM JA PONAVLIJAM JA PUSTIO VJETAR
S0065 MI EUROPEJCI SMO IPAK CIVILIZIRANI CXEKAJTE MALO SAMO MALO
S0066 HOCYETE RECYI DA SMO MI OSTALI RECIMO JUZNOAMERICXKI KATOLICI DIVLJACI
S0067 PODIGAO JE GLAS JASENKO TO SU VASXE RIJECXI GOSPODINE BRANIMIR
S0068 JA ONO SXTO MISLIM GLASNO I KAZXEM
S0069 VI GOSPODINE KISX IMATE NESXTO ZA PRIMIJETITI MUCAO JE BRANIMIR
S0070 NE SAMO S KOLEGOM PRETRESAM SKRIVENA BOGATSTVA SLAVENSKIH JEZIKA
S0071 NE BISMO LI RADije ODIGRALI JOSX JEDNU PARTIJU KARATA NEG0 SXTO SE OVDJE
S0072 PREPIREMO MRMLIAO JE JOSIP SEBI U BRADU A NE NE MOZXE TO TAKO
S0073 TU STVAR MORAMO DO KRAJA RASXCXISTITI
S0074 KAO PRVO VI STE GOSPODINE BRANIMIR VISXE GODINA ZHIVJELI U SXVICARSKOJ PA
S0075 STE PREMA TOME EUROPEJAC KAO I GOSPODIN JOSIP KOJI JE SXKOLOVANJEM
S0076 NAVIKAMA I PO SVEMU OSTALOM ENGLEZ
S0077 NJIHOVA VEZA TRAJALA JE TOCINO KOLIKO I DOGRADNJA KUCYE
S0078 VANI KISX NE PRESTAJE U SOBI OSIM KRONIKE SMRTI SVE JE NA SVOME MJESTU
S0079 DAVOR JE OTVARA OKRECYE NA POSLJEDNJU NEISPISANU STRANICU I UZIMA OLOVKU
S0080 UPISUJE SVE SXTO JE IZ TUDYIH USTA SAZNAO O IVANU
S0081 HOCYU LI SRESTI SONJU NIKOLU ILI MARIJU MOZXA IVANA NEMA DOBRIH VIJESTI
S0082 DAVOR SJEDI I ZAPISUJE TISXINU TJSKOBA RUB NOCYI KRAJ JESENI
S0083 KRAJ LJUBAVI ISTEK STOLJECYA KRAJ TISUCYLJECYA JESAM LI JA NA REDU
S0084 HOCYE LI OVA VODA VANi ODNIJETI TMURNE MISLI
S0085 TKO CYE OPISATI MOJU SMRT U KNJIZI
S0086 UVIEK OSTAJE NETKO TKO CYE POSVJEDOCXITI O NASXOJ SMRTI
S0087 NASXLI SMO SE TOG PETKA POSLIJEPODNE U TIHOM SALONU RESTORANA PURGATORIUM
S0088 NA PARTIJI BRIDZXA
S0089 NARAVNO SVI ODAVNO I POKOJN I SPOKOJN IZGLEDALI SMO BASX KAO NA
S0090 OMOTNICAMA NASXIH KNJIGA U NAJBOLJIM DANIMA
S0091 BIO SAM NAJMLADYI U DRUSXTVU TAKO DA JE MOJA DUZXNOST BILA STAROM HAMSUNU
S0092 POMOCYI ODLOZXITI KAPUT SXESXIR I KISXOBRAU U GARDEROBU
S0093 JOSIP JE VECY ZAUZEVO SVOJE MJESTO ZA VELIKIM OKRUGLIM STOLOM A BRANIMIR I
S0094 KISX SU PO OBICXAJU PRVO POPILI PO KONJAK ZA SXANKOM
S0095 NO HAJDE JESMO LI DOSXLI LOKATI ILI SE DRUZXITI
S0096 POZXRIVAO JE NESTRPLJIVI STARAC
S0097 DAJTE NAM JOSX RUNDU ZA STOL DOBACI BRANIMIR KRECYUCYI SE PREMA STOLU
S0098 MENI MOLIM TONIK RECXE JOSIP I KAVU ZA GOSPODINA HAMSUNA
S0099 SA SAHARINOM I DVije KAPI MILJEKA MOZXE I VASXEG FRKNUO JE STARAC BRKOM NA
S0100 SISATU KONOBARICU I DODAO ISPOD GLASA DOBRA GUZA NE
S0101 I PIVO ZA MALOG MLINARCA GOSPODINE KISX HOCYEMO LI POCXETI PITAO JE JOSIP
S0102 MLINAREC IMATE LI PAPIR DA SVE JE POD KONTROLOM UZVRATIO SAM
S0103 ISCRTAVAO SAM TABLICE U KOJE CYU UPISIVATI REZULTATE
S0104 KISX JE POSLJEDNI SJEO ZA STOL I ZASUKAO RUKAVE KAO DA GA CXEKA TEZXAK
S0105 FIZICXKI RAD ZAPALIO JE CIGARETU I S OLAKSXANJEM OTPUHNUO DIM
S0106 KONOBARICA JE DONIJELA PICYE PRVI JE DIJELIO JOSIP
S0107 NJEGOVI NJEGOVANI PRSTI NJEZXNO SU DOTICALI KARTE NARAVNO NOVOOTVORENI
S0108 SXPIL DA SVE BUDE NA NIVOU PRIJE NEGOLI BI OVE PADALE NA STOL PRED IGRACXE
S0109 NASTAO JE TAJAC
S0110 BRANIMIR SE MRSXTIO NA SVOJE KARTE A NEZAPALJENU CIGARU VECY JE NEKO
S0111 VRIJEME PREBACIVAO IZ KUTA U KUT USANA
S0112 HAMSUN JE PODIZAO I SPUSXTAO LIJEVU OBRVU I UVIIAO SUPROTNI BRK
S0113 KISX JE PREKO RAMENA ZAGLEDAO KONOBARICU KOJA SE SAGINJALA A CXIJE SU
S0114 OBLINE ZXELJELE ISKOCXITI IZ ZATEGNUTE UNIFORME
S0115 JA SAM KAO PISAR CRTAO CVJETICYE PO RUBU PAPIRA
S0116 SLABO SAM KARTAO A I TEK SAM NEDAVNO POCXEO PISATI PARTIJE
S0117 SLUSXAJTE GOSPODINE BRANIMIRE NEMAMO STO GODINA DA BISMO DOCXEKALI VASX

S0118 POTEZ DANAS NE PISXEMO ROMANE VECY KARTAMO
S0119 DA DA SAD CYU MRMLJAO JE KOLUMBIJAC IGRA JE NAPREDOVALA
S0120 KAKO SAM JOSX NEVJESXT S KARTAMA VISXE SAM PAZXNE OBRACYAO NA RAZGOVOR
S0121 LJUDI OD PISACYEG STROJA NEGO NA NJIHOVE KARTASXKE POTEZE
S0122 SALMANE ZNATE LI DA SAM VIDIO JEDAN NJEMACXKI CXASOPIS GDJE SU VAS
S0123 GRESXKOM GRAFICXKOG UREDNIKA U NASLOVU PREKRSTILI U SALMONA
S0124 NO BOLJE JE BITI I LOSOS NEGO SALMONELA ZAR NE HA HA HA
S0125 JEDINO SE STARIS HAMSUN SMJAO SVOJOJ SXALI
S0126 GOSPODINE KNUTE KAKO VASXI HEMEROIDI KRVARE ULJUDNO JE UZVRATIO JOSIP
S0127 STARIS JE UTRNUO OSMIJEH DA NIJE LAKO NAPISATI PEDESET I DVA TRI ROMANA
S0128 JE LI IH BILO STVARNO TOLIKO ILI SU TU I NEKA PONOVLJENA IZDANJA
S0129 PITAO JE BRANIMIR
S0130 GOSPODINE GABRIEL ILI ZXELIKO SVEJEDNO PRAVILA DOBROG PONASXANJA NALAZXU
S0131 AKO SE DOISTA NAMJERAVATE DRUZXITI S NEKIM A POGOTOVO S KOLEGAMA PISCIMA
S0132 DA BAREM ZNATE SXTO SU I KOLIKO TOGA NAPISALI
S0133 SADA STE IPAK U EUROPI A NE U VASXOJ TEKILA GERILA BANANA KOKAIN ZEMLJI
S0134 JURIJ JE U NJIHOVU MALOM KRUXOKU ZASTUPAO MISAO DA CYE RUSKA KULTURA
S0135 JEDNOGA DANA PRESTATI S USTUPCIMA SISTEMU KOJI JE OD NJIH AKADEMSKIH
S0136 UMJETNIKA NAPRAVIO PISMOSLIKARE I PORTRETISTE POLITICXARA
S0137 JURIJ NE BUDI NAIVAN A SXSPANJOLSKI I TALIJANSKI MAJSTORI
S0138 PA SVI SU ONI RADILI I BILI PLACYENI OD VLASTODRZXACA
S0139 ONI KOJI NISU TAKO RADILI NJIH POVJEST NIJE NITI ZABILJEZILA
S0140 MOLIM TE SJETI SE SAMO LUPINA UPOZORAVALA JE TATJANA MOZXDA IMASX PRAVO
S0141 ALI ONI SU BAREM MOGLI PUTOVATI BILI SU SLOBODNI
S0142 SXTO JE UMJETNIKU TEZXE TO BOLJE ZA UMJETNOST DOCYI CYE I NASXE VRIJEME
S0143 JURIJ SE TOG POSLIJEPODNEVA VRATIO KUCYI I ZATEKAO PORUKU ZATAKNUTU NA
S0144 ULAZNIM VRATA
S0145 U NJEMU JE SXTURIM SLUZXBENIM TONOM STAJALO DRUG UMJETNIK JURIJ IVANOVICX
S0146 GERAŠIMOV NEKA SE JAVI U NARODNU GALERIJU U LENJINGRADU DANA TOG I TOG U
S0147 DEVET SATI SOCIJALISTICXKI POZDRAV DRUG LEVINSKI PA TO JE SUTRA
S0148 POMISLI JURIJ SXTO CYU ODJENUTI
S0149 MORAM NAZVATI STIPU DA MI HITNO VRTI BIJELU KOSXULU
S0150 TE JE VECXERI JURIJ IVANOVICX GERAŠIMOV LEGAO RANO
S0151 SAN MU NIJE DOLAZIO NA OCXI
S0152 SUTRA NIJE SMIO ZAKASNITI A UJUTRO PRIJE POLASKA TREBAO JE JOSX POSUDITI
S0153 RUBALI ZA POVRATNU KARTU DO GALERIJE I DORUCXAK DOBRO JUTRO JA SAM
S0154 ZNAM DRUG JURIJ IVANOVICX GERAŠIMOV SJEDNITE JA SAM LEVINSKI
S0155 DAKLE VIDITE JA VECY TRI CXETIRI GODINE PRATIM VASX RAD DAKLE PET SKUPNIH
S0156 I DVJIE SAMOSTALNE IZLOZBE I MISLIM DA CYE NASXA GALERIJA U NAJSKORIJE
S0157 VRIJEME OTKUPITI OSIM AKO JOJ U MEDYUVREMENU NE ZXELITE DAROVATI NEKA
S0158 VASXA DJELA
S0159 RADI SE O NEKOLIKO ULJA I JEDNOJ SKULPTURI ZA KOJE DRZXIM DA SU JEDINSTVENI
S0160 OSIM TOGA NASXA CYE GALERIJA NA JESEN GOSTOVATI U RIMU A POTOM I U TORINU
S0161 I VENECIJI A DVOJICA UMJETNIKA BIT CYE I U SASTAVU NASXE SXESTEROCXLANE
S0162 DELEGACIJE JURIJU NAJEDNOM PROSTRUJI MISLIMA MOGAO BIH VIDJETI ITALIJU
S0163 ZNATE DRUZXE LEVINSKI JA SAM SE SPREMAN ODRECYI NEKIH SVOJIH DJELA U
S0164 KORIST NASXE NARODNE GALERIJE
S0165 MOZXDA JEDINO KAKO NEMAM DRUGOG ZAPOSLENJA DA MI SE ODOBRI NEKA MANJA
S0166 SVOTA ZA NABAVKU UMJETNICXKIH POTREPSXTINA
S0167 PLATNA LANENO ULJE TERPENTIN NESXTO BOJA I MOZXDA KOJI ARAK GRAFICXKOG
S0168 PAPIRA MUCAO JE JURIJ NARAVNO NARAVNO
S0169 IZVOLITE UZMITE KARTON ZA NABAVU I ZAPISXITE SVE SXTO VAM TREBA OD
S0170 UMJETNICXKOG MATERIJALA SVE CYEMO DOPREMITI U ATELIJER
S0171 A ISPLATIT CYEMO VAM U RACXUNOVODSTVU I TRISTO RUBALJA NA IME AKONTACIJE
S0172 ZA ZXIVOTNE TROSXKOYE IDUCYIH SXEST MJESECI HALUCINIRAM LI
S0173 POMISLI JURIJ TE SE PRIHVATI OLOVKE I POCXNE ISPUNJAVATI NABAVNI KARTON
S0174 ZA TO VRIJEME LEVINSKI JE ISPISIVAO CEDULJU NA KOJOJ JE STAJALO DA SE
S0175 DRUGU JURIJU NA IME AKONTACIJE ZA ZXIVOTNE TROSXKOYE IMA ISPLATITI U
S0176 GOTOVU NOVCU TRISTO RUBALJA
S0177 DRUG UPRAVITELJ GALERIJE LEVINSKI POTOM JE NAZVAO RACXUNOVODSTVO I USMENO
S0178 POTVRDIO DA JE DAN NALOG ZA ISPLATU
S0179 BILO MI JE DRAGO DRUZXE GERAŠIMOV OTRPRATIO JE LEVINSKI JURIJA DO IZLAZA I

S0180 NADAM SE DA CYE NASXA UMJETNOST KONACXNO ZAUZETI MJESTO KOJE JOJ PRIPADA U
S0181 SVJETSKIM RAZMJERIMA
S0182 BASX ME BRIGA POMISLI JURIJ DOBIO SAM NOVAC I NOVI MATERIJAL
S0183 A MOZXDA ITALIJA ZBOGOM BIJEDO
S0184 PRVO JE JURIJ ODJURIO U TRGOVINU U BLIZINI SVOJE KUCYE
S0185 IAKO IZBOR PROIZVODA NIJE BIO VELIK GURAO JE U KOSXARU SVE SXTO BI DOHVATIO
S0186 CIJENE UOPCYE NIJE GLEDAO SAMO JE TOVARIO
S0187 PRED TRGOVINOM JE POZVAO TAKSI KAKO BI SVE TE STVARI ODVEZAO KUCYI
S0188 POKUCAO JE DOBROJ BABUSXKI PREKO PUTA SPUSTIO JOJ U PREDSOBLJE KARTON PUN
S0189 RAZNIH NAMIRNICA I ZAMOLIO JE DA MU OCXISTI ATELIER
S0190 NO JURIJ SXTO SE DOGODILO BAKO POSTAO SAM POZNAT SLIKAR
S0191 NARODNA GALERIJA CYE IZLOZXTI VISXE MOJIH RADOVA A MOZXDA CYU I PUTOVATI
S0192 EVO GA JURIJ LIJUDI POMOCY VRISXTALA JE TATJANA
S0193 JURIJ JE LEZXAO NA LEDYIMA ISPRUZHEN I POMALO PLAVICXAST U LICU
S0194 NIJE SE MICAO HITNA ZOVITE HITNU DRUSXTO SE SJURILO NA MEDYUKAT
S0195 BULJILI SU U UKOCXENO JURIJEVO TIJELO I CZEKALI KOLA PRVE POMOCYI
S0196 IGOR JE SISXAO PRED ZGRADU KAKO BI SXTO BRZXE UPUTIO LIJECXNIKE NA PRAVO
S0197 MJESTO
S0198 ZA DESETAK MINUTA JURIJ IVANOVICX Gerasimov unezen je u AMBULANTNA KOLA
S0199 KOJA SU ZAVIJACYI PARALA PROLJETNU LENJINGRADSKU NOCY
S0200 DOKTOR MILIVOJ POPRAVLJAO JE KRAVATU I POSLJEDNJI SE PUT POGLEDALO U
S0201 OGLEDALO U PREDVORJU PRIJE NEGO JE IZASXAO IZ KUCYE
S0202 TA JE VECXER BILA OSOBITO VAZXNA U NJEGOVOM ZXIVOTU
S0203 BIO JE POCXASNI GOST LIJECXNICXKOGA KONGRESA U ZAGREBU
S0204 KAKO JE PO PRIRODI BIO VRLO PEDANTAN ZNAO JE DA MU DO CENTRA GRADA TREBA
S0205 TOCXNO DVADESET I PET MINUTA VOZXNJE AUTOMOBILOM URACXUNAVSXI I
S0206 UOBICXAJENU POSLIJEPODNEVNU GUZXVU NA CESTI
S0207 SJEU JE U NOVI AUTOMOBIL I KRENUO PREMA ODREDISXTU
S0208 MARKO JE NA KONGRESU TREBAO ODRZXATI DUZXE PREDAVANJE O PROJEKTU KOJI JE
S0209 VODIO SA SKUPINOM KOLEGA POSLJEDNJE DVije GODINE
S0210 BIO JE JEDAN OD NAJPERSPEKTIVNIJIH OKULISTA NOVOG ZELANDA A CXESTO JE
S0211 PUTOVAO U KINU I JAPAN
S0212 ODMAH NA ULAZU U CENTAR DOCXEKAQ GA JE KOLEGA IZ ISTRAZXIVACXKOG TIMA S
S0213 LOSXIM VIJESTIMA
S0214 MARKO UPRAVO SU JAVILI DA JE NORA IMALA SAOBRACYAJNU NESRECYU
S0215 NISXTA STRASXNO ALI NEMAMO PODATKE O NJEZINOM DIJELU LABORATORIJSKIH
S0216 ISTRAZXIVANJA SXTO CYEMO SADA UPITAO JE
S0217 MOZXEMO OGDODITI NASXE PREDAVANJE ZA SAT VREMENA USTVARI ODRZXATI GA
S0218 POSLJE PAUZE TAKO BI IMALI VREMENA DOCYI DO NORINIH MAPA PREDLAGAO JE
S0219 JOZXA MISLIM DA JE U TOM SLUXAJU NAJBOLJE DA U PAUZI ODEM SVOJOJ KUCYI PO
S0220 KOPIE REZULTATA KAZAO JE IGOR U REDU KRENIMO SADA U DVORANU
S0221 NIJEMCI SAMO SXTO NISU ZAPOXELI SVOJE PREDAVANJE
S0222 USXLI SU U PROSTORIJI ISPUNJENU DO POSLJEDNJEGA MJESTA
S0223 MARKO JE SA SMIESXKOM OTPOZDRAVLJAO KOLEGAMA CIJELO VRJEME ZAPRAVO
S0224 MISLEYI HOCYE LI SE NA VRJEME STICYI VRATITI S KOPIJAMA NJIHOVIH
S0225 POSLJEDNJIH LABORATORIJSKIH OTKRICYA
S0226 NAKON NIJEMACA ZA KATEDRU SU IZASXLI AUSTRALIJANCI A POTOM POLJACI
S0227 NAPUSTIO JE DVORANU PRIJE NEGO SU ZAVRSXILI IZLAGANJA I ZXURNO SE UPUTIO K
S0228 PARKIRALISXTU VOZIO JE MNOGO BRZXE NEGO OBICXNO
S0229 ZXALIO JE SXTO CYE PROPUSTITI NAZANIMLJIVIJI DIO SVIH LIJECXNICXKIH
S0230 KONGRESA ONAJ NEFORMALNI S KOKTELOM I ZAKUSKOM
S0231 NO IPAK SE OSJECYAO DUZXNIM KAO PRVI CXOVJEK TIMA PREDSTAVITI CJELOKUPAN
S0232 DVOGODISXNJI RAD O MIKROKIRURGIJI ZJENICE
S0233 ZASXTO NISAM ODMAH PONIO SVU DOKUMENTACIJU
S0234 ALI TKO BI MOGAO ZNATI DA CYE NORA STRADATI SAMO SAT VREMENA PRIJE KONGRESA
S0235 MISLIO JE MARKO UKLJUCXIO JE VIJESTI NA RADIJU
S0236 MUCXILA GA JE NESANICA POSLJEDNJIH GODINA
S0237 USTVARI NIJE NAJVAZXNIJA BILA NEMOGUCYNOST DA SE USNE VECY POTPUNO
S0238 ODSUSTVO SNOVA
S0239 OTKAD JE PRESTAO VIDYATI SONJU A IMA TOME SEDAM GODINA GOTODO UOPCYE NIJE
S0240 SANJAO
S0241 IZLAZIO JE U MEDYUVREMENU S VISXE ZXENA ALI SVE TE NAZOVI VEZE VRLO SU

S0242 BRZO ZAVRSXAVALE
S0243 OSTALO BI SVE NA PONEKOJ VECXERI TELEFONSKOM RAZGOVORU SEKSU A S NEKIM
S0244 ZXENAMA CXAK NIJE IMAO POTREBE PODIJELITI NOCY
S0245 TRUDI SE CXINI TO STALNO OVLADATI SVOJOM SAMOCYOM ALI SVJESTAN JE DA MU TO
S0246 NE USPIJEVA NIJE ZXALIO ZA PROSXLOSXYU ALI CXESTO BI MISLIO O SONJI
S0247 SADA MU SE NJIHOVA VEZA CXINILA MNOGO SUVISLIJOM NEGO TADA DOK SU BILI
S0248 ZAJEDNO KADA JE ZXELIO BITI JEDINI GOSPODAR I VLASNIK SVOGA VREMENA
S0249 POSLJE DVA SATA PO PONOCYI TIJEK VREMENA SE USPORAVA
S0250 KRENUO JE PREMA VELIKOJ POLICI S KNJIGAMA I NEGDJE SA SAMOG DNA IZVUKAO
S0251 RUCXNO UVEZANU KRONIKU SMRTI NIKOLE
S0252 SXTO GA JE NATJERALO DA BASX SADA NA RAZMEDYU NOCY I DANA IZVUCXE OMANJU
S0253 KNJIGU KAKVIH NA SVIJETU IMA TOCXNO PET OTISNUTIH AUTOROVOM RUKOM NA
S0254 PISACYEM STROJU
S0255 LOSXE OTISNUTO MALO SLOVO SX POSLJEDICA JE LOSXEG STROJA NA KOJEM JE
S0256 TIPKAO NIKOLA RIJETKO MIRAN I SUZDRZXAN DALMATINAC
S0257 TIJEKOM STUDIJA BIO JE DAVOROV NAJBOLJI PRIJATELJ I INTENZIVNI
S0258 PROUCXAVATELJ ZXIVOTOPISA POZNATIH OSOBA KOJI SU SVOJE ZXIVOTE SKONCXALI
S0259 SAMOUBOJSTVIMA POMALO CXUDNA OPSESIJA ILI HOBI ZA STUDENTA ARHITEKTURE
S0260 KRONIKA SMRTI NASTAJALA JE PUNIH PET GODINA
S0261 DAVOR KOJI JE BIO UPUCYEN U SVE NJENE DETALJE I FINESE DOZXIVIO JU JE KAO
S0262 VRHUNAC SVIH RAZGOVORA BILJESXKI UVIDA U ARHIVE PARALELNOG STUDIJA NA
S0263 KOJEM JE NIKOLA BIO JEDINI STUDENT I PROFESOR
S0264 MNOGE SU RECXENICE OSTALE LEBDJETI U ZRAKU IZMEDYU NJIH DVOJICE I NEKA
S0265 PRISNOST KOJU BI OSJETIO SVAKI PUT KADA BI DOTAKAO NJEZINE KORICE
S0266 SXTO LI JE SINOCY RADIO NIKOLA
S0267 LISTAO JE KNJIGU POLAKO MILUJUCYI BIJELI GRUBI PAPIR
S0268 VANI SU NALETI KISXE NOSXENI VJETROM BIVALI SVE JACKI
S0269 NA TRECYOJ STRANICI POSVETA TAMNOZELENOM TINTOM DAVORU VESELOM TRAGACXU ZA
S0270 SMISLOM ZAR JE VECY PROSXLO OSAMNAEST GODINA
S0271 POMALO ZABORAVLJENA POSVETA POKRENULA JE BUJICU SJECYANJA
S0272 LIJEPOM SE SAD UCXINILA DAVORU IZVJESNOST PROSXLO
S0273 STUDENTSKI DANI IZLASCI PETKOM I SUBOTOM DJEVOJKJE NEDJELJE NA SLJEMENU ILI
S0274 U SAMOBORU LUTANJA GRADOM ZAJEDNICXKO PRIPREMANJE ISPITA SKIJANJA U
S0275 SLOVENIJI LIETOVANJA U KUCYI NIKOLINIH NA MLJETU OPIJANJA S IVANOM U
S0276 NJEGOVOJ PODRUMSKOJ PODSTANARSKOJ SOBI KOTRLJANJE SPACXEKOM PO FRANCUSKOJ
S0277 I ITALIJI ODVRATIO JE POGLED S KNJIGE NA STAKLENI ORMARICY
S0278 SKULPTURA LJUBAVNIKA PRVA IZ SERIJE KOJU JE IVAN USPIO ODLITI PO
S0279 ZAVRSXETKU AKADEMIJE STAJALA JE NA SVOME MJESTU U POLUMRAKU VALIDA DA NE
S0280 UZNEMIRI ZAGRJENE U BRONCI
S0281 A TKO BI JE I MICAOD KAD JE DAVOR OD PREUDAJE MAJKE ZXIVIO SAM U STANU
S0282 DUGO NIJE OBRACYAO PAZXNUJ NA SKULPTURU A JOSX SE RJEDYE PRISJECYAO KAKO
S0283 JE STVARNO IZGLEDAO IVAN
S0284 VIDYAO BI GA NEKAD KAO I SVOG PREMINULOG DJEDA KOJI GA JE CXUVAO DOK JE
S0285 BIO SASVIM MALEN I KOJEG SLABO PAMTI JER JE OVAJ UMRO DAVNO KAKO HODA
S0286 ZRINJEVCEM CVJETNIM TRGOM ILI KAKO U VINODOLU ISPija TKO ZNA KOJI PO REDU
S0287 GEMISXT
S0288 NO UVIJEK BI SE TRGNUO I SHVATIO DA SU TO IPAK NEKI NOVI DRUGI LIUDI KOJI
S0289 SU SAMO PREUZELI ULOGE NAMA POZNATIH POKOJNIKA
S0290 JER SVIJET TAKO ODUVIJEK FUNKCIONIRA JEDNI ODLAZE DRUGI DOLAZE
S0291 BASX TOG DANA KADA JE IVAN SMRTNO STRADAO PRIJE NEKOLIKO GODINA DAVORA JE
S0292 ZBOG POSLA NAZVALA MARIJA VELIKA IVANOVA LIJUBAV I NESRECYA NJIHOVA
S0293 ZAJEDNICXKA DRUZICA IZ STUDENTSKIH DANA
S0294 ZNASX DAVORE ISKOPALA SAM TVOJ BROJ NIJE TE BILO LAKO NACYI DOGRADILI BI
S0295 NASXU KUCYU NA MLINOVIMA PA AKO BI TI IMAO VREMENA DA NAPRAVISX PROJEKT
S0296 NARAVNO DOBRO BI TI PLATILI KESX
S0297 A I NE MORA BITI ODMAH IONAKO NECYEMO GRADITI PRIJE LJETA MI NA MORE
S0298 MAJSTORI U KUCYU SAMO DA ZNAM MOZXEMO LI RACXUNATI NA TEBE ILI PRISTAO JE
S0299 KADA SAM JE ZADNJI PUT VIDIO
S0300 KOPKALO GA JE KAKO MARIJA SADA IZGLEDA I HOCYE LI UOPCYE OSIM ARHITEKTURE

13.2 Privitak trainprompts.txt/testprompts.txt-trening rečenice ciljane namjene

T0001 MATICXNI BROJ NULA NULA TRI SXEST PET OSAM TRI PET SEDAM PET OCJENA IZVRSTAN BROJ BODOVA DVADESET CXETIRI CIJELIH TRINAEST BROJ ZADATAKA TRINAEST ZADACI DVA SLJEDECYI SEDAM SLJEDECYI KRAJ
T0002 MATICXNI BROJ NULA NULA TRI SXEST SXEST SEDAM SXEST SXEST TRI SXEST OCJENA VRLO DOBAR BROJ BODOVA OSAMNAEST CIJELO DEVET BROJ ZADATAKA TRINAEST ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0003 MATICXNI BROJ NULA NULA TRI SXEST NULA TRI DEVET NULA PET OSAM OCJENA NEDOVOLJAN BROJ BODOVA SEDAM CIJELIH CXETIRI BROJ ZADATAKA TRINAEST ZADACI CXETIRI SLJEDECYI PET SLJEDECYI KRAJ
T0004 MATICXNI BROJ NULA NULA TRI SXEST SEDAM NULA SXEST JEDAN SXEST DVA OCJENA DOBAR BROJ BODOVA CXETRNAEST CIJELO DEVEDESET DEVET BROJ ZADATAKA TRINAEST ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ
T0005 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI JEDAN TRI SEDAM PET OCJENA DOVOLJAN BROJ BODOVA DEVET CIJELIH SEDAMDESET SEDAM BROJ ZADATAKA OSAMNAEST ZADACI SEDAM SLJEDECYI DVA SLJEDECYI KRAJ
T0006 MATICXNI BROJ NULA NULA TRI SXEST TRI SEDAM DEVET SEDAM TRI SXEST OCJENA NEDOVOLJAN BROJ BODOVA SXEZDESET TRI CIJELIH DVADESET DEVET BROJ ZADATAKA OSAMNAEST ZADACI SEDAM SLJEDECYI DVA SLJEDECYI KRAJ
T0007 MATICXNI BROJ NULA NULA TRI SXEST SXEST NULA SEDAM TRI SEDAM PET OCJENA DOVOLJAN BROJ BODOVA DVADESET DEVET CIJELIH CXETRNAEST BROJ ZADATAKA OSAMNAEST ZADACI SEDAM SLJEDECYI DVA SLJEDECYI KRAJ
T0008 MATICXNI BROJ NULA NULA TRI SXEST JEDAN DEVET DVA PET JEDAN OSAM OCJENA VRLO DOBAR BROJ BODOVA DESET CIJELA DVADESET DEVET BROJ ZADATAKA OSAMNAEST ZADACI SEDAM SLJEDECYI DVA SLJEDECYI KRAJ
T0009 MATICXNI BROJ NULA NULA TRI SXEST SXEST SEDAM DEVET SEDAM TRI SXEST OCJENA IZVRSTAN BROJ BODOVA SXEZDESET DEVET CIJELO DESET BROJ ZADATAKA DESET ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ
T0010 MATICXNI BROJ NULA NULA TRI SXEST TRI SEDAM SXEST TRI OSAM PET OCJENA IZVRSTAN BROJ BODOVA PEDESET PET CIJELA TRIDESET DVA BROJ ZADATAKA DESET ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ
T0011 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI NULA TRI SEDAM SXEST OSAM OCJENA DOBAR BROJ BODOVA TRIDESET DVA CIJELO JEDANAEST BROJ ZADATAKA DESET ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ
T0012 MATICXNI BROJ NULA NULA TRI SXEST SXEST NULA NULA CXETIRI OSAM OCJENA DOBAR BROJ BODOVA SXEST CIJELIH CXETRNAEST BROJ ZADATAKA DESET ZADACI CXETIRI SLJEDECYI SXEST SLJEDECYI KRAJ
T0013 MATICXNI BROJ NULA NULA TRI SXEST SEDAM SXEST DVA JEDAN DEVET TRI OCJENA IZVRSTAN BROJ BODOVA SEDAMNAEST CIJELA PET BROJ ZADATAKA DESET ZADACI CXETIRI SLJEDECYI SXEST SLJEDECYI KRAJ
T0014 MATICXNI BROJ NULA NULA TRI SXEST DVA SEDAM PET OSAM TRI PET OCJENA VRLO DOBAR BROJ BODOVA JEDAN CIJELIH SXEZDESET OSAM BROJ ZADATAKA PET ZADACI CXETIRI SLJEDECYI SXEST SLJEDECYI KRAJ
T0015 MATICXNI BROJ NULA NULA TRI SXEST NULA JEDAN JEDAN CXETIRI NULA TRI OCJENA IZVRSTAN BROJ BODOVA SXEZDESET DVA CIJELO PET BROJ ZADATAKA PET ZADACI CXETIRI SLJEDECYI SXEST SLJEDECYI KRAJ
T0016 MATICXNI BROJ NULA NULA TRI SXEST OSAM OSAM DVA SEDAM DEVET OSAM OCJENA IZVRSTAN BROJ BODOVA PETNAEST CIJELO PET BROJ ZADATAKA PET ZADACI CXETIRI SLJEDECYI SXEST SLJEDECYI KRAJ
T0017 MATICXNI BROJ NULA NULA TRI SXEST TRI JEDAN NULA NULA CXETIRI OSAM OCJENA NEDOVOLJAN BROJ BODOVA DVANAEST CIJELA JEDANAEST BROJ ZADATAKA PET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0018 MATICXNI BROJ NULA NULA TRI SXEST PET SEDAM DEVET DVA PET JEDAN OCJENA VRLO DOBAR BROJ BODOVA CXETIRI CIJELA PETNAEST BROJ ZADATAKA PET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0019 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI SXEST PET JEDAN SEDAM DEVET OCJENA VRLO DOBAR BROJ BODOVA DEVETNAEST CIJELA SXESNAEST BROJ ZADATAKA PET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0020 MATICXNI BROJ NULA NULA TRI SXEST OSAM NULA JEDAN SEDAM SEDAM OSAM OCJENA VRLO DOBAR BROJ BODOVA DEVETNAEST CIJELIH SXEZDESET DEVET BROJ ZADATAKA PET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0021 MATICXNI BROJ NULA NULA TRI SXEST NULA SXEST SXEST DVA SEDAM OSAM OCJENA IZVRSTAN BROJ BODOVA DEVEDESET JEDAN CIJELIH SXEZDESET DEVET BROJ ZADATAKA DEVET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0022 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI TRI SXEST OSAM DEVET SXEST OCJENA IZVRSTAN BROJ BODOVA PETNAEST CIJELIH DEVEDESET SEDAM BROJ ZADATAKA DEVET ZADACI DVA SLJEDECYI PET SLJEDECYI KRAJ
T0023 MATICXNI BROJ NULA NULA TRI SXEST SXEST TRI JEDAN SEDAM NULA DEVET OCJENA IZVRSTAN BROJ BODOVA SXEST CIJELO DEVETNAEST BROJ ZADATAKA DEVET ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ
T0024 MATICXNI BROJ NULA NULA TRI SXEST JEDAN SXEST CXETIRI PET DVA DVA OCJENA DOBAR BROJ BODOVA PEDESET CXETIRI CIJELIH DVANAEST BROJ ZADATAKA DEVET ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ
T0025 MATICXNI BROJ NULA NULA TRI SXEST DVA OSAM DVA OSAM JEDAN SXEST OCJENA DOBAR BROJ BODOVA OSAM CIJELO DVA BROJ ZADATAKA DEVET ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ
T0026 MATICXNI BROJ NULA NULA TRI SXEST SXEST DVA TRI OSAM DEVET DVA OCJENA DOBAR BROJ BODOVA CXETRDESET SXEST CIJELA DVANAEST BROJ ZADATAKA DEVET ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ
T0027 MATICXNI BROJ NULA NULA TRI SXEST DEVET TRI SEDAM PET SEDAM NULA OCJENA DOBAR BROJ BODOVA CXETIRI CIJELO TRI BROJ ZADATAKA DEVET ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ
T0028 MATICXNI BROJ NULA NULA TRI SXEST OSAM SXEST PET DVA PET CXETIRI OCJENA VRLO DOBAR BROJ BODOVA PET CIJELO DEVETNAEST BROJ ZADATAKA DVA ZADACI PET SLJEDECYI PET SLJEDECYI KRAJ

T0029 MATICXNI BROJ NULA NULA TRI SXEST SEDAM PET DEVET TRI SEDAM SEDAM OCJENA VRLO DOBAR BROJ BODOVA DVANAEST CIJELA SXESNAEST BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0030 MATICXNI BROJ NULA NULA TRI SXEST JEDAN DEVET DVA OSAM TRI SXEST OCJENA VRLO DOBAR BROJ BODOVA JEDAN CIJELIH TRI BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0031 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI SEDAM OSAM DVA DEVET DEVET OCJENA VRLO DOBAR BROJ BODOVA OSAM CIJELO DESET BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0032 MATICXNI BROJ NULA NULA TRI SXEST DVA PET SXEST SEDAM OSAM SEDAM OCJENA IZVRSTAN BROJ BODOVA CXETIRI CIJELIH SXEST BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0033 MATICXNI BROJ NULA NULA TRI SXEST NULA DVA DEVET CXETIRI NULA CXETIRI OCJENA IZVRSTAN BROJ BODOVA OSAMDESET JEDAN CIJELO OSAMNAEST BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0034 MATICXNI BROJ NULA NULA TRI SXEST DEVET CXETIRI TRI DVA OSAM SEDAM OCJENA IZVRSTAN BROJ BODOVA SXESNAEST CIJELA OSAMNAEST BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0035 MATICXNI BROJ NULA NULA TRI SXEST DVA DEVET NULA TRI SXEST SEDAM OCJENA DOVOLJAN BROJ BODOVA CXETIRI CIJELIH SEDAMNAEST BROJ ZADATAKA DVA ZADACI SXEST SLJEDECYI PET SLJEDECYI KRAJ

T0036 MATICXNI BROJ NULA NULA TRI SXEST CXETIRI CXETIRI DEVET TRI TRI NULA OCJENA DOVOLJAN BROJ BODOVA DVA CIJELIH DEVETNAEST BROJ ZADATAKA PEDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0037 MATICXNI BROJ NULA NULA TRI SXEST DEVET DVA PET SXEST TRI PET OCJENA DOVOLJAN BROJ BODOVA CXETRNAEST CIJELO SEDAMNAEST BROJ ZADATAKA PEDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0038 MATICXNI BROJ NULA NULA TRI SXEST PET SXEST CXETIRI JEDAN SEDAM SEDAM OCJENA VRLO DOBAR BROJ BODOVA TRIDESET OSAM CIJELIH JEDANAEST BROJ ZADATAKA PEDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0039 MATICXNI BROJ NULA NULA TRI SXEST NULA DVA DVA SXEST DVA JEDAN OCJENA VRLO DOBAR BROJ BODOVA SXEZDESSET CXETIRI CIJELIH JEDANAEST BROJ ZADATAKA TRIDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0040 MATICXNI BROJ NULA NULA TRI SXEST DVA DVA NULA OSAM OSAM OCJENA VRLO DOBAR BROJ BODOVA SXEZDESSET DVA CIJELIH DVANAEST BROJ ZADATAKA TRIDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0041 MATICXNI BROJ NULA NULA TRI SXEST DEVET DEVET TRI PET JEDAN DVA OCJENA IZVRSTAN BROJ BODOVA OSAM CIJELIH SXEST BROJ ZADATAKA TRIDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0042 MATICXNI BROJ NULA NULA TRI SXEST NULA DEVET SXEST CXETIRI PET SXEST OCJENA IZVRSTAN BROJ BODOVA SXEZDESSET CXETIRI CIJELIH JEDANAEST BROJ ZADATAKA TRIDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0043 MATICXNI BROJ NULA NULA TRI SXEST TRI NULA JEDAN NULA TRI PET OCJENA IZVRSTAN BROJ BODOVA SXEZDESSET DVA CIJELIH DVANAEST BROJ ZADATAKA TRIDESET ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0044 MATICXNI BROJ NULA NULA TRI SXEST SEDAM SXEST CXETIRI JEDAN SEDAM SEDAM OCJENA IZVRSTAN BROJ BODOVA SXEZDESSET DVA CIJELIH DVANAEST BROJ ZADATAKA CXETIRI ZADACI CXETIRI SLJEDECYI SEDAM SLJEDECYI KRAJ

T0045 MATICXNI BROJ NULA NULA TRI SXEST DVA NULA TRI OSAM CXETIRI SEDAM OCJENA IZVRSTAN BROJ BODOVA SXEZDESSET CXETIRI CIJELIH JEDANAEST BROJ ZADATAKA CXETIRI ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

T0046 MATICXNI BROJ NULA NULA TRI SXEST SXEST DVA SEDAM NULA SEDAM CXETIRI OCJENA IZVRSTAN BROJ BODOVA OSAM CIJELIH SXEST BROJ ZADATAKA CXETIRI ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

T0047 MATICXNI BROJ NULA NULA TRI SXEST DEVET DVA SEDAM NULA JEDAN JEDAN OCJENA IZVRSTAN BROJ BODOVA SXEZDESSET CXETIRI CIJELIH JEDANAEST BROJ ZADATAKA SEDAMNAEST ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

T0048 MATICXNI BROJ NULA NULA TRI SXEST SEDAM TRI DVA CXETIRI JEDAN SEDAM OCJENA IZVRSTAN BROJ BODOVA OSAM CIJELIH SXEST BROJ ZADATAKA SEDAMNAEST ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

T0049 MATICXNI BROJ NULA NULA TRI SXEST DVA PET DEVET JEDAN TRI SXEST OCJENA IZVRSTAN BROJ BODOVA OSAM CIJELIH SXEST BROJ ZADATAKA SEDAMNAEST ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

T0050 MATICXNI BROJ NULA NULA TRI SXEST PET DVA CXETIRI TRI TRI PET OCJENA IZVRSTAN BROJ BODOVA OSAM CIJELIH SXEST BROJ ZADATAKA SEDAMNAEST ZADACI SXEST SLJEDECYI SEDAM SLJEDECYI KRAJ

13.3 Privitak-grammar.txt

```
$mbr_rijec = (MATICXNI BROJ);
$mbr= NULA | JEDAN | DVA | TRI | CXETIRI | PET | SXEST | SEDAM | OSAM | DEVET;
$jednoznam= JEDAN | DVA | TRI | CXETIRI | PET | SXEST | SEDAM | OSAM | DEVET;
$dvoznam_br1 = DESET | JEDANAEST | DVANAEST | TRINAEST | CXETRNAEST | PETNAEST
| SXESNAEST | SEDAMNAEST | OSAMNAEST | DEVETNAEST;
$dvoznam_br2 = DVADESET | TRIDESET | CXETRDESET | PEDESET | SXEZDESET |
SEDAMDESET | OSAMDESET | DEVEDESET;
$troznam_br = STO;
$br_zadataka = <$jednoznam> | $dvoznam_br1 | ( $dvoznam_br2 $jednoznam) |
$troznam_br;
$dvoznam_ukupno=<$jednoznam> | $dvoznam_br1 | ( $dvoznam_br2 $jednoznam);
$stocka= CIJELA | CIJELIH | CIJELO;
$br_bodova = $dvoznam_ukupno [$stocka $dvoznam_ukupno];
$ocj = NEDOVOLJAN | DOVOLJAN | DOBAR | VRLO DOBAR | IZVRSTAN;
(SENT-START <$mbr_rijec <$mbr> OCJENA $ocj BROJ BODOVA $br_bodova BROJ
ZADATAKA $br_zadataka ZADACI <$br_bodova SLJEDECYI> KRAJ> SENT-END)
```

13.4 Privitak-rječnik uz pripadajuće transkripcije-dict_te(PT-1).txt

BODOVA	b o d o v a s p
BROJ	b rr o j s p
CIJELA	c ie l a s p
CIJELIH	c ie l i h s p
CIJELO	c ie l o s p
CXETIRI	cx e t i r i s p
CXETRDESET	cx e t rr d e s e t s p
CXETRNAEST	cx e t rr n a j e s t s p
DESET	d e s e t s p
DEVEDESET	d e v e d e s e t s p
DEVET	d e v e t s p
DEVETNAEST	d e v e t n a j e s t s p
DOBAR	d o b a r s p
DOVOLJAN	d o v o l j a n s p
DVA	d v a s p
DVADESET	d v a d e s e t s p
DVANAEST	d v a n a j e s t s p
IZVRSTAN	i z v r r s t a n s p
JEDAN	j e d a n s p
JEDANAEST	j e d a n a j e s t s p
KRAJ	k r a j s p
MATICXNI	m a t i c x n i s p
NEDOVOLJAN	n e d o v o l j a n s p
NULA	n u l a s p
OCJENA	o c j e n a s p
OSAM	o s a m s p
OSAMDESET	o s a m d e s e t s p
OSAMNAEST	o s a m n a j e s t s p
PEDESET	p e d e s e t s p
PET	p e t s p
PETNAEST	p e t n a j e s t s p
SEDAM	s e d a m s p
SEDAMDESET	s e d a m d e s e t s p
SEDAMNAEST	s e d a m n a j e s t s p
SENT-END	[] sil
SENT-START	[] sil
SLJEDECYI	s l j e d e c y i s p
STO	s t o s p
SXESNAEST	s x e s n a j e s t s p
SXEST	s x e s t s p
SXEZDESET	s x e z d e s e t s p
TRI	t r i s p
TRIDESET	t r i d e s e t s p
TRINAEST	t r i n a j e s t s p
VRLO	v rr l o s p
ZADACI	z a d a c i s p
ZADATAKA	z a d a t a k a s p