
UDK 801.41:681.3

Originalni znanstveni rad

Primljeno: 15. 5. 1990.

Milan Stamenković
VVTŠ KoVJNA, Zagreb

AUTOMATSKO PREPOZNAVANJE GOVORA

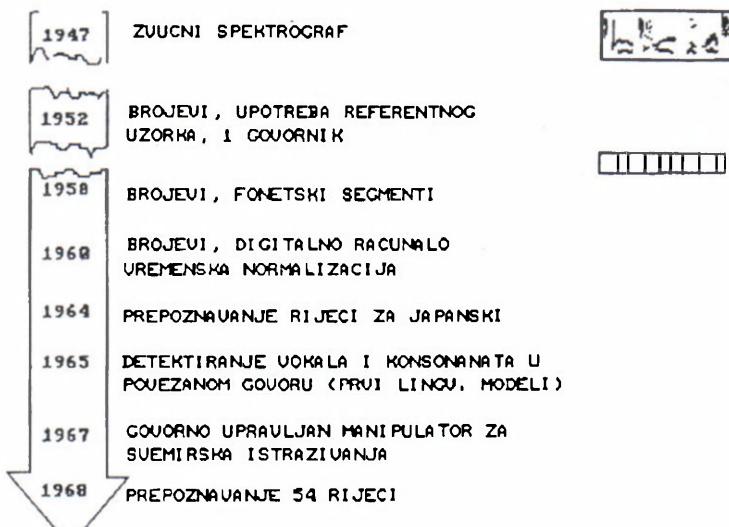
S A Ž E T A K

Osim što su definirana opća načela automatskog prepoznavanja govora, u ovom su radu razmatrani pristupi prepoznavanja govora temeljeni na tradicionalnoj teoriji prepoznavanja uzorka i strojnom učenju u opreci s modelima koji uključuju fonetsko-lingvističke aspekte. Središnje mjesto rada jest opis sistema za prepoznavanje povezanoga govora, koji modelira procese govorne komunikacije.

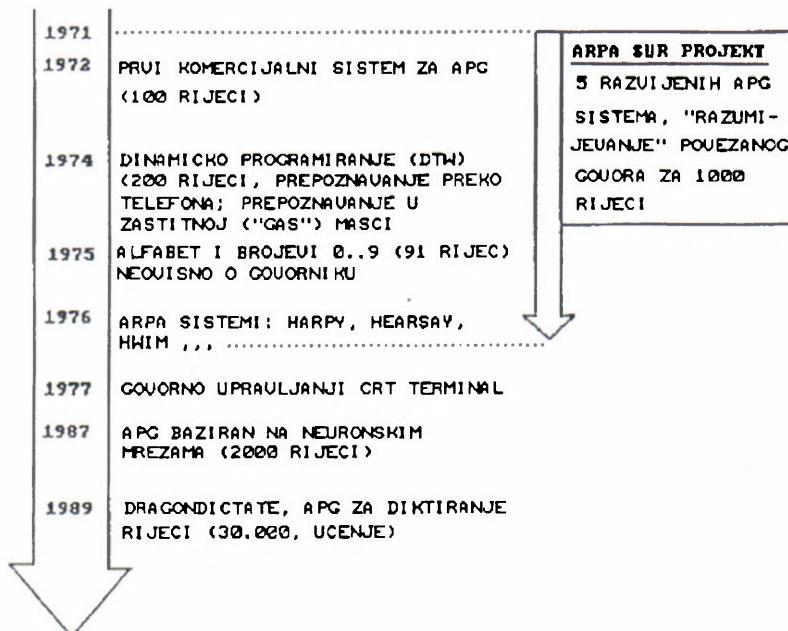
1. UVOD

Za razliku od pokušaja da se mehanički govor oponaša različitim vrstama uredaja, koji datiraju još iz drevnih vremena pa sve do danas (Witten, 1982) uspješna rješenja sistema za automatsku analizu i prepoznavanje govora (APG) znatno su novija. Naime, značajan napredak u analizi govora postignut je tek neposredno prije II svjetskog rata (1930-1940) kada je konstruiran uredaj za frekvencijsku analizu glasova koji je u naprednijoj verziji nazvan sonograf (Potter, 1947). Mjerenja spektra pojedinih glasova i njihovih medusobnih odnosa omogućila su da godine 1952. Davis, Biddulph i Balschek u Bell laboratoriju razviju prvi stroj za automatsko prepoznavanje brojeva (0. . 9). Njihov se uredaj sastojao od spektralnog analizatora za dva frekvencijska pojasa: ispod i iznad 900 Hz u kojem je bio ugraden sklop za mjerenje broja prolazaka signala kroz referentnu razinu. Takav način mjerenja predstavljaо je ekvivalentne centralne frekvencije unutar svakog opsega. Dobivene vrijednosti bile su osi koordinatnog sustava (poslije poznat kao dualna formantna ravnina F₁ -F₂) koji je usporedivan s etalonom za svaku pojedinu riječ. Za prepozнатu riječ proglašavana je ona čiji je referentni uzorak imao najveću mjeru korrelacije s nepoznatim. Početni uspjeci bili su inspiracija za dalja istraživanja. Tako je ista grupa 1958. godine razvila sistem "Audrey", koji je za analizu upotrebljavao deset pojasnih filtera i izdvajao pojedinc maksimume u spektru koji su bili vremenski uskladivani s referentnim uzorcima. Značajna novost u odnosu prema prvom radu bila je segmentacija govora na fonetske jedinice, koji su predstavljali pojedine tipove glasova. Postotak prepoznavanja za unaprijed određenog govornika i za isti vokabular praktično je bio 100% posto, pa ohrabrene takvim rezultatom niču mnoge istraživačke grupe, koje žele što prije konstruirati stroj za automatsko diktiranje. Međutim, tek kada se sistematski počeo rješavati taj problem, uočena je prava kompleksnost percepcije i razumijevanja govora koja nije mogla biti aproksimirana klasičnom teorijom prepoznavanja uzorka. Tek nakon dvadesetak godina (Lea, 1980) napravljen je komercijalno kompletni sistem za prepoznavanje izolirano izgovorenih riječi. Sistem koji je tada ponudila tvrtka "Threshold Technology Incorporated" mogao je prepoznavati do 100 riječi pažljivo izgovorenih. Najviše su razvoju APG-a pridonijeli rezultati projekta SUR (Speech Understanding Research - istraživanja o razumijevanju govora) koji je voden u sklopu institucije (D)ARPA (Defence Advanced Research Project Agency) za potrebe američke vojske i NATO-pakta sredinom osamdesetih godina. U tom razdoblju (sl. 1) intenzivno je proučavan lingvistički model prepoznavanja govora koji uključuje više razina govorne komunikacije (fonetsku, leksičku, semantičku). Konkretni realizirani laboratorijski sistemi SDC, HWIM, HEARSAY-II i HARPY bili su namijenjeni za prepoznavanje povezanoga govora, neovisno o govorniku i mogli su voditi specijalizirani dijalog s operatorm.

RANA HISTORIJA SISTEMA ZA APG



NOVIJA HISTORIJA



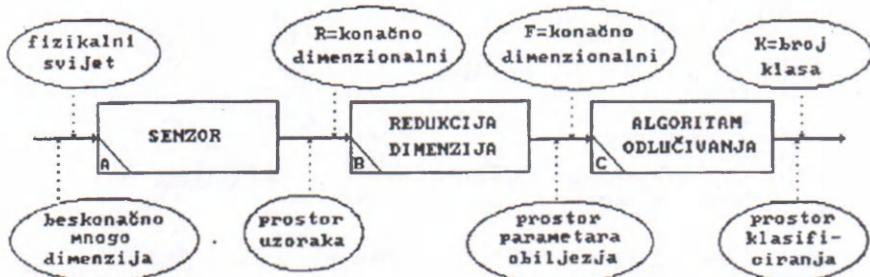
sl. 1 Povijesni pregled razvoja sistema za APG

Sistemi za prepoznavanje (segmentaciju) govora koji bi omogućavali slobodno diktiranje još nisu napravljeni. U posljednjem desetljeću mnogo se uključuje u koncepciju tzv. neuronskih mreža i strojnog učenja. Objavljeni rezultati već potvrđuju uspješnost prepoznavanja i nekoliko tisuća riječi za unaprijed pripremljenog govornika. Današnji "state of the art" u domeni APG je poopćeni HMM (Hidden Markov Model) model prepoznavanja, kojim se uspješno može prepoznavati i više desetaka tisuća (izoliranih) riječi za unaprijed pripremljenog govornika. Prvi takav komercijalni sistem predstavila je američka tvrtka "Apricot", na II Evropskoj konferenciji o govornoj komunikaciji i tehnologiji u Parizu rujna 1989.

Obrada govora na računalu u nas je tek u začetku. Prema prezentiranim radovima (ROJP III-1985, ROLP IV-1988) istraživanja su u domeni analize parametara obilježja signala i primjene tradicionalnih tehniki klasificiranja uzorka. Opsežnija istraživanja segmentacije povezanoga govora s uključivanjem lingvističkog aspekta u obradu signala do sada nisu objavljena. Publicirani radovi uglavnom se bave prepoznavanjem izoliranih riječi za unaprijed pripremljenog govornika (najčešće brojeve 0 - 9). Svrha je ovog rada prikazati globalna načela prepoznavanja govora, klasifikaciju sistema za APG te da predloži model automatske segmentacije govora koja zahvaća lingvističke elemente govorne komunikacije.

2. PRISTUPI U RJEŠAVANJU PROBLEMA APG

Prvi sistemi za APG vjerno su slijedili opću shemu prepoznavanja uzorka prikazanu na donjoj slici.



sl. 2-1 Koncepcija strojnog prepoznavanja uzorka

Pojave iz fizičkog svijeta pobuduju ulazne senzore koji okolini svijet svode na neku mjerljivu veličinu kodiranu na odgovarajući način. Nakon toga, iz mnoštva dobivenih kodova odabiru se samo oni koji prema definiranom kriteriju imaju najveću informativnost. Odabrane i transformirane prezentacijske kodove nazivamo parametri obilježja (engl. features). Redukcija promatranih parametara izuzetno je važna jer procesna moć postojećih računala uglavnom nije dovoljna za obradu svih izmјerenih veličina dobivenih s ulaznih senzora. Također, pažljivim odabirom parametara obilježja pojednostavljuje se klasifikacijski postupak i povećava njegova točnost. Iduća je faza klasifikacija (prepoznavanje) uzoraka prema definiranim pravilima. Primjenimo li opisanu shemu na segmentaciju (prepoznavanje) govora, tada je lako zaključiti da je ulazni senzor A zapravo mikrofon, dok odabir parametara čini vrsta primjenjene analize izvornog signala (analiza formanata, analiza F0, energija itd.). Kao i kod općeg modela govorni segmenti mogu se klasificirati prema beskonačno mnogo kriterija, spomenimo neke: podjela po periodičnosti valnog oblika (vokalizirani - nevokalizirani), podjela prema iznosu energije, podjela prema visini F0, položaju formanata itd. Dalje ovisno o dužini glasovnog segmenta možemo govoriti o prepoznavanju izolirano izgovorenih riječi ili o prepoznavanju povezanog govora. Dakle, prepoznavanje uzoraka možemo shvatiti kao dvostruku transformaciju (Gonzalez, 1978) skupa uzoraka P na reducirani skup parametara obilježja F, nad kojim se primjenjuje neki od postupaka iz skupa postupaka klasificiranja C:

$$P \rightarrow F \rightarrow C \quad \dots \quad (2-1)$$

Strukture uzoraka i parametara obilježja obično se predstavljaju kao linearne kombinacije nekih funkcija, dok je proces klasificiranja zapravo traženje najbolje aproksimacije referentne linearne kombinacije, koja predstavlja određenu klasu, s ulaznom linearnom kombinacijom, koja opisuje parametar obilježja. Da bi se preciznije odredila transformacija (2-1), nužno je definirati vektorski prostor i kriterij mјere sličnosti odnosno pripadnosti nekoj klasi, specificiranjem metričkog prostora (Kurepa, 1982), (Patrick, 1972).

DEF 2 - 1 Metrički prostor

Ureden par (X, d) nepraznog skupa X i funkcije $d: X \times X \rightarrow \mathbb{R}$ naziva se metrički prostor, a funkciju d zovemo razdaljinska funkcija ili metrika ako vrijedi:

1. $d(x, y) > 0$ za sve $x, y \in X$;
2. $d(x, y) = 0 \Leftrightarrow x = y$
3. $d(x, y) = d(y, x)$ za sve $x, y \in X$;
4. $d(x, y) < d(x, z) + d(z, y)$, za sve $x, y, z \in X$;

Vrijednost $d(x, y)$ nazivamo razdaljinom x i y .

Nažalost, klasična shema prepoznavanja uzoraka primjenjiva je samo na veoma ograničene sisteme za APG (vokabular do nekoliko desetaka riječi, pažljiv način izgovora itd.) zbog više razloga npr.:

a) Varijabilnost izgovora : Način izgovora (dinamika, tempo, naglasak, deorganizacija na kraju izričaja itd) neposredno djeluje na snimljeni oblik signala. Na

primjer, riječ "zdravo" izgovorena kao pozdrav pri neformalnom susretu često je toliko izobličena da zadnja dva glasa praktično nisu niti izgovoreni (!), bez obzira na to što ih percipiramo (zahvaljujući pragmatičkoj redundanciji jezika). Podemo li od pretpostavke da se automatsko prepoznavanje izvodi isključivo na osnovi fizičkog signala, jasno je da nema niti teoretske mogućnosti da se detektiraju svi glasovi unutar riječi, jer niti ne postoje.

b) Problem koartikulacije: Zbog mehaničke inercije i drugih psiho-fizioloških ograničenja svaki se glas izgovara u odnosu prema prethodnim glasovima i onim koji slijede. To znači da je, uslijed različitih početnih uvjeta izgovora, svaki fonem na određeni način modificiran okolinom. Prijelazi od jednog glasa na drugi kontaminirani su, tako da se ne može točno odrediti granica među glasovima, nego se može govoriti samo o mjestu na kojem prevladava jedan od glasova.

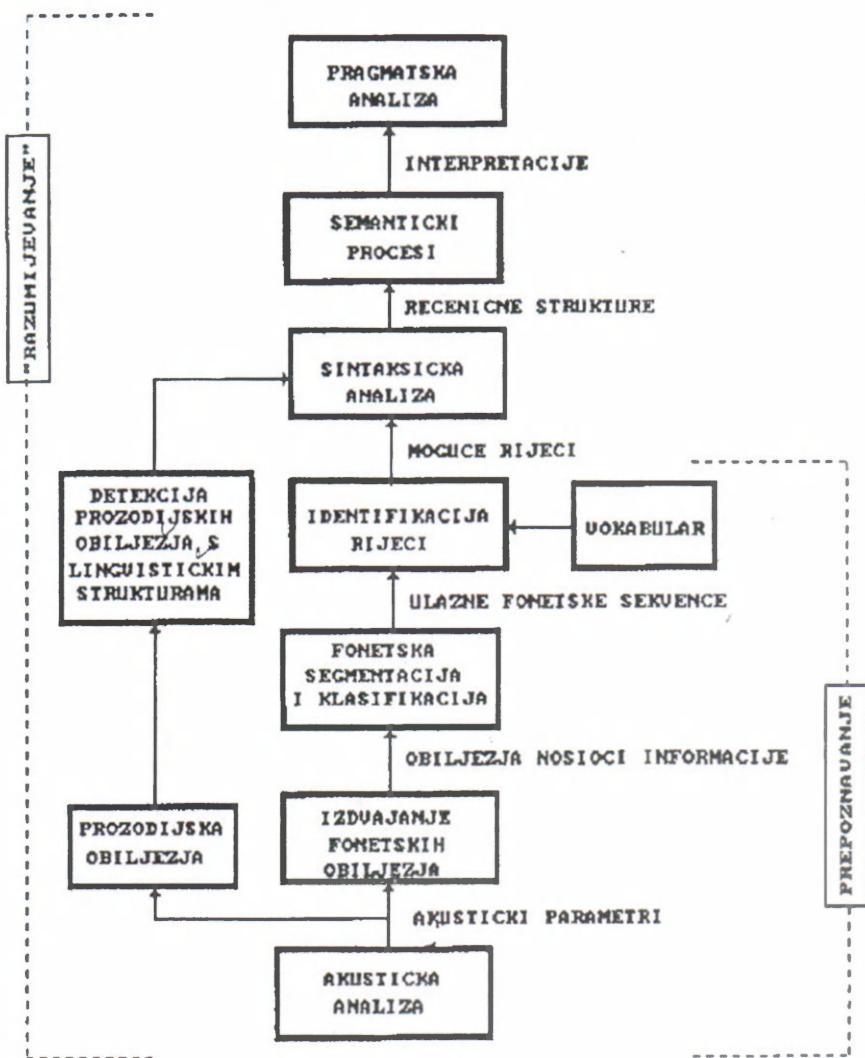
c) Varijabilnost govornika: Ovdje postoji problem da svaki govornik ima specifične govorne osobine koje možemo izraziti npr. kao srednji period F0, prosječni položaj formanata za pojedine glasove itd. Međutim, problem nastaje kada se parametri opisa realizacije pojedinih fonema jednoga govornika bolje podudaraju sa različitim glasovima drugoga govornika, čime je npr. fonem "m" jednog govornika uvjek sličniji fonemu "n" drugog itd.

a) Veličina vokabulara : Povećanjem broja riječi naglo se povećava broj sličnih riječi, što unosi nove zahtjeve za definiranje većeg broja elemenata koji se klasificiraju.

c) Tehnička ograničenja: Budući da se modeli automatskog prepoznavanja govora realiziraju realnim uredajima, uvjek je prisutan problem osjetljivosti prepojačala, rezolucije digitalizacije signala itd. Zbog tog se npr. uvode dodatna ograničenja za uspješnost prepoznavanja govora: smanjena buka okoline, fiksno rastojanje mikrofona od usta itd. Jedno od ključnih ograničenja vezano za efikasnost modela jest i arhitektura i procesna snaga računala koja, prema procenama vodećih laboratorijskih (Kohonen, 1988), mora biti barem 10. 000 MIPS-a (1 MIPS = milijun instrukcija u sekundi).

Da bi se riješili ti problemi, u sklopu ARPA SUR projekta razvijena je konceptacija za APG, koja efikasnost prepoznavanja (postotak grešaka, relativna neosjetljivost na način izgovora i govornika itd) postiže uključivanjem različitih razina govorne komunikacije. Sumarna konceptualna shema prikazana je na slici 2-2.

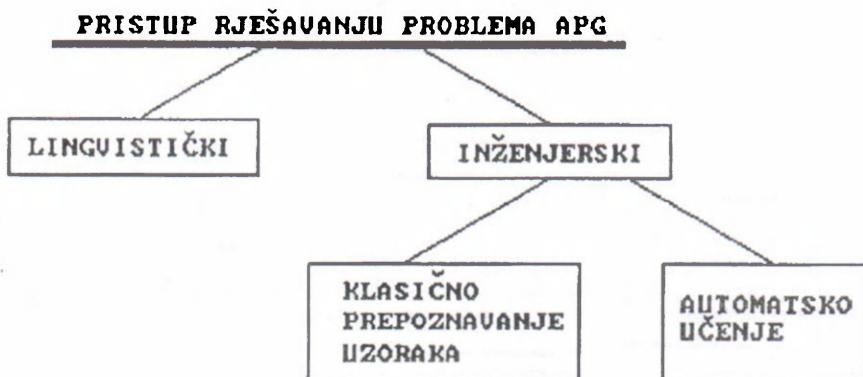
Prema predloženoj konceptciji, za prepoznavanje nije dominantna informacija o fizičkoj karakteristici govornog signala, nego naknadna simbolička obrada koja se realizira u procesu "razumijevanja". Nakon fizičko-akustičke analize formiraju se liste-kandidati, koji predstavljaju ulaz za sintaksičku razinu. Na toj se razini propuštaju one kombinacije koje zadovoljavaju sintaksna pravila, a potom služe kao parametri semantičke i pragmatske analize. Prema predloženom modelu udio klasičnog prepoznavanja (na osnovi fizikalne prirode signala i definiranih razdaljinskih funkcija) samo je 20-40%, dok se greške na toj razini korigiraju lingvističkom obradom. Međutim, ovdje nastaje problem modeliranja prirodnog jezika (sintakse, semantike i pragmatike) za koji i danas postoji tek gruba aproksimacija. Takva ograničenja (kompleksnost procesa) uvjetuju vezivanje sintakse za neko uže područje govornog diskursa, uglavnom za problemske situacije (kupovina, putovanje itd) o čemu će poslije biti više riječi.



sl. 2-2 Procesi uključeni u prepoznavanju i "razumijevanju" govora

U posljednjih desetak godina sve je više radova koji APG pokušavaju rješiti modelom strojnog učenja (Kohonen, 1988) (Stamenković, 1988) (McClelland, 1988). Ideja od koje se ovdje polazi jest da nije potrebno eksplizitno znanje (unaprijed definirani algoritam) o načinu klasificiranja, nego da se ekvivalentno znanje može "naučiti" na osnovi primjera i odgovora. Znanje koje dobiveno na taj način može biti eksplizitno (induktivno učenje) ili implicitno (učenje s pomoću konektivnih modela). U slučaju eksplizitnog znanja moguće je neposredno ustanoviti koja su pravila uzeta kao dijstinkтивno obilježje, dok kod implicitnog učenja to nije moguće.

Opisane globalne pristupe realizaciji sistema APG možemo prikazati na sljedeći način:



sl. 2-3 Pristupi u rješavanju APG

Dakle, razlikujemo sisteme za APG koji ne uključuju fonetsko-lingvističko znanje (inženjersko-tehnički pristup) i one koji ga uključuju.

Radi usporedbe performansi sistema za APG, definirano je nekoliko klase prepoznavanja u ovisnosti o načinu izgovora:

a) **povezani govor** (continuous speech) jest normalan način izgovaranja riječi (bez umjetnih pauza)

b) **izgovor po grupama riječi** (connected words) jest takav način izgovora gdje se pojedine grupe riječi izgovaraju bez razmaka, ali je razmak između grupa cca 200-300 ms.

c) **izolirane riječi** (isolated words) jest način izgovora gdje je pauza između uzastopnih riječi cca 200-300 ms.

Dodatni kriterij za sva tri načina izgovora uključuje govornika, tj. je li sistem neovisan (speaker independent) ili ovisan (speaker dependent) o njemu. Sistemi za APG koji su ovisni o govorniku zahtijevaju da se govornik unaprijed pripremi, tj. da svaki govornik prije procesa prepoznavanja snimi svoje referentne uzorke

(parametrc) glasova, riječi ili rečenica. Najčešći parametri koji služe kao zajednički elementi distinkтивnih obilježja opisani su u idućem poglavlju.

3. PARAMETRI OBILJEŽJA GOVORNOG SIGNALA

Nakon digitalizacije govora, slijedeći postupak prema segmentaciji jest definiranje pojedinih kvantitativnih i kvalitativnih svojstava signala na osnovi kojih se on analizira. Odabrana svojstva koja ulaze u metriku analize nazivamo parametri obilježja govornog signala. O vrsti analize, ovisit će i izbor parametara. Za većinu analiza iskustveno se uvode sljedeći parametri i njihove kombinacije:

- a) kratkovremenska energija
- b) broj prolaza kroz nulu
- c) trenutni spektar signala
- d) period osnovnog tona
- e) koeficijenti linearne predikcije govora

Najjednostavnija prezentacija digitaliziranoga govornoga signala $x(n)$ dana je iznosom njegove energije:

$$E = \sum_n x(n)^2 \quad \dots \quad (3-1)$$

Međutim, totalna energija izgovorene riječi nije informativna, jer različite riječi mogu imati približno istu energiju (npr. osamdeset i udaljenost) a ukupna energija iste riječi u mnogome ovisi o načinu izgovora (tempo, dinamika, akcent). Zbog toga se uvodi kratkovremenska energija koja opisuje energetsku razinu segmenta unutar riječi za N uzoraka:

$$E(n) = \frac{1}{N} \sum_{m=0}^{N-1} [w(m) \cdot x(n-m)]^2 \quad \dots \quad (3-2)$$

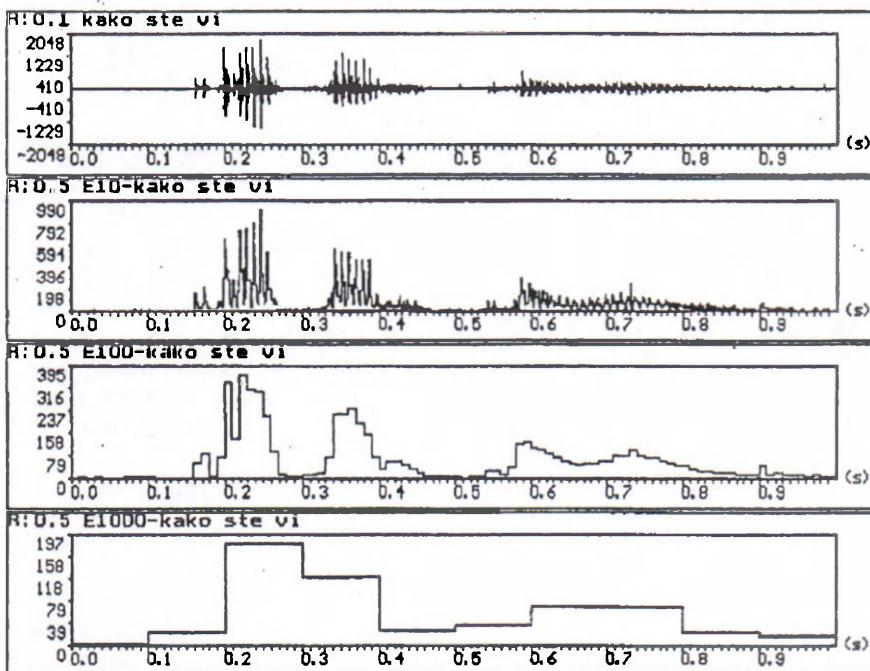
gde je $w(m)$ funkcija kojom se ponderiraju pojedini uzorci i u literaturi se naziva prozor. Najčešće se upotrebljava tzv. pravokutni prozor:

$$w(m) = \begin{cases} 1 & \text{za } 0 \leq m \leq N-1 \\ 0 & \text{inače} \end{cases} \quad \dots \quad (3-3)$$

Iznos $E(n)$ predstavlja srednju energiju signala po uzorku poslednjih N uzoraka do $x(n)$. Izraz 3-2 prenaglašava vokalizirane glasovne segmente u odnosu prema tišim govornim intervalima, pa se u praksi često koristi nešto izmijenjena definicija kratkovremenske energije, tj:

$$E(n) = \frac{1}{N} \sum_{m=0}^{N-1} |x(m) \cdot x(n-m)| \quad \dots \quad (3-4)$$

Posebnu pozornost treba obratiti na širinu prozora $w(m)$ (tj. na njegovo trajanje). Ako je N veće, tada je zahvaćeno više uzoraka, pa se izraz 3-2 približava izrazu 3-1. Međutim, uzme li se premalo uzoraka, funkcija $E(n)$ postaje sve sličnija izvornom signalu $x(n)$ (po apsolutnim iznosima). Efekt širine vremenskog prozora na izgled funkcije kratkovremenske energije ilustriran je na slici 3-1 ("kako ste vi").



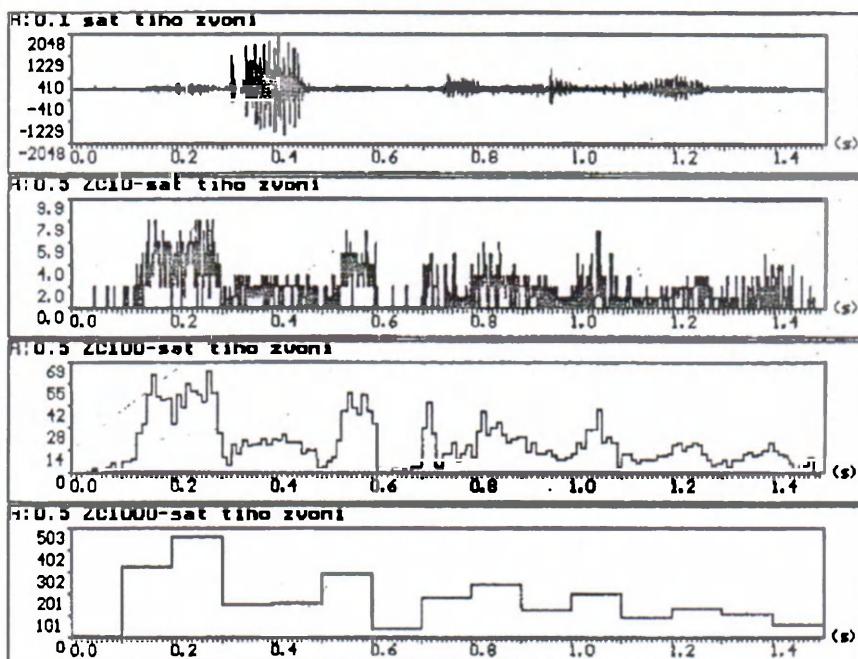
sl. 3-1 Utjecaj širine vremenskog prozora na oblik funkcije $E(n)$: a) PCM b)
 $N=10$ c) $N=100$ d) $N=1000$

Prema preporukama (Lea, 1980), (Schafcr, 1979) najprihvatljivija širina prozora je oko $\Delta t = 10$ ms, tj broj uzoraka za koje se izračunava srednja energija:

$$N = 0.01 [s] \cdot F_u [Hz] \quad \dots \quad (3-5)$$

Broj prolaza signala kroz nulu predstavlja prvu ocjenu o općoj frekvencijskoj prirodi signala. Naime, uzmememo li da je signal predstavljen nekom sinusnom (kosinusnom) funkcijom, tada je lako uspostaviti vezu između broja prolaza kroz nulu N i frekvencije :

$$F = \frac{1}{T} = \frac{1}{2} N_z \left[\frac{1}{s} \right] \quad \dots (3-6)$$



sl. 3-2 Veći iznos broja prolaza kroz nulu ukazuje na nevokalizirane glasove
b) N=10 c) N=100 d) N=1000

Funkciju jednog prolaza kroz nulu možemo definirati na sljedeći način:

$$N_z(n) = \begin{cases} 1 & \text{za } \text{sign}(x(n)) \neq \text{sign}(x(n-1)) \\ 0 & \text{inače} \end{cases} \quad \dots (3-7)$$

Analogno izrazima (3-2) i (3-4) promatramo određeni vremenski segment izražen brojem uzorka N :

$$ZC(n) = \sum_{m=0}^{N-1} w(m) N_z(n-m) \quad \dots (3-8)$$

Izraz (3-8) primijenjen na govorni signal implicitno upozorava na glasove čija je energija koncentrirana u višim dijelovima spektra (iznad 2-3 KHz) npr. s, c, č, š itd. Na slici 3-2 ("sat tiho zvoni") jasno se izdvajaju segmenti frikativa (h) i sibilanata (s, z).

Jedan od najvažnijih parametara govornog segmenta jest njegova frekvenčinska karakteristika (spektar). Prijelaz iz vremenske domene u frekvenčinsku najčešće se ostvaruje s pomoću diskretnе Fourierove transformacije:

$$X(e^{j\omega}) = \sum_{m=-\infty}^{m=\infty} w(n-m) x(m) e^{-j\omega m} \quad \dots \quad (3-9)$$

Indeks n odgovara posljednjoj digitaliziranoj vrijednosti signala. Funkcija vremenskog prozora $w(i)$ najčešće nije pravokutnog oblika, nego su u upotrebi tzv. Hamminog (3-10) ili Hanningov (3-11) prozor (Proakis, 1983):

$$w(m) = \begin{cases} 0.54 - 0.46 \cos(2\pi m/N) & \text{za } 0 \leq N-1 \\ 0 & \text{inače} \end{cases} \quad \dots \quad (3-10)$$

$$w(m) = \begin{cases} 0.5 (1 - \cos(2\pi m/N)) & \text{za } 0 \leq N-1 \\ 0 & \text{inače} \end{cases} \quad \dots \quad (3-11)$$

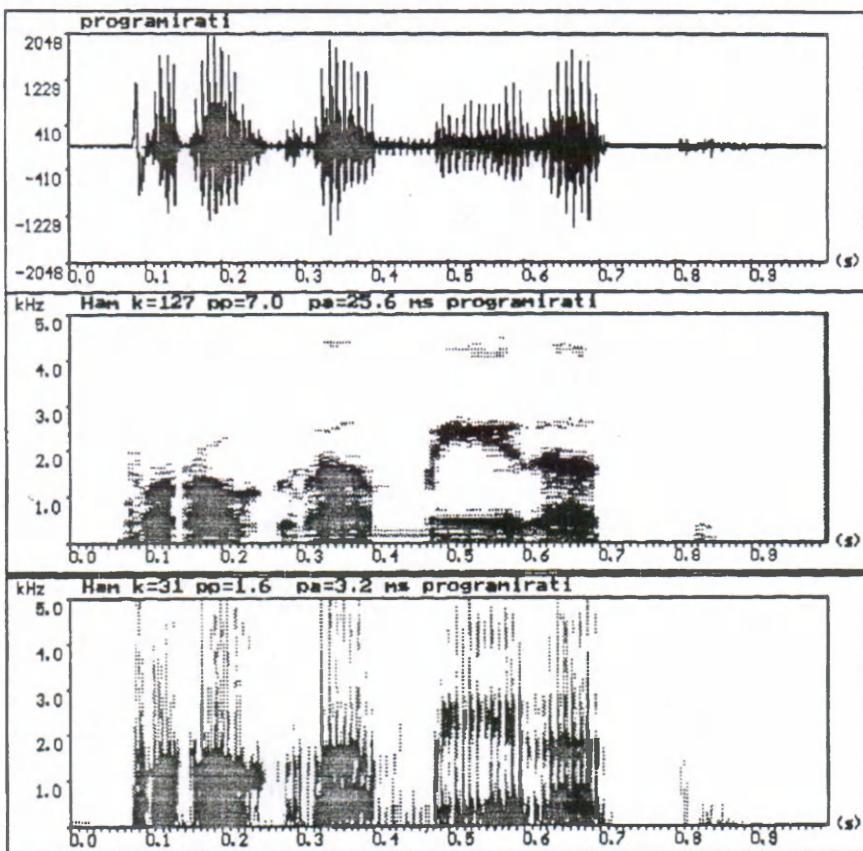
Pravokutni prozor ne upotrebljava se iz razloga jer uvodi dodatne lokalne maksimume u spektru zbog karakterističnog frekvenčinskog odziva na pravokutni puls. Iz istih razloga kao i kod funkcije totalne energije signala (izraz 3-1), u praksi nije od interesa ukupni spektar signala, nego njegova raspodjela u pojedinim vremenskim intervalima. Zato se 3-9 zapisuje u izmijenjenom lokaliziranom obliku:

$$X(k) = \sum_{m=0}^{N-1} x(m) e^{-j2\pi km/N}, \quad k=0, 1, \dots, N-1 \quad \dots \quad (3-12)$$

$$x(m) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j2\pi km/N}, \quad m=0, 1, \dots, N-1 \quad \dots \quad (3-13)$$

Izraz 3-12 predstavlja Fourierovu transformaciju, gdje je $X(k)$ amplituda spektra na frekvenciji $f=2\pi km/N$. Izraz 3-13 jest inverzna Fourierova transformacija. Najčešće se uzima da je N potencija broja 2, čime se (3-12) i (3-13) mogu programski realizirati kao FFT algoritmi (Papamichalis, 1987). Klasična uska i

Široka sonografska analiza se s pomoću FFT transformacije realizira izborom adekvatnog broja N (točaka) FFT analize i trajanja govornog segmenta (Δt).



sl. 3-3 FFT sonogramski prikaz a) PCM signal b) $N=32$, $\Delta t=3.2$ ms c)
 $N=128$, $\Delta t=25.6$ ms.

Na slici 3-3 prikazana je FFT analiza riječi "programirati" pri b) $N=128$ i c)
 $N=32$ i upotreboom Hammingova prozora.

Osim FFT analize, za sonogramske prikaze često se upotrebljavaju i FIR (Finite Impulse Response) filtri, koji se mogu specificirati kao filtri propusnici opsega, niskopropusni ili visokopropusni filtri.

Period osnovnog tona (engl. Pitch period) predstavlja periodu harmonijskog tona koji nastaje izgovaranjem vokaliziranih glasova. Često se obilježava i kao F0 (u smislu 0-tog formanta) te predstavlja značajni prozodijski parametar govora. Nažalost, precizno ustanovljavanje F0 u općem slučaju nije moguće zbog obezvučavanja na pojedinim prijelazima glasova ili pri kraju izgovora, pa su razvijeni mnogi algoritmi (Schafer, 1979), (Stamenković i Bakran, 1989) koji sa više ili

manje uspjeha detektiraju stvarni iznos F0. U ovom radu upotrijebljen je nešto izmijenjen AUTOC algoritam koji se temlji na centralnom ograničenju signala i funkciji autokorelacije (ACF - Autocorrelation Function). Centralno ograničenje signala jest linearna transformacija digitaliziranog signala i svrha joj je razbiti formantu strukturu glasa te istodobno zadržati informaciju o periodičnosti. Matematička formulacija centralnog ograničenja dana je izrazom (3-14).

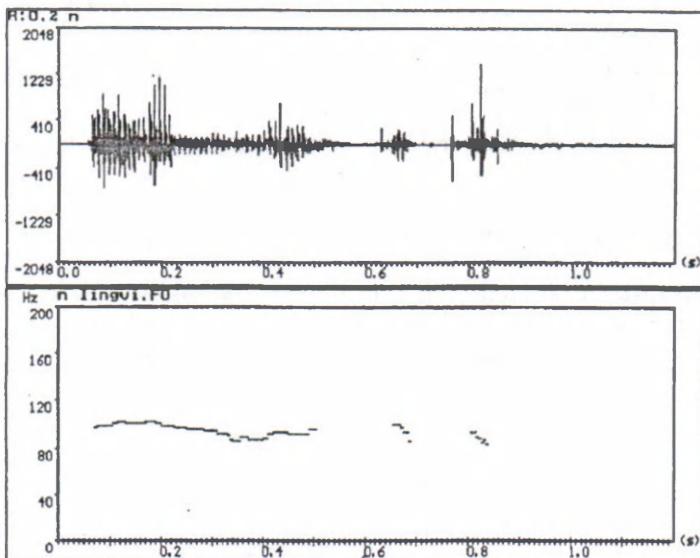
$$y(s(n)) = \begin{cases} s(n) - C & \text{za } s(n) < C \\ s(n) + C & \text{za } s(n) \geq C \\ 0 & \text{inače} \end{cases} \quad \dots \quad (3-14)$$

Digitaliziran uzorak $s(n)$ nakon centralnog ograničenja poprima vrijednost $y(s(n))$. Prag odsijecanja C iznosi 0.0-0.7 maksimalne amplitude signala unutar segmenta od $N/3$ uzorka. Nakon primjene izraza (3-14) izračunava se autokorelacija :

$$R(k) = \sum_{n=0}^{N-1} y(n) y(n+k), \quad k=0, 1, \dots, K \quad \dots \quad (3-15)$$

Autokorelacija periodičnog (vokaliziranog) signala imat će izrazite maksimume, koji će se ponavljati periodom izvornog signala i upravo će predstavljati period osnovnog toga T , odnosno $F_0 = 1/T$. Nevokalizirani segmenti davat će autokorelacijsku funkciju bez naglašenih maksimuma, tj. amplituda će gotovo uvijek bit ispod vrijednosti $C R(0)$, gdje je C konstanta oko 0.3. Znači, period osnovnog tona određen je prvim indeksom k koji označava prvi lokalni maksimum takav da je $R(k)C > R(0)$. Broj uzorka N predstavlja širinu autokorelacije i njegov izbor ovisi o donjoj frekvenciji F_0 , koja se želi analizirati. Radi univerzalnije primjene, često se uzima segment trajanja cca 30 ms ($F_0=33.3$ Hz), što znači da pri frekvenciji uzorkovanja od 10 KHz broj uzorka N treba biti 300. Nakon izračunavanja autokorelacije svih uzorka, pristupa se korekciji lažnih vrijednosti u toku višestrukih postupaka gladjenja (engl. smoothing), provjere kontekstnih i drugih poznatih uvjeta vezanih za prirodu F_0 .

U posljednjih desetak godina sve se više upotrebljava tzv. LPC analiza govora (Linear Prediction Code), koja je izvorno motivirana rješavanjem problema komprimiranog telekomunikacijskog prijenosa digitaliziranoga govora. Daljnom matematičkom razradom LPC modela otkrivena je neposredna veza između tradicionalnih formantnih frekvencija te vrijednosti i broja tzv. parametara LPC analize čime LPC lagano potiskuje tradicionalnu sonografsku analizu. Suštinu LPC analize čini izračunavanje koeficijenata predikcije $a(j)$ (osnovnih LPC parametara) :



sl. 3-4 a) PCM signal "lingvistika" b) F0

$$s(n) = \sum_{j=1}^k a(j) s(n-j) \quad \dots \quad (3-16)$$

Na osnovi k posljednjih uzoraka i s pomoću koeficijenata predikcije izračunava se n-ti uzorak $s(n)$. Primjenom Z-transformacije (Rabiner et al., 1978) izraz (3-16) prijelazi u:

$$H(Z) = \frac{1}{1 - \sum_{j=1}^k a(j)Z^{-j}} \quad \dots \quad (3-17)$$

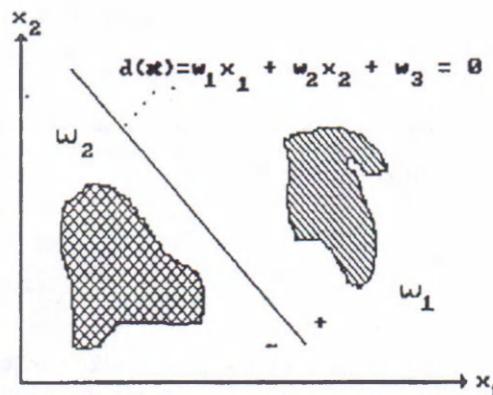
Uvrstimo li u brojnik konstantno pojačanja A, izraz (3-17) će predstavljati če vremenski promjenjiv filter, čiji frekvencijski odziv možemo interpretirati kao prijenosnu funkciju vokalnog trakta. Algoritmom transformiranja koeficijenata predikcije (Witten, 1982) u tzv. koeficijente refleksije neposredno se izračunava formantna karakteristika signala. Minimalni broj potrebnih LPC parametara za specifikaciju n formanata iznosi $2n+1$.

4. MODELI PREPOZNAVANJA GOVORA

Različiti pristupi rješavanju problema APG uvjetovali su razradu mnogobrojnih modela analize i prepoznavanja govora. U ovom poglavlju prikazani su reprezentativni modeli već prihvaćene kategorijacije pristupa prepoznavanju govora.

4. 1 Inženjersko-tehnički modeli

Inženjersko-tehnički modeli sistema za APG tretiraju uzorke govornog signala kao objekte u nekom prostoru klasifikacije bez fizičalne interpretacije njihova značenja. Općenito, problem se postavlja u definiranju funkcije (krivulje) diskriminacije među klasama objekata

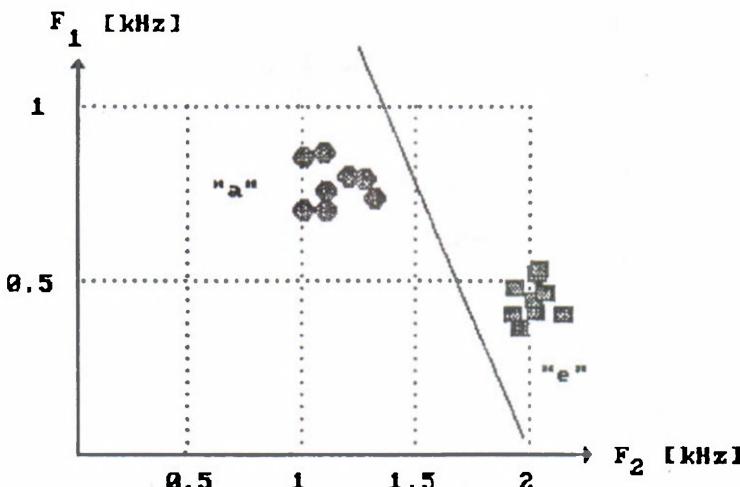


sl. 4. 1-1 Jednostavna diskriminacijska funkcija za dvije klase uzoraka

Pretpostavimo da postoje samo dvije klase objekata (ω_1 i ω_2) kao što je prikazano na slici 4. 1-1. Neka je dana jednadžba linije koja razdvaja ω_1 i ω_2 :

$$d(\mathbf{x}) = w_1 x_1 + w_2 x_2 + w_3 = 0 \quad \dots \quad (4.1-1)$$

Oznake ω_1 , ω_2 i ω_3 jesu parametri, x_1 i x_2 koordinate varijabli dok $d(\mathbf{x})$ skraćeno predstavlja udaljenost $d(x_1, x_2)$. Sa slike 4. 1-1 vidi se da će svaki uzorak \mathbf{x} (predstavljen koordinatama x_1 i x_2) iz klase ω_1 nakon uvrštavanja u 4. 1-1 rezultirati pozitivnu vrijednost $d(\mathbf{x})$. Isto tako, uzorci iz klase ω_2 leže na negativnoj strani od demarkacijske linije, tako da nakon uvrštavanja tih uzoraka $d(\mathbf{x})$ postaje negativno. Dakle, na osnovi predznaka od $d(\mathbf{x})$ dobivamo pravilo za pripadnost klasama, pa kažemo da uzorak \mathbf{x} pripada klasi w ako $d(\mathbf{x}) > 0$ odnosno pripada klasi ω_2 ako $d(\mathbf{x}) < 0$. Za uzorke koji leže na demarkacijskoj liniji vrijednost $d(\mathbf{x})=0$. Ovaj trivijalni primjer klasifikacije možemo ilustrirati usporedbom dvaju vokala, npr. "a" i "e" u ravnini F_1 - F_2 , što je prikazano na slici 4. 1-2.



sl. 4. 1-2 Razdvajanje vokala "A" i "E" (muški govornik).

Vrijednosti formanata dobiveni su FFT transformacijom (256 točaka, usrednjeni na širinu spektra od 340 Hz, Hammingov prozor) manualno segmentiranih odsječaka vokala digitaliziranih s 12 bita pri frekvenciji uzorkovanja 10 kHz.

Definiranje globalne diskrimijske funkcije za M klase (općenit slučaj) izvodi se s pomoću parcijalnih funkcija

$d_1(x), d_2(x), \dots, d_M(x)$ s osobinom da ako uzorak x pripada klasi ω_i tada:

$$d_i(x) > d_j(x), \quad j=1, 2, \dots, M, \quad j \neq i \quad \dots \quad (4.1-2)$$

Odluka o pripadnosti nekoj klasi donosi se na osnovi zadovoljenja parcijalnih uvjeta klasifikacije. Uzorak se tada dodjeljuje klasi čija diskriminacijska funkcija ima najveću numeričku vrijednost. Granica između dviju klasa ω_i i ω_j , tada je dana sa:

$$d_i(x) - d_j(x) = 0 \quad \dots \quad (4.1-3)$$

Opisani način klasifikacije (prepoznavanja) u literaturi poznat je kao klasifikacija na osnovi odluke ("decision-theoretic approach"). Drugi model predstavlja tzv. sintaksičko prepoznavanje uzorka ("syntactic approach"), gdje je funkcija udaljenosti nadomještена formalnom gramatikom, dok su objekti predstavljeni nizovima znakova koji čine jezik klase (Gonzalez i Thomson, 1978). Dakle, objekt pripada klasi ako je njegova nizovna interpretacija unutar jezika. Detaljnije o formalizmu generativne gramatike bit će objašnjeni u poglavlju 4. 2.

Doseg inženjersko-tehničkog pristupa jest prepoznavanje izoliranih riječi za unaprijed pripremljenog govornika. U iduća dva potpoglavlja bit će opisana dva najefikasnija modela za APG iz ove klase : dinamičko uskladivanje vremena (DTW - Dynamic Time Warping) i skriveni Markovljev model (HMM - Hidden Markov Model).

4. 1. 1 Dinamičko uskladivanje vremena (DTW)

Potpustavimo da smo definirali rječnik od M riječi koje služe kao etalon. Svaka riječ Y neka je predstavljena s L obilježja:

$$Y_1 = (y_1, y_2, \dots, y_L), \quad i=1..M. \quad \dots \quad (4.1.1-1)$$

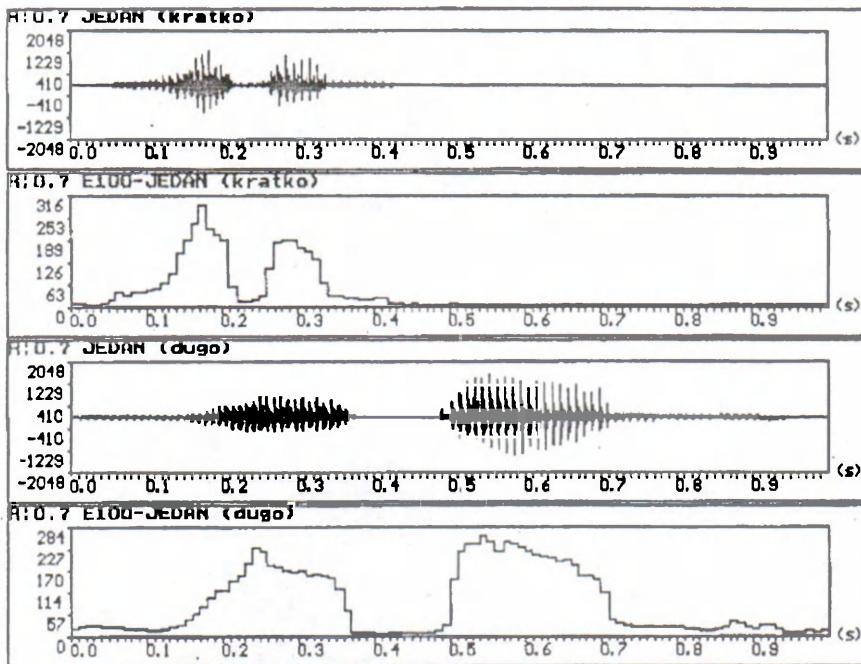
Vektor obilježja nepoznate riječi X jest:

$$X = (x_1, x_2, \dots, x_Z), \quad i=1..Z \quad \dots \quad (4.1.1-2)$$

Proces prepoznavanja riječi X sada je određivanje indeksa riječi u rječniku s najmanjom udaljenosti :

$$j = \arg(\min_k | D(X, Y_k)) \quad \dots \quad (4.1.1-3)$$

gdje je $D(X, Y_k)$ funkcija udaljenosti između k -te referentne i nepoznate riječi. Takav model prepoznavanja naziva se prepoznavanje prema etalonu (engl. template matching). Parametri y_1, \dots, y_k mogu biti kratkovremenska energija, FFT spektar, LPC koeficijenti, broj prolaza kroz nulu itd. Jedan od glavnih problema, koji se ovdje javlja, jest inherentna vremenska neuskladenost koja je posledica različitog tempa izgovora riječi. To znači da dužina L vektora u etalonu i potrebna dužina Z izgovorene riječi mogu znatno varirati, a da je pritom izgovorena ista riječ. Da bismo ilustrirali taj efekt, promatrajmo sliku 4. 1. 1-1.

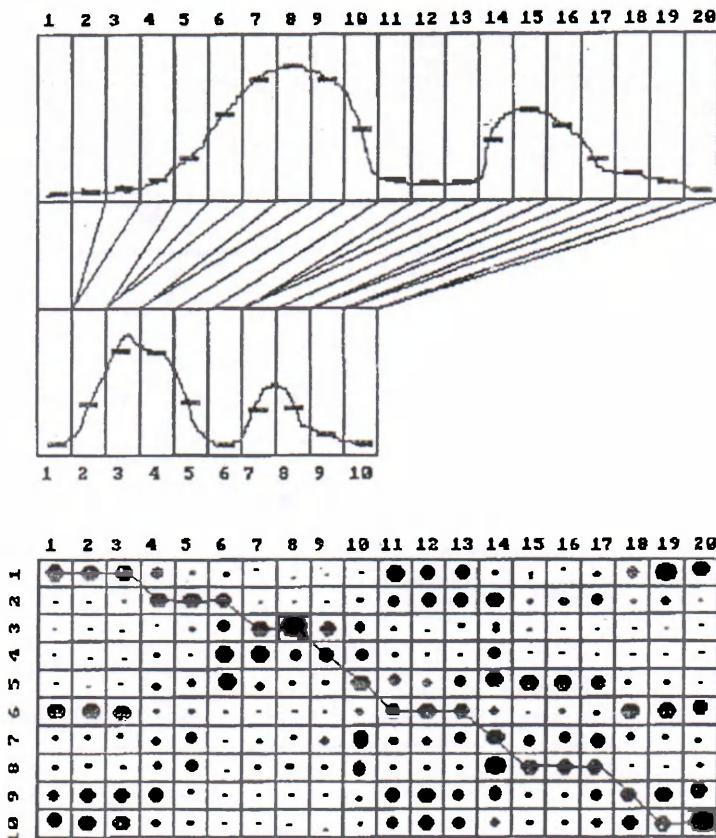


sl. 4. 1. 1-1 Riječ "jedan" izgovorena različitim tempom

Gornja slika prikazuje valni oblik i kratkovremensku energiju riječi "jedan", izgovorenju različitim tempom. Kratkovremenska energija izračunata je vremenskim prozorom od 10 ms. Označimo sa X i Y vektore kratkovremenske energije kratkog i dugog izričaja respectivno. Ako bismo definirali distancu između tih dviju riječi kao zbroj razlika energija u istim trenucima:

$$D(X, Y) = \sum_i |x_i - y_i| \quad \dots \quad (4.1.1-4)$$

odmah se vidi da mjeru lincearne distance nije adekvatna, jer se zbog različite vremenske pozicije ne usporeduju ekvivalentni segmentni riječi (npr. cijela riječ "jedan" izgovorena kratko usporeduje se s morsemom "je" u drugoj riječi, dok se morsem "dan" usporeduje s tišinom). Izlaz iz ove situacije je, dakle, nelinearno uskladivanje indeksa vektora obilježja. Ideja vremenskog uskladivanja prikazana je na donjoj slici.

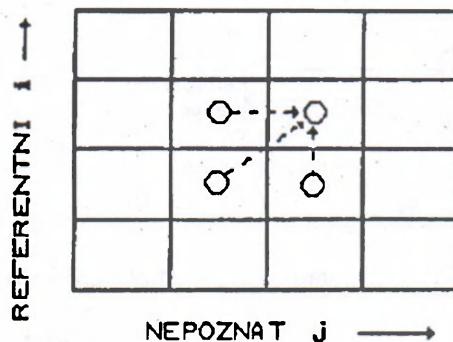


sl. 4. 1. 1-2 a) Nelinearna vremenska normalizacija b) matrica dinamičkog uspoređivanja.

Na slici 4. 1. 1-2 a) skicirane su krivulje kratkovremenske energije dugog i kratkog izričaja riječi "jedan" i segmentirane u ekvidistantnim razmacima. Dvebelim horizontalnim crticama označena je srednja razina energije u segmentu. Potupak određivanja distance vektora X i Y sada interpretiramo kao preslikavanje vremenskih osi nepoznatog uzorka na vremensku os referentnog tako da odstupanja budu minimalna. Matrica preslikavanja ima dimenzije LxZ (za naš primjer L=20, Z=10). Za svaki element (i, j) u matrici preslikavanja definirana je tzv. lokalana distanca $d(i, j)$. Svrha nelinearnog uskladivanja vremena sada je pronalaženje puta kroz matricu tako da ukupna distanca bude minimalna. Kumulativna distanca najčešće se definira jednadžbom dinamičkog programiranja (Nakanishi i Nakagava, 1987):

$$D(X, Y) = \min \sum_j d(u(j), j) \quad \dots (4.1.1-5)$$

gdje je $u(j)$ funkcija usklađivanja. Za slučaj potpuno jednakih uzoraka optimalni put predstavljać će dijagonalu matrice dok u ostalim slučajevima oscilira oko nje (vidi sl. 4. 1. 1-2b). Kumulativna distanca je zbroj distanci između referentnog i testnog uzorka duž "najboljeg" puta. Prilikom kretanja kroz matricu definiraju se dopušteni pomaci npr.



sl. 4. 1. 1.-3 Dozvoljeni pomaci duž dijagonale

Što formalno zapisujemo :

$$g(i, j) = \min \left\{ \begin{array}{l} g(i-1, j) \\ g(i-1, j-1) \\ g(i, j-1) \end{array} \right\} + d(i, j) \dots (4.1.1-6)$$

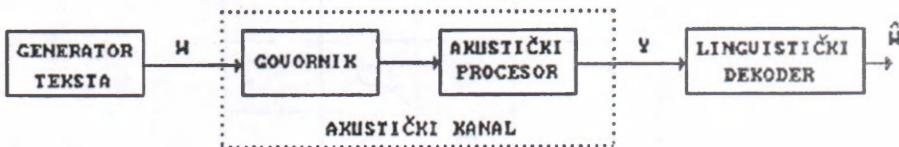
Nakon iterativnog postupka za $1 < I < J$ ukupna distanca $D(X, Y)$ bit će jednaka $g(I, J)$. Takav način prepoznavanja govora poznat je pod nazivom dinamčki usklađivanje vremena (DTW - Dynamic Time Warping), a elementi vektora obilježja najčešće predstavljaju FFT spektar.

Pretpostavka primjene DTW metode jest precizno određivanje početka i kraja izričaja, što znači da se on uspješno može primjenjivati samo za prepoznavanje izoliranih riječi. Drugi je nedostatak velika kompleksnost algoritma (broj računskih operacija), što otežava primjenu u realnom vremenu. U posljednjih nekoliko godina taj je problem riješen pojavom mikroprocesora specijalno namijenjenih za realizaciju DTW algoritama.

U poglavlju 4.3. 2 o automatskoj segmentaciji govora opisan je način prepoznavanja vokala jednom varijantom DTW metode.

4. 1. 2 Skriveni Markovljev model (IIMM)

Proces prepoznavanja govora se u terminima teorije informacija može pojednostavljeno prikazati na sljedeći način:



sl. 4. 1. 2-1 Informacijsko-komunikacijski model APG

Govornik i akustički procesor predstavljaju kanal kojim se prenose simboli (tekst) prema lingvističkom dekoderu. Zadaća lingvističkog dekodera jest restaurirati originalnu poruku koja je podložna deformaciji zbog buke u kanalu. Akustički procesor (AP) funkcioniра kao kompresor podataka koji transformira govorni valni oblik u niz parametara vektora, nakon kojih slijedi klasifikator uzorka. Klasifikator uzorka na svom izlazu daje povorku etiketa iz nekog konačnog alfabeta. Akustički procesor obično je vremenski sinkroniziran, tj. podaci na njegovom izlazu dostupni su u ekvidistantnim intervalima. Izlaz iz AP predstavlja, dakle, niz (vektor) Y na osnovi kojeg lingvistički dekoder formulira očekivanu rječ w za originalnu \hat{W} . Da bi se minimizirala pogreška očekivane rječi, W treba biti odabran tako da:

$$P(\hat{W}|y) = \max_w P(w|y) \quad \dots \quad (4.1.2-1)$$

Na osnovi Bayesovog pravila imamo:

$$P(w|y) = \frac{P(w)P(y|w)}{P(y)} \quad \dots \quad (4.1.2-2)$$

Budući da $P(y)$ ne ovisi o w , maksimiziranje $P(w|y)$ ekvivalentno je kao i maksimiziranje $P(w, y) = P(w)P(y|w)$. Ovdje je $P(w)$ apriorna vjerojatnost da će tekst generator producirati niz (rječ) w , a $P(y|w)$ je vjerojatnost da će akustički kanal (opravno AP) transformirati rječ w u izlazni niz y . Da bi se na dekoderu odredilo $P(w)$, mora se definirati probabilistički model izvora koji generira simbol w (tekst-generator). Isto tako izračunavanje $P(y|w)$ zahtijeva postojanje probabilističkog modela akustičkog kanala koji će uračunati varijete izgovora (dinamika, tempo, boja glasa itd). Pod pretpostavkom da postoje modeli za tekst-

generator (odnosno model jezika) i akustički kanal, biti će moguće neposredno odrediti simbol w s najvećom vjerojatnošću. Radi jednostavnosti, pretpostavimo da A emitira simbole u diskretnim i ekvidistantnim intervalima. Tada će se on zajedno s akustičkim kanalom moći predstaviti kao model nekog stohastičkog (Paušc, 1974) procesa. U praksi se kao zadovoljavajuća aproksimacija kompleksnosti procesa pokazao stohastički proces kod kojega distribucija slučajne varijable X u momentu $t=t_n$ ovisi samo o vrijednosti x_{n-1} procesa u trenutku $t_{n-1} < t$ koji je poznat kao Marakovljev proces. Specijalan slučaj diskretnog Markovljeva procesa, kada se radi o diskretnim parametrima, nazivamo Markovljev lanac i on je osnova HMM modela.

Probabilistička funkcija Markovljeva lanca (Paušc, 1974) jest stohastički proces generiran s dva međuvisna mehanizma: Markovljevim lancem, koji ima konačan skup stanja, i skup slučajnih funkcija, od kojih je po jedna dodijeljena svakom stanju. U diskretnim trenucima vremena, proces se nalazi u nekom stanju i pritom je generiran neki simbol koji odgovara tekućem stanju. U sljedećem trenutku, Markovljev lanac mijenja stanje u skladu s matricom vjerojatnosti promjene stanja. Promatrač sa strane jedino "vidi" izlaz slučajnih funkcija združenih svakom stanju, ali ne može neposredno otkriti stanje Markovljeva lanca. Odavde potiče i naziv "Skriveni" Markovljev lanac (model). Danas je razvijeno više tipova HMM modela, a ovdje ćemo prikazati samo osnovni oblik $M=(Q, A, B)$, gdje su:

$$Q = \{q_0, \dots, q_N\}, \text{gdje je } q_0 \text{ početno a } q_N \text{ završno stanje}$$

$$A = \{a_{ij}\} \text{ skup prijelaza gdje je } a_{ij} \text{ vjerojatnost prijelaza iz stanja } i \text{ u stanje } j.$$

$$B = \{b_{ij}(k)\} \text{ Matrica izlaza: } a_{ij}(k) \text{ označava vjerojatnost emitiranja simbola kada se prelazi iz stanja } i \text{ u stanje } j.$$

Promatrajmo konačni uređeni niz (vektor) pojava:

$$O = O_1 O_2 O_3 \dots O_T \quad \dots \quad (4.1.2-3)$$

gdje je svaka pojava diskretan simbol dobiven iz konačnog alfabetra, a njihova ukupnost predstavlja neku rječ w_i iz skupa riječi W , koje emituje izvor X . Pretpostavimo da postoji V definiranih HMM modela M_1, \dots, M_V . Za svaki model može se izračunati vjerojatnost $\pi_i = P(O|M_i)$ za $1 \leq i \leq V$. Nakon toga rangiramo vjerojatnosti i klasificiramo nepoznatu riječ kao

$$w = w_i \Leftrightarrow \pi_i \geq \pi_j, \quad \text{za } 1 \leq j \leq V.$$

Naravno, prije nego se izračunaju ukupne vjerojatnosti, moraju biti određeni parametri za svaki od V HMM modela M , što se najčešće realizira algoritmom "naprijed-nazad" (Levinson, 1983). Iako je u osnovnoj verziji HMM model namijenjen za prepoznavanje izoliranih riječi, danas je predloženo više uspješnih modifikacija za prepoznavanje kontinuiranoga govora. S aspekta točnosti prepoznavanja DTW i HMM približno su isti, osim što HMM zauzima cca 10 puta

manje memorije računala i zahtijeva oko 20 puta manje računskih operacija (Rabiner et al., 1983).

4. 2 Modeli prepoznavanja govora bazirani na strojnog učenju

Izvorna motivacija za istraživanje područja strojnog (automatskog) učenja bila je potreba za novim načinom programiranja računala ("kriza softverskog inženjerstva") kako bi se skratilo vrijeme obrade sve složenijih informacija te postavio nov odnos na relaciji komunikacije čovjek-računalo. Istraživanje strojnog učenja znatno je pridonijelo boljem razumijevanju prirode procesa učenja i predloženi su funkcionalni modeli zaključivanja i stjecanja novih znanja. Danas postoji mnoštvo klasifikacija i pristupa automatskom učenju (Michalski et al., 1984) npr. na osnovi strategije učenja: učenje memoriranjem (engl. Rote learning), učenje na osnovi rečenog (Learning by Being Told), učenje prema analogiji (Learning by Analogy), učenje na osnovi primjera (Learning from Examples), učenje samostalnim otkrivanjem (Learning from Observation and Discovery); prema formi naučenog znanja: strukturalno (znanja se neposredno mogu interpretirati) i statističko (znanja su kodirana na implicitan način) itd. Mehanizmi predstavljanja znanja u toku učenja također su raznovrsni: parametri algebarskih izraza, stabla odlučivanja, formalne gramatike, produkcijskih pravila, formalna logika, grafovi i mreže, semantički okviri (engl. frames), konfiguracije neuronskih mreža itd.

Detaljnije proučavanje automatskog učenja prelazi okvire ovog rada, a ovdje će biti prikazana dva modela učenja s aspekta moguće primjene u sistemima za prepoznavanje govora (prepoznavanje izoliranih vokala).

4. 2. 1 Eksplisitno učenje

Osnovna karakteristika mehanizama za eksplisitno (strukturalno) učenje jest da je naučeno znanje u obliku razumljivom čovjeku. Ovdje upotrijebljeni algoritam CORAL (Zagoruiko et al., 1985; Miškovic, 1989), spada u klasu induktivnih metoda učenja na osnovi primjera (konceptacija formiranja pojmova), a problem koji rješava može se opisati kao:

ZADANO: Skup $L = \{ l_1, \dots, l_M \}$ od M primjera opisanih skupom od N atributa. Svaki primjer pripada jednoj od K klase.

NAČI: Generalizirano distinkтивno pravilo za zadane primjere koје je upotrebljivo za klasificiranje novih primjera.

Objekt X prikazujemo skupom atributa $X = \{ x_1, \dots, x_N \}$ kojima je pridružen skup mogućih vrijednosti - $\text{DOM}(x_i)$. Ovisno o utjecaju poretku atributa na opis objekata razlikuju se:

- nominalni atributi (redoslijed atributa nije bitan)
- linearni atributi (vrijednosti predstavljaju ureden skup, odnosno prethodno definiran vektor obilježja)

- strukturirani atributi (atributi su parcijalno uređeni, najčešće hijerarhijski)

Algoritam CORAL predviđen je za rad s nominalnim i linearnim atributima. Globalna strategija algoritma je selekcija minimalnog broja informativnih

atributa koji obuhvaćaju što više objekata iste klase i istodobno što je moguće manje objekata iz drugih klasa. Opis klase predstavlja skup konjunktivnih formi od kojih svaka opisuje određen podskup primjera iste klase. Opći oblik distinkтивnih pravila je dakle:

$$(P_1 \text{ and } \dots \text{ and } P_n) \text{ or } \dots \text{ or } (P_z \text{ and } \dots \text{ and } P_{z+k})$$

... (4.2.1-1)

gdje su P binarne konjunkcije oblika:

$$P_i = X_i \in [r_1, r_2] \quad \dots \quad (4.2.1-2)$$

Detalji o postupku formiranja pravila (4.2.1-1) i (4.2.1-2) dani su (Zagoruiko et al., 1985), a ovdje će biti opisani samo ulazni objekti i bit će komentirani rezultati.

U eksperimentu prepoznavanja vokala sudjelovala su 3 muška govornika, koji su 14 puta izgovorili svaki vokal. Nakon digitalizacije (12-bitni A/D konvertor, frekvencija uzorkovanja 10 kHz) izračunata je FFT transformacija (Hammingov prozor) tako da je svaka klasa vokala bila predstavljena s 42 objekta. Radi usrednjavanja spektralne karakteristike, svaki objekt dobiven je kao srednja vrijednost FFT transformacije (32 spektralne vrijednosti) tri uzastopna segmenta trajanja 6.4 ms. Dakle, svaki vokal predstavljen je linearnim atributima:

$$X = [A_1, A_2, \dots, A_{32}] \quad \dots \quad (4.2.1-3)$$

čije su vrijednosti A iznosi energije na frekvenciji:

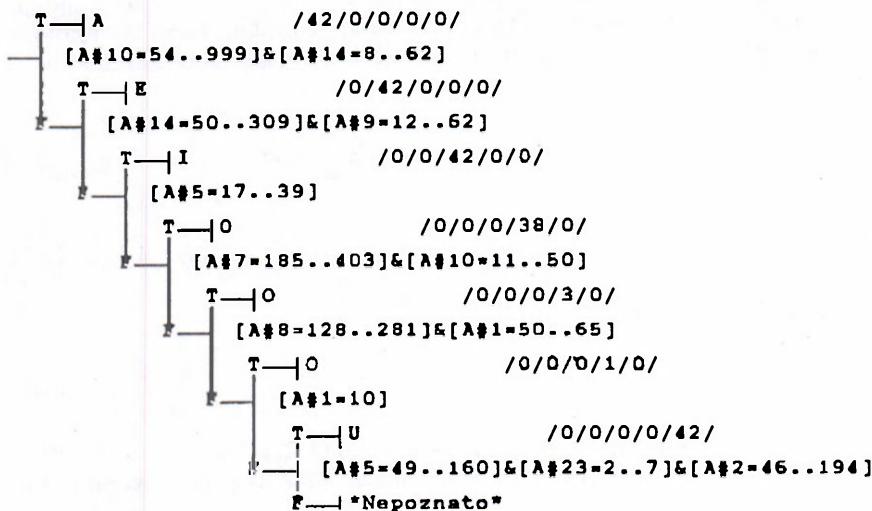
$$A_i = F_i = (i-1) \cdot 5/32 \text{ [kHz]} \quad \dots \quad (4.2.1-4)$$

Na slici 4.2.1.1-1 prikazano je klasifikacijsko stablo neposredno generirano programom CORAL (Mišković, 1989).

Uvjet za granjanje napisani su u razini čvora grananja. Desna kolona pokazuje broj uzoraka po klasama. Npr. dohiveno pravilo klasifikacije za vokal A glasi:

$$(A10 \in [54, 99]) \text{ and } (A14 \in [8..62]) \quad \dots \quad (4.2.1-5)$$

i dovoljno je da jednoznačno klasificira taj vokal što je zapisano u obliku: /42/0/0/0/0/



Sl. 4. 2. 1-1 Klasifikacijsko stablo vokala

Osim konjunkcije koja стоји уз pojedini čvor stabla, redoslijed grananja uključuje и све dodatne uvjete tako да правило за vokal "E" ima sljedeći oblik:

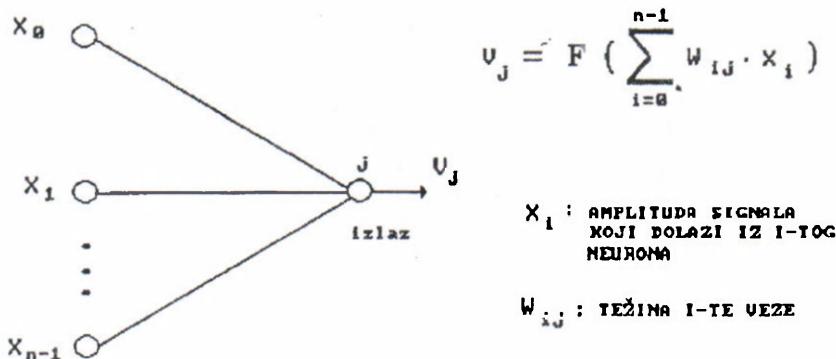
```

(NOT ((A10 ∈ {54, 99})) and (A14 ∈ {8..62}))) and
((A14 ∈ {50, 309}) and (A9 ∈ {12..62})))
... (4.2.1-6)
  
```

Za navedene primjere objekti koji pripadaju klasi vokala "o" svrstani su u tri grupe. U prvu је svrstano 38 objekta a, u drugoj 3, a u trećoj 1. Kao što se vidi iz stabla, klasifikacija јe dijsunktivna, tj. provedena је tako да se klase ne preklapaju (100 % točnost).

4. 2. 2 Implicitno učenje

Implicitno učenje obuhvaća one mehanizme gdje naučeno znanje nije lokalizirano na jednom mjestu, tj. ne može mu se dati fizikalni smisao (interpretacija). Algoritmi koji sekorište nekim od oblika te vrste učenja uglavnom se temelje na mnoštvu elementarnih medusobno povezanih procesora. Ovisno o prirodi modela mreže elementarni procesori u literaturi nazivaju se različito: ćelija, jedinica, neuron, perceptron itd. Topologija veza varira ovisno o upotrebljenom modelu učenja i definiranoj strukturi procesora. Motivacija za definiranje distribuirane obrade znanja jest imitacija rada ljudskog mozga, gdje je prirodni neuron najčešće formaliziran na sljedeći način (Yang et al., 1988):



sl. 4. 2. 2-1 Matematička prezentacija neurona

Neuroni imaju više ulaza (koji predstavljaju dendrite) i jedan izlaz (model za neurit) kojim su vezani za ulaze drugih neurona i šalju impulse aktivacije ili inhibicije. Neuroni koji dolaze u dodir s okolinom nazivaju se ulazno-izlazni (Input-Output) ili vidljivi (visible) dok su oni unutar mreže skriveni (Hidden). Organizacija skrivenih neurona može biti slojevita ili kompaktna ovisno o upotrijebljenom algoritmu učenja. Za slojevitu mrežu najčešće se koristi algoritam s povratnom propagacijom greške (Back Propagation Error) (McClelland i Rumelhart, 1988). Neki modeli uračunavaju i trenutni prag pobudnosti neurona koji se najčešće tretira kao veza s nekim jediničnim nevronom. U ovom radu bit će opisan eksperiment prepoznavanja izoliranih vokala konektivnim modelom poznatim u literaturi kao Boltzmannov stroj (BM-Boltzmann Machine) (Prager, 1988) (Stamenković, 1988.)

BM sastoji se od međusobno povezanih čelija, koje mogu biti u stanju 0 ili 1 (model koji je ovdje upotrijebljen dopušta više od dva stanja, što će biti objašnjeno. Komunikacija s vanjskim svijetom ostvaruje se vidiljivim čelijama, koje imaju istu strukturu kao i skrivene. Globalni parametar mreže jest totalna energija:

$$E = - \sum_{i < j} w_{i,j} s_i s_j + \sum_i b_i s_i \quad \dots \quad (4.2.2-1)$$

gdje su:

w_{ij} - veza između i-te i j-te čelije

s_i - stanje i-te

s_j - stanje j-te čelije

b_i - prag i-te čelije

Ćelije se adaptiraju na okolinu tako što minimiziraju globalnu energiju. Razlika između k-te ćelije kada je ona u stanju 1 i 0 jest:

$$\Delta E_k = \sum_i (w_{ki} s_i) - b_k \quad \dots (4.2.2-2)$$

gdje su:

w_{ki} - veza između k-te i i-te ćelije

s_i - stanje i te ćelije

b_k - prag k-te ćelije

Promjena stanja k-te ćelije najčešće se definira stohastički:

$$P_k(s_k=1) = 1 / (1 + \exp(-\Delta E_k/T)) \quad \dots (4.2.2-3)$$

Varijabla T u gornjem izrazu ima fizikalnu interpretaciju "temperature" na kojoj se nalazi mreža. Mreža uči tako što se prilagođava okolini, koju predstavljaju stohastička funkcija gustoće stanja vidljivih ćelija. U prihvaćnom modelu, vidljive ćelije podijeljene su na dva skupa: I - ulazne ćelije i O-izlazne ćelije. U toku učenja, stanja ulaznih ćelija odredena su ulaznim vektorom (koji parametarski predstavlja izgovoren vokal), a na izlazne ćelije postavlja se vektor koji predstavlja kodirani odgovor. U toku prepoznavanja za nepoznati ulazni vektor očekuje se distribucija stanja izlaznih ćelija koja opisuje izgovorenu vrstu vokala. Jedan ciklus učenja (LC - Learning Cycle) sastoji se od tri koraka:

1. Određivanje p.
2. Određivanje p'
3. Ažuriranje veza u funkciji od p i p'.

U prvom koraku a ulazne vidljive ćelije postavi se FFT vektor, dok su izlazne slobodne (bez forsiranja odgovora). BM se tada "zagrije" i "ohladi" do termičke ravnoteže te izračuna vjerojatnost p_{ij} da se i-ta i j-ta ćelija nalaze u stanju 1. Nakon toga, na izlazne ćelije prilikujući se dogovor i ponavlja postupak. U trećem koraku ažuriraju seveze u funkciji od izračunate p i p'. Budući da je u realiziranom modelu (radi smanjenja broja ćelija) dopušteno da ćelija ima 16 stanja, vjerojatnosti p i p' izračunavaju se na sljedeći način:

$$p_{ij} = \sum_{\text{trening}} s_i s_j \quad \dots (4.2.2-4)$$

$$p'_{ij} = \sum_{\text{prepoznavanje}} s_i s_j \quad \dots (4.2.2-5)$$

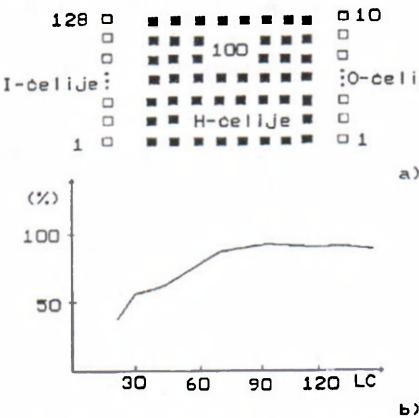
Detaljan opis algoritma učenja dan je u (Stamenković, 1988d) a ovdje ćemo još prikazati način obrade vokala i komentirati rezultate.

Bazu signala sačinjavalo je 20 uzoraka za svaki vokal (3 muška i 2 ženska govornika koji su izgovorili vokale po 4 puta). Frekvencija uzorkovanja bila je 10 KHz sa 8-bitnim A/D konvertorom. Centralni segment vokala u trajanju 25.6 ms automatski je ekstrahiran i podvrgnut FFT transformaciji. Amplitude spektra dobivene FFT transformacijom normalizirane su od 0 do 15 (16 razina) i predstavljale su element 128-dimenzionalnog ulaznog vektora za BM. Definirani vektori za kodiranje vokala bili su sljedeći:

vokal	vektor
I	0000110000
E	0001001000
A	0010000100
O	0100000010
U	1000000001

sl. 4. 2. 2-2 Kodirani izlazni vektori vokala

Vokali su kodirani prema kriteriju razdvojenosti formanata (prvih 5 bita) i prema poziciji momenta spektralne energije (drugih 5 bita). Struktura upotrijebljene BM i brzina učenja prikazani su na slici 4. 2. 2-3



sl. 4. 2. 2-3 Upotrijebljena BM a) Brzina učenja b)

BM u eksperimentu imala je 128 ulaznih ćelija čime je kodiran normaliziran (na 16 diskretnih razina koje predstavljaju stanja ulaznih ćelija) FFT spektar (128 točaka), 100 skrivenih i 10 izlaznih ćelija. Skrivene ćelije bile su povezane međusobno, dok su vidljive (ulazne i izlazne) vezane samo za skrivene.

Upotrijebljen konktivni model pokazao je zadovoljavajuće rezultate u prepoznavanju kvazistacionarnih segmenta govora. Osim zamjerkre da se ne vidi na osnovi čega je donešena odluka o vrsti vokala, nedostatak BM (kao i svih konktivnih modела) predstavlja kompleksnost algoritma jer jedan ciklus učenja na PC AT računalu (8 MHz) trajao je oko 20 minuta.

4. 3 Fonetsko-lingvistički modeli

Za razliku od inženjersko-tehničkog pristupa prepoznavanju govora kod koga se govorni signal isključivo tretira kao realizacija nekog slučajnog procesa ili kao specifičan klasifikacijski postupak, fonetsko-lingvistički model implicitno uključuje obradu koja se proteže kroz više razina. Ako primijenimo tradicionalnu teoriju percepcije govora, tada možemo definirati 5 razina automatske obrade govora, koje su prisutne u fonetskom lancu (Lincard, 1977):

1. fizička razina: Govor se prenosi u obliku longitudinalnih valova i uzrokuje promjenu pritiska na ulaznom senzoru (mikrofonu), koji te promjene pretvara u naponske impulse. Impulsi se pojačavaju, filtriraju, digitaliziraju, a nakon toga izračunavaju se parametri obilježja.

2. fonetska razina: Na osnovi definirane metrike klasificiranja govorni segmenti svrstavaju se u pojedine fonetske grupe glasova, koje nužno ne moraju biti disjunktnic.

3. leksička razina: Grupirani fonetski elementi prolaze kroz kontekstne provjere (npr. sonotaktička pravila) i provjere o mogućim kombinacijama nizova glasova (postojanje riječi u rječniku).

4. sintaksička razina: Nakon što se postavi lista mogućih riječi sintaksičkom se analizom provjerava koraktnost ponudenih sintaksičkih struktura.

5. semantička razina: Na osnovi prozodijskih elemenata (akcent, intonacija itd.) i semantičkog modela razumijevanja jezika određuje se globalna priroda analizirane govorne poruke.

Pojedini autori (Lea, 1980) definiraju i šestu razinu govorne komunikacije vezanu za pragmatsku prirodu govornog priopćavanja. Međutim, zbog izuzetne složenosti pragmatske informacije, koja je zapravo skupnost dotadašnjeg iskustva i broj percpcija svih čula, ne postoji adekvatna formalna interpretacija te razine. Zbog toga je nećemo razmatrati. Iz istih razloga semantička razina bit će analizirana samo djelomice.

Obrada govora na fizičkoj i (djelomice) fonetskoj razini preklapa se s već prikazanim načinima segmentiranja i izdvajanja vektora obilježja signala. Međutim, leksička i slijedeće razine ne odnose se više na fizičke pojave, nego na manipulaciju simbolima. Zbog toga se matematički aparat, kojim se definiraju parametri modela na tim razinama u mnogome razlikuje od onog s prve dvije razine. Za opis simboličkih razina najčešće se upotrebljava teorija formalnih jezika (FJ) (Aho i Ullman, 1972) čije su osnovne definicije dane u sljedećem poglavlju. Nakon što su definirani uvodni pojmovi teorije FJ, u poglavlju 4. 3. 2 prikazana je hijerarhijska segmentacija govora do fonetske razine. Model sim-

boličke obrade na leksičkoj i sintakšičkoj razini prikazan je u poglavlju 4. 3. 3, gdje je opisan APG sistem za prepoznavanje povezanoga govora, koji se kao akustičko-sonetski procesor koristi načinom segmentiranja iz poglavlja 4. 3. 2.

4. 3. 1 Osnovne postavke formalnih jezika

Polazni entitet u teoriji FJ jest znak. Međutim, za razliku od mesta koji znak ima u semiologiji (tj. gdje se znak uvijek promatra kroz proces semioze - odnosa između nosioca znaka, interpretanta i interpretatora (Moris, 1975), ovdje uzimamo samo intuitivnu predodžbu o njemu. To znači da se pojam znaka tretira jednako kao i npr. pojam točke u Euklidovoj geometriji. Najčešće, znaci predstavljaju grafeme nekog jezika, brojeve itd. Primjerice, znakovici jesu: 4, 7, (, a, d, , =, _, ?, x, y, . Proizvoljan konačan skup znakova x nazivamo alfabet i označavamo ga :

$$A = \{x_1, x_2, \dots, x_n\}.$$

Napišemo li znakove jedan do drugog tako da čine cjelinu, tada govorimo o simbolu (u literaturi se često susreću i nazivi string, riječ, rečenica koji će se i ovdje ravnopravno upotrebljavati). Broj znakova u simbolu predstavlja njegovu dužinu, tj.

$$|\alpha| = |x_1 x_2 x_3 x_4 \dots x_n| = n$$

Prazan simbol (string) jest simbol koji ne sadrži nijedan znak. Njegova je dužina 0 a označavat ćemo ga s λ tj. $|\lambda| = 0$.

Analogno potencirajući uvodi se skraćeni zapis repeticije znakova unutar stringa npr: $a^0 = \lambda$, $aaa = a^3$, $abbbbc = ab^4c$. Kombiniranje stringova dozvoljava nam relaciju konkatenacije.

DEF 4. 3. 1-1: konkatenacija stringova

Neka su i stringovi nad alfabetom A tj.

$$\alpha = x_1 x_2 x_3 \dots x_n .$$

$$\beta = y_1 y_2 y_3 \dots y_m .$$

Konkatenacija stringova i jest string g dobiven na sljedeći način:

$$\gamma = \alpha \beta = x_1 x_2 \dots x_n y_1 y_2 \dots y_m = z_1 z_2 \dots z_{n+m}$$

Za razliku od alfabeta koji je konačan skup, skup svih stringova nad alfabetom, svakako je beskonačan. Zvjezdica iznad oznake skupa npr. $L \leq A^*$ predstavljaće oznaku za tzv. zatvarač alfabetra, skup koji sadrži sve simbole (uključivši i λ) nad alfabetom A npr.:

$$A = \{a\}, \quad A^* = \{\lambda, a, aa, aaa, aaaa, \dots\} = \{a^n, n \geq 0\}$$

Formalni jezik L sačinjavaju rečnicice iz skupa A^* , što znači da je $L \subseteq A^*$. String α , koji je sadržan unutar stringa β , nazivamo podstring stringa β .

U toku simboličke obrade jedan niz znakova (rečenica) preoblikuje se u drugi. Od mnogih mehanizama preoblike spomenimo FST pretvarač (Finite State Transducer), koji će biti upotrijebljen na leksičkoj razini obradac govora (poglavlje 4. 3. 3):

DEF 4. 3. 1-2 FST pretvarač konačnog stanja

Deterministički pretvarač konačnog stanja jest 6-orka

$M = \{Q, \Sigma, \Delta, \delta, q_0, F\}$ gdje su:

$Q = \{q_0, q_1, q_2, \dots, q_n\}$	- konačni skup stanja
$\Sigma = \{a_1, a_2, a_3, \dots, a_m\}$	- ulazni alfabet
$\Delta = \{b_1, b_2, b_3, \dots, b_k\}$	- izlazni alfabet
$\delta : Q \times (\Sigma \cup \{\lambda\}) \rightarrow Q \times \Delta^*$	- funkcija prijelaza
$q_0 \in Q$	- početno stanje
$F \subseteq Q$	- skup završnih stanja

Na osnovi ulaznog simbola i internog stanja konačni pretvarač prelazi u slijedeće stanje i emitira novu etiketu (simbol). Obrada ulaznog niza etiketa obavila se u toku smjocene konfiguracija automata (q, x, y) , gdje su:

- 1) $q \in Q$, tekuće stanje
- 2) $x \in \Sigma^*$, preostali niz etiketa
- 3) $y \in \Delta^*$, emitirana etiketa

Definiramo relaciju \vdash (ili samo \vdash) ako se pretvarač podrazumijeva nad konfiguracijama pretvarača koju čitamo "prelazi u". Za sva stanja $q \in Q, x \in \Sigma^*$ takva da je $\delta(q, a) = (r, z)$ pišemo:

$$(q, ax, y) \vdash (r, x, yz)$$

Kažemo da je y izlaz za x ako je $(q_0, x, \lambda) \xrightarrow{*} (r, \lambda, y)$ pri $r \in F$. Zvjezdica iznad oznake relacije označava ponavljanje proizvoljnog broja puta promjene konfiguracije pretvarača.

U teoriji FJ kažemo da je rečenica sintakški ispravna ako pripada jeziku L i obrnuto. Budući da je jezik L obično beskonačan ili veoma velik skup, nužno je definirati neki konvergirajući mehanizam koji će provjeravati pripadnost neke rečenice jeziku. Jedno rješenje ovog problema jest formalizirana generativna gramatika Chomskog :

DEF 4. 3. 1-3: frazno-strukturirana gramatika $G = (N, P, S)$ je četvorka :

- 1) $N = \{ n_1, \dots, n_k \}$ - skup neterminalnih simbola
- 2) $\Sigma = \{ G_1, \dots, G_m \}$ - skup terminalnih simbola $N \cap \Sigma = \{ \}$
- 3) P - skup produkcionalnih pravila
 $P \subseteq (N \cup \Sigma)^* N (N \cup \Sigma)^* x (N \cup \Sigma)^*$
 $P = \{ (u, v) \mid u \in (N \cup \Sigma)^* N (N \cup \Sigma)^*, v \in (N \cup \Sigma)^* \}$
- 4) $S \in N$ - startni simbol

Elementi iz skupa N nazivaju se neterminalni simboli ili neterminali (ponkad se susreće naziv i lingvističke varijable), a elementi iz skupa Σ su terminalni simboli ili terminali (riječi). Treba naglasiti da su skupovi terminala i neterninala disjunktni. Skup P predstavlja skup produkcija (pravila) ili produkcija. Umjesto tradicionalne oznake za uređeni par, elementi (α, β) iz skupa P obično se prikazuju u formi produkcija :

$\alpha \rightarrow \beta$

Gornji prikaz čitamo : "alfa se producira u beta". Produciju oblika $\alpha \rightarrow \lambda$ nazivamo prazna produkcija ili λ -produkcija. Ovisno o obliku produkcija pravila gramatike su svrstane u 4 grupe (Aho, 1972) a najčešće su tzv. beskontekstne gramatike (CF, Context Free) koje imaju na lijevoj strani produkcije samo jedan neterminalni simbol.

Posljednji element gramatike S jest tzv. startni simbol od kojeg se polazi u procesu generiranja jezika. Startni element uvijek je neterminal. Za jezik L , koji je opisan gramatikom G , kažemo da je generiran gramatikom G i zapisujemo $L=L(G)$.

Dakle, rečenica α pripada jeziku L ako se može generirati gramatikom G . Generiranje jezika svodi se na smjenjivanje neterminalnih simbola drugim neterminalnim ili terminalnim simbolima. Sekvencu sukcesivne zamjene simbola nazivamo niz izvođenja dužine M , gdje je M broj zamjenjivanja simbola. Ako se prilikom svake zamjene zamjenjuje prvi s lijeva neterminalni simbol, za niz izvođenja kažemo da je derivacija s lijeva. Prijelaz niza simbola α u niz simbola α' označavamo $\alpha \Rightarrow \alpha'$. Primjerice, neka je dana gramatika $G = (\{ \sigma, \alpha, \beta, \delta \}, \{ a, b, c, d \}, P, \sigma)$ sa skupom produkcija: $P = \{ \sigma \Rightarrow a\alpha, \alpha \Rightarrow \beta\alpha, \alpha \Rightarrow \beta, \beta \Rightarrow dc, \beta \Rightarrow bb, \gamma \Rightarrow cc, \alpha \Rightarrow \alpha \}$. Niz izvođenja $\alpha \Rightarrow a\alpha \Rightarrow a\beta\alpha \Rightarrow a\beta\beta\alpha \Rightarrow a\beta\betadc$

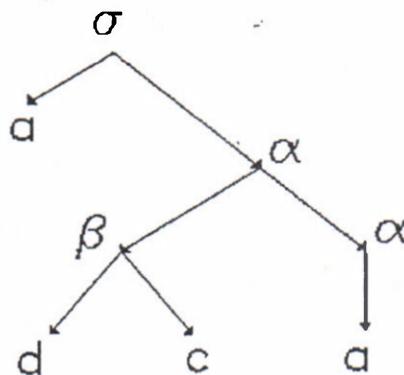
$$\sigma \Rightarrow a\alpha \Rightarrow a\beta\alpha \Rightarrow a\beta\beta\alpha \Rightarrow a\beta\betadc$$

Derivacija s lijeva grafički se prikazuje stablom izvodjenja:

DEF 4. 3. 1-4: stablo izvodjenja. Neka je dana CF gramatika $G = (N, \Sigma, P, S)$. Stablo izvodjenja nazivamo stablo (D, r) koje zadovoljava sljedeće uvjetc:

- 1) Svaki vrh označen je simbolom iz $N \cup \Sigma$
- 2) Korijen stabla označen je sa S .
- 3) Ako je vrh n označen s $A \in N$, a vrhovi $n_1 \dots n_k$ su direktni sljedbenici od n i označeni $X_1 \dots X_k$ respektivno, tada je $(A, X_1 \dots X_k) \in P$.
- 4) Ako je vrh n označen sa $A \in \Sigma$, tada je $I_S(n) = 0$.

Primjerice, stablo izvodjenja za rečenicu iz prošlog primjera je:



sl. 4. 3. 1-1 Stablo izvodjenja za rečenicu $\alpha = adca$

Budući da definicija 4. 3. 1-4 jednoznačno uspostavlja vezu između produkcija iz skupa P i strukture stabla izvodjenja, to znači da za zadano stablo izvodjenja možemo odrediti produkcije gramatike te niz izvodjenja koji generira danu rečenicu.

4. 3. 2 Model automatske segmentacije govora na fizičko-fonetskoj razini

Automatska segmentacija govora koja bi uključivala lingvističke razine obrade govora mora biti vezana za određeni diskurs govora, koji se segmentira (definiranje leksike, sintakse, semantike). Budući da se na ovom mjestu daje samo koncepcija hijerarhijske obrade a ne specijaliziran sistem za segmentiranje konkretnog korpusa, hijerarhijska organizacija segmentiranja može se uspostaviti samo na fizičkoj i fonetskoj razini. Jedna moguća hijerarhija segmentiranja na tim razinama je sljedeća:

- A. segmentiranje prema kriteriju prisutnosti - - odsutnosti govora
- B. segmentiranje prema fonetskim kategorijama glasova
- C. segmentiranje unutar fonetskih kategorija

Segmentiranje se sastoji u dodjeljivanju nekog simbola (etikete) govornom segmentu s koji počinje u trenutku t i traje sekundi. Definirajmo sada alfabet etiketa kojima će se etiketirati govorni segmenti prema gornjoj hijerarhiji:

$$E = \{ ., \#, D, G, S, X, M, F, V, *, a, e, i, o, u \} \quad \dots \quad (4.3.2-1)$$

Fizikalno značenje definiranih etiketa dano je u tabeli 4.3.2-1.

Etiketa	fizikalno značenje
.	časina, odsustvo govornog signala
#	prišustvo signala
G	zvučni glasovi male energije (b,d,g)
S	slbilanti, frikativi male energije (s,c)
D	zvučni prekidni glasovi (d2,d)
X	bezvučni kompaktni glasovi (š,č,č)
F	bezvučni glasovi srednje energije (f,h)
M	nazali (m,n,nj)
V	vokali (a,e,i,o,u)
*	nedefiniran vokalizirani tranzijent
a e i o u	vokali (a,e,i,o,u)

tbl. 4.3.2-1 Etikete i njihova interpretacija

Kod interpretacije etiketa treba biti obazriv, jer se ne smije zaboraviti da bepsrijekorna klasifikacija govornih segmenta nije moguća zbog kontinuirane prirode govora. Zato će predložene etikete pouzdano korelirati samo s općim karakteristikama govornog segmenta, koji se promatra, ali ne nužno i s pojedinim fonemima. Primjerice, zbog dezorganizacije glasova pri kraju izričaja treba očekivati etikete koje teže obezučavanju i manjim iznosima energije.

Radi jednostavnijeg matematičkog modela te i zbog preporuka (Schafer i Markel, 1979) izabran je ekvidistantni segment govora kao jedinicu segmentiranja s trajanjem $\tau = 10\text{ms}$. Znači, govorni signal s od N uzoraka predstavljamo kao zbroj disjunktnih segmenta jednakog trajanja, tj. kao:

$$s = \sum_t s_{[t, t+\tau]} \quad \dots \quad (4.3.2-2)$$

Niz etiketa segmenta možemo sada definirati kao rečnicu nekog jezika L , odnosno:

$$\alpha = \alpha_1 \alpha_2 \dots \alpha_j \dots \alpha_n \in E^* \quad \dots \quad (4.3.2-3)$$

Na prvoj razini segmentiranja (razina A) odredujemo da li t-ti segment govora predstavlja govor ili tišinu. Segment s će se etiketirati etiketom ako su zadovoljene nejednadžbe :

$$E_t = \frac{1}{100} \sum_{i=1}^{100} |s(t+i)| < A_1 \cdot E_o \quad \dots \quad (4.3.2-4)$$

$$ZC_t < A_2 ZC_o \quad \dots \quad (4.3.2-5)$$

U izrazu 4.3.2-5 oznake E_o i ZC_o predstavljaju srednju energiju šuma i broj prolaza signala kroz nulu, respektivno, dok su E_t i ZC_t pripadne vrijednosti vezane za govorni segment koji počinje u trenutku t (i traje 10 ms, odnosno zahvata narednih 100 uzoraka). Konstante A_1 i A_2 ovise o načinu digitalizacije (broj bita A/D konvertora, karakteristike ulaznog filtra itd) i uvjetima okoline. Segmentima koji nisu etiketirani s., dodjeljuje se # (oznaka prisustva govornog signala). Alfabet etiketiranja na prvoj razini jest:

$$\cdot \quad E_1 = \{ ., \# \} \subset E \quad \dots \quad (4.3.2-6)$$

Etiketiranje na višim razinama zahtijeva precizniji opis govornog segmenta. Zato svaki segment s opisujemo odabranim parametrima obilježja koje grupiranci iskazujuemo u formi vektora obilježja:

$$V_t = [x_1, x_2, x_3, x_4] \quad \dots \quad (4.3.2-7)$$

Definirani elementi vektora obilježja su sljedeći :

x_1 - kratkovremenska energija prema (3-4)

x_2 - odnos snage višeg i niže opsega spektra

x_3 - broj prolaza kroz nulu prema (3-8)

x_4 - kvocijent kvadrata brojeva prolaza kroz nulu
i kratkovremenske energije

Elementi vektora x i \hat{x} izračunavaju se na sljedeći način :

$$x_2 = 1000 \frac{EH}{EL} = 1000 \frac{\sum_{j=5}^7 FFT(j)}{\sum_{j=2}^4 FFT(j)} \dots (4.3.2-8)$$

$$x_4 = 1000 \frac{ZC^2}{E^2} \dots (4.3.2-9)$$

gdje $FFT(k)$ predstavlja k-tu komponentu FFT spektralnog vektora od 8 točaka. Prosječne vrijednosti elemenata x_1, \dots, x_4 za sve glasove hrvatskosrpskog jezika, osim zabezućne plozive (p, t, k) prikazane su na tabeli 4.3.2-2, gdje se pregledno vide globalne karakteristike pojedinih glasova. Primjerice, vjerojatno će zvučni glasovi b, d, g imati mali broj prolaza kroz nulu zbog izrazitog spektra u nižim frekvencijama i zbog dugog osnovnog perioda. Iz istih razlog, ali s općenim vrijednostima, izdvajaju se šuškavi konsonanti č, š, ē itd. Kategorizacija tipa zvučni/bezvručni se za najveći broj glasova može ostvariti na osnovi kratkovremenske energije i odnosa energija u gornjem i donjem dijelu spektra. Budući da se vrlo malo glasova samo prema jednom kriteriju izrazito razlikuje od drugih glasova, pouzdanija i preciznija kategorizacija može se sprovesti samo na osnovi kombinacije elemenata ($x_1 \dots x_4$).

Formalizirajmo sada drugu razinu segmentacije, odnosno specificirajmo alfabet etiketa i uvjete etiketiranja. Dakle, na drugoj razini segmentacije (razina B) etikete iz skupa E transformiramo u etikete iz skupa $E = \{ D, G, S, X, M, F, V, *, - \}$. Etikete E segmenata razine A bile su dužine 1, jer je odluka o prirodi segmenta S_τ isključivala drugu (prisustvo/osustvo govora). Međutim, na razini B etiketa S_τ bit će iz skupa E_2^* i predstavljati kompleksniji opis prirode govornog segmenta S_τ . Etiketa β_τ dobiva se konkatenacijom mogućih elementarnih etiketa

$$\beta_\tau = b_1 b_2 \dots b_7 \quad b_i \in E_2 \dots (4.3.2-10)$$

Uvjet $\psi_x(\tau)$ da bi se govornom segmentu koji počinje u trenutku τ i kojem je na prethodnoj razini etiketiranja (razina A) dodijeljena etiketa #, pridružila elementarna etiketa x, definiramo na sljedeći način :

$$\begin{aligned} \Psi_x(\tau) : & (E_{\min} < E_\tau) \wedge (E_\tau < E_{\max}) \wedge \\ & (EHL_{\min} < EHL_\tau) \wedge (EHL_\tau < EHL_{\max}) \wedge \\ & (ZC_{\min} < ZC_\tau) \wedge (ZC_\tau < ZC_{\max}) \wedge \\ & (ZCE_{\min} < ZCE_\tau) \wedge (ZCE_\tau < ZCE_{\max}) \end{aligned} \dots (4.3.2-11)$$

E	EH/EL	ZC	ZC^2/E^2	glas
684.40	7.35	18.57	1.24	a
53.98	10.80	5.50	11.43	b
24.63	388.31	24.67	981.60	c
97.16	3986.92	42.22	254.02	č
69.17	5780.00	48.00	625.78	č
51.39	23.72	6.81	20.36	d
118.30	482.41	29.50	94.76	dž
74.67	840.52	17.33	145.61	đ
402.22	39.61	11.47	0.99	e
86.32	42.74	14.80	49.50	f
56.22	20.19	8.50	27.62	g
155.42	14.01	25.61	68.52	h
243.11	346.72	15.36	5.26	i
115.88	20.20	7.02	5.54	j
190.48	2.59	9.50	2.99	l
93.90	53.23	9.75	14.62	lj
85.43	20.52	11.00	16.77	m
80.20	14.85	8.94	13.34	n
73.45	31.54	10.44	45.27	nj
641.51	6.03	13.59	0.57	o
349.95	5.22	14.67	3.26	r
63.82	296.74	20.20	169.06	s
126.09	1808.79	43.87	152.78	š
383.27	4.62	8.26	0.58	u
145.38	11.80	13.13	13.89	v
114.59	53.62	9.36	8.21	z
97.96	16.76	15.63	32.53	ž

gdje su : E_r , EHL_r , ZC_r i ZCE_r vrijednosti elemenata vektora obilježja prema 4. 3. 2-7 respektivno (govornog segmenta koji počinje u trenutku). Granične vrijednosti (E_{\min} , E_{\max} , EHL_{\min} , EHL_{\max} , ZC_{\min} , ZC_{\max} , ZCE_{\min} , ZCE_{\max}) dobivaju se višestrukim mjerljem etalona koji su chstrahirani "ručnim" segmentiranjem (12 bitni AD/DA, frekvencija uzorkovanja 10 KHz).

Postupak etiketiranja na razini B možemo interpretirati kao prevodenje jezika $L_1 \in E_1^*$ u $L_2 \in E_2^*$.

Posljednja razina etiketiranja (razina C) ovog modela uključuje klasificiranje unutar fonetskih kategorija. Zbog mnogih utjecaja na način izgovora i oblik govora (djelomično popisanih u poglavlju 2) na ovoj razini nij moguće pouzdano klasificirati sve glasove, pa je nužno odabrati određene podskupovne kategorije. U literaturi se uglavnom navode uspješna prepoznavanja izdvojenih vokala (Stamenković, 1981; Prager, 1988) pa su vokali i ovdje uzeti kao fonetska kategorija, ali će prepoznavanje biti unutar povezanoga govora. Dakle, segmentiranje na toj razini jest transformacija etiketa V u neku od etiketa iz skupa $E_3 = \{ a, e, i, o, u \}$ odnosno prevodenje iz jezika E_2 u jezik $\{ \{ E_2 \cup \{ a, e, i, o, u \} \} / \{ v \} \}^*$. Za govorni segment etiketiran sa V izračunava se 32-kanalna FFT transformacija, tj. iz segmenta s izuzima se prvi 64 uzoraka. Prije izračunavanja FFT uzorci se množe Hammingovim prozorom (izraz.3-10). Odluka o tipu vokala (a, e, i, o, u) donosi se na osnovi minimalne udaljenosti definirane metrike prema položaju formanta i prema globalnoj spektralnoj razlici. S obzirom na inherentnu frekvencijsku varijabilnost vokala, ne mogu se uspješno primijeniti linearne metrike oblika :

$$D(Y_r, Y_x) = \sum_i |Y_r(i) - Y_x(i)|^m \quad \dots \quad (4.3.2-12)$$

nego je nužno dopustiti određeni frekvencijski pomak dužine k između referentnog $Y_r(i)$ i nepoznatog elementa $Y_x(i+k)$ (vidi poglavlje 4. 1. 1). Ovdje primijenjeno klasificiranje vokala realizira se u dvije faze :

I - određivanje mogućih vokalskih kandidata

II - selekcioniranje na osnovu najmanje distance

Dakle, za segment $S_{[t,t+\tau]}$, koji je na razini B označen etiketom V, izračunava se FFT transformacija, koju prikazujemo vektorom :

$$Y = \langle y_1, \dots, y_{32} \rangle \quad \dots \quad (4.3.2-13)$$

Iz dobivenog spektralnog vektora izračunava se energija donjeg E_L i gornjeg E_H dijela spektra:

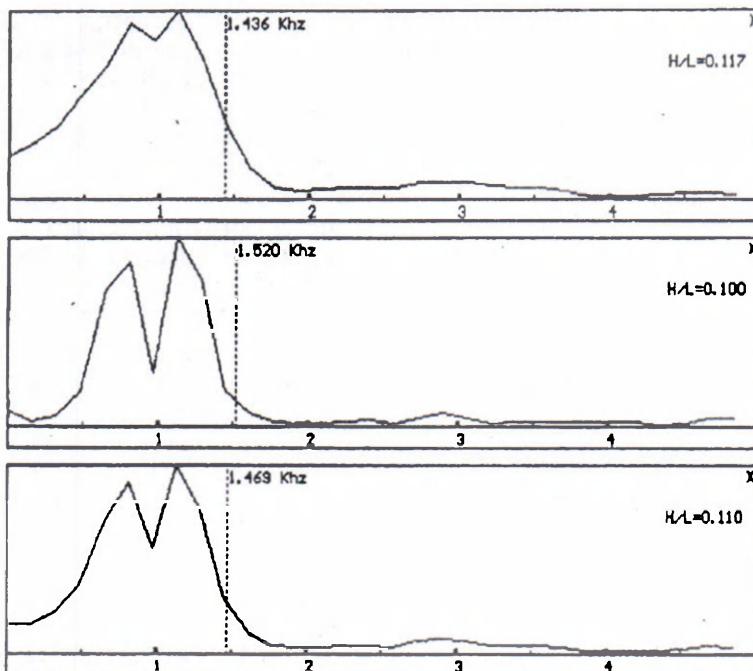
$$E_L = \sum_{j=1}^{16} Y_o(j) \quad \dots \quad (4.3.2-14)$$

$$E_H = \sum_{j=17}^{32} Y_o(j) \quad \dots \quad (4.3.2-15)$$

gdje je Y_o normalizirana vrijednost spektralnog vektora :

$$Y_o(i) = Y(i) / \max_{n=1}^{32} |Y(n)| \quad \dots \quad (4.3.2-16)$$

S obzirom na to da je odabrana širina prozora segmentiranja 100 uzoraka (10 ms pri $F_u = 10 \text{ KHz}$), radi preciznijeg izračunavanja, vektor Y zapravo predstavlja srednju vrijednost vektora Y_1 i Y_2 , koji se dobijaju nakon FFT analize 1..64 (Y_1) i 32..96 uzoraka (Y_2) etiketiranog segmenta. Primjeri izračunatih vektora Y_1 , Y_2 i Y_o za vokal "a" prikazani su na slici 4.3.2-1.



sl. 4.3.2-1 Normalizirani spektralni vektori vokala "a"

a) Y_1 b) Y_2 c) Y_o

U fazi I određuju se vokali-kandidati na osnovi odnosa E_H i E_L . Da bi j-ti vokal bio kandidat, mora biti zadovoljen sljedeći uvjet :

$$E_{HL_{min}}(j) \leq \frac{E_H}{E_L} \leq E_{HL_{max}}(j) \quad \dots \quad (4.3.2-17)$$

Iznosi $E_{HL_{min}}$ i $E_{HL_{max}}$ dobiveni su na osnovi izmjerenih vrijednosti referentnih sgemenata vokala. Da bi se smanjio utjecaj pogreške klasificiranja u

slučajevima jakog koartikulacijskog efekta, uvjet 4. 3. 2-17 oslabljuje se tako da se dopušta prekoračenje definiranih granica $E_{HL\min}$ i $E_{HL\max}$ s vjerojatnošću :

$$p(j) = \frac{1}{4} e^{-\left(\frac{E_{HL\min}}{E_H/E_L}\right)} \quad \dots \quad (4.3.2-18)$$

$$p(j) = \frac{1}{4} e^{-\left(\frac{E_H/E_L}{E_{HL\max}}\right)} \quad \dots \quad (4.3.2-19)$$

Nakon određivanja mogućih K ($K \leq 5$) kandidata vokala, izračunava se globalna minimalna distanca referentnih vokala i tekućeg segmenta (faza II) :

$$D(Y_j, Y_o) = \sum_{i=p}^q d(Y_j(i), Y_o(i)) \quad \dots \quad (4.3.2-20)$$

Lokalna distanca $d(R(i), X(i))$ elementa referentnog vektora $R(i)$ i ispitivanog $X(i)$ definirana je na sljedeći način :

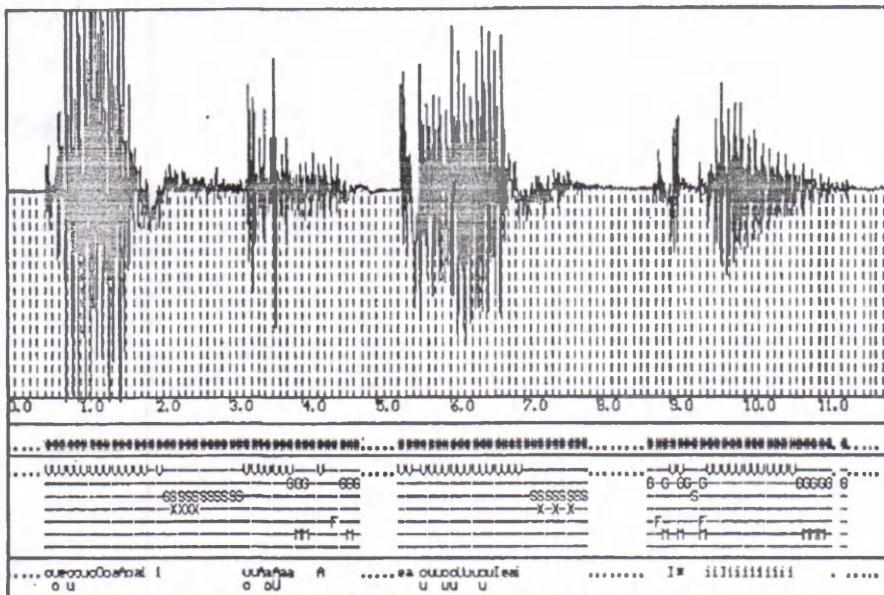
$$d(R(i), Y(i)) = \left[\min \{ |X(i)-R(i)|, |X(i)-R(i-1)|, |X(i)-R(i+1)| \} \right]^2 \quad \dots \quad (4.3.2-21)$$

Da bi se ocjenila točnost načina klasificiranja, svaki je vokal bio izgovoren 100 puta (muški govornik). Dobiveni rezultati prikazani su na donjoj slici u obliku "matrice konfuzije" :

	A	E	I	O	U
A	98	1	1	0	0
E	1	97	2	0	0
I	0	2	98	0	0
O	1	0	0	97	2
U	0	0	0	2	98

tbl. 4. 3. 2-3 Uspješnost prepoznavanja vokala

Srednja točnost prepoznavanja s referentnim uzorcima istog govornika bolja je od 97%. Na slici 4. 3. 2-2 prikazan je proces segmentiranja govora na fizičkoj i fonetskoj razini prema opisanom modelu.

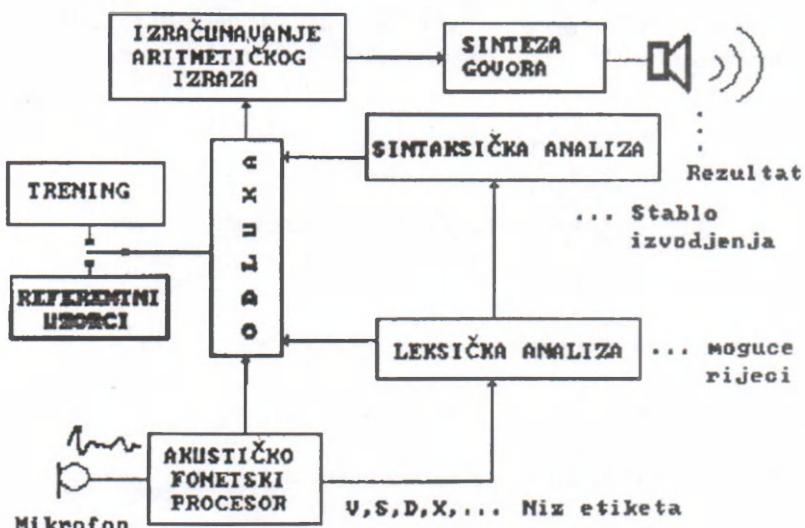


sl. 4. 3. 2-2 "Osam plus tri" (N=12000 uzoraka)

4. 3. 3 Primjer APG sistema govora baziranog na lingvističkom pristupu prepoznavanja govora

U ovom poglavlju prikazan je sistem za automatsko prepoznavanje povczanoga govora za unaprijed određenog govornika (engl. continuous speech speaker dependent recognition system). Definirani vokabular predstavljaju jednoznačnost brojevi ($0, \dots, 9$) i osnovne aritmetičke operacije ($+, -, *, /$). Funkcionalna shema sistema dana je na slici 4.3.3.-1.

Na slici se uočavaju dvije faze rada : a) uvježbavanje b) prepoznavanje). U fazi uvježbavanja govornik čita predviđene riječi nakon čega se formira datoteka referentnih obilježja. U fazi prepoznavanja pronalazi se najmanja distanca u odnosu prema referentnim parametrima i na osnovi nje donosi odluka o prepoznatoj poruci. Međutim, budući da se radi o prepoznavanju povezanoga govora, definirana metrika je kompleksna i hijerarhijski se proteže kroz fonetsku, leksičku i sintaksičku razinu analize govornog signala.



sl. 4. 3. 3-1 Opća slika sistema

Prva faza (akustičko-fonetska) prepoznavanja govora jest obrada signala iz mikrofona u akustičko-fonetskom procesoru, koji segmentira izgovorenu poruku na vremenske intervale od 10 ms i etiketira izdvojene segmente na način opisan u prethodnom poglavlju. Poslije etiketiranja slijedi faza leksičke analize. Na toj razini etikete se grupiraju i transformiraju u liste mogućih riječi (prema definiranom rječniku). Pripremljene alternative dalje se podvrgavaju sintaksičkoj analizi nakon čega se formira stablo izvodjenja, koje predstavlja sintaksu izgovorene poruke (aritmetički izraz). Posljednja faza je izračunavanje izraza, a rezultat se iskazuje i sintetiziranim (digitaliziranim) govorom.

Leksička obrada je prva razina simboličke obrade koja se ne oslanja na fizički govorni signal nego na izdvojeni parametarski opis (u ovom slučaju - etikete). Predobradu leksičke analize sačinjava grupiranje etiketa dobivenih na fonetskoj razini u određene skupine koje predstavljaju pojedine glasovne kategorije ili konkretnе foneme.

Prepoznati fonemi dalje se grupiraju u riječi i provjeravaju postoje li u vokabularu odgovarajući ekvivalenti. Definirani vokabular V jest skup koji sačinjavaju sljedeće riječi:

$V = \{ \text{nula}, \text{jedan}, \text{dva}, \text{tri}, \text{četiri}, \text{pet}, \text{šest}, \text{sedam}, \text{osam}, \text{devet}, \text{nula}, \text{plus}, \text{minus}, \text{podjeljeno sa}, \text{puta} \}$

Predobrada leksičke analize jest, dakle, grupiranje i transformiranje postojećih etiketa koje neposredno predstavljaju pojedine glasove. Nažalost, budući da nije moguće postići točnost grupiranja od 100%, i ovdje moramo uvesti postupnu analizu. Na prvoj razini leksičke analize odabiremo neko svojstvo glasova, koje se može pouzdano i jednostavno opisati na osnovi vektora obilježja parametarskog zapisa govornog segmenta. Budući da je zvučnost/bczvučnost

jedno od takvih svojstava, možemo ga definirati kao kriterij grupiranja etiketa dobivenih na fizičkoj i fonetskoj razini. Na osnovi segmentiranih etiketa u fazи fonetske analize:

$$\begin{aligned}\alpha &= \alpha_1 \alpha_2 \alpha_3 \alpha_4 \dots \alpha_i \dots \alpha_k && (\text{razina: } A) \\ \beta &= \beta_1 \beta_2 \beta_3 \beta_4 \dots \beta_i \dots \beta_k && (\text{razina: } B) \\ \nu &= \nu_1 \nu_2 \nu_3 \nu_4 \dots \nu_i \dots \nu_k && (\text{razina: } C)\end{aligned}$$

definiramo globalni string zvučnosti nad alfabetom $E_Z = \{ B, Z, T \}$:

$$\mu = \mu_1 \mu_2 \mu_3 \mu_4 \dots \mu_k \dots \mu_n, \quad \mu_i \in E_Z \quad \dots \quad (4.3.3-1)$$

Interpretacija elemenata alfabeta E je sljedeća:

etiketa	značenje
B	bezvučnost
T	tišina
Z	zvučnost

tbl. 4. 3. 3-1 Fizikalno značenje ciketa i eksičke razine

Vrijednost podstringa μ_i bit će Z ako β_i sadrži barem jednu od etiketa D, G, M ili V (oznake zvučnih segmenta), dok će biti etiketiran s B ako β_i ne sadrži spomenute etikete nego neku od etiketa S, X ili F (bczvučni segmenti). Odsustvo signalna registrirano je etiketom $\alpha = \bullet$ pa u tom slučaju μ_i poprima vrijednost T. Na primjer, ako su za izričaj riječi četiri dobivene etikete :

α = #####. . . #####. . . #####. . . #####
 β = -----VVVVVVV. . . . --V-V----VVVVVVV-
 -----G-----
 -S-S---S-----
 XXXXXXXXXX-----
 --F---F-----F-----
 -----M-M-----

 v = -----eieEie. . . . --I*-----eIiiii-

tada je globalni string zvučnosti :

$$\mu = \text{BBBBBBBBBBZZZZZZZTTTTTZZZZZZZZZZZZZZZZZZ}$$

Sličan oblik stringa zvučnosti dobili bismo ako bismo segmentaciju provodili na osnovi algoritma analize perioda osnovnog tona i funkcije kratkovremenske energije. Primjerice ako je izračunati F0 za i-ti segment različit od 0, tada će poprimiti vrijednost Z, inače će mu biti pridružena etiketa T ili B ovisno o tome prelazi li energija segmenta zadani prag tišinc. Međutim, zbog mnogobrojnih šumova (obezvručavanje i ozvučavanje glasova, utjecaj načina izgovora, fonološke okoline itd) koji su inherentno prisutni unutar govornog signala, dobiveni rezultati analize zvučnosti isključivo s pomoću vrijednosti F0 više će odstupati od "ručne" segmentacije.

Pridružimo sada svakoj riječi iz vokabulara pripadni string zvučnosti $\delta \in E_z^* = \{Z, T, B\}^*$, koji predstavlja opću karakteristiku zvučnosti izričaja pojedine riječi.

rječ	δ	rječ	δ	rječ	δ
nula	Z	pet	TZT	plus	TZB
jedan	Z	šest	BZBT	minus	ZB
dva	Z	sedam	BZ	puta	TZTZ
tri	TZ	osam	ZBZ	podjeleno	TZBZ
četri	BZTZ	devet	ZT		

tbl. 4. 3. 3-2 Stringovi zvučnosti

Na primjer, riječima nula, jedan i dva pridružen string zvučnosti je Z, što znači da svi govorni segmenti koji predstavljaju izričaje tih riječi imaju svojstvo zvučnosti. Iz istih razloga string zvučnosti $\delta = ZBZ$ predstavlja riječ "osam", jer ukazuje na alterniranje zvučnih i bezvručnih segmenata. Budući da definirani string zvučnosti ne uključuje vremenski aspekt izričaja (tj. broj segmenata), nego samo promjene zvučnosti, nije moguće formirati listu riječi-kandidata za neki globalni string zvučnosti. Zato komprimirajmo string μ u string, μ_c s pomoću FST pretvarača:

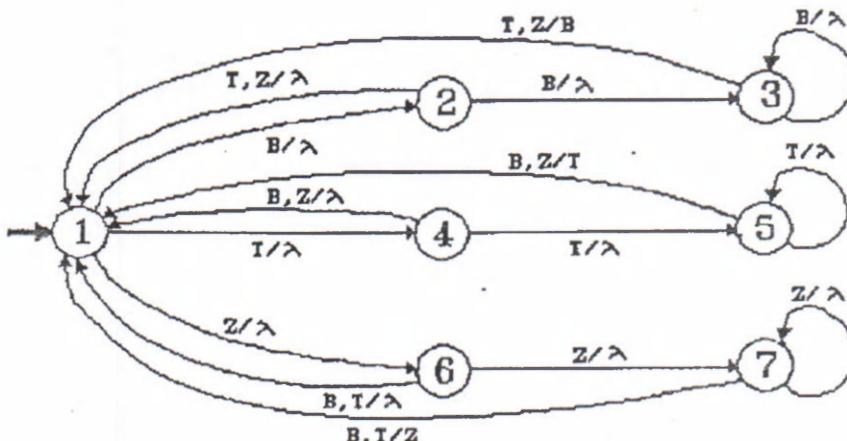
$$M = (\{1, 2, 3, 4, 5, 6, 7\}, \{B, T, Z\}, \{B T Z\}, \delta, 1, \{1, 2, 3, 4, 5, 6, 7\})$$

Funkcija ' α ' definirana je tabelarno :

q	x	p	y	q	x	p	y	q	x	p	y	q	x	p	y	q	x	p	y
1	B	2	λ	2	B	3	λ	3	B	3	λ	4	B	1	λ	5	B	1	T
1	T	4	λ	2	T	1	λ	3	T	1	B	4	T	5	λ	5	T	5	λ
1	Z	6	λ	2	Z	1	λ	3	Z	1	B	4	Z	1	λ	5	Z	1	T

Komprimirani globalni string zvučnosti uključuje samo promjene zvučnosti, pa je sada moguće izgraditi listu kandidata riječi. Na primjer, neka je $\mu_c = \text{BZTZZBZ}$. Moguće kombinacije (listice) riječi jesu:

1. četiri minus nula
2. četiri minus jedan
3. četiri minus dva
4. sedam tri osam
5. sedam tri nula sedam
6. sedam tri jedan sedam
7. sedam tri dva sedam



sl. 4. 3. 3-2 Grafički prikaz FST automata

Kad je odredena lista mogućih riječi, pristupamo drugoj fazi leksičke analize - sužavanju izbora na osnovi dodatnih uvjeta o prirodi riječi iz vokabulara. Prilikom definiranja dodatnih uvjeta mora se paziti da oni budu dovoljno široki kako koartikulacijski efekti i način izgovora ne bi bitno utjecali na konačnu odluku o mogućim rječima (tj. isključivali pravce kandidate), ali istodobno trebaju biti maksimalno uski kako bi se broj lista-kandidata što više reducira. Imajući na umu ta dva suprotna zahtjeva i raspoložive ciklone prema predloženom modelu segmentacije, definiramo dodatne uvjete na sljedeći način :

Svakoj riječi r iz vokabulara V pridružimo masku fonetske strukture $\emptyset \in \{W, T, S, G, M, X\}^*$, koja će preciznije opisivati vremenski slijed segmenta unutar riječi prema donjoj tabeli.

rječ	δ	rječ	δ	rječ	δ
nula	MW	pet	TWT	plus	TWS
jedan	WGW	šest	YWST	minus	WS
dva	GW	sedam	SWGW	puta	TWTW
tri	TW	osam	VSW	podjeljeno sa	TWGWSW
četri	YWTW	devet	GWT		

tbl. 4. 3. 3-3 Fonetske maske

Interpretacija etiketa T, G, S je već objašnjena (tbl. 4. 3. 2-1). Nove etikete koje se pojavljuju su W i Y. Etiketa W označava zvučni segment velike energije, koji ne može biti etiketiran sa G ili M, dok Y predstavlja grupe bezvučnih segmenata, koji su osim etikete S etiketirani i nekom drugom bezvučnom etiketom.

Na primjer, fonetska maska za riječ "jedan" jest $\emptyset = \text{WG}W$, što znači da unutar izričaja mora postojati grupa segmenata koji su etiketirani sa G a omeđeni drugim zvučnim segmentima velike energije (npr. vokalima).

Fonetska maska izričaja dobiva se u fazi komprimiranja globalnog stringa zvučnosti, gde se svakom znaku $\mu_i \in \{T, Z, B\}$ komprimiranog stringa zvučnosti $\mu_c = \mu_1 \mu_2 \dots \mu_n$ dodjeljuje indeks početnog (p) i završnog (z) segmenta koji je obuhvaćen i-tim znakom, odnosno:

$$\mu_c = \mu_1 \left|_{p_1}^{z_1} \right. \mu_2 \left|_{p_2}^{z_2} \right. \mu_3 \left|_{p_3}^{z_3} \dots \right. \mu_i \left|_{p_1}^{z_1} \dots \mu_k \left|_{p_n}^{z_n} \dots \right. \right. \quad (4.3.3-2)$$

Primjerice, komprimiranjem globalnog stringa zvučnosti koji se dobiva prema etiketama sa slike 4. 3. 2-2 imamo:

$$\mu_c = T \left|_0^5 \right. Z \left|_6^{16} \right. B \left|_{17}^{28} \right. Z \left|_{29}^{44} \right. T \left|_{45}^{49} \right. Z \left|_{50}^{68} \right. B \left|_{69}^{77} \right. T \left|_{78}^{86} \right. Z \left|_{87}^{112} \right. T \left|_{113}^{118} \right.$$

Pokušajmo sada izgraditi liste riječi za nekoliko prvih etiketa zvučnosti za dobiveni μ_c . Prve dvije etikete TZ odgovaraju po zvučnosti i po obliku fonetske maske riječi tri, pa se ona stavlja na listu-kandidata. Budući da leksička analiza mora zahvatiti sve moguće kombinacije, pomičemo se za jedno mjesto i promatramo neovisno prvi zvučni segment Z. Prema tablici 4. 3. 3-2 za zvučni segment Z moguće riječi su: nula, jedan, dva. Međutim, izračunata fonetska maska od 6. do 16. segmenta (W) ne podudara se ni sa jednom maskom riječi-

kandidata (nula, jedan, dva), što znači da prva zvučna oblast sigurno ne predstavlja zasebnu riječ. Daljnom analizom dobivamo da riječi osam i podijeljeno sa odgovaraju po zvučnosti strukturi TZBZ, ali samo fonetska maska riječi osam zadovoljava uvjet. Postupak leksičke analize ponavlja se dok se ne iscrpc sve alternativne liste kandidata.

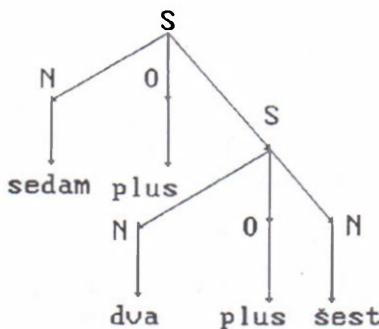
Kad je formirana lista kandidata mogućih nizova riječi, na sintaksičkoj razini se na osnovi sintaksnih pravila donosi konačna odluka o izgovorenoj poruci. Sintaksna pravila u ovom radu dana su u obliku CF gramatike:

$$\begin{aligned}
 G = & (\{S, N, O\}, \{nula, \dots, devet, plus, \dots, podijeljeno sa\}, P, S) \\
 S \rightarrow & N \ O \ N \mid N \ O \ S \\
 N \rightarrow & nula \mid jedan \mid dva \mid tri \mid četri \mid pet \mid šest \mid \\
 & sedam \mid osam \mid devet \\
 O \rightarrow & plus \mid minus \mid puta \mid podijeljeno \ sa
 \end{aligned}$$

Pretpostavimo sada da smo kao izlaz leksičke analize dobili sljedeće liste-kandidatice:

1. sedam plus dva minus minus
2. sedam plus dva plus plus
3. sedam plus dva plus šest

Primjenom algoritma sintaksičke analize (Ahoi Ullman, 1972), jedino će se dobiti stablo i niz izvođenja za rečenicu : "sedam plus dva plus šest", jer ona pripada definiranom jeziku aritmetičkih izraza:



sl. 4. 3. 3-3 Stablo izvođenja

Posljednji korak prema općoj slici sistema jest izračunavanje aritmetičkog izraza i govorna sinteza odgovora. Izračunavanje aritmetičkog izraza ovdje predstavlja semantiku prihvaćene sintaksičke strukture. Nakon izračunavanja aritmetičkog izraza, njegova se vrijednost prikazuje na monitoru i istodobno akustički realizira rudimentarnom sintezom govora (reprodukcijska predznačenih digitaliziranih znacenja).

5. ZAKLJUČAK

Unatoč četrdesetogodišnjoj povijesti automatskog prepoznavanja govora i naglog razvoja digitalnih računala, načini da se riješi automatsko prepoznavanje povezanoga govora još nisu pronađeni. Može se reći da je jedino riješen problem prepoznavanja ograničenog broja izoliranih riječi za unaprijed pripremljenog govornika (Baker, 1989). Zaključak mnogih istraživanja jest da se uspješno prepoznavanje govora ne može ostvariti ako se ne ugradi inherentno simboličko znanje i određeni mehanizmi učenja (na simboličkoj razini). Iako se u posljednjem desetljeću naglo propagira pristup konektivnog modela prepoznavanja temeljenog na različitim topologijama neuronskih mreža koje bi same trebale (na osnovi primjera) "naučiti" fonetsko-lingvističko znanje, još nisu prevladani ARPA rezultati u domeni razumijevanja govora. Kompromisno rješenje koje se nameće, jest da se neuronske mreže iskoriste za učenje na percepcijskoj razini (u akustičko-fonetskom procesoru) dok bi se i dalje zadržala tradicionalna simbolička obrada.

REFERENCIJE

1. Aho, A. V. , Ullman, J. D. (1972) : The Theory of Parsing, Translation, and Compiling, Volume I : Parsing, Toronto: Prentice-Hall
2. Allerhand M. (1987): Knowledge- based Speech Pattern Recognition, London: Kogan Page
3. Baker, J. M. (1989): Dragondictate - 30K: Natural Language Speech Recognition with 30. 000 words, EUROSPEECH-89, Paris, (str. 161-163)
4. Charniak E. i McDermott (1985) : Introduction to AI, Massachussetts : Addison-Wesley
5. Gonzalez, R. C. i Thomson M. G. (1978): Syntactic Pattern Recognition, Massachussetts: Addison-Wesley
6. Hatzsaki K. et al. (1988) : Phoneme segmentation by an expert system based on spectrogram reading knowledge, SPEECH-88, (str. 927-931) Edinburgh, 22-26 aug.
7. Kohonen, T. (1988): Neural Phonetic Typewriter, Computer, Vol XXI, No 3, (str. 11-22)
8. Kurepa, S. (1982) : Matematička analiza 1 i 2, Zagreb: TK
9. Lea, W. A. , izdavač (1980) : Trends in SpeechRecognition, New Jersey: Prentice-Hall
10. Levinson, S. E. (1983) : An introduction to the Applicationof the Theory of Probabilistic Functions of a Markov Process in Automatic Speech Recognition, (str. 1035-1074), The Bell System Technical Journal, Vol. 62, No4, Part 1
11. Linard, J. S. (1977) : Les processus de la communication parlée, Paris: Masson
12. Mc Clelland, L. i Rumelhart, D. E (1988) : Explorations in parallel distributed processing, Massachussetts: MIT Press

13. Michalski, R. S. et al. (1984) : "Machine learning: An artificial Intelligence Approach", Berlin : SpringerVerlag
14. Mišković, V. (1989) : "Obrada Linearnih stributa u algoritmu za induktivno učenje CORAL", u pripremi za časopis "AUTOMATIKA"
15. Moris, Čarls. (1975) : Osnove teorije o znacima, Beograd: BIGZ
16. Nakanishi, H. i Nakagava, S. (1987): Speaker-Independent word recognition by less cost and stochastic dynamic time warping method, (str. 292-295) Vol2, J. Laver, izdavač, Zbornik "European Conference on Speech Technology ", Edinburgh
17. Papamichalis, P. E. (1987) : Practical Approaches to Speech Coding , New-Jersey: Prentice-Hall
18. Patrick, E. A. (1972): Fundamentals of Pattern Recognition, New-Jersey: Prentice-Hall
19. Paušić, Ž. (1974): "Vjerojatnost, informacija, stohastički procesi", Zagreb: ŠK
20. Plotnikov, V. N. (1988), Rečevoj dialog v sistemah upravljenija, Moskva : Mashinostroenie
21. Potter, R. K i Kopp G. A (1947) : Visible Speech, New York, : D. van Nostrand Co.
22. Proakis J. G. (1983) : Digital Communications, Singapore: McGraw-Hill, Carnegie-Mellon
23. Rumelhart, D. E. et al. (1986) : Learning representation by back-propagation errors, Nature, 323, (str. 533-536)
24. Prager, R. W et al. (1986): Boltzmann machines for speech recognition, Computer Speech and Language, Vol. I , (str. 3- 27)
25. Rabiner L. R. et al. (1983): On the Application of Vector Quantization and Hidden Markov Models to Speaker-Independent, Isolated Word Recognition, (str. 1075- 1106, The Bell System Technical Journal, Vol. 62, No4, Part 1
26. Rabiner R. L. i Schafer W. Ronald (1978), Digital Processing of Speech Signals, Englewood Cliffs: Prentice-Hall
27. Schafer R. W., Markel, J. D., (1979), izdavači: Speech Analysis, New York: IEEE Press
28. Stamenković M. (1987): Primer govorno upravljanog procesnog sistema, MIPRO87, (str. 282-286), Opatija.
29. Stamenković, M. (1988.): Digitalno predstavljanje i analiza govora u vremenskoj domeni, Govor, br. 2. , (str. 109- 132)
30. Stamenković, M. i Bakran, J. (1988.): Fonetsko- lingvistički pristup prepoznavanja govora, MIPRO-88, Opatija
31. Stamenković, M. (1988.) : A learning speech recognition system, SPEECH-88, Edinburgh, (str. 773-780)
32. Stamenković, M. (1988) : Mašinsko učenje i prepoznavanje govora, ETAN-88, Sarajevo
33. Stamenković M. i J. Bakran (1989) : An Intelligent Pitch Tracker Based on Formal Language Theory and Phonetic Knowledge, EUROSPEECH-89, Paris, (str. 470-473)
34. Zbornik ROJP III, Institut "Jožef Štefan", Ljubljana, 1985.

35. Zbornik ROLP IV, Institut "Jožef Stefan", Ljubljana, 1988.
36. Yang, F. et al. (1988): Utilisation d'un réseau de neurones pour la reconnaissance des mots isolés, SPEECH-88, Edinburgh, (str. 859-866)
37. Zagoruiko N. G. et al. (1985): Alogirmy obnaruzenia empiriceskih zakonomiernostei, Novosibirsk: Nauka
38. Witten, I. H. (1982): Principles of Computer Speech, London: Academic Press

*Milan Stamenković
VVTŠ KoV JNA, Zagreb*

AUTOMATIC RECOGNITION OF SPEECH

SUMMARY

Besides the general principles of automatic speech recognition the paper deals with approaches to speech recognition based on the traditional theory of pattern recognition and machine learning opposed to models including phonetic and linguistic aspects. The central part of the paper is concerned with the description of the system for continuous speech recognition which shapes the speech communication processes.