

PRIMJER PREPOZNAVANJA UZORAKA OPISANIH NAD SKUPOM KVALITATIVNIH VARIJABLI UZ KONZISTENTNA LINEARNA OGRANIČENJA

Branko Nikolić
Fakultet za defektologiju
Sveučilište u Zagrebu

Originalni znanstveni članak
UDK: 519.2
Primljeno: 5. 9. 1985.

Behlul Brestovci
Fakultet za fizičku kulturu
Univerziteta u Prištini

SAŽETAK

Predložena je jedna nova klasa algoritama za prepoznavanje uzoraka koja se temelji na linearnoj regresijskoj proceduri, a parametri prepoznavanja procjenjuju se metodom najmanjih kvadrata.

Algoritam vrši prepoznavanje uzoraka opisanih nad skupovima kvalitativnih varijabli, kad su parametri prepoznavanja podvrgnuti skupu konzistentnih linearnih ograničenja i kad parametri prepoznavanja nisu podvrgnuti ograničenjima.

Funkcioniranje algoritama i programa pokazano je na prepoznavanju glasova hrvatskog ili srpskog jezika na osnovi njihovih zvučnih i tvorbenih karakteristika. Glasovi su se klasificirali u tri klase prema mjestu njihove tvorbe.

UVOD

Kada uzorke svrstavamo u pojedine klase na osnovi njihovih ulaznih karakteristika, onda su ti uzorci prepoznati.

Problem prepoznavanja uzoraka može se promatrati kao diskriminacija ulaznih podataka, populacija, preko traženja zajedničkih svojstava ili invarijantnih atributa među članovima populacije.

Problemi prepoznavanja uzoraka mogu se logički podijeliti u dvije kategorije:

1. Mogućnost prepoznavanja uzoraka kod ljudskih bića i drugih organizama.
2. Razvoj teorije i tehnike za konstrukciju uređaja sposobnih za izradu podataka prepoznavanja u specijalnim aplikacijama.

Prvu kategoriju razmatraju discipline kao psihologija, defektologija, fiziologija, biologija i slične, dok se drugom kategorijom bave discipline kao elektronika, računarska tehnika i druge srodne znanstvene discipline.

Prepoznavanje uzoraka najjednostavnije se definira kao kategorizacija ulaznih podataka u razrede koji se mogu identificirati pomoću izvođenja zajedničkih svojstava ili atributa.

Sistem prepoznavanja štampanih znakova je sistem prepoznavanja uzoraka koji prihvaća optičke signale kao ulazne podatke i identificira ime znaka.

Defektološke dijagnoze mogu biti problem prepoznavanja uzoraka. Načini ponašanja ljudi mogu biti ulazni podaci u sistemu prepoznavanja na osnovi kojih se

vrši kategorizacija ljudi prema tipu oštećenja. Predviđanje vremena možemo tretirati kao problem prepoznavanja uzoraka, čiji su ulazni podaci u formi vremenskih karata, a vremenska prognoza donosi se na osnovi zaključaka donesenih interpretacijom tih karata.

U sistemu prepoznavanja govora, imena glasova identificiraju se na osnovi određenih akustičkih valnih oblika.

Ne postoji neka generalna teorija koja kaže koje sve i kakve testove treba primijeniti na realnim primjerima da bi se dobila zadovoljavajuća klasifikacija uzoraka.

U ovom radu obrađena je jedna posebna klasa problema za prepoznavanje uzoraka, gdje su operatori prepoznavanja procijenjeni pomoću linearne regresijske procedure, pri čemu je funkcija prepoznavanja podvrgnuta skupu konzistentnih linearnih ograničenja u jednom slučaju, a u drugom nije.

1. CILJ ISTRAŽIVANJA

U podosta istraživanja u kojima se primjenjuju elektronička računala za prepoznavanje uzoraka, posebno u medicini, računarskim znanostima, defektologiji i psihologiji algoritmi prepoznavanja nisu prihvatljivi pod modelom koji definira obilježja uzoraka na skupu kvalitativnih varijabli, ako nisu poštovana ograničenja definirana internom strukturom skupa varijabli ili nekim skupom vanjskih kriterija. Cilj ovoga rada je pokazati kako se vrši prepoznavanje uzoraka ili entiteta opisanih nad skupom kvalitativnih ili nominalnih varijabli kada su operatori prepoznavanja podvrgnuti skupu konzistentnih linearnih ograničenja.

2. MODEL I PROGRAM

Parametri prepoznavanja uzoraka procjenjuju se metodom najmanjih kvadrata bez ograničenja i s konzistentnim linearnim ograničenjima kada su uzorci opisani nad skupom nominalnih varijabli. Da bi se moglo izvršiti prepoznavanje, potrebno je najprije sve nominalne varijable binarizirati.

Generalna linearna funkcija prepoznavanja glasi:

$$d(X) = W^T \cdot X,$$

gdje je $X = (X_1, X_2, \dots, X_n, 1)^T$

vektor uzorka, a

$$W = (W_1, W_2, \dots, W_{n+1})$$

$W = (W_1, W_2, \dots, W_n, W_{n+1})^T$ vektor regresijskih koeficijenata ili parametara prepoznavanja, koje treba procijeniti.

Program PARECON-N (Pattern Recognition with Constraints on a Sets of Nominal Variables) vrši procjenu parametara prepoznavanja pod modelom najmanjih kvadrata i prepoznaje uzorke ili entitet uz konzistentna linearna ograničenja i bez njih. Program koristi dio procedura iz programa SHEYTAN (Momirović, 1983) i BELZEBUB (Momirović, Prot i Bosner, 1983), a pisan je u programskom jeziku SS (Štalec, Momirović i Zakrajšek, 1981). Da bi se mogao koristiti program PARECON-N, potrebno je sve varijable prethodno binarizirati.

3. ULAZNI PODACI I VARIJABLE ZA PROGRAM PARECON-N

Da bi se pokazalo kako program PARECON-N vrši prepoznavanje uzoraka, kao testovni podaci poslužit će glasovi hr-

vatskog ili srpskog jezika odnosno neke njihove akustičke i artikulacijske osobine. Izvršit će se prepoznavanje glasova u tri različite klase, definirane kao artikulacijske osobine glasova, na osnovi nekih akustičkih osobina tih glasova. Za kreiranje varijabli na osnovi kojih se vršilo prepoznavanje korištena je: „Priručna gramatika hrvatskog književnog jezika“ (Barić i sur., 1979). Uzet je 31 glas, i to: A, B, C, Č, Ć, D, Dž, Đ, E, F, G, H, I, J, K, L, Lj, M, N, Nj, O, P, R_v (vokalsko r), R_k (konsonantsko r), S, Š, T, U, V, Z, Ž. Skup varijabli na osnovi kojih se vrši prepoznavanje predstavljaju akustičke osobine glasova, a varijable na kojima se vrši kategorizacija ili prepoznavanje glasova predstavljaju tri artikulacijske osobine glasova.

Sve varijable su binarne.

Ako glas pripada nekoj od varijabli, imat će vrijednost 1, a ako ne pripada, dobit će vrijednost 0.

Akustičke osobine glasova definiraju ove varijable:

1. VOKALI (VOKALI)

1 – DA
0 – NE

2. PRIJELAZNI GLASOVI (PREGLA)

1 – DA
0 – NE

3. SONANTI (SONANT)

1 – DA
0 – NE

4. KONSONANTI (KONSON)

1 – DA
0 – NE

5. NAZALI (NAZAL)

1 – DA
0 – NE

6. KOMPAKTNI GLASOVI (KOMPAK)

1 – DA
0 – NE

7. DIFUZNI GLASOVI (DIFUZ)

1 – DA
0 – NE

8. NEPREKIDNI GLASOVI (NEPREK)

1 – DA
0 – NE

9. STRIDENTNI GLASOVI (STRID)

1 – DA
0 – NE

10. ZVUČNI GLASOVI (ZVUČNI)

1 – DA
0 – NE

11. GRAVISNI ILI DUBOKI GLASOVI (GRAVIS)

1 – DA
0 – NE

Akustičke osobine glasova predstavljaju prediktorski skup varijabli.

Kriterijski skup čine artikulacijske osobine glasova, i to:

2. NEPČANI GLASOVI (NEPCAN)

1 - DA
0 - NE

1. PREDNJONEPČANI GLASOVI (PRE-DNO)

1 - DA
0 - NE

3. ZADNJONEPČANI GLASOVI (ZAD-NEP)

1 - DA
0 - NE

PREDIKTORSKI SKUP	VOKALNI	PRIJELAZNI GLASOVI	SONANTI	KONSONANTI	NAZALI	KOMPAKTNI GLASOVI	DIFUZNI GLASOVI	NEPREKIDNI GLASOVI	STRIDENTNI GLASOVI	ZVUČNI GLASOVI	GRAVISNI GLASOVI	KRITERIJSKI SKUP	PREDNJONEPČANI GLASOVI	NEPČANI GLASOVI	ZADNJONEPČANI GLASOVI
A	1	0	0	0	0	1	0	1	0	1	0		0	0	1
B	0	0	0	1	0	0	1	0	0	0	0		1	0	0
C	0	0	0	1	0	1	0	0	1	0	0		0	1	0
Č	0	0	0	1	0	1	0	0	0	0	0		0	0	0
D	0	0	0	1	0	0	1	0	0	0	0		0	1	0
Dž	0	0	0	1	0	1	0	0	0	1	0		1	0	0
Đ	0	0	0	1	0	1	0	0	0	1	0		0	1	0
E	1	0	0	0	0	0	0	1	0	1	0		0	1	0
F	0	0	0	1	0	0	1	1	1	0	1		1	0	0
G	0	0	0	1	0	1	0	0	0	1	1		0	0	1
H	0	0	0	1	0	1	0	1	0	0	1		0	0	1
I	1	0	0	0	0	0	1	1	0	1	0		0	0	0
J	0	1	0	0	0	1	0	1	0	1	0		0	1	0
K	0	0	0	1	0	1	0	0	0	0	1		0	0	1
L	0	0	1	0	0	0	1	1	0	1	0		1	0	0
Lj	0	0	1	0	0	1	0	1	0	1	0		0	0	0
M	0	0	1	0	1	0	1	0	0	1	0		0	1	0
N	0	0	1	0	1	0	1	0	0	1	1		1	0	0
Nj	0	0	1	0	1	1	0	0	0	1	0		0	1	0
O	1	0	0	0	0	0	0	1	0	1	1		0	0	1
P	0	0	0	1	0	0	1	0	0	0	1		1	0	0
R _v	1	0	0	0	0	0	1	0	0	0	1		1	0	0
R _k	0	0	1	0	0	0	1	0	0	1	0		1	0	0
S	0	0	0	1	0	0	1	1	1	0	0		1	0	0
Š	0	0	0	1	0	1	0	1	1	0	0		0	1	0
T	0	0	0	1	0	0	1	0	0	0	0		1	0	0
U	1	0	0	0	0	0	1	1	0	1	1		0	0	1
V	0	0	1	0	0	0	1	1	1	1	1		0	0	1
Z	0	0	0	1	0	0	1	1	1	1	0		1	0	0
Ž	0	0	0	1	0	1	0	1	1	1	0		0	0	0

U zagradama se nalaze imena varijabli kao u programu. Glasovi imaju u varijablama kodove navedene na str. 84.

Konzistentna linearna ograničenja kreirana su ovako:

Od sedam sonantnih glasova, pet mora biti prepoznato kao prednjonepčani glasovi, dva kao nepčani, a niti jedan kao zadnjonepčani glas.

Od 13 kompaktnih glasova niti jedan ne smije biti prepoznat kao prednjonepčani glas, devet ih treba biti prepoznato kao nepčani glasovi, a četiri kao zadnjonepčani glasovi. Od 10 gravisnih (dubokih) glasova, pet ih se treba prepoznati kao prednjonepčani, pet kao zadnjonepčani, a niti jedan ne smije biti prepoznat kao nepčani glas.

U matričnom obliku ova ograničenja imaju oblik:

$$R \cdot \beta = C$$

gdje su:

$$R = \begin{vmatrix} 007000000000 \\ 0000001300000 \\ 0000000000010 \end{vmatrix}$$

$$\beta = \begin{vmatrix} \beta(1)1\beta(1)2\beta(1)3 \\ \beta(2)1\beta(2)2\beta(2)3 \\ \cdot \\ \cdot \\ \beta(12)1\beta(12)2\beta(12)3 \end{vmatrix}$$

$$C = \begin{vmatrix} 5 & 2 & 0 \\ 0 & 9 & 4 \\ 5 & 0 & 5 \end{vmatrix}$$

Matrica β sadrži koeficijente prepoznavanja za pojedine klase uzoraka (u ovom slučaju artikulacijske osobine glasova).

5. INTERPRETACIJA DOBIVENIH REZULTATA

Program PARECON—N štampa matrice parametara prepoznavanja BETA (bez ograničenja) i GAMA (s konzistentnim linearnim ograničenjima).

Prepoznavanje bez ograničenja. Alokaicijska matrica ESTG predstavlja matricu prepoznavanja uzoraka bez ograničenja. Na osnovi akustičkih osobina izvršeno je prepoznavanje glasova klasificiranjem u tri klase (pattern classes) prema mjestu tvorbe.

U klasu prednjonepčanih glasova (PRE-DNE) svrstani su ovi glasovi:

B, C, D, F, L, M, N, P, R_v, R_k, S, T, V, Z.

Svi ovi glasovi po svojim artikulacijskim osobinama pripadaju u prednjonepčane glasove.

Kao nepčani (NEPCAN) glasovi prepoznati su ovi glasovi:

A, Č, Ć, Dž, Đ, E, I, Lj, Nj, Š, Ž.

U klasu zadnjonepčanih glasova (ZAD-NEP) svrstani su ovi glasovi:

G, H, F, K, O, U.

Vidi se da je glas A prepoznat kao nepčani, a stvarno je zadnjonepčani, dok je glas I nepčani, a prepoznat je kao zadnjonepčani.

Program štampa matricu grešaka ER-ROR kod prepoznavanja uzoraka bez ograničenja, koje nastaju uslijed procjene parametara prepoznavanja metodom najmanjih kvadrata.

Što su elementi matrice ERROR veći, to je lošija procjena koeficijenta prepoznavanja.

Prepoznavanje s ograničenjima. Alokaicijska matrica uz ograničenja PRGG sa-

drži vrijednosti prepoznavanja glasova, kada je procjena parametara izvršena uz konzistentna linearna ograničenja, a interpretira se identično matrici ESRG.

Uz navedena ograničenja kao prednjonepčani glasovi prepoznati su:

B, C, F, J, M, P, R_k, V.

Kao nepčani glasovi prepoznati su:

A, Ć, Č, Đ, Dž, I, Lj, N, R_v, Š, Ž, dok su u klasu zadnjonepčanih glasova ušli:

G, H, K, O, U.

Glasovi: D, E, L, N, S, Z nisu ušli niti u jednu klasu jer imaju negativne vrijednosti u svim klasama uzoraka.

Vidi se da je ovim ograničenjima postignuto prepoznavanje glasa I kao nepčanog glasa, ali je zato došlo do prepoznavanja glasa J, kao prednjonepčanog, a R_v kao nepčanog glasa, iako oni nemaju te osobi-

ne.

Očito je broj jednadžbi ograničenja bio nedovoljan za pouzdanije prepoznavanje glasova uz ograničenja.

Program štampa i matricu pogreški uz ograničenja DIST, koja ima isto značenje kao i matrica ERROR. Osim toga, program računa matricu kongruencije CONG parametara prepoznavanja bez ograničenja i s ograničenjima.

Pošto je cilj ovoga rada da se pokaže kako funkcionira algoritam prepoznavanja i kako se kreiraju konzistentna linearna ograničenja, to su dobiveni rezultati samo potvrdili ispravnost ove metode za klasifikaciju ili prepoznavanje uzoraka.

Za bolje prepoznavanje uzoraka bilo bi potrebno dalje istraživati na području konzistentnih i nekonzistentnih linearnih ograničenja.

LITERATURA

1. Momirović K.:

Sheytan—Algoritam i program za prepoznavanje uzoraka opisanih nad nesingularnim skupom kvantitativnih varijabli uz konzistentna linearna ograničenja, programska biblioteka SRCE – SS–MAKRO, 1983.

2. Momirović K., F. Prot i K. Bosnar:

Belzebub—Algoritam i program za prepoznavanje uzoraka opisanih nad skupom nominalnih varijabli, programska biblioteka SRCE – SS–MAKRO, 1983.

3. Barić E., M. Lončarić, D. Malić, S. Pavešić, M. Peti, V. Zečević, M. Znika:

Priručna gramatika hrvatskog književnog jezika, Zavod za jezik Instituta za filologiju i folkloristiku—Zagreb, Školska knjiga, Zagreb, 12–21, 1979.

EXAMPLE OF PATTERN RECOGNITION DESCRIBED ON SETS OF QUALITATIVE VARIABLES WITH A CONSISTENT LINEAR CONSTRAINTS

Summary

In the present study, a new class of algorithms for pattern recognition based upon linear regression procedure, is suggested. In this new class, parameters of recognition are determined by the method of the least squares. The algorithm recognizes patterns described on sets of qualitative variables when operators of recognition are subjected to a set of consistent linear constraints and also when operators of recognition are not subjected to constraints, respectively. The functioning of this algorithm and the program for it were tested on data obtained in a study of sounds of the Croatian language differing in their place of articulation and in whether they are voiced or unvoiced according to their place of articulation. These sounds were classified into three categories.