

Formantinių požymių išskyrimo metodai

Antanas Leonas Lipeika

Matematikos ir informatikos instituto
Atpažinimo procesų skyriaus vyresnysis
mokslo darbuotojas, docentas, daktaras
Institute of Mathematics and Informatics,
Senior Researcher, PhD
Goštauto g. 12, LT-01108 Vilnius

Vilniaus pedagoginio universiteto
Informacinių technologijų katedros profesorius,
docentas, daktaras
Vilnius Pedagogical University,
Department of Information Technology, Professor, PhD
Studentų g. 39, Vilnius
Tel. 266 03 90, faks. 261 99 05
El. paštas: lipeika@ktl.mii.lt

Straipsnyje nagrinėjami formantinių požymių išskyrimo metodai. Formantinių požymių išskyrimas remiasi spektro pikų radimu apskaičiuotame iš tiesinės prognozės modelio parametru spektre. Formantinių požymių išskyrimas priklauso nuo tiesinės prognozės modelio parametru vertinimo metodo. Anksčiau tiesinės prognozės modelio parametru vertinimui naudojome autokoreliacinių metodą, kuris neužtikrindavo patikimo formantinių požymių išskyrimo. Todėl, siekiant padidinti formantinių požymių išskyrimo patikimumą, ieškoma geresnio tiesinės prognozės modelio parametru vertinimo metodo. Autokoreliacinis tiesinės prognozės modelio parametru vertinimo metodas lyginamas su kovariaciniu, Burg, Marple metodais ir modifikuotu Split Levinson algoritmu. Tyrimais nustatyta, kad pagal formančių trajektorijų išskyrimą kovariaciniis, Burg, Marple tiesinės prognozės modelio parametru vertinimo metodai iš esmės nesiskiria nuo autokoreliacino, o modifikuotu Split Levinson algoritmu gauname daug patikimesnius formančių trajektorijų įverčius.

Literatūroje (De Wet ir kt., 2004) diskutuojama, ar formantiniai požymiai (balso trakto rezonansiniai dažnai) yra naudingi atpažistant kalbą. Pripažiasta, kad formantiniai požymiai gali būti naudojami kalbos atpažinimui, tačiau jie iki šiol nepopuliarūs dėl jų išskyrimo problemų. Balso trakto rezonansiniai dažnai dažniausiai randami iš tiesinės prognozės modelio parametru (Huang ir kt., 2001). Įmanomi du problemos sprendimo būdai. Galima iš tiesinės prognozės modelio parametru apskaičiuoti amplitudinių spektrą ir surasti spektro pikus, kurie ir yra traktuojami kaip balso trakto rezonansiniai dažnai – formantės. Alternatyvus būdas yra rasti

charakteringo tiesinės prognozės polinomo šaknis. Kompleksinės šaknys, kurių kampai su realia ašimi yra intervale $0 < \omega_i < \pi$, atitinka kalbos signalo *formantes*. Tokiu būdu suradę charakteringo polinomo šaknis, mes atmetame realias šaknies ir šaknies, atitinkančias neigiamus dažnus. Likusios šaknys yra surūšiuojamos dažnio didėjimo tvarka, ir tada šaknies numeris atitinka formantės numerį, o kampus su realia ašimi – formantės dažnį (Lipeika, 2005).

Pastarajame darbe buvo naudojamas autokoreliacinis tiesinės prognozės (LPC) modelio parametru vertinimo metodas (Rabiner ir kt., 1993) ir atliekant formančių dažnių išskyrimo

eksperimentus buvo pastebėta, kad formančių dažnai randami ne visada patikimai. Kai kalbos signale yra triukšmo dedamoji, spekro pikai neaštrūs, susilieja ir dažnai nepavyksta patikimai rasti formančių trajektorijų. Kartais gretimos formantės susilieja ir iškyla jų numeracijos problemą. Autokoreliacinis metodas geras tuo, kad tiesinės prognozės modelio parametrams rasti naudojama autokoreliacinė matrica ir dėl jos savybių nežinomiems parametrami rasti galima taikyti skaičiavimų apimties požiūriu efektyvų, rekurentinį Durbino algoritmą (Makhoul, 1975). Tačiau autokoreliacinis metodas turi vieną trūkumą: prognozės klaida yra skaičiuojama laikant, kad už analizės kadro ribų $0 \leq m \leq N - 1$ kalbos signalas yra lygus 0. Taigi prognozės klaidą gauname

$$E_n = \sum_{m=0}^{N-1+p} e_n^2(m),$$

čia N yra analizės kadro ilgis, p – tiesinės prognozės modelio eilė, n – analizės kadro numeris. Vadinasi, kai $m = 0, 1, \dots, p-1$, padaugintas iš lango funkcijos kalbos signalas $s_n(m)$ yra prognozuojamas pagal ankstesnes imtis ir kai kurios iš jų yra lygios nuliui. Dėl to dažnai atsianda didelių prognozės klaidų šioje srityje, ypač vokalizuočiems garsams. Be to, $m = N - 1, \dots, N - 1 + p$ srityje irgi dažnai pasitaiko dideilių prognozės klaidų dėl to, kad kalbos signalas yra prognozuojamas tik pagal keletą (mažiau negu p) ankstesnių kalbos signalo reikšmių. Dėl šios prielaidos gauname ne visai tikslius tiesinės prognozės modelio parametru iverčius. Todėl mes tyrėme alternatyvius tiesinės prognozės modelio parametru vertinimo būdus.

Tiesinės prognozės modelio parametrų vertinimo metodai

Nagrinėsime alternatyvius tiesinės prognozės modelio parametru vertinimo metodus ir parinksime tą, kuris geriausiai tinkta formančių trajektorijoms išskirti. Iš pradžių apžvelgsime išskirtines nagrinėjamų metodų savybes.

Kovariacinis metodas. Kovariacinis metodas (Rabiner ir kt., 1993) taiko kitą lango funkcijos naudojimo būdą – fiksuojanas intervalas (kad-

ras) $0 \leq m \leq N - 1$, kuriame kvadratinė klaida yra skaičiuojama kaip

$$E_n = \sum_{m=0}^{N-1} e_n^2(m)$$

ir kalbos signalas nedauginamas iš lango funkcijos. Naudojant šį metodą gauta kovariacinė matrica yra simetrinė ($\Phi_n(i, k) = \Phi_n(k, i)$), bet ne Tioplico. Skirtingai nuo autokoreliacinio metodo, kovariacinės matricos elementai ant įstrižainių nėra vienodi. Ši lygtių sistema gali būti išspręsta naudojant Cholesky dekompozicijos metodą. Kovariacinis metodas skaičiavimo požiūriu yra daug imlesnis ir todėl rečiau naujojamas. Šis metodas yra panašus į Proni metodą (McDonough ir kt., 1968), kur signalas yra aproksimuojamas gęstančiomis eksponentėmis.

Burg metodas. Burg metodas (Kay ir kt., 1981) įvertina atspindžio koeficientus, ir tiesinės prognozės modelio parametru iverčiams gauti naudojama Levinsono rekursija. Atspindžio koeficientų iverčiai gaunami rekursyviai minimizuojant prognozės klaidos energiją, esant skirtingoms prognozės eilėms. Skaičiuojant m -ojo atspindžio koeficiente įverti laikoma, kad jau yra įvertinti $(m-1)$ eilės prognozės klaidos filtro koeficientai $\{\hat{a}_1^{(m-1)}, \hat{a}_2^{(m-1)}, \dots, \hat{a}_{m-1}^{(m-1)}\}$, kurie jau buvo gauti minimizuojant $(m-1)$ eilės prognozės klaidos energiją. Burg pasiūlė įvertinti k_m minimizuojant tiesioginės ir atgalinės prognozės klaidų energijas. Vadinasi, kad gautume k_m įverti, minimizuojame

$$J_m = \sum_{n=m}^{N-1} \{(e^{(m)}[n])^2 + (r^{(m)}[n])^2\} \quad (1)$$

ir tada

$$a_i^{(m)} = \begin{cases} a_i^{(m-1)} + k_m a_{m-i}^{(m-1)}, & i = 1, \dots, m-1 \\ k_m, & i = m. \end{cases}$$

$(e^{(m)}[n])^2$ ir $(r^{(m)}[n])^2$ priklauso tiktais nuo k_m , nes $(m-1)$ eilės prognozės koeficientai jau yra įvertinti minimizuojant J_{m-1} . Įvertintos tiesioginės ir atgalinės prognozės klaidos yra

$$\begin{aligned} e^{(m)}[n] &= x[n] + \sum_{i=1}^m a_i^{(m)} x[n-i]; \\ r^{(m)}[n] &= x[n-m] + \sum_{i=1}^m a_i^{(m)} x[n-m+i]. \end{aligned}$$

Grotelinio filtro priklausomybės, kurios nusako modelio eilės atnaujinimą tiesioginės ir atgalinės prognozės klaidoms, yra

$$e^{(m)}[n] = e^{(m-1)}[n] + k_m r^{(m-1)}[n-1], \\ n = m, m+1, \dots, N-1;$$

$$r^{(m)}[n] = r^{(m-1)}[n-1] + k_m e^{(m-1)}[n], \\ n = m, m+1, \dots, N-1;$$

čia $e^{(0)}[n] = r^{(0)}[n] = x[n]$. Irašę šias priklausomybes į (1), gauname vidutinę įvertintą prognozės energiją. Negana to, diferencijuodami J_m atžvilgiu k_m , išvestinę prilygindami nuliui ir spręsdami k_m atžvilgiu, gauname

$$k_m = \frac{-2 \sum_{n=m}^{N-1} e^{(m-1)}[n] r^{(m-1)}[n-1]}{\sum_{n=m}^{N-1} \{(e^{(m-1)}[n])^2 + (r^{(m-1)}[n-1])^2\}}.$$

Tai ir yra m -ojo atspindžio koeficiente įvertinimas Burg metodu.

Marple metodas. Šis metodas (Marple, 1980), kaip ir Burg metodas, minimizuoja tiesioginės ir atgalinės prognozės kladų energiją

$$e_M = \sum_{k=1}^{N-M} |f_{M,k}|^2 + \sum_{k=1}^{N-M} |b_{M,k}|^2, \quad (2)$$

kur tiesioginės prognozės kaida yra

$$f_{M,k} = x_{k+M} + \sum_{i=1}^M a_{M,i} x_{k+M-i} = \sum_{i=0}^M a_{M,i} x_{k+M-i}, \quad (3)$$

atgalinės prognozės kaida

$$b_{M,k} = x_k + \sum_{i=1}^M a_{M,i} x_{k+i} = \sum_{i=0}^M a_{M,i} x_{k+i}, \quad (4)$$

čia M yra prognozės eilė, N – analizės intervalo ilgis.

Ne taip kaip Burg metodas, šis metodas ne taiko prielaidos, kad tiesioginės ir atgalinės prognozės klados tenkina Levinsono rekursijos apribojimus

$$f_{M,k} = f_{M-1,k+1} + a_{M,M} b_{M-1,k};$$

$$b_{M,k} = b_{M-1,k} + a_{M,M} f_{M-1,k+1}.$$

Naudojant Marple metodą, išrašius į (2) išraišką (3) ir (4), ieškoma e_M išvestinių

$a_{M,1}, \dots, a_{M,M}$ atžvilgiu ir jos prilyginamos nuiliui. Gauname

$$\frac{\partial e_M}{\partial a_{M,j}} = 2 \sum_{j=0}^M a_{M,j} r_M(i, j) = 0, \quad i = 1, \dots, M; (a_{M,0} = 1),$$

$$\text{čia } r_M(i, j) = \sum_{k=1}^{N-m} (x_{k+M-j} x_{k+M-i} + x_{k+j} x_{k+i}), \\ 0 \leq i, j \leq M.$$

Minimali prognozės klados energija yra

$$e_M = \sum_{j=0}^M a_{M,j} r_M(0, j).$$

Šias išraiškas galima užrašyti matricine forma

$$\mathbf{R}_M \mathbf{A}_M = \mathbf{E}_M;$$

čia

$$\mathbf{A}_M = \begin{bmatrix} 1 \\ a_{M,1} \\ \vdots \\ a_{M,M} \end{bmatrix}, \quad \mathbf{E}_M = \begin{bmatrix} e_M \\ 0 \\ \vdots \\ 0 \end{bmatrix},$$

$$\mathbf{R}_M = \begin{bmatrix} r_M(0,0) & \cdots & r_M(0,M) \\ \vdots & & \vdots \\ r_M(M,0) & \cdots & r_M(M,M) \end{bmatrix}.$$

Šią lygčių sistemą galima spręsti naudojant klasikinius metodus, tačiau tuo atveju skaičiavimo operacijų skaičius yra proporcionalus M^3 . Jai spręsti Marple pasiūlė rekurentinį metodą, kurį naudojant operacijų skaičius yra proporcingas NM .

Split Levinson algoritmas. Split Levinson algoritmas (Delsarte ir kt., 1986) tiesinės prognozės modelio parametrams įvertinti buvo sukurtas siekiant sumažinti autokoreliacinių LPC parametrų vertinimo metodo skaičiavimo operacijų skaičių. Naudojant Split Levinson algoritmą, LPC parametru įverčiai gaunami tie patys, kaip ir naujodant Levinson algoritmą, tačiau Split Levinson algoritmas reikalauja dvigubai mažesnio sandaugų skaičiaus negu Levinson algoritmas ir to paties sumų skaičiaus. Esminis skirtumas, kad Split Levinson algoritmas remiasi išsigimusių prognozės polinomų skaičiavimu. Jeigu turime tiesinės prognozės polinomų aibę

$$A_k(z) = 1 + a_k(1)z^{-1} + a_k(2)z^{-2} + \cdots + a_k(k)z^{-k}, \\ k = 1, \dots, p$$

jie yra susieti priklausomybe

$$A_{k+1}(z) = A_k(z) + \rho_{k+1} z^{-(k+1)} A_k(z^{-1}); \quad (5)$$

čia $\rho_1, \rho_2, \dots, \rho_p$ yra atspindžio koeficientai. Jeigu atspindžio koeficientą ρ_{k+1} prilyginsime 1 arba -1, iš (5) gausime du išsigimusius prognozės polinomus:

$$\begin{aligned} P_{k+1}(z) &= A_k(z) + z^{-(k+1)} A_k(z^{-1}) = \\ &= 1 + (a_k(1) + a_k(k))z^{-1} + (a_k(2) + a_k(k-1))z^{-2} + \\ &\quad + \cdots + (a_k(k) + a_k(1))z^{-k} + z^{-(k+1)} \end{aligned}$$

ir

$$\begin{aligned} Q_{k+1}(z) &= A_k(z) - z^{-(k+1)} A_k(z^{-1}) = \\ &= 1 + (a_k(1) - a_k(k))z^{-1} + (a_k(2) - a_k(k-1))z^{-2} + \\ &\quad + \cdots + (a_k(k) - a_k(1))z^{-k} - z^{-(k+1)}. \end{aligned}$$

Polinomas $P_{k+1}(z)$ yra simetrinis, $Q_{k+1}(z)$ – antisimetrinis. Todėl

$$A_{k+1}(z) = 1/2[P_{k+1}(z) + Q_{k+1}(z)].$$

Didinant modelio eilę rekurentiškai skaičiuojami išsigimė prognozės polinomai ir p -ajai eilei LPC modelio parametrai randami iš $p+1$ ir žemesnės eilės išsigimusų prognozės polinomų.

Modifikuotas Split Levinson algoritmas.

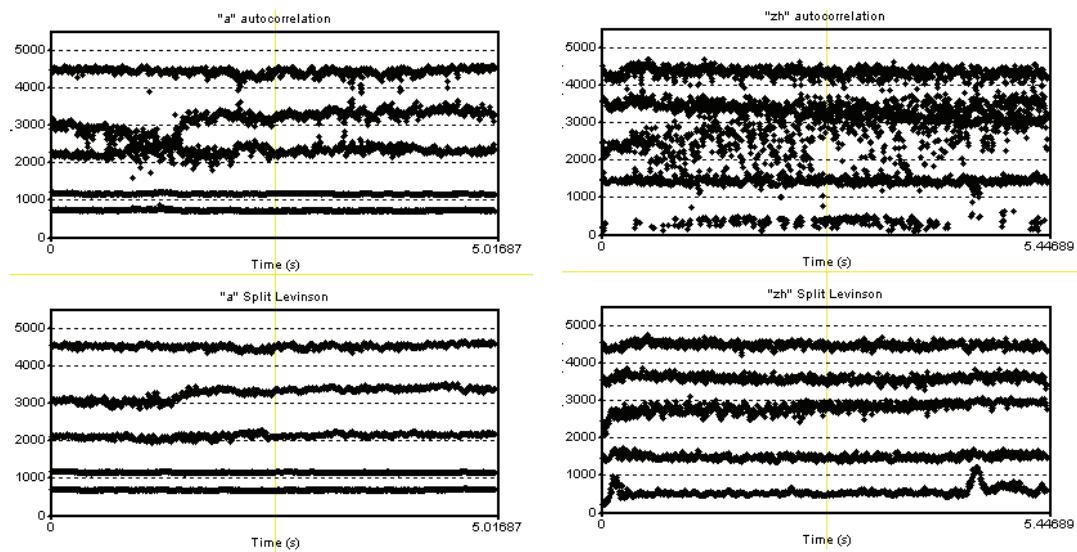
Split Levinson algoritmas buvo modifikuotas (Willems, 1987) formančių trajektorijoms įvertinti. Šis algoritmas naudoja Split Levinson algoritmą kiekvienam kalbos signalo kadriui nustatyti fiksuočia spektro maksimumu skaičių. Vietoje šaknų ieškojimo standartiniame LPC lyginiame, kad nustatyta spektro maksimumu vietas, yra konstruojamas vadinamas išsigimės prognozės polinomas, kurio nuliai yra randomi naudojant iteratyvią procedūrą. Visi šio išsigimusio prognozės polinomo nuliai yra ant vienetinio apskritimo ir rastų spektro maksimumu skaičius visais atvejais yra pusė LPC modelio eilės. Spektro maksimumu vietas yra traktuojamos kaip formantės, rastos pasitelkiant šį algoritmą.

Formantinių požymių išskyrimo metodų palyginimas

Eksperimentiškai buvo lyginami nagrinėti LPC parametru vertinimo metodai: autokoreliacinis, kovariacinis, Burg, Marple ir modifikuotas Split Levinson algoritmas. Metodams palyginti buvo naudojama kalbos signalų analizės programinė įranga „Praat“ (Boersma ir kt., 2005).

Kadangi mūsų sukurtas formantinių požymių išskyrimo būdas (Lipeika, 2005) naudoja autokoreliacinių tiesinės prognozės modelio parametru vertinimo metodą, ši metodą lyginome su kitais mūsų aprašytais tiesinės prognozės modelio parametru vertinimo metodais. Lygindami autokoreliacinių tiesinės prognozės parametru vertinimo metodą su kovariaciniu, Burg ir Marple metodais, esminią skirtumą tarp išskirtų formančių trajektorijų nepastebėjome. Pagal formančių dažnių išskyrimą šie metodai yra lygiaverčiai. Lygindami autokoreliacinių tiesinės prognozės parametru vertinimo metodą su modifikuotu Split Levinson algoritmu pastebėjome, kad modifikuotu Split Levinson algoritmu gaunamos daug stabilesnės formančių trajektorijos.

Kad būtų aiškiau, pateikiame keletą autokoreliacinių ir modifikuoto Split Levinson metodų palyginimo pavyzdžių. Iš balsio „a“ išskirti formantiniai požymiai naudojant autokoreliacinių metodą (viršuje) ir modifikuotą Split Levinson algoritmą (apačioje) pavaizduoti 1 pav. Matome, kad naudojant modifikuotą Split Levinson algoritmą formantiniai požymiai išskiriama daug patikimiau negu autokoreliaciniu metodu. Analogiskas priebalsio „ž“ palyginimas pateiktas 2 pav. Rezultatas vėl rodo modifikuoto Split Levinson algoritmo pranašumą. Šio algoritmo pranašumas būdingas visiems lietuvių kalbos garsams.



1 p a v. Iš balsio „a“ išskirti formantiniai požymiai naudojant autokoreliacinių metodą (viršuje) ir modifikuotą Split Levinson algoritmą (apačioje)

2 p a v. Iš priebaldo „ž“ išskirti formantiniai požymiai naudojant autokoreliacinių metodą (viršuje) ir modifikuotą Split Levinson algoritmą (apačioje)

Išvados

Straipsnyje formančių trajektorijų išskyrimo kokybės požiūriu tiriami tiesinės prognozės modelio parametru įvertinimo metodai. Išnagrinėti autokoreliacino, kovariacinio, Burg, Marple metodų ir modifikuoto Split Levinson algoritmo ypatumai. Šie metodai palyginti pagal formančių trajektorijų išskyrimo kokybę ir nustatyta, kad autokoreliacinis, kovaraicinis, Burg

ir Marple metodai pagal formančių trajektorijų išskyrimo kokybę beveik nesiskiria. Naudojant modifikuotą Split Levinson algoritmą gaunamos daug stabilesnės formančių trajektorijos, ir ši algoritmą siūlome taikyti tiesinės prognozės modelio parametrams vertinti iš kalbos signalo išskiriant formantinius požymius kalbai atpažinti.

LITERATŪRA

- BOERSMA, P.; WEENINK, D. (2005). Praat: doing phonetics by computer. Prieiga per internetą: www.praat.org
- DE WET, F.; WEBER, K.; BOVES, L.; CRANNEN, B.; BENGIO, S.; BOURLAND H. (2004). Evaluation of formant-like features on an automatic vowel classification task. *The Journal of the Acoustical Society of America*, vol. 116(3), p. 1781–1792.
- DELSARTE, P.; GENIN, Y. (1986). The Split Levinson Algorithm. *IEEE Trans. on Acoustics, Speech and Signal Processing*, ASSP-34 (3), p. 470–478.
- HUANG, X.; ACERO, A.; HON, H-W. (2001). *Spoken Language Processing*. Prentice Hall.
- LIPEIKA, A. L. (2005). Formantiniai požymiai atpažįstant kalbą. *Informacijos mokslai*, t. 34, p. 215–219.
- MARPLE, L. (1980). A New Autoregressive Spectrum Analysis Algorithm. *IEEE Trans. On Acoustics, Speech and Signal Processing*, ASSP-28 (4), p. 441–454.
- RABINER, L. R.; JUANG, B. H. (1993). *Fundamentals of Speech Recognition*. Prentice-Hall.
- WILLEMS, L.F. (1987). Robust Formant Analysis for Speech Synthesis Applications. *Proceedings of the European Conference on Speech Technology*, vol.1, p. 250–253.

FORMANT FEATURE EXTRACTION METHODS

Antanas Leonas Lipeika

S u m m a r y

Formant feature extraction is investigated in the paper. Extraction of formant features is based on calculating frequency positions of spectral peaks. The spectrum has been calculated from parameters of linear prediction model. Reliability of formant feature extraction depends on the method used for linear prediction model parameter estimation. The autocorrelation method previously used for linear prediction model parameter estimation was not reliable enough for formant feature extraction. Therefore we were

looking for more reliable method of linear prediction model parameter estimation. The previously used autocorrelation method was compared with covariance, Burg, Marple methods and the modified Split Levinson algorithm. It was concluded, that autocorrelation, covariance, Burg and Marple methods are similar from the point of view of formant feature extraction. The modified Split Levinson algorithm provides the best formant feature estimates.