

Tam tikrų laiko eilučių modelių įvertinimas, naudojant netiesinio mažiausiuju kvadratų uždavinio metodologiją

V. Šimonytė, V. Slivinskas (MII)

1. ĮVADAS

Vienas iš dažnai naudojamų modelių signalų apdorojimo srityje, sistemų identifikacijoje bei laiko eilučių analizėje yra kelių realiųjų sinusoidžių, stebimų triukšme, sumos modelis (žr., pvz., [3]). Jo pagrindiniai parametrai yra dažniai. Kitas populiarus modelis yra kelių silpstančių eksponenčių užtriukšminta suma (žr., pvz., [4]). Pagrindiniai tokio modelio parametrai yra gesimo koeficientai. Šių dviejų modelių kombinacija yra užtriukšminta silpstančių sinusoidžių suma (žr., pvz., [5], [6]). Jo pagrindiniai koeficientai yra gesimo koeficientai ir dažniai. Šiame darbe mes nagrinėjame modelių klasę, kuri apibendrina minėtųjų trijų modelių klasses. Tai vadinaudžiamieji kartotiniai eksponentiniai-sinusiniai modeliai. Šios klasės modelis yra apibrėžiamas kaip kelių kartotinių silpstančių eksponenčių bei kelių kartotinių silpstančių sinusoidžių užtriukšminta suma. Šiame darbe nagrinėjamas kartotinio eksponentinio-sinusinio modelio parametru įvertinimo uždaviny. Straipsnio struktūra yra tokia: nagrinėjamojo modelio aprašymas pateikiamas antrajame skyrelyje. Trečiąjame skyrelyje nagrinėjamas netiesinis mažiausiuju kvadratų uždaviny su atsiskiriančiais kintamaisiais. Kettvirtajame skyrelyje parodoma, kad kartotinio eksponentinio-sinusinio modelio parametru įvertinimo uždaviny gali būti sprendžiamas kaip netiesinis mažiausiuju kvadratų uždaviny su atsiskiriančiais kintamaisiais. Problemos, iškylančios taikant Levenbergo metodą nagrinėjamojo modelio „netiesiniu“ parametru įvertinimui, yra nagrinėjamos penktajame skyrelyje.

2. SIGNALO MODELIS

Šiame skyrelyje mes pateikiame signalo modelį. Nagrinėjamos trys modelio formas: skaliarinė, vektorinė ir forma, kurioje naudojama vadinamoji bazinių signalų matrica.

2.1 *Skaliarinė forma.* Nagrinėkime modelį

$$x(t) = q(t) + e(t), \quad t = 0, 1, \dots, N - 1,$$

čia $\{e(t)\}$ yra balto Gauso triukšmo seka, o $\{q(t)\}$ yra neužtriukšminto signalo reikšmių seka. Tarkime, kad neužtriukšmintas signalas q yra L signalų suma

$$q(t) = q_1(t) + \dots + q_L(t), \tag{1}$$

iš kurių pirmieji L_1 yra kartotinės silpstančios eksponentės, t.y. tokio pavidalo signalai

$$q_1(t) = e^{\lambda_{1,l}t}(A_{l1} + A_{l2}(t) + \dots + A_{lK_l}t^{K_l-1}), \quad (2)$$

čia $\lambda_{1,l} < 0$, $K_l \geq 1$, $A_{lk} \in \mathbf{R}$, $k = 1, \dots, K_l$; $l = 1, \dots, L_1$, o likusieji L_2 yra kartotinės silpstančios sinusoidės

$$q_{L_1+l}(t) = e^{\lambda_{2,l}t} \sum_{k=1}^{K_{L_1+l}} A_{L_1+l,k} t^{k-1} \sin(\omega_l t + \varphi_{L_1+l,k}), \quad (3)$$

čia $\lambda_{2,l} < 0$, $K_{L_1+l} \geq 1$, $A_{L_1+l,k} \in \mathbf{R}$, $\omega_l > 0$, $\varphi_{L_1+l,k} \in [-\pi, \pi]$, $k = 1, \dots, K_{L_1+l}$; $l = 1, \dots, L_2$ ($L = L_1 + L_2$).

2.2 Vektorinė forma. Nagrinėjamajį modelį galima užrašyti tokiu vektoriniu pavidalu:

$$\mathbf{x} = \mathbf{q} + \mathbf{e}$$

$$\mathbf{q} = \mathbf{q}_1 + \dots + \mathbf{q}_L$$

čia

$$\mathbf{x} = (x(0), x(1), \dots, x(N-1))^T,$$

$$\mathbf{q}_l = (q_l(0), q_l(1), \dots, q_l(N-1))^T.$$

Vektoriai \mathbf{e} ir \mathbf{q} yra apibrėžiami analogiškai.

2.3 Bazinių signalų matrica. Nagrinėjamajį modelį galima pateikti ir pavidalu, naudojančiu bazinių signalų matricą. Raide Φ pažymėkime $N \times (K_1 + \dots + K_{L_1} + 2(K_{L_1+1} + \dots + K_L))$ dydžio matricą, sudarytą iš dviejų matricų Φ_1 ir Φ_2 : $\Phi = [\Phi_1 \ \Phi_2]$. Φ_1 yra $N \times (K_1 + \dots + K_{L_1})$ matrica su tokiais stupeliais

$$\Phi_1 = [d_{11}^e, d_{12}^e, \dots, d_{1K_1}^e, \dots, d_{L_11}^e, d_{L_12}^e, \dots, d_{L_1K_{L_1}}^e],$$

čia

$$d_{lk}^e = [\delta_{k1}, e^{\lambda_{1,l}}, 2^{k-1}e^{2\lambda_{1,l}}, \dots, (N-1)^{k-1}e^{(N-1)\lambda_{1,l}}]^T, \quad k = 1, \dots, K_l; \quad l = 1, \dots, L_1.$$

Φ_1 atitinka kartotines silpstančias eksponentes. Φ_2 yra $N \times 2(K_{L_1+1} + \dots + K_L)$ matrica

$$\Phi_2 = [d_{L_1+1,1}^s, d_{L_1+1,1}^s, \dots, d_{L_1+1,K_{L_1+1}}^s, d_{L_1+1,K_{L_1+1}}^s, \dots,$$

$$d_{L_1}^s, d_{L_1}^s, \dots, d_{LK_L}^s, d_{LK_L}^s],$$

čia

$$d_{L_1+l,k}^s = [\delta_{k1}, e^{\lambda_{2,l}} \cos \omega_l, 2^{k-1}e^{2\lambda_{2,l}} \cos 2\omega_l, \dots, (N-1)^{k-1}e^{(N-1)\lambda_{2,l}} \cos(N-1)\omega_l]^T$$

$k = 1, \dots, K_{L_1+l}$; $l = 1, \dots, L_2$. Vektorius d_{lk}^s yra apibrėžiamas analogiškai (vienintelis skirtumas yra tas, kad „cos“ reikia pakeisti į „sin“, o δ_{k1} į 0). Matrica Φ_2 atitinka kartotines silpstančias sinusoides. Φ yra vadinama *bazinių signalų matrica*.

Naudojant šiuos pažymėjimus, neužtriukšmintos sumos vektorių \mathbf{q} galima parašyti taip: $\mathbf{q} = \Phi\mathbf{a}$. Čia \mathbf{a} yra $(K_1 + \dots + K_{L_1} + 2(K_{L_1+1} + \dots + K_L)) \times 1$ dydžio vektorius $\mathbf{a} = [\mathbf{a}_1, \mathbf{a}_2]$, kur vektorius \mathbf{a}_1 yra tokio pavidalo:

$$\mathbf{a}_1 = [A_{11}, \dots, A_{1K_1}, \dots, A_{L_11}, \dots, A_{L_1K_1}]^T,$$

o vektorius \mathbf{a}_2 yra toks:

$$\mathbf{a}_2 = [A_{M1} \sin \varphi_{M1}, A_{M1} \cos \varphi_{M1}, \dots, A_{MK_M} \sin \varphi_{MK_M}, A_{MK_M} \cos \varphi_{MK_M}, \dots, A_{L_1} \sin \varphi_{L_1}, A_{L_1} \cos \varphi_{L_1}, \dots, A_{LK_L} \sin \varphi_{LK_L}, A_{LK_L} \cos \varphi_{LK_L}]^T$$

čia $M = L_1 + 1$.

3. NETIESINIAI MAŽIAUSIŲ KVADRATŲ UŽDAVINIAI SU ATISKIRIANČIAIS KINTAMAISIAIS

Nagrinėkime netiesinį modelį

$$f(\mathbf{a}, \theta; n) = \sum_{m=1}^M a_m g_m(\theta; n),$$

čia $\{g_m(\cdot, \cdot)\}$ yra tolydžios funkcijos, $\mathbf{a} \in \mathbb{R}^M$, $\theta \in \mathbb{R}^k$ (M ir k yra teigiami sveiki skaičiai), $n = 1, \dots, N$. Ši modelį galima parašyti vektoriniu pavidalu $f(\mathbf{a}, \theta) = G(\theta)\mathbf{a}$. $G(\theta) = (G_{nm}(\theta))$ yra $N \times M$ matrica su $G_{nm}(\theta) = g_m(\theta, n)$, $m = 1, \dots, M$, $n = 1, \dots, N$. Reikia rasti parametrų \mathbf{a}, θ reikšmes, kurios minimizuoja funkcionalą

$$r(\mathbf{a}, \theta) = \sum_{n=1}^N (y_n - f(\mathbf{a}, \theta; n))^2 = \|\mathbf{y} - G(\theta)\mathbf{a}\|^2,$$

čia $\mathbf{y} = (y_1, \dots, y_N)^T$ yra duomenų vektorius, $\|\cdot\|$ – Euklido norma: $\|\mathbf{x}\|^2 = \mathbf{x}^T \mathbf{x}$. Esant matricos $G(\theta)$ lokalai pastovaus rango prielaidai, šis uždavinys yra ekvivalentus funkcionalo

$$r_2(\theta) = \|P_{G(\theta)}^\perp \mathbf{y}\|^2,$$

(čia $P_{G(\theta)}^\perp = I_N - G(\theta)G^+(\theta)$ yra ortogonalusis projektorius į matricos $G(\theta)$ stulpelių erdvės ortogonalūji papildini, I_N – vienetinė $N \times N$ matrica) minimizavimo uždaviniui [1]. Suradus θ įvertį, kuris minimizuoja $r_2(\theta)$ vektoriaus \mathbf{a} įvertis apskaičiuojamas taip: $\hat{\mathbf{a}} = G^+(\hat{\theta})\mathbf{y}$. Taigi kintamieji (parametrai) yra atskiriamai tarpusme, kad pirmiausia įvertinamas „netiesinis“ parametras θ , o po to „tiesinis“ parametras \mathbf{a} . Tokie įvertinimo uždaviniai vadinami netiesinių mažiausiuų kvadratų uždaviniais su atskiriančiais parametrais (žr., [1, 7]).

4. ĮVERTINIMO UŽDAVINIO FORMULAVIMAS

Grįžkime prie eksponentinio-sinusinio modelio (1)–(3). Antrame skyrelyje buvo parodyta, kad šio modelio vektorius \mathbf{q} yra lygus bazinių signalų matricos Φ ir vektoriaus \mathbf{a} sandaugai. Todėl kartotinio eksponentinio-sinusinio modelio parametru įvertinimo uždavinys gali būti formuluojamas kaip optimalių parametrų \mathbf{a} ir $\theta = [\lambda_{1,1}, \dots, \lambda_{1,L_1}, \lambda_{2,1}, \dots, \lambda_{2,L_2}, \omega_1, \dots, \omega_{L_2}]$, minimizuojančių netiesinį funkcionalą

$$r(\mathbf{a}, \theta) = \|x - \Phi(\theta)\mathbf{a}\|^2,$$

radimo uždavinys. Kaip tvirtinama 3-ame skyrelyje, esant matricos $\Phi(\theta)$ lokalai pastovaus rango prielaidai, šis uždavinys yra ekvivalentus parametro $\hat{\theta}$, minimizuojančiui funkcionalui

$$r_2(\theta) = \|P_{\Phi(\theta)}^\perp \mathbf{x}\|^2,$$

radimo uždaviniui (čia $P_{\Phi}^\perp = I_N - \Phi(\Phi^T \Phi)^{-1} \Phi^T = I_N - \Phi \Phi^+$ yra ortogonalusis projektorius į matricos Φ stulpelių erdvės ortogonaluji papildinį). Tuomet $\hat{\mathbf{a}} = \Phi^+(\hat{\theta})x$.

5. LEVENBERGO METODO REALIZACIJA EKSPONENTINIO-SINUSINIO MODELIO ATVEJU

Levenbergo metodas, taikant jį funkcionalo $r_2(\cdot)$ minimizavimui, yra parametru θ pradinio įverčio tikslinimo iteratyvi procedūra:

$$\theta^{l+1} = \theta^l - (V^T(\theta^l)V(\theta^l) + c_l I_k)^{-1} V^T(\theta^l) \mathbf{b}(\theta^l), \quad l = 0, 1, \dots$$

kur $V(\theta) = DP_{\Phi(\theta)}^\perp \mathbf{x}$ yra $N \times k$ matrica (čia D žymi atvaizdžio Frešė išvestinę), $\mathbf{b}(\theta) = P_{\Phi(\theta)}^\perp \mathbf{x} - N \times 1$ vektorius, $I_k - k \times k$ vienetinė matrica ($k = L_1 + 2L_2$), c_l – Levenbergo metodo konstanta l -oje iteracijoje (žr. [1]).

Iš pirmo žvilgsnio atrodo neaišku, kaip apskaičiuoti $V(\theta) = DP_{\Phi(\theta)}^\perp \mathbf{x}$. Pirmiausia reikia žinoti, kaip apskaičiuoti $DP_{\Phi(\theta)}^\perp$. Darbe [1] įrodyta, kad

$$DP_{\Phi}^\perp = -P_{\Phi}^\perp D\Phi B - (P_{\Phi}^\perp D\Phi B)^T,$$

čia $D\Phi$ yra trimatis tensorius, sudarytas iš $k(N \times n)$ matricų, kiekvienoje iš kurių yra matricos Φ elementų dalinės išvestinės vienos iš k parametru vektoriaus θ komponenčių atžvilgiu, o B yra tam tikra simetrinė apibendrinta matricos Φ atvirkštinė ($n = K_1 + \dots + K_{L_1} + 2(K_{L_1+1} + \dots + K_L)$). Tegu S_i yra $N \times n$ matrica, kuri lygi Φ išvestinei parametru vektoriaus θ i -osios komponentės θ_i atžvilgiu. Tuomet DP_{Φ}^\perp yra sudaryta iš k ($N \times N$) pavidalo

$$(DP_{\Phi}^\perp)_i = -P_{\Phi}^\perp S_i B - (P_{\Phi}^\perp S_i B)^T$$

matricų. Taigi $DP_{\Phi}^\perp \mathbf{x}$ yra sudaryta iš k ($N \times 1$) vektorių $(DP_{\Phi}^\perp)_i \mathbf{x}$ ($i = 1, \dots, n$). Vadinas, $V(\theta)$ yra $N \times k$ matrica.

Kaip apskaičiuoti $P_{\Phi}^\perp S_i B$? Speciali matricos S_i struktūra įgalina žymiai supaprastinti tokios matricų sandaugos apskaičiavimą. Žemaiate pateikiama teorema atskleidžia ši supaprastinimą.

TEOREMA. Tegu $1 \leq i \leq L_1$. Tada $N \times N$ matrica $P_\Phi^\perp S_i B$ yra lygi $N \times n$ matricos $P_\Phi^\perp S_i$ p_1 -ojo stulpelio ir $n \times N$ matricos B p_1 -osios eilutės sandaugai ($p_1 = K_1 + \dots + K_i$). Jei $L_1 + 1 \leq i \leq L_1 + L_2$, tai matrica $P_\Phi^\perp S_i B$ yra lygi matricos $P_\Phi^\perp S_i$ stulpelių su indeksais $p_2 - 1, p_2$ ir matricos B eilučių su tais pačiais indeksais sandaugai ($p_2 = K_1 + \dots + K_{L_1} + 2(K_{L_1+1} + \dots + K_i)$).

Irodymas. Nagrinėkime atvejį $1 \leq i \leq L_1$. Šiuo atveju matrica S_i yra lygi matricos Φ elementų dalinei išvestinei i -sios kartotinės silpstančios eksponentės gėsimo koeficiente λ atžvilgiu. S_i matmenys yra tokie patys kaip matricos Φ , t.y. $N \times n$. Visi n matricos S_i stulpeliai yra lygūs nuliui, išskyrus stulpelius su indeksais $m_1 + 1, m_1 + 2, \dots, m_1 + K_i$, čia $m_1 = K_1 + \dots + K_{i-1}$. Matrica S_i turi tokią struktūrą: $S_i = [0_{N \times m_1} \ E \ 0_{N \times r_1}]$, čia $r_1 = K_{i+1} + \dots + K_{L_1} + 2(K_{L_1+1} + \dots + K_L)$, o E yra tokio pavيدalo $N \times K_i$ matrica

$$E = \begin{pmatrix} 0 & \dots & 0 & 0 \\ e^\lambda & \dots & e^\lambda & e^\lambda \\ 2e^{2\lambda} & \dots & 2^{K_i-1}e^{2\lambda} & 2^{K_i}e^{2\lambda} \\ \vdots & \ddots & \vdots & \vdots \\ (N-1)e^{(N-1)\lambda} & \dots & (N-1)^{K_i-1}e^{(N-1)\lambda} & (N-1)^{K_i}e^{(N-1)\lambda} \end{pmatrix}$$

(kai $i = 1$, S_i neturi pirmojo nulinio bloko, o kai $i = L_1$, $r_1 = 2(K_{L_1+1} + \dots + K_L)$). E atitinka tokį bazinių signalų matricos $N \times K_i$ dydžio bloką:

$$\begin{pmatrix} 1 & 0 & \dots & 0 \\ e^\lambda & e^\lambda & \dots & e^\lambda \\ e^{2\lambda} & e^{2\lambda} & \dots & 2^{K_i-1}e^{2\lambda} \\ \vdots & \vdots & \ddots & \vdots \\ e^{(N-1)\lambda} & (N-1)e^{(N-1)\lambda} & \dots & (N-1)^{K_i-1}e^{(N-1)\lambda} \end{pmatrix}$$

Nesunku matyti, kad pirmieji K_i-1 matricos stulpeliai priklauso bazinių signalų matricos stulpelių erdvėi. Todėl projektoriaus matricos P_Φ^\perp ir bet kurio iš šių stulpelių sandauga yra lygi nuliniam stulpeliui. Vadinas, projektoriaus matricos P_Φ^\perp ir matricos S_i sandauga yra $N \times n$ matrica, kurios visi stulpeliai yra lygūs nuliniam stulpeliui, išskyrus stulpelį su indeksu $p_1 = K_1 + \dots + K_i$. Taigi matricų sandauga $P_\Phi^\perp S_i \Phi^B$ yra lygi $N \times n$ matricos $P_\Phi^\perp S_i$ p_1 -ojo stulpelio ir $n \times N$ matricos B p_1 -osios eilutės sandaugai.

Atvejis $L_1 + 1 \leq i \leq L_1 + L_2$ yra tiriamas analogiškai.

IŠVADOS. Mes nagrinėjome vadinamąjį kartotinį eksponentinį-sinu-sinį modelį. Buvo parodyta, kad tokio modelio parametru įvertinimo uždavinys yra ekvivalentus netiesiniams mažiausiuju kvadratų uždavinui su atskiriančiais kintamaisiais. Buvo aptartos problemos, išskylančios realizuojant Levenbergo metodą nagrinėjamojį modelio „netiesinių“ parametru įvertinimui, bei gauti kai kurie rezultatai, supaprastinantys metodo įgyvendinimą šiuo atveju.

LITERATŪRA

- [1] G. Golub and V. Pereyra, The differentiation of pseudo-inverses and nonlinear least squares problems whose variables separate, *SIAM Journal on Numerical Analysis*, **10** (1973), 413–432.
- [2] A. Sen and M. Srivastava, *Regression Analysis: Theory, Methods and Applications*, Springer-Verlag, New York, 1990.
- [3] J.-J. Fuchs, Multiscale identification of real sinusoids in noise, *Automatica*, **30** (1994), 147–155.
- [4] M. R. Osborne and G. K. Smyth, A modified Prony algorithm for exponential function fitting, *SIAM J. Sci. Comput.*, **6** (1995), 119–138.
- [5] T. Wigren and A. Nehorai, Asymptotic Cramer-Rao bounds of the parameters of damped sine waves in noise, *IEEE Trans. Signal Processing*, **39** (1991), 1017–1020.
- [6] Y. -X. Yao and S. M. Pandit, Cramer-Rao lower bounds for a damped sinusoidal process, *IEEE Trans. Signal Processing*, **43** (1995), 878–885.
- [7] G. J. S. Ross, *Nonlinear Estimation*, Springer-Verlag, New York, 1990.

Estimation of some time series models using methodology of a nonlinear least squares problem

V. Šimonytė, V. Slivinskas

We have considered the so-called multiple exponential-sinusoidal model. This model is defined as a sum of multiple damped exponentials and multiple damped sinusoids in noise. The problem of estimation of parameters of the model has been addressed. It has been shown that this problem can be solved as a nonlinear least squares problem whose variables separate. The problems arising in implementation of Levenberg method for estimation of „nonlinear” parameters of the model have been discussed, and some results simplifying implementation of the method in this case have been obtained.