

Noi algoritmi de tip LMS cu convergență variabilă

SINTEZA FAZEI UNICE / 2011

Contract nr. 7/5.08.2010, Cod TE-50

Convergența algoritmilor de tip LMS poate fi controlată prin prisma a doi parametri. În primul rând, pasul de adaptare al algoritmului realizează compromisul între viteza de convergență și dezadaptare. Cel de al doilea parametru este factorul de regularizare, ce aparent urmărește evitarea unei probleme de nesingularitate. În literatura de specialitate există numeroase variante de algoritmi de tip LMS cu pas de adaptare variabil, dezvoltăți în scopul obținerii unui compromis avantajos între cele două criterii de performanță enunțate anterior. Cu toate acestea, se poate demonstra că factorul de regularizare joacă de asemenea un rol deosebit de important în acest context, în special în situațiile practice în care semnalul de referință este afectat de un zgomot.

În cadrul acestei etape de cercetare a proiectului, am dezvoltat o nouă familie de algoritmi adaptivi de tip LMS cu convergență variabilă, pe baza controlului factorului de regularizare. S-au elaborat expresii optimale pentru acest parametru, ținând cont de prezența și nivelul zgomotului ce afectează semnalul de referință al filtrului adaptiv. Vom prezenta în continuare sintetic abordarea în cazul a trei algoritmi foarte utilizati în aplicațiile de compensare a ecoului [1]. Este vorba despre NLMS (*Normalized Least-Mean-Square*), *signed-regressor* NLMS (SR-NLMS) și *improved proportionate* NLMS (IPNLMS). Prezentarea detaliată a acestor rezultate, precum și extinderea în cazul altor algoritmi a fost publicată în [2].

Să presupunem că avem următorul semnal de referință:

$$d(n) = \mathbf{h}^T \mathbf{x}(n) + w(n) = y(n) + w(n), \quad (1)$$

unde $\mathbf{h} = [h_0 \ h_1 \ \dots \ h_{L-1}]^T$ este răspunsul la impulsul al sistemului necunoscut (ce urmează a fi identificat) de lungime L , $\mathbf{x}(n) = [x(n) \ x(n-1) \ \dots \ x(n-L+1)]^T$ este vectorul semnalului de intrare și $w(n)$ este un zgomot aditiv de medie nulă. Secvența $y(n)$ joacă rolul semnalului de ecou într-o aplicație de compensare a ecoului. De asemenea, putem defini raportul semnal pe zgomot sau ecou pe zgomot astfel:

$$\text{ENR} = \frac{\sigma_y^2}{\sigma_w^2} = \frac{\mathbf{h}^T \mathbf{R}_x \mathbf{h}}{\sigma_w^2}, \quad (2)$$

unde $\sigma_y^2 = E[y^2(n)]$ și $\sigma_w^2 = E[w^2(n)]$ sunt varianțele lui $y(n)$ și $w(n)$, iar $\mathbf{R}_x = E[\mathbf{x}(n)\mathbf{x}^T(n)]$ reprezintă matricea de corelație a lui $\mathbf{x}(n)$. În acest context, obiectivul principal este de a identifica/estima \mathbf{h} cu un filtru adaptiv

$$\hat{\mathbf{h}}(n) = [\hat{h}_0(n) \quad \hat{h}_1(n) \quad \dots \quad \hat{h}_{L-1}(n)]^T, \quad (3)$$

astfel încât dezalinierea normată să îndeplinească următoarea condiție:

$$\frac{\|\hat{\mathbf{h}}(n) - \mathbf{h}\|_2^2}{\|\mathbf{h}\|_2^2} \leq \iota, \quad (4)$$

unde ι este o constantă pozitivă mică și $\|\cdot\|_2$ reprezintă norma ℓ_2 .

Algoritmul NLMS este definit de următoarele relații:

$$e(n) = d(n) - \mathbf{x}^T(n)\hat{\mathbf{h}}(n-1) = d(n) - \hat{y}(n), \quad (5)$$

$$\hat{\mathbf{h}}(n) = \hat{\mathbf{h}}(n-1) + \alpha \frac{\mathbf{x}(n)e(n)}{\delta + \mathbf{x}^T(n)\mathbf{x}(n)}, \quad (6)$$

unde α ($0 < \alpha < 2$) este pasul de adaptare și δ este constanta de regularizare. Relația de reactualizare a coeficienților se poate scrie astfel:

$$\hat{\mathbf{h}}(n) = \mathbf{P}(n)\hat{\mathbf{h}}(n-1) + \alpha\tilde{\mathbf{h}}(n), \quad (7)$$

unde

$$\mathbf{P}(n) = \mathbf{I} - \alpha \frac{\mathbf{x}(n)\mathbf{x}^T(n)}{\delta + \mathbf{x}^T(n)\mathbf{x}(n)}, \quad (8)$$

și

$$\tilde{\mathbf{h}}(n) = \frac{\mathbf{x}(n)d(n)}{\delta + \mathbf{x}^T(n)\mathbf{x}(n)} \quad (9)$$

reprezintă termenul de corecție al algoritmului NLMS. De fapt, $\tilde{\mathbf{h}}(n)$ se obține prin

$$\min_{\tilde{\mathbf{h}}(n)} [d(n) - \mathbf{x}^T(n)\tilde{\mathbf{h}}(n)]^2 \quad \text{s.t.} \quad \delta \|\tilde{\mathbf{h}}(n)\|_2^2. \quad (10)$$

Deoarece $\tilde{e}(n) = d(n) - \mathbf{x}^T(n)\tilde{\mathbf{h}}(n)$ este eroarea dintre semnalul de referință și semnalul obținut pe baza optimizării (10), parametrul de regularizare se poate obține din condiția

$$E[\tilde{e}^2(n)] = \sigma_w^2. \quad (11)$$

De asemenea, avem relația (valabilă pentru $L \gg 1$)

$$\mathbf{x}^T(n)\mathbf{x}(n) = L\sigma_x^2. \quad (12)$$

Dezvoltând (11) și ținând cont de (12), se obține ecuația:

$$\delta^2 - 2\frac{L\sigma_x^2}{\text{ENR}}\delta - \frac{(L\sigma_x^2)^2}{\text{ENR}} = 0, \quad (13)$$

ce are soluția:

$$\delta = \frac{L(1 + \sqrt{1 + \text{ENR}})}{\text{ENR}} \sigma_x^2 = \beta_{\text{NLMS}} \sigma_x^2, \quad (14)$$

unde

$$\beta_{\text{NLMS}} = \frac{L(1 + \sqrt{1 + \text{ENR}})}{\text{ENR}}. \quad (15)$$

În plus, $\lim_{\text{ENR} \rightarrow 0} \delta = \infty$ și $\lim_{\text{ENR} \rightarrow \infty} \delta = 0$, ceea ce justifică validitatea rezultatului obținut.

În cazul algoritmului SR-NLMS avem relațiile:

$$e(n) = d(n) - \hat{y}(n), \quad (16)$$

$$\hat{\mathbf{h}}(n) = \hat{\mathbf{h}}(n-1) + \alpha \frac{\text{sgn}[\mathbf{x}(n)] e(n)}{\delta + \mathbf{x}^T(n) \text{sgn}[\mathbf{x}(n)]}, \quad (17)$$

Performanțele sale sunt echivalente cu cele ale algoritmului NLMS, dar având o complexitate mai scăzută (cu L multiplicări).

Descompunerea relației de reactualizare a algoritmului SR-NLMS se face tot pe baza (7), dar acum

$$\mathbf{P}(n) = \mathbf{I} - \alpha \frac{\text{sgn}[\mathbf{x}(n)] \mathbf{x}^T(n)}{\delta + \mathbf{x}^T(n) \text{sgn}[\mathbf{x}(n)]} \quad (18)$$

și

$$\tilde{\mathbf{h}}(n) = \frac{\text{sgn}[\mathbf{x}(n)] d(n)}{\delta + \mathbf{x}^T(n) \text{sgn}[\mathbf{x}(n)]}. \quad (19)$$

Astfel avem

$$\mathbf{x}^T(n) \text{sgn}[\mathbf{x}(n)] = L E[|x(n)|]. \quad (20)$$

Presupunând că semnalul $x(n)$ este Gaussian și utilizând teorema Price se obține

$$E[|x(n)|] = \sqrt{\frac{2}{\pi \sigma_x^2}} \sigma_x^2 = \beta_x \sigma_x^2,$$

unde

$$\beta_x = \sqrt{\frac{2}{\pi \sigma_x^2}}. \quad (21)$$

De asemenea, avem

$$\mathbf{x}^T(n) \text{sgn}[\mathbf{x}(n)] = L \beta_x \sigma_x^2. \quad (22)$$

Pe baza condițiilor (11) și (22) se obține ecuația:

$$\delta^2 - 2 \frac{L \beta_x \sigma_x^2}{\text{ENR}} \delta - \frac{(L \beta_x \sigma_x^2)^2}{\text{ENR}} = 0. \quad (23)$$

Soluția rezultată este

$$\delta = \frac{L\beta_x (1 + \sqrt{1 + \text{ENR}})}{\text{ENR}} \sigma_x^2 = \beta_{\text{SR-NLMS}} \sigma_x^2,$$

unde

$$\beta_{\text{SR-NLMS}} = \frac{L\beta_x (1 + \sqrt{1 + \text{ENR}})}{\text{ENR}}. \quad (24)$$

Algoritmii de tip *proportionate* au la bază ideea de reactualizare a coeficienților filtrului adaptiv în funcție de amplitudinea fiecărui, favorizând astfel adaptarea mai rapidă a coeficienților semnificativi [3]. Acești algoritmi se pretează foarte bine în cazul identificării sistemelor de tip *sparse*, cum este cazul căilor de ecou (de linie sau acustic) [4]. Algoritmul IPNLMS [5] face parte din această categorie, fiind foarte utilizat în practică datorită simplității și eficacității sale. Acest algoritm are la bază relațiile:

$$e(n) = d(n) - \hat{y}(n), \quad (25)$$

$$\hat{\mathbf{h}}(n) = \hat{\mathbf{h}}(n-1) + \alpha \frac{\mathbf{G}(n-1)\mathbf{x}(n)e(n)}{\delta + \mathbf{x}^T(n)\mathbf{G}(n-1)\mathbf{x}(n)}, \quad (26)$$

unde $\mathbf{G}(n-1) = \text{diag} [g_0(n-1) \ g_1(n-1) \ \cdots \ g_{L-1}(n-1)]$ este o matrice de dimensiune $L \times L$,

$$g_l(n-1) = \frac{1-\kappa}{2L} + (1+\kappa) \frac{|\hat{h}_l(n-1)|}{2 \|\hat{\mathbf{h}}(n-1)\|_1}, \quad 0 \leq l \leq L-1, \quad (27)$$

$\kappa (-1 \leq \kappa < 1)$ este parametrul de “proporționalitate”, iar $\|\cdot\|_1$ reprezintă norma ℓ_1 .

Relația de reactualizare IPNLMS se poate scrie astfel [6]:

$$\hat{\mathbf{h}}(n) = \mathbf{P}'(n)\hat{\mathbf{h}}(n-1) + \alpha \tilde{\mathbf{h}}'(n), \quad (28)$$

unde

$$\mathbf{P}'(n) = \mathbf{I} - \alpha \frac{\mathbf{G}(n-1)\mathbf{x}(n)\mathbf{x}^T(n)}{\delta + \mathbf{x}^T(n)\mathbf{G}(n-1)\mathbf{x}(n)} \quad (29)$$

și

$$\tilde{\mathbf{h}}'(n) = \frac{\mathbf{G}(n-1)\mathbf{x}(n)d(n)}{\delta + \mathbf{x}^T(n)\mathbf{G}(n-1)\mathbf{x}(n)} \quad (30)$$

reprezintă componenta de corecție a algoritmului. În acest context, se poate arăta că $\tilde{\mathbf{h}}'(n)$ reprezintă o soluție a problemei de optimizare:

$$\min_{\tilde{\mathbf{h}}'(n)} \left[d(n) - \mathbf{x}^T(n)\tilde{\mathbf{h}}'(n) \right]^2 \quad \text{s. t. } \delta \|\tilde{\mathbf{h}}'(n)\|_1. \quad (31)$$

Prin urmare, pe baza condiției (11) se poate obține expresia parametrului de regularizare optim. Pentru $L \gg 1$ și presupunând că semnalul $x(n)$ este staționar, rezultă

$$\begin{aligned} \mathbf{x}^T(n)\mathbf{G}(n-1)\mathbf{x}(n) &= \frac{1-\kappa}{2L}\mathbf{x}^T(n)\mathbf{x}(n) + \frac{1+\kappa}{2\|\hat{\mathbf{h}}(n-1)\|_1} \sum_{l=0}^{L-1} x^2(n-l) |\hat{h}_l(n-1)| \\ &\approx \frac{1-\kappa}{2}\sigma_x^2 + \frac{1+\kappa}{2}\sigma_x^2 \\ &\approx \sigma_x^2. \end{aligned} \quad (32)$$

Utilizând condițiile (11) și (32), se obține ecuația:

$$\delta^2 - 2 \frac{\sigma_x^2}{\text{ENR}} \delta - \frac{(\sigma_x^2)^2}{\text{ENR}} = 0, \quad (33)$$

a cărei soluție este

$$\delta = \frac{1 + \sqrt{1 + \text{ENR}}}{\text{ENR}} \sigma_x^2 = \beta_{\text{IPNLMS}} \sigma_x^2, \quad (34)$$

unde

$$\beta_{\text{IPNLMS}} = \frac{1 + \sqrt{1 + \text{ENR}}}{\text{ENR}}. \quad (35)$$

Abordarea poate fi extinsă într-o manieră similară și pentru algoritmul SR-IPNLMS, precum în cazul algoritmului proiecțiilor afine (APA) [7].

O serie de simulări au fost efectuate în contextul unei aplicații de compensare a ecouului acustic. Calea de ecou are 512 coeficienți (la o frecvență de eşantionare de 8 kHz), iar filtrul adaptiv are lungimea $L = 512$. Semnalul de intrare $x(n)$ este zgomot alb Gaussian sau secvență vocală. Zgomotul de fond este presusupus alb și Gaussian, cu ENR = 10 dB. Performanțele algoritmilor au fost evaluate prin prisma dezalinierii normate (în dB), mediată pe 20 de realizări independente. Performanțele obținute utilizând parametrii de regularizare optimi au fost comparate cu cele obținute în cazul unor valori constante. Rezultatele prezentate în figurile anexate justifică validitatea soluțiilor propuse.

References

- [1] J. Benesty, T. Gaensler, D. R. Morgan, M. M. Sondhi, and S. L. Gay, *Advances in Network and Acoustic Echo Cancellation*. Berlin, Germany: Springer-Verlag, 2001.
- [2] J. Benesty, C. Paleologu, and S. Ciochină, “On regularization in adaptive filtering,” *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 19, pp. 1734–1742, Aug. 2011.
- [3] D. L. Duttweiler, “Proportionate normalized least-mean-squares adaptation in echo cancelers,” *IEEE Transactions on Audio, Speech, and Language Processing*, vol. 8, pp. 508–518, Sept. 2000.
- [4] C. Paleologu, J. Benesty, and S. Ciochină, *Sparse Adaptive Filters for Echo Cancellation*. Morgan & Claypool Publishers, 2010.
- [5] J. Benesty and S. L. Gay, “An improved PNLMS algorithm,” in *Proc. IEEE ICASSP*, 2002, pp. 1881–1884.
- [6] J. Benesty, C. Paleologu, and S. Ciochină, “Proportionate adaptive filters from a basis pursuit perspective,” *IEEE Signal Processing Letters*, vol. 17, pp. 985–988, Dec. 2010.
- [7] C. Paleologu, J. Benesty, and S. Ciochină, “Regularization of the affine projection algorithm,” *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 58, pp. 366–370, June 2011.

Director de proiect

Conf. dr. ing. Constantin Paleologu




Figure 1: Performanțele algoritmului NLMS, zgomot alb Gaussian la intrare.




Figure 2: Performanțele algoritmului NLMS, semnal vocal la intrare.




Figure 3: Performanțele algoritmului SR-NLMS, zgomot alb Gaussian la intrare.




Figure 4: Performanțele algoritmului IPNLMS, zgomot alb Gaussian la intrare.




Figure 5: Performanțele algoritmilor NLMS și IPNLMS, semnal vocal la intrare.




Figure 6: Performanțele algoritmului SR-IPNLMS, zgomot alb Gaussian la intrare.