

روشی نو برای استخراج سریع پتانسیل‌های برانگیخته شنوایی

علی حیدری چالشتری^۱، احمدرضا شرافت^{۲*}

۱- دانشجوی دکتری مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس

۲- استاد مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس

sharafat@modares.ac.ir

(دریافت مقاله: خرداد ۱۳۸۹، پذیرش مقاله: آبان ۱۳۸۹)

چکیده- در این مقاله، روشهای سازگار مبتنی بر شبکه توابع پایه شعاعی و فیلتر کالمن در استخراج پتانسیل‌های برانگیخته مرور شده و عملکرد آنها در استخراج سریع پتانسیل‌های برانگیخته شنوایی مقایسه می‌شود. همچنین برای بهبود مشخصه SNR پتانسیل‌های برانگیخته، روشی مبتنی بر مدل‌سازی سیگنال برانگیخته در چارچوب فیلتر کالمن ارائه می‌شود که دقت استخراج سیگنال برانگیخته را نسبت به روشهای قبل، به طور قابل ملاحظه‌ای بهبود می‌بخشد. نتایج شبیه‌سازی نشان می‌دهند که روشهای سازگار و فیلتر کالمن در کاهش تعداد آزمون‌های مورد نیاز برای استخراج پتانسیل‌های برانگیخته شنوایی، تفاوت قابل ملاحظه‌ای ندارند و روش پیشنهادی، امکان استخراج دقیق‌تر دامنه پتانسیل برانگیخته را برای تعداد کم آزمون‌ها فراهم می‌سازد.

کلید واژگان: پتانسیل‌های برانگیخته شنوایی، شبکه توابع پایه شعاعی، هموارساز کالمن، الکتروانسفالوگرافی.

۱- مقدمه

پتانسیل‌های برانگیخته^۱ حسی به طور گسترده‌ای در آزمون‌های کلینیکی استفاده می‌شوند. این پتانسیل‌ها اطلاعاتی را درباره سیستم‌های حسی فراهم می‌سازند که معمولاً به روشهای دیگری قابل دسترسی نیست. نبود پتانسیل برانگیخته طبیعی، می‌تواند ناشی از عملکرد نادرست اندام حسی انتهایی یا وجود اختلال

در سازوکار تولیدکننده پتانسیل برانگیخته باشد [۱] تا [۳].

پاسخ شنوایی ساقه مغز^۲ (ABR) به صورت گسترده‌ای استفاده می‌شود، زیرا این سیگنال برانگیخته شاخص کلینیکی ارزشمندی در ارزیابی آسیب‌های حلزون شنوایی و عصب هشتم، پایش^۳ در زمان عمل جراحی و غربالگری^۴ شنوایی کودکان و بیماران خاص است. این

2. Auditory Brainstem Response
3. Monitoring
4. Screening

1. Evoked Potential

سیگنال با تعداد پنج تا هفت قله مثبت مشخص می‌شود که شاخص‌ترین آنها، قله پنجم است. بررسی تأخیر قله‌های پتانسیل برانگیخته شنوایی و نسبت دامنه قله پنجم به قله اول، هسته اصلی در بررسی‌های کلینیکی است [۴] تا [۸].

استخراج پتانسیل‌های برانگیخته از سیگنال الکتروانسفالوگرافی^۱ (EEG) پس‌زمینه، به علت پایین بودن نسبت سیگنال به نویز^۲ (SNR) این پتانسیل‌ها دشوار است. برای حذف فعالیت مغزی پس‌زمینه و بهبود SNR، معمولاً از تعداد زیادی آزمون به صورت سنکرون، متوسط‌گیری می‌شود. متوسط‌گیری سنکرون، از نظر کلینیکی دشوار و زمان‌بر بوده و برای بسیاری از بیماران مانند کودکان و سالخوردگان، نامطلوب است. علاوه بر این، متوسط‌گیری، تغییرات پتانسیل‌های برانگیخته در طی آزمون‌ها را - که می‌توانند حاوی اطلاعات کلینیکی مهمی باشند - از بین می‌برد [۱] تا [۳].

تصویر کردن سیگنال برانگیخته بر روی مؤلفه‌های الگوی حاصل از تجزیه سیگنال متوسط با استفاده از تخمین حداقل مربعات^۳ (LS)، فیلتر کالمن، فیلتر سازگار مبتنی بر شبکه توابع پایه شعاعی^۴ (RBF)، و تخمین بیشترین شباهت^۵ (ML)، روشهایی جایگزین برای متوسط‌گیری است که به منظور کاستن از تعداد آزمون‌های مورد نیاز و تخمین سریع‌تر پتانسیل برانگیخته یا تحلیل آزمون‌های متوالی پتانسیل‌های برانگیخته ارائه شده است [۴]، [۹] تا [۱۴].

روشهای متعددی برای تخمین سیگنال برانگیخته شنوایی ارائه شده که آنها را می‌توان به سه دسته تقسیم کرد. دسته اول، روشهای تک‌آزمون^۶ استخراج سیگنال برانگیخته از پس‌زمینه سیگنال EEG با هدف تعقیب تغییرات دامنه و تأخیر سیگنال‌های برانگیخته در آزمون‌های مختلف است. این روش‌ها که بیشتر برای سیگنال‌های برانگیخته مربوط به ادراک به کار رفته‌اند، در پایش زمان عمل جراحی کاربرد دارند [۱۵]. دسته دوم، روشهای آشکارسازی و طبقه‌بندی سیگنال‌های برانگیخته شنوایی است که هدف آنها کاهش زمان ثبت سیگنال‌ها است. این روش‌ها، شکل کامل سیگنال برانگیخته را استخراج نمی‌کنند بلکه فقط وجود قله پنجم را آشکارسازی می‌کنند. کاربرد این روش‌ها بیشتر در غربالگری شنوایی کودکان است [۱۶] و [۱۷]. هدف دسته سوم - که آنها را روشهای استخراج سریع پتانسیل‌های برانگیخته می‌نامیم - کاهش زمان ثبت سیگنال از طریق کاهش تعداد آزمون‌های مورد نیاز برای متوسط‌گیری و بهبود سیگنال متوسط است. این روش‌ها، شکل کامل سیگنال برانگیخته را استخراج می‌کنند [۴] و [۱۸].

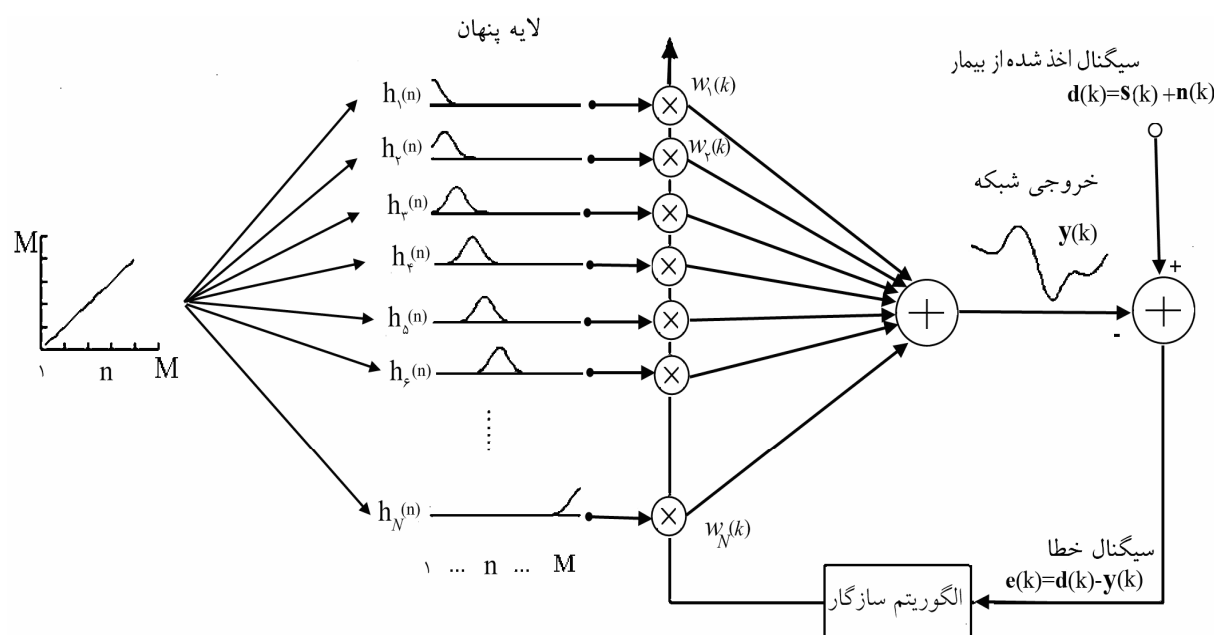
یکی از روشهایی که برای استخراج سریع سیگنال‌های برانگیخته ارائه شده، روش فیلتر سازگار مبتنی بر شبکه توابع پایه شعاعی است. این روش سیگنال برانگیخته را به شکل ترکیبی خطی از توابع گوسی انتقال یافته توصیف می‌کند. مزیت این ساختار سازگار آن است که به سیگنال مرجع نیاز نداشته و می‌تواند با انجام ۸۰ آزمون به دقتی معادل با دقت متوسط‌گیری از ۱۰۰۰ آزمون دست یابد [۴]. نکته ضعف این روش آن است که فقط از فرض

1. Electroencephalography
2. Signal-to-Noise Ratio
3. Least Squares
4. Radial Basis Functions
5. Maximum Likelihood

6. Single Trial

در این مقاله، نخست به بررسی و مقایسه این روش‌ها می‌پردازیم. سپس روش متفاوتی برای استفاده مجدد از اطلاعات آزمون‌های قبلی ارائه می‌شود که می‌تواند دقت تخمین دامنه پتانسیل‌های برانگیخته را برای تعداد کم آزمون‌ها بهبود بخشیده و راه را برای توسعه روشهای استخراج سریع پتانسیل‌های برانگیخته هموار کند. در بخش‌های بعدی مقاله، پس از معرفی روشهای بالا، شباهت این روش‌ها را نشان داده و کارایی آنها را در استخراج سریع پتانسیل‌های برانگیخته شنوایی مقایسه می‌کنیم. سپس، روش خود را ارائه و نتایج به‌کارگیری آن را در بهبود SNR سیگنال ABR نشان می‌دهیم.

هموار بودن شکل سیگنال‌های برانگیخته استفاده کرده و اطلاعات اولیه بیشتری را برای تخمین به‌کار نمی‌گیرد؛ در نتیجه، دقت تخمین دامنه و تأخیر قله‌های سیگنال برانگیخته در این روش، برای تعداد کم آزمون‌ها کافی نیست [۱۲] و [۱۳]. روشهایی برای بهبود عملکرد این روش و تخمین دقیق‌تر پتانسیل‌های برانگیخته ارائه شده که روش به‌کارگیری اطلاعات آزمون‌های قبلی و استفاده از ترکیب خطی پایه‌های گوسی با مراکز متغیر با زمان، از آن جمله‌اند [۱۲]، [۱۳]. علاوه بر روشهای سازگار بالا، از فیلتر کالمن نیز در استخراج پتانسیل‌های برانگیخته استفاده شده که شباهت زیادی به روش فیلتر سازگار مبتنی بر شبکه توابع پایه شعاعی دارد [۱۰].



شکل ۱ شبکه عصبی برای تخمین سیگنال‌های برانگیخته [۴]

$$\mathbf{y}(k) = \mathbf{H}\mathbf{w}(k) \quad (4)$$

که در آن

$$\mathbf{w}(k) = [w_1(k), \dots, w_N(k)]^T \quad (5)$$

$$\mathbf{H} = \begin{bmatrix} h_1(1) & h_2(1) & \dots & h_N(1) \\ h_1(2) & h_2(2) & \dots & h_N(2) \\ \vdots & \vdots & & \vdots \\ h_1(M) & h_2(M) & \dots & h_N(M) \end{bmatrix} \quad (6)$$

مقدار خطا در آزمون k ام برابر است با:

$$\mathbf{e}(k) = \mathbf{d}(k) - \mathbf{y}(k) = \mathbf{d}(k) - \mathbf{H}\mathbf{w}(k) \quad (7)$$

محل مراکز توابع گوسی رابطه (۳)، به توزیع نمونه‌های ورودی بستگی دارد. c_j به گونه‌ای انتخاب می‌شود که N تابع فعالیت لایه میانی، به صورت یکنواخت، M نمونه هر آزمون را پوشش دهند و یک RBF در آغاز و یکی در انتهای بازه سیگنال ورودی قرار گیرد [۴] و [۱۰]:

$$c_j = (j-1) \left(\frac{M-1}{N-1} \right) + 1, \quad j = 1, \dots, N \quad (8)$$

پهنای تمامی توابع گوسی یکسان در نظر گرفته شده و به صورت زیر تعیین می‌شود [۴]:

$$\sigma = \beta \frac{M-1}{N-1} \quad (9)$$

که در آن β معمولاً برابر ۰/۸ انتخاب می‌شود. از آنجا که ورودی‌ها و پارامترهای تابع فعالیت لایه میانی شبکه شکل (۱) مستقل از شماره آزمون‌ها تعیین شده، ماتریس \mathbf{H} ثابت است.

۲- روشهای استخراج پتانسیل برانگیخته

۲-۱- فیلتر سازگار مبتنی بر توابع پایه شعاعی

در روش فیلتر سازگار مبتنی بر توابع پایه شعاعی، برای استخراج پتانسیل برانگیخته، از شبکه عصبی پیش‌خورد چندلایه^۱ مطابق با شکل (۱) استفاده می‌شود [۴]. شبکه شامل یک لایه ورودی، یک لایه پنهان از واحدهای غیرخطی که به‌عنوان تابع فعالیت شبکه عمل می‌کنند و یک لایه خروجی برای ترکیب خطی واحدهای لایه میانی است. فرض کنید تعداد K آزمون از سیگنال برانگیخته ثبت شده در دست و هر آزمون، شامل M نمونه به‌صورت بردار زیر باشد [۴]:

$$\mathbf{d}(k) = [d_1(k), \dots, d_M(k)]^T, \quad k = 1, 2, \dots, K \quad (1)$$

$\mathbf{d}(k)$ آزمون ثبت شده در k امین تحریک و برابر است با:

$$\mathbf{d}(k) = \mathbf{s}(k) + \mathbf{n}(k) \quad (2)$$

$\mathbf{s}(k)$ و $\mathbf{n}(k)$ به ترتیب پتانسیل برانگیخته و نویز ثبت شده در k امین تحریک است.

در هر آزمون، مقدار ورودی شبکه، از ۱ تا M تغییر می‌کند. لایه میانی شامل N نورون با تابع فعالیت گوسی زیر است:

$$h_j(n) = \exp\left(-\frac{(n-c_j)^2}{\sigma_j^2}\right), \quad j = 1, 2, \dots, N \quad (3)$$

n شماره نمونه در هر آزمون و c_j و σ_j به ترتیب، مرکز و پهنای j امین RBF است. با توجه به شکل (۱) خروجی شبکه در آزمون k ام برابر است با:

سپس با استفاده از آزمون‌های $\mathbf{d}(k)$ و $\mathbf{d}(k-1)$ تا $\mathbf{d}(k-L)$ ، به ترتیب مقادیر $\mathbf{w}^1(k)$ ، $\mathbf{w}^2(k)$ تا $\mathbf{w}^{L+1}(k)$ محاسبه می‌شود:

(۱۳)

$$\begin{cases} \text{for } l = 0, \dots, L \\ \mathbf{e}^l(k) = \mathbf{d}(k-l) - \mathbf{H}\mathbf{w}^l(k) \\ \mathbf{w}^{l+1}(k) = \mathbf{w}^l(k) \\ \quad + \mu \mathbf{H}^T (\mathbf{H}\mathbf{H}^T + \varepsilon \mathbf{I})^{-1} \mathbf{e}^l(k) \end{cases}$$

در پایان مقدار $\mathbf{w}^{L+1}(k)$ به $\mathbf{w}(k+1)$ نسبت داده می‌شود:

$$\mathbf{w}(k+1) = \mathbf{w}^{L+1}(k) \quad (14)$$

L تعداد آزمون‌هایی را نشان می‌دهد که مجدداً استفاده می‌شوند.

۳-۲- روش سازگار مبتنی بر تغییر مراکز گوسی

در روش سازگار مبتنی بر تغییر مراکز گوسی، پس از به‌هنگام سازی وزن‌ها در هر آزمون، مراکز توابع شعاعی شکل (۱) برای کاهش مقدار میانگین مربع خطا، تغییر داده می‌شود [۱۳]. این روش، مشابه دو روش قبلی است، اما برای نشان دادن تفاوت این روش با روش اول، فرض کنید $\mathbf{d}(k)$ آزمون ثبت شده در k -امین تحریک باشد که حاوی پتانسیل برانگیخته $\mathbf{s}(k)$ و نویز $\mathbf{n}(k)$ است. همچنین فرض کنید که نویز و سیگنال جمع شونده و ناهمبسته‌اند. با این فرض‌ها، مقدار میانگین مربع خطا برابر است با:

$$\begin{aligned} f(k) &= E\{[\mathbf{d}(k) - \mathbf{y}(k)]^T [\mathbf{d}(k) - \mathbf{y}(k)]\} \\ &= E\{[\mathbf{s}(k) - \mathbf{y}(k)]^T [\mathbf{s}(k) - \mathbf{y}(k)]\} \\ &\quad + E\{\mathbf{n}^T(k) \mathbf{n}(k)\} \end{aligned} \quad (15)$$

پس از تعیین پارامترهای لایه میانی، باید وزن‌های $\mathbf{w}(k)$ تنظیم شود. برای تنظیم وزن‌های لایه میانی، از الگوریتم^۱ LMS استفاده شده است. نحوه به‌هنگام سازی وزن‌ها به صورت زیر است:

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \mu \mathbf{H}^T (\mathbf{d}(k) - \mathbf{y}(k)) \quad (10)$$

که در آن μ ضریب همگرایی است. میزان بهبود SNR در حالت ماندگار برابر است با [۴]

$$\Delta SNR = \frac{N-1}{2\mu^2 \pi^{r/2} (M-1) \beta^r} \quad (11)$$

بنابراین میزان بهبود SNR در این روش کران بالایی دارد که از تعداد آزمون‌ها مستقل است.

۲-۲- روش فیلتر سازگار با استفاده مجدد از داده‌ها

در فیلتر سازگار با استفاده مجدد از داده‌ها^۲ (DR-NLMS)، با استفاده از ساختار شکل (۱) الگوریتم سازگار NLMS به‌گونه‌ای تغییر داده می‌شود که جفت داده ورودی-خروجی از تکرارهای قبلی برای تولید تخمین‌های جدید و به‌هنگام سازی وزن‌ها، دوباره به کار می‌روند [۱۲].

همان‌گونه که در رابطه (۱۰) دیده می‌شود، در روش LMS، وزن‌های شبکه در آزمون $k+1$ -ام با توجه به وزن $\mathbf{w}(k)$ و بردار $\mathbf{d}(k)$ ، به‌هنگام سازی می‌شوند. در روش DR-NLMS، علاوه بر اطلاعات آزمون فعلی، از اطلاعات تعداد L آزمون قبلی نیز برای تخمین بردار وزن جاری استفاده می‌شود. برای توضیح این روش، از شاخص کمکی l استفاده می‌شود. در این روش، ابتدا مقدار $\mathbf{w}(k)$ به $\mathbf{w}^l(k)$ تخصیص داده می‌شود:

$$\mathbf{w}^l(k) = \mathbf{w}(k) \quad (12)$$

1. Least Mean Square

2. Data-Reusing Normalized Least Mean Square

در روش کالمن، انتخاب مناسب ماتریس مشاهدات حالت \mathbf{H}_k اهمیت فراوانی دارد. برای تعیین این ماتریس، فرض می شود که شکل پتانسیل های برانگیخته هموار و دارای برآمدگی ها و فرورفتگی های مثبت و منفی است. ترکیب توابع گوسی با وزن های مثبت و منفی می تواند این نوع سیگنال ها را مدل سازی کند. در تحقیقات قبلی، ماتریس کوواریانس اندازه گیری ها و ماتریس کوواریانس حالت ها، به صورت ماتریس هایی قطری در نظر گرفته شده است [۱۰].

۲-۵- مقایسه روشهای معرفی شده

تمامی روشهای معرفی شده در قسمت های قبل، ساختاری مشابه شکل (۱) دارند که در آن، خروجی ترکیب وزن دار توابع گوسی انتقال یافته بوده و وزن های این روشهای سازگار به صورت آزمون - به - آزمون به هنگام سازی می شوند. در حقیقت متغیرهای حالت روش کالمن، همان وزن های شکل (۱) است.

به منظور مقایسه و ارزیابی کارایی روشهای معرفی شده در کاهش تعداد آزمون های مورد نیاز در استخراج سیگنال های برانگیخته شنوایی، روشهای کالمن، فیلتر سازگار با استفاده مجدد از داده ها و فیلتر سازگار مبتنی بر توابع پایه شعاعی، پیاده سازی شد.

برای شبیه سازی، از سیگنال مصنوعی پتانسیل برانگیخته شنوایی با واریانس ۱ و SNR برابر ۱۵- دسیبل به عنوان ورودی استفاده شده است. نویز پس زمینه، دو نوع سفید گوسی و مخلوط نویزهای سفید و رنگی گوسی در نظر گرفته شده است. برای تولید نویز رنگی مطابق با مرجع [۱۲]، از یک مدل AR مرتبه چهار به صورت زیر استفاده شد:

$$v(n) = \sum_{i=1}^4 a_i v(n-i) + \zeta(n) \quad (18)$$

فرض می شود که نویز، مستقل از وزن ها و مراکز تابع فعالیت لایه اول است، بنابراین $f(k)$ در صورتی کمینه می شود که $\mathbf{y}(k)$ به $\mathbf{s}(k)$ تا حد ممکن نزدیک باشد. در این روش ابتدا بر طبق رابطه (۸)، مراکز توابع گوسی، مقداردهی اولیه می شوند. سپس آرایه مراکز، یک نمونه جابه جا و مقدار $f(k)$ محاسبه می شود. اگر مقدار جاری $f(k)$ ، کوچکتر از مقدار قبلی آن باشد، محل مراکز باز هم یک نمونه جابه جا می شود و در غیر این صورت، مقدار جابه جایی به مقدار قبلی باز گردانده می شود. به طور شهودی، حداکثر جابه جایی مراکز به اندازه تعداد نمونه بین دو مرکز متوالی است. پس از تنظیم مراکز، نوبت به تنظیم وزن ها می رسد. وزن ها از یک آزمون به آزمون بعدی، با رابطه (۱۰) به هنگام سازی می شوند.

۲-۴- روش فیلتر کالمن

در فیلتر کالمن، ابتدا یک مدل فضای حالت برای دینامیک خطی سیستم به صورت زیر در نظر گرفته می شود:

$$\mathbf{x}[k+1] = \mathbf{A}_k \mathbf{x}[k] + \mathbf{B}_k \mathbf{w}[k] \quad (16)$$

که در آن $\mathbf{x}[k]$ متغیر حالت فیلتر کالمن، و $\mathbf{w}[k]$ نویز سفید گوسی با متوسط صفر و کوواریانس \mathbf{Q} است. مقدار اولیه تخمین یعنی $\mathbf{x}[0]$ دارای توزیع گوسی بوده و مستقل از نویز \mathbf{w} است. \mathbf{A}_k ، \mathbf{B}_k و \mathbf{Q} معلوم فرض می شود. مدل مشاهده خطی به صورت زیر در نظر گرفته می شود:

$$\mathbf{y}[k] = \mathbf{s}[k] + \mathbf{v}[k] = \mathbf{H}_k \mathbf{x}[k] + \mathbf{v}[k] \quad (17)$$

که در آن $\mathbf{v}[k]$ نویز سفید گوسی با متوسط صفر و کوواریانس \mathbf{R} بوده و \mathbf{H}_k معلوم فرض می شود [۱۹] تا [۲۳]. برای توصیف تغییرات بردار حالت از مدل قدم زدن تصادفی استفاده شده و ماتریس های \mathbf{A}_k و \mathbf{B}_k ، ماتریس همانی در نظر گرفته می شود [۱۰].

قله‌های سیگنال خروجی این روش‌ها در تعداد ۴۰ آزمون با شکل سیگنال مطلوب، زیاد است.

خروجی روشهای متوسط‌گیری، شبکه سازگار توابع پایه شعاعی با الگوریتم‌های LMS و DR-NLMS، و فیلترکالمن در حالت مخلوط نویزهای سفید و رنگی گوسی، به ترتیب در شکل‌های (۶) تا (۹) نشان داده شده است. مقایسه شکل‌های (۶) تا (۹) نیز نشان می‌دهد که برای نویزهای مخلوط گوسی، تفاوت قابل ملاحظه‌ای بین روش کالمن و روشهای سازگار مبتنی بر توابع پایه شعاعی در تخمین دامنه و محل قله‌های شکل موج پتانسیل برانگیخته شنوایی وجود ندارد و در حالت نویز رنگی گوسی، قله‌های مجازی با دامنه قابل ملاحظه‌ای در انتهای شکل موج خروجی این روش‌ها دیده می‌شود و محل قله اول هم به درستی شناسایی نشده است.

شکل‌های (۱۰) و (۱۱) میزان بهبود SNR را در روشهای پیشین برای نویز سفید و نویز مخلوط نشان می‌دهند. هرچند میزان بهبود SNR در روش کالمن اندکی بیشتر است، اما تفاوت‌ها در این تعداد آزمون، قابل ملاحظه نیست.

همان‌گونه که در شکل‌های (۲) تا (۹) دیده می‌شود، الگوریتم‌های مبتنی بر ساختارهای مشابه شکل (۱) به شکل سیگنال‌های مشابهی منجر می‌شوند و با استفاده از روشهای سازگار معرفی شده، محل تقریبی قله‌های سیگنال قابل تخمین است اما تعداد آزمون‌ها برای تخمین دامنه‌ها کافی نیست.

همان‌گونه که در شکل‌های (۱۰) و (۱۱) دیده می‌شود، نمودار میزان بهبود SNR در تمامی روشهای سازگار معرفی شده، شیب ملایم یکسانی دارد. در این روش‌ها، فقط فرض هموار بودن شکل موج پتانسیل‌های برانگیخته در اختیار تخمین‌گر بوده است.

که در آن $v(n)$ سیگنال EEG شبیه‌سازی شده در لحظه n ، و $\hat{v}(n)$ نویز سفید گوسی با متوسط ۰ و واریانس ۱ است. ضرایب a_1 تا a_4 به ترتیب برابر ۱/۵۰۸، ۰/۱۵۸۷، -۰/۳۱۰۹، و ۰/۰۵۱- است.


برای مقایسه روش‌ها، نمودار خروجی هر روش پس از ۴۰ آزمون همراه با سیگنال مطلوب ترسیم شده است. علاوه بر این، برای مقایسه کمی روش‌ها، بهبود SNR خروجی بر طبق رابطه زیر اندازه‌گیری می‌شود:

$$SNR_{output} = 10 \log_{10} \frac{\sum_{n=1}^M [s_n(k)]^2}{\sum_{n=1}^M [s_n(k) - y_n(k)]^2} \quad (19)$$


M تعداد نمونه‌های آزمون، و \mathbf{s} و \mathbf{y} به ترتیب سیگنال برانگیخته مطلوب و خروجی روش مورد نظر در آزمون k ام است. واریانس سیگنال برانگیخته شبیه‌سازی شده برابر یک، و وزن اولیه روشهای سازگار برابر صفر در نظر گرفته شده، بنابراین همان‌گونه که در شکل (۱۰) دیده می‌شود، SNR خروجی از صفر شروع شده است.

خروجی روشهای متوسط‌گیری، شبکه سازگار توابع پایه شعاعی با الگوریتم‌های LMS و DR-NLMS، و فیلترکالمن در حالت نویز سفید گوسی، به ترتیب در شکل‌های (۲) تا (۵) نشان داده شده است. همان‌گونه که در این شکل‌ها دیده می‌شود، خروجی روشهای شبکه توابع پایه شعاعی با الگوریتم‌های LMS و DR-NLMS و فیلترکالمن، تفاوت زیادی از نظر تخمین دامنه و محل قله‌های شکل موج پتانسیل برانگیخته شنوایی ندارند.

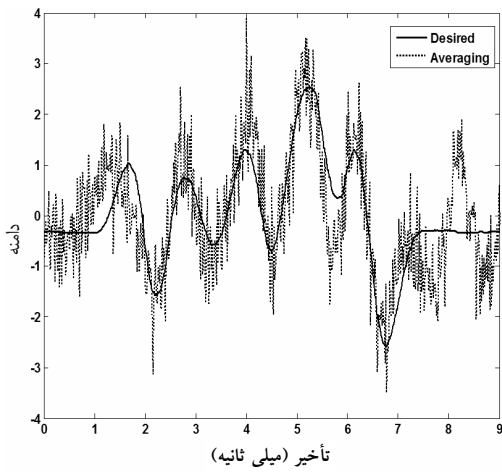
تنها فرض مورد استفاده در این ساختارها، هموار بودن شکل سیگنال پتانسیل برانگیخته است. هر چند شکل خروجی این روش‌ها، هموار است، اما تفاوت میان دامنه




شکل ۵ خروجی روش کالمن - نویز سفید




شکل ۲ خروجی روش متوسط گیری - نویز سفید



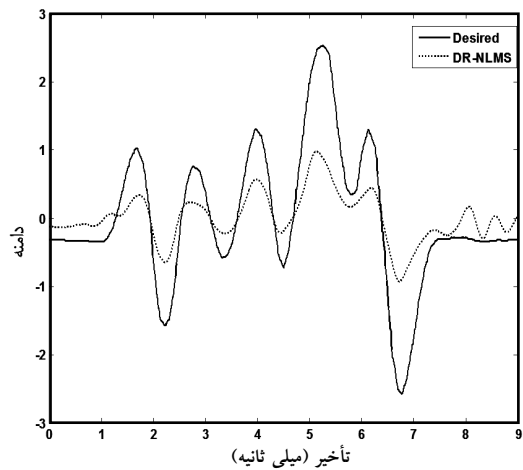
شکل ۶ خروجی متوسط گیری - مخلوط نویز سفید و رنگی




شکل ۳ خروجی روش LMS - نویز سفید




شکل ۷ خروجی LMS - مخلوط نویز سفید و رنگی



شکل ۴ خروجی DR-NLMS - نویز سفید




شکل ۱۱ مقایسه بهبود SNR [dB] - نویز سفید و رنگی



شکل ۸ خروجی DR-NLMS - مخلوط نویز سفید و رنگی

به علت SNR پایین سیگنال ورودی، امکان افزایش نرخ همگرایی روش LMS، وجود ندارد و استفاده مجدد از داده‌ها در روش DR-NLMS نیز بهبود قابل ملاحظه‌ای را در شکل خروجی ایجاد نمی‌کند. در مورد فیلتر کالمن نیز سرعت همگرایی فیلتر و میزان کاهش کوواریانس خطای تخمین، متناسب با $\sqrt{Q/R}$ است که به علت آن که SNR سیگنال‌های برانگیخته کم است، مقدار R بزرگ بوده و نرخ همگرایی کم است [۲۱].




شکل ۹ خروجی فیلتر کالمن - مخلوط نویز سفید و رنگی

به علت SNR پایین سیگنال ورودی، امکان افزایش ضریب همگرایی روشهای سازگار معرفی شده وجود ندارد. بنابراین برای تخمین دقیق دامنه قله‌های سیگنال مطلوب، به تعداد بیشتری آزمون نیاز است. در بخش بعدی روشی پیشنهاد می‌شود که با همین تعداد کم آزمون، تخمین بهتری از دامنه‌ها را به دست می‌دهد.

۳- روش پیشنهادی

در این بخش روشی برای تخمین دقیق‌تر دامنه سیگنال پتانسیل‌های برانگیخته ارائه می‌شود.



شکل ۱۰ مقایسه بهبود SNR [dB] - نویز سفید گوسی

همان گونه که در بخش ۲ گفته شد سیگنال خروجی در روشهای کالمن و روشهای مبتنی بر توابع پایه شعاعی، ترکیب خطی توابع پایه گوسی است و وزن های روشهای سازگار، به صورت آزمون - به - آزمون به هنگام سازی می شوند. هرچند این روش ها در تعداد کم آزمون محل قله ها را تعقیب می کنند، اما محل قله ها تقریبی است و دامنه قله ها به درستی تعیین نشده است. بنابراین برای بهبود سیگنال خروجی، پیشنهاد می شود که اطلاعات پیشین درباره محل تقریبی قله های پتانسیل برانگیخته در اختیار فیلتر سازگار قرار گیرد. این اطلاعات پیشین را می توان به کمک یکی از روشهای ترکیب توابع پایه شعاعی یا فیلتر کالمن که در بخش ۲ معرفی شد، به دست آورد.

در شکل (۱۲) مراحل روش پیشنهادی نشان داده شده است. سیگنال برانگیخته مطلوب را به صورت زیر در نظر می گیریم:

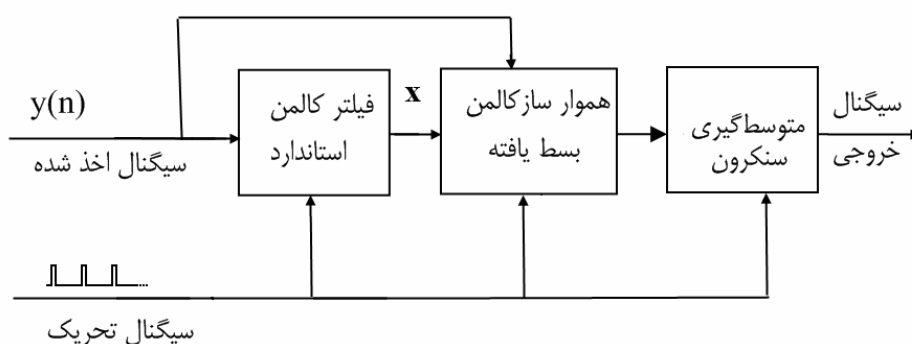
$$s(t) = \sum_{j=1}^N \alpha_j \exp\left(-\frac{(t-c_j)^2}{2\sigma_j^2}\right) \quad (20)$$

$$\dot{s}(t) = -\sum_{j=1}^N \alpha_j \frac{(t-c_j)}{\sigma_j^2} \exp\left(-\frac{(t-c_j)^2}{2\sigma_j^2}\right) \quad (21)$$

و شکل گسسته رابطه (۲۱) به صورت زیر است:

$$s(n+1) = s(n) - \delta \sum_{j=1}^N \alpha_j \frac{(t_n - c_j)}{\sigma_j^2} \exp\left(-\frac{(t_n - c_j)^2}{2\sigma_j^2}\right) \quad (22)$$

که در آن δ تناوب نمونه برداری است. این رابطه ضمن نشان دادن ارتباط نمونه $n+1$ با نمونه قبلی، یک آزمون از سیگنال برانگیخته را مدل سازی می کند. ثبت سیگنال های برانگیخته، سنکرون با تحریک است، لذا اگر هر آزمون سیگنال برانگیخته مطلوب را شامل M نمونه در نظر بگیریم و از تغییرات ناچیز سیگنال برانگیخته در طی آزمون ها صرف نظر کنیم، در این صورت می توانیم $s(n)$ را متناوب با دوره M در نظر بگیریم:



شکل ۱۲ بلوک دیاگرام روش پیشنهادی

رابطه (۲۴) و (۲۵)، ارتباط غیرخطی بین متغیرهای حالت و مشاهدات فیلتر کالمن را نشان می‌دهد. برای آن که بتوان از روابط فیلتر کالمن استفاده نمود، بایستی از متغیرهای حالت را حول مقدار فعلی تخمین، تقریب بزیم [۱۹]-[۲۳]. رابطه (۲۴) را می‌توانیم به صورت زیر بنویسیم.

$$\begin{cases} \theta(n+1) = f(\theta(n), n) \\ s(n+1) = g(s(n), \theta(n), \eta(n), n) \end{cases} \quad (26)$$

با تعریف فوق، مشتقات جزئی تابع g نسبت به مرکز و دامنه توابع گوسی با استفاده از روابط زیر قابل محاسبه هستند.

$$\frac{\partial g}{\partial \theta_j} = \delta \frac{\alpha_j \omega}{\sigma^2} \left(1 - \frac{\Delta \theta_j(n)}{\sigma^2}\right) \exp\left(-\frac{\Delta \theta_j(n)}{2\sigma^2}\right) \quad (27)$$

$$\frac{\partial g}{\partial \alpha_j} = -\delta \omega \frac{\Delta \theta_j(n)}{\sigma^2} \exp\left(-\frac{\Delta \theta_j(n)}{2\sigma^2}\right) \quad (28)$$

بردار متغیرهای حالت و مشاهدات را به ترتیب $\mathbf{y}(n) = [\varphi(n), y(n)]^T$ و $\mathbf{x}(n) = [\theta(n), s(n)]^T$ و بردار نویز مشاهدات را $\mathbf{v}(n) = [u(n), v(n)]^T$ در نظر می‌گیریم و با محاسبه مشتقات جزئی حالت‌ها و با به کارگیری فیلتر کالمن توسعه یافته^۱ (EKF)، مقادیر بهینه ضرایب و مراکز گوسی را محاسبه می‌کنیم.

روش پیشنهادی شامل دو مرحله است. در مرحله اول، سیگنال برانگیخته به صورت مخلوط توابع گوسی با پهنا و مرکز معلوم و با دامنه مجهول در نظر گرفته شده و با به کارگیری یکی از روشهای مبتنی بر شبکه

$$s(n+M) = s(n) \quad (23)$$

سنکرون بودن با تحریک را با استفاده از یک متغیر حالت که فاز مشاهدات را نشان می‌دهد، مدل‌سازی می‌کنیم. اگر هر آزمون سیگنال برانگیخته شامل M نمونه باشد، در دستگاه مختصات قطبی این نمونه‌ها با فاصله زاویه‌ای $2\pi/M$ نسبت به هم قرار گرفته‌اند. استفاده از دستگاه مختصات قطبی تنها به تصور شفاف‌تر رابطه (۲۳) کمک می‌کند. بنابراین با ترکیب دو رابطه (۲۲) و (۲۳) می‌توانیم رابطه زیر را برای مدل حالت فیلتر کالمن بنویسیم:

$$\begin{cases} \theta(n+1) = [\theta(n) + \omega \delta] \bmod(2\pi) \\ s(n+1) = s(n) - \sum_{j=1}^N \delta \frac{\alpha_j \omega}{\sigma^2} \Delta \theta_j(n) \exp\left(-\frac{\Delta \theta_j(n)}{2\sigma^2}\right) \end{cases} \quad (24)$$

که در آن مرکز j امین گوسی در مختصات قطبی، $\Delta \theta_j(n) = (\theta(n) - \theta_j) \bmod(2\pi)$ ، δ پریود نمونه برداری، $\omega = 2\pi/T$ که T طول دوره زمانی یک آزمون از سیگنال برانگیخته است، N تعداد توابع گوسی، $\theta(n)$ و $s(n)$ متغیرهای حالت، و σ پهناهای پایه‌های گوسی هستند. ضمناً می‌توانیم رابطه زیر را برای مدل مشاهدات فیلتر کالمن بنویسیم:

$$\begin{cases} \phi(n) = \theta(n) + u(n) \\ y(n) = s(n) + v(n) \end{cases} \quad (25)$$

که $y(n)$ سیگنال برانگیخته اخذ شده از بیمار و $u(n)$ و $v(n)$ نویزهای مشاهدات هستند. سیگنال فاز مشاهدات، یعنی $\phi(n)$ ، با توجه به فرکانس نمونه برداری و طول سیگنال برانگیخته یک آزمون، ساخته می‌شود و به کمک آن می‌توان تغییرات مراکز توابع گوسی را مدل کرد.

1. Extended Kalman Filter

تخمین دقیق تری از دامنه قله‌ها به دست می‌آید. بنابراین برای بررسی پایداری و سرعت همگرایی روش پیشنهادی، پایداری این فیلترها باید بررسی شود. در پیاده‌سازی الگوریتم پیشنهادی، از روش پایش کوواریانس سیگنال نوآوری^۲ برای جلوگیری از واگرایی فیلتر کالمن استفاده شده است. در این روش با قرار دادن پنجره زمانی بر روی نمونه‌های آخر سیگنال نوآوری و محاسبه کوواریانس مقادیر پنجره شده، مقدار محاسبه شده، با مقداری از کوواریانس سیگنال نوآوری که فیلتر کالمن محاسبه کرده، مقایسه می‌شود. سپس کوواریانس‌های مشاهدات و حالت‌های فیلتر کالمن - برای جبران تفاوت کوواریانس سیگنال نوآوری - تغییر داده می‌شود [۲۴].

یک راه برای بررسی پایداری، بررسی کوواریانس تخمین است. در این روش با توجه به فرض گوسی بودن نویزها و بردارهای حالت اولیه، مقادیر خطای تخمین حالت‌های سیستم و جذر درایه‌های قطری متناظر در ماتریس کوواریانس تخمین نسبت به زمان، ترسیم می‌شود. در این روش، فیلتر در صورتی همگرا است که خطای تخمین، داخل پوش جذر درایه قطری متناظر در ماتریس کوواریانس خطای تخمین قرار گیرد [۱۹] و [۲۵].

روش دیگر برای بررسی پایداری و سرعت همگرایی فیلتر کالمن، استفاده از شکل رؤیت‌پذیر برای متغیرهای حالت است. رابطه به‌هنگام‌سازی حالت در فیلتر کالمن به صورت زیر است [۱۹] تا [۲۱]

$$\hat{\mathbf{x}}[k+1]^- = (\mathbf{A}_k - \mathbf{A}_k \mathbf{K}_k \mathbf{H}_k) \hat{\mathbf{x}}[k]^- + \mathbf{A}_k \mathbf{K}_k \mathbf{y}[k] \quad (29)$$

که در آن \mathbf{K}_k بهره فیلتر کالمن و سایر ماتریس‌ها مانند رابطه (۱۶) و (۱۷) است. رابطه (۲۹) در شکل ۱۳ نشان داده شده است.

توابع پایه شعاعی یا فیلتر کالمن، ضرایب فیلتر شکل (۱) که همان دامنه پایه‌های گوسی است، با استفاده از تعداد محدودی آزمون به دست می‌آید. در این مرحله، در واقع نوعی پردازش سازگار بلوکی بر روی K سطر از ماتریس داده‌های ورودی انجام می‌شود.


در مرحله اول برای مقداردهی اولیه مراکز و پهنای پایه‌های گوسی از روابط (۸) و (۹) استفاده شده و پارامترها و مدل فضای حالت فیلتر کالمن با استفاده از روابط (۶)، (۱۶) و (۱۷) تعیین می‌شود. خروجی این مرحله، آخرین تخمین بردار حالت \mathbf{x} است که شامل تخمین ضرایب پایه‌های گوسی می‌شود. با توجه به این که پهنای و مرکز پایه‌های گوسی را قبلاً تعیین کرده‌ایم، تمامی پارامترهای مدل رابطه (۲۴)، در این مرحله معلوم است.

در بلوک اول شکل (۱۲) می‌توان از یکی از روشهای معرفی شده در بخش ۲ استفاده نمود و در اینجا از فیلتر کالمن استاندارد در این بلوک استفاده کرده‌ایم.

در مرحله دوم، ضرایب به دست آمده از مرحله اول را در مدل حالت فیلتر غیرخطی کالمن به کار می‌بریم. پس از تعیین مدل، با توجه به رابطه غیرخطی بین مشاهدات و متغیرهای حالت، از هموارساز بسط یافته کالمن^۱ (EKS)، برای تخمین حالت استفاده می‌کنیم. برای افزایش همواری شکل موج خروجی متوسط آزمون‌های فیلتر شده را به عنوان خروجی مرحله نهایی در نظر می‌گیریم.

۴- پایداری و سرعت همگرایی

همان‌گونه که گفته شد، الگوریتم پیشنهادی دو گام متوالی دارد. در گام اول به کمک فیلتر کالمن، ضرایب پایه‌های گوسی تعیین شده و در گام دوم با استفاده از گونه‌های بسط یافته فیلتر کالمن و دانش به دست آمده درباره محل قله‌های سیگنال مطلوب،



شکل ۱۴ مقادیر ویژه حلقه بسته شکل ۱۳

۵- نتایج شبیه‌سازی‌ها و بحث

اکنون از طریق شبیه‌سازی، کارایی روش پیشنهادی را در کاهش تعداد آزمون مورد نیاز برای استخراج سیگنال برانگیخته در مقایسه با روشهای معرفی شده در بخش ۲ نشان می‌دهیم. در این بخش نیز مشابه بخش ۲، برای شبیه‌سازی، از ۴۰ آزمون سیگنال مصنوعی پتانسیل برانگیخته شنوایی با SNR برابر ۱۵- دسیبل به‌عنوان ورودی استفاده شده است. نویز پس‌زمینه، دو نوع سفید گوسی و مخلوط نویزهای سفید و رنگی گوسی در نظر گرفته شده است.

شکل (۱۵) خروجی روش پیشنهادی را در حالت نویز سفید گوسی نشان می‌دهد. در شکل (۱۶) شکل سیگنال خروجی روش پیشنهادی با روشهای پیشین مقایسه شده است. این شکل نشان می‌دهد که استفاده از روش ترکیبی پیشنهادی، دقت تخمین دامنه قله‌های سیگنال برانگیخته را در مقایسه با روشهای پیشین افزایش داده است. همان‌گونه که در شکل (۱۷) دیده می‌شود، این بهبود با استفاده از روش پیشنهادی در مقایسه با روشهای پیشین، حدود ۱۰ دسیبل است.

شکل (۱۸) خروجی روش پیشنهادی را در حالت نویز مخلوط گوسی نشان می‌دهد. در شکل (۱۹) سیگنال


سرعت همگرایی، به پراکندگی مقادیر ویژه ماتریس $\mathbf{A}_k - \mathbf{A}_k \mathbf{K}_k \mathbf{H}_k$ و پایداری فیلتر به پراکندگی مقادیر ویژه این ماتریس در حالت ماندگار بستگی دارد. برای پایداری، باید مقادیر ویژه ماتریس $\mathbf{A}_k - \mathbf{A}_k \mathbf{K}_k \mathbf{H}_k$ داخل دایره واحد قرار گیرد. مقدار ماندگار کواریانس تخمین از رابطه زیر به دست می‌آید:

$$\bar{\mathbf{P}} = \bar{\mathbf{A}}\bar{\mathbf{P}}\bar{\mathbf{A}}^T - \bar{\mathbf{A}}\bar{\mathbf{P}}\bar{\mathbf{H}}^T(\bar{\mathbf{H}}\bar{\mathbf{P}}\bar{\mathbf{H}}^T + \mathbf{R})^{-1}\bar{\mathbf{H}}\bar{\mathbf{P}}\bar{\mathbf{A}}^T + \mathbf{Q} \quad (30)$$

پس از محاسبه مقدار ماندگار کواریانس تخمین، بهره کالمن از رابطه زیر قابل محاسبه می‌شود [۱۹] تا [۲۱]:


$$\mathbf{K} = \bar{\mathbf{P}}\bar{\mathbf{H}}^T(\bar{\mathbf{H}}\bar{\mathbf{P}}\bar{\mathbf{H}}^T + \mathbf{R})^{-1} \quad (31)$$

برای حل معادله (۳۱) می‌توان از دستور dare متلب^۱ استفاده کرد [۲۰]. به کمک این دستور می‌توان مقدار ماندگار ماتریس کواریانس تخمین، مقدار ماندگار بهره فیلتر کالمن و مقادیر ویژه حلقه بسته شکل (۱۳) را محاسبه کرد. شکل (۱۴)، مقادیر ویژه ماتریس $\mathbf{A}_k - \mathbf{A}_k \mathbf{K}_k \mathbf{H}_k$ را برای الگوریتم پیشنهادی نشان می‌دهد. همان‌گونه که در این شکل دیده می‌شود، مقادیر ویژه کمتر از واحد بوده و فیلتر پایدار است.




شکل ۱۳ شکل رؤیت‌پذیر حالت در فیلتر کالمن


1. MATLAB




شکل ۱۸ خروجی روش پیشنهادی - نویز سفید و رنگی




شکل ۱۵ خروجی روش پیشنهادی - نویز سفید




شکل ۱۹ خروجی روشهای سازگار - نویز سفید و رنگی



شکل ۱۶ مقایسه خروجی روشهای سازگار - نویز سفید



شکل ۲۰ بهبود SNR [dB] روش پیشنهادی - نویز مخلوط



شکل ۱۷ بهبود SNR [dB] روش پیشنهادی - نویز سفید

۶- جمع بندی

در این مقاله، روشهای سازگار مبتنی بر شبکه توابع پایه شعاعی و روش کالمن مرور شده و در کاربرد تخمین پتانسیل برانگیخته شنوایی مقایسه شد. همچنین روشی برای بهبود SNR سیگنالهای برانگیخته در تکرارهای کم، پیشنهاد شد. نتایج به دست آمده از شبیه سازی نشان می دهد که روشهای سازگار معرفی شده و فیلتر کالمن، از ساختار مشابهی برای تخمین پتانسیل های برانگیخته استفاده می کنند و تفاوت قابل ملاحظه ای در کاهش تعداد آزمون مورد نیاز برای تخمین پتانسیل برانگیخته شنوایی ندارند. روش پیشنهادی، امکان تخمین دقیق تر دامنه پتانسیل برانگیخته را در تعداد کم آزمون ها میسر ساخته و چارچوبی را برای افزودن اطلاعات اولیه بیشتری به ساختار تخمین گر پتانسیل برانگیخته فراهم ساخته و راه را برای توسعه روشهای استخراج سریع تر پتانسیل های برانگیخته، هموار می سازد. برای افزایش کارایی این روش و بهبود آن می توان در معادلات حالت فیلتر کالمن، دینامیک نویز را هم در نظر گرفت و اطلاعات بیشتری از محل مؤلفه های سیگنال مطلوب در اختیار تخمین گر قرار داد.

۷- منابع

- [1] J. Britton, B. W. Jervis, and R. A. Grunewald, "Extracting single trial event related potentials," IEE Proc. Sci. Meas. Technol., vol. 147, no. 6, pp. 382-388, 2000.
- [2] P. Jaśkowski and R. Verleger, "Amplitudes and latencies of single-trial ERP's estimated by a maximum-likelihood method," IEEE Trans. on

خروجی روش پیشنهادی با روشهای پیشین مقایسه شده است. این شکل بهبود تخمین دامنه قله های شکل موج سیگنال برانگیخته را در حالت نویز مخلوط با استفاده از روش پیشنهادی نشان می دهد. شکل (۲۰) میزان بهبود SNR روشهای سازگار را در حالت نویز مخلوط نشان می دهد.

علت بهبود تخمین دامنه ها آن است که در مرحله اول تخمین، همواری شکل موج سیگنال برانگیخته، تنها اطلاعاتی است که درباره سیگنال برانگیخته در اختیار تخمین گر قرار داده شده است، اما در مرحله دوم علاوه بر این اطلاعات، تخمین اولیه ای از شکل مطلوب - که محل تقریبی قله ها را به درستی تعیین کرده - در اختیار تخمین گر قرار دارد و در نتیجه انتظار داریم که SNR بهبود یابد.

بنابراین برای به دست آوردن SNR بهتر یا کاهش بیشتر تعداد آزمون ها، اطلاعات اولیه دقیق تری باید در اختیار تخمین گر قرار داده شود. با وجود این، روش پیشنهادی، کاربردی کلی داشته و برای تخمین هر نوع سیگنال برانگیخته همواری، قابل استفاده است.

همان گونه که نتایج شبیه سازی ها نشان می دهد، در تمامی این روشهای سازگار، میزان بهبود SNR برای سیگنال های آغشته به نویز سفید، بیش از سیگنال های آغشته به نویز رنگی است. با توجه به آن که در معادلات فیلتر کالمن استاندارد فرض می شود که نویز مشاهدات و حالت ها، سفید و گوسی هستند، برای بهبود تخمین در حالت نویز رنگی، می توان در معادلات فیلتر کالمن، دینامیک نویز را نیز در نظر گرفته و از فیلتر کالمن الحاقی^۱ استفاده کرد [۲۰].

1. Augmented Kalman Filter

- using time and frequency features,” *Artificial Intelligence in Medicine*, vol. 40, pp. 1-14, 2007.
- [9] D. H. Lange, H. Pratt, and G. F. Inbar, “Modeling and estimation of single evoked brain potential components,” *IEEE Trans. on Biomed. Eng.*, vol. 44, no. 9, pp. 1191-1198, 1997.
- [10] S. D. Georgiadis, P. O. Ranta-aho, M. P. Tarvainen, and P. A. Karjalainen, “Single-trial dynamical estimation of event-related potentials: a Kalman filter-based approach,” *IEEE Trans. on Biomed. Eng.*, vol. 52, no. 8, pp. 1397-1406, 2005.
- [11] M. E. Khan and D. N. Dutt, “An expectation-maximization algorithm based on Kalman smoother approach for event-related desynchronization (ERD) estimation from EEG,” *IEEE Trans. on Biomed. Eng.*, vol. 54, no. 7, pp. 1191-1198, 2007.
- [12] W. Qiu, C. Chang, W. Liu, P. W. F. Poon, Y. Hu, F. K. Lam, R. P. Hamernik, G. Wei, and F. H. Y. Chan, “Real-time data-reusing adaptive learning of a radial basis function network for tracking evoked potentials,” *IEEE Trans. on Biomed. Eng.*, vol. 53, no. 2, pp. 226-237, 2006.
- [13] C. Merzagora, F. Bracchi, S. Cerutti, L. Rossi, A. Gaggiani, and A. M. Bianchi, *Biomed. Eng.*, vol. 46, no. 8, pp. 987-993, 1999.
- [3] R. Zhang, G. McAllister, B. Scotney, S. McClean, and G. Houston, “Combining wavelet analysis and bayesian networks for the classification of auditory brainstem response,” *IEEE Trans. on Information Technology in Biomedicine*, vol. 10, no. 3, pp. 458-467, 2006.
- [4] K. S. M. Fung, F. H. Y. Chan, F. K. Lam, and P. W. F. Poon, “A tracing evoked potential estimator,” *Medical & Biological Engineering & Computing*, vol. 37, pp. 218-227, 1999.
- [5] M. R. Nuwer, M. Amionoff, D. Goodin, S. Matsuoka, F. Mauguiere, A. Starr, and J. F. Vibert, “IFCN recommended standards for brain-stem auditory evoked potentials,” *Electroencephalography and Clinical Neurophysiology*, vol. 91, pp. 12-17, 1994.
- [6] L. J. Hood, *Auditory Evoked Potentials*, Austin Texas: PRO-ED, 1986.
- [7] L. D. Petrova, “Brainstem auditory evoked potentials,” *American Journal of Electroneurodiagnostic Technology*, vol. 49, pp. 317-332, 2009.
- [8] R. Davey, P. McCullagh, G. Lightbody, and G. McAllister, “Auditory brainstem response classification: a hybrid model

- Biosensors, Cambridge UK, pp. 19-22, Aug. 2007.
- [18] E. Causevic, R. E. Morley, M. V. Wickerhauser, and A. E. Jacquin, "Fast wavelet estimation of weak biosignals," IEEE Trans. on Biomed. Eng., vol. 52, no. 6, pp. 1021-1032, 2005.
- [19] P. S. Maybeck, *Stochastic Models, Estimation, and Control*, vol. 1, New York: Academic Press, 1979.
- [20] D. Simon, *Optimal State Estimation, Kalman, H_∞ and Nonlinear Approaches*, New Jersey: Wiley, 2006.
- [21] M. S. Grewal, and A. P. Andrews, *Kalman Filtering: Theory and Practice Using MATLAB*, 3rd Ed., New Jersey: Wiley, 2008.
- [22] J. V. Candy, *Model-based Signal Processing*, New Jersey: Wiley, 2006.
- [23] S. Haykin, *Kalman Filtering and Neural Networks*, New York: Wiley, 2001.
- [24] M. S. Grewal, L. R. Weill, and A. P. Andrews, *Global Positioning Systems, Inertial Navigation, and Integration*, New York: Wiley, 2001.
- [25] Gelb, *Applied Optimal Estimation*, Cambridge, MA: MIT Press, 1974.
- "Evaluation and application of a RBF neural network for online single-sweep extraction of SEPs during scoliosis surgery," IEEE Trans. on Biomed. Eng., vol. 54, no. 7, pp. 1300-1308, 2007.
- [14] L. Xu, P. Stoica, J. Li, S. L. Bressler, X. Shao, and M. Ding, "ASEO: a method for the simultaneous estimation of single-trial event-related potentials and ongoing brain activities," IEEE Trans. on Biomed. Eng., vol. 56, no. 1, pp. 111-121, 2009.
- [15] P. Celka, K. N. Le, and T. R. H. Cutmore, "Noise reduction in rhythmic and multi trial biosignals with applications to event-related potentials," IEEE Trans. on Biomedical Eng., vol. 55, no. 7, pp. 1809-1821, 2008.
- [16] R. Zhang, G. McAllister, B. Scotney, S. McClean, and G. Houston, "A comparison of wavelet and wavelet-bayesian approaches for the classification of auditory brainstem response," The 3rd IEE Int. Seminar on Medical Applications of Signal Processing, London, pp. 65-70, Nov. 2005.
- [17] S. Rahbar, M. D. Abolhassani, H. Arabalibeik, and A. H. Jafari, "Auditory brainstem response classification using wavelet transform and multilayer feed-forward networks," IEEE EMBS Int. Symposium on Medical Device&