

حذف برخط آرتیفکت پلک‌زدن از سیگنال‌های مغزی در سیستم‌های ارتباطی مغز با کامپیوتر با استفاده از تحلیل وفقی مؤلفه‌های مستقل

فرزانه شایق بروجنی و عباس عرفانیان امیدوار

1- مقدمه

سیگنال‌های مغزی نقش بسیار مهمی در تشخیص‌های کلینیکی و سیستم‌های ارتباط مغز با کامپیوتر دارند. لازمه تشخیص درست و پردازش مناسب سیگنال‌های مغزی، در دست داشتن سیگنال‌های کاملاً عاری از نویز است. یکی از مهم‌ترین نویزهایی که می‌تواند در سیگنال EEG اختلال ایجاد کند، نویز ناشی از پلک‌زدن چشم است. روش معمول حذف آرتیفکت پلک‌زدن، نادیده‌گرفتن بخش‌های حاوی آرتیفکت از سیگنال EEG است. هرگاه دامنه سیگنال EEG از یک حدی بیشتر شود، پلک‌زدن اتفاق افتاده است؛ به این وسیله بخش‌های حاوی آرتیفکت تشخیص داده شده و از مجموعه داده‌ها حذف می‌شوند. هرچند با این روش سیگنال EEG باقیمانده بدون آرتیفکت خواهد بود؛ اما بخش عظیمی از داده‌ها از بین می‌رود. این مسأله به‌خصوص در مورد بیماران و کودکان مشکل‌ساز خواهد بود. همچنین روش‌های متفاوتی مبتنی بر رگرسیون در حوزه زمان و فرکانس [1] و [2] برای حذف آرتیفکت پیشنهاد شده است. اما تمام این روش‌ها نیاز به آنالیز برون‌خط دارند که برای کاربردهای بی‌درنگ مناسب نیستند. آنالیز مؤلفه‌های اساسی نیز برای حذف آرتیفکت از سیگنال‌های مغزی چندکاناله استفاده شده است. اما این روش قادر به حذف کامل آرتیفکت، علی‌الخصوص هنگامی که سیگنال‌های مغزی و آرتیفکت دارای دامنه قابل مقایسه باشند، نیست [1]. از روش‌های پردازش تطبیقی نیز برای حذف آرتیفکت پلک‌زدن استفاده شده است. در [3] از حذف‌کننده نویز تطبیقی با دو فیلتر خطی برای حذف آرتیفکت چشمی استفاده شده است. یک جفت الکتروود در بالا و پایین چشم و یک جفت دیگر در طرف راست و چپ گیج‌گاه، به‌ترتیب برای ثبت حرکت عمودی و افقی چشم قرار داده شده است. سیگنال چشمی افقی و عمودی به‌عنوان سیگنال مرجع به دو فیلتر اعمال شده است. سپس خروجی هر یک از این دو فیلتر از سیگنال‌های ثبت‌شده مغزی کسر شده است. ساداسیوان و دات [4]، از یک حذف‌کننده نویز وفقی غیر خطی برای حذف EOG از سیگنال‌های EEG استفاده کرده‌اند. اما در این روش‌ها حذف بی‌درنگ آرتیفکت مورد توجه قرار نگرفته است. عرفانیان و محمودی یک روش مؤثر برای حذف آرتیفکت چشمی از سیگنال‌های مغزی در حالت بی‌درنگ ارائه کرده‌اند. این روش مبتنی بر فیلتر تطبیقی است و از یک شبکه عصبی برای حذف آرتیفکت پلک‌زدن و حرکت‌های افقی و عمودی چشم استفاده شده است [5].

اخیراً یک روش آماری بسیار مؤثر برای حذف آرتیفکت‌های مختلف از سیگنال‌های مغزی و سیگنال‌های الکترومغناطیسی مغزی بر اساس جداسازی کور منابع به‌نام روش تحلیل مؤلفه‌های مستقل [6] و [7] معرفی شده است. حذف آرتیفکت با استفاده از این روش در حالت برون‌خط

چکیده: در سال‌های اخیر کوشش‌های بسیار زیادی جهت استفاده از سیگنال‌های مغزی به‌عنوان یک کانال ارتباطی مستقیم بین انسان و کامپیوتر انجام گرفته است. این کانال ارتباطی، سیستم‌های واسط مغز با کامپیوتر مبتنی بر سیگنال مغزی نامیده می‌شود. هدف تحقیقات در سیستم‌های واسط مغز با کامپیوتر ایجاد یک کانال ارتباطی است که مستقیماً فعالیت‌های مغزی را به فرمان‌های کنترلی تبدیل کند. این سیستم‌ها بر اساس تصور ذهنی حرکت و یا یک فعالیت ذهنی خاص استوار هستند. تصور حرکت باعث ایجاد پتانسیل‌هایی در سطح قشر حرکتی مغز می‌شود. می‌توان از این سیگنال‌ها به‌عنوان یک دستور به کامپیوتر استفاده کرد. اما تشخیص این سیگنال‌ها به علت پایین بودن نسبت سیگنال به نویز و وجود آرتیفکت‌های مختلف یک فرآیند پیچیده است. از مهم‌ترین مشکلات در گسترش سیستم‌های ارتباطی مغز با کامپیوتر، حذف بی‌درنگ آرتیفکت ناشی از پلک‌زدن چشم از سیگنال‌های مغزی است. تاکنون روش‌های مختلفی برای حذف آرتیفکت پلک‌زدن از سیگنال‌های مغزی ارائه شده است. یکی از روش‌های مؤثر و مطرح برای حذف آرتیفکت‌های مختلف از سیگنال‌های الکتروانسفالوگرام استفاده از تحلیل مؤلفه‌های مستقل است. اما این روش نیاز به تشخیص چشمی مؤلفه‌های مستقل مربوط به آرتیفکت‌ها دارد. بازبینی چشمی از مؤلفه‌ها بسیار زمان‌بر بوده و برای حذف برخط آرتیفکت، مناسب نیست. در این مقاله، راهکار جدیدی مبتنی بر تحلیل مؤلفه‌های مستقل برای حذف برخط آرتیفکت پلک‌زدن از سیگنال‌های مغزی گسترش داده شده است. برای این منظور، الگوریتم‌های مختلف وفقی تحلیل مؤلفه‌های مستقل پیشنهاد و کارایی آنها در شرایط مختلف با انواع داده‌های شبیه‌سازی شده مورد ارزیابی قرار گرفته است. نتایج شبیه‌سازی نشان می‌دهد که روش‌های وفقی تحلیل مؤلفه‌های مستقل در شرایط خاصی به‌خوبی قادر به جداسازی برخط منابع هستند. به‌منظور حذف برخط آرتیفکت از سیگنال‌های مغزی با استفاده از راهکار پیشنهادی، آزمایشات مختلفی بر روی انسان انجام شده است. نتایج نشان می‌دهد که این روش‌ها به‌خوبی قادر به حذف کامل آرتیفکت پلک‌زدن چشم به‌صورت برخط از سیگنال‌های مغزی بوده و برای استفاده در مانیورینگ برخط EEG و سیستم‌های ارتباطی مغز با کامپیوتر مناسب هستند.

کلید واژه: سیستم‌های ارتباطی مغز با کامپیوتر، سیگنال الکتروانسفالوگرام، آرتیفکت چشم، تحلیل مؤلفه‌های مستقل، پردازش تطبیقی، شبکه‌های عصبی.

این مقاله در تاریخ 14 مهر ماه 1386 دریافت و در تاریخ 3 اردیبهشت ماه 1388 بازنگری شد. این تحقیق در مرکز فناوری عصبی ایران، آزمایشگاه سیستم‌های واسط مغز - کامپیوتر و با حمایت مالی معاونت پژوهشی دانشگاه علم و صنعت ایران انجام شده است.

فرزانه شایق بروجنی، دانشکده مهندسی برق، گروه مهندسی پزشکی، دانشگاه علم و صنعت ایران، تهران، (email: farzaneh.shayegh@gmail.com).
عباس عرفانیان امیدوار، دانشکده مهندسی برق، گروه مهندسی پزشکی، دانشگاه علم و صنعت ایران، تهران، (email: erfaniyan@iust.ac.ir).

مثال تنسورهای کمولنت حالت کلی ماتریس کواریانس است. ماتریس کواریانس تنسور کمولنت درجه دوم است و تنسور درجه چهارم با کمولنت درجه چهارم تعریف می‌شود. نشان داده شده است که می‌توان با دانستن ماتریس ویژه تنسور کمولنت، مؤلفه‌های مستقل را به دست آورد. می‌توان با تجزیه مقادیر ویژه ماتریس کواریانس، داده‌ها را سفید کرد. این به معنی آن است که می‌توان طوری داده‌ها را تبدیل کرد که وابستگی درجه دوم صفر شود. در حالت کلی این اصل، می‌توان با استفاده از تنسور کمولنت درجه چهارم، کمولنت درجه چهارم را صفر کرد. این نوع تجزیه درجه بالا، دسته‌ای از روش‌های تخمین ICA را به وجود آورده است. در این راستا کروکز [12] از کمولنت درجه چهارم و از روش قطری‌سازی توأم تقریبی ماتریس ویژه برای تخمین مؤلفه‌های مستقل استفاده کرده است. همه این روش‌ها که در جعبه ابزار ICALAB نیز گرد هم آورده شده‌اند به صورت برون‌خط عمل می‌کنند. یعنی برای محاسبه مؤلفه‌های مستقل به گروهی از داده‌ها نیاز دارند.

3- حذف آرتیفکت با استفاده از ICA

یکی از فرض‌های قطعی ICA، مستقل بودن مؤلفه‌ها است. از آنجا که منبع سیگنال‌های آرتیفکت پلک‌زدن چشم از منبع سیگنال‌های مغزی جدا است، می‌توان از ICA برای جداسازی سیگنال‌های مغزی و آرتیفکت پلک‌زدن به صورت مؤلفه‌های مستقل استفاده کرد. برای حذف آرتیفکت نیاز به تشخیص مؤلفه مربوط به آرتیفکت است. سیگنال بدون آرتیفکت با تصویرکردن مؤلفه‌های انتخاب‌شده به روی کانال‌های مغزی به دست می‌آید $\mathbf{x}_0 = \mathbf{W}^{-1}\mathbf{s}_0$. ماتریس \mathbf{s}_0 شامل مؤلفه‌های مستقل است در حالی که ردیف مربوط به مؤلفه‌های آرتیفکت صفر قرار داده شده است.

4- الگوریتم‌های عصبی - وقتی ICA

تاکنون روش‌های متعددی برای تحلیل وقتی مؤلفه‌های مستقل ارائه شده است [6] تا [12]. کارهونن و همکاران [13] چند شبکه عصبی برای جداسازی کور منابع معرفی کرده‌اند. شبکه اصلی ICA شامل سفیدسازی، جداسازی و تخمین بردارهای پایه ICA است. سیچوکی [14] دو الگوریتم یادگیری بدون معلم برای شناسایی و جداسازی منابع مستقل ارائه کرده است. یکی از این الگوریتم‌ها برای یادگیری برخط یک شبکه تک‌لایه پیش‌رو و دیگری برای شبکه خود بازگشتی گسترش داده شده است. کاردزو و لاهلد [15]، یک دسته الگوریتم وقتی برای جداسازی منابع تحت عنوان جداسازی وقتی هم‌واریانس از طریق استقلال³ (EASI) معرفی کرده‌اند. سیچوکی با همکاران [16] نیز یک الگوریتم یادگیری ICA با قابلیت انتخاب توابع غیر خطی مختلف تحت عنوان تحلیل مؤلفه‌های مستقل قابل انعطاف ارائه کرده‌اند. این الگوریتم قابلیت جداسازی منابع فراگوسی و فروگوسی را دارد. با این وجود هیچ یک از این روش‌ها در حذف آرتیفکت از سیگنال‌های مغزی به طور برخط به کار گرفته نشده‌اند.

هدف از این مقاله استفاده از الگوریتم‌های وقتی تحلیل مؤلفه‌های مستقل کارهونن [13] و EASI [15] در جداسازی و حذف برخط آرتیفکت پلک‌زدن از سیگنال‌های EEG است و مبنای این الگوریتم‌ها شبکه‌های عصبی می‌باشد. در واقع شبکه عصبی برای تخمین ماتریس‌های ترکیب و جداسازی به کار می‌رود. در این روش‌ها اولین گام، ناهم‌بسته‌سازی وقتی داده‌های ورودی است. سپس ماتریس جداسازی و منابع مستقل

مورد توجه زیادی قرار گرفته است. برای حذف آرتیفکت با استفاده از روش تحلیل مؤلفه‌های مستقل نیاز به تشخیص چشمی مؤلفه‌های مستقل مربوط به آرتیفکت است. تشخیص چشمی مؤلفه‌های مستقل مربوط به آرتیفکت بسیار زمان‌بر بوده [8] و برای حذف آرتیفکت به صورت بی‌درنگ مناسب نیست. اگرچه روش‌های تحلیل وقتی مؤلفه‌های مستقل مختلفی ارائه شده، اما تاکنون کارایی این روش‌ها در حذف بی‌درنگ آرتیفکت از سیگنال‌های مغزی مورد بررسی قرار نگرفته است. در این مقاله روش تحلیل مؤلفه‌های مستقل مورد بررسی قرار گرفته و کاربرد آن در حذف بی‌درنگ آرتیفکت چشمی از سیگنال‌های مغزی ارائه می‌شود.

2- تحلیل مؤلفه‌های مستقل

روش تحلیل مؤلفه‌های مستقل یک روش آماری است که برای استخراج مؤلفه‌های تا حد امکان مستقل از یکدیگر با استفاده از داده‌های تصادفی مشاهده‌شده، به کار می‌رود. این روش بر این فرض استوار است که داده‌های مشاهده‌شده، \mathbf{x} ، در هر لحظه ترکیب خطی از یک سری منبع، \mathbf{s} ، باشند [8]

$$\mathbf{x}_k = [x_1(k), x_2(k), \dots, x_n(k)] \quad (1)$$

$$\mathbf{s}_k = [s_1(k), s_2(k), \dots, s_n(k)] \quad (2)$$

$$\mathbf{x}_k = \mathbf{A}_k \mathbf{s}_k \quad (2)$$

منابع دارای مقدار حقیقی، متوسط صفر، توزیع غیرگوسی و مستقل آماری از یکدیگر برای هر نمونه در هر لحظه k هستند. هدف ICA تخمین ماتریس جداسازی است به طوری که

$$\mathbf{s}_k = \mathbf{W}_k \mathbf{x}_k \quad (3)$$

ماتریس جداسازی به نحوی تخمین زده می‌شود که اطلاعات متقابل بین مؤلفه‌ها کمینه شود. اطلاعات متقابل یک اندازه‌گیری غیر پارامتریک از وابستگی بین متغیرهای تصادفی است و همیشه برای متغیرهای مستقل دارای مقدار منفی و یا صفر است. مهم‌ترین ویژگی اطلاعات متقابل، مقاوم بودن نسبت به نویز و تبدیل داده‌ها در مقایسه با ممان اول و دوم آماری است [8].

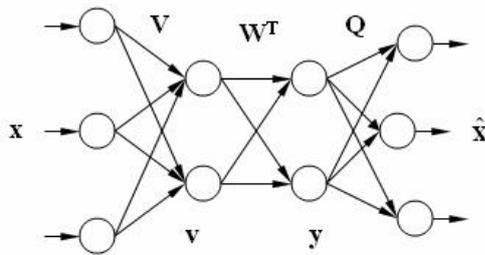
برای تخمین مدل ICA روش‌های مختلفی تاکنون ارائه شده است. هاوارینن [8] الگوریتمی تحت عنوان FastICA پیشنهاد کرده است. این الگوریتم بر مبنای بیشینه کردن میزان غیر گوسی بودن منابع عمل می‌کند و برای اندازه‌گیری میزان غیر گوسی بودن از نگنترویی استفاده شده است. بل و سیچنسکی [10] یک الگوریتم بدون معلم برای بیشینه کردن اطلاعات در یک شبکه پیش‌رو تک‌لایه با خروجی غیر خطی به منظور جداسازی کور منابع ارائه کرده‌اند. الگوریتم تحت عنوان Infomax نامیده می‌شود. آنها نشان دادند که بیشینه کردن آنتروپی توأم خروجی شبکه معادل با کمینه کردن اطلاعات متقابل است. الگوریتم در جداسازی منابع با توزیع فراگوسی موفق است، اما قادر به جداسازی منابعی که دارای کورت منفی هستند (مثل توزیع یکنواخت)، نیست. لی و همکاران [11] قابلیت الگوریتم Infomax را جهت جداسازی منابع با توزیع فراگوسی و فروگوسی گسترش دادند.

از روش‌های تنسوری² نیز برای تخمین مدل ICA استفاده شده است. تنسور یک حالت کلی‌تر از ماتریس و عملگرهای خطی است. به عنوان

1. Unsupervised

2. Tensor

3. Equivariant Adaptive Separation via Independence



شکل 1: ساختار شبکه عصبی سه لایه پیشنهادی برای انجام ICA وفقی [13].

2-4 جداسازی

اصلی‌ترین و در عین حال مشکل‌ترین بخش در تحلیل مؤلفه‌های مستقل، یادگیری ماتریس جداسازی W است. چون بردارهای v ناهم‌بسته هستند، برای استقلال بردارهای y ، ماتریس W لزوماً باید متعامد باشد [13]

$$E(\mathbf{y}\mathbf{y}^T) = \mathbf{I} = E(\mathbf{W}\mathbf{v}\mathbf{v}^T\mathbf{W}^T) = \mathbf{W}E(\mathbf{y}\mathbf{y}^T)\mathbf{W}^T = \mathbf{W}\mathbf{W}^T \quad (8)$$

روش‌های ارائه‌شده، تعمیم غیر خطی از اجرای PCA به کمک شبکه‌های عصبی به‌شمار می‌روند. در توسعه الگوریتم‌های ICA مهم‌ترین مسأله مجهول بودن تابع توزیع احتمال منابع است. چرا که میزان دقیق استقلال منابع تنها با دانستن تابع چگالی احتمال آنها به‌دست می‌آید. بنابراین باید میزان استقلال منابع را به کمک توابع ارزشی مناسب تخمین زد. توابع ارزشی که آمارگان مرتبه بالاتر مثل کرتوزیس را به‌کار می‌برند، از این دسته‌اند. شکل کلی توابع ارزشی مطابق زیر است

$$J(\mathbf{y}) = \sum_{i=1}^M E(f(y(i))) \quad (9)$$

با استفاده از شیوه‌گرادیان تصادفی در بیشینه (کمینه) کردن این تابع و اعمال شرط متعامد بودن W ، قانون یادگیری W مطابق زیر خواهد بود [18]

$$\Delta W = \mu_k [\mathbf{I} - W_k W_k^T] \mathbf{v}_k g(\mathbf{v}_k^T W_k) \quad (10)$$

که در آن $g(y) = f'(y)$ می‌بینیم که تنها تفاوت (10) با قاعده یادگیری PCA وجود بخش غیر خطی $g(y)$ در مرحله آموزش شبکه است. همین امر سبب استخراج ویژگی‌های مفیدتری از میان داده‌ها شده است. بنابراین الگوریتم را PCA مقاوم³ خوانند. با انتخاب $f(y) = y^4/4$ که معادل $g(y) = y^3$ می‌باشد، تابع ارزشی زیر حاصل می‌شود

$$J(\mathbf{y}) = \sum_{i=1}^M E(y(i)^4) \quad (11)$$

این رابطه با در نظر گرفتن کرتوزیس منابع با شرط واریانس واحد و حذف مقدار ثابت 3 به دست آمده است [13]. برای جداسازی منابع فراگوسی⁴ باید (11) را بیشینه و برای منابع فروگوسی⁵ آن را کمینه کرد.

اگر f مجموع ممان‌های زوج باشد، $g(y) = \tanh(y)$ خواهد بود. همواره باید یک تابع فرد انتخاب شود. اشکال عمده این روش زمانی نمود می‌کند که تعداد منابع مستقل برابر سیگنال‌های مشاهده شده باشد. در این حالت W یک ماتریس مربعی خواهد شد و این امکان وجود دارد که قبل از استقلال، منابع W برابر با \mathbf{I} شود و عملیات به‌روز کردن

به‌صورت وقفی به‌دست می‌آید. در گام آخر، ماتریس ترکیب بدون نیاز به وارون کردن ماتریس جداسازی تخمین زده می‌شود. این شبکه در شکل 1 نشان داده شده است. خروجی لایه دوم (بدون توجه به دامنه و ترتیب)، تخمینی از مؤلفه‌های مستقل، v خروجی لایه اول، داده‌های ناهم‌بسته شده \hat{x} در لایه آخر تخمینی از L سیگنال ورودی می‌باشد. در شکل 1 اتصالات فیدبک که برای آموزش شبکه لازم می‌باشند، نشان داده نشده‌اند. شبکه خطی بوده و توابع غیر خطی تنها در تعیین و به‌روزسازی وزن‌های شبکه (در حین مرحله آموزش و سپس در هنگام استفاده برخط از شبکه) به‌کار گرفته می‌شوند.

1-4 ناهم‌بسته‌سازی

در مدل ICA فرض می‌شود که بردار x دارای میانگین صفر است. این فرض از کلیت مسأله نمی‌کاهد. بدین سان آمارگان مرتبه اول سیگنال‌ها صفر است. هدف اصلی از ناهم‌بسته‌سازی (سفیدسازی)¹، سرعت در همگرایی شبکه، سادگی جداسازی و ویژگی‌های پایداری بهتر است. ناهم‌بسته‌سازی علاوه بر آن با حذف سیگنال‌های با واریانس بسیار کوچک، می‌تواند بعد داده‌ها را از L به M کاهش دهد و از این طریق تا حدی در کاهش اولیه نویز مؤثر باشد. اگر V ماتریس ناهم‌بسته‌سازی باشد [13]

$$\mathbf{v}_k = \mathbf{V}_k \mathbf{x}_k \quad (4)$$

بردارهای v ، بردار ناهم‌بسته هستند. بنابراین برای هر نمونه k از داده‌ها، رابطه $E(\mathbf{v}_k \mathbf{v}_k^T) = \mathbf{I}$ است. روش برون‌خط به‌دست آوردن ماتریس V ، استفاده از تجزیه به مقادیر ویژه است. علاوه بر روش وقفی یافتن مقادیر ویژه، چند قانون یادگیری برای V پیشنهاد شده است [13]

$$\Delta \mathbf{V}_k = \mu (\mathbf{v}_k \mathbf{v}_k^T - \mathbf{I}) \mathbf{V}_k \quad (5)$$

$$\Delta \mathbf{V}_k = \mu (\mathbf{v}_k \mathbf{v}_k^T - \mathbf{I}) \quad (6)$$

الگوریتم‌های (5) و (6) از کمینه‌کردن واگرایی کولباک - لیبلر بین دو توزیع با کورایانس \mathbf{I} و $E(\mathbf{v}_k \mathbf{v}_k^T)$ [17] به دو روش گرادیان معمولی و طبیعی به‌دست آمده‌اند. الگوریتم (6) سرعت همگرایی بالاتری دارد اما گاه با مشکل پایداری مواجه است.

در الگوریتم‌های وقفی برخط، عملکرد لحظه‌ای شیوه‌های سفیدسازی حائز اهمیت است. ما در این مقاله از ناهم‌بسته‌سازی برون‌خط داده‌های آموزشی برای مقاردهی اولیه ماتریس ناهم‌بسته‌سازی برخط استفاده می‌کنیم. برای این منظور با استفاده از تجزیه مقادیر منفرد (SVD)، ماتریس ثابتی، S ، به‌دست آورده می‌شود. از تجزیه ماتریس کورایانس مربوط به بخش آموزشی سیگنال‌های مشاهده‌شده، x ، به مقادیر ویژه، ماتریس S بدین گونه به‌دست می‌آید [8]

$$R_x = \text{cov}(x) = U \times C \times U^T \Rightarrow S = C^{\frac{1}{2}} \times U^T \quad (7)$$

که در آن C ماتریس قطری مقادیر ویژه و U ماتریس یکه² است. از این ماتریس برای ناهم‌بسته‌سازی داده‌ها قبل از اعمال داده‌های آزمایشی به شبکه استفاده می‌شود. در این صورت سفیدسازی برخط تنها مسئول اصلاح نتیجه در زمان تغییر احتمالی داده‌ها خواهد بود. در بخش بعد کارایی جالب این ترفند نشان داده شده است.

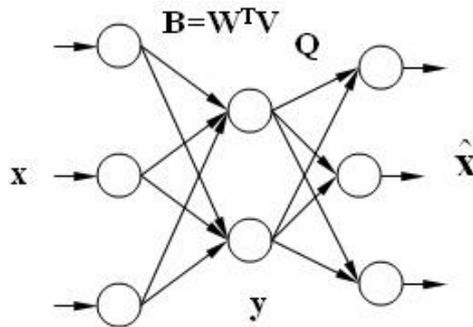
3. Robust PCA

4. Super - Gaussian

5. Sub-Gaussian

1. Whitening

2. Unitary



شکل 2: ساختار شبکه عصبی دو لایه معادل برای انجام ICA وفقی [13].

با اندکی تغییر (EASI تعمیم یافته³)، می توان مشکل ناپایداری که معمولاً در EASI دیده می شود را حل کرد [15]

$$\Delta \mathbf{B}_k = \mu_k \left[\frac{y_k y_k^T - \mathbf{I}}{1 + \mu_k y_k^T y_k} + \frac{g(y_k) y_k^T - y_k g(y_k)}{1 + \mu_k y_k^T g(y_k)} \right] \mathbf{B}_k \quad (18)$$

نقش عبارات اسکالر موجود در مخرج، تنها پایدارسازی الگوریتم می باشد. شرط پایداری این الگوریتم، هم علامت بودن مجموع کورتوزیس هر دو منبع است، با وجود این که سفیدسازی در این الگوریتم نهفته است، اما سفیدسازی مجزا در بهبود نتایج حاصل از این روش نیز مؤثر است.

5- ارزیابی ICA عصبی با داده های شبیه سازی

در این بخش عملکرد چهار روشی را که به آنها اشاره شد، با اعمال بر روی سه مثال با سیگنال های شبیه سازی شده متفاوت با مشخصات آماری گوناگون در چهار حالت متفاوت مورد بررسی قرار می دهیم. تفاوت چهار حالت در نحوه ناهم بسته سازی سیگنال ها است:

الف) هیچ گونه سفیدسازی بر روی داده ها انجام نشده است یعنی شبکه دو لایه شکل 2 استفاده شده است.

ب) سفیدسازی برون خط مبتنی بر تجزیه ماتریس کوارینانس داده های آموزشی به مقادیر ویژه [20] انجام می گیرد. ماتریس \mathbf{S} حاصل برای داده های آزمایشی به عنوان یک فیلتر ایفای نقش می کند. اگرچه این فیلتر برای ناهم بسته سازی داده های آزمایشی کاملاً مناسب نیست؛ اما جداسازی سیگنال ها را بسیار ساده تر می کند. در این حالت نیز از شبکه دو لایه استفاده شده است، اما داده ها پس از عبور از فیلتر \mathbf{S} وارد شبکه می شوند.

ج) در این حالت شبکه سه لایه مورد استفاده قرار می گیرد و آموزش لایه اول مطابق الگوریتم 7 انجام می شود.

د) این حالت ترکیب «ب» و «ج» است که در آن علاوه بر سه لایه شبکه، داده ها پس از عبور از فیلتر \mathbf{S} وارد شبکه می شوند. در این حالت انتظار می رود ویژگی های ناهم بسته سازی برخط و برون خط با هم ترکیب شده و نتایج بهتری حاصل شود. یعنی علاوه بر سرعت همگرایی بیشتر، تغییر احتمالی ماتریس ترکیب در طول زمان دنبال می شود.

به منظور قضاوت مفید در مورد نتیجه جداسازی روش های مختلف، ضریب عملکرد⁴ (PI) را به عنوان یک معیار در این بررسی معرفی می کنیم.

متوقف شود. در روابط یادگیری (12) و (13) این مشکل حل شده است [13]

$$\mathbf{W}_{k+1} = \mathbf{W}_k + \mu_k [\mathbf{v}_k - \mathbf{W}_k g(\mathbf{y}_k)] g(\mathbf{y}_k^T) \quad (12)$$

$$\mathbf{W}_{k+1} = \mathbf{W}_k + \mu_k \mathbf{v}_k g(\mathbf{y}_k^T) + \gamma_k \mathbf{W}_k (\mathbf{I} - \mathbf{W}_k^T \mathbf{W}_k) \quad (13)$$

الگوریتم (12) را PCA غیر خطی¹ می نامند. تنها تفاوت قاعده یادگیری (13) با (10) در این است که جملات به جای این که در هم ضرب شوند، با استفاده از دو ضریب یادگیری متفاوت با هم جمع شده اند. در این صورت حتی با وجود صفر شدن جمله اول، یادگیری ادامه می یابد. این الگوریتم به واسطه وجود دو جمله با ضرایب یادگیری متفاوت، دو گرایانه² خوانده می شود. مقدار پارامتر γ_k عملاً در حد 0.5 قرار داده می شود. اگرچه همگرایی همه الگوریتم ها با شرط هم علامت بودن کورتوزیس منابع تضمین می شود؛ اما عملکرد الگوریتم های ذکر شده با هم متفاوت است. به هر حال انتخاب مناسب توابع غیر خطی متناسب با توزیع ورودی ها و پارامترها، در کارآمد بودن الگوریتم ها تأثیر به سزایی دارد. همان طور که قبلاً بیان شد، در این روش ها جداسازی منابع با کورتوزیس های ناهم علامت با استفاده از یک تابع برای همه منابع، ممکن نیست؛ گاهی برای جداسازی ترکیب منابع فرا و فروگوسی، لازم است که از ترکیب دو یا چند تابع مختلف استفاده شود.

3-4 تخمین ماتریس ترکیب

از مدل ICA چنین برمی آید که دو ماتریس جداسازی و ترکیب، معکوس یکدیگرند. بنابراین با دانستن هر یک از ماتریس ها، دیگری را خواهیم داشت. اما حجم عملیات معکوس گیری برای یک فرآیند برخط زیاد است. تلاش های زیادی در جهت محاسبه برخط معکوس یک ماتریس صورت گرفته است [19]؛ برای یادگیری ماتریس \mathbf{Q} می توان میانگین مربعات خطای بین ورودی و خروجی شبکه را کمینه کرد

$$E\{\|\mathbf{x}_k - \mathbf{Q}\mathbf{y}_k\|^2\} \quad (14)$$

این کار در لایه سوم با قاعده یادگیری زیر انجام می گیرد

$$\mathbf{Q}_{k+1} = \mathbf{Q}_k + \mu_k (\mathbf{x}_k - \mathbf{Q}_k \mathbf{y}_k) \mathbf{y}_k^T \quad (15)$$

4-4 الگوریتم EASI

در شبکه عصبی بالا می توان فرآیند سفیدسازی داده ها را حذف و یا آن را با مرحله جداسازی منابع ادغام کرد و یک لایه از شبکه کم کرد. در شبکه عصبی جدید (شکل 2)، ماتریس \mathbf{B} ترکیبی از دو ماتریس \mathbf{V} و \mathbf{W} می باشد [13]

$$\mathbf{B} = \mathbf{W}^T \mathbf{V} \quad (16)$$

کاردزو و لاهلد [15] بدون تأکید بر شبکه های عصبی، الگوریتمی به نام EASI مبتنی بر کمینه سازی کورتوزیس منابع برای یادگیری \mathbf{B} پیشنهاد نموده اند

$$\Delta \mathbf{B}_k = -\mu_k [y_k y_k^T - \mathbf{I} + g(y_k) y_k^T - y_k g(y_k^T)] \mathbf{B}_k \quad (17)$$

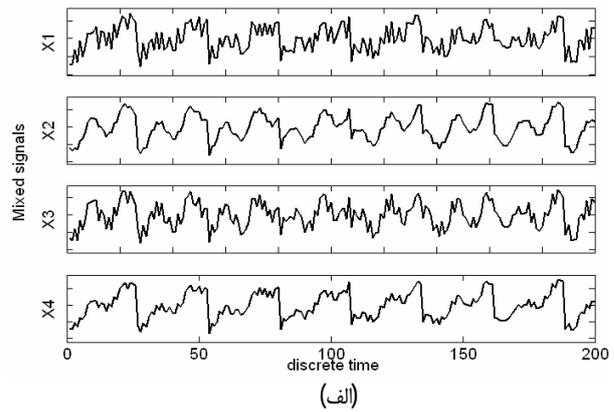
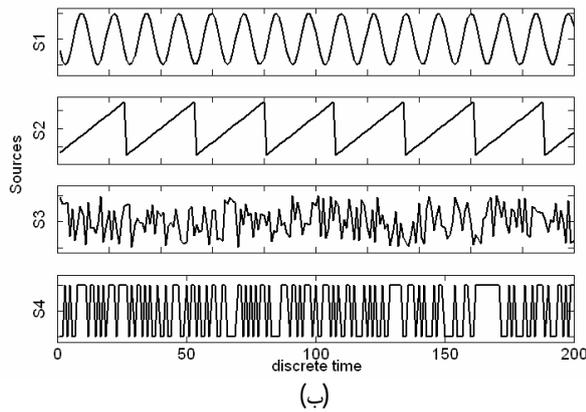
به سادگی می توان از این الگوریتم برای آموزش شبکه عصبی استفاده کرد. کمینه کردن اطلاعات متقابل بین منابع نتیجه مشابهی به دست می دهد [16].

3. Generalized EASI (GEASI)

4. Performance Index

1. Nonlinear PCA

2. Bigradient



شکل 3: سیگنال‌های مثال 1، (الف) ترکیب خطی منابع و (ب) منابع اصلی.

1-5 ضریب عملکرد

استخراج شده به ترتیب با روش‌های دوگرادیان، PCA غیر خطی و EASI نشان داده شده است. شکل 4-ها تغییرات ضریب عملکرد روش‌های همگرا شده را در حالات سفیدسازی موفق نشان می‌دهد. همان‌طور که از این شکل برمی‌آید، روش EASI در حالت «ب» (سفیدسازی برون خط) بهترین امتیاز را از نظر سرعت همگرایی و دقت در جداسازی منابع کسب کرده است.

نوع سفیدسازی تنها تعیین‌کننده سرعت همگرایی در مرحله آموزش است و در نتیجه نهایی تأثیر چندانی ندارد. استفاده از سفیدسازی برخط در روش EASI مانع از همگرایی آن شده است. نکته دیگر در الگوریتم EASI، تأثیر منفی سفیدسازی برخط بر سرعت همگرایی بالای سفیدسازی برون خط است. علت احتمالاً آن است که سفیدسازی اعمال شده در EASI و شیوه مورد استفاده روش (7) با هم تعارض دارند. به نحوی که ترکیب آن دو با هم به همگرایی نمی‌انجامد. هرچند در روش EASI، سفیدسازی برخط اضافی (شبکه سه لایه) منجر به ضعیف‌تر شدن عملکرد روش شده است، اما سفیدسازی برون خط تأثیر غیر قابل انکار دارد. مثال 2: پنج سیگنالی که در اینجا مورد بحث می‌باشند در [21] معرفی شده‌اند تا به کمک آنها بتوان اثر تفاوت زیاد دامنه در منابع ترکیبی را شبیه‌سازی کرد. همان‌طور که از (20) برمی‌آید، پنجین سیگنال، نویز یکنواختی با دامنه یک یعنی 102 تا 105 برابر مؤلفه‌های دیگر است. به طوری که سیگنال‌های حاصل از ترکیب آنها (شکل 5-الف) ظاهراً فقط شامل نویز هستند و دیگر مؤلفه‌ها در این ترکیب خود را نشان نمی‌دهند. شکل 5-ب تنها یک بخش 5000 نقطه‌ای از مجموع 20000 نقطه کل داده‌ها که الگوریتم بر روی آنها انجام گرفته است را نشان می‌دهد

$$\begin{aligned} s_1(t) &= 10^{-5} \text{sign}[\cos(155t)] \\ s_2(t) &= 10^{-4} \sin(80t) \sin(60t) \\ s_3(t) &= 10^{-3} \sin[30t + 6 \cos(61t)] \\ s_4(t) &= 10^{-2} \sin(90t) \\ s_5(t) &= \text{uniform noise} \end{aligned} \quad (20)$$

در این مثال همه مؤلفه‌ها فروگوسی و با کورتوزیس منفی به ترتیب برابر با 2,0001، -0,7425، -1,5149، -1,4974 و -1,2108 هستند. ماتریس

ترکیب در این حالت به گونه زیر است

$$A = \begin{bmatrix} 0,7000 & 0,1500 & -0,2200 & 0,1200 & -0,4800 \\ 0,9200 & -0,9000 & -0,2700 & -0,9300 & -0,6900 \\ 0,4000 & -0,9100 & 1,000 & 0,7800 & 0,5000 \\ -0,8800 & 0,9900 & 0,1000 & -0,7800 & 0,2900 \\ 0,8400 & -0,3300 & 0,0200 & -0,2600 & 0,5100 \end{bmatrix}$$

با تحلیل مؤلفه‌های مستقل می‌توان به تخمینی از منابع مستقل با دو ابهام در مورد ترتیب و واریانس آنها دست یافت. به بیان دیگر در تحلیل مؤلفه‌های مستقل ماتریس ترکیب بدون توجه به ترتیب سطرها و دامنه آنها تخمین زده می‌شود، چون ماتریس جداسازی، معکوس ماتریس ترکیب است، ابهام در ترتیب و واریانس مؤلفه‌های تخمین زده شده وجود دارد. بنابراین می‌توان گفت با دانستن مقدار واقعی ماتریس ترکیب، تخمینی دقیق‌تر است که در آن حاصل ضرب ماتریس جداسازی تخمین زده شده و ماتریس ترکیب واقعی، $G = W.A$ ، به ماتریس همانی I نزدیک‌تر باشد. لذا می‌توان ضریب عملکرد را بدین گونه تعریف کرد

$$PI = \sum_{i=1}^n \left\{ \left(\sum_{k=1}^n \frac{|g_{ik}|^2}{\max_j |g_{ij}|^2} - 1 \right) + \left(\sum_{k=1}^n \frac{|g_{ki}|^2}{\max_j |g_{ji}|^2} - 1 \right) \right\} \quad (19)$$

هرچه این ضریب به صفر نزدیک‌تر باشد، جداسازی بهتر انجام شده است. عملکرد روش‌ها در حالت‌های متفاوت با ضریب عملکرد PI مورد مقایسه قرار گرفته‌اند.

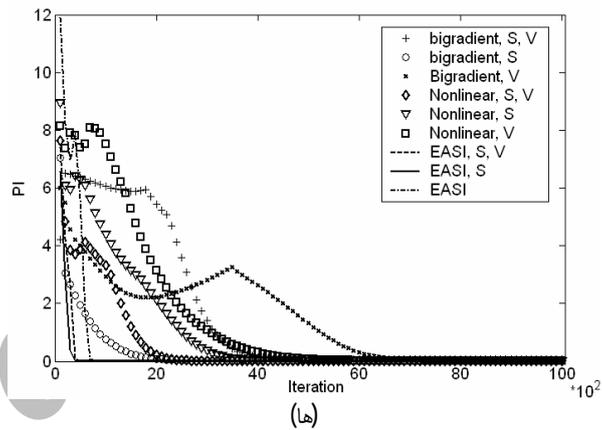
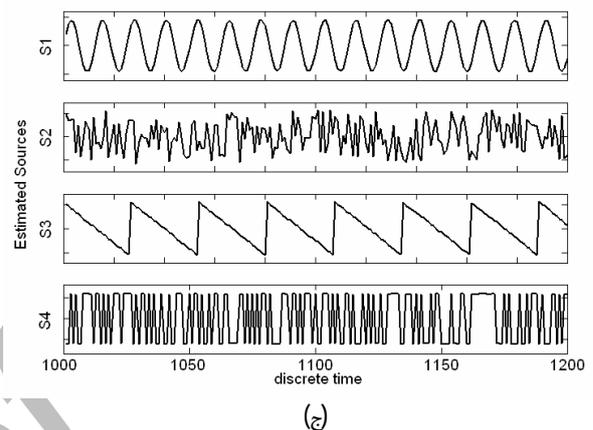
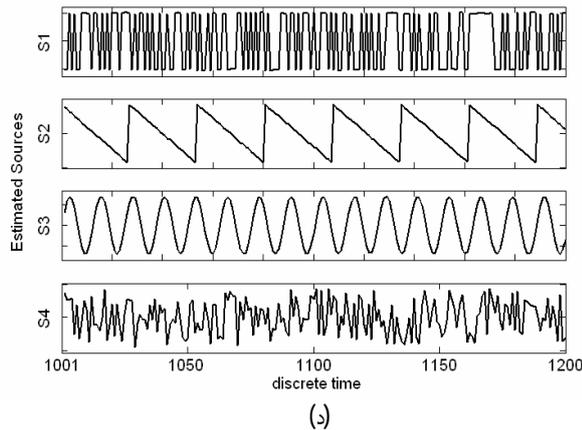
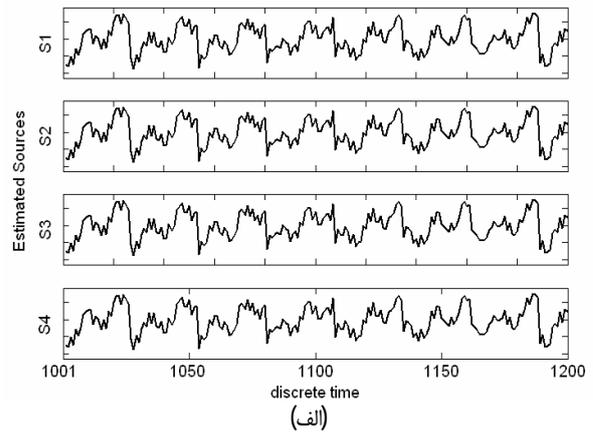
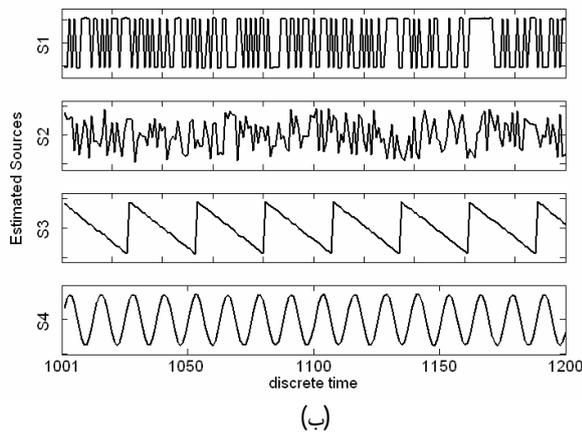
2-5 نتایج مثال‌های شبیه‌سازی شده

مثال 1: شکل 3-الف ترکیب خطی چهار منبع با ماتریس ترکیب A را نشان می‌دهد. چهار سیگنال فروگوسی سینوسی، دندان اره‌ای، تصادفی یکنواخت با واریانس 1 و باینری به ترتیب با کورتوزیس 1,5002، -1,2042، -1,9995 و -1,2168 در شکل 3-ب نشان داده شده‌اند

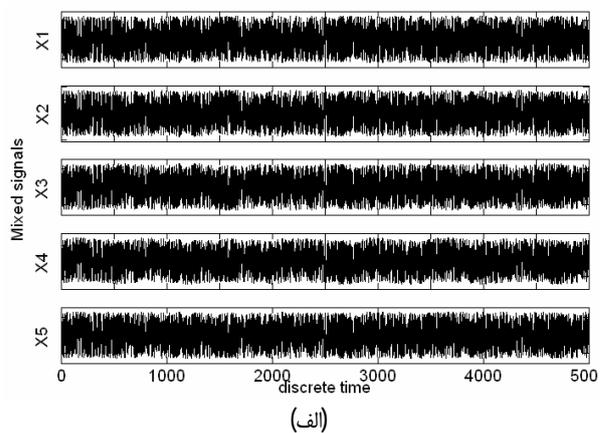
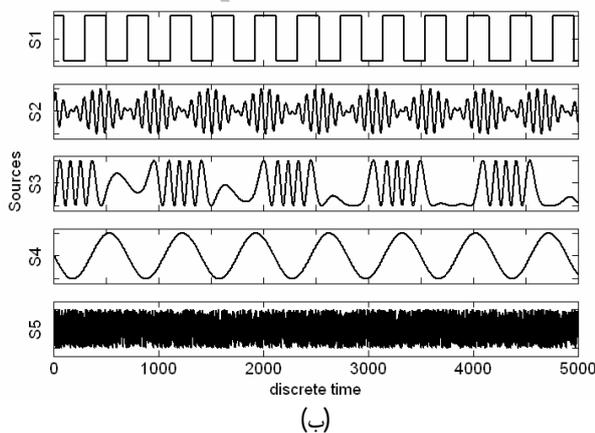
$$A = \begin{bmatrix} 0,2371 & 0,5548 & -0,2481 & 0,3921 \\ 0,6263 & 0,6013 & 0,0116 & 0,1197 \\ 0,6423 & 0,4087 & -0,1447 & 0,3691 \\ 0,3514 & 0,8029 & 0,0046 & 0,1918 \end{bmatrix}$$

همان‌طور که قبلاً اشاره شد الگوریتم EASI برای آموزش شبکه دولایه (لایه استخراج ضرایب جداسازی و لایه ترکیب) گسترش داده شده است. ما در این مقاله اثر سفیدسازی برخط را در ابتدای این الگوریتم مورد بررسی قرار می‌دهیم. از شکل 4-الف روشن است که روش PCA مقاوم در هیچ حالتی نتیجه قابل قبولی ندارد (همگرا نشده است). در تمامی روش‌ها (بخش 3-2) سفیدسازی (برخط یا برون خط) در فرآیند جداسازی منابع نقش آشکاری دارد، چون هیچ یک از الگوریتم‌ها بدون سفیدسازی، حتی با تکرار زیاد مرحله آموزش جواب خوبی به دست نمی‌دهند.

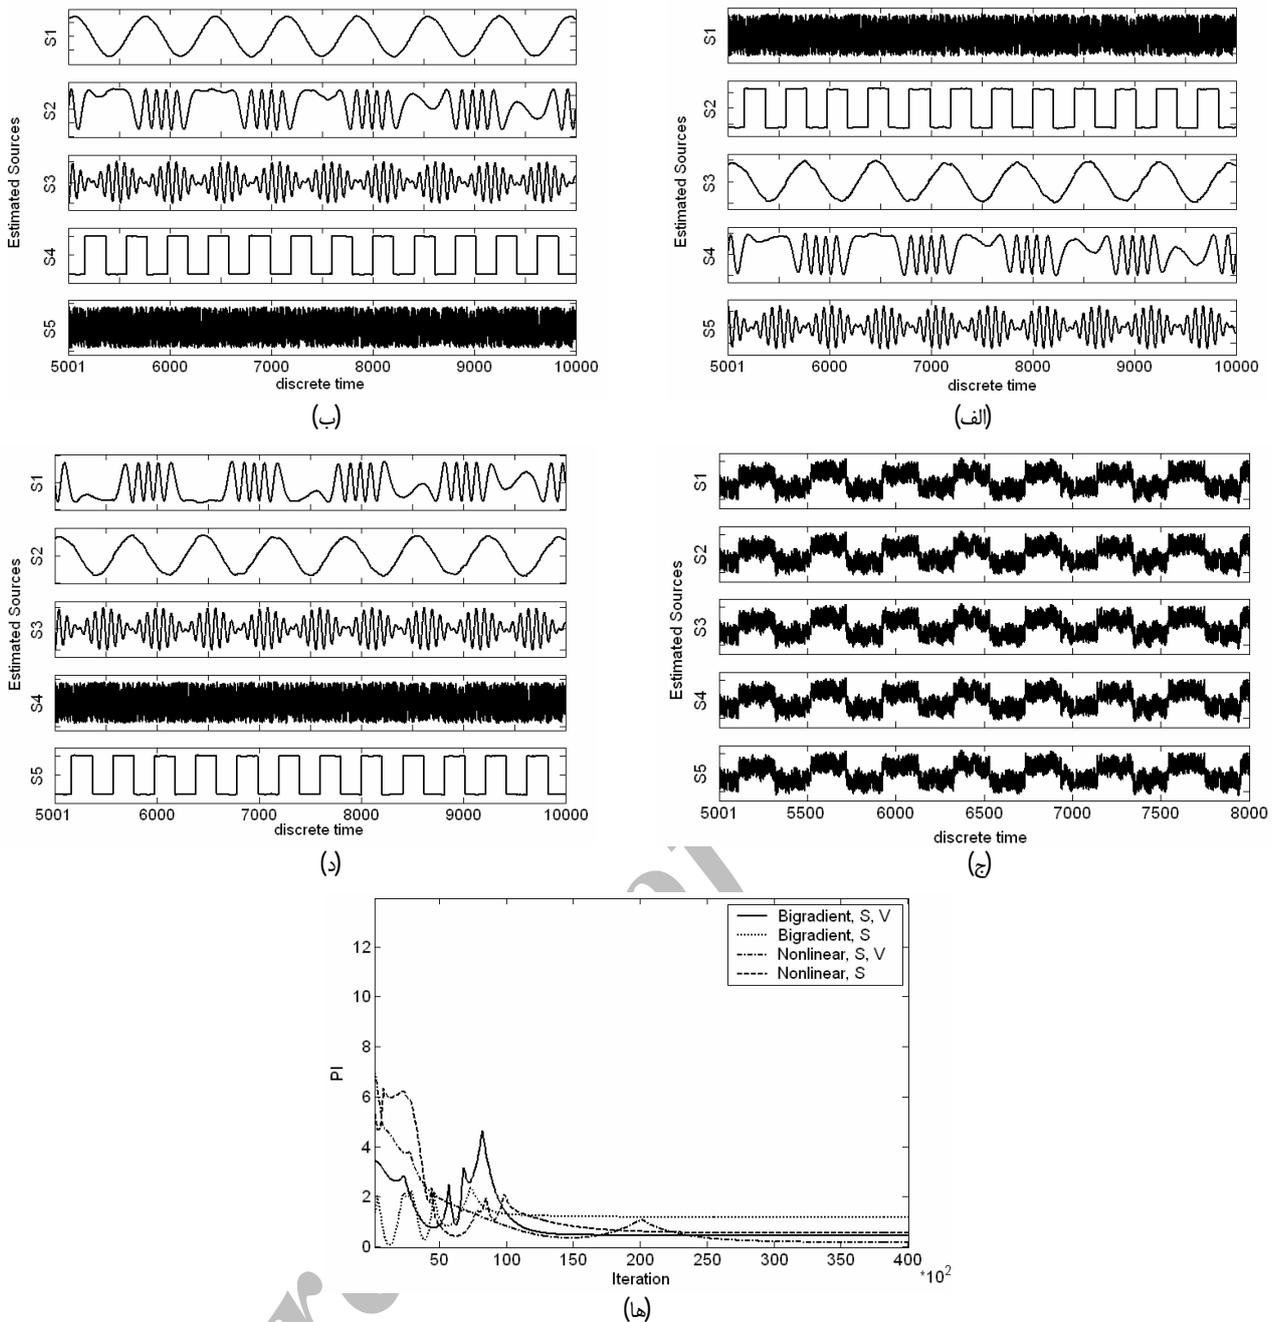
در همه روش‌ها، 1000 نقطه ابتدایی داده‌ها برای آموزش شبکه عصبی به کار رفته‌اند. تابع غیر خطی مورد استفاده در سه روش اول، $\tanh(y)$ و در روش EASI، y^3 بوده است. در شکل‌های 4-ب، 4-ج و 4-د منابع



شکل 4: نتایج حاصل از اعمال الگوریتم‌های (الف) مقاوم، (ب) دوگرادینانه، (ج) PCA غیرخطی با تابع $\tanh(y)$ ، (د) EASI با تابع y^3 ، بر روی داده‌های مثال 1 در بهترین حالت سفیدسازی و (ه) تغییرات ضریب عملکرد برای سه روش PCA غیرخطی، دوگرادینانه و EASI.



شکل 5: سیگنال‌های مثال 2، (الف) ترکیب خطی منابع و (ب) منابع اصلی.

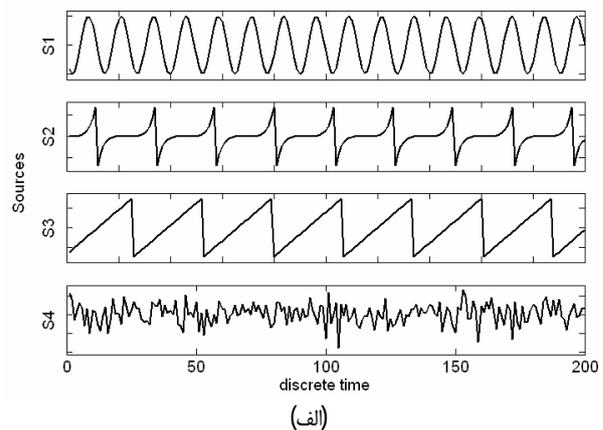
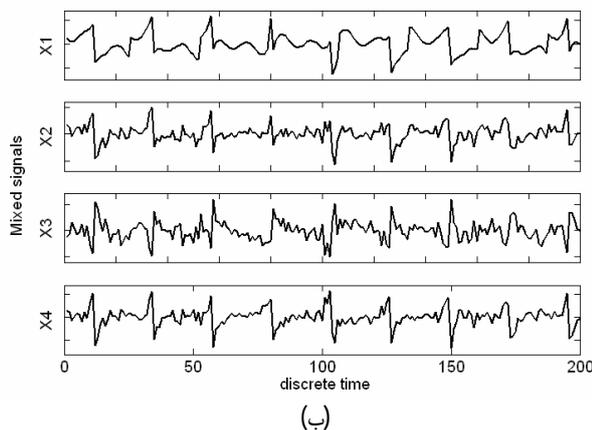


شکل 6: نتایج حاصل از اعمال الگوریتم‌های (الف) PCA مقاوم، (ب) دوگرادیانه، (ج) PCA غیرخطی با تابع $\tanh(y)$ ، (د) EASI با تابع y^3 ، بر روی داده‌های مثال 2 در بهترین حالت سفیدسازی و (هـ) تغییرات ضریب عملکرد برای سه روش PCA غیرخطی، دوگرادیانه و EASI.

نتایج جداسازی منابع به روش‌های گوناگون و در حالات مختلف سفیدسازی در جدول 1 آورده شده است. ملاحظه می‌شود که روش PCA مقاوم در هیچ حالتی نتیجه قابل قبولی ندارد. روش دوگرادیانه و PCA غیر خطی تنها در زمانی که فقط از سفیدسازی برون خط استفاده شده است کارساز می‌باشد. می‌توان چنین نتیجه گرفت که الگوریتم‌های یادگیری شبکه عصبی سه‌لایه قادر به جداسازی منابع بدون سفیدسازی برون خط نیستند.

در همه روش‌ها 5000 نقطه ابتدایی داده‌ها برای آموزش شبکه عصبی به کار رفته‌اند. تابع غیر خطی مورد استفاده در سه روش اول $\tanh(y)$ و در روش EASI y^3 بوده است. همان‌طور که در شکل مشخص است، روش PCA غیر خطی در حالت «د» بهترین امتیاز را از نظر سرعت و دقت در جداسازی منابع کسب کرده است.

حاصل از به‌کارگیری روش‌های PCA مقاوم، دوگرادیانه و PCA غیر خطی برای جداسازی منابع این مثال در شکل‌های 6-الف تا 6-د نشان داده شده است. ذکر این نکته لازم است که شکل‌ها مربوط به عملکرد هر الگوریتم در بهترین حالت آن است. شکل 6-هـ تغییرات ضریب عملکرد را تنها برای دو الگوریتم دوگرادیانه و PCA غیر خطی در حالتی که به منابع مناسبی همگرا شده‌اند نشان می‌دهد. در این مثال این دو الگوریتم حتماً نیاز به سفیدسازی برون خط دارند و سفیدسازی برخط برای آنها کافی نیست. EASI به جز در حالتی که از سفیدسازی برخط در آن استفاده شده است، ضریب عملکرد قابل قبولی دارد، اما همگرایی آن به علت دامنه زیاد نویز یکنواخت به شدت نوسانی است. بنابراین وجود نوسانات زیاد در ضریب عملکرد شکل 6-هـ را می‌تواند شاهد کرد و از رسم تغییرات PI در روش EASI صرف نظر کرده‌ایم.



شکل 7: سیگنال‌های مثال 3، (الف) ترکیب خطی منابع و (ب) منابع اصلی.

جدول 2: ضریب عملکرد برای چهار روش PCA مقاوم، PCA غیرخطی دوگرادیانه و EASI تعمیم‌یافته پس از مرحله آموزش برای مثال 3، ناکارآمدی تابع غیرخطی y^3 در جداسازی منابع مرکب برای همه الگوریتم‌ها.

روش	الف	ب	ج	د
PCA مقاوم	7/2847	6/7322	4/5682	5/5569
دوگرادیانه	4/1649	4/5391	3/8346	7/0487
PCA غیرخطی	3/1251	6/4450	4/9556	10/2182
EASI	4/1649	6/3968	واگرا	5/6660

جدول 1: ضریب عملکرد برای چهار روش PCA مقاوم، PCA غیرخطی دوگرادیانه و EASI تعمیم‌یافته پس از مرحله آموزش برای مثال 2.

روش	الف	ب	ج	د
PCA مقاوم	12/2118	6/6058	11/7835	5/4389
دوگرادیانه	6/6279	4/3866	1/1521	0/4982
PCA غیرخطی	10/3178	12/0034	0/5270	0/1800
EASI	0/2952	1/3505	0/2952	0/2349

مثال 3: در این مثال برای بررسی حساسیت الگوریتم‌ها به توزیع ورودی، سیگنال باینری را با یک سیگنال سوزنی شکل با کورتوزیس $2/4222$ جایگزین کرده‌ایم و واریانس نویز را متغیر در نظر گرفته‌ایم. به طوری که کورتوزیس آن $0/0611$ است (شبه‌سازی سیگنال غیر ایستادن). سیگنال‌ها با ماتریس A ترکیب شده و به ترتیب در شکل 7-الف و 7-ب نشان داده شده است.

$$A = \begin{bmatrix} 0.5443 & -0.5169 & 0.3405 & -0.0343 \\ 0.4148 & -1.3291 & 0.3309 & -0.7634 \\ 0.7614 & 1.5886 & -0.0269 & 1.3691 \\ -0.3329 & -1.9743 & -0.1608 & -0.8432 \end{bmatrix}$$

با انتخاب تابع غیر خطی مشابه برای هر چهار منبع، مثلاً $\tanh(y)$ در روش‌های بخش (4-2) و y^3 برای EASI، حتی حالت «ب» روش EASI که بهترین روش در مورد مثال قبلی بوده است، جواب قابل قبولی به دست نمی‌دهد. بررسی مقدار ضریب عملکرد در جدول 2 برای هر چهار روش و شکل‌های 8-الف تا 8-د که منابع استخراج شده را برای هر روش با توابع غیر خطی مذکور نشان می‌دهند، مؤید این نکته است.

6- حذف بی‌درنگ آرتیفکت از داده‌های واقعی

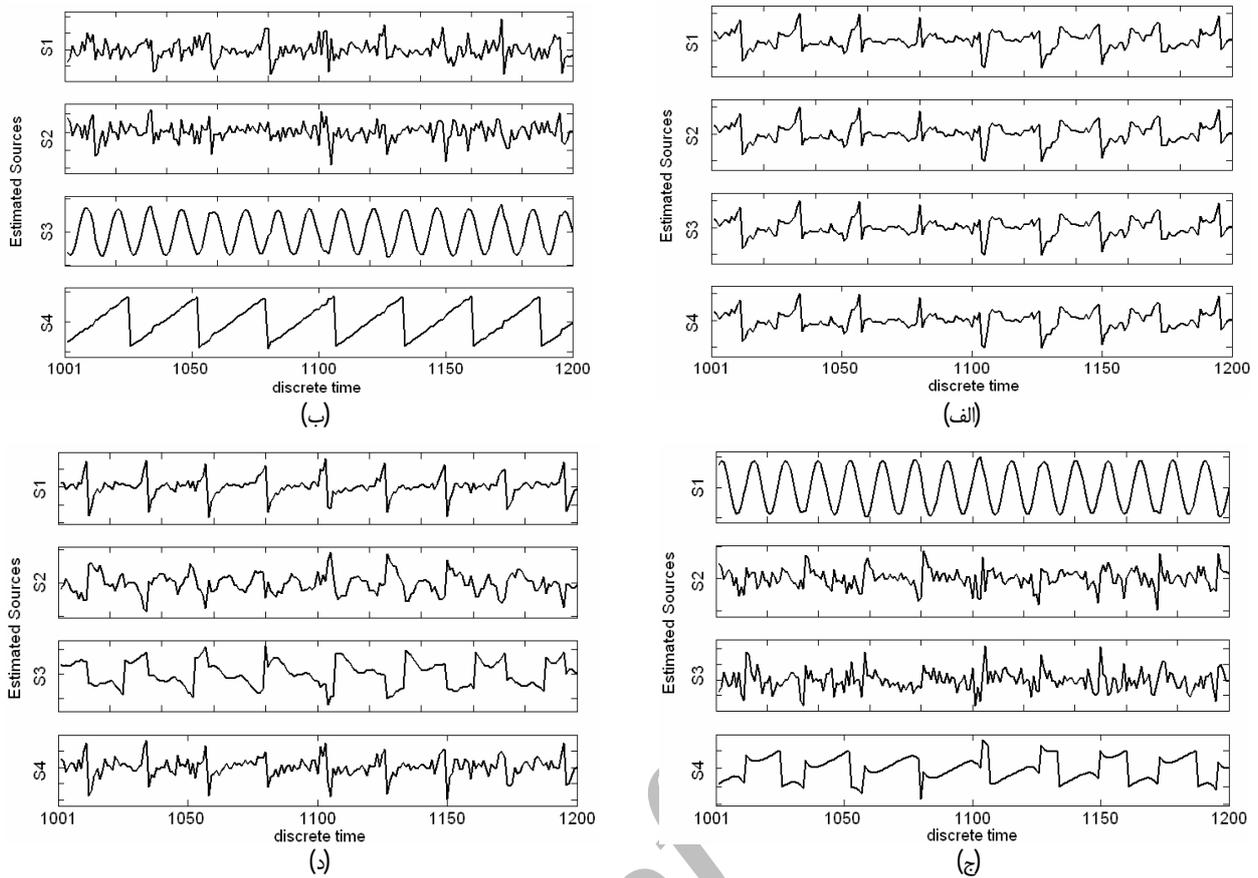
سیگنال EEG با نصب الکترودهایی از جنس Ag/AgCl در موقعیت‌های F3، F4، Fz، Cz، T5 و Fp1 مطابق استاندارد 10-20 از سر 4 فرد سالم ثبت شده است. همه کانال‌ها نسبت به الکتروود مرجع در گوش راست با فرکانس نمونه‌برداری 256 هرتز ثبت شدند. نهایتاً 71 آزمون برای بررسی عملکرد الگوریتم‌ها انتخاب شده است. طول این سیگنال‌ها 60 ثانیه است. این طول با فرکانس نمونه‌برداری 256 هرتز، 15360 نقطه از هر آزمون در اختیار قرار می‌دهد. برای جداسازی آرتیفکت پلک‌زدن از سیگنال‌های مغزی سه الگوریتم PCA غیر خطی، EASI و PCA غیر خطی قابل انعطاف انتخاب شده‌اند. از هر آزمون تنها 1000 نقطه برای آموزش در هر روش انتخاب شده است. داده‌های

آموزشی از بخشی از سیگنال مغزی انتخاب شده‌اند که دارای آرتیفکت پلک‌زدن بوده است. الگوریتم‌ها در حالتی به کار گرفته شده‌اند که از سفیدسازی برون‌خط S استفاده شده باشد. فرآیند آموزش 1000 بار تکرار شده است. پس از آموزش، دو الگوریتم مذکور جهت استخراج مؤلفه‌های مستقل بر روی داده‌های EEG به‌طور برخط به کار گرفته شده است.

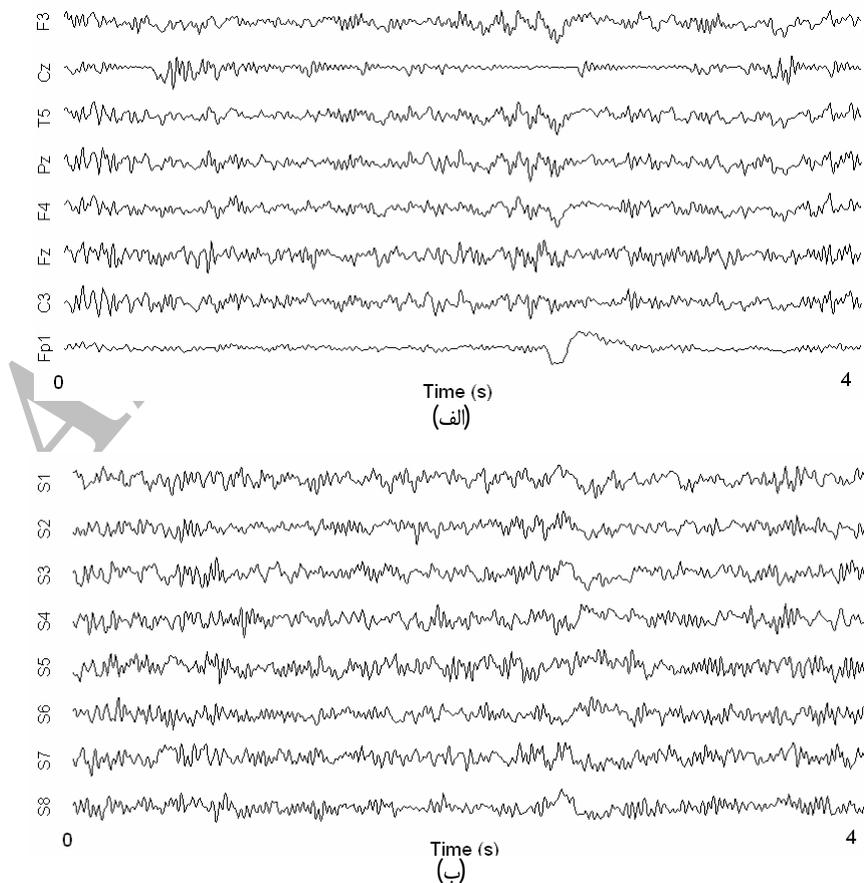
شکل 9-الف بخشی از سیگنال‌های ثبت شده (ثانیه 0 تا 4) را نشان می‌دهد. این بخش از سیگنال برای آموزش الگوریتم‌ها استفاده شده است. شکل 9-ب مؤلفه‌های استخراج شده در فاز آموزش به روش الگوریتم PCA غیر خطی را با استفاده از تابع غیر خطی $\tanh(y)$ نشان می‌دهد. واضح است که آرتیفکت در همه مؤلفه‌ها وجود دارد و نمی‌توان هیچ مؤلفه‌ای کاملاً عاری از آرتیفکت و حتی مؤلفه‌ای را بیش از همه شامل آرتیفکت دانست. بنابراین این الگوریتم با این تابع غیر خطی در حذف آرتیفکت، عملکرد مطلوبی نداشته است. شاید بتوان ادعا کرد که تابع $\tanh(y)$ به دلیل فراگوسی بودن ماهیت مؤلفه آرتیفکت در سیگنال‌های مغزی عملکرد مناسبی نداشته است.

شکل 10 بخش دیگری از سیگنال‌های مغزی (ثانیه 8 تا 20) را نشان می‌دهد. این بخش از سیگنال برای نمایش عملکرد الگوریتم‌ها استفاده شده است تا از هم‌گراشدن هر سه روش مطمئن باشیم و مقایسه معنی داشته باشد. شکل 11-الف همان بخش 12 ثانیه‌ای از مؤلفه‌های استخراج شده به روش PCA غیر خطی را با استفاده از تابع غیر خطی y^3 نشان می‌دهد. پس از آموزش، مؤلفه پنجم به‌عنوان آرتیفکت شناسایی و در فرآیند حذف آرتیفکت به‌طور برخط حذف شده است. سیگنال تصحیح‌شده‌ای که بدین سان به دست آمده، در شکل 11-ب نشان داده شده است. با مقایسه آن با شکل 10 می‌توان دید که آرتیفکت‌ها کاملاً حذف شده‌اند.

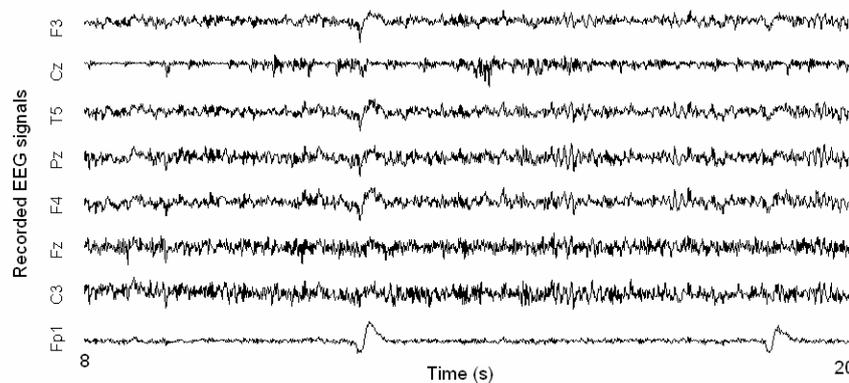
شکل 12-الف مؤلفه‌های استخراج شده به روش الگوریتم PCA غیر خطی قابل انعطاف را نشان می‌دهد. در این الگوریتم در مرحله آموزش به کمک داده‌های آموزشی کورتوزیس مؤلفه‌ها تخمین زده شده و با توجه



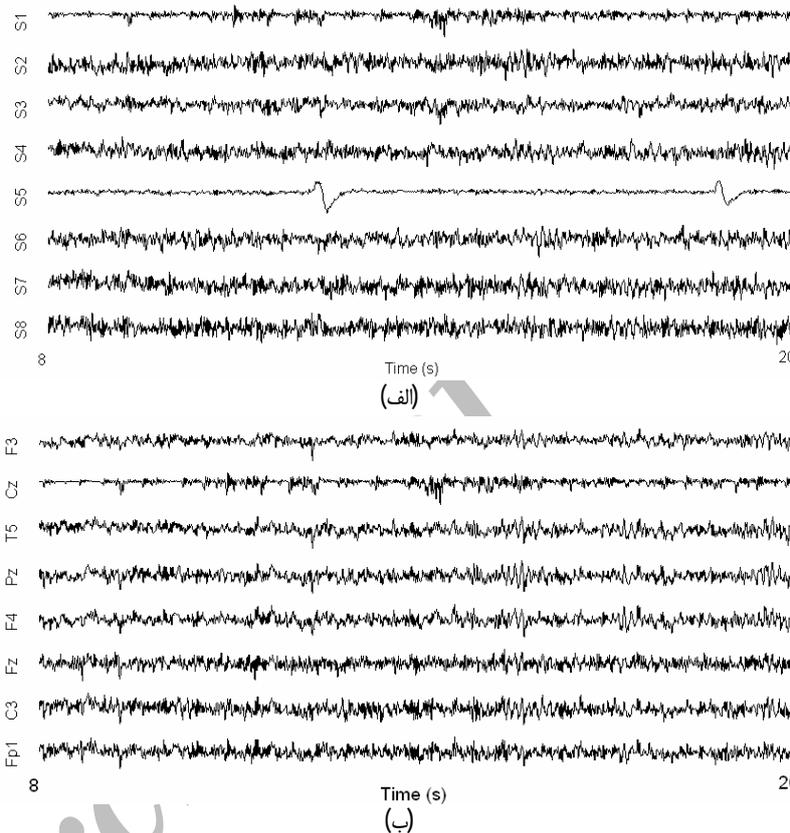
شکل 8: نتایج حاصل از اعمال الگوریتم‌های (الف) PCA مقاوم، (ب) دوگرادینانه، (ج) PCA غیرخطی با تابع $\tanh(y)$ ، و (د) EASI با تابع y^3 ، بر روی داده‌های مثال 3.



شکل 9: (الف) بخشی از سیگنال‌های EEG شامل آرتیفکت پلک‌زدن ثبت‌شده واقعی (0 تا 4 ثانیه) مربوط به کانال‌های Fp1 و T5، Cz، C3، Pz، Fz، F4، F3، S5، S1 و (ب) مولفه‌های استخراج‌شده به روش PCA غیرخطی با استفاده از تابع $\tanh(y)$ در مرحله آموزش.



شکل 10: بخشی از سیگنال‌های EEG شامل آرتیفکت پلک‌زدن ثبت‌شده واقعی (8 تا 20 ثانیه) مربوط به کانال‌های F3, F4, Fz, Pz, Cz, T5 و Fp1.



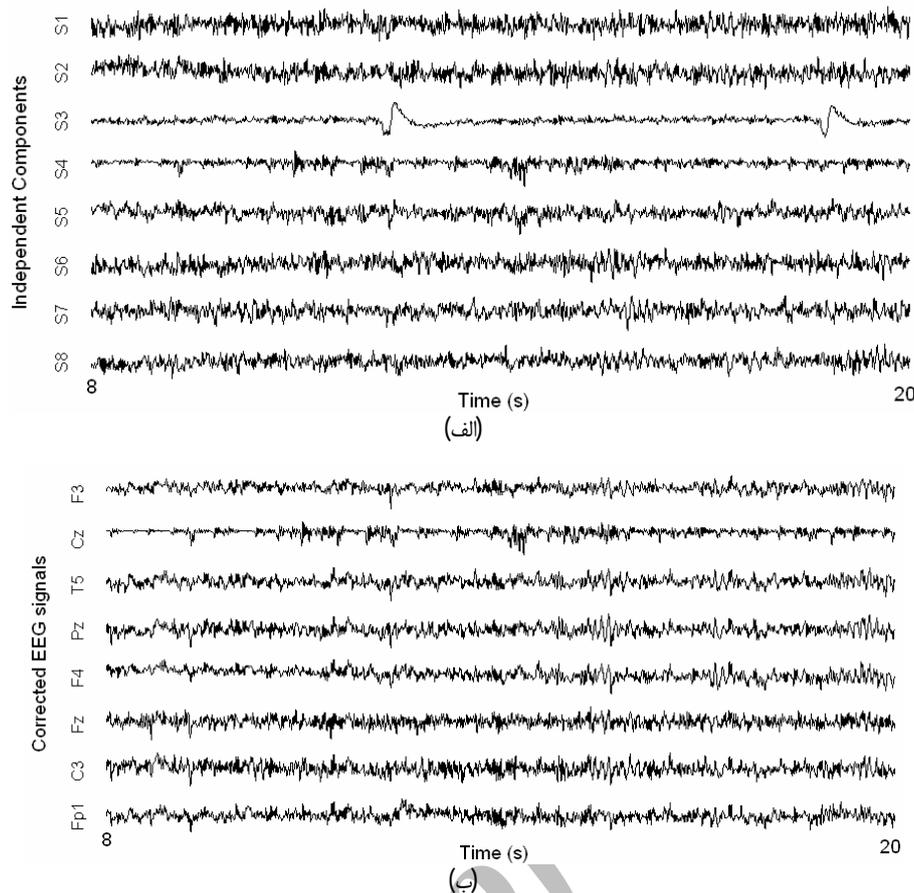
شکل 11: (الف) حذف بر-خط آرتیفکت پلک‌زدن از داده‌های EEG ثبت‌شده از کانال‌های F3, F4, Fz, Pz, Cz, T5 و Fp1، مؤلفه‌های مستقل سیگنال EEG به‌دست آمده به روش PCA غیرخطی با استفاده از تابع y^3 و (ب) داده‌های اصلاح‌شده با حذف مؤلفه پنجم.

آرتیفکت پلک‌زدن نسبتاً موفق عمل کرده است. شکل 13- الف، مؤلفه‌های مستقل حاصل از اعمال الگوریتم EASI با تابع غیر خطی y^3 را بر روی همان بخش 12 ثانیه‌ای از داده‌های EEG نشان می‌دهد. ضریب یادگیری برای Q برابر 0/01 انتخاب شده است. پس از آموزش، اولین مؤلفه به‌عنوان مؤلفه ناشی از پلک‌زدن شناسایی شده و به‌صورت بر-خط حذف شده است. در شکل 13- ب نتایج حذف آرتیفکت پلک مشاهده می‌شود.

لازم به ذکر است که بررسی عملکرد الگوریتم‌ها در حذف آرتیفکت پلک‌زدن از سیگنال‌های مغزی، با توجه به این که از ماتریس ترکیب هیچ اطلاعی در دست نیست، به‌طور چشمی عمل شده است.

نتایج نشان می‌دهد که سه الگوریتم PCA غیر خطی با تابع غیر خطی y^3 ، PCA غیر خطی قابل انعطاف و EASI، قادر به حذف آرتیفکت پلک‌زدن بوده است. این سه الگوریتم بر روی داده‌های 70 آزمون دیگر که از 4 فرد در چند روز ثبت شده‌اند و طول هر یک 60 ثانیه است، مورد

به آنها تابع غیر خطی بین $\tanh(y)$ و y^3 انتخاب می‌شود. سپس در جریان حذف آرتیفکت، تخمین کورتوزیس مؤلفه‌ها نیز به‌صورت برخط به‌روز می‌شود و به دنبال آن، توابع غیر خطی مربوط به هر مؤلفه تغییر می‌کند. یعنی در روش PCA غیر خطی قابل انعطاف توابع غیر خطی با تغییر کورتوزیس منابع در هر لحظه بین $\tanh(y)$ و y^3 تغییر می‌کنند. μ در آموزش V و W در ابتدا برابر 0/0001 انتخاب و به شکل نمایی کاهش می‌یابد. ضریب یادگیری برای Q برابر 0/01 انتخاب شده است. پس از آموزش، مؤلفه سوم به‌عنوان مؤلفه ناشی از پلک‌زدن شناسایی شده و در مرحله حذف بر-خط، لایه سوم شبکه عصبی، این مؤلفه در ترکیب دوباره مؤلفه‌ها با صفر جایگزین می‌شود. چنانچه می‌بینیم، مؤلفه سوم به‌طور قابل قبولی آرتیفکت پلک‌زدن است. از حذف بر-خط این مؤلفه، سیگنال‌های تصحیح‌شده شکل 12- ب حاصل شده است که با مقایسه آن با شکل 10 می‌توان دید که آرتیفکت‌ها کاملاً حذف شده‌اند. الگوریتم EASI با استفاده از سفیدسازی برون-خط هم در جداسازی



شکل 12: حذف بر-خط آرتیفکت پلک‌زدن از داده‌های EEG ثبت‌شده از کانال‌های F3, F4, Fz, Cz, T5 و Fp1. (الف) مولفه‌های مستقل سیگنال EEG به‌دست آمده به روش PCA غیر خطی قابل انعطاف و (ب) داده‌های اصلاح‌شده با حذف مولفه سوم.

یک تابع برای استخراج همه مؤلفه‌ها کارآمد باشد، اما این امر همیشه نیست؛ استفاده از توابع مختلف منطق با ویژگی‌های آماری مؤلفه‌ها به‌صورت بر-خط مناسب‌ترین راه است. پس از آموزش شبکه، ترتیب مؤلفه‌ها ثابت مانده و این امر ابهام در مورد ترتیب مؤلفه‌ها را برطرف و امکان حذف بر-خط مؤلفه آرتیفکت را فراهم می‌کند. هدف از این مقاله مقایسه عملکرد الگوریتم‌های مختلف نبوده است، بلکه قصد ما معرفی مجموعه‌ای از روش‌های برخط برای حذف آرتیفکت از سیگنال‌های مغزی و نشان دادن کارآمدی آنها است. مسلماً با بررسی بیشتر این روش‌ها، برای ارتباط مغز با کامپیوتر در عمل روشی که بهترین نتیجه (سرعت همگرایی بیشتر و ضریب عملکرد کمتر) را به دست دهد، انتخاب خواهد شد.

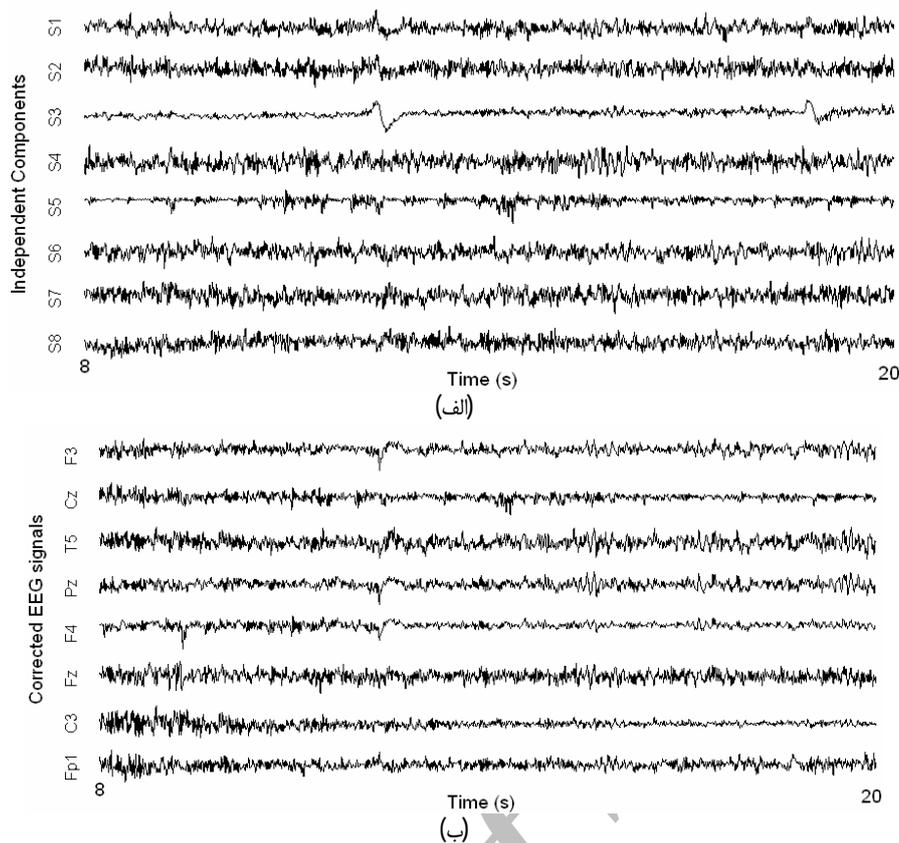
مراجع

- [1] T. P. Jung, et al., "Removing electroencephalographic artifacts by blind source separation," *Psychophysiology*, vol. 37, pp. 163-178, 2000.
- [2] J. C. Woestenburg, M. N. Verbaten, and J. L. Slangen, "The removal of the eye-movement artifact from the EEG by regression analysis in the frequency domain," *Biol. Psych.*, vol. 16, pp. 127-147, no. 1-2, Feb/Mar. 1993.
- [3] P. He, G. Wilson, and C. Russel, "Removal of ocular artifacts from electro-encephalogram by adaptive filtering," *Med. & Biol. Eng. & Comput.*, vol. 42, no. 3, pp. 407-412, 2004.
- [4] P. K. Sadasivan and D. N. Dutt, "Development of newton-type adaptive algorithm for minimization of EOG artifacts from noisy EEG signals," *Signal Processing*, vol. 62, no. 2, pp. 173-186, Nov. 1997.
- [5] A. Erfanian and B. Mahmoudi, "Real-time ocular artifact suppression using recurrent neural network for electro-encephalogram based brain-computer interface," *Med. Biol. Comput.*, vol. 43, no. 2, pp. 296-305, 2005.

ارزیابی قرار گرفته‌اند. در تمام موارد، PCA غیر خطی قابل انعطاف و EASI نتیجه مطلوب مشابهی داشته‌اند، اما PCA غیر خطی با تابع y^3 گاه قادر به حذف آرتیفکت نبوده است. نتایج به‌دست آمده نشان می‌دهد که کارایی الگوریتم‌های برخط پیشنهادی با استفاده از شیوه سفیدسازی مناسب در حذف آرتیفکت چشمی از سیگنال‌های مغزی در حد شیوه‌های برون خط مانند FastICA است.

7- نتیجه‌گیری

حذف بی‌درنگ آرتیفکت چشمی در تحلیل بر-خط سیگنال‌های مغزی نقش اساسی دارد. هرچند اخیراً تحلیل مؤلفه‌های مستقل در حذف آرتیفکت از سیگنال‌های مغزی موفقیت فراوانی داشته است؛ اما کاربرد آن در حذف بی‌درنگ آرتیفکت مورد توجه چندانی قرار نگرفته است. در این مقاله از تحلیل بر-خط مؤلفه‌های مستقل مبتنی بر شبکه عصبی برای حذف آرتیفکت پلک‌زدن در حالت بی‌درنگ استفاده شده است. این شبکه‌ها دو ساختار متفاوت دارند که عده‌ای را می‌توان تعمیمی از روش مشهور تحلیل مؤلفه‌های اساسی، با وارد کردن توابع غیر خطی در آموزش وزن‌های شبکه (PCA غیر خطی و دوگرادیانه) دانست. در گروه دیگر کمینه‌کردن یک تابع ارزشی به‌نحوی که بتوان الگوریتم حاصل را بر روی شبکه عصبی پیاده کرد (EASI) مد نظر است. هر دو مورد در استفاده از یک تابع غیر خطی در شبکه عصبی با هم اشتراک دارند. انتخاب درست این تابع بیشترین نقش را در جداسازی منابع مستقل از هم دارد. توابع متفاوت برای منابعی با ویژگی‌های آماری مختلف (کرتوزیس) در بهبود نتایج تأثیر به‌سزایی دارد. گرچه ممکن است گاهی استفاده از



شکل 13: حذف بر-خط آرتیفکت پلک زدن از داده‌های EEG ثبت شده از کانال‌های F3, F4, Fz, Cz, T5, Fp1 و (الف) مولفه‌های مستقل سیگنال EEG به دست آمده به روش EASI (ب) داده‌های اصلاح شده با حذف مولفه سوم.

- [19] S. C-Alvarez, A. Cichocki, and L. C-Ribas, "An iterative inversion approach to blind source separation," *IEEE Trans. on Neural Networks*, vol. 11, no. 6, pp. 1423-1437, Nov. 2000.
- [20] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, New York, Wiley, 2001.
- [21] C. Jutten and J. Herault, "Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic architecture," *Signal Processing*, vol. 24, no. 1, pp. 1-10, Jul. 1991.
- [6] A. Delorme, T.J. Sejnowski, and S. Makeig, "Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis," *NeuroImage*, vol. 34, no. 4, pp. 1443-49, 15 Feb. 2007.
- [7] T.-P. Jung, et al., "Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects," *Clin. Neurophysiol.*, vol. 111, no. 10, pp. 1745-1758, 2000.
- [8] A. Hyvärinen and E. Oja, "Independent component analysis: algorithms and applications," *Neural Networks*, vol. 13, no. 4-5, pp. 411-430, 2000.
- [9] S. Cruces, L. Castedo, and A. Cichocki, "Robust blind source separation algorithms using cumulants," *Neurocomputing*, vol. 49, pp. 87-118, no. 1-4, Dec. 2002.
- [10] A. J. Bell and T. J. Sejnowski, "An information maximization approach to blind separation and blind deconvolution," *Neural Computation*, vol. 7, no. 6, pp. 1004-1034, Nov. 1995.
- [11] T. -W. Lee, M. Girolami, and T. J. Sejnowski, "Independent component analysis using an Extended Infomax algorithm for mixed subgaussian and supergaussian sources," *Neural Computation*, vol. 11, no. 2, pp. 417-441, 15 Feb. 1999.
- [12] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Analysis*, Wiley, 2001.
- [13] J. Karhunen, E. Oja, L. Wang, R. Vigário, and J. Joutsensalo; "A class of neural networks for independent component analysis," *IEEE Trans. on Neural Networks*, vol. 8, no. 3, pp. 486-504, May 1997.
- [14] A. Cichocki, R. Unbehauen, "Robust neural networks with on-line learning for blind identification and blind separation of sources," *IEEE Trans. on Circuits and Systems-I: Fundamental Theory and Applications*, vol. 43, no. 11, pp. 894-906, Nov. 2000.
- [15] J. -F. Cardoso and B. H. Laheld, "Equivariant adaptive source separation," *IEEE Trans. on Signal Processing*, vol. 44, no. 12, pp. 3017-3030, Dec. 1996.
- [16] S. Choi, A. Cichocki, and S. Amari, "Flexible independent component analysis," *J. of VLSI Signal Processing*, vol. 26, pp. 25-38, 2000.
- [17] S. C. Douglas and A. Cichocki, "Neural networks for blind decorrelation of signals," *IEEE Trans. on Signal Processing*, vol. 45, no. 11, pp. 2829-2842, Nov. 1997.
- [18] J. Karhunen and J. Joutsensalo, "Representation and separation of signals using nonlinear PCA type learning," *Neural Networks*, vol. 7, no. 1, pp. 113-127, 1994.

فرزانه شایق بروجنی مدرک کارشناسی خود را در سال 1381 در رشته مهندسی برق-الکترونیک از دانشگاه شهید بهشتی و سپس در سال 1384 مدرک کارشناسی ارشد خود را از دانشگاه علم و صنعت در رشته مهندسی پزشکی-بیوالکترونیک گرفته است. نام برده هم‌اکنون در حال گذراندن دوره دکتری خود در زمینه پردازش سیگنال EEG در دانشگاه صنعتی اصفهان می‌باشد.

عباس عرفانیان امیدوار مدرک لیسانس خود را در سال 1364 در رشته مهندسی کامپیوتر از دانشگاه شیراز، مدرک فوق لیسانس را در سال 1368 در مهندسی برق و الکترونیک از دانشگاه صنعتی شریف تهران و مدرک دکتری تخصصی خود را در مهندسی پزشکی در سال 1374 از دانشگاه تربیت مدرس تهران، ایران اخذ کرده است. نام برده از سال 1365 الی 1368 به عنوان مهندسی الکترونیک در مرکز تحقیقات مخابرات ایران مشغول بکار بوده و در زمینه طراحی و ساخت آزمایشگاه‌های میان‌مداری فعالیت داشته است. از سال 1368 الی 1370 بعنوان مربی آموزشی در دانشکده کامپیوتر دانشگاه علم و صنعت ایران مشغول بکار بوده است. ایشان از سال 1374، عضو هیات علمی گروه مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران بوده و هم‌اکنون دانشیار مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران است. زمینه‌های تحقیقاتی دکتر عرفانیان شبکه‌های عصبی، پردازش سیگنال‌های بیولوژیک، سیستم‌های واسط مغز با کامپیوتر، مهندسی عصبی، سیستم‌های کنترل عصبی-عضلانی، نظریه آشوب و فرکتال و کاربرد آن در حل مسائل پزشکی می‌باشد. یکی از مهمترین موضوعات تحقیقاتی دکتر عرفانیان، کاربرد فناوری عصبی در رفع مشکلات حرکتی افراد دچار ضایعه نخاعی و مغزی است. وی تحقیقات خود را در این زمینه از سال 1368 در ایران شروع کرده و در سال 1992، به عنوان محقق میهمان در دانشگاه کیس وسترن، کیولند، آمریکا و مرکز پزشکی VA کیولند، تحقیقاتی در زمینه فناوری عصبی و کاربرد آن در رفع مشکلات حرکتی افراد دچار ضایعه نخاعی انجام داده است.