

پیش بینی حمله صرع با استفاده از فیلتر کالمن توسعه یافته در فضای حالت

مصطفی قنادرضایی، حمید سلطانیان زاده و رضا آقایی زاده ظروفی

آزمایشگاه پردازش سیگنال و تصویر، گروه مهندسی برق و کامپیوتر

دانشگاه تهران

چکیده

در این مقاله به کاربرد فیلتر کالمن توسعه یافته برای حل مساله پیش بینی بلند مدت حمله صرع می پردازیم. هدف اصلی بررسی امکان مدل سازی این سیستم غیر خطی نسبتا پیچیده برای یافتن زمان حملات بعدی است. انتظار داریم با استفاده از فیلتر کالمن به مدل هایی با همگرایی خوب و سرعت بالا برسیم. خصوصا در مورد سیستم های بلادرنگ استفاده از برتری های کالمن فیلتر توسعه یافته مد نظر است.

واژه های کلیدی: فیلتر کالمن-حملات صرع-پیش بینی بلند مدت-EM-EEG

مقدمه

فیلتر کالمن به عنوان یکی از ابزار های کلاسیک در پردازش سیگنال، خصوصا برای پردازش وقتی به شمار می رود. مدل توسعه یافته فیلتر کالمن به عنوان ابزاری برای مدل سازی و پیش بینی سیستم های غیر خطی به کار می رود. این مدل بر روی مدل خطی شده سیستم در نقطه کار توسعه یافته است.

در دهه اخیر علاقه زیادی به شکل توسعه یافته فیلتر کالمن خصوصا برای آموزش شبکه های عصبی به خصوص برای مدل های عصبی پیچیده چون مدل ها با فیدبک نشان داده شده است. محبوبیت فیلتر کالمن به خاطر سرعت همگرایی بالا، کنترل بالا روی عناصر همگرایی و قابلیت پیاده سازی RealTime است. البته بایستی مدنظر داشت که حجم بالای محاسبات در یک مرحله می تواند کاربرد فیلتر کالمن را محدود کند. امروزه حملات عصبی و خصوصا صرع به عنوان پنجره های به سوی شناخت ساختار مغز به حساب می آید و از این رو به عنوان شاخه با پیشرفت روز افزون به حساب می آید. حملات

عصبی به عنوان دومین عامل بیمای های اعصاب پس از سکتة های مغزی، بیش از ۱٪ از کل مردم جهان را گرفتار خود ساخته است. نیز تخمین زده می شود که سالانه ۲۴ تا ۵۳ مورد در هر ۱۰۰۰۰۰ نفر به این آمار اضافه گردد. وجود حملات عصبی در هر سنی و تعدد بسیار علل به وجود آمدن بیماری باعث تمرکز طرح های تحقیقاتی عظیمی در این شاخه گشته است.

به دلیل پیچیدگی تحلیل در حملات عصبی، عدم دسترسی مستقیم به محل صدمه و ساختار آشوبناک حملات، تصمیم گیری روی یک اطلاع خاص برای پیش بینی حمله و انتخاب نوع و زمان درمان دقت تصمیم گیری را به شدت کاهش می دهد. از طرفی تصمیم گیری برای نوع درمان در چند سال آینده نیاز به داشتن اطلاعات جامعی از وضعیت کنونی بیمار و پیش بینی وضعیت آینده بیمار دارد. آمار ها نشان می دهند که ضریب خطا در تصمیم گیری و پیش بینی وضعیت بیمار نسبتا بالا است [۴].

گذری بر کالمن فیلتر توسعه یافته

$$\begin{cases} \hat{x}_0 = E[x_0] \\ P_0 = \text{var}[x_0] \end{cases} \quad (4)$$

اثر این شرایط اولیه بعد از مدتی محو می شود. در اینجا P خطای تخمین به حساب می آید. در مرحله بعد بهترین تخمین پیشین از حالت سیستم تا زمان حال زده می شود:

$$\hat{x}_k^- = F_{k,k-1} \hat{x}_{k-1}^- \quad (5)$$

این تخمین دارای خطایی است که بایستی با اطلاعات جدید جبران شود. برای یافتن این خطا روند متعامد سازی بردار حالت بر مشاهدات صورت می گیرد:

$$\hat{x}_k = \hat{x}_k^- + G_k (y_k - H_k \hat{x}_k^-) \quad (6)$$

جهت بردار متعامد شده به سادگی به دست می آید. آنچه در این مرحله باقی می ماند و هنر فیلتر کالمن در آن نهفته است، تخمین اندازه بردار G متعامد کننده است. این ضریب به نام ضریب کالمن معروف است. برای بدست آوردن ضریب کالمن ابتدا بایستی خطای تخمین پیشین سیستم به صورت

$$P_k^- = F_{k,k-1} P_{k-1}^- F_{k,k-1}^T + Q_{k-1} \quad (7)$$

بدست آید. سپس ضریب کالمن به صورت

$$G_k = P_k^- H_k^T [H_k P_k^- H_k^T + R_k]^{-1} \quad (8)$$

محاسبه می گردد. خطای کلی تخمین در این مرحله به صورت ضریبی از احتمال خطای پیشین به صورت زیر بدست می آید:

$$P_k = (I - G_k H_k) P_k^- \quad (9)$$

همان طور که از فرمول بندی فیلتر کالمن مشخص است، این ساختار برای سیستم های متغیر با زمان و خطی به کار می رود. با توجه به گوسی بودن سیگنالهای نویز در سیستم و فرض تواما گوسی بودن دو سیگنال، توزیع حالت سیستم در هر لحظه به صورت گوسی با میانگین حالت کنونی و ماتریس کواریانس خطای سیستم است. این حالت یک شرط پایه روی گسترش های مختلف فیلتر کالمن برای تضمین گوسی ماند حالت سیستم در هر مرحله ایجاد می کند.

فیلتر کالمن در حالت استاندارد برای سیستم های خطی به کار می رود. در حالت غیر خطی حالت سیستم به صورت

فیلتر کالمن در حالت کلاسیک، ابزاری برای تخمین حالت یک سیستم خطی به صورت بازگشتی است.

معادله یک سیستم خطی را می توان به صورت دو معادله پردازش و اندازه گیری به صورت

$$\begin{cases} x_{k+1} = F_{k,k+1} x_k + w_k \\ y_k = H_k x_k + v_k \end{cases} \quad (1)$$

بدست آورد که در آن x حالت سیستم، w ورودی سیستم، v نویز اندازه گیری و y خروجی سیستم را نشان می دهد. همچنین ماتریس های F و H رفتار سیستم را مدل می کنند. در این حالت اندیس k در تمام معادلات نشان دهنده مرحله ای است که متغیر در آن استفاده شده است.

در حالت کلاسیک فرض های

$$w \propto N(0, Q) \quad (2)$$

و

$$v \propto N(0, R) \quad (3)$$

نیز در نظر گرفته می شود. جامعیت فرمول بندی فیلتر کالمن سیستم های ایستا و نایستا و سیستم های متغیر با زمان را به صورت یکسان پوشش می دهد. مساله کالمن به صورت زیر طرح می شود:

حالت سیستم در لحظه اول تا k-1 را با معلوم بودن خروجی های y تا لحظه k بدست آورید به طوری که میانگین مربعات خطای حالت سیستم به حداقل مقدار برسد.

این مساله به فرمول بندی کالمن به صورت زیر ختم می شود:

در لحظه اول با توجه به تابع توضیح حالت سیستم می توان متغیر های موجود در فیلتر کالمن را به صورت زیر به صورت پیش فرض گرفت. در صورت عدم دقت این شرایط اولیه، باز هم فیلتر کالمن می تواند به همگری، البته در زمان طولانی تر، برسد:

فیلتر کالمن برای شناسایی سیستم در فضای

حالت

یک مثال غیر مستقیم از شناسایی سیستم با استفاده از فیلتر کالمن، به کاربردن فرمول بندی فیلتر کالمن برای آموزش شبکه های عصبی پیچیده است [۸]. هرچند راه حل مساله آموزش شبکه های عصبی نسبتا ساده همانند شبکه های Forward Feed به وسیله روش های پس انتشار خطا به صورت نسبتا ساده ای بدست می آید، شبکه های پیچیده تر مانند شبکه های با حلقه بازگشتی، دارای روشی موثر برای آموزش نیستند. توسعه فیلتر کالمن این امکان را فراهم می کند تا با استفاده از مدل شبکه امکان آموزش online فراهم آید. البته حجم بالای محاسبات، غیر قابل گسترش بودن روش به حالت پیچیده تر، مساله پایداری در این مدل ها و نیاز به مشتق پذیری توابع کاربرد فیلتر کالمن را به حالاتی خاص کاهش می دهد [۷].

برای معرفی روش شناسایی سیستم بر اساس فیلتر کالمن به صورت مستقیم، ابتدا مورری بر روش حداکثر سازی امید EM خواهیم داشت. فرض کنیم رفتار سیستمی به صورت $G(x; \theta)$ مد نظر باشد. در این جا θ پارامترهای سیستم و x حالت سیستم است. معمولا از آنجا که θ به ساختار سیستم وابسته است، در مدت نسبتا طولانی ثابت می ماند. در حالی که x اصولا به عنوان حالت سیستم به دینامیک سیستم و ورودی آن وابسته است. روش EM شامل یک روش تکراری و دو مرحله ای است. در مرحله اول با استفاده از حالت سیستم، که در مراحل قبل بدست آمده است، دینامیک سیستم پیش بینی می شود. در مرحله دوم حالت سیستم در دینامیک جدید بدست می آید. در هنگامی که شناسایی سیستم همگرا شد، می توان تعداد عملیات شناسایی دینامیک سیستم را کاهش داد. می توان این الگوریتم را به صورت زیر فرمول بندی کرد:

$$\begin{cases} E - step: x_{k+1} \leftarrow \arg \max_x G(x, \theta_k) \\ M - step: \theta_{k+1} \leftarrow \arg \max_{\theta} G(x_{k+1}, \theta) \end{cases} \quad (13)$$

در گذشته، استفاده از الگوریتم EM برای شناسایی و آموزش سیستم های با دینامیک خطی مانند سیستم های فضای حالت با ماتریس مشاهده به کار رفته است. در اینجا

$$\begin{cases} x_{k+1} = f(k, x_k) + w_k \\ y_k = h(k, x_k) + v_k \end{cases} \quad (10)$$

بدست می آید که در حات کلی f و g توابعی غیر خطی هستند [۵،۳]. برای سیستم غیر خطی و در حالت کلی نویز غیر گوسی، تخمین حالت سیستم بسیار مشکل تر است. تقابل میان توابع حالت می تواند به عدم امکان پیش بینی سیستم شود. روش های متعددی برای مقابله با این مشکل پیشنهاد شده است. فرض کنیم توابع f و g مشتق پذیر و نویز سیستم گوسی باشد. یک راه حل در این مورد استفاده از تقریب خطی محلی حالت سیستم حول حالت کنونی است. با این فرض حالت جدید سیستم باز هم توزیع گوسی داشته و فرض های فیلتر کالمن برقرار است. این الگوریتم به نام توسعه فیلتر کالمن شناخته شده است. در این حالت ماتریس های F و H به صورت :

$$\begin{cases} F_{k+1,k} = \left. \frac{\partial f(k, x)}{\partial x} \right|_{x=x_k} \\ H_k = \left. \frac{\partial h(k, x)}{\partial x} \right|_{x=x_k^-} \end{cases} \quad (11)$$

از ژاکوبین توابع f و h بدست می آیند. نکته قابل توجه در اینجا، استفاده از تخمین پیشین حالت سیستم برای ماتریس H و استفاده از تخمین حالت کنونی برای ماتریس F است. لذا مدل سیستم به صورت زیر بدست می آید:

$$\begin{cases} x_{k+1} \approx f(k, \hat{x}_k) + F_{k,k+1}(x_k - \hat{x}_k) + w_k \\ y_k \approx h(k, \hat{x}_k) + H_k(x_k - \hat{x}_k) + v_k \end{cases} \quad (12)$$


توسعه فیلتر کالمن به عنوان روشی کلاسیک برای تخمین حالت سیستم های غیر خطی و آموزش online برای شبکه های عصبی به حساب می آید. از دیگر روش های تقریب حالت که می توان در حالت کلی تر به کاربرد می توان به روش های filtering particle اشاره کرد. این روش ها بر اساس نمونه برداری نصادفی از فضای حالت با استفاده از توابع f و g استوار است. در این روش سعی می توان با تغییر وزن های ساختار به حداکثر احتمال شرطی خروجی مشاهده شده بر اساس حالت سیستم رسید.

تخمین هم زمان توابع f و g را فراهم می سازد. در این حالت پیچیدگی های مربوط به تخمین هر دو تابع از بین می رود. شبکه RBF مورد بحث تلاش می کند تا ورودی های u و حالت سیستم x را به خروجی مورد نظر y تصویر کند. در این حالت بردار خروجی بر اساس ترکیب خطی حالت و ورودی سیستم و یک نویز ورودی و تخمین ورودی بر اساس توابع گوسی که به وسیله شبکه RBF بدست آمده است زده می شود. در این حالت هر نود در شبکه RBF نماینده یک تابع p و ترکیب خطی آنها به وسیله h صورت می گیرد.

$$y = \sum_{i=1}^l h_i p_i(x) + Ax + Bu + b + w \quad (14)$$

$$p_i(x) = \frac{1}{2\pi S_i} \exp\left[-\frac{1}{2}(x - c_i)^T S_i^{-1}(x - c_i)\right]$$

شکل زیر نمایه کاملی از سیستم شناسایی بر اساس کالمن فیلتر و شبکه RBF را نشان می دهد.



شکل ۱- شناسایی سیستم به استفاده از فیلتر کالمن

آنچه در این مباحث می ماند، روش آموزش شبکه RBF و تعیین حالت اولیه سیستم برای سیستم است. تعیین ساختار اولیه برای شبکه RBF و نقطه شروع کار نقش عمده ای در همگرایی به نقطه مورد نظر دارد.

مدل حملات عصبی به عنوان یک سیستم غیر خطی و آشوب ناک

مساله اصلی در سیگنال های EEG در حملات عصبی، شناسایی و پیش بینی زمان شروع حمله، زمان اوج حملات


یک روش استفاده از ترکیب الگوریتم EM، فیلتر کالمن و شبکه عصبی RBF برای شناسایی سیستم غیر خطی معرفی می شود [۶]. به صورت کلی روش EM سه مزیت عمده بر روش های مشابه دارد. اولاً این روش راه حلی اساسی برای جبران داده های از دست رفته در رودی یا خرجی سیستم دارد. ثانیاً EM قابل تعمیم به حالت های بسیار پیچیده تر هم می باشد. این روش قابلیت کشف متغیر های پنهان و غیر قابل مشاهده سیستم را هم دارد. به طور مثال می توان فرمول بندی EM را به صورت ترکیبی از چندین سیستم غیر خطی هم انجام داد. از طرف دیگر با وجود آنکه اثبات پایداری در سیستم های غیر خطی عموماً مشکل است، EM با تلاش برای حداکثر کردن معیار شباهت، که در آنجا همانند تابع لیاپانف سیستم عمل می کند، سیستمی پایدار به وجود می آورد. این مزایا بر روش های کلاسیک قدرت EM را برای کاربرد های شناسایی و آموزش خصوصاً در سیستم های غیر خطی نشان می دهد. در ادامه این قسمت به بررسی روش EM با استفاده از توسعه فیلتر کالمن می پردازیم.

همانند فرمول فرض می کنیم یک سیستم غیر خطی در فضای حالت تعریف شده باشد. در حالت کلی روش های بر اساس گسترش فیلتر کالمن، یک سیستم غیر خطی و تا حدودی ایستا را به سیستمی غیر ایستا ولی خطی مدل می کنند. در این حالت ماتریسی های متغیر با زمان در توسعه فیلتر کالمن به صورتی که در فصل دوم اشاره شد بدست می آیند. این تخمین در مرحله اول، حالت سیستم را بر اساس مدل پیش فرض بدست می دهد که مرحله E الگوریتم را می سازد.

در مرحله دوم پارامتر های مدل بر اساس خروجی و حالت سیستم بدست می آید. در این حالت مدل مجدداً تخمین زده می شود. برای مدل پارامتر های تابع f ، g و مدل های نویز وجود دارند. برای بدست آوردن پارامتر های توابع راه های مختلفی وجود دارد. به عنوان مثال یک روش ساده ولی غیر بهینه پیدا کردن توزیع های گوسی در داده ها و برازش تابع f روی آنهاست [۱].

روش بهتری که برای مرحله M می توان پیشنهاد داد استفاده از یک شبکه RBF با توابع پایه گوسی برای تخمین تابع هدف است. استفاده از شبکه RBF امکان

در شکل ۳ مشاهده کرد. در اینجا m_1 تا mk فرکانسهای پایه ای هستند که در [۹، ۱۰] به آنها اشاره شده است. این مدل تنها در حالت عادی معتبر است. با ورود به ناحیه حمله، خطای مدل نسبت به سیگنال اصلی به شدت افزایش می یابد. در نتیجه افزایش ناگهانی خطا را می توان به عنوان معیاری برای شناسایی حمله بکار برد.




شکل ۳- مدل عصبی برای سیگنال EEG

در یک حمله زمان هایی به عنوان پیک حمله شناسایی می شوند. زمان و تعداد این حملات به عنوان معیاری برای تشخیص علت بیماری و نوع درمان به کار می رود. شکل ۴ یک حمله همراه با سه اوج حمله را نشان می دهد. این نمونه از پایگاه داده [Dataset # 1 : ۱۴] تهیه شده است. فرایند شناسایی پیک حملات نیز به وسیله الگوریتم پیاده شده در [۱۴] صورت می گیرد. کل سیگنال به مدت ۶۰ دقیقه وجود دارد (شکل ۱۲) و برای آموزش هر شبکه از قطعات ۹ ثانیه ای از سیگنال به عنوان یک ست استفاده شده است. شکل ۴ به عنوان یک مدل شاهد برای کل سیگنال و آموزش آن به حساب می آید. همچنین این پایگاه داده شامل یک سری زمانی برای توصیف تکرار حملات در طول شبانه روز برای بیماری مشابه است (شکل ۱۴).

در تمام نمودارها محور افقی شماره نمونه برداری شده و محور عمودی میزان ولتاژ دریافتی برای EEG بر حسب μV است. در غیر این صورت روی نمودار پارامترها تصریح شده است. برای مدل سازی یک سیگنال EEG در اکثر موارد فرض بر عدو موجود حالات غیر طبیعی در سیگنال است. به طور مثال هنگامی که مدل ARMAX پیشنهادی برای EEG روی نمونه ای که دارای یک حمله است (شکل ۴) پیاده می شود، نتایج بدست آمده کاملاً غیر

و تعداد تکرار حملات در مدت زمان طولانی است. این پارامترها هم برای کنترل حمله و هم برای تصمیم گیری روی نوع درمان حیاتی هستند. در این بررسی به سیگنال یک کاناله EEG که ناشی از دو الکتروود اول از یک سیستم چیدمان الکتروودی ۱۰-۲۰ است می پردازیم. انتظار می رود استفاده از چندین سیگنال EEG روند مدل سازی و تخمین را بهبود ببخشد. لیکن در این جا تنها به بررسی یک سیگنال تک کاناله می پردازیم. این سیگنال در 200 Hz فیلتر می شود با ۳ برابر نرخ نایکویست نمونه برداری شده است.

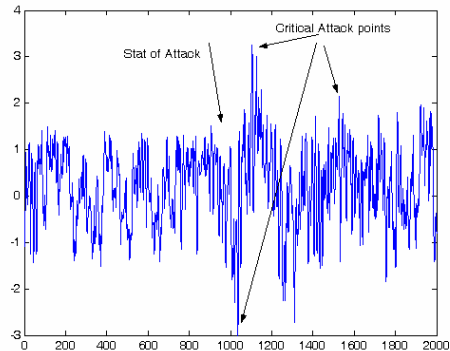


شکل ۲-پروسه یادگیری سیستم در EM

در این فصل به بررسی انواع روش های هوشمند و کلاسیک برای شناسایی و پیش بینی در چنین سیستمی می پردازیم. شکل ۴ سیگنال زمانی EEG همراه با یک حمله را نشان می دهد. برای شناسایی زمان حمله و پیک حملات روش های متعددی پیشنهاد شده است. از جمله روش هایی که برای شناسایی حمله در یک سیگنال EEG معرفی شده است، می توان به روش های متکی بر مدل سازی سیگنال در حالت عادی اشاره کرد. مدل های متعددی از جمله مدل های خطی دینامیک و مدل های غیر خطی و مدل های شبکه عصبی برای مدل سازی است. نمونه ای از این مدل ها را می توان

$$\sin(2\pi m_1 n)$$

قابل قبول هستند و حتی وجود حمله در این مدل قابل تشخیص نمی باشد (شکل ۵).



شکل ۴- مثالی از شروع یک حمله عصبی

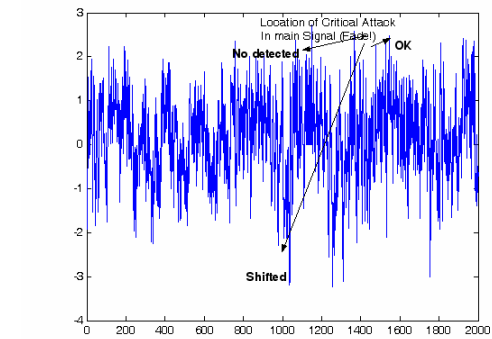

با توجه به این نکته می توان دید که اصولاً مدل های خطی معمول در مورد سیگنال های EEG در مورد سیگنال های غیر طبیعی قابل استفاده نمی باشد. همان طور که اشاره شد، مدل های شبکه عصبی برای حالت نرمال EEG بر اساس ترکیب سیگنال های سینوسی خاصی تعریف شده است [۱۲، ۱۱]. شکل ۶ کاربرد این روش را برای مدل سازی سیگنال شکل ۴ نشان می دهد. دید می شود که مدل ارایه شده در ناحیه نرمال دارای قابلیت پیش بینی پیک ها و نیز شروع حمله را ندارد. با توجه به ساختار فیزیولوژی شروع حمله صرع به نظر می رسد ساختار های پیچیده تر عصبی توانایی بهتری در مدل سازی سیگنال در زمان حمله را دارند. شکل ۷ دو نمونه خروجی سیستم های شبکه عصبی با فیدبک را که برای مساله مورد نظر نشان می دهند [۱۳]. هر دو مساله مانند شبکه قبلی دو لایه می باشند. در حالت اول خروجی های هر دو لایه به عنوان ورودی لایه قبل و در حالت دوم تنها خروجی لایه آخر به عنوان ورودی لایه قبل به کار رفته است [۹]. برای حفظ پایداری در هنگام آموزش از روش کالمن با گام های کوتاه آموزش استفاده شده است. هر چند دومین مدل در حالت حمله نسبتاً خوب کار می کند، سیگنال نرمال را نمی تواند تعقیب کند، لذا امکان بدست آوردن زمان حمله را نمی دهد. نیز هنگامی که مدل برای پیش بینی خروجی تنها با ۱۰ نمونه اختلاف صورت می گیرد، تخمین خصوصاً در ناحیه نرمال به صورت شیفت یافته خروجی ظاهر می شود که نشانه عدم یافتن اطلاعات

سیگنال و تخمین همانند نویز سفید است (شکل ۸). یک مدل هوشمندانه تر از شبکه شامل دو بلوک موازی برای تخمین ناحیه نرمال به وسیله یک بلوک خطی و تخمین ناحیه حمله به وسیله یک بلوک عصبی بازگشتی است. کل سیستم به وسیله یک روش کالمن توسعه یافته آموزش می یابد. شکل ۹ نتایج شبیه سازی برای این مدل را نشان می دهد. دیده می شود که این مدل نیز دارای مشکل شناسایی زمان حمله و تشخیص صحیح پیک های حمله است.

استفاده از ترکیب فیلتر کالمن و شبکه عصبی مصنوعی برای پیش بینی حملات عصبی

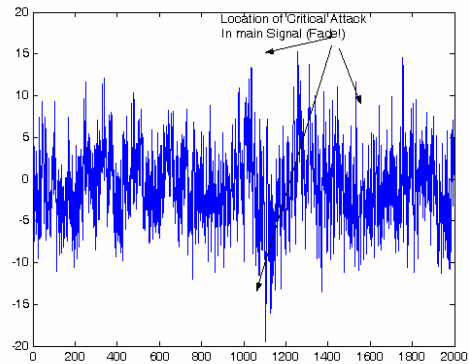
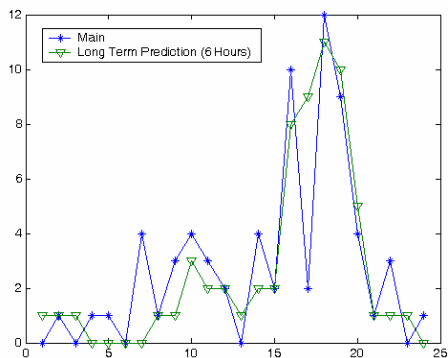
همان طور که در شبیه سازی های قبلی نشان داده شد، روش های معمول در تخمین سیگنال EEG توانایی مدل سازی و پیش بینی عواملی مهمی که در بیماری های عصبی مانند صرع مهم تلقی می شوند را ندارند. این فصل از ایده فیلتر کالمن و شناسایی سیستم در آن به عنوان انتخابی مناسب تر در مساله فوق استفاده می کند. در اینجا مدل شبکه RBF به صورت ثابت و شامل یک لایه گوسی با ۲۴ نورون که با سعی و خطا در مرحله اول نمودار شکل دو به دست آمده است می باشد. شکل ۱۰ و ۱۱ نشان دهنده مدل سیستم بر اساس تعداد حالات ۵ و ۱۰ برای فیلتر کالمن است. دید شده است که با بیش از این تعداد حالات سیستم قابلیت پیش بینی را از دست می دهد. نهایتاً مدل برای تست بلند مدت سیگنال یکار رفته است. شکل ۱۳ نشان می دهد که این مدل برای پیش بینی در مدت ۱۵ دقیقه از انتهای نمونه های در دستری بسیار موفق عمل کرده است. همچنین مدل توانسته است در پیش بینی با ۶ ساعت تاخیر در طول شبانه روز حداکثر حملات در طول شبانه روز را به خوبی پیش بینی کند که هم از نظر تعداد حملات و هم از نظر زمان حملات نتیجه قابل توجهی است (شکل ۹).

شهای جیدی توسعه فیلتر کالمن برای استفاده در شناسایی وجود دارد .




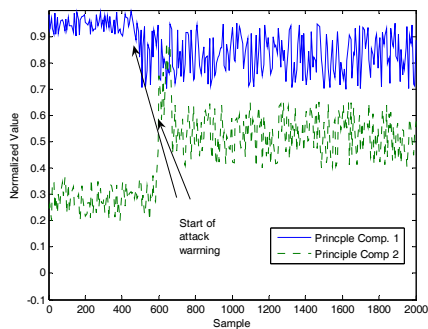
شکل ۵- مدل عصبی با سیستم عصبی و خطی به صورت موازی

شکل ۸- پیش بینی بلند مدت سیگنال برای محل حملات



شکل ۶- مدل فیلتر کالمن اولیه برای شناسایی پیک

شکل ۹- پیش بینی بلند مدت تعداد حملات در ساعت با استفاده از مدل کالمن



شکل ۷- یک ساعت از سیگنال ضبط شده

شکل ۱۰- پیش بینی با استفاده تغییر در مدل کالمن

زمینه های کاری آتی

استفاده از روشهای پیشرفته تر خصوصا برای آموزش شبکه RBF با توجه به ساختار می توانند به عنوان زمینه های کاری آینده در نظر گرفته شود. همچنین جای کار برای رو

فیلتر کالمن در ایستایی سیستم غیر خطی برای مدت نسبتاً طولانی است.

مراجع

- [1] Angelov, P.P.; Filev, D.P.; "Flexible models with evolving structure Intelligent Systems," *Proceedings. 2002 First International IEEE Symposium*, vol. 2, pp. 28 – 33, 2002.
- [2] Dawei Huang; "Efficient estimation for non-linear and non-Gaussian state space models Decision and Control," *Proceedings of the 36th IEEE Conference on*, vol. 5 pp. 5036 – 5041, 1997.
- [3] Ruiz, V.F.; "An efficient approach to highly non-linear estimation," *Digital Signal Processing, 2002. DSP 2002. 2002 14th International Conference on*, vol. 2 pp. 737 – 740, 2002.
- [4] Popivanov, D.; Dushanova, J.; Mineva, A.; Krekule, I.; "Detection of successive changes in dynamics of EEG time series: linear and nonlinear approach," *Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE*, vol. 4, pp. 1590 – 1591, 1996.
- [5] David, A.; Aboulnasr, T.; Adaptive non-linear modeling "Advances in Digital Filtering and Signal Processing," *1998 IEEE Symposium on*, pp. 126-129, 1998.
- [6] Zarrop, M.B.; Wellstead, P.E.; "Two-dimensional and EM techniques for cross directional estimation and control," *Control Theory and Applications, IEE Proceedings-*, vol. 149, Issue: 5, pp. 457 – 462, 2002.
- [7] Sun, P.; Marko, K.; "The square root Kalman filter training of recurrent neural networks" *Systems, Man, and Cybernetics IEEE International Conference on*, vol. 2, pp. 1645 – 1651 vol.2, 1998.
- [8] Rughooputh, H.C.S.; Rughooputh, S.D.D.V.; "Extended Kalman filter learning algorithm for hyper-complex multilayer neural networks," *IJCNN '99*, vol. 3, pp. 1824 – 1828, 1999.
- [9] Mingui Sun; Scabassi, R.J.; "The forward EEG solutions can be computed using artificial neural networks," *Biomedical Engineering, IEEE Transactions on*, vol. 47, Issue: 8, pp. 1044 – 1050, 2000.
- [10] Al-Nashash, H.A.; Zalzal, A.M.S.; Thakor, N.V.; "A neural networks approach to EEG signals modeling," *Engineering in Medicine and Biology Society*, vol. 3, pp. 2451 – 2454, 2003.
- [11] Penny, W.D.; Roberts, S.J.; "EEG-based communication via dynamic neural network models," *IJCNN '99*, vol. 5, pp. 3586 – 3590, 1999.
- [12] Shimada, T.; Shiina, T.; Saito, Y.; "Detection of characteristic waves of sleep EEG by neural network analysis" *Biomedical Engineering, IEEE Transactions on*, vol. 47, Issue: 3 pp. 369 – 379, 2000.
- [13] Bondarenko, V.E.; "Epilepsy as a self-organization process: a computational model," *Neuroinformatics and Neurocomputers*, pp. 108 – 114, 1995.
- [14] Caltech EEG database available on <http://www.vis.caltech.edu/~rodri/data.htm>

خصوصاً این مساله برای سیستم های با حالت محدود و آشوب ناک در حال پیشرفت است.

نکته قابل توجه دیگری که در مورد مدل بدست آمده وجود دارد، استفاده از روش های کالمن بر اساس نویز غیر گوسی است. علاوه بر نویز محیطی در سیگنال EEG نویز های محیطی، نویز های ناشی از منابع ناخواسته مانند ROG و سیگنال CGE و نیز جریان های ناشی از حرکت یون ها روی سیگنال EEG اثر می گذارد. از آنجا که سیستم غیر خطی است، فرض گوسی بودن نویز روی سیگنال تا حدودی اعتبار خود را از دست می دهد و لذا توزیع حالت سیستم از حالت گوسی خارج می شود. از آنجا که فرمول بندی اولیه بر اساس گوسی بودن حالت صورت گرفته است، به نظر می رسد روش های جدید که توزیع غیر گوسی حالت را در حالت غیر گوسی در نظر می گیرند مانند [۲] می توانند به عنوان مدلی مناسب تر مد نظر قرار بگیرند. نهایتاً نتایج این روش قابل استفاده در کاربرد های تشخیصی و کلاسه بندی سیگنال است. از آنجا که روش سعی در بدست آوردن حداقل حالتی را دارد که سیگنال به صورت کامل و خصوصاً در زمان حمله بازسازی کند، حالت بدست آمده در فیلتر کالمن به عنوان عنصر مناسبی برای تشخیص نوع سیگنال است. از آنجا که مدل قابلیت تعقیب سیگنال را در حالات حمله و در دراز مدت دارد، حالت بدست آمده در دراز مدت به عامل جدا کننده ای مطرح است.

جمع بندی

با توجه به آنچه در اینجا ارایه شد، به نظر می رسد مدل شناسایی کالمن خصوصاً در مواردی که سیستم به صورت تئوری دارای حالت پنهان و دینامیک غیر خطی است، بهتر از روش های کلاسیک و حتی روش های معمول هوشمند عمل می کنند. البته می توان دید که هنگامیکه سیستم از حالت ایستا خارج می شود، مدل شناسایی شده نمی تواند به صورت مطلوبی کار کند. در واقع در حالتی که سیستم دارای تغییرات شدیدی است مانند زمان شروع حملات در مساله حملات عصبی، امکان دنبال کردن مدل را از دست می دهد که علت اصلی در فرض های توسعه