

توسعه ماشین یادگیری هیجانی مغز با الهام از ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی مبتنی بر شبکه‌های عصبی

مهدی گلشن^۱، محمد تشنه‌لب^{۲*} و آرش شریفی^۳

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۰/۰۹/۲۱ بازنگری مقاله: ۱۴۰۰/۱۲/۱۹ پذیرش مقاله: ۱۴۰۱/۰۱/۱۵</p>	<p>پیش‌بینی داده‌ها در قالب سری‌های زمانی آشوبی و پیچیده یکی از مهم‌ترین مسائل اساسی در حوزه‌های مختلف علمی و صنعتی است. مدل‌های داده محور همانند شبکه‌های عصبی مصنوعی و عصبی فازی در مقایسه با سایر مدل‌ها به دلیل ویژگی‌های خاص بیشتر مورد توجه قرار گرفته‌اند. به منظور توسعه و بهبود این مدل‌ها از مفاهیم سیستم لیمیک مغز پستانداران استفاده می‌شود. بر این اساس ماشین یادگیری هیجانی معرفی می‌شود. در این مقاله، ماشین یادگیر مفروط ترتیبی آنلاین به عنوان مولفه اصلی در مراکز پردازشی ماشین یادگیری هیجانی مغز استفاده می‌شود. به منظور تعامل بین مراکز پردازشی، ماشین یادگیر مفروط ترتیبی آنلاین به صورت یک شبکه حافظه‌دار بازگشتی با قابلیت انتقال یادگیری طراحی می‌شود. مدل پیشنهادی ماشین یادگیری هیجانی مغز مبتنی بر ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی نامیده می‌شود. به منظور بررسی و مقایسه کارایی مدل پیشنهادی، پارامترهای اولیه مدل‌ها به ازای داده‌های سری‌های زمانی مکی‌گلاس و لورنز در شرایط یکسان تنظیم می‌شوند. مدل‌های مختلف بر اساس معیارهای قابل اندازه‌گیری معتبر در پیش‌بینی مسائل رگرسیون مورد ارزیابی و مقایسه قرار می‌گیرند. نتایج شبیه‌سازی نشان می‌دهد که مدل پیشنهادی با تابع فعال‌ساز سیگموئید تک قطبی و دوقطبی به ترتیب برای داده‌های تست سری زمانی مکی‌گلاس و لورنز دارای بیشترین معیار کارایی نسبت به مدل‌های آنلاین مشابه است. همچنین برای داده‌های آموزش دارای کارایی قابل قبولی نسبت به مدل‌های مشابه می‌باشد.</p>
<p>واژگان کلیدی: ماشین یادگیری هیجانی مغز، ماشین یادگیر مفروط ترتیبی آنلاین، شبکه‌های حافظه‌دار بازگشتی، شبکه‌های عصبی.</p>	

۱- مقدمه

سری‌های زمانی پیچیده آشوب‌گونه یکی از مهم‌ترین مسائل اساسی محسوب می‌شود. مدل‌های پیش‌بینی مبتنی بر داده الهام گرفته شده از مدل‌های زیست‌شناسی همانند شبکه‌های عصبی مصنوعی، سیستم‌های استنتاج عصبی فازی و روش‌های محاسبات تکاملی به دلیل قابلیت‌ها و ویژگی‌های خاص، مورد علاقه بسیاری از محققین در این حوزه قرار گرفته‌اند.

به عنوان مثال در [۱] جهت پیش‌بینی داده‌های کیفیت هوا، بازار بورس استانبول و مجموعه داده‌های SML۲۰۱۰

داده‌ها و اطلاعات بسیاری از جمله داده‌های ترافیکی، شبکه، بازارهای مالی و غیره در قالب سری‌های زمانی توصیف می‌شوند. این مجموعه داده از مشاهدات به صورت پیوسته با زمان تغییر می‌کنند. در برخی از موارد به دلیل زمان‌بر بودن، پرهزینه بودن و نیز همراه بودن با محدودیت‌های کاربردی توسط نیروی انسانی، از مجموعه داده‌های آماده جمع‌آوری شده موجود در پایگاه داده‌های معتبر همانند سایت UCI استفاده می‌شود [۱]. پیش‌بینی

* پست الکترونیک نویسنده مسئول: teshnehlab@eetd.kntu.ac.ir

۱. گروه کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. گروه مهندسی کنترل و سیستم، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۳. گروه کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

مطرح می‌گردد. در مدل‌سازی شناختی از نتایج و تحقیقات محققان رشته‌های مختلف از جمله روان‌شناسی^۳، زبان شناختی^۴، فلسفه^۵، علوم و فیزیولوژی اعصاب^۶ که سوالات و تحقیقات مشابهی در مورد طبیعت ذهن آدمی^۷ دارند، جهت خلق و توسعه روش‌های هوش مصنوعی استفاده می‌شود. شبکه‌های عصبی مصنوعی^۸ نمونه‌ای از دستاوردهای حاصل شده در این زمینه است. این شبکه‌ها بر پایه یک مدل محاسباتی ساده از سلول عصبی مغز ارائه شده و تا شبکه‌های چند لایه به عنوان تخمین‌گرهای عمومی توسعه یافته‌اند [۱۶].

آمیگدلا و اوربیتوفرانثال دو مرکز پردازش اصلی کاملاً مجزا در مدل یادگیری هیجانی مغز هستند که هر کدام روابط و پارامترهای مرتبط با خود را دارند. هر کدام به صورت مجزا بر اساس قوانین و روابط مختلف پیاده‌سازی و بر اساس الگوریتم‌های یادگیری مختلف به صورت مجزا برورسانی می‌شوند. پارامترهای هر بلوک می‌تواند بر اساس خروجی همان بلوک یا خروجی بلوک دیگر و خروجی نهایی برورسانی شود. در صورتیکه پارامترهای هر بلوک وابسته به خروجی نهایی و خروجی بلوک خود باشد، خروجی نهایی از ترکیب وزن‌دار خروجی بلوک‌ها به دست می‌آید. جهت تعامل و اثرگذاری بلوک‌های هیجانی و کنترلی بر یکدیگر، پارامترهای یادگیری هر بلوک علاوه بر خروجی نهایی و خروجی همان بلوک، به خروجی بلوک دیگر نیز وابسته می‌شوند. در بخش‌های اصلی ماشین BEL می‌توان از شبکه‌های عصبی مصنوعی تک لایه و چند لایه، ماشین بردار پشتیبان، شبکه‌های عصبی مبتنی بر توابع پایه‌ای شعاعی^۹ [۴]، شبکه‌های عصبی فازی تطبیقی^{۱۰} [۵]، آتاماتای سلولی^{۱۱} و یا دیگر ابزارهای طبقه‌بندی و پیش‌بینی استفاده کرد. ماشین یادگیر مغروط توسعه‌یافته شبکه‌های عصبی مصنوعی پیش‌رو با یک لایه پنهان است که سرعت یادگیری بسیار بالا و حداقل پارامتر قابل تنظیم و قابل یادگیری دارد. این ماشین یادگیر می‌تواند به عنوان عنصر اصلی و بلوک سازنده در بخش‌های مختلف ماشین یادگیر هیجانی مغز به کار گرفته شود.

بر این اساس ماشین یادگیر هیجانی مغز مبتنی بر ماشین

در قالب سری‌های زمانی از ترکیب مدل‌های پیش‌بینی شبکه عصبی پرسپترون چند لایه و توابع پایه‌ای شعاعی و ماشین بردار پشتیبان با الگوریتم‌های ژنتیک، فاخته و هوش ازدحامی ذرات استفاده می‌شود. در [۲] به منظور تخمین نرخ نفوذ در یک فرآیند حفاری از شبکه‌های عصبی بهینه‌شده با الگوریتم وال و الگوریتم مورچگان استفاده شده است. نتایج حاصل، نشان‌دهنده عملکرد بهتر روش‌های آموزش ماشین نسبت به مدل‌های ریاضی مرسوم بورگوان و یانگ و بینگهام می‌باشد. در [۳] به منظور پیش‌بینی مقادیر آتی سری آشوبی مکی‌گلاس و یک سیستم غیرخطی با داده‌های تصادفی از سیستم فازی عصبی نوع ۲ بازه‌ای با الگوریتم آموزش گرادیان نزولی و فیلتر کالمن به ترتیب برای بخش‌های مقدم و تالی استفاده می‌شود. مدل‌های بیان شده دارای برخی معایب از قبیل بیش‌برازش، پیچیدگی مدل، نفرین ابعاد و پارامتر زیاد یادگیر می‌باشند. بنابراین توسعه و بهبود آن‌ها مورد نیاز است. محققان در جستجوی توسعه معماری و الگوریتم‌های یادگیری مبتنی بر شبکه‌های عصبی مصنوعی هستند [۴، ۵].

بر این اساس، الهام گرفتن از سیستم مغز هیجانی جهت این شبکه‌ها مورد توجه واقع شده است [۶، ۷]. مغز هیجانی که پستانداران از آن بهره‌مند هستند، بخش‌هایی از مغز است که وظیفه آن دریافت، پردازش و ایجاد حالات و پاسخ‌های هیجانی است. مغز هیجانی دارای ویژگی‌های اساسی از قبیل توانایی کشف حالات احساسی از محرک‌های ورودی، بر عهده داشتن وظیفه بروز احساسات، داشتن سرعت بسیار سریع و انجام عمل بدون بررسی و درنگ است [۸].

ویژگی‌های بیان شده، انگیزه اصلی محققان در طراحی مدل محاسباتی یادگیری هیجانی مغز^۱ با الهام گرفتن از مغز هیجانی [۶، ۷] و توسعه آن [۴، ۵، ۹-۱۵] می‌باشد. این ماشین شناختی به خوبی توانسته است ویژگی‌های مغز هیجانی را در کامپیوتر پیاده‌سازی کند و تأثیر بسزایی در کاربردهای مختلف الگوریتم‌های هوش مصنوعی داشته باشد [۶، ۷].

ماشین شناختی BEL در چهارچوب مدل‌سازی شناختی^۲

⁷ Human mind

⁸ Artificial Neural Network (ANN)

⁹ Radial Basis Function (RBF)

¹⁰ Adaptive Network-Based Fuzzy Inference System (ANFIS)

¹¹ Cellular Automaton (CA)

¹ Brain Emotional Learning (BEL)

² The cognitive modeling approach


³ Psychology

⁴ Linguistics

⁵ Philosophy

⁶ Neuroscience

گام ۱: در صورتیکه $j = 1, \dots, L$ انتخاب شود، وزن‌های a_{ij} و بایاس b_j به صورت تصادفی مقداردهی می‌شوند.
 گام ۲: ماتریس خروجی لایه پنهان (H) بر اساس نورون‌های افزایشی^۵ با توابع فعال‌ساز (g) مختلف ارائه شده در شبکه عصبی مصنوعی پرسپترون، توابع پایه شعاعی و یا مشتقات دیگر همانند سیستم‌های فازی عصبی محاسبه می‌شود. نحوه تولید ماتریس خروجی لایه پنهان به ازای تابع فعال‌ساز g در رابطه (۱) نشان داده شده است.
 گام ۳: وزن‌های خروجی β بر اساس تعداد $k = 1, \dots, m$ خروجی مطلوب شبکه عصبی T مطابق با روابط (۲) و (۳) محاسبه می‌شود.



شکل ۱- ساختار ماشین یادگیر مفروط با n ورودی و m خروجی.

در رابطه $H\beta = T$ به ازای N ورودی، L نورون لایه پنهان و m خروجی، اندازه متغیرهای H ، β و T به صورت $[H]_{N \times L} \cdot [\beta]_{L \times m} = [T]_{N \times m}$ بیان می‌شود. ماتریس های β و T به ازای $1, \dots, N$ ورودی، $1, \dots, L$ نورون لایه پنهان و $1, \dots, m$ خروجی، به ترتیب در رابطه (۴) و رابطه (۵) نمایش و خروجی پیش‌بینی بر اساس رابطه (۶) محاسبه می‌شود.

یادگیر مفروط^۱ ارائه می‌شود.

در روش پیشنهادی از ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی^۲ مبتنی بر شبکه‌های عصبی با توابع فعال‌ساز مختلف استفاده می‌شود. ماشین ارائه شده در بلوک‌های اصلی آمیگدلا و اوربیتوفران‌تال ماشین یادگیری هیجانی مغز به کار گرفته می‌شوند. بر این اساس ماشین یادگیری هیجانی مغز مبتنی بر ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی^۳ طراحی می‌شود. مدل پیشنهادی ارائه شده بر اساس ورودی داده‌ها به صورت الگو-الگو و دسته-دسته با انواع مختلف تابع فعال‌ساز مورد تست و آزمایش قرار می‌گیرد. بر اساس استفاده از ماشین یادگیر مفروط در روش پیشنهادی، مدل ارائه شده نیز دارای حداقل پارامتر یادگیر و حداقل تعداد پارامتر قابل تنظیم توسط کاربر است.

۲- پیشینه تحقیق

۲-۱- ماشین یادگیر مفروط

ماشین یادگیر مفروط، یک الگوریتم یادگیری جدید برای شبکه‌های عصبی پیش‌رو تک لایه است که مشکلات شبکه‌های عصبی پیش‌رو مبتنی بر آموزش گرادینان نزولی را بهبود داده است. برخلاف تفکر قدیمی و اکثریت شبیه‌سازی و پیاده‌سازی‌های عملی، نودهای لایه پنهان در آن به صورت تصادفی انتخاب و وزن‌های خروجی بر اساس یک روش تحلیلی تنظیم و انتخاب می‌شوند. این الگوریتم دارای قابلیت تعمیم‌دهی بهتر به ازای سرعت یادگیری سریع است. تعداد پارامترهای قابل تنظیم در آن به شکل قابل توجهی کاهش و تنها نیاز است تعداد نورون‌های لایه پنهان تنظیم شوند. این شبکه‌ها به تعداد تکرار اجرای برنامه^۴ وابسته نیستند. علت نامگذاری این شبکه عصبی مصنوعی به ماشین یادگیر مفروط، حداقل پارامتر مورد نیاز جهت انتخاب توسط برنامه‌نویس و حداقل پارامتر قابل یادگیر است. ساختار این ماشین با n ورودی و m خروجی در شکل (۱) نشان داده شده است.

بر اساس N مجموعه داده، ورودی‌های x_1, \dots, x_n به ازای $i = 1, \dots, n$ ویژگی، تابع فعال‌ساز $g(x)$ و تعداد نودهای لایه پنهان L ، گام‌های الگوریتم به صورت زیر است [۱۷]:

³ Brain Emotional Learning Based on Online Recurrent Memory Sequential ELM (BEL-ORMS-ELM)

⁴ Epoch

⁵ Additive Neuron

¹ Brain Emotional Learning based on Extreme Learning Machine (BEL-ELM)

² Online Recurrent Memory Sequential ELM (ORMS-ELM)

$$H(a_{i1}, \dots, a_{iL}, b_1, \dots, b_L, x_1, \dots, x_n) = \begin{bmatrix} g(a_{i1}, b_1, x_1) & \dots & g(a_{iL}, b_L, x_1) \\ \dots & \dots & \dots \\ g(a_{i1}, b_1, x_n) & \dots & g(a_{iL}, b_L, x_n) \end{bmatrix}_{N \times L} \quad (1)$$

$$\|H(a_{i1}, \dots, a_{iL}, b_1, \dots, b_L) \cdot \beta - T\| = \min_{\beta} \|H(a_{i1}, \dots, a_{iL}, b_1, \dots, b_L) \cdot \beta - T\| \quad (2)$$

$$H\beta = T \Rightarrow \beta^* = H^+ \cdot T \Rightarrow \beta^* = (H^T H)^{-1} \cdot H^T \cdot T \quad (3)$$

$$\beta = \begin{bmatrix} \beta_{1,1}^T & \beta_{1,2}^T & \dots & \beta_{1,m-1}^T & \beta_{1,m}^T \\ \beta_{2,1}^T & \beta_{2,2}^T & \dots & \beta_{2,m-1}^T & \beta_{2,m}^T \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \beta_{L-1,1}^T & \beta_{L-1,2}^T & \dots & \beta_{L-1,m-1}^T & \beta_{L-1,m}^T \\ \beta_{L,1}^T & \beta_{L,2}^T & \dots & \beta_{L,m-1}^T & \beta_{L,m}^T \end{bmatrix}_{L \times m} \quad (4)$$

$$T = \begin{bmatrix} t_{1,1}^T & t_{1,2}^T & \dots & t_{1,m-1}^T & t_{1,m}^T \\ t_{2,1}^T & t_{2,2}^T & \dots & t_{2,m-1}^T & t_{2,m}^T \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ t_{N-1,1}^T & t_{N-1,2}^T & \dots & t_{N-1,m-1}^T & t_{N-1,m}^T \\ t_{N,1}^T & t_{N,2}^T & \dots & t_{N,m-1}^T & t_{N,m}^T \end{bmatrix}_{N \times m} \quad (5)$$

$$O_j^2 = H \beta^* \quad (6)$$

$$P_0 = (H_0^T H_0)^{-1} \quad (8)$$

$$\beta^0 = P_0 \cdot H_0^T \cdot T_0 \quad (9)$$

$$Out_0 = H_0 \times \beta^0 \quad (10)$$

مرحله یادگیری ترتیبی: بروزرسانی وزن لایه خروجی در مرحله $k+1$ بر اساس ماتریس لایه پنهان H_{k+1} ، خروجی مطلوب $T_{k+1} = [t_{(\sum_{j=0}^k N_j)+1}, \dots, t_{(\sum_{j=0}^{k+1} N_j)}]^T$ به ازای ورود داده‌ها به صورت الگو-الگو یا دسته-دسته (بلوک-بلوک) با اندازه مشخص یا متغیر به صورت زیر است:

۲-۲- ماشین یادگیر مفروط ترتیبی آنلاین

قانون یادگیری در ماشین یادگیر مفروط ترتیبی آنلاین (OS-ELM) با توجه به ورود داده‌ها به صورت الگو-الگو یا دسته-دسته و $T_0 = [t_1, t_2, \dots, t_{N0}]^T$ خروجی مطلوب در ۲ مرحله به صورت زیر است [۱۸]:
مرحله مقداردهی اولیه: محاسبه وزن لایه خروجی $[[Out]]_0$ بر اساس ماتریس خروجی لایه پنهان H_0 ، خروجی مطلوب T_0 به‌ازای تعداد $N0$ داده ورودی اولیه به صورت زیر است:

$$H_0 = \begin{bmatrix} g(a_1, b_1, x_1) & \dots & g(a_L, b_L, x_1) \\ \dots & \dots & \dots \\ g(a_1, b_1, x_{N0}) & \dots & g(a_L, b_L, x_{N0}) \end{bmatrix}_{N0 \times L} \quad (7)$$

$$H_{k+1} = \begin{bmatrix} g(a_1, b_1, x_{(\sum_{j=0}^k N_j)+1}) & \dots & g(a_L, b_L, x_{(\sum_{j=0}^k N_j)+1}) \\ \dots & \dots & \dots \\ g(a_1, b_1, x_{(\sum_{j=0}^{k+1} N_j)}) & \dots & g(a_L, b_L, x_{(\sum_{j=0}^{k+1} N_j)}) \end{bmatrix}_{N_{k+1} \times L} \quad (11)$$

$$P_{k+1} = P_k - P_k H_{k+1}^T (I + H_{k+1} P_k H_{k+1}^T)^{-1} \times H_{k+1} P_k \quad (12)$$

¹ Block-Block (B) / Chunk-Chunk

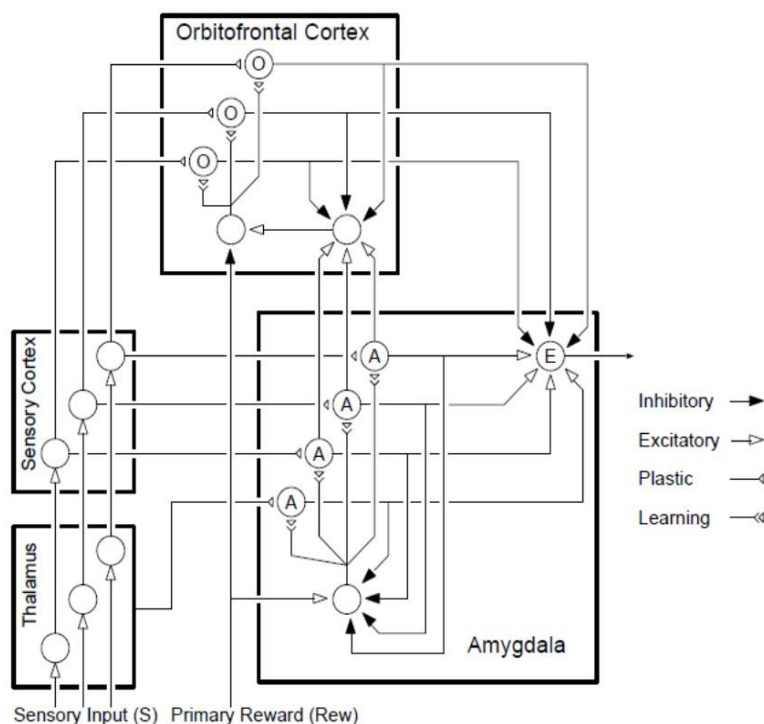
$$\beta^{k+1} = \beta^k + P_{k+1} H_{k+1} (T_{k+1}^T - H_{k+1}^T \cdot \beta^k) \quad (13)$$

$$Out_{k+1} = H_{K+1} \cdot \beta^{K+1} \quad (14)$$

استفاده شده است. در [۲۵] از اجماع آشوبی ماشین یادگیر مفروط بازگشتی آنلاین جهت پیش‌بینی دینامیکی دما استفاده شده است. نشان داده شد که در مسائل پیش‌بینی آنلاین ماشین یادگیر مفروط بازگشتی آنلاین طراحی شده بر اساس ماشین یادگیر مفروط اتوانکدر دارای کارایی بهتری نسبت به شبکه‌های یادگیری عمیق بازگشتی با حافظه طولانی کوتاه‌مدت^۷ آنلاین است. در [۲۶] به منظور غلبه بر چالش‌های الگوریتم آموزش گرادیان نزولی در معماری شبکه‌های یادگیری عمیق کانولوشن^۸ از الگوریتم آموزش مبتنی بر ماشین یادگیر مفروط استفاده می‌شود. آموزش پارامترهای مختلف در ساختار شبکه‌های یادگیری عمیق کانولوشن بر اساس الگوریتم گرادیان نزولی همراه با پس انتشار خطا منجر به همگرایی کند روند آموزش و تنظیم پارامترهای زیاد می‌شود.

۲-۳- مدل‌های بهبود یافته ماشین یادگیر مفروط

ماشین یادگیر مفروط^۱ یک شبکه عصبی پیش‌رو تک لایه^۲ با ساختار و قانون یادگیری ساده و سریع است [۱۷] که مشتقات و مدل‌های توسعه یافته‌ای از آن ارائه شده است. این ماشین در بسیاری از زمینه‌های کاربردی از جمله پیش‌بینی کوتاه مدت قیمت بازار برق مورد استفاده قرار می‌گیرد [۱۹]. برخی از مدل‌های توسعه یافته ELM عبارتند از ماشین یادگیر مفروط آنلاین^۳ [۱۸]، ماشین یادگیر مفروط فازی آنلاین^۴ [۲۰]، شبکه‌های یادگیری عمیق ماشین یادگیر مفروط [۲۱]، ماشین یادگیر مفروط ترتیبی آنلاین نیمه‌نظارت شده و بدون نظارت^۵ [۲۲]، ماشین یادگیر مفروط وزن دار^۶ [۲۳]. در [۲۴] جهت حذف ویژگی‌های نامرتبط از مجموعه فازی و از نوروهای راف مبتنی بر دانش بازه‌ای در لایه ویژگی



شکل ۲- ماشین یادگیری هیجانی مغز ارائه شده توسط مورن [۶، ۷].

⁶ Weighted extreme learning machine for imbalance learning (W-ELM)

⁷ Long Short-Term Memory (LSTM)

⁸ Convolutional neural network (CNN)

¹ Extreme Learning Machine (ELM)

² Single hidden Layer Feed forward Neural network (SLFN)

³ Online Sequential Extreme Learning Machine (OS-ELM)

⁴ Online Sequential Fuzzy ELM (OS-FELM)

⁵ Semi-Supervised and Unsupervised Extreme Learning Machines

۲-۴- ماشین یادگیری هیجانی مغز

ماشین شناختی BEL در چهارچوب مدل سازی شناختی مطرح و تحت عنوان شبکه‌های عصبی مصنوعی هیجانی^۱ شناخته و الگوریتم خاصی جهت تنظیم وزن‌های آن ساختار ارائه می‌گردد. این شبکه‌ها از یافته‌های کالبدشناسی لداکس^۲ الهام گرفته شده است [۸]. نتیجه تحقیقات نشان دهنده مسیرهای مشخص انتشار سیگنال مغز هیجانی است. به دلیل وجود مسیرهای کوتاه‌تر در مغز هیجانی، محرک‌های احساسی سریع‌تر از محرک‌های معمولی پردازش می‌شوند. پردازش‌های سریع در حجم عظیم اطلاعات، محققان را بر آن داشت تا از مغز هیجانی الگوبرداری و مدل‌های الهام گرفته شده را در کاربردهای مختلف مهندسی بکار گیرند. پیاده‌سازی کامپیوتری مدل ماشین یادگیری هیجانی مغز مبتنی بر مفاهیم هیجان و مغز هیجانی در شکل (۲) ارائه شده است [۶، ۷].

در این معماری از دو ماشین یا پردازنده موازی استفاده می‌شود. این دو ماشین در قالب دو عامل در یک سیستم چندعامله، دو پردازنده یا ماکرو نورون به صورت موازی بر روی اطلاعات پردازش‌های لازم را انجام می‌دهند، با یکدیگر تعامل می‌کنند و بعد از همگرایی، خروجی مطلوب را تولید می‌کنند. خروجی مدل بر اساس ترکیب وزن‌دار سیگنال‌های بازدارنده و کنترل‌کننده اوربیتوفرانیتال و هیجانی آمیگدلا تولید می‌شود.

در ماشین یادگیری هیجان مغز سیگنال‌های بازدارنده^۳، سیگنال هیجانی^۴، سیگنال اتصالات^۵ و سیگنال یادگیری^۶ وجود دارد. خروجی مدل (r_j) براساس ترکیب وزن‌دار سیگنال‌های بازدارنده اوربیتوفرانیتال (r_0) و سیگنال‌های هیجانی آمیگدلا (r_a) تولید می‌شود. پارامترهای اوربیتوفرانیتال بر اساس سیگنال‌های خروجی بازدارنده اوربیتوفرانیتال و سیگنال‌های خروجی هیجانی آمیگدلا و سیگنال پاداش/جریمه بروزسانی می‌شود. الگوریتم پیش‌رو مدل محاسباتی ارائه شده به صورت رابطه (۱۵) الی رابطه (۱۸) و الگوریتم یادگیری هیجانی در این مدل به صورت رابطه (۱۹) الی رابطه (۲۰) است. متغیر i در این روابط نشان‌دهنده تعداد ورودی‌ها یا تعداد ویژگی‌های دیتاست مورد نظر است.

$$A_i = S_i V_i \quad (15)$$

$$O_i = S_i W_i \quad (16)$$

$$E = \sum_i A_i - \sum_i O_i \quad (17)$$

$$A_{th} = \max(S_i) \quad (18)$$

$$\Delta v_i = \alpha \max(0, R - \sum_i A_i) S_i \quad (19)$$

$$\Delta W = \beta (E - R) S_i \quad (20)$$

در روابط فوق S_i سیگنال‌های ورودی، V_i وزن‌های مرتبط با آمیگدلا، W_i وزن‌های مرتبط با اوربیتوفرانیتال، A_i خروجی آمیگدلا، O_i خروجی اوربیتوفرانیتال، E سیگنال خروجی سیستم می‌باشند. در روابط فوق α و β نرخ یادگیری و R سیگنال تقویت‌کننده است که در مدل پایه به صورت زیر محاسبه می‌شود.

$$R = \begin{cases} \left[\sum_i A_i - Rew \right]^+ - \sum_i O_i & \text{if } Rew \neq 0 \\ \left[\sum_i A_i - \sum_i O_i \right]^+ & \text{Otherwise} \end{cases} \quad (21)$$

در رابطه فوق، متغیر R تعریف شده بر اساس سیگنال Rew است. در مدل پایه این سیگنال فرمول نشده و این نقطه شروع توسعه در مدل یادگیر هیجانی مغز می‌باشد.

۲-۵- مدل‌های بهبود یافته ماشین یادگیری هیجانی مغز

به منظور توسعه، بهبود و رفع مشکلات ماشین و مدل شناختی پایه BEL، تحقیقات متعددی از منظر ساختار، معماری و الگوریتم یادگیری ارائه شده است. در [۲۷] یک کنترل‌کننده هوشمند بر اساس مجموع وزن‌دار عامل‌ها تعریف شده است. طراحی ماشین یادگیری هیجانی مغز مبتنی بر ماشین یادگیر مفروط و ماشین یادگیر مفروط فازی در [۲۸، ۲۹] انجام شده است. در [۵] مدل هیجانی مغز بر اساس سیستم استنتاج عصبی

⁴ Excitatory

⁵ Plastic

⁶ Learning

¹ Emotional Artificial Neural Network (EANN)

² LeDux

³ Inhibitory

در [۳۸] کنترل‌کننده مبتنی بر ماشین یادگیری هیجان مغز در یک سیستم غیرخطی، در [۳۹] کنترل ردیابی سیستم غیر خطی چند متغیره غیرقطعی با استفاده از کنترل‌کننده یادگیری هیجانی مغزی فازی تبدیل موجک پویای تاکاگی-سوگنو، در [۴۰] یک روش جدید تخمین‌گر سلامت با استفاده از شبکه عصبی یادگیری هیجانی مغز فازی و در [۴۱] از ترکیب ماشین یادگیری هیجانی مغز و کنترل‌کننده پیش‌بینی مدل پویا برای درایور موتور القایی استفاده شده است.

تحقیقات مختلف انجام گرفته جهت توسعه ماشین یادگیر هیجانی مغز نشان‌دهنده توسعه مدل پایه BEL بر اساس ساختار و معماری، بلوک سازنده و یا نوع الگوریتم یادگیری استفاده شده در آن است. بر این اساس می‌توان از این دیدگاه‌ها این مدل شناختی را توسعه و بهبود داد.

۳- روش پیشنهادی

به منظور استفاده از یک مدل سریع با کم‌ترین پارامتر قابل تنظیم و پارامتر قابل یادگیری و همچنین الهام گرفتن از مغز هیجانی، از ترکیب دو ماشین یادگیری هیجان مغز و ماشین یادگیر مفروط استفاده می‌شود. مطابق با معماری ارائه شده در شکل (۳) بخش‌های اصلی MO اوربیتوفرانتال و BL آمیگدلا ماشین یادگیری هیجانی مغز بر اساس ماشین یادگیر مفروط ترتیبی آنلاین طراحی و ماشین ترکیبی طراحی شده BEL-OS-ELM نامیده می‌شوند. اجزای تشکیل دهنده در این بلوک‌ها بر اساس شکل (۴) ماشین یادگیر مفروط ترتیبی آنلاین با نورون‌های افزایشی با توابع فعال‌ساز مختلف یا توابع پایه‌ای شعاعی است.

به منظور تعامل دو بلوک اصلی، خروجی‌های زمان t آمیگدلا و اوربیتوفرانتال به ترتیب به خروجی‌های اوربیتوفرانتال و آمیگدلا در زمان‌های $t-1$ الی $t-M$ وابسته می‌شوند و ویژگی حافظه‌دار بازگشتی با قابلیت انتقال یادگیری در مدل پیشنهادی شبیه‌سازی می‌شود. مدل پیشنهادی ماشین یادگیری هیجانی مغز مبتنی بر ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی نامیده می‌شود. M مقدار عمق حافظه را نشان می‌دهد. خروجی‌ها در هر لحظه، به M مقدار خروجی قبل وابسته هستند و هر خروجی بر اساس ورودی‌های به صورت الگو-الگو یا دسته-

فازی و در [۴] یک معماری شناختی بر اساس ترکیب شبکه عصبی RBF و K مینیمم همسایگی وزن‌دار ارائه شده است. ماشین یادگیری هیجانی مبتنی بر یادگیری فراموشی حافظه با یادگیری حالات هیجانی در [۳۰] ارائه شده است. در [۳۱] مدل ADBEL^۱ [۹، ۱۰] بهبود یافته و از نورون‌های فازی در بخش اوربیتوفرانتال سیستم لیمبیک مغز استفاده و ماشین NF-ADBEL^۲ معرفی می‌شود. طراحی ساختار رقابتی عصبی کورتکس و ساختار یادگیری هیجانی در [۱۱، ۱۴] معرفی شده است. در این مقالات تعامل میان شناخت و هیجان مدل‌سازی شده است. همچنین در [۳۲، ۳۳] ماشین یادگیری هیجانی مغز توسعه یافته جهت شناسایی زلزله و ترس معرفی شده است. در [۳۳] رکوردهای زلزله مصنوعی بر اساس ترکیب الگوریتم هوش ازدحامی ذرات و ماشین یادگیری هیجانی تولید شده است.

مدل‌های بهبودیافته ماشین یادگیری هیجانی مغز در سیستم شناسایی گفتار هیجانی نیز بکارگرفته شده است [۱۲، ۱۳، ۳۴، ۳۵]. در [۱۲] از آتاماتای یادگیر جهت الگوریتم یادگیری در ماشین یادگیری هیجانی، در [۳۴] از شبکه‌های عصبی مصنوعی چندلایه پرسپترون^۳ و ANFIS جهت بهبود مدل BEL، در [۱۳] جهت کاهش ویژگی از ترکیب تجزیه و تحلیل مولفه اصلی^۴ و تجزیه و تحلیل تفکیک خطی^۵ و از الگوریتم ژنتیک جهت آموزش پارامترهای مدل BEL ارائه شده در [۱۱] و در [۳۵] از ترکیب مدل یادگیر هیجانی مغز و ذهن به منظور شناسایی گفتار هیجانی استفاده شده است.

مدل یادگیری هیجانی مغز فازی در تحقیقات مختلفی ارائه شدند [۱۵، ۳۶، ۳۷]. در [۳۶] سیستم کنترل یادگیری هیجانی مغز فازی در طراحی سیستم‌های غیرخطی معرفی و یک کنترل‌کننده یادگیری هیجان مغز^۶ با قوانین استنتاج فازی ارائه شد. در [۳۷] جهت طبقه‌بندی تومور سرطان سینه و همزمان‌سازی سیستم‌های آشوبی از شبکه یادگیری هیجان مغز مبتنی بر شبکه‌های عصبی پیوند تابع^۷ استفاده شد. در [۱۵] از یک کنترل‌کننده یادگیری هیجانی مغز فازی تطبیقی خودسازمان‌ده جهت سیستم‌های غیر خطی استفاده شد.

^۵ Linear Discriminant Analysis (LDA)

^۶ Brain Emotional Learning Controller (BELC)

^۷ A function link neural network

^۱ Adaptive Decayed Brain Emotional Learning (ADBEL)

^۲ Neo-Fuzzy integrated ADBEL (NF-ADBEL)

^۳ Multilayer perceptron (MLP)

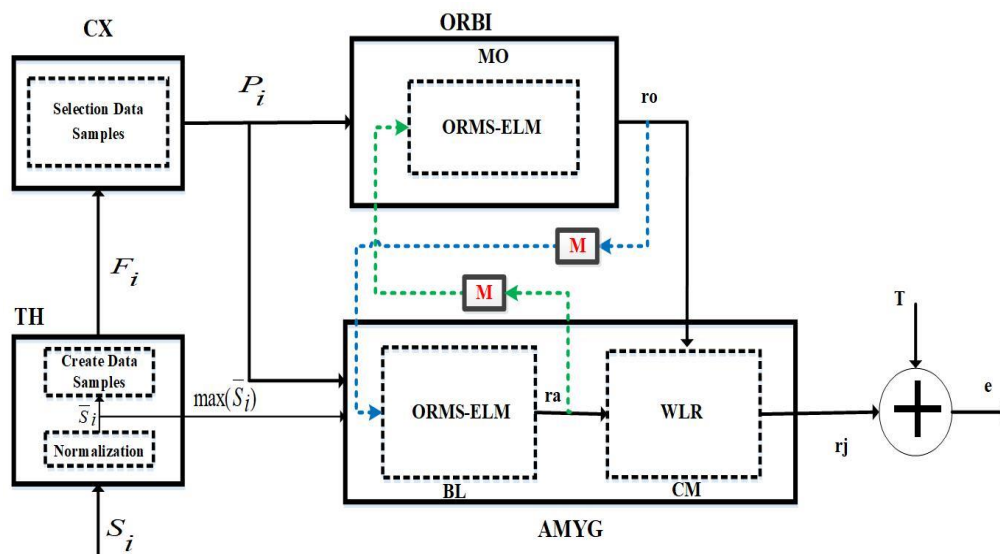
^۴ Principal Component Analysis (PCA)

می‌کند. در صورت نیاز سیگنال‌های ورودی در بازه $[0, 1]$ یا $[-1, +1]$ در این بخش نرمالیزه می‌شوند. (\bar{S}_i) و مقادیر ماکزیمم آن $(\max(\bar{S}_i))$ به صورت مستقیم به آمیگدلا ارسال می‌شود. همچنین بر اساس صورت مساله و نوع داده‌ها، نمونه‌ها بر اساس ورودی/خروجی (x_i, t_i) در یک مساله با نظارت تنظیم و به صورت یک سیگنال خروجی (F_i) به سمت کورتکس ارسال می‌شوند. نشان دهنده ویژگی‌های الگوی ورودی و t_i بیانگر خروجی الگوها/نمونه‌ها است. سیگنال‌های ورودی (F_i) در قالب ورودی/خروجی الگوهای صورت مساله در کورتکس (CX) ممکن است به شکل و فرمت دیگری نگاشت داده شوند. سیگنال‌های خروجی کورتکس (P_i) در قالب الگوهای ورودی/خروجی نگاشت شده حاصل از عملیات‌های انتخاب/استخراج ویژگی، کاهش بعد و نگاشت ویژگی به بلوک‌های اصلی AMYG و ORBI به صورت همزمان ارسال می‌شوند.

دسته محاسبه می‌شود. ماشین طراحی شده بر اساس ورودی داده‌ها به صورت الگو-الگو یا دسته-دسته به ترتیب BEL-ORMS1-ELM و BEL-ORMS2-ELM نامیده می‌شوند.

ماشین یادگیر مفروط ترتیبی آنلاین دارای کارایی خوبی نسبت به حالت دسته‌ای آن نمی‌باشد. بر این اساس داده‌ها به صورت دسته-دسته وارد می‌شوند و خروجی‌های هر دسته علاوه بر ورودی‌های همان دسته در زمان t به خروجی‌های یک دسته قبل‌تر بر اساس مقدار حافظه M در زمان‌های گذشته $t-1$ الی $t-M$ وابسته خواهند شد. طراحی بر اساس این مفهوم منجر به تولید ماشین یادگیر هیجانی مغز با ورودی داده‌های به صورت دسته-دسته یا بلوک-بلوک با اندازه مشخص یا متغیر (BEL-ORMS2-ELM) می‌شود.

در بلوک دیاگرام ارائه شده شکل (۳)، بخش تالاموس مغز هیجانی است که سیگنال‌های ورودی S_i را دریافت



شکل ۳- ماشین یادگیری هیجانی مغز مبتنی بر ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی.


مقایسه و بر اساس آن مقدار خطا e محاسبه می‌شود. سیگنال Rew در مسائل بانظارت برابر با سیگنال خطای e است که منجر به تغییر مقادیر پارامترهای بخش‌های AMYG و ORBI می‌شود.

الگوریتم یادگیری BEL-ORMS-LEM پیشنهادی مطابق با معماری ارائه شده در شکل (۳) و شکل (۴) مبتنی بر الگوریتم یادگیری در ماشین یادگیر مفروط ترتیبی آنلاین از ۲ مرحله مقاردهی اولیه و مرحله یادگیری ترتیبی تشکیل شده است. در مرحله اولیه بر

بخش‌های MO از ORBI و BL از AMYG، هسته و پردازنده اصلی جهت تجزیه و تحلیل بر روی داده‌های ورودی (P_i) هستند. این دو مرکز پردازش اصلی علاوه بر دریافت سیگنال‌های ورودی از کورتکس، سیگنال‌های خروجی گذشته مرکز دیگر را دریافت می‌کند. M نشان‌دهنده میزان عمق حافظه استفاده از خروجی‌های گذشته است. خروجی‌های آمیگدلا (ra) و اوربیتوفرانثال (ro) جهت پردازش به بلوک CM از آمیگدلا ارسال می‌شوند. خروجی پیش‌بینی t_j با خروجی حقیقی T

مرحله مقاردهی اولیه : در این مرحله بر اساس تعداد NO نمونه از دیتاست یادگیری شروع می‌شود. پارامترهای لایه میانی پنهان a و b به صورت تصادفی مقداردهی و ماتریس خروجی پنهان لایه خروجی آمیگدلا (H_{0a}) و اوربیتوفرانانتال (H_{0o}) مطابق با روابط زیر بر اساس معماری پیشنهادی محاسبه می‌شوند.

اساس تعداد NO نمونه از داده‌ها، ماتریس خروجی لایه پنهان H_0 تشکیل و سپس در مرحله یادگیری این ماتریس بروزسانی می‌شود. در مرحله یادگیری ترتیبی بر اساس ورودی داده‌ها به صورت الگو-الگو یا دسته-دسته ماتریس خروجی لایه پنهان در مرحله $k+1$ و خروجی‌ها به صورت ترتیبی محاسبه می‌شوند.



شکل ۴- ساختار داخلی معماری پیشنهادی (BEL-ORMS-ELM).

$$H_{0a}(a_{1a}, \dots, a_{La}, b_{1a}, \dots, b_{La}, x_1, \dots, x_{N0}) = \begin{bmatrix} g(a_{1a}, b_{1a}, x_1) & \dots & g(a_{La}, b_{La}, x_1) \\ \dots & \dots & \dots \\ g(a_{1a}, b_{1a}, x_{N0}) & \dots & g(a_{La}, b_{La}, x_{N0}) \end{bmatrix}_{N0 \times L} \quad (22)$$

$$H_{0o}(a_{1o}, \dots, a_{Lo}, b_{1o}, \dots, b_{Lo}, x_1, \dots, x_{N0}) = \begin{bmatrix} g(a_{1o}, b_{1o}, x_1) & \dots & g(a_{Lo}, b_{Lo}, x_1) \\ \dots & \dots & \dots \\ g(a_{1o}, b_{1o}, x_{N0}) & \dots & g(a_{Lo}, b_{Lo}, x_{N0}) \end{bmatrix}_{N0 \times L} \quad (23)$$

محاسبه می‌شوند.

خروجی‌های حاصل از بلوک‌های اصلی MO اوربیتوفرانانتال ($r_{0a} = Out_{0a}$) و BL آمیگدلا ($r_{0o} = Out_{0o}$) وارد بخش CM آمیگدلا می‌شوند. این بخش همانند یک نورون ساده عصبی است. خروجی نهایی ماشینی پیشنهادی ($r_j = Out_{0cm}$) بر اساس رابطه (۳۳) به‌ازای NO نمونه داده اولیه ورودی و خروجی مطلوب T0 محاسبه می‌شود. بخش CM آمیگدلا بر اساس مدل ترکیب خطی وزن‌دار ورودی‌ها

تخمین وزن لایه خروجی اولیه آمیگدلا (β_{0a}) بر اساس ماتریس خروجی لایه پنهان آمیگدلا به‌ازای NO خروجی مطلوب $T_0 = [t_1, t_2, \dots, t_{N0}]^T$ و خروجی پیش‌بینی آمیگدلا (Out_{0a}) به ترتیب در رابطه (۲۵) و رابطه (۲۶) بر اساس قوانین یادگیری بیان شده در مرحله اولیه ماشینی یادگیر مفروض ترتیبی آنالین محاسبه می‌شوند. روابط بیان شده جهت محاسبه وزن لایه خروجی اولیه و خروجی پیش‌بینی اوربیتوفرانانتال در رابطه (۲۸) و رابطه (۲۹)

$H_{(k+1)a}$ و اوربیتوفرانانتال $H_{(k+1)o}$ به‌ازای خروجی مطلوب $T_{k+1} = \left[t_{(\sum_{j=0}^k N_j)+1}, \dots, t_{(\sum_{j=0}^k N_j)+1} \right]^T$ به ترتیب در رابطه (۳۴) و رابطه (۳۵) محاسبه می‌شوند.

$$P_{0a} = (H_{0a}^T \cdot H_{0a})^{-1} \quad (۲۴)$$

$$\beta_{0a} = P_{0a} \cdot H_{0a}^T \cdot T_0 \quad (۲۵)$$

$$Out_{0a} = H_{0a} \times \beta_{0a} \quad (۲۶)$$

$$P_{0o} = (H_{0o}^T \cdot H_{0o})^{-1} \quad (۲۷)$$

$$\beta_{0o} = P_{0o} \cdot H_{0o}^T \cdot T_0 \quad (۲۸)$$

$$Out_{0o} = H_{0o} \times \beta_{0o} \quad (۲۹)$$

$$H_{(k+1)a} = H(a_{1a}, \dots, a_{La}, b_{1a}, \dots, b_{La}, x_{(N_0+1)}, \dots, x_{(N_0+p)}, r_{(N_0+1)o}, \dots, r_{(N_0+p)o}) = \begin{bmatrix} g(a_{1a}, b_{1a}, x_{(N_0+1)}) & g(a_{La}, b_{La}, x_{(N_0+1)}) & r_{(N_0+1)o}(t-1) & \dots & r_{(N_0+1)o}(t-M) \\ \dots & \dots & \dots & \dots & \dots \\ g(a_{1a}, b_{1a}, x_{(N_0+p)}) & g(a_{La}, b_{La}, x_{(N_0+p)}) & r_{(N_0+p)o}(t-1) & \dots & r_{(N_0+p)o}(t-M) \end{bmatrix}_{n \times (L+M)} \quad (۳۴)$$

$$H_{(k+1)o} = H(a_{1o}, \dots, a_{Lo}, b_{1o}, \dots, b_{Lo}, x_{(N_0+1)}, \dots, x_{(N_0+p)}, r_{(N_0+1)a}, \dots, r_{(N_0+p)a}) = \begin{bmatrix} g(a_{1o}, b_{1o}, x_{(N_0+1)}) & g(a_{Lo}, b_{Lo}, x_{(N_0+1)}) & r_{(N_0+1)a}(t-1) & \dots & r_{(N_0+1)a}(t-M) \\ \dots & \dots & \dots & \dots & \dots \\ g(a_{1o}, b_{1o}, x_{(N_0+p)}) & g(a_{Lo}, b_{Lo}, x_{(N_0+p)}) & r_{(N_0+p)a}(t-1) & \dots & r_{(N_0+p)a}(t-M) \end{bmatrix}_{n \times (L+M)} \quad (۳۵)$$

حافظه M برای اوربیتوفرانانتال مطابق با $H_{(k+1)o}$ محاسبه می‌شود. تخمین رابطه بیان شده در مرحله $k+1$ و عمق حافظه M برای اوربیتوفرانانتال مطابق با $H_{(k+1)o}$ محاسبه می‌شود. تخمین وزن لایه خروجی در مرحله $k+1$ آمیگدلا $(\beta_{(k+1)a})$ و خروجی پیش‌بینی آمیگدلا $(Out_{(k+1)a})$ به ترتیب در رابطه (۳۷) و رابطه (۳۸) محاسبه می‌شوند. تخمین وزن لایه خروجی $(\beta_{(k+1)o})$ در مرحله $k+1$ و خروجی پیش‌بینی $(Out_{(k+1)o})$ اوربیتوفرانانتال در رابطه (۴۰) و رابطه (۴۱) محاسبه می‌شوند.

$$P_{(k+1)a} = P_{ka} - P_{ka} H_{(k+1)a}^T (I + H_{(k+1)a} P_{ka} H_{(k+1)a}^T)^{-1} \times H_{(k+1)a} P_{ka} \quad (۳۶)$$

$$\beta_{(k+1)a} = \beta_{ka} + P_{(k+1)a} H_{(k+1)a} (T_{k+1}^T - H_{(k+1)a}^T \cdot \beta_{ka}) \quad (۳۷)$$

$$Out_{(k+1)a} = H_{(k+1)a} \cdot \beta_{(k+1)a} \quad (۳۸)$$

$$P_{(k+1)o} = P_{ko} - P_{ko} H_{(k+1)o}^T (I + H_{(k+1)o} P_{ko} H_{(k+1)o}^T)^{-1} \times H_{(k+1)o} P_{ko} \quad (۳۹)$$

$$\beta_{(k+1)o} = \beta_{ko} + P_{(k+1)o} H_{(k+1)o} (T_{k+1}^T - H_{(k+1)o}^T \cdot \beta_{ko}) \quad (۴۰)$$

$$Out_{(k+1)o} = H_{(k+1)o} \cdot \beta_{(k+1)o} \quad (۴۱)$$

مبتنی بر الگوریتم یادگیری حداقل مربعات وزن‌دار^۱ یا رگرسیون خطی وزن‌دار^۲ پیاده‌سازی می‌شود.

$$H_{0cm} = [Out_{0a}, Out_{0o}, 1] \quad (۳۰)$$

$$P_{0cm} = (H_{0cm}^T \cdot H_{0cm})^{-1} \quad (۳۱)$$

$$\beta_{0cm} = P_{0cm} H_{0cm}^T \cdot T_0 \quad (۳۲)$$

$$\beta_{0cm} = P_{0cm} H_{0cm}^T \cdot T_0 \quad (۳۳)$$

مرحله یادگیری ترتیبی: با مشاهده p نمونه جدید در مرحله $k+1$ و به‌ازای $N_0 + 1, N_0 + 2, \dots, N_0 + p$ داده، ماتریس خروجی لایه پنهان آمیگدلا

مطابق با روابط فوق، وابستگی، تعامل و اثربخشی خروجی‌های آمیگدلا و اوربیتوفرانانتال به یکدیگر بر اساس ماتریس خروجی لایه پنهان H در هر یک از این بلوک‌ها صورت می‌گیرد. ماتریس لایه پنهان آمیگدلا $H_{(k+1)a}$ در مرحله $k+1$ و عمق حافظه M به صورت ترکیبی از (۱) خروجی توابع فعال‌ساز نورون‌های بخش آمیگدلا $(g(a_a, b_a, x_i))$ و (۲) خروجی‌های حاصل از اوربیتوفرانانتال در M زمان گذشته $(r_o(t-1) \dots r_o(t-M))$ محاسبه می‌شود. رابطه بیان شده در مرحله $k+1$ و عمق

² Weighted Linear Regression (WLR)

¹ Weighted Least Squares (WLS)

داده‌های ورودی به صورت بلوک-بلوک یا دسته-دسته (B)، مقدار حافظه یا وابستگی به اطلاعات گذشته (M) و تعداد تکرار اجرای الگوریتم (epoch) می‌باشد. پارامترهای بیان شده به ازای سری زمانی مکی گلاس و لورنز به ترتیب در جدول ۱ و جدول ۲ ارائه شده است. بلوک اصلی استفاده شده در ماشین یادگیری هیجانی مغز، ماشین یادگیر مفروط ترتیبی آنلاین است. بنابراین مدل‌های پیشنهادی برای ورودی داده‌های مختلف با این مدل اصلی و سازنده مورد مقایسه قرار می‌گیرند.

به منظور ارزیابی روش پیشنهادی از معیارهای مدت زمان لازم جهت آموزش پارامترهای یادگیر^۵ (DOL) بر اساس داده‌های آموزش، مدت زمان اجرای تست مدل به ازای داده‌های آموزش و تست (Train Time, Test Time)، مجذور میانگین مربعات خطا^۶، میانگین درصد مطلق خطا^۷، رگرسیون^۸، میانگین انحراف معیار (eStd)، منحنی تغییرات خروجی مطلوب و خروجی مدل پیش‌بینی، میانگین و واریانس خطا استفاده می‌شود. به منظور اعتبارسنجی نتایج از معیارهای معتبر استنتاج آماری در پیش‌بینی مسائل رگرسیون همانند فاصله اطمینان^۹ استفاده می‌شود. بر این اساس میانگین خروجی‌های پیش‌بینی شده داده‌های آموزش و تست (mean) همراه با حد پائین (CI-L) و حد بالا (CI-H) 95% CI گزارش می‌شود. برنامه‌های نوشته شده در محیط برنامه‌نویسی Matlab R2020b، در شرایط یکسان با سیستمی به مشخصات CPU core i5 1.6 GHz، RAM 8GB اجرا شده است.

نتایج حاصل از شبیه‌سازی و مقایسه مدل‌های مختلف با معیارهای ارزیابی معتبر برای مسائل پیش‌بینی رگرسیون به ازای سری زمانی مکی گلاس در جدول ۳ و جدول ۴ و به ازای سری زمانی لورنز در جدول ۵ و جدول ۶ نشان داده شده است. به ازای هر مدل، برنامه به تعداد تکرار مشخص (۵ مرتبه) اجرا و سپس میانگین آن گزارش می‌گردد. همچنین منحنی خروجی واقعی و خروجی پیش‌بینی، رگرسیون خروجی‌ها، نمودار تغییرات مقدار خطای پیش‌بینی و هیستوگرام خطا به ازای داده‌های آموزش و تست برای مدل پیشنهادی برای سری زمانی مکی گلاس

در نهایت پس از تخمین خروجی‌های آمیگدلا و اوربیتوفران‌تال، خروجی نهایی سیستم پیشنهادی در بخش CM آمیگدلا بر اساس ترکیب وزن‌دار خطی خروجی‌های آمیگدلا و اوربیتوفران‌تال و بر اساس الگوریتم یادگیری کمترین مربعات خطا^۱ (LSE) با استفاده از روابط زیر در مرحله k+1 محاسبه می‌شود:

$$H_{(k+1)cm} = [Out_{(k+1)a}, Out_{(k+1)o}, 1] \quad (42)$$

$$P_{(k+1)cm} = (H_{(k+1)cm}^T \cdot H_{(k+1)cm})^{-1} \quad (43)$$

$$\beta_{(k+1)cm} = P_{(k+1)cm} H_{(k+1)cm}^T \cdot T_{(k+1)} \quad (44)$$

$$Out_{(k+1)cm} = H_{(k+1)cm} \times \beta_{(k+1)cm} \quad (45)$$

۴- تجزیه و تحلیل نتایج

بر اساس مدل ارائه شده و ساختار حاکم بر آن، داده‌ها و اطلاعات موجود در قالب سری زمانی به عنوان داده‌های مورد آزمایش جهت راستی آزمایی روش پیشنهادی استفاده می‌شوند و نتایج حاصل از مقایسه مدل‌های ارائه شده بر اساس معیارهای خاص در این حوزه مورد ارزیابی قرار می‌گیرد.

۴-۱- پایگاه داده مورد بررسی

به منظور راستی آزمایی روش پیشنهادی با روش‌های مشابه، خروجی سری مکی گلاس در زمان x(t+85) بر اساس زمان‌های x(t-18)، x(t-12)، x(t-6)، x(t-1) و x(t+30) سری زمانی لورنز بر اساس اطلاعات گذشته x(t)، x(t-1) و x(t-2) پیش‌بینی می‌گردد.

۴-۲- نتایج بدست آمده

داده‌های سری زمانی جهت ارائه به مدل‌ها به شکل مناسب تبدیل و در بازه [۱-، +۱] نرمالیزه می‌شوند. به ترتیب مقادیر ۹۰٪ و ۶۰٪ از داده‌های سری زمانی مکی گلاس و لورنز به عنوان داده‌های آموزش و بقیه به عنوان داده‌های تست در نظر گرفته می‌شوند. پارامترهای مدل‌های مختلف در شرایط یکسان به ازای داده‌های سری زمانی تنظیم می‌شوند. این پارامترها شامل نوع تابع فعال‌ساز^۲ g(x)، تعداد نورون لایه پنهان^۳، تعداد نمونه اولیه از داده‌ها^۴، تعداد

^۶ Root Mean squared error (RMSE)

^۷ Mean Absolute Percent Error (MAPE)

^۸ Regression (R)

^۹ Confidence Interval (CI95%)

^۱ Least Square Estimator (LSE)

^۲ Activation Function (AF)

^۳ Hidden Neurons (HN)

^۴ Initial Training Set (NO)

^۵ Duration of Online Learning (DOL)

در شکل (۵) و شکل (۶) و برای سری زمانی لورنز در شکل (۷) و شکل (۸) نشان داده شده است.

جدول ۱- پارامترهای مختلف مدل‌ها به ازای سری زمانی مکی‌گلاس.

Model	AF	HN	N0	B	M	epoch
ELM [۱۷]	logsig	۱۰	-	-	-	-
	tansig					
	rbf					
OS-ELM [۱۸]	logsig	۱۰	۱۰	۱	-	-
	tansig					
	rbf					
OS-ELM [۱۸]	logsig	۱۰	۲۰	۱۰	-	-
	tansig					
	rbf					
BEL [۶]	purelin	۴	-	-	-	۵۰
BEL-ORMS1-ELM	logsig	۱۰	۱۰	۱	۵	-
	tansig					
	rbf					
BEL-ORMS2-ELM	logsig	۱۰	۲۰	۱۰	۵	-
	tansig					
	rbf					

جدول ۲- پارامترهای مختلف مدل‌ها به ازای سری زمانی لورنز.

Model	AF	HN	N0	B		M	Epoch
ELM [۱۷]	logsig	۱۰	-	-		-	-
	tansig						
	radbas						
ELM [۱۷]	logsig	۵۰	-	-		-	-
	tansig						
	radbas						
OS-ELM [۱۸]	logsig	۱۰	۲۰۰	۱		-	-
	tansig						
	radbas						
OS-ELM [۱۸]	logsig	۵۰	۱۱۰۰	۱۰۰۰		-	-
	tansig						
	radbas						
BEL [۶]	purelin	۳	-	-		-	۳۰
BEL-ORMS1-ELM	logsig	۵۰	۱۰	۱		۵	-
	tansig						
	radbas						
BEL-ORMS2-ELM	logsig	۵۰	۱۱۰۰	۱۰۰۰		۱۰	-
	tansig						
	radbas						

جدول ۳- نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی مکی گلاس برای داده‌های آموزش.

Methods	Train						(mean, CI-L, CI-U)
	DOL	T	RMSE	MAPE	R	eStd	
ELM [۱۷] (AF:logsig)	۰.۰۱	۰	۰.۱۱۲	۰.۱۸۰	۰.۸۴۰	۰.۱۱۲	(۰.۶۴۹, ۰.۶۳۸, ۰.۶۶۰)
ELM [۱۷] (AF:tansig)	۰.۰۳	۰	۰.۲۲۰	۱.۷۵۰	۰.۸۴۸	۰.۲۲۰	(۰.۲۹۵, ۰.۲۷۳, ۰.۳۱۷)
ELM [۱۷] (AF:rbf)	۰.۰۱	۰.۰۱	۰.۱۰۷	۰.۱۷۱	۰.۸۵۵	۰.۱۰۷	(۰.۶۴۹, ۰.۶۳۸, ۰.۶۶۰)
OS-ELM [۱۸] (AF:logsig, N0:۱۰, B:۱)	۰.۰۵	۰.۰۲	۰.۱۲۵	۰.۱۸۰	۰.۸۰۲	۰.۱۲۵	(۰.۶۴۲, ۰.۶۳۱, ۰.۶۵۳)
OS-ELM [۱۸] (AF: tansig, N0:۱۰, B:۱)	۰.۰۵	۰.۰۱	۰.۲۳۶	۱.۸۶۴	۰.۸۴۹	۰.۲۳۵	(۰.۶۴۹, ۰.۶۳۷, ۰.۶۶۰)
OS-ELM [۱۸] (AF: radbas, N0:۱۰, B:۱)	۰.۰۶	۰.۰۱	۰.۱۰۸	۰.۱۶۹	۰.۸۵۴	۰.۱۰۸	(۰.۶۴۹, ۰.۶۳۸, ۰.۶۶۰)
OS-ELM [۱۸] (AF:logsig, N0:۲۰, B:۱۰)	۰.۰۶	۰	۰.۱۱۲	۰.۱۸۰	۰.۸۴۱	۰.۱۱۲	(۰.۶۴۹, ۰.۶۳۸, ۰.۶۶۰)
OS-ELM [۱۸] (AF:tansig, N0:۲۰, B:۱۰)	۰.۰۶	۰	۰.۲۳۲	۱.۷۵۲	۰.۸۲۸	۰.۲۳۳	(۰.۲۹۸, ۰.۲۷۶, ۰.۳۱۹)
OS-ELM [۱۸] (AF:radbas, N0:۲۰, B:۱۰)	۰.۰۶	۰.۰۰	۰.۱۱۲	۰.۱۸۰	۰.۸۴۰	۰.۱۱۲	(۰.۶۴۹, ۰.۶۳۸, ۰.۶۶۰)
BEL [۶] (epoch:۵۰)	۴.۰۶	۰.۰۲	۰.۱۹۱	۰.۷۹۶	۰.۷۷۷	۰.۱۶۲	(۰.۸۳۲, ۰.۸۲۲, ۰.۸۴۲)
BEL-ORMS1-ELM (AF:logsig, N0:۱۰, B:۱, M:۵)	۰.۲۶	۰.۱۰	۰.۱۶۵	۰.۱۹۷	۰.۶۷۹	۰.۱۵۸	(۰.۶۰۲, ۰.۵۹۱, ۰.۶۱۴)
BEL-ORMS1-ELM (AF:tansig, N0:۱۰, B:۱, M:۵)	۰.۳۰	۰.۱۳	۰.۲۹۶	۱.۹۲۸	۰.۷۲۵	۰.۲۹۳	(۰.۳۰۸, ۰.۲۸۵, ۰.۳۳۲)
BEL-ORMS1-ELM (AF:radbas, N0:۱۰, B:۱, M:۵)	۰.۳۲	۰.۲۳	۰.۱۲۵	۰.۱۹۰	۰.۸۰۲	۰.۱۲۵	(۰.۶۳۰, ۰.۶۱۹, ۰.۶۴۲)
BEL-ORMS2-ELM AF:logsig, N0:۲۰, B:۱۰, M:۵)	۰.۰۵	۰.۰۱	۰.۱۳۴	۰.۱۷۳	۰.۷۸۱	۰.۱۳۳	(۰.۶۳۷, ۰.۶۲۵, ۰.۶۴۹)
BEL-ORMS2-ELM (AF:tansig, N0:۲۰, B:۱۰, M:۵)	۰.۰۴	۰.۰۲	۰.۲۵۶	۱.۸۵۱	۰.۷۹۷	۰.۲۵۵	(۰.۲۷۸, ۰.۲۵۴, ۰.۳۰۱)
BEL-ORMS2-ELM (AF:radbas, N0:۲۰, B:۱۰, M:۵)	۰.۰۵	۰.۰۱	۰.۱۳۵	۰.۱۷۵	۰.۷۷۷	۰.۱۳۴	(۰.۶۳۴, ۰.۶۲۲, ۰.۶۴۶)

جدول ۴- نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی مکی گلاس برای داده‌های تست.

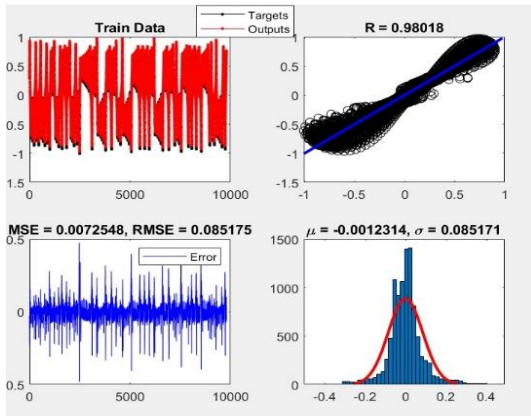
Methods	Test					
	T	RMSE	MAPE	R	eStd	(mean, CI-L, CI-U)
ELM [۱۷] (AF:logsig)	۰	۰.۰۶۶	۰.۱۱۴	۰.۹۵۳	۰.۰۶۶	(۰.۶۵۲, ۰.۶۲۰, ۰.۶۸۳)
ELM [۱۷] (AF:tansig)	۰	۰.۱۳۵	۱.۰۲۱	۰.۹۴۹	۰.۱۳۶	(۰.۳۰۱, ۰.۲۳۶, ۰.۳۶۵)
ELM [۱۷] (AF:rbf)	۰.۰۱	۰.۰۶۱	۰.۱۰۴	۰.۹۶۰	۰.۰۶۱	(۰.۶۵۰, ۰.۶۱۸, ۰.۶۸۲)
OS-ELM [۱۸] (AF:logsig, N0:۱۰, B:۱)	۰	۰.۰۶۲	۰.۱۰۵	۰.۹۵۹	۰.۰۶۳	(۰.۶۵۰, ۰.۶۱۸, ۰.۶۸۲)
OS-ELM [۱۸] (AF: tansig, N0:۱۰, B:۱)	۰	۰.۱۳۰	۰.۹۵۷	۰.۹۵۴	۰.۱۳۱	(۰.۳۰۶, ۰.۲۴۲, ۰.۳۷۱)
OS-ELM [۱۸] (AF: radbas, N0:۱۰, B:۱)	۰	۰.۰۵۹	۰.۱۰۳	۰.۹۶۳	۰.۰۶۰	(۰.۶۵۲, ۰.۶۲۰, ۰.۶۸۴)
OS-ELM [۱۸] (AF:logsig, N0:۲۰, B:۱۰)	۰	۰.۰۶۷	۰.۱۱۶	۰.۹۵۱	۰.۰۶۷	(۰.۶۵۴, ۰.۶۲۲, ۰.۶۸۶)
OS-ELM [۱۸] (AF:tansig, N0:۲۰, B:۱۰)	۰	۰.۱۳۷	۰.۸۴۹	۰.۹۵۰	۰.۱۳۸	(۰.۳۰۸, ۰.۲۴۶, ۰.۳۷۰)
OS-ELM [۱۸] (AF:radbas, N0:۲۰, B:۱۰)	۰	۰.۰۷۱	۰.۱۲۳	۰.۹۴۲	۰.۰۷۲	(۰.۶۵۱, ۰.۶۱۹, ۰.۶۸۳)
BEL [۶] (epoch:۵۰)	۰.۰۰	۰.۱۴۲	۰.۶۶۷	۰.۹۴۶	۰.۱۰۵	(۰.۸۳۴, ۰.۸۰۷, ۰.۸۶۲)
BEL-ORMS1-ELM (AF:logsig, N0:۱۰, B:۱, M:۵)	۰.۰۱۵	۰.۱۱۵	۰.۱۷۰	۰.۸۵۴	۰.۱۰۷	(۰.۶۰۵, ۰.۵۷۵, ۰.۶۳۵)
BEL-ORMS1-ELM (AF:tansig, N0:۱۰, B:۱, M:۵)	۰.۰۲	۰.۲۰۰	۱.۶۷۰	۰.۸۸۶	۰.۱۸۵	(۰.۳۴۳, ۰.۲۷۸, ۰.۴۰۹)
BEL-ORMS1-ELM (AF:radbas, N0:۱۰, B:۱, M:۵)	۰.۰۴	۰.۰۷۵	۰.۱۲۳	۰.۹۴۵	۰.۰۷۵	(۰.۶۳۴, ۰.۶۰۲, ۰.۶۶۶)
BEL-ORMS2-ELM (AF:logsig, N0:۲۰, B:۱۰, M:۵)	۰.۰۱	۰.۰۴۷	۰.۰۷۷	۰.۹۸۱	۰.۰۴۶	(۰.۶۳۴, ۰.۶۰۲, ۰.۶۶۷)
BEL-ORMS2-ELM (AF:tansig, N0:۲۰, B:۱۰, M:۵)	۰.۰۲	۰.۰۹۶	۰.۵۳۷	۰.۹۸۱	۰.۰۹۶	(۰.۲۸۸, ۰.۲۲۳, ۰.۳۵۳)
BEL-ORMS2-ELM (AF:radbas, N0:۲۰, B:۱۰, M:۵)	۰.۰۱	۰.۰۵۸	۰.۰۸۹	۰.۹۶۶	۰.۰۵۶	(۰.۶۳۵, ۰.۶۰۲, ۰.۶۶۷)

جدول ۵- نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی لورنز برای داده‌های آموزش.

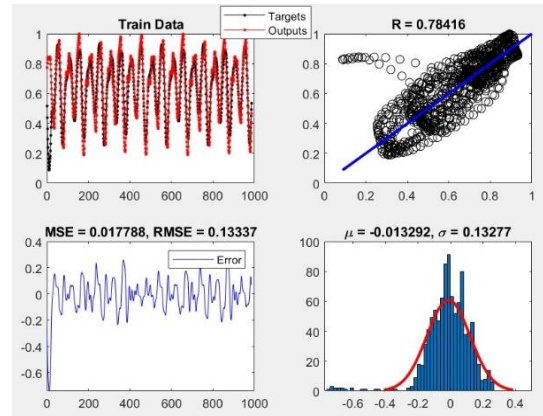
Methods	Train						(mean, CI-L, CI-U)
	DOL	T	RMSE	MAPE	R	eStd	
ELM [۱۷] (AF:logsig, HN=۱۰)	۰.۰۳	۰.۰۲	۰.۱۳۶	۰.۳۷۱	۰.۷۷۳	۰.۱۳۶	(۰.۵۱۵, ۰.۵۱۲, ۰.۵۱۹)
ELM [۱۷] (AF:tansig, HN=۱۰)	۰.۰۳	۰	۰.۲۱۰	۱.۵۶۵	۰.۸۷۱	۰.۲۱۰	(۰.۰۳۱, ۰.۰۲۴, ۰.۰۳۹)
ELM [۱۷] (AF:radbas, HN=۱۰)	۰.۰۴	۰	۰.۱۱۱	۰.۲۹۹	۰.۸۵۳	۰.۱۱۱	(۰.۵۱۵, ۰.۵۱۲, ۰.۵۱۹)
ELM [۱۷] (AF:logsig, HN=۵۰)	۰.۰۸	۰.۰۱	۰.۰۶۵	۰.۱۵۸	۰.۹۵۲	۰.۰۶۵	(۰.۵۱۵, ۰.۵۱۱, ۰.۵۱۹)
ELM [۱۷] (AF:tansig, HN=۵۰)	۰.۱۰	۰.۰۴	۰.۰۸۰	۰.۵۰۵۶	۰.۹۸۲	۰.۰۸۰	(۰.۰۳۱, ۰.۰۲۳, ۰.۰۴۰)
ELM [۱۷] (AF:radbas, HN=۵۰)	۰.۱۲	۰.۰۲	۰.۰۵۵	۰.۱۳۳	۰.۹۶۵	۰.۰۵۵	(۰.۵۱۵, ۰.۵۱۱, ۰.۵۲۰)
OS-ELM [۱۸] (AF:logsig, N0:۲۰۰, B:۱)	۰.۴۷	۰	۰.۱۲۱	۰.۳۳۰	۰.۸۲۶	۰.۱۲۰	(۰.۵۱۶, ۰.۵۱۲, ۰.۵۱۹)
OS-ELM [۱۸] (AF:tansig, N0:۵۰, B:۱)	۰.۴۰	۰	۰.۲۱۱	۱.۴۹۴	۰.۸۷۰	۰.۲۱۱	(۰.۰۳۲, ۰.۰۲۵, ۰.۰۴۰)
OS-ELM [۱۸] (AF:radbas, N0:۵۰, B:۱)	۰.۵۴	۰.۰۱	۰.۱۱۱	۰.۲۹۰	۰.۸۵۵	۰.۱۱۱	(۰.۵۱۵, ۰.۵۱۱, ۰.۵۱۸)
OS-ELM [۱۸] (AF: logsig, N0:۱۱۰۰, B:۱۰۰۰)	۱.۸۳	۰.۰۳	۰.۱۹۶	۰.۳۱۵	۰.۷۵۲	۰.۱۹۲	(۰.۵۰۰, ۰.۴۹۴, ۰.۵۰۶)
OS-ELM [۱۸] (AF: tansig, N0:۱۱۰۰, B:۱۰۰۰)	۲.۰۹	۰.۰۵	۰.۱۳۴	۱.۵۴	۰.۹۵۶	۰.۱۳۲	(۰.۲۸۰, ۰.۲۷۰, ۰.۲۹۰)
OS-ELM [۱۸] (AF: radbas, N0:۱۱۰۰, B:۱۰۰۰)	۲.۰۰	۰.۰۴	۰.۱۶۲	۰.۳۱۸	۰.۸۶۳	۰.۱۳۴	(۰.۴۷۸, ۰.۴۷۴, ۰.۴۸۳)
BEL [۶] (epoch:۳۰)	۱۷.۹	۰.۲۵	۰.۳۱۰	۰.۸۱۱	۰.۳۲۳	۰.۲۷۹	(۵.۲۳۲, ۵.۰۴۰, ۵.۴۲۳)
BEL-ORMS1-ELM (AF:logsig, N0:۱۰, B:1, M:۵)	۶.۰۳	۰.۵۸	۰.۱۹۸	۰.۵۶۳	۰.۴۲۰	۰.۱۹۸	(۰.۵۱۹, ۰.۵۱۷, ۰.۵۲۰)
BEL-ORMS1-ELM (AF: tansig, N0:۱۰, B:1, M:۵)	۵.۸۱	۰.۸۸	۰.۲۷۲	۲.۰۳۴	۰.۷۸۳	۰.۲۷۱	(۰.۰۳۸, ۰.۰۳۲, ۰.۰۴۵)
BEL-ORMS1-ELM (AF: radbas, N0:۱۰, B:1, M:۵)	۶.۰۴	۰.۵۶	۰.۱۹۷	۰.۵۶۵	۰.۳۹۱	۰.۱۹۷	(۰.۵۲۰, ۰.۵۱۸, ۰.۵۲۱)
BEL-ORMS2-ELM (AF: logsig, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۳.۶۷	۰.۲۴	۰.۱۲۲	۰.۳۱۵	۰.۸۳۴	۰.۱۱۸	(۰.۵۱۶, ۰.۵۱۳, ۰.۵۲۰)
BEL-ORMS2-ELM (AF: tansig, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۳.۵	۰.۱۲	۰.۰۸۲	۰.۵۰۲	۰.۹۸۱	۰.۰۸۲	(۰.۰۳۴, ۰.۰۲۵, ۰.۰۴۲)
BEL-ORMS2-ELM (AF:radbas, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۳.۱۹	۰.۱۰	۰.۰۸۶	۰.۲۱۴	۰.۹۱۶	۰.۰۸۶	(۰.۵۲۰, ۰.۵۱۶, ۰.۵۲۴)

جدول ۶- نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی لورنز برای داده‌های تست.

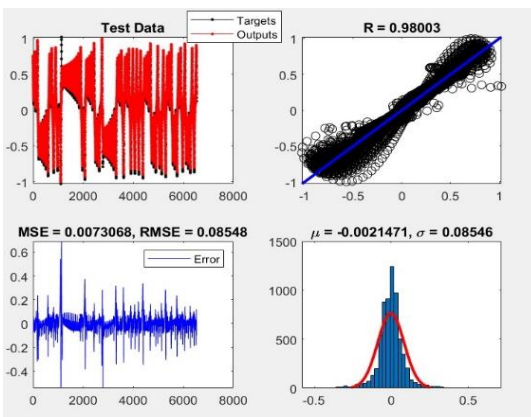
Methods	Test					
	T	RMSE	MAPE	R	eStd	(mean, CI-L, CI-U)
ELM [۱۷] (AF:logsig, HN=۱۰)	۰.۰۱	۰.۱۳۳	۰.۳۸۳	۰.۷۸۲	۰.۱۳۳	(۰.۵۱۹, ۰.۵۱۵, ۰.۵۲۳)
ELM [۱۷] (AF:tansig, HN=۱۰)	۰.۰۱	۰.۲۰۹	-۰.۱۹۹	۰.۸۷۳	۰.۲۰۹	(۰.۰۳۴, ۰.۰۲۵, ۰.۰۴۳)
ELM [۱۷] (AF:radbas, HN=۱۰)	۰	۰.۱۱۰	۰.۳۱۴	۰.۸۵۷	۰.۱۱۰	(۰.۵۲۲, ۰.۵۱۷, ۰.۵۲۶)
ELM [۱۷] (AF:logsig, HN=۵۰)	۰.۰۲	۰.۰۶۸	۰.۱۷۵	۰.۹۴۷	۰.۰۶۸	(۰.۵۱۹, ۰.۵۱۴, ۰.۵۲۴)
ELM [۱۷] (AF:tansig, HN=۵۰)	۰.۰۱	۰.۰۸۸	-۰.۲۶۶	۰.۹۷۸	۰.۰۸۸	(۰.۰۴۲, ۰.۰۳۲, ۰.۰۵۳)
ELM [۱۷] (AF:radbas, HN=۵۰)	۰.۰۱	۰.۰۵۸	۰.۱۴۹	۰.۹۶۱	۰.۰۵۸	(۰.۵۱۸, ۰.۵۱۳, ۰.۵۲۳)
OS-ELM [۱۸] (AF:logsig, N0:۲۰۰, B:۱)	۰.۰۱	۰.۱۱۹	۰.۳۴۴۳	۰.۸۳۱	۰.۱۱۹	(۰.۵۱۹, ۰.۵۱۴, ۰.۵۲۳)
OS-ELM [۱۸] (AF:tansig, N0:۵۰, B:۱)	۰.۰۱	۰.۲۱۰	-۰.۵۶۴	۰.۸۷۱	۰.۲۱۰	(۰.۰۴۱, ۰.۰۳۱, ۰.۰۵۰)
OS-ELM [۱۸] (AF:radbas, N0:۵۰, B:۱)	۰.۰۱	۰.۱۱۰	۰.۳۰۴	۰.۸۵۸	۰.۱۱۰	(۰.۵۱۶, ۰.۵۱۲, ۰.۵۲۱)
OS-ELM [۱۸] (AF:logsig, N0:۱۱۰۰, B:۱۰۰۰)	۰.۰۳	۰.۲۸۲	۰.۳۸۶	۰.۶۶۷	۰.۲۷۶	(۰.۵۳۶, ۰.۵۲۷, ۰.۵۴۶)
OS-ELM [۱۸] (AF:tansig, N0:۱۱۰۰, B:۱۰۰۰)	۰.۰۳	۰.۱۹۰	-۰.۳۹۶	۰.۹۱۸	۰.۱۸۷	(۰.۳۰۸, ۰.۲۹۵, ۰.۳۲۰)
OS-ELM [۱۸] (AF:radbas, N0:۱۱۰۰, B:۱۰۰۰)	۰.۰۳	۰.۲۰۹	۰.۳۵۹	۰.۷۹۱	۰.۱۸۹	(۰.۴۹۶, ۰.۴۸۹, ۰.۵۰۲)
BEL [۶] (epoch:۳۰)	۰.۱۸	۰.۳۰۳	۰.۸۱۵	۰.۳۵۷	۰.۲۷۲	(۵.۴۲۹, ۵.۱۹۴, ۵.۶۶۳)
BEL-ORMS1-ELM (AF:logsig, N0:۱۰, B:1, M:۵)	۰.۵۲	۰.۱۹۶	۰.۵۷۷	۰.۴۴۵	۰.۱۹۶	(۰.۵۲۱, ۰.۵۱۹, ۰.۵۲۳)
BEL-ORMS1-ELM (AF:tansig, N0:۱۰, B:1, M:۵)	۰.۶۶	۰.۲۶۵	-۰.۸۶۱	۰.۷۹۴	۰.۲۶۵	(۰.۰۴۶, ۰.۰۳۸, ۰.۰۵۴)
BEL-ORMS1-ELM (AF:radbas, N0:۱۰, B:1, M:۵)	۰.۴۹	۰.۱۹۴	۰.۵۷۷	۰.۴۲۵	۰.۱۹۴	(۰.۵۲۱, ۰.۵۲۰, ۰.۵۲۳)
BEL-ORMS2-ELM (AF:logsig, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۰.۱۴	۰.۱۲۱	۰.۳۳۱	۰.۸۳۹	۰.۱۱۷	(۰.۵۲۱, ۰.۵۱۶, ۰.۵۲۵)
BEL-ORMS2-ELM (AF:tansig, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۰.۱۷۱	۰.۰۸۴	-۰.۲۵۹	۰.۹۸۰	۰.۰۸۴	(۰.۰۴۲, ۰.۰۳۲, ۰.۰۵۳)
BEL-ORMS2-ELM (AF:radbas, N0:۱۱۰۰, B:۱۰۰۰, M:۱۰)	۰.۰۶۲	۰.۰۸۶	۰.۲۲۸	۰.۹۱۶	۰.۰۸۶	(۰.۵۲۴, ۰.۵۱۹, ۰.۵۲۹)



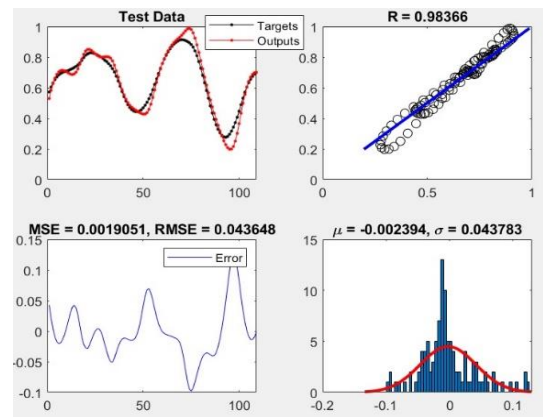
شکل ۷- نتایج شبیه‌سازی بر روی داده‌های آموزش سری زمانی آشوبی لورنز.



شکل ۵- نتایج شبیه‌سازی بر روی داده‌های آموزش سری زمانی آشوبی مکی گلاس.



شکل ۸- نتایج شبیه‌سازی بر روی داده‌های تست سری زمانی آشوبی لورنز.



شکل ۶- نتایج شبیه‌سازی بر روی داده‌های تست سری زمانی آشوبی مکی گلاس.

رگرسیون مدل پیشنهادی BEL-ORMS2-ELM با تابع فعال‌ساز $AF=tansig$ ، تعداد نمونه اولیه $N_0=1100$ ، اندازه بلوک $B=1000$ و مقدار حافظه بازگشتی $M=10$ نسبت به دیگر مدل‌ها است. به ازای معیارهای مختلف دیگر برای داده‌های آموزش و تست، مدل ELM با تابع فعال‌ساز $AF=radbas$ و تعداد نرون لایه پنهان $HN=50$ دارای بیشتری کارایی است. مدل ELM با یادگیری دسته‌ای دارای دقت و کارایی بیشتری نسبت به مدل آنلاین آن است. دلیل بیشتر بودن کارایی مدل ELM بیان شده نسبت به مدل پیشنهادی، یادگیری دسته‌ای آن است. مطابق با نتایج حاصل از جدول ۵ و جدول ۶ مشاهده می‌شود که مدل پیشنهادی نسبت به مدل‌های آنلاین دیگر دارای دقت قابل قبولی است. نتایج حاصل از شبیه‌سازی مدل پیشنهادی به ازای داده‌های آموزش و تست سری زمانی آشوبی مکی گلاس و لورنز به ترتیب در شکل (۵) الی شکل (۸) نشان داده شده است.

مطابق با نتایج حاصل از جدول ۳ و جدول ۴ به ازای معیارهای مختلف ارزیابی ذکر شده، مدل پیشنهادی BEL-ORMS2-ELM با انتخاب تابع فعال‌ساز $AF=logsig$ ، تعداد نمونه اولیه $N_0=20$ ، اندازه بلوک $B=10$ و مقدار حافظه بازگشتی $M=5$ برای داده‌های تست سری زمانی آشوبی مکی گلاس دارای بیشترین کارایی و دقت است. مقدار پارامتر رگرسیون این مدل $R=0.98154$ به ازای داده‌های تست نسبت به دیگر مدل‌ها و همچنین مدل BEL-ORMS2-ELM با تابع فعال‌ساز $AF=tansig$ با مقدار $R=0.98136$ بیشتر است. به ازای داده‌های آموزش، مقدار معیارهای ارزیابی RMSE و MAPE مدل پیشنهادی تقریباً دارای نتایج برابری با مدل ELM با تابع فعال‌ساز rbf و مدل OS-ELM با تابع فعال‌ساز $radbas$ است.

نتایج حاصل از جدول ۵ و جدول ۶ برای سری زمانی لورنز به ازای داده‌های تست نشان دهنده بیشترین مقدار

به نظر می‌رسد در شرایط دشوارتر با تعداد ورودی بیشتر، وجود نویز یا افزایش افق پیش‌بینی، مدل پیشنهادی BEL-ORMS2-ELM، تطبیق‌پذیری و دقت بیشتری نسبت به دیگر مدل‌ها داشته باشد. همچنین در صورتیکه مدل پیشنهادی بر اساس یادگیری دسته‌ای طراحی شود، می‌تواند کارایی بیشتری نسبت به مدل ELM دسته‌ای داشته باشد.

۵- نتیجه‌گیری

در تحقیق حاضر به منظور پیش‌بینی داده‌های سری‌های زمانی آشوبی مکی گلاس و لورنز از ماشین یادگیر هیجانی مغز الهام گرفته شده از سیستم لیمبیک مغز پستانداران استفاده شده است.

به منظور شبیه‌سازی ویژگی پردازش حجم عظیم داده در کمترین زمان ممکن مغز هیجانی از ماشین یادگیر مفروط استفاده می‌شود. این ماشین یادگیر دارای حداقل پارامتر قابل یادگیر و حداقل پارامتر قابل تنظیم توسط کاربر و برنامه‌نویس با قابلیت انعطاف‌پذیری، تعمیر و سرعت اجرای بالا است.

بر این اساس در مراکز پردازش اصلی آمیگدلا و اوربیتوفرانثال ماشین یادگیری هیجانی مغز از ماشین یادگیر مفروط آنلاین حافظه‌دار بازگشتی استفاده می‌شود. مدل پیشنهادی دارای عمق حافظه با قابلیت انتقال یادگیری است. عمق حافظه M و قابلیت انتقال یادگیری بر اساس وابستگی خروجی آمیگدلا در زمان t به خروجی‌های گذشته اوربیتوفرانثال در زمان‌های $t-1$ الی $t-M$ و بالعکس پیاده‌سازی می‌شود.

مدل‌های پیشنهادی ارائه شده با ماشین یادگیر مفروط با یادگیری دسته‌ای و ترتیبی آنلاین به ازای توابع فعال‌ساز و تعداد نوروں لایه پنهان مختلف و همچنین با مدل BEL مورد مقایسه و آزمایش قرار گرفته است. نتایج حاصل از شبیه‌سازی نشان دهنده کارایی بهتر مدل پیشنهادی BEL-ORMS2-ELM است.

جهت مقایسه مدل پیشنهادی با مدل‌های مشابه به ازای داده‌های سری زمانی مکی گلاس و لورنز پارامترهای اولیه در شرایط یکسان مطابق با جدول ۱ و جدول ۲ تنظیم می‌شوند. مدل‌های مختلف بر اساس معیارهای ارزیابی معتبر در پیش‌بینی مسائل رگرسیون مورد تجزیه و تحلیل و مقایسه قرار می‌گیرند.

نتایج حاصل از جدول ۳ و جدول ۴ برای داده‌های سری

زمانی مکی گلاس نشان می‌دهد که زمان مورد نیاز جهت آموزش پارامترهای مدل یادگیر (DOL) تقریباً برابر با مدل‌های یادگیر آنلاین مشابه است و نسبت به مدل یادگیری BEL مبتنی بر تکرار (epoch) دارای زمان اجرای کمتری است. زمان تست مدل به ازای داده‌های آموزش و تست نسبتاً زمان کم و قابل قبولی است. به ازای داده‌های آموزش میزان دقت و کارایی مدل‌های پیشنهادی به ازای توابع فعال‌ساز مختلف و نوع ورود داده، کمتر از مدل آنلاین ماشین یادگیر مفروط و نوع دسته‌ای آن است. اما به ازای داده‌های تست مدل پیشنهادی با تابع فعال‌ساز $\log\text{sig}$ و ورود داده‌ها به صورت دسته‌ای دارای بهترین دقت و کارایی است.

نتایج حاصل از جدول ۵ و جدول ۶ به ازای داده‌های سری زمانی لورنز نشان می‌دهد که زمان مورد نیاز جهت آموزش پارامترهای الگوریتم یادگیری (DOL) مدل‌های پیشنهادی با توابع فعال‌سازی مختلف نسبت به دیگر مدل‌ها افزایش یافته است. اما نسبت به مدل‌های مبتنی بر تکرار (BEL) دارای زمان اجرای کمتری است. این امر بدلیل آنلاین ترتیبی بودن مدل پیشنهادی و تعداد نمونه‌های ورودی است که به صورت ترتیبی وارد مدل می‌شوند. زمان تست مدل پیشنهادی به ازای داده‌های آموزش و تست تقریباً برابر با دیگر مدل‌ها است. کارایی مدل پیشنهادی با تابع فعال‌ساز tansig به ازای داده‌های آموزش با معیارهای مختلف نسبت به مدل‌های آنلاین دیگر بهتر است اما نسبت به مدل پایه ELM با آموزش دسته‌ای نسبتاً کمتر است. به ازای داده‌های تست، مدل پیشنهادی با تابع فعال‌ساز tansig دارای کمترین معیار خطای RMSE و بیشترین مقدار رگرسیون (R) نسبت به مدل‌های آنلاین است. مدل پیشنهادی در مقایسه با ELM دسته‌ای با تابع فعال‌ساز radbas ، دارای خطای بیشتر و رگرسیون بهتر است. به ازای داده‌های تست مدل پیشنهادی با تابع فعال‌ساز tansig دارای کمترین معیار خطای RMSE و بیشترین مقدار رگرسیون (R) نسبت به مدل‌های آنلاین است. مدل پیشنهادی در مقایسه با ELM دسته‌ای با تابع فعال‌ساز radbas ، دارای خطای بیشتر و رگرسیون بهتر است.

پیشنهاد می‌شود در تحقیقات آینده به منظور بهبود و توسعه معماری ماشین یادگیری هیجانی مغز، تکنیک‌ها و ماشین‌های مختلف یادگیر و الگوریتم‌های یادگیری متفاوت

کورتکس، عملیات نگاشت و کاهش ویژگی بر اساس یادگیری عمیق و در بلوک‌های اصلی آمیگدلا و اوربیتوفرانثال، سیستم‌های عصبی فازی و مدل‌های حافظه دار بازگشتی استفاده گردد.

در بلوک‌های تالاموس، کوتکس، آمیگدلا و اوربیتوفرانثال و استفاده گردد. در بلوک تالاموس بر اساس نوع دیتاست، فرمت و شکل داده‌ها انتخاب و یا تغییر داده شود. عملیات‌های انتخاب و استخراج ویژگی مبتنی بر الگوریتم‌های هوش جمعی و تکاملی استفاده گردد. در بلوک

مراجع

- [۱] راضیه محمدی و فرشید کی‌نیا، "ارائه یک روش جدید انتخاب ورودی بر اساس دسته‌بندی نیمه نظارتی برای تخمین سری‌های زمانی"، نشریه مدل‌سازی در مهندسی، دوره ۱۷، شماره ۵۹، سال ۱۳۹۸، صفحه ۱۵۳-۱۶۳.
- [۲] احسان برنجکار، "ارزیابی عملکرد شبکه‌های عصبی مصنوعی تلفیق شده با الگوریتم‌های فراابتکاری وال و مورچگان در تخمین نرخ نفوذ حفاری و مقایسه با شبکه‌های عصبی ساده و مدل‌های ریاضی مرسوم"، نشریه مدل‌سازی در مهندسی، دوره ۱۹، شماره ۶۵، سال ۱۴۰۰، صفحه ۱۱۵-۱۳۵.
- [۳] محمد مهدی ذبیحی شش‌پلی، مهدی علیاری شوره‌دلی و علی معرفیان‌پور، "تحلیل پایداری لیاپانوف در آموزش سیستم فازی-عصبی نوع ۲ با یک الگوریتم ترکیبی مبتنی بر گرادیان نزولی و فیلتر کالمن"، نشریه مدل‌سازی در مهندسی، دوره ۱۹، شماره ۶۷، سال ۱۴۰۰، صفحه.
- [4] M. Parsapoor, "Brain emotional learning-based prediction model for long-term chaotic prediction applications", arXiv preprint arXiv:1605.01681, 2016,
- [5] M. Parsapoor and U. Bilstrup, "Brain emotional learning based fuzzy inference system (belfis) for solar activity forecasting", 2012 IEEE 24th International Conference on Tools with Artificial Intelligence, Vol. 1, 2012, pp. 532-539.
- [6] J. Morén and C. Balkenius, "A computational model of emotional learning in the amygdala", From animals to animats, Vol. 6, 2000, pp. 115-124.
- [7] C. B. MorÉn, Jan, "Emotional learning: A computational model of the amygdala", Cybernetics & Systems, Vol. 32, No. 6, 2001, pp. 611-636.
- [8] J. E. LeDoux, "Emotion circuits in the brain", Annual review of neuroscience, Vol. 23, No. 1, 2000, pp. 155-184.
- [9] E. Lotfi and M.-R. Akbarzadeh-T, "Supervised brain emotional learning", The 2012 International Joint Conference on Neural Networks (IJCNN) 2012, pp. 1-6.
- [10] E. Lotfi and M.-R. Akbarzadeh-T, "Adaptive brain emotional decayed learning for online prediction of geomagnetic activity indices", Neurocomputing, Vol. 126, 2014, pp. 188-196.
- [11] E. Lotfi and M.-R. Akbarzadeh-T, "A winner-take-all approach to emotional neural networks with universal approximation property", Information Sciences, Vol. 346, 2016, pp. 369-388.
- [12] Z. Farhoudi, S. Setayeshi, and A. Rabiee, "Using learning automata in brain emotional learning for speech emotion recognition", International Journal of Speech Technology, Vol. 20, No. 3, 2017, pp. 553-562.
- [13] Z.-T. Liu, Q. Xie, M. Wu, W.-H. Cao, Y. Mei, and J.-W. Mao, "Speech emotion recognition based on an improved brain emotion learning model", Neurocomputing, Vol. 309, 2018, pp. 145-156.
- [14] E. Lotfi, O. Khazaei, and F. Khazaei, "Competitive brain emotional learning", Neural Processing Letters, Vol. 47, No. 2, 2018, pp. 745-764.
- [15] C.-M. Lin, R. Ramarao, and S. H. Gopalai, "Self-organizing adaptive fuzzy brain emotional learning control for nonlinear systems", International Journal of Fuzzy Systems, Vol. 21, No. 7, 2019, pp. 1989-2007.
- [16] N. A. Stillings, C. H. Chase, and M. H. Feinstein, Cognitive science: An introduction: MIT press, 1995.
- [17] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: Theory and applications", Neurocomputing, Vol. 70, No. 1-3, 2006, pp. 489-501.

- [18] N.-Y. Liang, G.-B. Huang, P. Saratchandran, and N. Sundararajan, "A fast and accurate online sequential learning algorithm for feedforward networks", *IEEE Transactions on Neural Networks*, Vol. 17, No. 6, 2006, pp. 1411-1423.
- [19] L. Parhizkari, A. Najafi, and M. Golshan, "Medium term electricity price forecasting using extreme learning machine", *Journal of Energy Management and Technology*, Vol. 4, No. 2, 2020, pp. 20-27.
- [20] H.-J. Rong, G.-B. Huang, N. Sundararajan, and P. Saratchandran, "Online sequential fuzzy extreme learning machine for function approximation and classification problems", *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Vol. 39, No. 4, 2009, pp. 1067-1072.
- [21] J. Tang, C. Deng, and G.-B. Huang, "Extreme learning machine for multilayer perceptron", *IEEE transactions on neural networks and learning systems*, Vol. 27, No. 4, 2016, pp. 809-821.
- [22] X. Jia, R. Wang, J. Liu, and D. M. Powers, "A semi-supervised online sequential extreme learning machine method", *Neurocomputing*, Vol. 174, 2016, pp. 168-178.
- [23] W. Zong, G.-B. Huang, and Y. Chen, "Weighted extreme learning machine for imbalance learning", *Neurocomputing*, Vol. 101, 2013, pp. 229-242.
- [24] L. Feng, S. Xu, F. Wang, S. Liu, and H. Qiao, "Rough extreme learning machine: A new classification method based on uncertainty measure", *Neurocomputing*, Vol. 325, 2019, pp. 269-282.
- [25] L. Liu, Q. Zhang, D. Wei, G. Li, H. Wu, Z. Wang, et al., "Chaotic ensemble of online recurrent extreme learning machine for temperature prediction of control moment gyroscopes", *Sensors*, Vol. 20, No. 17, 2020, p. 4786.
- [26] Y. Park and H. S. Yang, "Convolutional neural network based on an extreme learning machine for image classification", *Neurocomputing*, Vol. 339, 2019, pp. 66-76.
- [27] C. Lucas, D. Shahmirzadi, and N. Sheikholeslami, "Introducing belbic: Brain emotional learning based intelligent controller", *Intelligent Automation & Soft Computing*, Vol. 10, No. 1, 2004, pp. 11-21.
- [۲۸] مهدی گلشن، محمد تشنه لب و آرش شریفی، "ماشین یادگیر هیجانی مغز مبتنی بر ماشین یادگیر محدود فازی"، *کنگره مشترک سیستم های فازی و هوشمند ایران، بجنورد، ایران، ۹ تا ۱۱ بهمن، دوره ۷، سال ۱۳۹۷*.
- [۲۹] مهدی گلشن، محمد تشنه لب و آرش شریفی، "بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین حافظه‌دار بازگشتی مبتنی بر سیستم عصبی فازی تاکاگی سوگنو"، *مجله سیستم های فازی و کاربردها، دوره ۴، شماره ۱، سال ۱۴۰۰، صفحه ۴۷-۷۸*.
- [30] E. Lotfi and M.-R. Akbarzadeh-T, "Practical emotional neural networks", *Neural Networks*, Vol. 59, 2014, pp. 61-72.
- [31] H. S. Milad, U. Farooq, M. E. El-Hawary, and M. U. Asad, "Neo-fuzzy integrated adaptive decayed brain emotional learning network for online time series prediction", *IEEE Access*, Vol. 5, 2017, pp. 1037-1049.
- [32] S. H. Fakhrmoosavy, S. Setayeshi, and A. Sharifi, "A modified brain emotional learning model for earthquake magnitude and fear prediction", *Engineering with Computers*, Vol. 34, No. 2, 2018, pp. 261-276.
- [33] S. H. Fakhrmoosavy, S. Setayeshi, and A. Sharifi, "An intelligent method for generating artificial earthquake records based on hybrid pso-parallel brain emotional learning inspired model", *Engineering with Computers*, Vol. 34, No. 3, 2018, pp. 449-463.
- [34] S. Motamed, S. Setayeshi, and A. Rabiee, "Speech emotion recognition based on a modified brain emotional learning model", *Biologically inspired cognitive architectures*, Vol. 19, 2017, pp. 32-38.
- [35] S. Motamed, S. Setayeshi, and A. Rabiee, "Speech emotion recognition based on brain and mind emotional learning model", *Journal of integrative neuroscience*, Vol. 17, No. 3-4, 2018, pp. 577-591
- [36] C.-M. Lin and C.-C. Chung, "Fuzzy brain emotional learning control system design for nonlinear systems", *International Journal of Fuzzy Systems*, Vol. 17, No. 2, 2015, pp. 117-128.
- [37] Q. Zhou, F. Chao, and C.-M. Lin, "A functional-link-based fuzzy brain emotional learning network for breast tumor classification and chaotic system synchronization", *International Journal of Fuzzy Systems*, Vol. 20, No. 2, 2018, pp. 349-365.
- [38] C. M. Lin, H. B. Nguyen, and T. T. Huynh, "A new self-organizing double function-link brain emotional learning controller for mimo nonlinear systems using sliding surface", *IEEE Access*, Vol. 9, 2021, pp. 73826-73842.

- [39] J. Zhao, Z. Zhong, C.-M. Lin, and H.-K. Lam, " H_∞ tracking control for nonlinear multivariable systems using wavelet-type tsk fuzzy brain emotional learning with particle swarm optimization", *Journal of the Franklin Institute*, Vol. 358, No. 1, 2021, pp. 650-673.
- [40] Q. Lin, Z. Xu, and C.-M. Lin, "Battery-supercapacitor state-of-health estimation for hybrid energy storage system using a fuzzy brain emotional learning neural network", *International Journal of Fuzzy Systems*, 2021,
- [41] M. Affan and R. Uddin, "Brain emotional learning and adaptive model predictive controller for induction motor drive: A new cascaded vector control topology", *International Journal of Control, Automation and Systems*, Vol. 19, No. 9, 2021, pp. 3122-3135.