

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین حافظه دار بازگشی مبتنی بر سیستم عصبی فازی تاکاگی سوگنو

مهدی گلشن، محمد تشنه لب و آرش شریفی

گروه کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران
گروه مهندسی کنترل و سیستم، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران
گروه کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ پذیرش: ۱۴۰۰/۶/۲۹

تاریخ دریافت: ۱۴۰۰/۴/۲۶

چکیده

الگوریتم‌های مختلف طبقه‌بندی و مدل‌های پیش‌بینی در بسیاری از علوم و تکنولوژی بطور گسترده استفاده می‌شوند. در میان روشهای مختلف آنها، روش‌های داده-محور مشهور شامل مدل‌های شبکه‌های عصبی مصنوعی و فازی عصبی بدلیل ویژگی‌هایشان مورد توجه بسیاری از محققین قرار گرفته است. به منظور توسعه و غلبه بر معایب این مدلها، از مفاهیم سیستم‌های بیولوژیکی مغز انسان استفاده می‌شود. بر این اساس از سیستم لیمبیک مغز هیجانی جهت توسعه این مدل‌های استفاده می‌شود. یادگیر هیجانی مغز یک شبکه عصبی مصنوعی هیجانی مبتنی بر تعامل مولفه‌های تالاموس، کورتکس، آمیگدلا و اوربیتوفرانثال است. این ماشین یادگیر معماری و الگوریتم‌های یادگیری متفاوتی دارد.

در این مقاله از ماشین یادگیر محدود فازی آنلاین به عنوان اجزای تشکیل دهنده آمیگدلا و اوربیتوفرانثال در ماشین یادگیر هیجانی مغز استفاده می‌شود. (ادامه دارد)

عبارات و کلمات کلیدی: ماشین یادگیر هیجانی مغز، ماشین یادگیر محدود آنلاین، شبکه‌های حافظه دار بازگشتی، شبکه‌های عصبی فازی تاکاگی سوگنو

Email(s): .

۱۴۰۰ انجمن سیستم‌های فازی ایران

Mathematics Subject Classification (2010): 93C42

به منظور تعامل میان اجزای اصلی ماشین یادگیر هیجانی مغز، از ماشین یادگیر محدود فازی آنلاین حافظه دار بازگشتی با عمق حافظه مختلف با قابلیت انتقال یادگیری استفاده می‌شود. ماشین طراحی شده نهایی، ماشین یادگیر هیجانی مبتنی بر ماشین یادگیر محدود فازی حافظه‌دار بازگشتی آنلاین نامیده می‌شود. ماشین شناختی ارائه شده بر اساس یادگیری داده‌های آموزش به صورت الگو-الگو یا دسته-دسته (با طول ثابت و متغیر) طراحی شده است و می‌تواند داده‌های آموزشی را که قبلاً آموزش دیده اند را کنار بگذارد. مقایسه کارایی روش پیشنهادی با روشهای یادگیری مشابه بر روی مسائل سریهای زمانی آشوبی انجام می‌شود. نتایج تجزیه و تحلیل و شبیه‌سازی نشان می‌دهد که کارایی و دقت روش پیشنهادی بیشتر از سایر روش‌ها است.

۱ مقدمه

الگوریتم‌های طبقه‌بندی و مدل‌های پیش‌بینی در بسیاری از علوم مهندسی، صنعت، کسب و کار، اقتصاد و پزشکی به طور گسترده استفاده می‌شوند. در میان روشهای مختلف طبقه‌بندی و پیش‌بینی، تکنیک‌های مبتنی بر داده الهام گرفته شده از مدل‌های زیست‌شناسی همانند شبکه‌های عصبی مصنوعی، سیستم‌های استنتاج نرو فازی و تکنیک‌های محاسبات تکاملی بدلیل قابلیت‌های خودسازمان‌دهی و تعمیم‌دهی بالا بیشترین علاقه‌مندی را در میان محققین دارند و در اکثر کاربردها مورد استفاده قرار گرفته می‌شوند.

این مدلها دقت قابل قبولی در پیش‌بینی غیرخطی سریهای زمانی آشوبی دارند. با این وجود دارای برخی معایب از قبیل بیشبرازش، پیچیدگی مدل، نفرین ابعاد، تعداد زیاد پارامتر یادگیر و ... جهت دستیابی به دقت مناسب می‌باشند. بنابراین توسعه و ارائه یک مدل جهت افزایش دقت و حل معایب مذکور به عنوان یک چالش و موضوع تحقیقاتی در یادگیری ماشین می‌گیرند.

محققان در جستجوی ساختارهای جدید و توسعه الگوریتم‌های یادگیری در کاربردهای مختلف برای شبکه‌های عصبی مصنوعی می‌باشند. بر این اساس الهام گرفتن از مغز هیجانی جهت توسعه شبکه‌های عصبی مصنوعی مورد توجه واقع شده 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. ویژگی‌های بیان شده انگیزه اصلی محققان در طراحی مدل یادگیر هیجانی مغز^۱ (BEL) با الهام گرفتن از مغز هیجانی می‌باشد. 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^۲، شبکه‌های عصبی فازی تطبیقی^۳ (ANFIS)، آتاماتای سلولی^۴ (CA) و یا دیگر ابزارهای طبقه‌بندی و پیش‌بینی استفاده کرد.

ماشین یادگیر محدود^۵ (ELM) یک شبکه عصبی پیشرو تک لایه^۶ (SLFN) یک شبکه عصبی پیشرو تک لایه با ساختار و قانون یادگیری ساده و سریع است [۱، ۲] که مشتقات و مدل‌های توسعه یافته‌های از آن ارائه شده است. این ماشین یادگیر در بسیاری از زمینه‌های کاربردی از جمله در علوم مهندسی برق جهت پیش‌بینی قیمت برق مورد استفاده قرار می‌گیرد [۳]. برخی از مدل‌های توسعه یافته ELM عبارتند از ماشین یادگیر محدود آنلاین^۷ (OS-ELM) [۴]، ماشین یادگیر محدود فازی آنلاین^۸ (OS-FELM) [۵، ۶]، شبکه‌های یادگیری عمیق مبتنی بر ماشین یادگیر محدود [۷، ۸]، ماشین یادگیر محدود آنلاین نیمه نظارت شده و بدون نظارت^۹ [۹، ۱۱]، ماشین یادگیر محدود وزندار برای یادگیری نمونه‌های نامتعادل^{۱۰} (W-ELM) [۱۱].

ماشین یادگیر محدود و برخی از مشتقات توسعه یافته آن می‌توانند به عنوان عنصر اصلی و بلوک سازنده در بخش‌های مختلف ماشین یادگیر هیجانی مغز بکار گرفته شوند و بر این اساس ماشین یادگیر هیجانی مغز مبتنی بر ماشین یادگیر محدود^{۱۱} (BELELM) با قابلیت‌های جدید ارائه می‌شود.

¹ Brain Emotional Learning (BEL)

² Radial Basis Function (RBF)

³ Adaptive Network-Based Fuzzy Inference System (ANFIS)

⁴ Cellular Automaton

⁵ Extreme Learning Machine

⁶ Single hidden Layer Feed forward Neural network

⁷ Online Sequential Extreme Learning Machine (OS-ELM)

⁸ Online Sequential Fuzzy ELM (OS-FELM)

⁹ Semi-Supervised and Unsupervised Extreme Learning Machines

¹⁰ Weighted extreme learning machine for imbalance learning (W-ELM)

¹¹ Brain Emotional Learning Based Extreme Learning Machine (BEL-ELM)

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین — ۵۰

در روش پیشنهادی از ماشین یادگیر محدود فازی آنلاین حافظه دار بازگشتی^{۱۲} (ORMS-FELM) مبتنی بر سیستم استنتاج عصبی فازی تاکاگی سوگنو^{۱۳} مرتبه ۰ یا ممدانی (TSK0) و تاکاگی سوگنو (TSK1) استفاده می‌شود. ماشین‌های ارائه شده در بلوک‌های اصلی آمیگدلا و اوربیتوفران‌تال ماشین یادگیر هیجانی مغز بکار گرفته می‌شوند. براین اساس ماشین یادگیر هیجانی مغز مبتنی بر ماشین یادگیر محدود فازی آنلاین حافظه‌دار بازگشتی^{۱۴} (BEL-ORMS-FELM) طراحی می‌شود. خروجی نهایی مدل پیشنهادی براساس ترکیب خطی وزندار حاصل از بلوک‌های اصلی بیان شده محاسبه می‌شود. با توجه به طراحی انجام گرفته براساس ورودی داده‌ها به صورت الگو-الگو و دسته-دسته (۲ حالت) و نوع ماشین یادگیر محدود فازی ارائه شده (۲ حالت، در نهایت ۴ مدل پیشنهادی معرفی می‌شود.

۲ پیشینه تحقیق

۱.۲ ماشین یادگیر محدود

ماشین یادگیر محدود 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 براساس 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^{۱۵} وابسته نیستند. علت نامگذاری این شبکه عصبی مصنوعی به ماشین یادگیر محدود، حداقل

¹² Online Recurrent Memory Sequential Fuzzy ELM (ORMS-FELM)

¹³ Takagi Sugeno Kang (TSK)

¹⁴ Brain Emotional Learning Based on Online Recurrent Memory Sequential Fuzzy ELM (BEL-ORMS-FELM) Epoch

¹⁵ Epoch

پارامتر مورد نیاز جهت انتخاب توسط برنامه‌نویس و حداقل پارامتر قابل یادگیر است. ساختار این ماشین با n ورودی و ۱ خروجی در شکل ۱ نشان داده شده است.

براساس N مجموعه داده / الگو و تعداد n ویژگی (x_1, \dots, x_n) ، تابع فعالساز $g(x)$ و تعداد نودهای لایه پنهان L ، گام‌های این الگوریتم به صورت زیر است [۲، ۱]:
گام ۱: در صورتیکه $L, \dots, 1 = i$ انتخاب شود، وزنه‌های a_i و بایاس b_i به صورت تصادفی مقدردهی می‌شوند.

گام ۲: ماتریس خروجی لایه پنهان (H) براساس نورونهای افزایشی^{۱۶} با توابع فعالساز مختلف همانند یک شبکه عصبی مصنوعی پرسپترون، نورونهای مبتنی بر توابع شعاعی و یا مشتقات دیگر همانند سیستم‌های فازی عصبی محاسبه می‌شود. نحوه تولید ماتریس لایه پنهان به ازای تابع فعالساز g در رابطه (۱) نشان داده شده است.

$$H(a_1, \dots, a_L, b_1, \dots, b_L, x_1, \dots, x_N) = \begin{bmatrix} g(a_1, b_1, x_1) & \dots & g(a_L, b_L, x_1) \\ \dots & \dots & \dots \\ g(a_1, b_1, x_N) & \dots & g(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (1)$$

گام ۳: وزنه‌های خروجی β براساس روابط زیر محاسبه می‌شود.

$$\|H(a_1, \dots, a_L, b_1, \dots, b_L) \cdot \hat{\beta} - T\| = \min_{\beta} \|H(a_1, \dots, a_L, b_1, \dots, b_L) \cdot \beta - T\| \quad (2)$$


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

۲.۲ ماشین یادگیر محدود آنلاین

قانون یادگیری در ماشین یادگیر محدود آنلاین با توجه به ورود N داده‌ها ورودی به صورت الگو-الگو یا دسته-دسته و $T = [t_1, t_2, \dots, t_N]^T$ خروجی واقعی به صورت زیر است [۴]:

فاز اولیه: محاسبه وزن لایه خروجی Out براساس ماتریس لایه پنهان H ، خروجی

¹⁶ Additive Neuron



شکل ۱: ساختار ماشین یادگیر محدود.

واقعی T_0 به ازای تعداد N_0 داده ورودی اولیه به صورت زیر است :

$$H_0 = \begin{bmatrix} g(a_1, b_1, x_1) & \cdots & g(a_L, b_L, x_1) \\ \dots & \dots & \dots \\ g(a_1, b_1, x_{N_0}) & \cdots & g(a_L, b_L, x_{N_0}) \end{bmatrix}_{N_0 \times L} \quad (۴)$$

$$P_0 = (H_0^T H_0)^{-1} \quad (۵)$$

$$\beta^0 = P_0 \cdot H_0^T \cdot T_0 \quad (۶)$$

$$Out_0 = H_0 \times \beta^0 \quad (۷)$$

فاز یادگیری ترتیبی : بروزسانی وزن لایه خروجی Out_{k+1} در مرحله $k + 1$ براساس ماتریس لایه پنهان H_{k+1} ، خروجی واقعی $T_{k+1} = [t_{(\sum_{j=0}^k N_j)+1}, \dots, t_{(\sum_{j=0}^{k+1} N_j)}]^T$ به ازای ورود داده‌ها به صورت الگو-الگو یا دسته-دسته (بلوک-بلوک (B)) با اندازه

مشخص یا متغیر) به صورت زیر است:

$$H_{k+1} = \begin{bmatrix} g(a_1, b_1, x_{(\sum_{j=0}^k N_j)+1}) & \cdots & g(a_L, b_L, x_{(\sum_{j=0}^k N_j)+1}) \\ \cdots & \cdots & \cdots \\ g(a_1, b_1, x_{(\sum_{j=0}^k N_j)}) & \cdots & g(a_L, b_L, x_{(\sum_{j=0}^k N_j)}) \end{bmatrix}_{N_{k+1} \times L} \quad (۸)$$

$$P_{k+1} = P_k - P_k H_{k+1}^T (\lambda + H_{k+1} P_k H_{k+1}^T)^{-1} \times H_{k+1} P_k \quad (۹)$$

$$\beta^{k+1} = \beta^k + P_{k+1} H_{k+1} (T_{k+1}^T - H_{k+1}^T \cdot \beta^k) \quad (۱۰)$$

$$Out_{k+1} = H_{k+1} \times \beta^{k+1} \quad (۱۱)$$

۳.۲ شبکه عصبی فازی تطبیقی

ساختار شبکه‌های عصبی فازی تطبیقی مبتنی بر توابع پایه‌های شعاعی براساس مدل فازی تاکاگی سوگنو مرتبه ۰ یا ممدانی یا مرتبه ۱ در ۵ لایه مختلف مطابق با رابطه (۱۲) الی رابطه (۱۵) به صورت زیر معرفی می‌شود:

لایه ۱ : هر نود به عنوان متغیر ورودی نشان داده می‌شود.

لایه ۲ : هر نود مقادیر عضویت متغیر ورودی را نشان می‌دهد. مطابق با عملکرد مشابه بین شبکه عصبی مبتنی بر توابع پایه‌های شعاعی و سیستم استنتاج فازی^{۱۷} (FIS)، بخش مقدم در قوانین فازی بخش if توسط تابع گوسی شبکه توابع پایه‌ای شعاعی طراحی می‌شود. مقادیر عضویت $A_{ik}(x_i)$ از i امین متغیر ورودی x_i در k امین تابع گوسی به صورت زیر محاسبه می‌شود:

$$A_{ik}(x_i) = \exp\left(-\frac{(x_i - \mu_{ik})^2}{\sigma_k^2}\right), \quad k = 1, 2, \dots, L \quad (۱۲)$$

لایه ۳ : هر نود در این لایه بخش اگر از قوانین اگر- آنگاه را بوسیله ترکیب ضرب یا جمع نشان می‌دهد و بصورت زیر تعریف می‌شود:

$$R_k(X) = \prod_{i=1}^u A_{ik}(x_i) = \exp\left(-\frac{(x_i - \mu_{ik})^2}{\sigma_k^2}\right) \quad (۱۳)$$

¹⁷ Fuzzy Inference System (FIS)

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین — ۵۴

لایه ۴ : نودهای این لایه عملیات نرمالیزه شدن را انجام می‌دهند و به صورت زیر تعریف می‌شود:

$$\bar{R}_k = \frac{R_k(x)}{\sum_{k=1}^L R_k(x)} \quad (14)$$

لایه ۵ : هر نود نشان دهنده جمع وزندار خروجی هر قانون نرمالیزه شده است و به صورت زیر محاسبه می‌شود :

$$y = \frac{\sum_{k=1}^L w_k \times R_k(x)}{\sum_{k=1}^L R_k(x)} = \sum_{k=1}^L \beta_k \times \bar{R}_k(x) \quad (15)$$

در مدل سیستم فازی تاکاگی سوگنو مرتبه ۱ بجای w_k از ترکیب خطی ورودیهای مطابق با رابطه زیر استفاده می‌شود. در این روابط q_{ik} ها ضرائب خطی تابع ورودیها یا بخش تالی فازی سیستم می‌باشند.

$$y = \frac{\sum_{k=1}^L f_k \times R_k(x)}{\sum_{k=1}^L R_k(x)} = \sum_{k=1}^L \beta_k \times \bar{R}_k(x) \\ = \sum_{k=1}^L (q_{0k} + q_{1k} \cdot x_1 + q_{2k} \cdot x_2 + \dots + q_{ik} \cdot x_i) \times \bar{R}_k(x) \quad (16)$$

۴.۲ ماشین یادگیر محدود فازی آنلاین

تفاوت ماشین یادگیر محدود فازی آنلاین با ماشین یادگیر محدود آنلاین در روش تولید و ساخت ماتریس لایه پنهان (H) است. در این ماشین بجای استفاده از نورونهای افزایشی و نورونهای مبتنی بر توابع پایه‌های شعاعی در لایه های پنهان از قوانین فازی ($Rule$ ها) تولید شده در بخش مقدم استفاده می‌شود. متغیرهای $TSK0$ و $HTSK \setminus H$ به ترتیب ماتریس لایه پنهان خروجی در ماشین یادگیر محدود فازی ممدانی آنلاین OS-FTSK0ELM ($TSK0$) و ماشین یادگیر محدود فازی تاکاگی سوگنو آنلاین ($TSK1$) OS-FTSK1ELM

به صورت زیر معرفی می‌شوند [۵، ۶].

$$\begin{aligned}
 H_{TSK^0}(\mu_1, \dots, \mu_L, \sigma_1, \dots, \sigma_L, x_1, \dots, x_N) &= [h_1, \dots, h_N]^T \\
 &= \begin{bmatrix} \bar{R}(\mu_1, \sigma_1, x_1) & \dots & \bar{R}(\mu_L, \sigma_L, x_1) \\ \dots & \dots & \dots \\ \bar{R}(\mu_1, \sigma_1, x_N) & \dots & \bar{R}(\mu_L, \sigma_L, x_N) \end{bmatrix}_{N \times L} \quad (17)
 \end{aligned}$$

$$\begin{aligned}
 H_{TSK^1}(\mu_1, \dots, \mu_L, \sigma_1, \dots, \sigma_L, x_1, \dots, x_N) &= \begin{bmatrix} \bar{R}(\mu_1, \sigma_1, x_1) & \dots & \bar{R}(\mu_L, \sigma_L, x_N) \\ \dots & \dots & \dots \\ \bar{R}(\mu_L, \sigma_L, x_1) & \dots & \bar{R}(\mu_L, \sigma_L, x_N) \end{bmatrix}^T \\
 &= \begin{bmatrix} \bar{R}(\mu_1, \sigma_1, x_1) \cdot x_{11} & \dots & \bar{R}(\mu_1, \sigma_1, x_N) \cdot x_{1N} \\ \dots & \dots & \dots \\ \bar{R}(\mu_L, \sigma_L, x_1) \cdot x_{11} & \dots & \bar{R}(\mu_L, \sigma_L, x_N) \cdot x_{1N} \end{bmatrix} \\
 &= \begin{bmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \bar{R}(\mu_1, \sigma_1, x_1) \cdot x_{u1} & \dots & \bar{R}(\mu_1, \sigma_1, x_N) \cdot x_{uN} \\ \bar{R}(\mu_L, \sigma_L, x_1) \cdot x_{u1} & \dots & \bar{R}(\mu_L, \sigma_L, x_N) \cdot x_{uN} \end{bmatrix}_{L(u+1) \times N} \quad (18)
 \end{aligned}$$

در این روابط x ورودی‌ها μ و σ پارامترهای ورودی که به صورت تصادفی مقداردهی می‌شوند و \bar{R} قوانین فازی تولید شده به صورت نرمال، N تعداد نمونه‌ها، L تعداد نورون‌های لایه پنهان که در این ماشین برابر تعداد قوانین می‌باشد و u تعداد ورودیها است. ماتریس لایه پنهان به ازای ورودی x_1 به صورت $h_1 = [\bar{R}(\mu_1, \sigma_1, x_1), \dots, \bar{R}(\mu_1, \sigma_1, x_N)]$ به ازای مقادیر مختلف پارامترهای σ و μ تعریف می‌شود. الگوریتم یادگیری آنلاین در این ماشین همانند الگوریتم یادگیری در ماشین یادگیر محدود آنلاین مطابق با رابطه (۴) الی رابطه (۱۱) است. ماتریس لایه پنهان

در فاز اولیه به ازای N_0 نمونه برای مدل فازی TSK^0 و TSK^1 به ترتیب براساس رابطه (۱۹) و رابطه (۲۱) محاسبه می‌شوند. همچنین ماتریس لایه پنهان در فاز یادگیری در مرحله $k+1$ و براساس تعداد n نمونه $(n = N_0 + 1, N_0 + 2, N_0 + 3, \dots, N_0 + p)$ داده به ترتیب براساس رابطه (۲۱) و رابطه (۲۲) محاسبه می‌شوند. p شماره آخرین نمونه است.

$$H_{TSK^0} = H(\mu_1, \dots, \mu_L, \sigma_1, \dots, \sigma_L, x_1, \dots, x_{N_0}) = [h_1, \dots, h_{N_0}]^T \quad (19)$$

$$\begin{aligned} H_{TSK^1} &= H(\mu_1, \dots, \mu_L, \sigma_1, \dots, \sigma_L, x_1, \dots, x_{N_0}) \\ &= [h_1, \dots, h_{N_0}, \dots, (h_1, \dots, h_{N_0}) \cdot x_{un^0}] \end{aligned} \quad (20)$$

$$\begin{aligned} H_{(k+1)TSK^0} &= [h_{(N_0+1)}, h_{(N_0+2)}, h_{(N_0+3)}, \dots, h_{(N_0+p)}]^T \\ &= [\bar{R}(\mu_1, \sigma_1, x_n), \dots, \bar{R}(\mu_L, \sigma_L, x_n)]^T \end{aligned} \quad (21)$$

$$\begin{aligned} H &= (k[\bar{R} + 1(\mu_{TSK^1}, \sigma_1, x_n), \dots, \bar{R}(\mu_L, \sigma_L, x_n), \dots, \\ &\quad \bar{R}(\mu_1, \sigma_1, x_n) \cdot x_{un}, \dots, \bar{R}(\mu_L, \sigma_L, x_n) \cdot x_{n \cdot un}]^T \end{aligned} \quad (22)$$

۵.۲ ماشین یادگیر هیجانی مغز و مدل‌های بهبود یافته آن

ماشین شناختی یادگیر هیجانی مغز در چهارچوب مدلسازی شناختی مطرح و تحت عنوان شبکه‌های عصبی مصنوعی هیجانی^{۱۸} شناخته و الگوریتم خاصی را جهت تنظیم وزنه‌های آن ساختار ارائه می‌کند. این شبکه‌ها از یافته‌های وابسته به کالبدشناسی لداکس^{۱۹} الهام گرفته شده است [۱۲، ۱۴]. نتیجه تحقیقات انجام گرفته نشان دهنده مسیرهای مشخص انتشار سیگنال مغز هیجانی است.

بدلیل وجود مسیرهای کوتاه‌تر در مغز هیجانی، محرک‌های احساسی سریعتر از محرک‌های معمولی پردازش می‌شوند.

¹⁸Emotional Artificial Neural Network (EANN)

¹⁹ LeDux

پردازش‌های سریع در حجم عظیم اطلاعات، محققان را بر آن داشته است تا از مغز هیجانی الگوبرداری کنند و مدل‌های الهام گرفته شده را در کاربردهای مختلف مهندسی بکار گیرند.

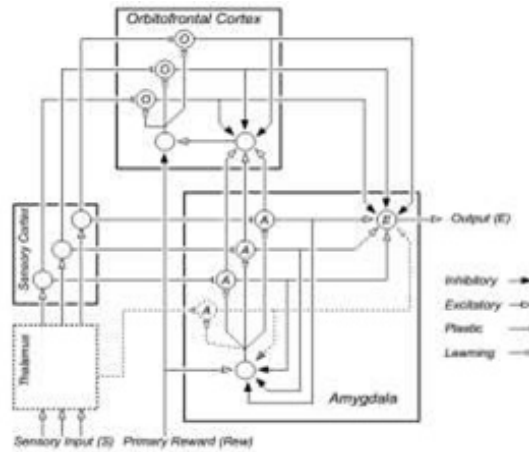
پیاده‌سازی کامپیوتری مدل ماشین یادگیر هیجانی مغز مبتنی بر مفاهیم هیجان و مغز هیجانی در شکل ۲ ارائه شده است [۱۵، ۱۶]. در این معماری از دو ماشین یادگیرنده موازی استفاده می‌شود. این دو ماشین در قالب دو عامل در یک سیستم چندعامله، دو پردازنده یا ماکرو نورون به صورت موازی بر روی اطلاعات پردازش‌های لازم را انجام می‌دهند، با یکدیگر تعامل می‌کنند و بعد از همگرایی، خروجی مطلوب را تولید می‌کنند. خروجی مدل بر اساس ترکیب وزندار سیگنال‌های بازدارنده و کنترل کننده اوربیتوفران‌تال و هیجانی آمیگدلا تولید می‌شود.

به منظور توسعه، بهبود و رفع مشکلات ماشین و مدل شناختی پایه ماشین یادگیر هیجانی، تحقیقات متعددی از منظر ساختار، معماری و الگوریتم یادگیری ارائه شده است. در [۱۷] یک کنترل‌کننده هوشمند براساس مجموع وزندار عاملها تعریف شده است. در [۱۸] به منظور توسعه ماشین یادگیر هیجانی مغز از ماشین یادگیر محدود آنلاین و ماشین یادگیر محدود فازی آنلاین به عنوان بلوک‌های اصلی آمیگدلا و اوربیتوفران‌تال استفاده شده است. در [۱۹] مدل هیجانی مغز براساس سیستم استنتاج عصبی فازی و در [۲۱] یک معماری شناختی براساس ترکیب شبکه عصبی توابع پایهای شعاعی و (K) مینیم همسایگی وزندار ارائه شده است. ماشین یادگیر هیجانی مبتنی بر یادگیری فراموشی حافظه با یادگیری حالات هیجانی در [۲۱] ارائه شده است. در [۲۲] مدل $ADBEL^{20}$

[۲۳، ۲۴] بهبود یافته و از نورونهای فازی در بخش اوربیتوفران‌تال سیستم لیمبیک مغز استفاده و ماشین $NFADBEL^{21}$ معرفی می‌شود. طراحی ساختار رقابتی عصبی کورتکس و ساختار یادگیری هیجانی در [۲۵، ۲۶] معرفی شده است. در این مقالات تعامل میان شناخت و هیجان مدل‌سازی شده است. همچنین در [۲۷، ۲۸] ماشین یادگیر هیجانی مغز توسعه یافته جهت شناسایی زلزله و ترس معرفی شده است. در [۲۸] رکوردهای زلزله

²⁰ Adaptive Decayed Brain Emotional Learning (ADBEL)

²¹ Neo-Fuzzy integrated ADBEL (NF-ADBEL)



شکل ۲: ماشین یادگیر هیجانی مغز ارائه شده توسط مورن [۱۱، ۱۲].

مصنوعی براساس ترکیب الگوریتم هوش ازدحامی ذرات و ماشین یادگیر هیجانی تولید شده است.

مدل‌های بهبودیافته ماشین یادگیر هیجانی مغز در سیستم شناسایی گفتار هیجانی نیز بکارگرفته شده است [۲۹]–[۳۲]. در [۲۹] از آتاماتای یادگیر جهت الگوریتم یادگیری در ماشین یادگیر هیجانی، در [۳۱] از شبکه‌های عصبی مصنوعی چندلایه پرسپترون^{۲۳} (MLP) و عصبی فازی تطبیقی جهت بهبود مدل یادگیر هیجان مغز، در [۳۱] جهت کاهش ویژگی از ترکیب تجزیه و تحلیل مولفه اصلی^{۲۳} (PCA) و تجزیه و تحلیل تفکیک خطی^{۲۴} (LDA) و از الگوریتم ژنتیک جهت آموزش پارامترهای مدل یادگیر هیجان مغز ارائه شده در [۲۵] و در [۳۲] 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 [۳۳، ۳۴]. در [۳۳] سیستم کنترل یادگیری هیجانی مغز فازی در طراحی سیستم‌های غیرخطی معرفی و یک کنترلکننده یادگیر هیجان مغز^{۲۵} با قوانین استنتاج فازی ارائه شد. در [۳۴] جهت طبقه‌بندی تومور سرطان سینه و همزمانسازی سیستم‌های آشوبی از شبکه یادگیر هیجان

^{۲۳} Multilayer perceptron (MLP)

^{۲۳} Principal Component Analysis (PCA)

^{۲۴} Linear Discriminant Analysis (LDA)

^{۲۵} Brain Emotional Learning Controller (BELC)

مغز مبتنی بر شبکه‌های عصبی پیوند تابع ۲۶ استفاده شد. در [۳۵] از یک کنترل کننده یادگیر هیجانی مغز فازی تطبیقی خودسازمانده جهت سیستم‌های غیر خطی استفاده شد. تحقیقات مختلف انجام گرفته جهت توسعه ماشین یادگیر هیجانی مغز نشاندهنده توسعه مدل پایه یادگیری هیجانی مغز براساس 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

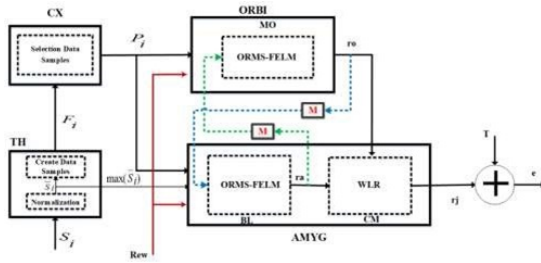
ماشین یادگیر هیجانی مغز پایه مطابق با شکل ۲ شامل بخش‌های اصلی تالاموس (TH)، کورتکس (CX)، اوربیتوفرانیتال (ORBI)، آمیگدلا (AMYG) است. بلوک دیاگرام روش پیشنهادی جهت توسعه این ماشین در شکل ۲۴ نشان داده شده است.

در بخش تالاموس داده‌های دریافت شده از محیط (S_i) به شکل و فرمت مناسب (F_i) تبدیل می‌شوند. ماکزیمم ورودهای دریافت شده ($\max(\bar{S}_i)$) محاسبه و مستقیماً از تالاموس به آمیگدلا ارسال می‌شوند. در بخش کورتکس اطلاعات دریافت شده از تالاموس (F_i) به بخش‌های آمیگدلا و اوربیتوفرانیتال (P_i) ارسال می‌شوند. عملیاتها و پردازشهای لازم بر روی اطلاعات بدست آمده از تالاموس در این بخش انجام می‌شود. پردازشهایی از قبیل تغییر شکل ویژگیهای بدست آمده ورودی همانند انتخاب ویژگی / استخراج ویژگی، نگاشت، کاهش و مهندس ویژگی. پردازشهای اصلی بر روی ویژگیهای نهایی بدست آمده (P_i) در مرکز BL آمیگدلا و MO اوربیتوفرانیتال انجام و خروجی های آمیگدلا (r_a) و اوربیتوفرانیتال (r_a) را تولید میکنند. این ۲ مرکز اصلی پردازش در علوم مهندسی توسط تکنیکها، ابزارها و مدل‌های مختلف ارائه شده در هوش مصنوعی و یادگیری ماشین شبیه‌سازی می‌شوند.

خروجی نهایی پیش‌بینی براساس خروجیهای آمیگدلا و اوربیتوفرانیتال در بخش CM آمیگدلا محاسبه می‌شود.

در بلوک دیاگرام روش پیشنهادی براساس نوع داده‌های استفاده شده مبتنی بر داده‌های سریهای زمانی آشوبی، پیش پردازشهای لازم همانند نرمالیزه کردن ورودیها و انتخاب

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین — ۶۰



شکل ۳: ماشین یادگیر هیجانی مغز مبتنی بر ماشین یادگیر محدود فازی آنلاین حافظه دار بازگشتی (BEL-ORMS-FELM)

فرمت سریهای زمانی به شکل قابل استفاده برای مدل‌های مبتنی بر شبکه‌های عصبی و سیستم فازی در بخش تالاموس انجام می‌شود. انتخاب نمونه‌ها و الگوهای ورودی و خروجی براساس افق پیش‌بینی آینده براساس اطلاعات زمانی گذشته در بخش کورتکس انجام می‌شود. در صورت نیاز عملیاتهای استخراج، کاهش و نگاهت ویژگی در این بخش انجام می‌شوند. اطلاعات و مفاهیم بدست آمده از این بلوک جهت پردازش وارد ماکرو نورونهای و پردازندههای اصلی آمیگدلا و اوربیتوفراتال می‌شود. این دو بخش توسط ماشین یادگیر محدود فازی آنلاین حافظه‌دار بازگشتی (BEL-ORMS-FELM) پیاده‌سازی می‌شوند. بخش (CM) آمیگدلا براساس مدل ترکیب خطی وزندار ورودی‌ها مبتنی بر الگوریتم حداقل مربعات وزندار^{۲۷} (WLS) یا رگرسیون خطی وزندار^{۲۸} (RLS) پیاده‌سازی می‌شود.

۱.۳ طراحی بخش BL آمیگدلا و MO اوربیتوفراتال

به منظور طراحی یک مدل جهت پردازش حجم عظیم اطلاعات در زمان پاسخگویی سریع و الهام گرفتن از مغز هیجانی از ماشین یادگیر هیجان مغز استفاده می‌شود. به منظور استفاده از یک مدل سریع با کمترین پارامتر قابل تنظیم و پارامتر قابل یادگیری از ماشین یادگیر محدود استفاده می‌شود. جهت پیاده‌سازی عدم قطعیت مشابه با عملکرد سیستم زیستی مغز انسان از شبکه‌های عصبی فازی تطبیقی استفاده می‌شود. این شبکه‌ها می‌تواند در قالب ماشین یادگیر محدود توصیف و منجر به طراحی ماشین یادگیر محدود

²⁷ Weighted Least Squares (WLS)

²⁸ Weighted Linear Regression (WLR)

فازی شوند. ماتریس لایه خروجی در این شبکه‌ها براساس اینکه سیستم عصبی فازی به صورت ممدانی (TSK0) و یا تاکاگی سوگنو (TSK1) استفاده شود به ترتیب مطابق با رابطه (۱۷) و رابطه (۱۸) محاسبه و بنام‌های FTSK0ELM و FTSK1ELM نامیده می‌شوند.

در صورتی‌که داده‌های به صورت ترتیبی و آنلین وارد مدل شوند ماشین یادگیر محدود فازی آنلین معرفی می‌شود. قانون یادگیری در این ماشین همانند قانون یادگیری آنلین در ماشین یادگیر محدود آنلین است. تفاوت آن در نوع ماتریس لایه‌های پنهان تولید شده است. ماشین یادگیر محدود فازی آنلین مبتنی بر سیستم نروفازی ممدانی و تاکاگی سوگنو بیان شده به ترتیب OS-FTSK0ELM و OS-FTSK1ELM نامیده می‌شوند.

در معماری ارائه شده، خروجیهای زمان t آمیگدلا و اوربیتوفرانتال به ترتیب به خروجیهای اوربیتوفرانتال و آمیگدلا در زمانهای $t - 1$ الی $t - M$ وابسته می‌شوند و ویژگی حافظه دار بازگشتی با قابلیت انتقال یادگیری را در مدل پیشنهادی شبیه‌سازی می‌کنند. M مقدار عمق حافظه را نشان می‌دهد. خروجی‌ها در هر لحظه، به M مقدار خروجی قبل وابسته هستند و هر خروجی براساس ورودی‌های به صورت الگو-الگو یا دسته-دسته محاسبه می‌شود. براساس نوع سیستم ممدانی و تاکاگی سوگنو استفاده شده در ماشین یادگیر محدود آنلین با قابلیت حافظه‌دار بازگشتی، ماشین‌های طراحی شده به ترتیب ORMS-FTSK0ELM و ORMS-FTSK1ELM نامیده می‌شوند. اگر داده‌های ورودی به صورت الگو-الگو وارد سیستم شود، ماشین‌های طراحی شده به ترتیب براساس نوع سیستم فازی ممدانی و تاکاگی سوگنو ORMS1-FTSK0ELM و ORMS1-FTSK1ELM نامیده می‌شوند. در صورتیکه داده‌های ورودی به صورت دسته-دسته وارد شوند ماشین‌های طراحی شده به ترتیب ORMS2-FTSK0ELM و ORMS2-FTSK1ELM نامیده می‌شوند. و چنانچه ماشین‌های یادگیر محدود فازی آنلین بیان شده در معماری ارائه شده در شکل ۲۴ در بخشهای آمیگدلا و اوربیتوفرانتال استفاده شوند، ماشین یادگیر هیجانی مغز مبتنی بر ماشین یادگیر محدود فازی آنلین (BEL-OS-FELM) براساس قابلیت حافظه دار بازگشتی و نحوه ورود داده‌ها به صورت الگو-الگو یا دسته-دسته به ترتیب به نام‌های BEL-ORMS1-FTSK0ELM، BEL-ORMS2-FTSK0ELM، مبتنی بر سیستم

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین — ۶۲

فازی ممدانی و BEL-ORMS2-FTSK1ELM، BEL-ORMS1-FTSK1ELM مبتنی بر سیستم فازی تاکاگی سوگنو طراحی می‌شوند.

ماشین یادگیر محدود آنلاین دارای کارایی خوبی نسبت به حالت دستهای^{۲۹} 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 براساس مقدار حافظه M در زمانهای گذشته $t - 1$ الی $t - M$ وابسته خواهند شد. طراحی براساس 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-FELM می‌شود.

الگوریتم یادگیری BEL-ORMS-FLEM پیشنهادی مبتنی بر نوع سیستم عصبی فازی ممدانی و تاکاگی سوگنو از ۲ مرحله مقداردهی اولیه و مرحله یادگیری ترتیبی تشکیل شده است. در مرحله اولیه براساس تعداد N_0 نمونه از داده‌ها، ماتریس لایه پنهان H_0 تشکیل و سپس در مرحله یادگیری این ماتریس بروزرسانی می‌شود. در مرحله یادگیری ترتیبی براساس ورودی داده‌ها به صورت الگو-الگو یا دسته-دسته ماتریس لایه پنهان در مرحله $k + 1$ و خروجی‌ها به صورت ترتیبی محاسبه می‌شوند.

مرحله مقداردهی اولیه:

در این مرحله براساس تعداد N_0 نمونه از دیتاست یادگیری شروع می‌شود. پارامترهای لایه ورودی μ و σ بخش مقدم سیستم عصبی فازی به صورت تصادفی مقداردهی و ماتریس لایه پنهان آمیگدلا (H_{0a}) و اوربیتوفرانانتال (H_{0o}) مطابق با روابط زیر براساس معماری پیشنهادی در شکل ۲۴ محاسبه می‌شوند. مطابق با رابطه (۲۳) در ماتریس لایه پنهان آمیگدلا H_{0a} ، وابستگی، تعامل و تاثیرگذاری خروجی‌های اوربیتوفرانانتال $(r_{j_0}(t-1), \dots, r_{j_0}(t-M))$ بر آمیگدلا نشان داده شده است. ماتریس لایه پنهان آمیگدلا براساس N_0 نمونه اولیه، L قانون فازی تولید شده، M عمق حافظه و ترکیب ماتریس لایه پنهان آمیگدلا مبتنی بر قوانین تولید شده ماشین یادگیر محدود فازی $(h_{1a}, \dots, h_{N_0a})$ و خروجی‌های حاصل از اوربیتوفرانانتال در M زمان گذشته $(r_{j_0}(t-1), \dots, r_{j_0}(t-M))$ محاسبه می‌شود. رابطه بیان شده برای N_0 نمونه اولیه

²⁹ Batch-ELM

جهت وابستگی اوربیتوفران탈 به خروجیهای آمیگدلا محاسبه و ماتریس لایه پنهان خروجی اوربیتوفران탈 مطابق با رابطه (۲۴) محاسبه می‌شود.

$$\begin{aligned}
 H_{\circ a} &= (\mu_{\backslash a}, \dots, \mu_{La}, \sigma_{\backslash a}, \dots, \sigma_{La}, x_{\backslash}, \dots, x_{N_{\circ}}, r_{\backslash}, \dots, r_{N_{\circ}o}) \\
 &= \begin{bmatrix} h_{\backslash a} & r_{\backslash o}(t-1) & \dots & r_{\backslash o}(t-M) \\ \dots & \dots & \dots & \dots \\ h_{N_{\circ}a} & r_{N_{\circ}o}(t-1) & \dots & r_{N_{\circ}o}(t-M) \end{bmatrix}_{N_{\circ} \times (L+M)} \quad (23)
 \end{aligned}$$

$$\begin{aligned}
 H_{\circ o} &= (\mu_{\backslash o}, \dots, \mu_{Lo}, \sigma_{\backslash o}, \dots, \sigma_{Lo}, x_{\backslash}, \dots, x_{N_{\circ}}, r_{\backslash a}, \dots, r_{N_{\circ}a}) \\
 &= \begin{bmatrix} h_{\backslash o} & r_{\backslash a}(t-1) & \dots & r_{\backslash a}(t-M) \\ \dots & \dots & \dots & \dots \\ h_{N_{\circ}o} & r_{N_{\circ}a}(t-1) & \dots & r_{N_{\circ}a}(t-M) \end{bmatrix}_{N_{\circ} \times (L+M)} \quad (24)
 \end{aligned}$$

تخمین وزن لایه خروجی اولیه آمیگدلا (β_{oa}) براساس ماتریس لایه پنهان آمیگدلا به ازای N_{\circ} خروجی واقعی $T_{\circ} = [t_1, t_2, \dots, t_{N_{\circ}}]^T$ خروجی پیش‌بینی آمیگدلا (Out_{oa}) به ترتیب در رابطه (۲۶) و رابطه (۲۷) براساس قوانین یادگیری بیان شده در ماشین یادگیر محدود انلاین OS-ELM محاسبه می‌شوند. روابط بیان شده جهت محاسبه وزن لایه خروجی اولیه و خروجی پیش‌بینی اوربیتوفران탈 در رابطه (۲۹) و رابطه (۳۱) محاسبه می‌شوند.

$$\beta_{\circ a} = P_{\circ a} \cdot H_{\circ a}^T \cdot T_{\circ} \quad (25)$$

$$P_{\circ a} = (H_{\circ a}^T \cdot H_{\circ a})^{-1} \quad (26)$$

$$Out_{\circ a} = H_{\circ a} \times \beta_{\circ a} \quad (27)$$

$$\beta_{\circ o} = P_{\circ o} \cdot H_{\circ o}^T \cdot T_{\circ} \quad (28)$$

$$P_{\circ o} = (H_{\circ o}^T \cdot H_{\circ o})^{-1} \quad (29)$$

$$Out_{\circ o} = H_{\circ o} \times \beta_{\circ o} \quad (30)$$

مرحله یادگیری ترتیبی:

با مشاهده p نمونه جدید در مرحله $k + 1$ ، به ازای ورودی داده $n = N_0 + 1, N_0 + 2, \dots, N_0 + p$ ، ماتریس لایه پنهان آمیگدلا $H_{(k+1)a}$ و اوربیتوفرائنتال $H_{(k+1)o}$ به ازای خروجی واقعی $T_{k+1} = [t_{(\sum_{j=0}^k N_j)+1}, \dots, t_{(\sum_{j=0}^k N_j)+p}]^T$ برای سیستم فازی ممدانی TSK0 به ترتیب در رابطه (۳۲) و رابطه (۳۱) محاسبه می‌شوند. یادگیری ترتیبی در سیستم فازی تاکاگی سوگنو TSK1 مطابق با رابطه (۳۳) و رابطه (۳۴) است.

$$\begin{aligned}
H_{(k+\lambda)a} &= H(\mu_{\lambda a}, \dots, \mu_{La}, \sigma_{\lambda a}, \dots, \sigma_{La}, x_{(N_c+\lambda)}, \dots, x_{(N_c+p)}, r_{(N_c+\lambda)o}, \dots, x_{(N_c+p)o}) \\
&= \begin{bmatrix} \bar{R}(\mu_{\lambda a}, \sigma_{\lambda a}, x_{(N_c+\lambda)}) & \bar{R}(\mu_{La}, \sigma_{La}, x_{(N_c+\lambda)}) & r_{(N_c+\lambda)o}(t-1) & \dots & r_{(N_c+\lambda)o}(t-M) \\ \bar{R}(\mu_{\lambda a}, \sigma_{\lambda a}, x_{(N_c+p)}) & \bar{R}(\mu_{La}, \sigma_{La}, x_{(N_c+p)}) & r_{(N_c+p)o}(t-1) & \dots & r_{(N_c+p)o}(t-M) \end{bmatrix}_{n \times (L+M)}
\end{aligned} \tag{۳۱}$$

$$\begin{aligned}
H_{(k+\lambda)o} &= H(\mu_{\lambda o}, \dots, \mu_{Lo}, \sigma_{\lambda o}, \dots, \sigma_{Lo}, x_{(N_c+\lambda)}, \dots, x_{(N_c+p)}, r_{(N_c+\lambda)a}, \dots, x_{(N_c+p)a}) \\
&= \begin{bmatrix} \bar{R}(\mu_{\lambda o}, \sigma_{\lambda o}, x_{(N_c+\lambda)}) & \bar{R}(\mu_{Lo}, \sigma_{Lo}, x_{(N_c+\lambda)}) & r_{(N_c+\lambda)a}(t-1) & \dots & r_{(N_c+\lambda)a}(t-M) \\ \bar{R}(\mu_{\lambda o}, \sigma_{\lambda o}, x_{(N_c+p)}) & \bar{R}(\mu_{Lo}, \sigma_{Lo}, x_{(N_c+p)}) & r_{(N_c+p)a}(t-1) & \dots & r_{(N_c+p)a}(t-M) \end{bmatrix}_{n \times (L+M)}
\end{aligned} \tag{۳۲}$$

$$\begin{aligned}
 H_{(k+1)\alpha} &= H(\mu_{1\alpha}, \dots, \mu_{L\alpha}, \sigma_{1\alpha}, \dots, \sigma_{L\alpha}, x(N_c+1), \dots, x(N_c+p), \tau(N_c+1)\alpha, \dots, x(N_c+p)\alpha) \\
 &= \left[\begin{array}{cccc} \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+1)) & \bar{R}(\mu_{L\alpha}, \sigma_{L\alpha}, x(N_c+1)) & \dots & \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+1)) \cdot x_{un} \\ \dots & \dots & \dots & \dots \\ \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+p)) & \bar{R}(\mu_{L\alpha}, \sigma_{L\alpha}, x(N_c+p)) & \dots & \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+p)) \cdot x_{un} \end{array} \right] \cdot x_{un} \\
 &= \left[\begin{array}{cccc} \tau_{(N_c+1)\alpha}(t-1) & \dots & \dots & \tau_{(N_c+1)\alpha}(t-M) \\ \dots & \dots & \dots & \dots \\ \tau_{(N_c+p)\alpha}(t-1) & \dots & \dots & \tau_{(N_c+p)\alpha}(t-M) \end{array} \right] \cdot x_{un} \quad (33)
 \end{aligned}$$

$$\begin{aligned}
 H_{(k+1)\alpha} &= H(\mu_{1\alpha}, \dots, \mu_{L\alpha}, \sigma_{1\alpha}, \dots, \sigma_{L\alpha}, x(N_c+1), \dots, x(N_c+p), \tau(N_c+1)\alpha, \dots, x(N_c+p)\alpha) \\
 &= \left[\begin{array}{cccc} \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+1)) & \bar{R}(\mu_{L\alpha}, \sigma_{L\alpha}, x(N_c+1)) & \dots & \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+1)) \cdot x_{un} \\ \dots & \dots & \dots & \dots \\ \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+p)) & \bar{R}(\mu_{L\alpha}, \sigma_{L\alpha}, x(N_c+p)) & \dots & \bar{R}(\mu_{1\alpha}, \sigma_{1\alpha}, x(N_c+p)) \cdot x_{un} \end{array} \right] \cdot x_{un} \\
 &= \left[\begin{array}{cccc} \tau_{(N_c+1)\alpha}(t-1) & \dots & \dots & \tau_{(N_c+1)\alpha}(t-M) \\ \dots & \dots & \dots & \dots \\ \tau_{(N_c+p)\alpha}(t-1) & \dots & \dots & \tau_{(N_c+p)\alpha}(t-M) \end{array} \right] \cdot x_{un} \quad (34)
 \end{aligned}$$

تخمین وزن لایه خروجی در مرحله $k + 1$ آمیگدلا و خروجی پیش‌بینی آمیگدلا $(Out_{(k+1)a})$ به ترتیب در رابطه (۳۶) و رابطه (۳۷) محاسبه می‌شوند. تخمین وزن لایه خروجی $(\beta_{(k+1)a})$ در مرحله $k + 1$ و خروجی پیش‌بینی $(Out_{(k+1)o})$ اوربیتوفران‌تال در رابطه (۳۹) و رابطه (۴۱) محاسبه می‌شوند.

$$P_{(k+1)a} = P_{ka} H_{(k+1)a}^T (\mathbf{1} + H_{(k+1)a} P_{ka} H_{(k+1)a}^T)^{-1} \times H_{(k+1)a} P_{ka} \quad (35)$$

$$\beta_{(k+1)a} = \beta_{ka} + P_{(k+1)a} H_{(k+1)a} (T_{k+1}^T - H_{(k+1)a}^T \cdot \beta_{ka}) \quad (36)$$

$$Out_{(k+1)a} = H_{(k+1)a} \cdot \beta_{(k+1)a} \quad (37)$$

$$P_{(k+1)o} = P_{ko} - P_{ko} H_{(k+1)o}^T (\mathbf{1} + H_{(k+1)o} P_{ko} H_{(k+1)o}^T)^{-1} \times H_{(k+1)o} P_{ko} \quad (38)$$

$$\beta_{(k+1)o} = \beta_{ko} + P_{(k+1)o} H_{(k+1)o} (\mathbf{1} + H_{(k+1)o} P_{ko} H_{(k+1)o}^T)^{-1} \cdot \beta_{ko} \quad (39)$$

$$Out_{(k+1)o} = H_{(k+1)o} \cdot \beta_{(k+1)o} (T_{k+1}^T - H_{(k+1)o}^T \cdot \beta_{ko}) \quad (40)$$

۴ طراحی بخش CM آمیگدلا

خروجی‌های حاصل از بلوک‌های اصلی MO اوربیتوفران‌تال $(r_o = Out_o)$ و BL آمیگدلا $(r_a = Out_a)$ وارد بخش CM آمیگدلا می‌شوند. این بخش همانند یک نورون ساده عصبی است. خروجی آن براساس رابطه (۴۱) مطابق با الگوریتم حداقل مربعات وزندار یا رگرسیون خطی وزندار محاسبه می‌شود. پارامترهای خطی خروجی w شامل

$$w = [w_1, w_2, w_3]$$

براساس الگوریتم یادگیری کمترین مربعات خطا^{۳۰} (LSE) و براساس مقادیر ماتریس $A = [r_{a'}, r_{o'}, \mathbf{1}]$ مطابق با رابطه (۴۲) محاسبه می‌شوند در این روابط O_{cm} خروجی CM آمیگدلا، خروجی نهایی ماشین یادگیر هیجانی مغز پیشنهادی یا خروجی پیش‌بینی و

³⁰ Least Square Estimator (LSE)

T خروجی واقعی است.

$$O_{cm} = w_1 \cdot r_a + w_2 \cdot r_o + w_3 \quad (41)$$

$$w = (A^T A)^{-1} A^T T \quad (42)$$

۵ تجزیه و تحلیل نتایج

براساس 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 براساس معیارهای خاص در این حوزه مورد ارزیابی قرار می‌گیرد.

۱.۵ پایگاه داده مورد بررسی

به منظور راستی آزمایی روش پیشنهادی با روشهای مشابه، خروجی سری مکیگلاس در زمان $x(t + 85)$ براساس زمانهای گذشته $x(t - 18)$ ، $x(t - 12)$ ، $x(t - 6)$ ، $x(t - 1)$ پیش‌بینی می‌شود. همچنین خروجی با افق بیشتر $x(t + 30)$ سری زمانی لورنز براساس اطلاعات گذشته $x(t)x(t - 1)$ و $x(t - 2)$ پیش‌بینی می‌گردد.

۲.۵ نتایج بدست آمده

داده‌های سری زمانی جهت ارائه به مدلها به شکل مناسب تبدیل و در بازه $[-1, +1]$ نرمالیزه می‌شوند. به ترتیب مقادیر ۹۱٪ و ۶۱٪ از داده‌های سری زمانی مکیگلاس 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^{۳۱} (AF) و توابع عضویت^{۳۲} (MF)،

³¹ Activation Function (AF)

³² Membership Function (MF)

تعداد نورون لایه پنهان ^{۳۳} (HN)، تعداد توابع عضویت ^{۳۴} (NMF)، تعداد نمونه اولیه از داده‌ها ^{۳۵} (N_0)، تعداد داده‌های ورودی به صورت بلوک-بلوک یا دسته-دسته (B)، مقدار حافظه یا وابستگی به اطلاعات گذشته (M) می‌باشد. پارامترهای بیان شده به ازای سری زمانی مکیگلاس و لورنز به ترتیب در جدول ۱ و جدول ۲ ارائه شده است.

بلوک‌های اصلی استفاده شده در ماشین یادگیر هیجانی مغز، ماشین یادگیر محدود فازی مددانی آنلاین OS-FTSK0ELM و ماشین یادگیر محدود فازی تاکاگی سوگنو آنلاین OS-FTSK1ELM هستند. بنابراین مدل‌های پیشنهادی با این ۲ مدل اصلی و سازنده مورد مقایسه قرار می‌گیرند.

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

Model	MF	NMF	N_0	B	M
OS-FTSK0ELM	gussi	۱۰	۱۰	۱	-
OS-FTSK1ELM	gussi	۱۰	۱۰	۱	-
BEL-ORMS1-FTSK0ELM	gussi	۱۰	۱	۱	۵
BEL-ORMS2-FTSK0ELM	gussi	۱۰	۲۰	۱۰	۵
BEL-ORMS1-FTSK1ELM	gussi	۱۰	۱	۱	۵
BEL-ORMS2-FTSK1ELM	gussi	۱۰	۲۰	۱۰	۵

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

Model	MF	NMF	N_0	B	M
OS-FTSK0ELM	gussi	۵۰	۵۰	۱	-
OS-FTSK1ELM	gussi	۵۰	۵۰	۱	-
BEL-ORMS1-FTSK0ELM	gussi	۱۰	۱	۱	۵
BEL-ORMS2-FTSK0ELM	gussi	۵۰	۱۱۰۰	۱۰۰۰	۱۰
BEL-ORMS1-FTSK1ELM	gussi	۱۰	۱	۱	۵
BEL-ORMS2-FTSK1ELM	gussi	۵۰	۱۱۰۰	۱۰۰۰	۱۰

به منظور ارزیابی روش پیشنهادی از معیارهای مدت زمان آموزش آنلاین ^{۳۶} (DOL) جهت آموزش پارامترهای مدل براساس داده‌های آموزش، مدت زمان اجرای تست مدل به ازای داده‌های آموزش و تست ($TestTime$)، ($TrainTime$)، میانگین مربعات

³³ Hidden Neurons (HN)

³⁴ Number of Membership Function (NMF)

³⁵ Initial Training Set (N_0)

³⁶ Duration of Online Learning (DOL)

بهبود ماشین یادگیر هیجانی مغز با الهام از ماشین یادگیر محدود فازی آنلاین — ۷۰

خط ^{۳۷} (MSE) و جذر آن ^{۳۸} (RMSE)، رگرسیون ^{۳۹} (R)، منحنی تغییرات خروجی واقعی و خروجی مدل پیش‌بینی، میانگین و واریانس خطا استفاده می‌شود. برنامه‌های نوشته شده در محیط برنامه‌نویسی (MatlabR2017b)، در شرایط یکسان با سیستمی به مشخصات (RAM) (۸GB)، (CPU core i5\6GHz) اجرا شده است. نتایج حاصل از شبیه‌سازی و مقایسه مدل‌های مختلف به ازای سری زمانی مکی‌گلاس و لورنز به ترتیب در جدول ۳ و جدول ۴ ارائه شده است. به ازای هر مدل برنامه به تعداد تکرار مشخص (۵ مرتبه) اجرا و سپس میانگین آن گزارش می‌گردد.

مطابق با نتایج حاصل از جدول ۳ مشاهده می‌شود که به ازای ورودی داده‌ها به صورت دسته-دسته در سیستم فازی (TSK^o) و (TSK¹)، مدل‌های BEL-ORMS2-FTSK1ELM و BEL-ORMS2-FTSK0ELM دارای دقت بیشتری نسبت به دیگر مدلها هستند. همچنین نتایج حاصل از جدول ۴ نشان دهنده دقت بیشتر مدل BEL-ORMS2-FTSK1ELM نسبت به دیگر مدلها به ازای داده‌های آموزش و تست است. به نظر میرسد در شرایط دشوارتر با تعداد ورودی بیشتر، وجود نویز یا افزایش آفق پیش‌بینی، مدل مبتنی بر سیستم نرو فازی تاکاگی سوگنو دستهای (BEL-ORMS2-FTSK1ELM) بتواند تطبیق‌پذیری و دقت بیشتر خود را نسبت به دیگر مدلها نشان دهد. نتایج حاصل از شبیه‌سازی این مدل بر روی داده‌های آموزش و تست سری زمانی آشوبی مکی‌گلاس و لورنز به ترتیب در شکل ۴ الی شکل ۷ نشان داده شده است.

جدول ۳: نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی مکی‌گلاس.

Methods	Train				Test				
	DOL	Time	MSE	RMSE	R	Time	MSE	RMSE	R
OS-FTSK\ELM	۰.۷۰۶۲	۰.۲۵۲	۰.۱۳۲	۰.۱۱۵۲	۰.۸۳۲۶	۰.۴۳۷	۰.۰۴۶	۰.۶۷۶	۰.۹۵۰۹
OS-FTSK\ELM	۲.۵۴۳۷	۰.۲۵۲	۰.۱۳۳	۰.۱۱۵۵	۰.۸۳۱۶	۰.۴۳۱	۰.۰۴۳	۰.۶۵۹	۰.۹۵۶۴
BEL-ORMS1-FTSK ^o ELM	۰.۷۳۷۴	۰.۲۸۷۴	۰.۲۹۱	۰.۱۷۰۱	۰.۵۹۰۷	۰.۵۳۰	۰.۲۶۲۸	۰.۱۵۹۱	۰.۷۶۴۴
BEL-ORMS2-FTSK ^o ELM	۱.۳۳۷۵	۰.۵۴۰۶	۰.۱۲۲	۰.۱۱۰۴	۰.۸۹۸۶	۰.۱۴۰۶	۰.۰۳۷	۰.۶۰۸	۰.۹۶۱۱
BEL-ORMS1-FTSK ¹ ELM	۲.۵۹۳۷	۰.۴۹۶۸	۰.۳۰۲	۰.۱۷۳۲	۰.۵۵۲۳	۰.۴۷۸	۰.۲۷۲	۰.۱۶۳۷	۰.۶۲۸۳
BEL-ORMS2-FTSK ¹ ELM	۲.۴۷۵	۰.۵۱۲۴	۰.۱۲۹	۰.۱۱۳۵	۰.۸۹۳۱	۰.۱۲۸	۰.۰۳۹	۰.۶۲۴	۰.۹۶۰۱


³⁷ Mean squared error (MSE)

³⁸ Root Mean squared error (RMSE)

³⁹ Regression (R)

جدول ۴: نتایج حاصل از شبیه‌سازی مدل‌های مختلف به ازای سری زمانی لورنز.

Methods	DOL	Time	Train		R	Test		R	
			MSE	RMSE		Time	MSE		RMSE
OS-FTSK0ELM	۴۹,۷۴۳۷	۸,۴۵۹۳	۰,۰۰۸۲	۰,۰۰۹۰۴	۰,۹۰۶۳	۴,۹۵۶۲	۰,۰۰۸۶	۰,۰۰۹۲۹	۰,۹۰۱۰
OS-FTSK\ELM	۱۱۰,۹۱	۱۳,۱۶۸	۰,۰۰۸۲	۰,۰۰۹۰۲	۰,۹۰۵۹	۷,۲۸۱۲	۰,۰۰۸۷	۰,۰۰۹۲۹	۰,۹۰۰۵
BEL-ORMS\FTSK\ELM	۴,۸۸۴	۴,۲۲۱۸	۰,۰۰۳۸۷	۰,۰۱۹۶۸	۰,۴۰۳۶	۲,۸۶۲۳	۰,۰۰۳۸۰	۰,۰۰۱۹۵۰	۰,۴۲۵۲
BEL-ORMS\FTSK\ELM	۱۸,۰۵۳	۱۲,۸۳۱	۰,۰۰۰۴۴	۰,۰۰۶۶۱	۰,۹۵۱۰	۱۱,۲۴۳	۰,۰۰۰۴۶	۰,۰۰۶۸۰	۰,۹۴۸۴
BEL-ORMS\FTSK\ELM	۶,۸۱۲۱	۶,۷۵۶۰	۰,۰۰۳۸۹	۰,۰۱۹۷۰	۰,۸۳۰۰	۳,۶۷۵	۰,۰۰۳۷۸	۰,۰۰۱۹۴۳	۰,۴۱۰۹
BEL-ORMS\FTSK\ELM	۱۸,۱	۱۱,۴۴۶۹	۰,۰۰۰۲۹	۰,۰۰۵۲۸	۰,۹۶۷۴	۸,۰۳۷۳	۰,۰۰۰۳۶	۰,۰۰۵۹۸	۰,۹۶۳۶




شکل ۴: نتایج شبیه‌سازی مدل پیشنهادی به ازای داده‌های آموزش سری زمانی آشوبی مکیگلاس.

۶ نتیجه‌گیری

تشخیص و پیش‌بینی داده‌ها در قالب سری زمانی یکی از مهم‌ترین مسائل در دنیای واقعی است. ارائه یک مدل و معماری پیش‌بینی جدید در حوزه داده‌های سری زمانی یک چالش اساسی است. به منظور توسعه تکنیک‌های مبتنی بر داده از ساختار یادگیری هیجانی مغز استفاده می‌شود. در ساختار و اجزای این ماشین از ماشین یادگیر محدود با حداقل پارامتر ممکن قابل یادگیری و حداقل پارامتر قابل تنظیم توسط کاربر و حداکثر سرعت اجرا استفاده شده است.

شبیه‌سازی به ازای ساختار ماشین یادگیر هیجانی مغز با استفاده از نورونهای مبتنی بر سیستم‌های عصبی فازی مدانی BEL-ORMS-FTSK0ELM(TSK0) و تاکاگی سوگنو BEL-ORMS-FTSK1ELM (TSK1) به ازای ورودی داده‌ها به صورت الگو-الگو-دسته-دسته انجام و ۴ مدل پیشنهادی ارائه شد. در مدل‌های پیشنهادی براساس




شکل ۵: نتایج شبیه‌سازی مدل پیشنهادی به ازای داده‌های تست سری زمانی آشوبی مکیگلاس.

ساختار حافظه‌دار بازگشتی پیاده‌سازی شده در بخشهای آمیگدلا و اوربیتوفرانտال، خروجی در هر بلوک اصلی در زمان t به M خروجی قبل در زمان‌های $t + 1$ الی $t - M$ بلوک اصلی دیگر وابسته و قابلیت یادگیری انتقالی در آن پیاده‌سازی می‌شود.

مدل‌های پیشنهادی ارائه شده با ماشین یادگیر محدود فازی آنلاین ممدانی (OS-FTSK0ELM) و تاکاگی سوگنو (OSFTSK1ELM) مورد مقایسه و آزمایش قرار گرفته است. نتایج حاصل از شبیه‌سازی مدل‌های ارائه شده و نتایج بدست آمده از جداول و شکلها، نشان دهنده کارایی بهتر روش پیشنهادی (BEL-ORMS2-FTSK1ELM) یعنی ماشین یادگیر هیجانی مغز الهام گرفته شده از ماشین یادگیر محدود فازی آنلاین حافظه‌دار بازگشتی است.

۷ پیشنهادات آینده

به منظور توسعه ساختار ماشین یادگیر هیجانی مغز می‌توان در بخشهای اصلی MO اوربیتوفرانտال و BL آمیگدلا از شبکه‌های عصبی فازی، شبکه‌های مبتنی بر نورونهای راف و یا سیستم‌های فازی نوع II استفاده کرد. همچنین استفاده از مشتقات مختلف ماشین یادگیر محدود و یا شبکه‌های یادگیر دیگر پیشنهاد می‌شود. در بخش CM آمیگدلا می‌توان شبکه‌های مختلف استفاده شده در MO و BL را نیز استفاده نمود.




شکل ۶: نتایج شبیه‌سازی مدل پیشنهادی به ازای داده‌های آموزش سری زمانی آشوبی لورنز.

جهت یادگیری و آموزش پارامترهای مختلف بخشهای بیان شده می‌توان از الگوریتم‌های یادگیری مختلف و یا الگوریتم‌های تکاملی همانند الگوریتم ژنتیک استفاده کرد. پیشنهاد می‌شود براساس مفهوم عملکرد بخش کورتکس سیستم لیمبیک مغز هیجانی از تکنیکها و ابزارهای انتخاب و استخراج ویژگی و یا نگاشت ویژگی همانند یادگیری عمیق استفاده شود. استفاده از ماشین یادگیر محدود براساس قابلیت‌های آن در بخشهای مختلف ماشین یادگیر هیجان مغز می‌تواند منجر به افزایش سرعت اجرای این مدل شناختی و تطبیق‌پذیری بیشتر آن با سیستم بیولوژیکی سیستم لیمبیک مغز شود.

مراجع

- [1] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in *2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541)*, 2004, pp. 985-990.
- [2] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, pp. 489-501, 2006.



شکل ۷: نتایج شبیه‌سازی مدل پیشنهادی به ازای داده‌های تست سری زمانی آشوبی لورنز.

- [3] L. Parhizkari, A. Najafi, and M. Golshan, "Medium term electricity price forecasting using extreme learning machine," *Journal of Energy Management and Technology*, vol. 4, pp. 20-27, 2020.
- [4] 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. 11, pp. 1411-1423, 2006.
- [5] G.-B. Huang, N.-Y. Liang, H.-J. Rong, P. Saratchandran, and N. Sundararajan, "On-Line Sequential Extreme Learning Machine," *Computational Intelligence*, vol. 2005, pp. 232-237, 2005.
- [6] 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, pp. 1067-1072, 2009.
- [7] J. Tang, C. Deng, and G.-B. Huang, "Extreme learning machine for multilayer perceptron," *IEEE transactions on neural networks and learning systems*, vol. 27, pp. 809-821, 2016.

- [8] L. L. C. Kasun, H. Zhou, G.-B. Huang, and C. M. Vong, "Representational learning with ELMs for big data," 2013.
- [9] G. Huang, S. Song, J. N. Gupta, and C. Wu, "Semi-supervised and unsupervised extreme learning machines," *IEEE transactions on cybernetics*, vol. 44, pp. 2405-2417, 2014.
- [10] X. Jia, R. Wang, J. Liu, and D. M. Powers, "A semi-supervised online sequential extreme learning machine method," *Neurocomputing*, vol. 174, pp. 168-178, 2016.
- [11] W. Zong, G.-B. Huang, and Y. Chen, "Weighted extreme learning machine for imbalance learning," *Neurocomputing*, vol. 101, pp. 229-242, 2013.
- [12] J. LeDoux, "Emotion and the limbic system concept," *Concepts in neuroscience*, vol. 2, pp. 169-199, 1991.
- [13] J. LeDoux, *The emotional brain: The mysterious underpinnings of emotional life*: Simon and Schuster, 1998.
- [14] J. E. LeDoux, "Emotion circuits in the brain," *Annual review of neuroscience*, vol. 23, pp. 155-184, 2000.
- [15] J. Morén and C. Balkenius, "A computational model of emotional learning in the amygdala," *From animals to animats*, vol. 6, pp. 115-124, 2000.
- [16] J. Moren, *Emotion and learning-A computational model of the amygdala* vol. 93: Lund University Cognitive Science, 2002.
- [17] C. Lucas, D. Shahmirzadi, and N. Sheikholeslami, "Introducing BELBIC: brain emotional learning based intelligent controller," *Intelligent Automation Soft Computing*, vol. 10, pp. 11-21, 2004.

- [18] M. Golshan, A. Sharifi, and M. Teshnehlab, "Brain Emotional Learning based on Fuzzy Extreme Learning Machine," *7th Iranian Joint Congress on Fuzzy and Intelligent System*, pp. 770-776, 2019.
- [19] M. Parsapoor and U. Bilstrup, "Brain Emotional Learning Based Fuzzy Inference System (BELFIS) for Solar Activity Forecasting," in *2012 IEEE 24th International Conference on Tools with Artificial Intelligence*, 2012, pp. 532-539.
- [20] M. Parsapoor, "Brain Emotional Learning-Based Prediction Model For Long-Term Chaotic Prediction Applications (BELPM)," *arXiv preprint arXiv:1605.01681*, 2016.
- [21] E. Lotfi and M.-R. Akbarzadeh-T, "Practical emotional neural networks," *Neural Networks*, vol. 59, pp. 61-72, 2014.
- [22] 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, pp. 1037-1049, 2017.
- [23] E. Lotfi and M.-R. Akbarzadeh-T, "Supervised brain emotional learning," in *Neural Networks (IJCNN), The 2012 International Joint Conference on*, 2012, pp. 1-6.
- [24] E. Lotfi and M.-R. Akbarzadeh-T, "Adaptive brain emotional decayed learning for online prediction of geomagnetic activity indices," *Neurocomputing*, vol. 1, pp. 188-196, 2014.
- [25] E. Lotfi and M.-R. Akbarzadeh-T, "A winner-take-all approach to emotional neural networks with universal approximation property," *Information Sciences*, vol. 346, pp. 369-388, 2016.
- [26] E. Lotfi, O. Khazaei, and F. Khazaei, "Competitive Brain Emotional Learning," *Neural Processing Letters*, vol. 47, pp. 745-764, 2018.

- [27] S. H. Fakharmoosavy, S. Setayeshi, and A. Sharifi, "A modified brain emotional learning model for earthquake magnitude and fear prediction," *Engineering with Computers*, pp. 1-16, 2017.
- [28] S. H. Fakharmoosavy, 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*, pp. 1-1.2111, 5.
- [29] 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, pp. 553-562, 2017.
- [30] S. Motamed, S. Setayeshi, and A. Rabiee, "Speech emotion recognition based on a modified brain emotional learning model," *Biologically inspired cognitive architectures*, vol. 19, pp. 32-38, 2017.
- [31] 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*, 2018.
- [32] S. Motamed, S. Setayeshi, and A. Rabiee, "Speech emotion recognition based on brain and mind emotional learning model," *Journal of integrative neuroscience*, pp. 1-15, 2018.
- [33] C.-M. Lin and C.-C. Chung, "Fuzzy brain emotional learning control system design for nonlinear systems," *International Journal of Fuzzy Systems*, vol. 17, pp. 117-128, 2015.
- [34] 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, pp. 349-365, 2018.

- [35] 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, pp. 1989-2007, 2019.