



Semnan University

# Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>



## Research Article

# Observer-based adaptive emotional controller for a class of uncertain nonlinear systems

Fahimeh Baghbani<sup>1,\*</sup>

1. Assistant professor, Department of Electrical and Computer Engineering, Semnan University

\*Corresponding Author: [baghbani.fahimeh@semnan.ac.ir](mailto:baghbani.fahimeh@semnan.ac.ir)

## PAPER INFO

### Paper history:

Received: 25 November 2022

Revised: 23 March 2023

Accepted: 11 April 2023

### Keywords:

Emotional neural networks, observer-based adaptive control, Lyapunov stability theory,  $H_\infty$  tracking performance.

## ABSTRACT

Uncertainties and complexities of the actual control problems, such as unknown dynamics, unmeasurable states, external disturbances, and measurement noise, require powerful control structures capable of handling such complexities. Emotional controllers offer fast system response while also carrying a simple structure. However, the emotional controllers to date have not been evaluated rigorously. Here, the continuous radial basis emotional neural network (CRBENN) is employed to approximate the unknown dynamics in observer-based adaptive control structures for uncertain affine nonlinear systems. The system dynamics are unknown. Also, external disturbance and measurement noise affect system performance. Compared to the previous emotional controllers for affine nonlinear systems, the system states are not measurable and are estimated using a state estimator. The  $H_\infty$  tracking performance is verified using Lyapunov stability theory, and suitable adaptive laws are designed for the weights of the proposed emotional networks that are consistent with the basic brain emotional learning model. Results indicate that the proposed controllers reach a lower tracking error with similar control energy consumption compared to another neuro-controller.

© 2023 Published by Semnan University Press.

DOI: <https://doi.org/10.22075/jme.2023.27988.2367>

## How to cite this article:

Baghbani, F. (2023). Observer-based adaptive emotional controller for a class of uncertain nonlinear systems. Journal of Modeling in Engineering, 21(74), 37-49. doi: 10.22075/jme.2023.27988.2367

# طراحی کنترل کننده عصبی عاطفی تطبیقی و پایدار بر پایه رویکرد برای دسته‌ای از سیستم‌های غیر خطی نامعین

فهیمة باغبانی<sup>۱</sup>

چکیده	اطلاعات مقاله
<p>عدم قطعیت‌ها و پیچیدگی‌های مسائل کنترلی واقعی همچون دینامیک نامعلوم، در دسترس نبودن حالت‌ها و اغتشاش خارجی، ساختار کنترلی قوی برای برخورد با این عدم قطعیت‌ها را ایجاد می‌کنند. مدل‌های عصبی عاطفی ویژگی‌هایی همچون سادگی ساختار و سرعت بالای پاسخگویی را از خود نشان داده‌اند؛ اما کنترل کننده‌های عاطفی طراحی شده، برای مسائلی همچون محدودیت دسترسی به حالت‌ها هنوز در گام‌های ابتدایی می‌باشند. بدین منظور در این پژوهش، طراحی کنترل کننده عصبی عاطفی تطبیقی بر پایه رویکرد برای دسته‌ای از سیستم‌های غیر خطی نامعین خطی-ورودی معرفی شده است. دینامیک‌های سیستم نامعلوم هستند و توسط شبکه عصبی عاطفی پایه شعاعی پیوسته (CRBENN) تخمین زده می‌شوند. پارامترهای شبکه عصبی عاطفی با استفاده از قواعد تطبیق مناسب و سازگار با پیش‌زمینه‌های زیستی مغز عاطفی به روز می‌شوند. همچنین اغتشاش خارجی بر عملکرد سیستم تاثیر می‌گذارد. برخلاف کنترل کننده‌های عاطفی قبلی، حالات سیستم نیز در دسترس نیستند و با استفاده از رویکرد حالت تخمین زده می‌شوند. معیار عملکرد ردیابی <math>H_\infty</math> برای سیستم حلقه بسته بر اساس نظریه پایداری لیاپانوف به اثبات رسیده است. نتایج شبیه‌سازی، خطای ردیابی و انرژی کنترلی کمتر را برای روش پیشنهادی در مقایسه با یک کنترل کننده عصبی دیگر نشان می‌دهند.</p>	<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۱/۰۹/۰۴ بازنگری مقاله: ۱۴۰۲/۰۱/۰۳ پذیرش مقاله: ۱۴۰۲/۰۱/۲۲</p> <p><b>واژگان کلیدی:</b> شبکه‌های عصبی عاطفی، کنترل تطبیقی بر پایه رویکرد، نظریه پایداری لیاپانوف، عملکرد ردیابی <math>H_\infty</math></p>

## ۱-مقدمه

با الهام از بخش یادگیری عاطفی مغز در سال‌های اخیر در ساختارهای کنترلی مورد توجه قرار گرفته‌اند. هرچند که هنوز تمام جوانب آن‌ها مورد بررسی قرار نگرفته است. لذا انتظار بر این است که بکارگیری آن‌ها در طراحی ساختارهای کنترل هوشمند، نتایج ارزشمندی داشته باشد. بیشتر مدل‌های عصبی عاطفی الهام گرفته از مدل یادگیری عاطفی مغز (BEL)<sup>۲</sup> معرفی شده توسط مورن و بالکنیوس [۳] می‌باشند. هدف مدل BEL تقلید از فرآیند پردازش عاطفی مغز است که عمدتاً در آمیگدالا و اجزای مرتبط با آن صورت می‌گیرد. مدل دارای چهار زیر سیستم اصلی آمیگدالا، قشر

پیچیدگی‌ها و عدم قطعیت‌های موجود در سیستم‌های کنترلی واقعی همچون دینامیک نامعلوم یا نامعین، اغتشاش خارجی، نویز اندازه‌گیری و در دسترس نبودن حالت‌ها، طراحی سیستم‌های کنترلی را با مشکل مواجه می‌کنند. لذا طراحی سیستم‌های کنترلی مناسب، به نحوی که با این عدم قطعیت‌ها مقابله کرده و کارایی مناسبی داشته باشند؛ مورد نیاز است. سیستم‌های هوشمند همچون شبکه‌های عصبی و سیستم‌های فازی الهام گرفته از عملکرد مغز و ذهن انسان می‌باشند و تاکنون در مسائل کنترلی مختلفی بکار گرفته شده‌اند [۱]-[۲]. شبکه‌های عصبی عاطفی نیز

<sup>2</sup> Brain emotional learning

\* پست الکترونیک نویسنده مسئول: baghbani.fahimeh@semnan.ac.ir  
۱. استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان

پایداری بودند (بعنوان نمونه مراجع [۹]-[۱۰] را ببینید). اولین پژوهش ارائه شده در این زمینه، به قسمی که ساختار کنترلی پایدار و سازگار با پیش زمینه‌های زیستی مدل مغز عاطفی باشد؛ توسط باغبانی و همکاران در سال ۲۰۱۸ ارائه شده است [۱۱]. در [۱۱]، شبکه عصبی عاطفی پایه شعاعی (RBENN)<sup>۷</sup> با خاصیت تقریب‌گیری عمومی ارائه و در ساختار کنترل تطبیقی غیرمستقیم و پایدار بکار گرفته شده است. این شبکه دارای گره‌های تابع پایه شعاعی RBF<sup>۸</sup> در تالاموس می‌باشد. همچنین دارای خاصیت تقریب‌گیری عمومی بر اساس پرسپترون چند لایه می‌باشد. در [۱۲]، شبکه عصبی عاطفی پایه شعاعی پیوسته (CRBENN)<sup>۹</sup> معرفی شده است که دارای خاصیت تقریب‌گیری عمومی بر اساس شبکه‌های عصبی تابع پایه شعاعی (RBFNN)<sup>۱۰</sup> است. در این شبکه اتصال مستقیم از تالاموس به آمیگدالا حذف شده است؛ در نتیجه خروجی شبکه پیوسته و نسبت به وزن‌ها مشتق‌پذیر می‌باشد. این شبکه نیز در طراحی کنترل تطبیقی مستقیم سیستم‌های غیرخطی نامعین خطی-ورودی<sup>۱۱</sup> بکار گرفته شده است.

اخیرا معرفی ساختارهای کنترلی عصبی عاطفی پایدار برای سیستم‌های غیرخطی مورد توجه قرار گرفته است. بعنوان نمونه، در [۱۳]-[۱۴]، کنترل‌کننده‌های عصبی عاطفی خودسازمانده به ترتیب برای سیستم‌های آشوبناک و ربات‌های متحرک معرفی شده‌اند. در هر دو پژوهش وزن‌های آمیگدالا، برخلاف وزن‌های غیرکاهش آمیگدالا در مدل BEL، هم کاهش و هم افزایشی هستند. در [۱۵]، مدل بهبود داده شده فازی BEL معرفی شده است. قواعد تطبیق آمیگدالا همان قواعد مرسوم مدل‌های عاطفی می‌باشند. قواعد تطبیق OFC و پارامترهای شبکه فازی عصبی با استفاده از نظریه پایداری لیاپانوف بدست آمده‌اند. در [۱۶]، از BELBIC برای تخمین دینامیک نامعلوم دسته‌ای از سیستم‌های غیرخطی خطی-ورودی با بهره ورودی معلوم استفاده شده است. قواعد تطبیق آمیگدالا لزوماً غیرکاهشی نیستند. پایداری سیستم حلقه بسته از طریق نظریه پایداری لیاپانوف به اثبات رسیده است. در [۱۷]، مدل یادگیری عاطفی مغز نرمال شده برای تخمین

پیشین حلقه‌ای (OFC)<sup>۱</sup>، قشر حسی<sup>۲</sup> و تالاموس می‌باشد. این مدل دارای دو مسیر از ورودی به خروجی از طریق OFC و آمیگدالا می‌باشد. وزن‌های آمیگدالا غیرکاهشی<sup>۳</sup> هستند و در واقع هرآنچه توسط آمیگدالا یادگرفته می‌شود؛ فراموش نمی‌شود. از طرف دیگر OFC با وزن‌های هم کاهش و هم افزایشی از پاسخ‌های نامناسب آمیگدالا جلوگیری می‌کند. در مدل پایه BEL [۳]، آمیگدالا یک ورودی دیگر از تالاموس نیز دریافت می‌کند که بیشینه بین ورودی‌ها می‌باشد. در [۴]، این ورودی اضافی به جهت نتایج زمخت در شبیه‌سازی و تداخل با یادگیری معمول، جهت تحقیقات بیشتر برای جایگزین کردن تابعی مناسب‌تر حذف شده است.

بر مبنای مدل BEL مدل‌های یادگیری عاطفی مختلف در تصمیم‌گیری و کنترل معرفی شده‌اند. بعنوان نمونه، در [۵]، با اضافه کردن ضرایب نگرانی و اطمینان در فرآیند یادگیری، شبکه عصبی عاطفی مصنوعی بر پایه لیمبیک معرفی شده است. همچنین آمیگدالا و OFC توسط پرسپترون دو لایه مدل شده‌اند. شبکه سپس در بازشناسی چهره و عاطفه بکار گرفته شده است. همچنین در [۶]، شبکه عصبی عاطفی به نام WTAENN<sup>۴</sup> معرفی شده است که یک شبکه عصبی پسخور تک‌لایه با خاصیت تقریب‌گیری عمومی اثبات شده می‌باشد. این شبکه در مسائل مختلف همچون شناسایی الگو، پیش‌بینی و طبقه‌بندی بکار گرفته شده است. در [۷]، ماشین یادگیر عاطفی مغز مبتنی بر ماشین یادگیر مفروضه<sup>۵</sup> معرفی شده و در پیش‌بینی سری‌های زمانی مورد ارزیابی قرار گرفته است.

بر مبنای مدل BEL، کنترل‌کننده BELBIC<sup>۶</sup> در سال ۲۰۰۴ توسط پرفسور لوکس و همکاران ارائه شد [۸]. کنترل‌کننده BELBIC به سرعت در زمینه کنترل مورد توجه قرار گرفت. کنترل‌کننده‌های مبتنی بر مدل عاطفی مغز ویژگی‌های مثبتی چون سرعت بالای برخورد با عدم قطعیت‌ها، سادگی ساختار، بار محاسباتی کم و حتی مقاومت بالاتر در برخورد با عدم قطعیت‌ها را در مقایسه با شبکه‌های عصبی مرسوم و سیستم‌های فازی از خود نشان دادند. اما عمدتاً طراحی‌ها برای سیستم خاص و بدون اثبات

<sup>6</sup> Brain Emotional Learning Based Intelligent Controller

<sup>7</sup> Radial basis emotional neural network

<sup>8</sup> Radial basis function

<sup>9</sup> Continuous radial basis emotional neural network

<sup>10</sup> Radial basis function neural network

<sup>11</sup> Affine nonlinear systems

<sup>1</sup> Orbitofrontal cortex

<sup>2</sup> Sensory cortex

<sup>3</sup> Non decreasing

<sup>4</sup> Winner-take-all emotional neural network

<sup>5</sup> Brain Emotional Learning based on Extreme Learning Machine (BEL-ELM)

پایداری سیستم توسط نظریه پایداری لیاپانوف به اثبات رسیده است. نتایج شبیه‌سازی نشان می‌دهد که سیستم پیشنهادی بر پایه CRBENN در مقایسه با یک سیستم مشابه طراحی شده بر اساس RBFNN به خطای ردیابی و انرژی کنترلی مصرفی کمتر دست یافته است. ساختار ادامه مقاله به شرح زیر است: در بخش ۲ شبکه CRBENN معرفی می‌شود. در بخش ۳ مشخصات مساله بیان می‌شوند. سپس در بخش ۴ کنترل کننده پیشنهادی طراحی می‌گردد. نتایج شبیه‌سازی در بخش ۵ ارائه می‌گردند و در انتها نتیجه‌گیری را خواهیم داشت.

## ۲- شبکه عصبی عاطفی پایه شعاعی پیوسته (CRBENN)

ساختار کلی شبکه CRBENN در شکل (۱) نشان داده شده است. همانگونه که مشاهده می‌شود؛ این شبکه دارای چهار بخش اصلی تالاموس، قشرحسی، آمیگدالا و OFC می‌باشد. در ابتدا ورودی وارد تالاموس می‌شود. در تالاموس توابع پایه شعاعی (RBF) به صورت زیر ساخته می‌شوند:

$$\varphi_j = \exp\left(-\left[\frac{(\underline{z} - \underline{\mu}_j)^T (\underline{z} - \underline{\mu}_j)}{\sigma_j^2}\right]\right), \quad (1)$$

$$j = 1, \dots, m$$

که در آن  $m$  تعداد گره‌های موجود در تالاموس،  $\underline{z} \in \mathbb{R}^n$  ورودی شبکه،  $\underline{\mu}_j \in \mathbb{R}^n$  بردار مرکز و  $\sigma_j$  انحراف از معیار می‌باشند. بردار RBF ساخته شده سپس از طریق قشر حسی به OFC و آمیگدالا انتقال می‌یابد. خروجی OFC و آمیگدالا به ترتیب به صورت زیر محاسبه می‌شوند:

$$E_o = \sum_{j=1}^m w_j \varphi_j, \quad (2)$$

$$E_a = \sum_{j=1}^m v_j \varphi_j, \quad (3)$$

که در آن‌ها  $w_j$  و  $v_j$  به ترتیب وزن گره موجود در OFC و آمیگدالا می‌باشند. خروجی کلی CRBENN از رابطه زیر محاسبه می‌شود:

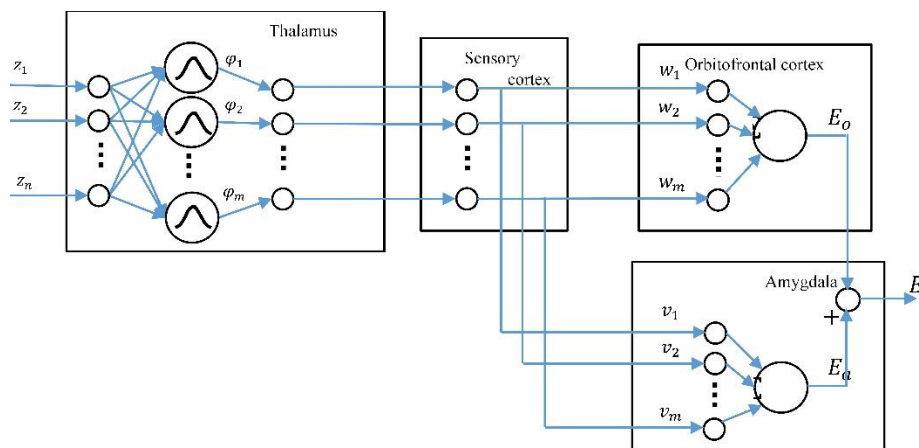
$$E = E_a - E_o = \underline{v}^T \underline{\varphi} - \underline{w}^T \underline{\varphi}, \quad (4)$$

که در آن  $\underline{v} = [v_1, v_2, \dots, v_m]^T$  و  $\underline{w} = [w_1, w_2, \dots, w_m]^T$

پارامترهای نامعلوم سیستم‌های دینامیک معرفی شده است و همگرایی وزن‌های مدل تضمین شده است.

در [۱۸]، کنترل تطبیقی پایدار برای سیستم‌های چندکارگزاره بر اساس RBENN ارائه شده است. شبیه‌سازی‌ها، کارایی بهتر شبکه‌های عصبی عاطفی را در مقایسه با سیستم‌های فازی و عصبی معمول در زمینه در خطای ریایی، انرژی کنترلی مصرفی، بار محاسباتی کم و همچنین توانایی بالاتر در دفع اغتشاش‌های ناگهانی از خود نشان داده‌اند. پارسا و همکاران در [۱۹]، کنترل کننده مقاوم پسگام عاطفی را برای سیستم‌های غیرخطی با فیدبک اکید<sup>۱</sup> بکار برده‌اند. همچنین میرحاجیان و اکبرزاده [۲۰]، کنترل عصبی عاطفی پیشبین را برای سیستم‌های غیرخطی معرفی نمودند. در [۲۱]، کنترل کننده عصبی عاطفی پایدار برای دسته‌ای از سیستم‌های غیرخطی چندکارگزاره بکار گرفته شده است. از آنجا که شبکه‌های عصبی عاطفی جدید می‌باشند؛ هنوز کاربرد آن‌ها در زمینه‌های مختلف از جمله سیستم‌های غیرخطی نامعین با حالات بدون دسترس در گام‌های ابتدایی هستند. تنها در [۲۲] کنترل عاطفی بر پایه رویکرد بر مبنای RBENN برای دسته‌ای از سیستم‌های غیرخطی فیدبک اکید دارای اشباع ورودی، با بهره کنترلی ثابت معلوم طراحی شده است. در پژوهش حاضر هدف توسعه ساختارهای کنترلی عاطفی در [۱۱]-[۱۲]، برای سیستم‌های غیرخطی نامعین خطی-ورودی با دینامیک‌های تماما نامعلوم و با محدودیت عدم دسترسی به حالت‌ها می‌باشد. در مقایسه با [۱۱]-[۱۲]، در این پژوهش فقط خروجی سیستم در دسترس می‌باشد. لذا یک تخمین‌زن حالت برای تخمین حالات سیستم با استفاده از خروجی بکار گرفته شده است. دینامیک‌های نامعلوم سیستم توسط شبکه عصبی CRBENN تخمین زده می‌شوند. قواعد تطبیق مناسب که سازگار با مدل‌های پایه یادگیری عاطفی هستند؛ برای وزن‌های آمیگدالا و OFC در نظر گرفته شده‌اند. قابل ذکر است که در نظر گرفتن قواعد تطبیق سازگار با مدل‌های پایه عاطفی (قواعد غیرکاهشی برای آمیگدالا) منجر به اثبات دشوارتر پایداری می‌شود. همچنین عبارت کنترل مقاوم  $H_\infty$  نیز برای کاهش خطای ناشی از تخمین حالت، تقریب شبکه عصبی و اغتشاشات خارجی بکار گرفته شده است. در نهایت معیار

<sup>1</sup> Strict-feedback nonlinear systems



شکل ۱- ساختار کلی شبکه عصبی عاطفی CRBENN [۱۲].

### ۳- مشخصات مساله

دسته‌ای از سیستم‌های غیرخطی نامعین خطی-ورودی به صورت زیر در نظر گرفته شده‌اند:

$$\begin{aligned} \dot{x}^{(n)} &= f(\underline{x}) + g(\underline{x})u + d(t), \\ y &= x, \end{aligned} \quad (5)$$

که در آن  $\underline{x} = [x_1, x_2, \dots, x_n]^T = [x, \dot{x}, \dots, x^{(n-1)}]^T \in \mathbb{R}^n$  بردار حالت‌های سیستم است. همچنین  $u \in \mathbb{R}$  ورودی کنترلی،  $d(t)$  اغتشاش خارجی و  $y \in \mathbb{R}$  خروجی سیستم است. توابع  $f(\underline{x})$  و  $g(\underline{x})$  نامعلوم اما کراندار به صورت  $|f(\underline{x})| \leq f_U$  و  $g_L \leq g(\underline{x}) \leq g_U$  فرض شده‌اند. در این روابط  $f_U, g_L, g_U$  و ثابت‌های مثبت نامعلوم هستند. اغتشاش خارجی کراندار و به صورت  $|d(t)| \leq d_U$  است که کران بالای آن نیز نامعلوم می‌باشد. حالت‌های سیستم در دسترس نمی‌باشند و از رویکرد جهت تخمین حالت‌های سیستم استفاده خواهد شد.

معادله (۵) به صورت برداری به صورت زیر نوشته می‌شود:

$$\begin{aligned} \dot{\underline{x}} &= A\underline{x} + B(f(\underline{x}) + g(\underline{x})u + d(t)), \\ y &= C^T \underline{x}, \end{aligned} \quad (6)$$

که در آن  $A = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \\ 0 & 0 & 0 & \dots & 0 \end{bmatrix}$  و  $B = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{bmatrix}$  و  $C^T = [1, 0, \dots, 0]$

خطای ردیابی به صورت زیر تعریف می‌شود:

$$e = x - x_d, \quad (7)$$

که در آن  $x_d$  مسیر مطلوب معلوم می‌باشد که خود آن و مشتقاتش تا مرتبه  $m$  معلوم و کراندار می‌باشند.

از آنجایی که حالات سیستم در دسترس نیستند؛ تخمین حالت  $x$  و خطای  $e$  را به ترتیب با  $\hat{x}$  و  $\hat{e}$  نشان می‌دهیم. خطای تخمین زده شده  $\hat{e}$  به صورت زیر تعریف می‌شود:

$$\hat{e} = \hat{x} - x_d. \quad (8)$$

با تعریف  $\hat{\underline{x}} = [\hat{x}, \dot{\hat{x}}, \dots, \hat{x}^{(n-1)}]^T \in \mathbb{R}^n$  و  $\underline{x}_d = [x_d, \dot{x}_d, \dots, x_d^{(n-1)}]^T \in \mathbb{R}^n$  و  $\hat{\underline{e}} = [\hat{e}, \dot{\hat{e}}, \dots, \hat{e}^{(n-1)}]^T \in \mathbb{R}^n$  فرم برداری رابطه (۸) به صورت زیر بدست می‌آید:

$$\hat{\underline{e}} = \hat{\underline{x}} - \underline{x}_d. \quad (9)$$

هدف این بخش طراحی کنترل کننده بر پایه شبکه‌های عصبی عاطفی برای سیستم (۵) است؛ به قسمی که سیستم حلقه بسته پایدار باقی بماند و تمام سیگنال‌های موجود در سیستم برای  $t \geq 0$  محدود باقی بمانند. همچنین اثر اغتشاش کمتر از یک حد مطلوب قرار بگیرد.

### ۴- کنترل کننده پیشنهادی

در این پژوهش توابع نامعلوم  $f(\underline{x})$  و  $g(\underline{x})$  توسط شبکه CRBENN به ترتیب به صورت  $\hat{f}(\hat{\underline{x}})$  و  $\hat{g}(\hat{\underline{x}})$  تخمین زده می‌شوند:

$$\hat{f}(\hat{\underline{x}}) = \underline{v}_f^T \underline{\varphi} - \underline{w}_f^T \underline{\varphi}, \quad (10)$$

$$\hat{g}(\hat{\underline{x}}) = \underline{v}_g^T \underline{\varphi} - \underline{w}_g^T \underline{\varphi}, \quad (11)$$

که در آن‌ها  $\underline{v}_f = [v_{1f}, v_{2f}, \dots, v_{mf}]^T$  و  $\underline{v}_g = [v_{1g}, v_{2g}, \dots, v_{mg}]^T$  و  $\underline{w}_f = [w_{1f}, w_{2f}, \dots, w_{mf}]^T$  و  $\underline{w}_g = [w_{1g}, w_{2g}, \dots, w_{mg}]^T$  متغیر  $\underline{\varphi}$  در ذیل رابطه (۴) تعریف شده‌است.

**فرض ۱:** فرض شده است که پارامترهای تطبیقی  $\underline{w}_f, \underline{v}_f, \underline{w}_g, \underline{v}_g$  به ترتیب به مجموعه‌های فشرده زیر تعلق دارند:

$$[\underline{v}_g^*, \underline{w}_g^*] = \arg \min_{\substack{\underline{v}_g \in \Omega_{gv}, \underline{w}_g \in \Omega_{gw} \\ -g(\underline{x})}} [\sup \|\hat{g}(\hat{x})[\underline{v}_g, \underline{w}_g] - g(\underline{x})\|], \quad (15)$$

با توجه به اینکه مقادیر ایده‌آل پارامترها وجود ندارند؛ خطای تقریب کمینه به صورت (۱۶) تعریف می‌شود:

$$\varepsilon = f(\underline{x}) - \hat{f}(\hat{x})[\underline{v}_f^*, \underline{w}_f^*] + (g(\underline{x}) - \hat{g}(\hat{x})[\underline{v}_g^*, \underline{w}_g^*])u, \quad (16)$$

با جایگذاری  $\hat{f}(\hat{x})$  و  $\hat{g}(\hat{x})$  از روابط (۱۰)-(۱۱) در (۱۳)، رابطه زیر بدست می‌آید:

$$\dot{\underline{e}} = A\underline{e} - BK^T \underline{e} + B(\tilde{v}_f^T \underline{\varphi} - \tilde{w}_f^T \underline{\varphi} + \tilde{v}_g^T \underline{\varphi} u - \tilde{w}_g^T \underline{\varphi} u + u_r + \omega_1), \quad (17)$$

$$e = C^T \underline{e},$$

که در آن  $\tilde{v}_f = \underline{v}_f^* - \underline{v}_f$ ،  $\tilde{w}_f = \underline{w}_f^* - \underline{w}_f$ ،  $\tilde{v}_g = \underline{v}_g^* - \underline{v}_g$ ،  $\tilde{w}_g = \underline{w}_g^* - \underline{w}_g$  و  $\omega_1 = \varepsilon + d$

به دلیل در دسترس نبودن حالات سیستم، معادله زیر برای تخمین زدن خطای حالت معرفی می‌شود:

$$\begin{aligned} \dot{\underline{\hat{e}}} &= (A - BK^T)\underline{\hat{e}} + K_o(e - \hat{e}), \\ \hat{e} &= C^T \underline{\hat{e}}, \end{aligned} \quad (18)$$

که در آن  $K_o = [k_{o1}, k_{o2}, \dots, k_{on}]^T \in \mathbb{R}^n$  بهره رویکرد می‌باشد. با تفریق (۱۸)، (۱۷)، (۱۹) بدست می‌آید:

$$\begin{aligned} \dot{\underline{\hat{e}}} &= (A - K_o C^T)\underline{\hat{e}} \\ &+ B(\tilde{V}_f^T \underline{\varphi}_A - \tilde{W}_f^T \underline{\varphi} + \tilde{V}_g^T \underline{\varphi}_A u - \tilde{W}_g^T \underline{\varphi} u + u_r \\ &+ \omega_1), \end{aligned} \quad (19)$$

$$\bar{e} = C^T \underline{\hat{e}},$$

که در آن خطای رویکرد به صورت  $\bar{e} = e - \hat{e}$  تعریف شده است.

در مدل پایه BEL در [۳] وزن‌های آمیگدالا نمی‌توانند کاهش پیدا کنند و وظیفه گره‌های OFC است که با کاهش و یا افزایش، پاسخ‌های نامناسب آمیگدالا را حذف کنند. بنابراین برای سازگار بودن با مدل پایه یادگیری عاطفی مغز، در شبکه CRBENN قواعد تطبیق زیر برای گره‌های آمیگدالا و OFC در نظر گرفته شده‌اند:

$$\dot{\underline{v}}_f = \alpha_f \underline{\varphi} \max(\bar{e}^T P B, 0), \quad (20)$$

$$\dot{\underline{w}}_f = -\beta_f \underline{\varphi} \bar{e}^T P B, \quad (21)$$

$$\dot{\underline{v}}_g = \alpha_g \underline{\varphi} \max(\bar{e}^T P B u, 0), \quad (22)$$

$$\dot{\underline{w}}_g = -\beta_g \underline{\varphi} \bar{e}^T P B u, \quad (23)$$

$$\Omega_{fv} = \{\underline{v}_f \mid \|\underline{v}_f\| \leq M_{fv}\}$$

$$\Omega_{fw} = \{\underline{w}_f \mid \|\underline{w}_f\| \leq M_{fw}\}$$

$$\Omega_{gv} = \{\underline{v}_g \mid 0 < \delta \leq \|\underline{v}_g\| \leq M_{gv}\}$$

$$\Omega_{gw} = \{\underline{w}_g \mid 0 < \delta \leq \|\underline{w}_g\| \leq M_{gw}\}$$

و  $M_{fv}, M_{fw}, M_{gv}, M_{gw}$  و  $\delta$  ثابت‌های مثبت هستند. عبارت  $\|\cdot\|$  نرم نوع دو (اقلیدوسی) می‌باشد.

با توجه به فرضیات بالا و روابط (۱۰) و (۱۱) داریم

$$|\hat{f}(\underline{x})| \leq f_{Umax} < \infty$$

و  $f_{Umax} < \infty$ ،  $g_{Lmin} \leq |\hat{g}(\underline{x})| \leq g_{Umax} < \infty$  در آن‌ها

$g_{Lmin}$  و  $g_{Umax}$  ثابت‌های مثبت هستند.

کنترل کننده تطبیقی عصبی عاطفی بر پایه رویکرد به صورت زیر تعریف شده است:

$$u = -\hat{g}^{-1}(\hat{x}) (f(\hat{x}) + K^T \underline{e} - x_d^{(n)} - u_r), \quad (12)$$

که در آن  $K = [k_1, k_2, \dots, k_n]^T$  و عبارت کنترل مقاوم برای کاهش اثر خطای تقریب شبکه عصبی عاطفی و اغتشاش خارجی است و در ادامه تعریف می‌شود.

با جایگذاری (۱۲) در (۶) و ساده‌سازی (۱۳) بدست می‌آید:

$$\begin{aligned} \dot{\underline{e}} &= A\underline{e} - BK^T \underline{e} + B(f(\underline{x}) - \hat{f}(\hat{x}) \\ &+ (g(\underline{x}) - \hat{g}(\hat{x}))u + u_r \\ &+ d), \end{aligned} \quad (13)$$

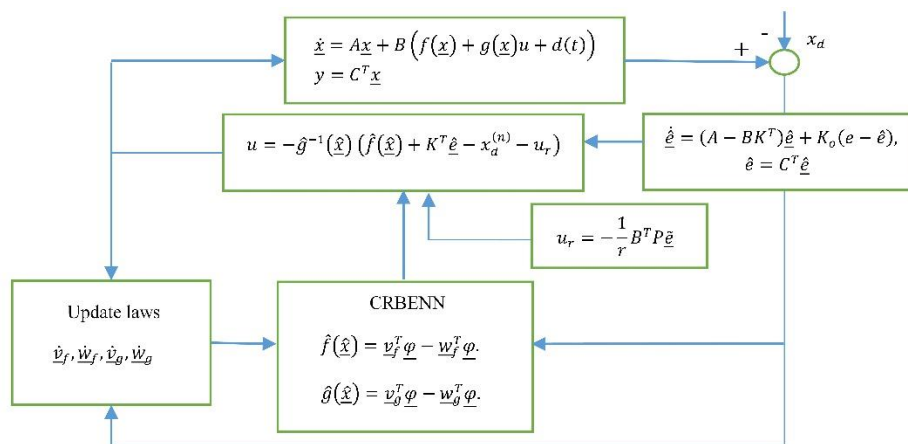
$$e = C^T \underline{e}.$$

**نکته ۱:** توجه شود که در رابطه (۱۲)، با تنظیم مناسب شرایط اولیه وزن‌های  $\hat{g}(\hat{x})$ ، از صفر شدن احتمالی آن و در نتیجه صفر شدن مخرج جلوگیری می‌شود. همچنین می‌توان مشابه مقاله [۲۳] پارامتر بسیار کوچک  $\varepsilon_G$  را تعریف کرد؛ به صورتی که اگر  $|\hat{g}(\hat{x})| \leq \varepsilon_G$  شود آنگاه  $\hat{g}^{-1}(\hat{x})$  در (۱۲) با  $(\hat{g}(\hat{x}) + k_G \mu_G)^{-1}$  جایگزین گردد

$$\mu_G = \begin{cases} 1, & \text{if } |\hat{g}(\hat{x})| \leq \varepsilon_G \\ 0, & \text{if } |\hat{g}(\hat{x})| > \varepsilon_G \end{cases}$$

با توجه به خاصیت تقریب‌گری عمومی شبکه CRBENN، پارامترهای بهینه  $[\underline{v}_f^*, \underline{w}_f^*]$  و  $[\underline{v}_g^*, \underline{w}_g^*]$  وجود دارند؛ به قسمی که  $\hat{f}(\hat{x})$  و  $\hat{g}(\hat{x})$  می‌توانند به ترتیب  $f(\underline{x})$  و  $g(\underline{x})$  را بر روی یک مجموعه فشرده  $\Omega_i$  با دقت دلخواه تخمین بزنند. پارامترهای بهینه را به صورت زیر تعریف می‌کنیم:

$$[\underline{v}_f^*, \underline{w}_f^*] = \arg \min_{\substack{\underline{v}_f \in \Omega_{fv}, \underline{w}_f \in \Omega_{fw} \\ -f(\underline{x})}} [\sup \|\hat{f}(\hat{x})[\underline{v}_f, \underline{w}_f] - f(\underline{x})\|], \quad (14)$$



شکل ۲- ساختار کنترل کننده پیشنهادی

$$+ \frac{1}{2\alpha_g} \tilde{v}_g^T \tilde{v}_g + \frac{1}{2\beta_g} \tilde{w}_g^T \tilde{w}_g.$$

با مشتق گیری از (۲۷) نسبت به زمان داریم:

$$\dot{V}_L = \frac{1}{2} \dot{\hat{e}}^T P \hat{e} + \frac{1}{2} \hat{e}^T P \dot{\hat{e}} - \frac{1}{\alpha_f} \dot{v}_f^T \tilde{v}_f - \frac{1}{\beta_f} \dot{w}_f^T \tilde{w}_f - \frac{1}{\alpha_g} \dot{v}_g^T \tilde{v}_g - \frac{1}{\beta_g} \dot{w}_g^T \tilde{w}_g. \quad (28)$$

با استفاده از خطای روینگر (۱۹) و جبران ساز مقاوم (۲۵)، رابطه زیر بدست می آید:

$$\begin{aligned} \dot{V}_L = & \frac{1}{2} \hat{e}^T \left( \Lambda^T P + P \Lambda - \frac{2}{r} P B B^T P \right) \hat{e} \\ & + \frac{1}{2} \left( \omega_1^T B^T P \hat{e} + \hat{e}^T P B \omega_1 \right) + \tilde{v}_f^T \left( \varphi \hat{e}^T P B - \frac{1}{\alpha_f} \dot{v}_f \right) \\ & - \tilde{w}_f^T \left( \varphi \hat{e}^T P B + \frac{1}{\beta_f} \dot{w}_f \right) + \tilde{v}_g^T \left( \varphi \hat{e}^T P B u - \frac{1}{\alpha_g} \dot{v}_g \right) \\ & - \tilde{w}_g^T \left( \varphi \hat{e}^T P B + \frac{1}{\beta_g} \dot{w}_g \right). \end{aligned} \quad (29)$$

با اعمال قواعد تطبیق (۲۰)-(۲۳) و معادله شبه ریگاتی (۲۴)، رابطه (۲۹) به صورت زیر ساده می شود:

$$\begin{aligned} \dot{V}_L = & -\frac{1}{2} \hat{e}^T Q \hat{e} - \frac{1}{2\rho^2} P B B^T P \\ & + \frac{1}{2} \left( \omega_1^T B^T P \hat{e} + \hat{e}^T P B \omega_1 \right) \\ & + \tilde{v}_f^T \varphi \left( \hat{e}^T P - \max(\hat{e}^T P B, 0) \right) \\ & + \tilde{v}_g^T \varphi \left( \hat{e}^T P B u - \max(\hat{e}^T P B u, 0) \right). \end{aligned} \quad (30)$$

با کمک روابط  $\hat{e}^T P B - \max(\hat{e}^T P B, 0) \leq \hat{e}^T P B$  و  $\hat{e}^T P B u - \max(\hat{e}^T P B u, 0) \leq \hat{e}^T P B u$  به رابطه (۳۰) تبدیل می شود:

که در آن ها  $\alpha_f, \alpha_g, \beta_f$  و  $\beta_g$  نرخ های یادگیری مثبت و ثابت می باشند و  $P$  از معادله شبه ریگاتی زیر بدست می آید:

$$P \Lambda + \Lambda^T P + Q - \frac{2}{r} P B B^T P + \frac{1}{\rho^2} P B B^T P = 0, \quad (24)$$

که در آن  $PB = C$  و  $2\rho^2 \geq r, \Lambda = A - K_o C^T$  ساختار کنترل کننده پیشنهادی در شکل ۲ نشان داده شده است.

**قضیه ۱:** سیستم با رابطه (۶) را در نظر بگیرید که دینامیک های کاملاً نامعلوم  $f(x)$  و  $g(x)$  به ترتیب توسط روابط (۱۰)-(۱۱) تخمین زده می شوند. ورودی کنترلی به صورت (۱۲) طراحی شده است و قواعد تطبیق برای CRBENN توسط (۲۰)-(۲۳) بدست می آیند. همچنین جبران ساز مقاوم  $u_r$  با رابطه (۲۵) تعریف می شود:

$$u_r = -\frac{1}{r} B^T P \hat{e}. \quad (25)$$

در این صورت معیار عملکرد ردیابی  $H_\infty$  به صورت زیر، برای سطح تضعیف<sup>۱</sup> از قبل تعیین شده  $\rho$ ، برقرار خواهد شد:

$$\begin{aligned} \int_0^T \hat{e}^T Q \hat{e} \leq & \int_0^T \hat{e}^T(0) P \hat{e}(0) + \frac{1}{\alpha_f} \tilde{v}_f^T(0) \tilde{v}_f(0) \\ & + \frac{1}{\beta_f} \tilde{w}_f^T(0) \tilde{w}_f(0) + \frac{1}{\alpha_g} \tilde{v}_g^T(0) \tilde{v}_g(0) \\ & + \frac{1}{\beta_g} \tilde{w}_g^T(0) \tilde{w}_g(0) + \rho^2 \int_0^T \omega^T \omega dt, \end{aligned} \quad (26)$$

که در آن  $\omega = \tilde{v}_f^T \varphi + \tilde{v}_g^T \varphi u + \omega_1$  بدترین نوع عدم قطعیت<sup>۲</sup> می باشد.

اثبات: تابع لیاپانوف زیر را در نظر بگیرید:

$$V_L = \frac{1}{2} \hat{e}^T P \hat{e} + \frac{1}{2\alpha_f} \tilde{v}_f^T \tilde{v}_f + \frac{1}{2\beta_f} \tilde{w}_f^T \tilde{w}_f \quad (27)$$

<sup>2</sup> Worst-case uncertainty

<sup>1</sup> Attenuation level

که در آن  $x_1$  زاویه پاندول نسبت به محور عمودی بر حسب رادیان،  $x_2$  سرعت زاویه‌ای بر حسب رادیان بر ثانیه،  $g_p = 9.8 \frac{m}{s^2}$  ثابت گرانش زمین،  $m_p$  جرم پاندول بر حسب کیلوگرم،  $M$  جرم کارت بر حسب کیلوگرم و  $a = \frac{1}{m_p + M}$  می‌باشد. همچنین  $2l_p$  طول پاندول بر حسب متر،  $u$  ورودی کنترلی،  $d$  اغتشاش خارجی و  $v_n$  نویز اندازه‌گیری می‌باشد. مقادیر پارامترها به صورت  $m_p = 0.1 \text{ kg}$ ،  $M = 1 \text{ kg}$  و  $2l_p = 1 \text{ m}$  در نظر گرفته شده‌اند. مقادیر اولیه حالت‌ها به صورت  $[x_1(0), x_2(0)] = [0, 0]$  در نظر گرفته شده است. هدف این است که خروجی سیستم مسیر ایده‌آل  $x_{1d} = \sin(t)$  را دنبال کند. زمان نمونه برداری برابر  $\Delta t = 0.01$  ثانیه و کل زمان شبیه‌سازی  $T_t = 20 \text{ s}$  در نظر گرفته شده است.

معیار انرژی کنترلی مصرف‌شده به صورت زیر است:

$$J = \frac{1}{T} \sum_{k_t=1}^T |u(k_t)|. \quad (35)$$

که در آن  $T = \frac{T_t}{\Delta t}$  می‌باشد.

پارامترهای کنترلی با سعی و خطا و برای بدست آوردن خطای ردیابی و انرژی کنترلی معقول و منطقی به صورت  $K_o^T = [0.8, 1]$ ،  $K^T = [15, 5]$ ،  $Q = \begin{bmatrix} 250 & 15 \\ 15 & 0.1 \end{bmatrix}$ ،  $b_g = 0.0001$ ،  $\alpha_g = 0.001$ ،  $b_f = 5$ ،  $\alpha_f = 0.1$  و  $r = 0.01$  تنظیم شده‌اند. همچنین از معادله ریکاتی (۲۴)، مقدار  $P = \begin{bmatrix} 9 & 1 \\ 1 & 0.1 \end{bmatrix}$  بدست آمده است که در آن  $C = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \approx PB$  می‌باشد. پارامترهای توابع پایه شعاعی در تالاموس به صورت  $\mu_j \in [-0.5, 0.5]^T$ ،  $m = 25$ ،  $z = \underline{x} = [\hat{x}_1, \hat{x}_2]^T$  و  $\sigma_j = 1$  ( $j = 1, \dots, m$ ) در نظر گرفته شده‌اند. مقادیر اولیه پارامترهای وزنی برای  $\underline{w}_f$  در بازه  $[-1, 1]$ ،  $\underline{v}_f$  در بازه  $[0, 0.25]$ ، مقدار ثابت  $0.01$  و  $\underline{v}_g$  مقدار ثابت  $0.001$  در نظر گرفته شده‌اند.

برای مقایسه و نشان دادن کارایی شبکه عصبی CRBENN، روش پیشنهادی با یک کنترل کننده عصبی تطبیقی بر پایه شبکه عصبی RBFNN تحت شرایط مختلف بدون اغتشاش، با اغتشاش خارجی (سینوسی و پالس) و نویز اندازه‌گیری با  $\text{SNR}=40$  مقایسه شده است. کنترل کننده برپایه RBFNN با همان ساختار روش

$$\begin{aligned} \dot{V}_L \leq & -\frac{1}{2} \underline{\bar{e}}^T Q \underline{\bar{e}} - \frac{1}{2\rho^2} \underline{\bar{e}}^T P B B^T P \underline{\bar{e}} \\ & + \frac{1}{2} (\omega_1^T B^T P \underline{\bar{e}} + \underline{\bar{e}}^T P B \omega_1) \\ & + (\underline{\bar{v}}_f^T \underline{\varphi} + \underline{\bar{v}}_g^T \underline{\varphi} u) \underline{\bar{e}}^T P B. \end{aligned} \quad (31)$$

با استفاده از تعریف  $\omega = \underline{\bar{v}}_f^T \underline{\varphi} + \underline{\bar{v}}_g^T \underline{\varphi} u + \omega_1$  رابطه (۳۱) به رابطه (۳۲) تبدیل می‌شود:

$$\begin{aligned} \dot{V}_L \leq & -\frac{1}{2} \underline{\bar{e}}^T Q \underline{\bar{e}} - \frac{1}{2\rho^2} \underline{\bar{e}}^T P B B^T P \underline{\bar{e}} \\ & + \frac{1}{2} (\omega^T B^T P \underline{\bar{e}} + \underline{\bar{e}}^T P B \omega) \end{aligned} \quad (32)$$

با اضافه و کم کردن  $\frac{1}{2} \rho^2 \omega^2$  از رابطه (۳۲) و ساده‌سازی، رابطه زیر بدست می‌آید:

$$\begin{aligned} \dot{V}_L \leq & -\frac{1}{2} \underline{\bar{e}}^T Q \underline{\bar{e}} - \frac{1}{2} \left( \frac{1}{\rho} B^T P \underline{\bar{e}} - \rho \omega \right)^T \left( \frac{1}{\rho} B^T P \underline{\bar{e}} \right. \\ & \left. - \rho \omega \right) + \frac{1}{2} \rho^2 \omega^2 \\ \leq & -\frac{1}{2} \underline{\bar{e}}^T Q \underline{\bar{e}} + \frac{1}{2} \rho^2 \omega^2 \end{aligned} \quad (33)$$

در نهایت با انتگرال‌گیری از رابطه (۳۳) از  $t = 0$  تا  $t = T$ ، رابطه (۲۶) بدست می‌آید و اثبات کامل می‌شود.

**نکته ۲:** با استفاده از الگوریتم تصویرسازی در [۲۴] می‌توان قواعد تطبیق (۲۰) - (۲۳) را اصلاح کرد؛ به نحوی که پارامترها کراندار باقی بمانند و در عین حال قضیه ۱ هنوز برقرار باشد.

## ۵- نتایج شبیه‌سازی

در این بخش روش پیشنهادی بر روی سیستم پاندول معکوس پیاده شده است. از نرم‌افزار متلب (MATLAB) برای شبیه‌سازی بر روی یک کامپیوتر با مشخصات Intel core i5-3337U, 1.6GHz استفاده شده است. نتایج حاصل از شبیه‌سازی با یک سیستم مشابه بطوریکه بجای CRBENN از RBFNN برای تخمین دینامیک‌های سیستم استفاده می‌کند؛ مقایسه شده است. معادلات پاندول معکوس به صورت زیر هستند:

$$\begin{aligned} \dot{x}_1 &= x_2, \\ \dot{x}_2 &= \frac{g_p \sin(x_1) - \frac{a m_p l_p x_2^2 \sin(2x_1)}{2} + a \cos(x_1) l}{\frac{4l_p}{3} - a m_p l_p \cos^2(x_1)} \\ &+ d, \\ y &= x_1 + v_n, \quad a = \frac{l}{m_p + M} \end{aligned} \quad (34)$$



پارامترها و شرایط اولیه آن‌ها برای کنترل‌کننده بر پایه RBFNN کاملاً یکسان با پارامترهای کنترل‌کننده پیشنهادی در نظر گرفته شده‌اند؛ همچنین  $\gamma_{Rf} = 5$  و  $\gamma_{Rg} = 0.0001$  می‌باشند. در هر آزمایش  $J$  و  $MSE$  در جدول ۱ آورده شده‌اند. همچنین مسیر حالات تخمینی سیستم، خطا و ورودی کنترلی رسم شده‌اند.

آزمایش ۵-۱: نتایج شبیه‌سازی بر روی پاندول معکوس بدون اغتشاش

در این آزمایش اغتشاش خارجی و نویز صفر می‌باشند ( $d = 0$  و  $v_n = 0$ ). شکل (۳) حالت‌های تخمینی سیستم  $\hat{x}_1$  و  $\hat{x}_2$  را نشان می‌دهد. همانگونه که مشاهده می‌شود هر دو کنترل‌کننده به نتایج رضایت‌بخشی رسیده‌اند. برای تحلیل و مقایسه بهتر نتایج، ورودی کنترلی ( $u$ ) و خطا ( $e$ ) در شکل (۴) رسم شده‌اند. در جدول ۱ نیز مقادیر  $MSE$  و  $J$  برای هر دو کنترل‌کننده آورده شده‌اند. بر طبق شکل‌های (۳) تا (۴) و اعداد جدول ۱، روش پیشنهادی در مقایسه با کنترل‌کننده بر مبنای شبکه عصبی RBFNN، با مصرف ۴٪ انرژی کنترلی ( $J$ ) کمتر به خطای ردیابی به میزان ۲۶٪ کمتر دست پیدا کرده است. به عبارت دیگر برهمکنش بین آمیگدالا و OFC در ساختار یادگیری عاطفی سبب افزایش درجات آزادی و عملکرد ردیابی بهتر شده است. همچنین مقادیر واقعی و تخمینی توابع  $f(x)$  و  $g(x)$  برای هر دو روش برای مدت ۸۰ ثانیه به ترتیب در شکل‌های (۵) و (۶) نشان داده شده‌اند. همانطور که مشخص است؛ روش پیشنهادی تخمین بهتری از هر دو تابع  $f(x)$  و  $g(x)$  داشته است. وزن‌های تطبیقی  $w_f$  و  $v_f$  نیز به ترتیب در شکل‌های (۷) و (۸) نشان داده شده‌اند. همانطور که مشاهده می‌شود؛ وزن‌های OFC ( $w_f$ ) هم افزایشی و هم کاهشی می‌باشند. همچنین در ثانیه‌های بیشتر به علت کاهش خطا ثبات بیشتری پیدا کرده‌اند. اما وزن‌های آمیگدالا ( $v_f$ ) فقط افزایشی می‌باشند (طبق ویژگی‌های مغز عاطفی). البته همانگونه که از شکل (۸) مشخص است؛ وزن‌ها مقادیر زیادی ندارند و پس از ۸۰ ثانیه هنوز حداکثر به مقدار ۰.۴ رسیده‌اند. در صورتی که وزن‌ها خیلی افزایش یابند؛ طبق الگوریتم تصویرسازی (نکته ۲) مقدار آن‌ها محدود خواهد شد.

پیشنهادی ساخته شده است تا تنها بخش تخمین‌زن که همان شبکه عصبی است؛ متفاوت باشد و کارایی کنترل‌کننده عاطفی بهتر مشخص شود. بنابراین کنترل‌کننده ساخته شده بر پایه RBFNN به صورت (۳۶) است:

$$u_{RBF} = -\hat{g}_R(\hat{x}) \left( \hat{f}_R(\hat{x}) + K^T \hat{e} - x_d^{(n)} - u_r \right). \quad (36)$$

همانطور که مشاهده می‌شود؛ ساختار کاملاً مشابه سیستم کنترلی پیشنهادی است با این تفاوت که توابع غیرخطی سیستم یعنی  $f(x)$  و  $g(x)$  توسط RBFNN، به ترتیب به صورت (۳۷) و (۳۸) تخمین زده می‌شوند:

$$\hat{f}_R(\hat{x}) = \underline{w}_{Rf}^T \underline{\varphi}_R, \quad (37)$$

$$\hat{g}_R(\hat{x}) = \underline{w}_{Rg}^T \underline{\varphi}_R, \quad (38)$$

که در آن‌ها  $\underline{w}_{Rf} = [w_{Rf1}, \dots, w_{Rfm}]^T$  و  $\underline{w}_{Rg} = [w_{Rg1}, \dots, w_{Rgm}]^T$  بردارهای وزنی هستند. همچنین  $\underline{\varphi}_R = [\varphi_{R1}, \varphi_{R2}, \dots, \varphi_{Rm}]^T$  بردار شامل توابع پایه شعاعی  $\varphi_{Rj}$  به صورت (۳۹) است:

$$\varphi_{Rj} = \exp \left( - \left[ \frac{(\hat{x} - \underline{\mu}_{Rj})^T (\hat{x} - \underline{\mu}_{Rj})}{\sigma_{Ri}^2} \right] \right), \quad Rj = 1, \dots, m \quad (39)$$

که در آن  $\underline{\mu}_{Rj}$  مرکز و  $\sigma_{Rj}$  انحراف از معیار توابع گوسی هستند.

قواعد تطبیق برای وزن‌های شبکه RBFNN با روال مشابه سیستم کنترلی پیشنهادی و به صورت (۴۰) و (۴۱) بدست آمده‌اند:

$$\dot{\underline{w}}_{Rf} = \gamma_{Rf} \underline{\varphi}_R \hat{e}^T P B, \quad (40)$$



$$\dot{\underline{w}}_{Rg} = \gamma_{Rg} \underline{\varphi}_R \hat{e}^T P B u, \quad (41)$$

که در آن‌ها  $\gamma_{Rf}$  و  $\gamma_{Rg}$  ثابت‌های وزنی می‌باشند. همانطور که از (۴۰) و (۴۱) مشخص است؛ شبکه RBFNN مشابه شبکه CRBENN است با این تفاوت که فقط دارای OFC و با علامت منفی نسبت به CRBENN است. هدف از ساختن کنترل‌کننده بر پایه RBFNN در اینجا مطالعه اثر یادگیری عاطفی با اضافه کردن بخش آمیگدالا می‌باشد.



<sup>1</sup> Mean squared error

خطای ردیابی با میزان ۲۵٪ کمتر دست یافته است. آزمایش ۴-۵: نتایج شبیه‌سازی بر روی پاندول معکوس با نویز اندازه‌گیری

در این آزمایش اغتشاش خارجی صفر است ( $d = 0$ ) است؛ اما نویز سفید گوسی به  $SNR=40$  به خروجی سیستم ( $y$ ) اضافه شده است. برای بدست آوردن نتایج قابل اعتماد، شبیه‌سازی‌ها ۲۰ بار تکرار شده‌اند و مقادیر متوسط، کمینه و بیشینه  $MSE$  و  $J$  در جدول ۱ آورده شده‌اند. بر طبق داده‌های موجود در جدول ۱، روش پیشنهادی با مصرف انرژی کنترلی کمتر (۷٪)، به خطای ردیابی به میزان ۲۲٪ کمتر، در مقایسه با کنترل کننده بر پایه RBFNN دست یافته است.



شکل ۳- مسیر حالت‌های تخمینی ( $\hat{x}_1$  و  $\hat{x}_2$ ) پاندول معکوس بدون اغتشاش.



شکل ۴- ورودی کنترلی ( $u$ ) و خطای ردیابی ( $e$ ) برای روش پیشنهادی و روش بر مبنای RBFNN بدون اغتشاش.

جدول ۱- انرژی کنترلی مصرفی  $J$  و  $MSE$  برای سیستم پاندول معکوس. اعداد پررنگ نتایج بهتر را نشان می‌دهند.


1000*MSE		J		J/MSE	آزمایش
روش پیشنهادی	روش بر مبنای RBFNN	روش پیشنهادی	روش بر مبنای RBFNN		
۶.۶۳	۸.۹۲	۱۱.۹۵	۱۲.۴۳	۱-۵: بدون اغتشاش	
۷.۷۲	۹.۴۲	۱۲.۲۴	۱۲.۵۵	۲-۵: اغتشاش سینوسی	
۷.۰۴	۹.۲۹	۱۲.۲۷	۱۲.۶۷	۳-۵: اغتشاش پالس	
۱۴.۰۱	۱۸.۰۴	۱۴.۱۸	۱۵.۲	۴-۵: نویز با SNR=35	

آزمایش ۲-۵: نتایج شبیه‌سازی بر روی پاندول معکوس با اغتشاش سینوسی


در این آزمایش یک اغتشاش سینوسی به صورت  $d = \sin(2\pi t)$  اعمال می‌شود. شکل (۹) حالت‌های تخمینی سیستم ( $\hat{x}_1$  و  $\hat{x}_2$ ) را نشان می‌دهد. همانگونه که مشاهده می‌شود هر دو روش عملکرد مطلوبی را نشان داده‌اند. ورودی کنترلی ( $u$ ) و خطا ( $e$ ) در شکل (۱۰) رسم شده‌اند. با توجه به شکل‌ها و همچنین  $MSE$  و  $J$  در جدول ۱، همانند آزمایش قبل، یادگیری عاطفی در روش پیشنهادی منجر به خطای ردیابی کمتر (به میزان ۱۸٪) با مصرف انرژی کنترلی به میزان ۳٪ کمتر در مقایسه با کنترل کننده مشابه بر پایه RBFNN شده است. البته در مقایسه با آزمایش قبل به دلیل وجود اغتشاش، خطای هر دو روش کمی بیشتر شده است.

آزمایش ۳-۵: نتایج شبیه‌سازی بر روی پاندول معکوس با اغتشاش پالس


در این آزمایش یک اغتشاش پله به صورت  $d = 2(u(t-6) - u(t-8))$  شده است. شکل (۱۱) حالت‌های تخمینی سیستم ( $\hat{x}_1$  و  $\hat{x}_2$ ) را نشان می‌دهد. همانند آزمایش‌های قبل هر دو روش به نتایج مطلوبی در دفع اغتشاش رسیده‌اند. ورودی کنترلی ( $u$ ) و خطا ( $e$ ) در شکل (۱۲) رسم شده‌اند. با توجه به شکل‌ها و جدول ۱، در مقایسه با کنترل کننده بر پایه RBFNN با ساختار و قواعد تطبیق مشابه، روش پیشنهادی با مصرف ۳٪ انرژی کنترلی مصرفی کمتر، به




شکل ۸- وزن‌های تطبیقی  $V_f$  در آزمایش بدون اغتشاش برای روش پیشنهادی.



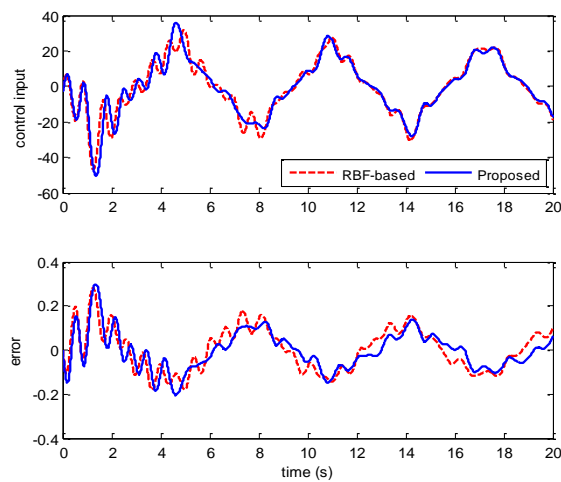
شکل ۵- تخمین تابع  $f(x)$  در آزمایش بدون اغتشاش.




شکل ۹- مسیر حالت‌های تخمینی  $(\hat{x}_2$  و  $\hat{x}_1$ ) پاندول معکوس با اغتشاش سینوسی.



شکل ۶- تخمین تابع  $g(x)$  در آزمایش بدون اغتشاش.




شکل ۱۰- ورودی کنترلی  $(u)$  و خطای ردیابی  $(e)$  برای روش پیشنهادی و روش برمبنای RBFNN با اغتشاش سینوسی.



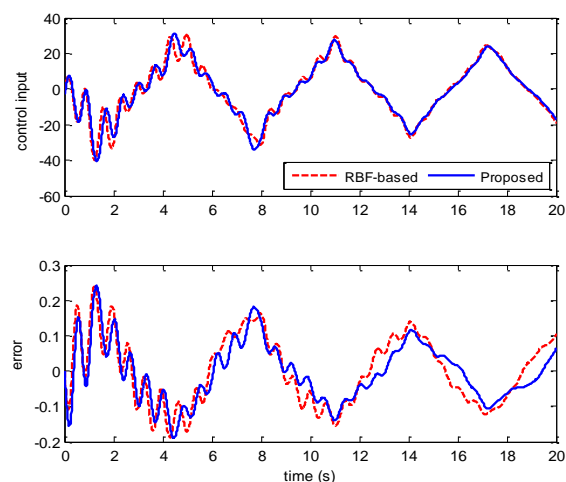
شکل ۷- وزن‌های تطبیقی  $W_f$  در آزمایش بدون اغتشاش برای روش پیشنهادی.

## ۶- نتیجه‌گیری

در این پژوهش، کنترل کننده عصبی عاطفی تطبیقی بر پایه رویکرد برای دسته‌ای از سیستم‌های غیرخطی نامعین طراحی شده است. از شبکه عصبی CRBENN برای تخمین دینامیک‌های نامعین سیستم استفاده شده است. همچنین فرض شده است که حالات سیستم در دسترس نیستند. لذا یک رویکرد برای تخمین حالات سیستم طراحی شده است. عبارت کنترل مقاوم  $H_\infty$  برای کاهش خطای تقریب و اثر عدم قطعیت‌های سیستم نیز بکار گرفته شده است. قواعد تطبیق برای شبکه عصبی بر پایه نظریه پایداری لیاپانوف و سازگار با پیش‌زمینه‌های زیستی حاکم بر مغز عاطفی بدست آمده‌اند. نتایج شبیه‌سازی در مقایسه با یک ساختار کنترلی مشابه طراحی شده بر پایه شبکه عصبی RBFNN، خطای کمتر با مصرف انرژی کنترلی کمتر در حضور عدم قطعیت‌ها را برای سیستم پیشنهادی نشان داده است. به عنوان پژوهش آینده می‌توان سیستم کنترلی طراحی نمود که به عملکرد از قبل مشخص شده در حضور عدم قطعیت‌های دنیای واقعی همچون اشباع عملگرها دست یابد.



شکل ۱۱- مسیر حالت‌های تخمینی ( $\hat{x}_2$  و  $\hat{x}_1$ ) پاندول معکوس با اغتشاش پالس.



شکل ۱۲- ورودی کنترلی ( $u$ ) و خطای ردیابی ( $e$ ) برای روش پیشنهادی و روش برمبنای RBFNN با اغتشاش پالس.

## ۷- مراجع

- [1] محمد مهدی ذبیحی شش پلی، مهدی علیاری شوره دلی و علی معرفیان پور، "تحلیل پایداری لیاپانوف در آموزش سیستم فازی-عصبی نوع ۲ با یک الگوریتم ترکیبی مبتنی بر گرادینان نزولی و فیلتر کالمن"، نشریه مدل‌سازی در مهندسی، دوره ۲۰، شماره ۶۸، فروردین ۱۴۰۱، صفحه ۸۵-۱۰۰.
- [2] مجتبی رادمهر و حسن زرآبادی پور، "کنترل مد لغزشی فازی برای ردیابی پروفایل بهینه سرعت قطار با وجود نامعینی"، نشریه مدل‌سازی در مهندسی، دوره ۲۰، شماره ۶۸، فروردین ۱۴۰۱، صفحه ۱۳۹-۱۵۲.
- [3] J. Moren and C. Balkenius, "A Computational Model of Emotional Learning in the Amygdala", From Anim. to Animat. From animals to animats 6, 2000, pp. 115-124.
- [4] J. Moren, Emotion and Learning- A Computational Model of the Amygdala, Lund University, Lund, Sweden., 2002.
- [5] E. Lotfi and M.-R. Akbarzadeh-T, "Practical Emotional Neural Networks", Neural networks, Vol. 59, 2014, pp. 61-72.
- [6] E. Lotfi and M.-R. Akbarzadeh-T, "A Winner-Take-All Approach to Emotional Neural Networks with Universal Approximation Property", Inf. Sci., Vol. 346, 2016, pp. 369-388.

- [۷] مهدی گلشن، محمد تشنه لب و آرش شریفی، "توسعه ماشین یادگیری هیجانی مغز با الهام از ماشین یادگیر مفروط ترتیبی آنلاین حافظه‌دار بازگشتی مبتنی بر شبکه‌های عصبی"، نشریه مدل‌سازی در مهندسی، دوره ۲۰، شماره ۷۰، مهر ۱۴۰۱، صفحه ۱-۲۱.
- [8] C. Lucas, D. Shahmirzadi, and N. Sheikholeslami, "Introducing BELBIC: Brain Emotional Learning Based Intelligent Controller", *Intell. Autom. Soft Comput.*, Vol. 10, No. 1, 2004, pp. 11–21.
- [9] M. R. Khalghani, M. H. Khooban, E. Mahboubi-Moghaddam, N. Vafamand, and M. Goodarzi, "A Self-Tuning Load Frequency Control Strategy for Microgrids: Human Brain Emotional Learning", *Int. J. Electr. Power Energy Syst.*, Vol. 75, 2016, pp. 311–319.
- [10] A. Sadeghieh, H. Sazgar, K. Goodarzi, and C. Lucas, "Identification and Real-Time Position Control of a Servo-Hydraulic Rotary Actuator by Means of a Neurobiologically Motivated Algorithm", *ISA Trans.*, Vol. 51, No. 1, 2012, pp. 208–219.
- [11] F. Baghbani, M.-R. Akbarzadeh-T, and M.-B. N. Sistani, "Stable Robust Adaptive Radial Basis Emotional Neurocontrol for a Class of Uncertain Nonlinear Systems," *Neurocomputing*, vol. 309, 2018, pp. 11–26.
- [12] F. Baghbani, M.-R. Akbarzadeh-T, M.-B. Naghibi-Sistani, and A. Akbarzadeh, "Emotional Neural Networks with Universal Approximation Property for Stable Direct Adaptive Nonlinear Control Systems", *Eng. Appl. Artif. Intell.*, Vol. 89, 2020, p. 103447.
- [13] T. L. Le, C. M. Lin, and T. T. Huynh, "Self-Evolving Type-2 Fuzzy Brain Emotional Learning Control Design for Chaotic Systems Using PSO", *Appl. Soft Comput. J.*, Vol. 73, 2018, pp. 418–433.
- [14] Q. Wu et al., "Self-Organizing Brain Emotional Learning Controller Network for Intelligent Control System of Mobile Robots", *IEEE Access*, Vol. 6, 2018, pp. 59096–59108.
- [15] W. Fang, F. Chao, C. M. Lin, L. Yang, C. Shang, and C. Zhou, "An Improved Fuzzy Brain Emotional Learning Model Network Controller for Humanoid Robots", *Front. Neurorobot.*, Vol. 13, 2019, pp. 1–16.
- [16] S. Khorashadizadeh, S. M. Hashem Zadeh, M. R. Koohestani, S. Shekofteh, and S. Erkaya, "Robust Model-Free Control of a Class of Uncertain Nonlinear Systems Using BELBIC: Stability Analysis and Experimental Validation", *J. Brazilian Soc. Mech. Sci. Eng.*, Vol. 41, No. 8, 2019, pp. 1–12.
- [17] A. Naderi Akhormeh, J. Roshanian, H. MoradiMaryamnegari, and A. M. Khoshnood, "Online and Stable Parameter Estimation Based on Normalized Brain Emotional Learning Model (NBELM)", *Int. J. Adapt. Control Signal Process.*, Vol. 33, No. 7, 2019, pp. 1047–1065.
- [18] F. Baghbani, M. R. Akbarzadeh-T, and M. B. Naghibi Sistani, "Cooperative Adaptive Emotional Neuro-Control for a Class of Higher-Ordered Heterogeneous Uncertain Nonlinear Multi-Agent Systems", *Neurocomputing*, Vol. 447, 2021, pp. 196–212.
- [19] P. Parsa, M. R. Akbarzadeh-T, and F. Baghbani, "Command-Filtered Backstepping Robust Adaptive Emotional Control of Strict-Feedback Nonlinear Systems with Mismatched Uncertainties," *Inf. Sci.*, vol. 579, 2021, pp. 434–453, doi: 10.1016/j.ins.2021.07.090.
- [20] H. Mirhajianmoghdam and M. R. Akbarzadeh-T., "Predictive Hierarchical Harmonic Emotional Neuro-Cognitive Control of Nonlinear Systems", *Eng. Appl. Artif. Intell.*, Vol. 111, 2022, p. 104781.
- [21] I. R. Scola, L. R. G. Carrillo, and J. P. Hespanha, "Limbic System-Inspired Performance-Guaranteed Control for Nonlinear Multi-Agent Systems with Uncertainties", *IEEE Trans. Neural Networks Learn. Syst.*, 2021, pp. 1–12.
- [22] P. Parsa, M. R. Akbarzadeh-T, and F. Baghbani, "Observer-Based Adaptive Emotional Command-Filtered Backstepping For Cooperative Control Of Input-Saturated Uncertain Strict-Feedback Multi-Agent Systems", *IET Control Theory & Applications*, Vol. 17, No. 7, 2021, pp. 906–926, Doi: 10.1049/cth2.12426.
- [23] W.-Y. Wang, Y.-H. Chien, and T.-T. Lee, "Observer-Based T – S Fuzzy Control for a Class of General Nonaffine Nonlinear Systems Using Generalized Projection-Update Laws", *IEEE Trans. Fuzzy Syst.*, Vol. 19, No. 3, 2011, pp. 493–504.
- [24] L. X. Wang, *A Course in Fuzzy Systems and Control*. Prentice-Hall International, Inc., 1997.