

طراحی کنترل کننده عصبی - فازی نوع-۲

حسین مرادی فراهانی^۱، کارشناس ارشد، جواد عسگری^۲، دانشیار

۱-دانشکده مهندسی برق و کامپیوتر- دانشگاه صنعتی اصفهان-اصفهان- ایران- h.moradifarahani@ec.iut.ac.ir

۲- دانشکده مهندسی برق و کامپیوتر- دانشگاه صنعتی اصفهان -اصفهان- ایران- j-askari@cc.iut.ac.ir

چکیده: در این مقاله یک کنترل کننده تطبیقی غیرمستقیم عصبی- فازی نوع-۲ برای کنترل کلاسی از سیستم‌های غیرخطی، با استفاده از نظریه فیدبک خطی‌ساز و شبکه‌های عصبی- فازی نوع-۲ ارائه می‌شود. در این روش ابتدا توسط دو شبکه عصبی- فازی نوع-۲ ورودی کنترلی فیدبک خطی‌ساز تقریب زده می‌شود. به منظور آموزش شبکه از الگوریتم گرادیان نزولی با نرخ یادگیری تطبیقی استفاده شده است. در این مقاله روش پیشنهادی برای ساده‌سازی شبکه‌های عصبی- فازی نوع-۲ کاهش تعداد قواعد فازی می‌باشد که با کاهش تعداد قواعد از پیچیدگی مدل عصبی- فازی نوع-۲ کاسته می‌شود. با استفاده از نظریه پایداری لیاپانوف، با بیان یک قضیه پایداری سیستم حلقه‌بسته تضمین می‌شود و قوانین تطبیقی لازم برای تنظیم پارامترهای شبکه عصبی- فازی نوع-۲ به دست می‌آید. در قسمت شبیه‌سازی، سیستم دوتانک در حضور داده‌های نویزی با کنترل کننده پیشنهادی و شبکه عصبی- فازی تطبیقی شبیه‌سازی می‌شود. نتایج شبیه‌سازی کارایی روش پیشنهادی را نشان می‌دهد.

واژه‌های کلیدی: نظریه پایداری لیاپانوف، سیستم دوتانک، شبکه عصبی- فازی نوع-۲، فیدبک خطی‌ساز، کنترل تطبیقی غیرمستقیم.

Type-2 Fuzzy- Neural Controller Design

H. Moradi Farahani, J. Askari

Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan, Iran

Abstract: This paper presents an indirect adaptive type-2 fuzzy neural controller to control a class of nonlinear systems using feedback linearization theory and type-2 fuzzy neural networks. In this method, feedback linearization control input using two type-2 fuzzy neural networks is approximated. The gradient descent learning algorithm with adaptive learning rate is used for learning phase. In this paper, reduction in the number of fuzzy rules is proposed to simplify type-2 fuzzy neural network. By reducing the number of fuzzy rules, model complexity is diminished. Using Lyapunov stability theory, with the expression theorem, adaptation laws for tuning type-2 fuzzy neural networks is derived and stability of the closed loop system is guaranteed. Finally, the proposed controller is applied to twin-tank system in the presence of noisy data. Results are compared with Adaptive-Network-Based Fuzzy Inference System (ANFIS). Simulation results show the ability of the proposed method.

Keywords: Feedback Linearization, Indirect Adaptive Control, Lyapunov Stability Theory, Type-2 Fuzzy Neural Network, Twin-Tank System.

تاریخ ارسال مقاله: ۱۳۹۲/۰۳/۱۳

تاریخ اصلاح مقاله: ۱۳۹۲/۰۴/۲۹

تاریخ پذیرش مقاله: ۱۳۹۲/۰۶/۲۵

نام نویسنده‌ی مسئول: دکتر جواد عسگری

نشانی نویسنده‌ی مسئول: ایران - اصفهان - دانشگاه صنعتی اصفهان - دانشکده‌ی مهندسی برق و کامپیوتر

۱- مقدمه

در دو دهه گذشته روش فیدبک خطی ساز برای کنترل گروه خاصی از سیستم‌های غیرخطی گسترش یافته و در حل مسائل عملی کنترل شامل کنترل بالگرد، ربات‌های صنعتی و دستگاه‌های پزشکی موفق بوده است [۱]. در سیستم‌های غیرخطی که معادلات آن‌ها به صورت $\dot{x} = f(x) + g(x)u$ و توابع مشخص غیرخطی می‌باشند می‌توان با انتخاب مناسب ورودی کنترل u ، از طریق روش خطی سازی با فیدبک، بخش غیرخطی را حذف و کنترل کننده‌ای بر مبنای نظریه کنترل خطی طراحی کرد [۲]. با این حال این روش فقط می‌تواند به سیستم‌های غیرخطی مشخص با پارامترهای معین اعمال شود. اما در عمل توابع $f(x)$ و $g(x)$ نامعلوم هستند و به همین دلیل یافتن روش‌هایی برای تعیین این توابع و کنترل این چنین سیستم‌هایی دارای اهمیت است. به این منظور، [۳] به بررسی کاربرد شبکه‌های گوسی در کنترل تطبیقی مستقیم پرداخته است. در [۴] دو روش کنترل تطبیقی مستقیم و غیرمستقیم با استفاده از سیستم‌های فازی تاکاگی-سوگنو ارائه شده است. [۵] یک روش کنترل عصبی تطبیقی برای سیستم‌های غیرخطی معرفی کرده است. در [۶] یک روش کنترل تطبیقی غیرخطی بر مبنای شبکه عصبی-فازی تطبیقی (ANFIS) که یک روش هوشمند نو فازی برای مدل کردن و کنترل سیستم‌های دارای نامعینی است، ارائه شده است.

از طرفی پروفیسور زاده در سال ۱۹۷۵ مجموعه‌های فازی نوع-۲ را به عنوان توسعه‌ای از مجموعه‌های فازی معرفی کرد [۷]. از آن پس برای تمایز بین مجموعه‌های فازی و مجموعه‌های فازی نوع-۲، به مجموعه‌های فازی قبلی، به طور معمول مجموعه‌های فازی نوع-۱ می‌گویند. مجموعه‌های فازی نوع-۲ دارای درجه عضویت‌های فازی می‌باشند، از این رو در برخورد با عدم قطعیت‌ها توانایی کاهش اثر و مدل کردن آن‌ها را دارند [۸]. سیستم‌های فازی نوع-۲ در بسیاری از زمینه‌ها مانند پیش‌بینی سری‌های زمانی [۹]، بازساخت الگو [۱۰]، کنترل ربات [۱۱]، یکسان‌سازی کانال‌های متغییر با زمان [۱۲] مورد استفاده قرار گرفته‌اند.

شبکه‌های عصبی-فازی نوع-۲ به جهت ترکیب توانایی یادگیری شبکه‌های عصبی و قدرت استنتاج و مقاوم بودن سیستم‌های فازی نوع-۲ در برابر نویز بوجود آمده‌اند. در [۱۳] سه ساختار از شبکه‌های عصبی-فازی نوع-۲ ارائه شده است. هم‌چنین از الگوریتم گرادیان نزولی برای آموزش شبکه استفاده شده است. در [۱۴] یک سیستم دینامیکی غیرخطی توسط شبکه عصبی-فازی نوع-۲ و شبکه عصبی-فازی تطبیقی، در حالت آغشته‌شدن داده‌های شناسایی به نویز سفید گوسی مورد شناسایی قرار گرفته است و شبکه عصبی-فازی نوع-۲ در مقایسه با شبکه عصبی-فازی تطبیقی به خوبی سیستم را شناسایی کرده است. یک موضوع مهم در طراحی شبکه‌های عصبی-فازی نوع-۲ روش آموزش شبکه می‌باشد. در سال‌های اخیر

روش‌های مختلفی برای آموزش شبکه‌های عصبی-فازی نوع-۲ از قبیل خوشه‌بندی فازی [۱۵]، الگوریتم ژنتیک [۱۶]، کوچ پرندهگان [۱۷] و الگوریتم گرادیان نزولی [۱۸] پیشنهاد شده است. به عنوان بیشترین روش مورد استفاده برای آموزش شبکه‌های عصبی-فازی از روش پس انتشار خطا می‌توان نام برد. زمان طولانی آموزش جهت همگرایی و وجود عدم قطعیت در بدست آوردن مقدار حداقل سراسری^۳ تابع هزینه از جمله ضعف‌های روش پس انتشار خطا، با وجود استفاده زیاد از آن در مقالات مختلف می‌باشد [۲۱-۱۹]. برطرف کردن هر یک از این مشکلات می‌تواند به بهبود عملکرد این روش کمک کند. بنابراین روش‌هایی برای بهبود عملکرد این الگوریتم پیشنهاد شده است که تعدادی از این روش‌ها بر اساس یادگیری تطبیقی پارامترها می‌باشند [۲۲-۲۴]. در [۲۲] یک تابع کاهشی برای بروزسانی نرخ یادگیری استفاده شده است اما ساختار بسیار پیچیده‌ای دارد. در [۲۳] از ترکیب مشتق پارامترهای مختلف (بدون در نظر گرفتن تاثیر تغییرات جداگانه هر پارامتر) بر اساس بسط تیلور برای بروزسانی نرخ یادگیری استفاده شده است. در این روش زمان یادگیری پارامترها طولانی است. در [۲۴] قانون بروزسانی نرخ یادگیری با یک رابطه پیچیده بیان شده است. در این رابطه از یک پارامتر اضافه به نام ضریب تطبیق نرخ یادگیری^۴ استفاده شده است. تعیین این پارامتر بر اساس نظریه‌ی بخصوصی نمی‌باشد. در روش پس‌انتشار خطا تعیین نرخ یادگیری مشکل است و بر اساس نظریه خاصی نمی‌باشد و معمولاً با آزمایش تعیین می‌شود.

در این مقاله با استفاده از شبکه‌های عصبی-فازی نوع-۲ و نظریه فیدبک خطی ساز، یک کنترل کننده تطبیقی غیرمستقیم برای کلاسی از سیستم‌های غیرخطی طراحی می‌شود. در این روش، توسط دو شبکه عصبی-فازی نوع-۲ ورودی کنترلی فیدبک خطی ساز سیستم‌های آفین^۵ غیرخطی تک‌ورودی - تک‌خروجی تقریب زده می‌شود. برای آموزش شبکه از الگوریتم گرادیان نزولی با نرخ یادگیری تطبیقی استفاده شده است. در این روش با الهام‌گیری از روش دونیمه‌سازی^۶ جهت پیدا کردن ریشه‌های چندجمله‌ای، بدون استفاده از روش آزمایش و خطا مقدار نرخ یادگیری تعیین می‌شود. علاوه بر رضایت بخشی نتایج، این روش از سایر روش‌هایی که ارائه شده ساده‌تر است. نداشتن پارامتر اضافی در قانون بروزسانی و هم‌چنین افزایش دقت از جمله مزیت‌های این روش می‌باشد. هم‌چنین با کاهش بهینه تعداد قواعد فازی، از پیچیدگی مدل عصبی-فازی نوع-۲ کاسته می‌شود. با استفاده از نظریه پایداری لیاپانوف، با بیان یک قضیه پایداری سیستم حلقه بسته تضمین می‌شود و قوانین تطبیقی لازم برای تنظیم پارامترهای شبکه عصبی-فازی نوع-۲ بدست می‌آید. در قسمت شبیه‌سازی سیستم دوتانک در حضور داده‌های نویزی با کنترل کننده پیشنهادی و کنترل کننده عصبی-فازی تطبیقی شبیه‌سازی و نتایج حاصل مقایسه می‌شود.

توابع $f(x)$ و $g(x)$ نامعلوم می باشند لذا کنترل کننده ایده آل نمی تواند مورد استفاده قرار بگیرد بنابراین می بایست توابع غیرخطی $f(x)$ و $g(x)$ را تقریب زد.

۳- مجموعه فازی نوع-۲

مجموعه فازی نوع-۲ \tilde{A} را به صورت رابطه (۵) و یا (۶) نمایش می دهند.

$$\tilde{A} = \{x, \mu_{\tilde{A}}(x) | \forall x \in X\} \quad (5)$$

$$\tilde{A} = \int_{x \in X} \frac{\mu_{\tilde{A}}(x)}{x} = \int_{x \in X} \left[\int_{u \in J_x} \frac{f_x(u)}{u} \right] / x \quad (6)$$

در این روابط X مجموعه مرجع، x متغیر اولیه یا متغیر اصلی مانند فشار، دما می باشد. $\mu_{\tilde{A}}(x)$ تابع عضویت ثانویه می باشد. $J_x \subseteq [0, 1]$ مجموعه ای از درجات عضویت اولیه می باشد. u متغیر ثانویه، $f_x(u) \in [0, 1]$ درجه عضویت ثانویه می باشد. هرگاه همه درجات عضویت ثانویه در یک مجموعه فازی نوع-۲ برابر یک باشند ($f_x(u) = 1, \forall u \in J_x$) به آن مجموعه فازی نوع-۲ فاصله ای می گویند.

سیستم های فازی نوع-۲ معمولاً به صورت قوانین فازی اگر- آنگاه مدل مدانی یا تاکاگی-سوگنو-کانگ طراحی می شوند. یک نمونه از قانون مدل سوگنو فاصله ای به این صورت است

$$R^k: \text{If } x_1 \text{ is } \tilde{A}_1^k \text{ and } \dots \text{ and } x_n \text{ is } \tilde{A}_n^k \\ \text{Then } y_j \text{ is } \tilde{y}_k^j = C_{k,1}^j x_1 + \dots + C_{k,n}^j x_n + C_{k,0}^j \\ k=1, \dots, M; i=0, 1, \dots, n \quad j=1, \dots, m$$

در این قانون $C_{k,i}^j$ ضرایب (مجموعه های فازی نوع-۱) قسمت نتیجه می باشند. \tilde{A}_i^k (مجموعه های فازی نوع-۲) قسمت شرط هستند \tilde{y}_k^j خروجی j ام قانون k ام می باشد. هم چنین $C_{k,i}^j \in [s_{k,i}^j - c_{k,i}^j, c_{k,i}^j + s_{k,i}^j]$ که $s_{k,i}^j$ به ترتیب مراکز و پراکندگی حول مراکز $C_{k,i}^j$ می باشند. مطالب بیشتر در رابطه با مفهوم مجموعه و سیستم های فازی نوع-۲ در [۲۷] و [۲۸] آمده است.

۴- ساختار شبکه عصبی- فازی نوع-۲

ساختار شبکه عصبی- فازی نوع-۲ فاصله ای در شکل (۱) نشان داده شده است. این شبکه از شش لایه تشکیل شده است [۱۳].

لایه ۱: این لایه، لایه ورودی است و به تعداد ورودی ها گره وجود دارد.
لایه ۲: این لایه از گره های تطبیقی تشکیل شده است و فازی سازی ورودی را برعهده دارد، هم چنین خروجی این لایه با استفاده از $t -$ نرم و $s -$ نرم حد بالا و پایین تابع عضویت را برای محاسبه قسمت مقدمه قانون فازی محاسبه می کند.

روند ارائه مطالب در این مقاله به صورت زیر است: بخش دوم به معرفی مختصر روش فیدبک خطی ساز برای سیستم های آفین غیرخطی می پردازد. در بخش سوم و چهارم مجموعه فازی نوع-۲ و ساختار شبکه عصبی- فازی نوع-۲ به طور مختصر معرفی می شوند. بخش پنجم روش یادگیری و بروزرسانی نرخ یادگیری را بیان می کند. در بخش ششم روش طراحی کنترل کننده تطبیقی غیرمستقیم عصبی- فازی نوع-۲ و قوانین تطبیقی بیان می شود. روش ساده سازی شبکه عصبی- فازی نوع-۲ در بخش هفتم ارائه می شود. در بخش هشتم سیستم دوتانک توسط کنترل کننده تطبیقی غیرمستقیم عصبی- فازی نوع-۲ کنترل می شود. در بخش نهم نتیجه گیری بیان می شود.

۲- فیدبک خطی ساز

معادلات یک سیستم آفین غیرخطی مرتبه n به صورت رابطه (۱) بیان می شود.

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = x_3 \\ \vdots \\ \dot{x}_{(n)} = f(x) + g(x)u \\ y = x_1 \end{cases} \quad (1)$$

در این رابطه y خروجی و u ورودی سیستم هستند. هم چنین $\underline{x} = [x_1, x_2, \dots, x_n]^T = [x_1, \dot{x}_1, \dots, x_1^{(n-1)}]^T \in R^n$ بردار حالت سیستم است و فرض می شود که قابل اندازه گیری می باشد. برای اینکه سیستم کنترل پذیر باشد لازم است که $g(x) \neq 0$ باشد. بدون دست رفتن کلیت موضوع فرض می شود که $g(x) > 0$ است [۲۵].

خطای ردیابی به صورت $e = y_d - y = y_d - x_1$ که در آن y_d خروجی مطلوب می باشد، بردار خطا به صورت $\underline{e} = [e, \dot{e}, \dots, e^{(n-1)}]^T$ اگر توابع غیرخطی $f(x)$ و $g(x)$ مشخص باشند، ورودی کنترل به صورت زیر انتخاب می شود:

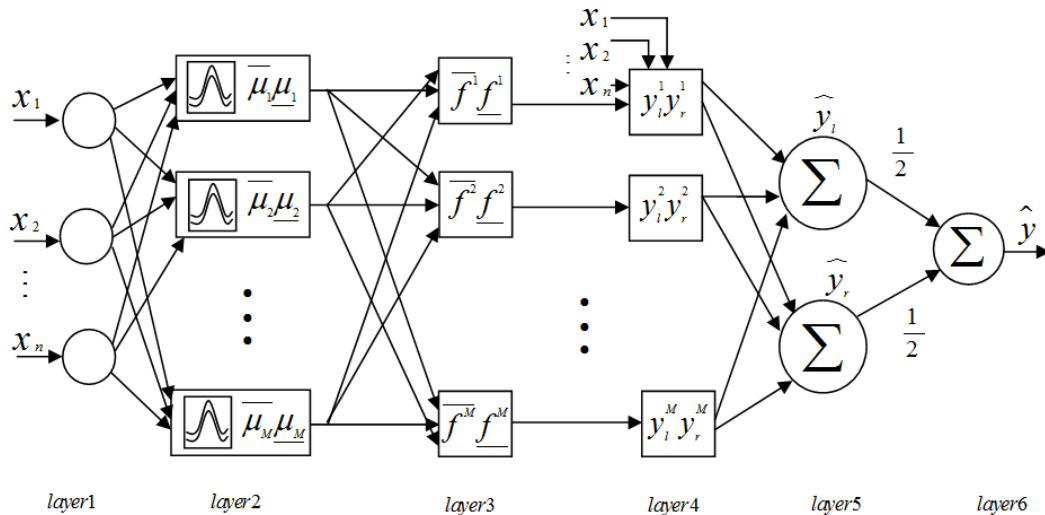
$$u^* = \frac{1}{g(x)} [-f(x) + y_d^{(n)} + \underline{c}^T \underline{e}] \quad (2)$$

که در آن y_d خروجی مطلوب می باشد. با جایگذاری u^* در رابطه (۱)، سیستم حلقه بسته به صورت زیر به دست می آید:

$$e^{(n)} + c_1 e^{(n-1)} + \dots + c_n e = 0 \quad (3)$$

لذا بردار ضرایب $\underline{c} = [c_1, c_2, \dots, c_n]^T$ به گونه ای انتخاب می شود که ریشه های چند جمله ای $s^n + c_1 s^{n-1} + \dots + c_n = 0$ در نیم صفحه باز سمت چپ صفحه مختلط واقع شوند. با انتخاب مناسب بردار \underline{c} ، $\lim_{t \rightarrow 0} |e(t)| \rightarrow 0$ یعنی با گذشت زمان خطای ردیابی به سمت صفر

همگرا شده و خروجی سیستم قادر به ردیابی خروجی مطلوب y_d می باشد. بنابراین اگر کنترل کننده ایده آل u^* قابلیت پیاده سازی را داشته باشد، سیستم کنترل شده پایدار خواهد بود [۲۶]. اما در عمل



شکل (۱): ساختار شبکه عصبی فازی نوع-۲ فاصله‌ای

لایه ۵: این لایه کاهش مرتبه را انجام می‌دهد.

$$\hat{y}_l = \frac{\sum_{k=1}^M \underline{f}_l^k y_l^k}{\sum_{k=1}^M \underline{f}_l^k} = \frac{\sum_{k=1}^L \bar{f}^k y_l^k + \sum_{k=L+1}^M \underline{f}^k y_l^k}{\sum_{k=1}^L \bar{f}^k + \sum_{k=L+1}^M \underline{f}^k} \quad (12)$$

$$\hat{y}_r = \frac{\sum_{k=1}^M \underline{f}_r^k y_r^k}{\sum_{k=1}^M \underline{f}_r^k} = \frac{\sum_{k=1}^R \underline{f}^k y_r^k + \sum_{k=R+1}^M \bar{f}^k y_r^k}{\sum_{k=1}^R \underline{f}^k + \sum_{k=R+1}^M \bar{f}^k} \quad (13)$$

در روابط (۱۲) و (۱۳) مقادیر R و L از الگوریتم زیر بدست می‌آیند [۲۹].

الگوریتم تعیین L : فرض کنیم $y_l^1 \leq y_l^2 \leq \dots \leq y_l^M$

(۱) \hat{y}_l را از رابطه (۹) و با جایگذاری $f_l^k = \frac{\bar{f}^k + \underline{f}^k}{2}$ و

$k=1, \dots, M$ محاسبه و سپس $y_l' = \hat{y}_l$ قرار دهید

(۲) مقدار L را در بازه $[1, M-1]$ طوری بیابید که

$$y_l^L \leq y_l' \leq y_l^{L+1}$$

(۳) در رابطه (۹) به ازای $k \leq L$ قرار دهید $f_l^k = \bar{f}^k$ و به

ازای $k > L$ قرار دهید $f_l^k = \underline{f}^k$ و \hat{y}_l را محاسبه و

سپس $y_l'' = \hat{y}_l$ قرار دهید.

(۴) اگر $y_l' \neq y_l''$ به مرحله ۵ برو و اگر $y_l' = y_l''$ قرار بده

$$\hat{y}_l = y_l''$$

(۵) $y_l' = y_l''$ قرار دهید و به مرحله ۲ بروید.

برای تعیین R این الگوریتم را بر روی دنباله $y_r^1 \leq y_r^2 \leq \dots \leq y_r^M$ بایستی اعمال شود.

$$\mu_{k,i}^1(x_i) = e^{-1/2 \left(\frac{x_i - m_{k,i}^1}{\sigma_{k,i}} \right)^2}; \mu_{k,i}^2(x_i) = e^{-1/2 \left(\frac{x_i - m_{k,i}^2}{\sigma_{k,i}} \right)^2} \quad (7)$$

$i = 1, \dots, n; k = 1, \dots, M$

$$\bar{\mu}_{k,i}(x_i) = \begin{cases} \mu_{k,i}^1(x_i) & x_i < m_{k,i}^1 \\ 1 & m_{k,i}^1 \leq x_i \leq m_{k,i}^2 \\ \mu_{k,i}^2(x_i) & x_i > m_{k,i}^2 \end{cases}$$

$$\underline{\mu}_{k,i}(x_i) = \begin{cases} \mu_{k,i}^2(x_i) & x_i \leq \frac{m_{k,i}^1 + m_{k,i}^2}{2} \\ \mu_{k,i}^1(x_i) & x_i > \frac{m_{k,i}^1 + m_{k,i}^2}{2} \end{cases} \quad (8)$$

$$i = 1, \dots, n, k = 1, \dots, M$$

در روابط (۷) و (۸) μ درجه عضویت گوسی، $m_{k,i}^1, m_{k,i}^2, \sigma_{k,i}$ به ترتیب حد بالا و پایین مرکز تابع عضویت گوسی و پراکندگی تابع گوسی و ورودی شبکه می‌باشد.

لایه ۳: این لایه قواعد است و قدرت آتش‌زنی بالا \bar{f}^k و پایین \underline{f}^k را برای هر قانون محاسبه می‌کند

$$\underline{f}^k = \prod_{i=1}^n \underline{\mu}_{k,i}, \quad \bar{f}^k = \prod_{i=1}^n \bar{\mu}_{k,i} \quad (9)$$

لایه ۴: این لایه، لایه نتیجه است که شامل گره‌های تطبیقی می‌باشد و حد چپ و راست قسمت نتیجه هر قانون را محاسبه می‌کند.

$$y_l^k = \sum_{i=1}^n c_{k,i} x_i + c_{k,0} - \sum_{i=1}^n s_{k,i} |x_i| - s_{k,0} \quad (10)$$

$$y_r^k = \sum_{i=1}^n c_{k,i} x_i + c_{k,0} + \sum_{i=1}^n s_{k,i} |x_i| + s_{k,0} \quad (11)$$

در روابط (۱۰) و (۱۱) $|x_i|$ بیانگر قدر مطلق ورودی می‌باشد.

خطا در مقایسه با $\eta = \eta_{\min}$ و $\eta = \eta_{\max}$ تغییر نکرد، آنگاه بایستی مقادیر η_{\min} ، η_{\max} را دوباره انتخاب کرد. این روش تا دوره نهایی ادامه خواهد داشت.

لایه ۶: این لایه یک گره دارد که خروجی را محاسبه می کند.

$$\hat{y} = \frac{\hat{y}_l + \hat{y}_r}{2} \quad (14)$$

۶- طراحی کنترل کننده تطبیقی غیرمستقیم

عصبی - فازی نوع-۲

در این بخش به دنبال جایگزین کردن توابع $f(x)$ و $g(x)$ با $\hat{f}_{T2FNN}(x)$ و $\hat{g}_{T2FNN}(x)$ حاصل از شبکه عصبی - فازی نوع-۲ هستیم.

با بازنویسی روابط (۱۲) و (۱۳) خواهیم داشت

$$\begin{aligned} \hat{y}_l &= \sum_{k=1}^L \bar{q}_l^k y_l^k + \sum_{k=L+1}^M \underline{q}_l^k y_l^k \\ &= [\bar{Q}_l \underline{Q}_l^T] \begin{bmatrix} y_l \\ y_l \end{bmatrix} = \xi_l^T \theta_l \end{aligned} \quad (15)$$

که در رابطه (۱۵) تعاریف زیر صورت گرفته است:

$$\begin{aligned} \xi_l^T &= [\bar{Q}_l \underline{Q}_l^T], \quad \theta_l = \begin{bmatrix} y_l \\ y_l \end{bmatrix} \\ \bar{Q}_l &= [\bar{q}_l^{-1}, \bar{q}_l^{-2}, \dots, \bar{q}_l^{-L}], \\ \underline{Q}_l^T &= [\underline{q}_l^{L+1}, \underline{q}_l^{L+2}, \dots, \underline{q}_l^M] \\ \bar{y}_l &= [y_l^1, y_l^2, \dots, y_l^L], \\ \underline{y}_l &= [y_l^{L+1}, y_l^{L+2}, \dots, y_l^M] \\ \bar{q}_l^k &= \frac{\bar{f}^k}{D_l}, \quad \underline{q}_l^k = \frac{\underline{f}^k}{D_l}, \\ D_l &= \sum_{k=1}^L \bar{f}^k + \sum_{k=L+1}^M \underline{f}^k \end{aligned} \quad (16)$$

هم چنین

$$\begin{aligned} \hat{y}_r &= \sum_{k=1}^R \underline{q}_r^k y_r^k + \sum_{k=R+1}^M \bar{q}_r^k y_r^k \\ &= [\underline{Q}_r \bar{Q}_r^T] \begin{bmatrix} y_r \\ y_r \end{bmatrix} = \xi_r^T \theta_r \end{aligned} \quad (17)$$

که در رابطه (۱۷) تعاریف زیر صورت گرفته است:

$$\begin{aligned} \xi_r^T &= [\underline{Q}_r \bar{Q}_r^T], \quad \theta_r = \begin{bmatrix} y_r \\ y_r \end{bmatrix} \\ \underline{Q}_r &= [\underline{q}_r^1, \underline{q}_r^2, \dots, \underline{q}_r^R], \quad \bar{Q}_r^T = [\bar{q}_r^{-R+1}, \bar{q}_r^{-R+2}, \dots, \bar{q}_r^{-M}] \\ \underline{y}_r &= [y_r^1, y_r^2, \dots, y_r^R], \\ \bar{y}_r &= [y_r^{R+1}, y_r^{R+2}, \dots, y_r^M] \\ \underline{q}_r^k &= \frac{\underline{f}^k}{D_r}, \quad \bar{q}_r^k = \frac{\bar{f}^k}{D_r}, \quad D_r = \sum_{k=1}^R \underline{f}^k + \sum_{k=R+1}^M \bar{f}^k \end{aligned} \quad (18)$$

خروجی شبکه در رابطه (۱۴) به صورت زیر خواهد بود:

۵- روش یادگیری و بروزرسانی نرخ یادگیری

یکی از مهم ترین مساله ها در روش یادگیری، همگرایی می باشد. در روش بیشترین نزول همگرایی به نرخ یادگیری وابسته است به نحوی که نرخ یادگیری کوچک موجب همگرایی آهسته می شود و نرخ یادگیری بزرگ هم می تواند موجب ناپایداری شود. مساله این است که نرخ یادگیری بزرگ اگر چه همگرایی را تضمین کند همواره نمی تواند موجب اجرای سریع الگوریتم شود به خصوص در حالت تکرارهای نهایی در نزدیکی نقطه بهینه که بایستی نرخ یادگیری کوچک باشد. بنابراین پیدا کردن نرخ یادگیری به نحوی که بتوان به نقطه بهینه با سرعت بالا رسید بسیار مفید می باشد. در این مقاله برای بالا بردن سرعت همگرایی شبکه عصبی - فازی نوع-۲ یک الگوریتم تطبیقی [۳۰] برای تعیین مناسب نرخ یادگیری بیان شده است. به این ترتیب که در هر دوره i نرخ یادگیری متفاوت می باشد و مقدار آن با توجه به علامت تابع هزینه تغییر می کند. بنابراین روش بروزرسانی نرخ یادگیری از ۲ قسمت تشکیل شده است:

• مقداردهی اولیه

این مرحله شامل سه دوره اول آموزش شبکه می باشد. ابتدا بازه $[\eta_{\min}, \eta_{\max}]$ شامل مقدار حداقل و حداکثر نرخ یادگیری به نحوی که همگرایی تضمین شود انتخاب می شوند. در دوره اول با استفاده از نرخ یادگیری حداقل $\eta = \eta_{\min}$ ، در دوره دوم با استفاده از نرخ یادگیری حداکثر $\eta = \eta_{\max}$ و در دوره سوم با استفاده از میانگین دو نرخ یادگیری حداقل و حداکثر $\eta = \frac{\eta_{\min} + \eta_{\max}}{2}$ آموزش شبکه انجام می شود.

• بروزرسانی نرخ یادگیری

در این قسمت نرخ یادگیری η مطابق تغییرات گرادیان تابع خطا بروزرسانی می شود. به این ترتیب زمانی که علامت گرادیان تابع خطا با استفاده از $\eta = \frac{\eta_{\min} + \eta_{\max}}{2}$ با علامت آن در زمان استفاده از $\eta = \eta_{\min}$ با هم متفاوت باشد آنگاه طول فاصله تغییرات نرخ یادگیری به صورت تغییر می کند $\left[\eta_{\min}, \left(\frac{\eta_{\min} + \eta_{\max}}{2} \right) \right]$. علاوه بر این اگر علامت گرادیان تابع خطا با استفاده از $\eta = \frac{\eta_{\min} + \eta_{\max}}{2}$ با علامت آن در زمان استفاده از $\eta = \eta_{\max}$ با هم متفاوت باشد آنگاه طول فاصله تغییرات نرخ یادگیری به صورت $\left[\left(\frac{\eta_{\min} + \eta_{\max}}{2} \right), \eta_{\max} \right]$ تغییر نکند. اگر علامت گرادیان تابع

و $\underline{b}=[0 \ 0 \ \dots \ 0 \ 1]^T$ بردار پارامترهای بهینه به صورت روابط زیر تعریف می شود:

$$\underline{\theta}_f^* = \arg \min_{\underline{\theta}_f \in R^n} \left[\sup_{\underline{x} \in R^n} |\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) - f(\underline{x})| \right] \quad (27)$$

$$\underline{\theta}_g^* = \arg \min_{\underline{\theta}_g \in R^n} \left[\sup_{\underline{x} \in R^n} |\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) - g(\underline{x})| \right] \quad (28)$$

هم چنین حداقل خطای تقریب به صورت زیر تعریف می شود:

$$\psi = [\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) - f(\underline{x})] + [\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) - g(\underline{x})] \quad (29)$$

با استفاده از روابط (۲۷) و (۲۸)، رابطه معادله خطای (۲۴) به صورت رابطه زیر در می آید:

$$\dot{\underline{e}} = \Lambda \underline{e} + \underline{b} \left[[\underline{\theta}_f - \underline{\theta}_f^*]^T \underline{\xi}_f(\underline{x}) + [\underline{\theta}_g - \underline{\theta}_g^*]^T \underline{\xi}_g(\underline{x}) \right] u - \quad (30)$$

حال هدف بدست آوردن بردار پارامترهای $\underline{\theta}_f$ و $\underline{\theta}_g$ به گونه ای که سیستم کنترل حلقه بسته پایدار و خطای تعقیب \underline{e} به ازای کاهش خطاهای پارامتری $\underline{\theta}_f - \underline{\theta}_f^*$ و $\underline{\theta}_g - \underline{\theta}_g^*$ حداقل گردد. برای به دست آوردن قوانین تطبیق، قضیه زیر مطرح شده و با استفاده از آن، قوانین تطبیق به صورت زیر به دست می آیند:

$$\begin{aligned} \dot{\underline{\theta}}_f &= -\gamma_1 e^T P \underline{b} \underline{\xi}_f(\underline{x}) \\ \dot{\underline{\theta}}_g &= -\gamma_2 e^T P \underline{b} \underline{\xi}_g(\underline{x}) \end{aligned} \quad (31)$$

در این رابطه γ_1 و γ_2 ضرایب ثابت مثبت می باشند و $\underline{\xi}_f(\underline{x})$ و $\underline{\xi}_g(\underline{x})$ از رابطه (۱۹) بدست می آیند.

قضیه: اگر ورودی کنترل رابطه (۲۰) به سیستم غیرخطی رابطه (۱) اعمال شود، \hat{f} و \hat{g} با رابطه (۱۹) داده شوند و بردارهای پارامترهای $\underline{\theta}_f$ و $\underline{\theta}_g$ طبق قوانین تطبیقی رابطه (۳۱) تنظیم شوند، در این صورت:

(الف) خطای ردیابی و خطای تقریب پارامترهای کراندار هستند و سیستم حلقه بسته پایدار لیپانوفی می باشد.

(ب) خطای ردیابی و مشتقات آن به صورت مجانبی به صفر همگرا می گردند.

اثبات (الف): تابع لیپانوف زیر را در نظر می گیریم:

$$V = \frac{1}{2} e^T P e + \frac{1}{2\gamma_1} \underline{\phi}_f^T \underline{\phi}_f + \frac{1}{2\gamma_2} \underline{\phi}_g^T \underline{\phi}_g \quad (32)$$

که در آن $\underline{\phi}_f = \underline{\theta}_f - \underline{\theta}_f^*$ و $\underline{\phi}_g = \underline{\theta}_g - \underline{\theta}_g^*$ می باشند و γ_1 و γ_2 ضرایب ثابت مثبت و P یک ماتریس متقارن مثبت معین که در معادله لیپانوف (۲۵) صدق می کند. مطابق با قضیه لیپانوف، اگر مشتق تابع لیپانوف مذکور منفی نیمه معین باشد، آنگاه سیستم پایدار

$$\hat{y} = \frac{\hat{y}_l + \hat{y}_r}{2} = \frac{1}{2} (\xi_l^T \theta_l + \xi_r^T \theta_r) \quad (19)$$

$$= \frac{1}{2} \begin{bmatrix} \xi_l^T & \xi_r^T \end{bmatrix} \begin{bmatrix} \theta_l \\ \theta_r \end{bmatrix} = \xi^T \theta$$

که در آن $\frac{1}{2} \begin{bmatrix} \xi_l^T & \xi_r^T \end{bmatrix} = \xi^T$; $\begin{bmatrix} \theta_l^T & \theta_r^T \end{bmatrix} = \theta^T$ می باشند.

بنابراین با توجه به رابطه (۱۹) می توان نوشت:

$$\hat{f}_{T2FNN}(\underline{x}) = \hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f)$$

$$\hat{g}_{T2FNN}(\underline{x}) = \hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g)$$

پس کنترل کننده تطبیقی غیرمستقیم به صورت رابطه زیر به دست می آید:

$$u = \frac{1}{\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g)} \left[-\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) + y_d^{(n)} + \underline{c}^T \underline{e} \right] \quad (20)$$

خروجی شبکه عصبی- فازی نوع-۲ به صورت زیر است:

$$\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) = \underline{\theta}_f^T \underline{\xi}_f(\underline{x}) \quad (21)$$

$$\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) = \underline{\theta}_g^T \underline{\xi}_g(\underline{x})$$

با توجه به رابطه (۲۱):

$$\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) - \hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f^*) = \underline{\theta}_f^T \underline{\xi}_f(\underline{x}) - \underline{\theta}_f^{*T} \underline{\xi}_f(\underline{x}) \quad (22)$$

$$\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) - \hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g^*) = \underline{\theta}_g^T \underline{\xi}_g(\underline{x}) - \underline{\theta}_g^{*T} \underline{\xi}_g(\underline{x})$$

با قرار دادن رابطه (۲۰) در رابطه (۱) و بعد از انجام محاسبات رابطه زیر به دست می آید:

$$\begin{aligned} \dot{e}^{(n)} &= -\underline{c}^T \underline{e} + [\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) - f(\underline{x})] \\ &+ [\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) - g(\underline{x})] u \end{aligned} \quad (23)$$

رابطه (۲۳) را می توان به صورت زیر نوشت:

$$\dot{\underline{e}} = \Lambda \underline{e} + \underline{b} \left\{ [\hat{f}_{T2FNN}(\underline{x}|\underline{\theta}_f) - f(\underline{x})] + [\hat{g}_{T2FNN}(\underline{x}|\underline{\theta}_g) - g(\underline{x})] u \right\} \quad (24)$$

که Λ از رابطه (۲۶) محاسبه می شود. از طرفی ضرایب \underline{c} در رابطه (۳) به نحوی انتخاب می شوند که چند جمله ای $\det(sI - \Lambda) = s^n + c_n s^{n-1} + \dots + c_1$ پایدار شود. بنابراین ماتریس Λ یک ماتریس پایدار است و همچنین یک ماتریس متقارن مثبت معین P به طور یکتا وجود دارد که در معادله لیپانوف زیر صدق می کند:

$$\Lambda^T P + P \Lambda = -Q \quad (25)$$

در رابطه (۲۵) Q یک ماتریس مثبت معین دلخواه می باشد و

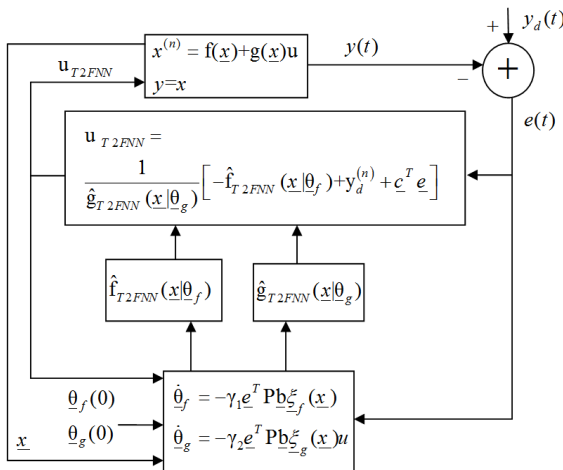
$$\Lambda = \begin{bmatrix} 0 & 1 & \dots & 0 & \dots & 0 \\ 0 & \vdots & \ddots & 0 & \vdots & 1 \\ -c_1 & -c_2 & \dots & -c_{n-1} & \dots & -c_n \end{bmatrix} \quad (26)$$

طرفی طبق رابطه (۳۵) می توان نتیجه گرفت که $\lim_{t \rightarrow \infty} e(t) = 0$ ، از طرفی چون $e = [e, \dot{e}, \dots, e^{(n-1)}]^T$ می باشد پس می توان گفت

$$\dot{V} \leq -\frac{1}{2} e^T Q e \quad (35)$$

$$\lim_{t \rightarrow \infty} e^{(n-1)}(t) = 0 \quad \text{و} \quad \lim_{t \rightarrow \infty} \dot{e}(t) = 0 \quad \text{و} \quad \lim_{t \rightarrow \infty} e(t) = 0$$

در شکل (۲) بلوک دیباگرام کنترل کننده عصبی- فازی نوع-۲ تطبیقی به روش غیر مستقیم نشان داده شده است.



شکل(۲): ساختار کنترل کننده عصبی- فازی نوع-۲ تطبیقی به روش غیر مستقیم

۴- ساده سازی شبکه های عصبی- فازی نوع-۲

با توجه به اینکه مدل های عصبی- فازی نوع-۲ نسبت به مدل های چند جمله ای پیچیده تر هستند، بنابراین جهت گسترش موارد استفاده از مدل های عصبی- فازی نوع-۲ بایستی این مدل ها هر چه بیشتر ساده شوند. در این مقاله روش پیشنهادی برای ساده سازی شبکه های عصبی- فازی نوع-۲، کاهش تعداد قواعد فازی است. با توجه به اینکه تعداد پارامترهای قسمت نتیجه، وابسته به تعداد قواعد است، لذا

کاهش تعداد قواعد منجر به کاهش تعداد پارامترهای قسمت نتیجه می شود. روش پیشنهادی جهت کاهش تعداد قواعد، هم به صورت دستی و هم به صورت خودکار قابل اعمال است. در این روش، ابتدا با توجه به تعداد توابع عضویت فازی نوع-۲ برای هر ورودی در قسمت شرط، تعداد کل قواعد (n) محاسبه می شوند. سپس ترکیب های

r-تایی از n قاعده تشکیل شده $\binom{n}{r} = \frac{n!}{r!(n-r)!}$ و طی یک

الگوریتم خودکار می توان کمترین مقدار r که منجر به کمترین مقدار خطای مدل می شود، پیدا کرد. نحوه انتخاب این r قاعده به این صورت است که ابتدا از تعداد قواعد کمتر شروع کرده و اگر دقت مناسب حاصل نشد، تعداد قواعد یکی یکی زیاد می شوند تا دقت

لیاپانوفی است. حال با مشتق گیری از رابطه (۳۲) و با استفاده از رابطه (۳۱) پس از انجام محاسبات، مشتق تابع لیاپانوف برابر است با:

$$\begin{aligned} \dot{V} = & -\frac{1}{2} e^T Q e - e^T Q b \psi + \\ & \frac{1}{\gamma_1} \phi_f^T [\dot{\phi}_f + \gamma_1 e^T P b \xi_f(x)] + \\ & \frac{1}{\gamma_2} \phi_g^T [\dot{\phi}_g + \gamma_2 e^T P b \xi_g(x)] u \end{aligned} \quad (33)$$

با فرض اینکه قوانین تطبیقی به صورت رابطه (۳۱) انتخاب شوند دو عبارت آخر رابطه (۳۳) صفر می شوند و مشتق تابع لیاپانوف را می توان به صورت زیر نوشت:

$$\dot{V} = -\frac{1}{2} e^T Q e - e^T Q b \psi \quad (34)$$

بر اساس [۳۱]، شبکه های عصبی- فازی نوع-۲ دارای خاصیت تقریب زنی عمومی در فضای $L^2(R)$ می باشند. از طرفی با توجه به اینکه با تعداد محدودی قوانین فازی و نرون های عصبی، شبکه های عصبی- فازی نوع-۲ جهت توصیف سیستم کافی می باشند. می توان ϵ_ψ را به نحوی انتخاب کرد که حداقل خطای تقریب ψ کران دار باشد و در شرط $|\psi| \leq \epsilon_\psi$ صدق کند. با توجه به این نامساوی و رابطه (۲۹) و (۲۱) به ازای x کران دار $\xi_f(x)$ و $\xi_g(x)$ نیز کران دار بوده و در نتیجه u کران دار می باشد.

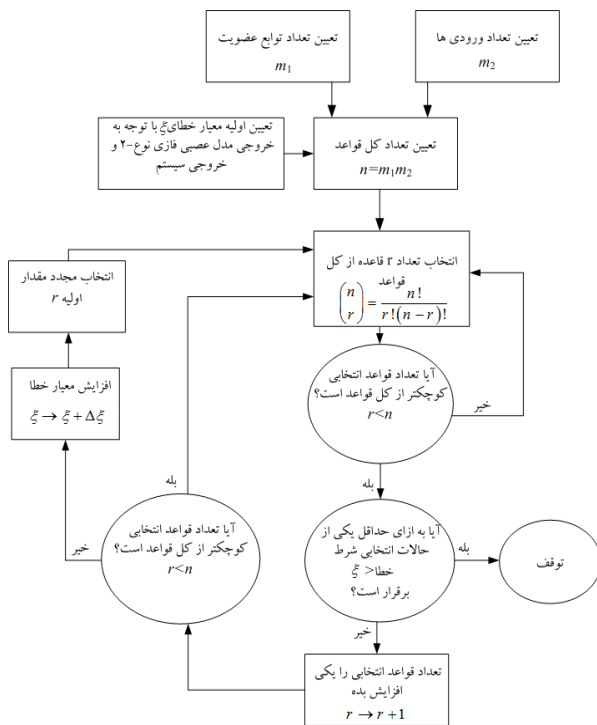
با انتخاب ϵ_ψ آن چنان که $\epsilon_\psi \leq \frac{1}{2} |b^T Q b|^{-1/2} |e^T Q e|^{1/2}$ و با توجه به $|e^T Q b \psi| \leq \epsilon_\psi |e^T Q b|$ ، و با استفاده از نامساوی کوشی- شوارتز خواهیم داشت:

$$|e^T Q b \psi| \leq |e^T Q^2 Q^2 e|^{1/2} |b^T Q^2 Q^2 b|^{1/2}$$


بنابراین می توان از عبارت $-e^T Q b \psi$ در برابر $-\frac{1}{2} e^T Q e$ صرف نظر کرد. بنابر این مشتق تابع لیاپانوف به صورت رابطه (۳۵) به دست می آید:

طبق رابطه (۳۵) مشتق تابع لیاپانوف منفی معین است و از این رو بر اساس قضایای روش مستقیم لیاپانوف، سیستم حلقه بسته پایدار لیاپانوفی می باشد. از طرفی چون تابع لیاپانوف رابطه (۳۲) مثبت معین و مشتق آن منفی معین می باشد، در نتیجه بردار پارامترهای e, ϕ_f, ϕ_g کراندار می باشند.

اثبات (ب): از آنجایی که تابع لیاپانوف دارای کران پایین است و مشتق آن منفی معین می باشد همچنین با توجه به کراندار بودن بردار پارامترهای e, ϕ_f و ϕ_g ، با استفاده از لم باربالت [۱]، به ازای $e \in L_2$ ، \dot{e} نیز کراندار خواهد بود. بنابراین $\lim_{t \rightarrow \infty} \dot{V}(t) = 0$ ، از



شکل (۳): فلوچارت روش پیشنهادی جهت ساده‌سازی مدل عصبی- فازی نوع-۲



شکل (۴): سیستم دوتانک

۸- نتایج شبیه‌سازی

در این قسمت ابتدا سیستم دوتانک، که یک سیستم دینامیکی غیرخطی است معرفی می‌شود و سپس با روش کنترل تطبیقی غیرمستقیم عصبی- فازی نوع-۲، کنترل می‌شود. در شکل (۴) نمایی از سیستم دوتانک آمده است. سیستم دوتانک به صورت رابطه (۳۶) می‌باشد [۳۲].


$$\begin{aligned} \dot{z}_1 &= -c_1\sqrt{z_1} + c_2\sqrt{z_2} \\ \dot{z}_2 &= c_1\sqrt{z_1} - 2c_2\sqrt{z_2} + U_{in}/A \\ y &= z_1 \end{aligned} \quad (36)$$

در این رابطه


$$\begin{aligned} z_1 &= h_2 > 0, \quad z_2 = h_1 - h_2 > 0 \\ c_1 &= a_2\sqrt{2g}/A, \quad c_2 = a_{12}\sqrt{2g}/A \end{aligned} \quad (37)$$

به تانک ۱ می‌باشند. هم‌چنین a_{12}, a_2, g و A به ترتیب ثابت h_2, h_1 سطح ارتفاع آب تانک ۱ و تانک ۲، U_{in} نرخ جریان ورودی


مناسب بدست آید. به عنوان مثال فرض کنید یک شبکه عصبی- فازی نوع-۲ دارای دو ورودی و برای هر کدام سه تابع عضویت در نظر گرفته شده باشد، در این حالت تعداد کل قواعد برابر $3 \times 3 = 9$ می‌باشد. تعداد ترکیب‌های دو قاعده‌ای برابر ۳۶ حالت و ترکیب‌های سه قاعده‌ای برابر ۸۴ حالت خواهد بود. باید در نظر داشت که در حالت داشتن چهار قاعده تعداد پارامترهای قسمت شرط $(\sigma_{k,i}, m_{k,i}^1, m_{k,i}^2)$ برابر $12 \times 6 = 72$ و پارامترهای قسمت نتیجه $c_{k,i}^j, s_{k,i}^j$ برابر $24 \times 4 = 96$ می‌باشد. در صورتی که با کاهش قواعد به دو قاعده تعداد پارامترهای قسمت نتیجه $12 \times 2 = 24$ خواهد بود. پس قواعد کمتر یا حداقل قواعد (در اینجا ۲ قاعده) با حفظ دقت مورد انتظار می‌باشد. برای روشن تر شدن موضوع، یک شبکه عصبی- فازی نوع-۲ فاصله‌ای را در نظر بگیرید که این شبکه دارای دو ورودی هر کدام با دو تابع عضویت گوسی فازی نوع-۲ است. بنابراین برای این شبکه چهار قاعده تعریف می‌شود. جهت اعمال روش پیشنهادی کاهش قواعد ابتدا فرض می‌شود با دو قاعده بتوان یک سیستم را به عنوان مثال شناسایی کرد، بنابراین جهت انتخاب دو قاعده از چهار قاعده ۶ حالت وجود دارد. با امتحان کردن هر ۶ حالت اگر حداقل خطای مورد نظر حاصل شد که آن حالت با دو قاعده می‌تواند جایگزین شبکه چهار قاعده‌ای شود. البته در انتخاب هر یک از این ۶ حالت این دقت در انتخاب وجود دارد که حالتی را که موجب از دست رفتن مودهای اصلی جواب می‌شوند (یعنی موجب ناپایداری و از بین رفتن جواب مطلوب می‌شوند) انتخاب نشوند. اما اگر پس از امتحان کردن هر شش حالت، حداقل خطای مورد نظر حاصل نشد تعداد قواعد را به سه قاعده افزایش می‌دهیم. جهت انتخاب سه قاعده از چهار قاعده، چهار حالت وجود دارد. با تکرار مراحل قبل اگر با سه قاعده حداقل خطا بدست آمد که شبکه با سه قاعده می‌تواند جایگزین شبکه با چهار قاعده شود، در غیر این صورت بایستی معیار خطا را مقداری بیشتر در نظر گرفت و مراحل فوق را دوباره تکرار کرد. اگر باز هم حداقل خطای مورد نظر بدست نیامد الگوریتم بصورت خودکار معیار خطا را اندکی افزایش داده و مراحل فوق تکرار می‌شود. در شکل (۳) فلوچارت روش پیشنهادی جهت ساده‌سازی مدل عصبی- فازی نوع-۲ نشان داده شده است.



شکل (۶): سیگنال کنترل متناظر با کنترل کننده تطبیقی غیرمستقیم عصبی-فازی نوع-۲ و ANFIS بدون حضور نویز سفید



شکل (۷): عملکرد کنترل کننده تطبیقی غیرمستقیم عصبی-فازی نوع-۲ و ANFIS در حضور نویز سفید



شکل (۸): سیگنال کنترل متناظر با کنترل کننده تطبیقی غیرمستقیم عصبی-فازی نوع-۲ و ANFIS در حضور نویز سفید

۹- نتیجه گیری

در این مقاله، یک کنترل کننده عصبی-فازی نوع-۲ تطبیقی به روش غیرمستقیم برای سیستم‌های آفین غیرخطی تک‌ورودی - تک‌خروجی پیشنهاد شد. در این روش که براساس نظریه فیدبک خطی‌ساز و شبکه‌های عصبی-فازی نوع-۲ می‌باشد، ورودی کنترلی فیدبک خطی‌ساز با استفاده از دو شبکه عصبی-فازی نوع-۲ تقریب زده می‌شود. در این قسمت از الگوریتم گرادیان نزولی با نرخ یادگیری تطبیقی استفاده شد. این روش از سایر روش‌هایی موجود ساده‌تر است. نداشتن پارامتر اضافی در قانون بروزرسانی و همچنین افزایش دقت از جمله مزیت‌های این روش می‌باشد. با استفاده از نظریه پایداری لیاپانوف، با بیان یک قضیه پایداری سیستم حلقه بسته تضمین قوانین بروز رسانی پارامترهای شبکه عصبی-فازی نوع-۲ نیز بدست آمد. روش ساده‌سازی مدل عصبی-فازی نوع-۲ در این مقاله، کاهش تعداد قواعد فازی بود. همچنین نتایج حاصل از شبیه‌سازی سیستم

گرایش، سطح دهانه خروجی، سطح دهانه بین دوتانک و مقطع عرضی تانک‌های ۱ و ۲ است. در اینجا هدف رسیدن سطح ارتفاع آب در تانک دوم h_2 به مقدار مرجع $H = 5cm$ می‌باشد. در اینجا:


$$A = 208.2cm^2, a_2 = 0.24cm^2, a_{21} = 0.58cm^2, g = 981 \frac{cm}{sec^2}$$

$$c_1 = 2 \quad c_2 = 1, P = \begin{pmatrix} 15 & 5 \\ 5 & 5 \end{pmatrix}, Q = \text{diag}(10,10)$$

شبکه عصبی فازی نوع-۲ دارای دو ورودی می‌باشد و سه تابع عضویت فازی نوع-۲ گوسی با عدم قطعیت در میانگین، برای هر ورودی در نظر گرفته شده است. برای ساده‌سازی شبکه سه قانون فازی برای شبکه عصبی-فازی نوع-۲ فاصله‌های معرفی شده در نظر گرفته می‌شود. همچنین روش یادگیری برخط برای بروزرسانی پارامترهای شبکه استفاده شده است.

در شکل (۵) سیگنال خروجی سیستم کنترل شده با روش تطبیقی غیرمستقیم عصبی-فازی نوع-۲ به همراه نتیجه حاصل از ANFIS و نشان داده شده است. هم چنین در شکل (۶) سیگنال کنترلی متناظر با روش پیشنهادی و ANFIS نمایش داده شده است. در اینجا برای نشان دادن مقاوم بودن روش پیشنهادی نسبت به عدم قطعیت‌ها، نویز سفید گوسی با میانگین صفر و واریانس $0.1 \times [33]$ به سیگنال‌های ورودی شبکه‌های عصبی-فازی نوع-۲ و ANFIS اضافه می‌کنیم. نتایج حاصل از روش پیشنهادی و ANFIS و سیگنال کنترلی متناظر به ترتیب در شکل (۷) و شکل (۸) نشان داده شده است.

همان طور که در شکل (۷) دیده می‌شود، خروجی حاصل از ANFIS در حضور نویز سفید دچار نوسان می‌شود ولی کنترل کننده تطبیقی غیرمستقیم عصبی-فازی نوع-۲ به خوبی سیگنال مرجع را تعقیب می‌کند. در این مقاله به دلیل استفاده از منطق فازی نوع-۲ و روش کنترل تطبیقی خطای دنبال کردن در حضور و عدم حضور نویز کمتر از روش استفاده از ANFIS بود.



شکل (۹): عملکرد کنترل کننده تطبیقی غیرمستقیم عصبی-فازی نوع-۲ و ANFIS بدون حضور نویز سفید

- Controller Based on Genetic Algorithms and Particle Swarm Optimization,” *Expert Systems with Applications*, Vol. 38, pp. 11217-11229, 2011.
- [18] C. H. Wang, C. S. Cheng and T. T. Lee, “Dynamical Optimal Training for Interval Type-2 Fuzzy Neural Network (T2FNN),” *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, Vol. 14, pp. 808-821, 2006.
- [19] V. V. J. Rajapandian and N. Gunaseeli, “Modified Standard Back Propagation Algorithm With Optimum Initialization for Feedforward Neural Networks,” *Int. J. of Image Sci. Eng.*, Vol. 1, No. 3, pp. 86-89, 2007.
- [20] T. Kathirvalavakumar and P. Thangavel, “A Modified Backpropagation Training Algorithm for Feedforward Neural Networks,” *Neural Processing Letters*, Vol. 23, pp. 111-119, 2006.
- [21] S. Abid, F. Fnaiech and M. Najim, “A Fast Feed Forward Training Algorithm Using a Modified Form of The Standard Backpropagation Algorithm,” *IEEE Transactions on Neural Network*, Vol. 12, No. 2, pp. 424-430, 2001.
- [22] M. B. Nasr and M. Chtourou, “A Hybrid Training Algorithm for Feedforward Neural Network,” *Neural Processing Letters*, Vol. 24, pp. 107-117, 2006.
- [23] Y. Li, Y. Fu, H. Li and S.W. Zhang, “The Improved Training Algorithm of Backpropagation Neural Network with Self-Adaptive Learning Rate,” *Proceedings of IEEE International Conference on Computer Intelligence and Natural Computer*, Vol. 1, pp. 73-76, 2009.
- [24] F. Diotalevi, M. Valle and D. D. Cavaglia, “Evaluation of Gradient Descent Learning Algorithms With an Adaptive Local Rate Technique for Hierarchical Feedforward Architectures,” *Proceedings of IEEE International Joint Conference on Neural Network*, Vol. 2, pp. 185-190, 2000.
- [25] A. Isidori, *Nonlinear Control systems*, 3rd Edition, Berlin, Springer-Verlag, 1995.
- [26] L. X. Wang, *Adaptive Fuzzy Systems and Control: Design and Stability Analysis*, Upper Saddle River, NJ, Prentice-Hall, 1994.
- [27] N. N. Karnik, J. M. Mendel and Q. Liang, “Type-2 Fuzzy Logic Systems,” *IEEE Transactions on Fuzzy Systems*, Vol. 120, pp. 643-658, 1999.
- [28] J. M. Mendel, “Advances in Type-2 Fuzzy Sets and Systems,” *Information Sciences*, Vol. 177, pp. 84-110, 2007.
- [29] J. M. Mendel, *Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions*, NJ, Prentice-Hall, 2001.
- [30] M. Davanipoor, M. Zekri and F. Sheikholeslam, “Fuzzy Wavelet Neural Network with an Accelerated Hybrid Learning Algorithm,” *IEEE Transactions on Fuzzy Systems*, Vol. 20, No. 3, pp. 463-470, 2012.
- [31] J. R. Castro, O. Castillo, P. Melin, and A. Rodríguez-Díaz, “Universal Approximation of a Class of Interval Type-2 Fuzzy Neural Networks Illustrated with the Case of Non-linear Identification,” *Conference of European Society for Fuzzy Logic and Technology*, pp. 1382-1387, 2009.
- [32] N. B. Almutairi and M. Zribi, “Sliding Mode Control of Coupled Tanks,” *Mechatronics*, Vol. 16, pp. 427-441, 2006.
- [33] H. W. Ge, W. L. Du, F. Qian and Y. C. Liang, “Identification and Control of Nonlinear Systems by A Time-delay Recurrent Neural Network,” *Neurocomputing*, Vol. 72, pp. 2857-2864, 2009.
- دوتانک در حضور نویز سفید نشان داد که کنترل کننده پیشنهادی در مقایسه با ANFIS در حضور داده‌های نویزی عملکرد بهتری دارد.
- ### مراجع
- [1] J. E. Slotine and W. Li, *Applied Nonlinear Control*, Englewood Cliffs, NJ, Prentice-Hall, 1991.
- [2] H. K. Khalil, *Nonlinear Systems*, 3rd Edition, Englewood Cliffs, NJ, Prentice-Hall, 2005.
- [3] R. M. Sanner and J. J. E. Slotine, “Gaussian Networks for Direct Adaptive Control,” *IEEE Transactions on Neural Networks*, Vol. 3, No. 6, pp. 837-863, 1992.
- [4] J. T. Spoonera and K. M. Passino, “Stable Adaptive Control Using Fuzzy Systems and Neural Networks,” *IEEE Transactions on Fuzzy Systems*, Vol. 4, No. 3 pp. 339-358, 1996.
- [5] I. Kar and L. Behera, “Direct Adaptive Neural Control for Affine Nonlinear Systems,” *Applied Soft Computing*, Vol. 9, pp. 756-764, 2009.
- [6] A. Baberi, M. Zekri and S. Hosseini, “Indirect Adaptive Neuro Fuzzy Controller for a Class of Non-Linear Systems,” *IEEE Conference on Computer Science and Automation Engineering*, 2011.
- [7] L. A. Zadeh, “The Concept of a Linguistic Variable and Its Application to Approximate Reasoning—I,” *Information Sciences*, Vol. 8, pp. 199-249, 1975.
- [8] J. M. Mendel, R. I. John and F. Liu, “Interval Type-2 Fuzzy Logic Systems Made Simple,” *IEEE Transactions on Fuzzy Systems*, Vol. 14, pp. 808-821, 2006.
- [9] N. N. Karnik and J. M. Mendel, “Applications of Type-2 Fuzzy Logic Systems to Forecasting of Time-series,” *Information Sciences*, Vol. 120, pp. 89-111, 1999.
- [10] P. Melin, O. Mendoza and O. Castillo, “An Improved Method for Edge Detection Based on Interval Type-2 Fuzzy Logic,” *Expert Systems with Applications*, Vol. 37, pp. 8527-8535, 2010.
- [11] H. A. Hagra, “A Hierarchical Type-2 Fuzzy Logic Control Architecture for Autonomous Mobile Robots,” *IEEE Transactions on Fuzzy Systems*, Vol. 12, pp. 524-539, 2004.
- [12] Q. Liang and J. M. Mendel, “Equalization of Nonlinear Time-Varying Channels Using Type-2 Fuzzy Adaptive Filters,” *IEEE Transactions on Fuzzy Systems*, Vol. 8, pp. 551-563, 2000.
- [13] J. R. Castro, O. Castillo, P. Melin and A. Rodríguez-Díaz, “A hybrid Learning Algorithm for a Class of Interval Type-2 Fuzzy Neural Networks,” *Information Sciences*, Vol. 179, pp. 2175-2193, 2009.
- [۱۴] مرادی فراهانی، ح، عسگری، ج و ذکری، م. “شناسایی سیستم‌های دینامیکی غیرخطی در حضور داده‌های نویزی با شبکه‌های عصبی فازی نوع-۲”، سومین کنفرانس بین المللی اتوماسیون صنعتی ایران، تهران، دانشگاه صنعتی شریف ۱۳۹۱.
- [15] R. H. Abiyev, O. Kaynak, T. Alshanebleh and F. Mamedov, “A Type-2 Neuro-Fuzzy System Based on Clustering and Gradient Techniques Applied to System Identification and Channel Equalization,” *Applied Soft Computing*, Vol. 11, pp. 1396-1406, 2011.
- [16] R. Martínez, O. Castillo and L. T. Aguilar, “Optimization of Interval Type-2 Fuzzy Logic Controllers for a Perturbed Autonomous Wheeled Mobile Robot Using Genetic Algorithms,” *Information Sciences*, Vol. 179, pp. 2158-2174, 2009.
- [17] S. K. Oh, H. J. Jang and W. Pedrycz, “A Comparative Experimental Study of Type-1/Type-2 Fuzzy Cascade

زیر نویس ها

- ¹ Type-2 Fuzzy Sets
- ² Particle Swarm Optimization
- ³ Global Minimum
- ⁴ Learning Rate Adaptation Coefficient
- ⁵ Affine
- ⁶ Halving Method
- ⁷ Interval
- ⁸ Epoch