مجله مهندسی مکانیک مدرس، دی 1395، دوره 16، شماره 10، ص‌ص 163-172

ماهنامه علمی پژوهشی

مهندسی مکانیک مدرس

mme.modares.ac.ir

کنترل کننده نروفازی بازوهای مکانیکی ماهر صلب-انعطاف‌پذیر با توابع عضویت هوشمند

سید محمد رضا فریطوس[1]، هادی همایی[2*]، شهرام هادیان جزی[3]

1- دانشجوی دکتری، مهندسی مکانیک، دانشگاه شهرکرد، شهرکرد
2- استادیار، مهندسی مکانیک، دانشگاه شهرکرد، شهرکرد
3- استادیار، مهندسی مکانیک، دانشگاه اصفهان، اصفهان
* شهرکرد، صندوق پستی 115 ، hadi-h@eng.sku.ac.ir

اطلاعات مقاله

مقاله پژوهشی کامل
دریافت: 18 تیر 1395
پذیرش: 16 شهریور 1395
ارائه در سایت: 18 مهر 1395

کلید واژگان:
بازوی مکانیکی انعطاف‌پذیر
کنترل کننده نروفازی
شبکه عصبی بازگشتی پویا

چکیده

این مقاله یک سیستم کنترل نرو فازی جدید را برای کنترل بازوهای مکانیکی ماهر صلب- انعطاف‌پذیر ارایه می‌دهد. ارتقاء عملکرد کنترل کننده فازی و هوشمندسازی در واحدهای فازی‌ساز و غیرفازی‌ساز، از اهداف موردنظر این تحقیق هستند. سیستم کنترل پیشنهادی شامل کنترل کننده فازی در قسمت پسخورد و شبکه عصبی در قسمت پیشخورد است. شبکه وظیفه تخمین دینامیک معکوس دستگاه و نیز تولید فرمان کنترلی را به‌عهده دارد. به روزرسانی ضرایب وزنی شبکه، با استفاده ازخروجی قسمت فازی و بر روی خط انجام می‌شود. از طرفی برای هوشمند سازی واحد فازی‌ساز، از دو شبکه عصبی بازگشتی پویا استفاده شده است. شبکه ها وظیفه تنظیم ضرایب اصلی توابع عضویت را در کنترل کننده فازی به‌عهده دارند. ورودی این شبکه‌ها خطا و نرخ تغییر خطا هستند و وزن های آن‌ها با استفاده از الگوریتم پس انتشار خطا انجام می‌شود. جهت تصدیق و کارآمدی روش ارایه شده، شبیه‌سازی برای بازوی مکانیکی ماهر با سه رابط که رابط انتهایی انعطاف‌پذیر است، انجام شده است. پاسخ سیستم به ورودی پله و ورودی سینوسی به‌طور مجزا برای کنترل کننده فازی و کنترل کننده پیشنهادی به‌دست آمده و با یکدیگر مقایسه شده‌اند. مقایسه و بررسی‌های انجام شده، نشان از کارآمدی روش ارایه شده دارد.

Neuro-fuzzy Controller of Rigid-Flexible Manipulators with Intelligence Membership Function

Seyed Mohammad Reza Faritus[1], Hadi Homaei[1*], Shahram Hadian Jazi[2]

1- Faculty of Engineering, Shahrekord University, Shahrekord, Iran
2- Department of Mechanical Engineering, University of Isfahan, Isfahan, Iran
* P.O.B.115, Shahrekord, Iran, hadi-h@eng.sku.ac.ir

ARTICLE INFORMATION

Original Research Paper
Received 08 July 2016
Accepted 06 September 2016
Available Online 09 October 2016

Keywords:
Flexible Manipulator
Neuro-fuzzy Controller
Dynamic Recurrent Neural Network

ABSTRACT

This paper presents a new Neuro-fuzzy control system to control rigid-flexible manipulators. Enhancing the performance of fuzzy controller and intelligence in fuzzy and non-fuzzy units is the goal of this research. Proposed control system includes a fuzzy controller in the feedback and a neural network is the feed-forward. The network has the responsibility of estimating the inverse dynamic of device and then, the production of control command. Updating weighting coefficients of network is done online using the fuzzy controller output. On the other hand, two dynamic recurrent neural networks are used for making fuzzy unit intelligent. Networks are responsible for regulating the main factors of membership functions in the fuzzy controller. The input of these networks is error and error change rate and their weights are done by using an error back-propagation algorithm. To verify the effectiveness of the proposed method, simulation is conducted for skilled manipulators with three interfaces where the end interface is flexible. System responses to step input and sinusoidal input are separately obtained for fuzzy controllers and proposed controller and compared. Comparison and studies indicate the effectiveness of the provided method.

1- مقدمه

استفاده از رابط‌ها و قطعات حجیم در بازوهای مکانیکی، سبب کاهش ارتعاش و افزایش دقت حرکت پنجه می‌شود. ولی پیامد آن علاوه بر بالا رفتن مصرف انرژی و هزینه های ساخت، افزایش اینرسی و کاهش سرعت در هنگام نیاز به عکس‌العمل سریع خواهد بود. استفاده از رابط‌های سبک‌تر علاوه بر کاهش مصرف انرژی، سرعت و ایمنی عملیات را بالا برده و قابلیت مانور را ارتقاء می‌بخشد. همچنین باعث کاهش سختی سازه ربات شده که نتیجه آن افزایش تغییر شکل خمشی خواهد بود. با افزایش ارتعاش مکانیکی، کارایی ربات کاهش یافته و کنترل آن مشکل می شود. بنابراین در دو دهه گذشته مساله تعقیب مسیر در ربات های انعطاف‌پذیر و فرمول‌بندی معادلات حرکت و کنترل سیستم‌های چند بازویی صلب-انعطاف‌پذیر به یکی از مهمترین زمینه‌های تحقیقاتی بدل گشته است [1-6]. روش‌های سنتی، از یک مدل ریاضی که رفتار دینامیکی دستگاه را توصیف می‌کند برای طراحی سیستم کنترل اتوماتیک بهره می‌برند [8,7]. چنین مدلی شامل مجموعه‌ای از

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Please cite this article using:
S. M. R. Faritus, H. Homaei, Sh. Hadian Jazi, Neuro-fuzzy Controller of Rigid-Flexible Manipulators with Intelligence Membership Function, *Modares Mechanical Engineering*, Vol. 16, No. 10, pp. 163-172, 2016 (in Persian)

معادلات دیفرانسیل خطی و غیرخطی است که اکثر آن‌ها از تخمین‌ها و ساده‌سازی به‌دست می‌آیند. به‌علت کوپله و غیرخطی بودن معادلات دینامیکی ربات‌ها و نیز حضور عدم قطعیت‌ها[1]، تهیه مدل دقیق ریاضی و استخراج معادلات حرکت با مشکل مواجه خواهد شد. در این شرایط،کنترل کننده‌های سنتی که براساس مدل[2] هستند، عملکرد لازم را نداشته و مناسب نخواهند بود [9]. در این شرایط کنترل کننده باید توانایی مقابله با تاثیرات ارتعاشات گذرا و پیچیده را داشته باشد.

در سال‌های اخیر، کنترل کننده‌های هوشمند (مثل شبکه عصبی و منطق فازی) که بدون نیاز به دانش مقدماتی دینامیک سیستم عمل می‌کنند، توجه بسیاری از محققان را به خود جلب کرده‌اند [10]. شبکه عصبی جزو دسته محاسبات سطح پایین قرار می‌گیرد و قابلیت یادگیری، محاسبات موازی و تخمین شرایط پیچیده غیرخطی را دارد. کنترل براساس منطق فازی (FLC) یکی دیگر از روش‌های هوشمند است که از استراتژی کنترل زبانی[3]برای استخراج فرمان کنترل استفاده می‌کند. این روش کنترلی به مدل دقیق دینامیکی احتیاجی ندارد ولی به یک مدل ریاضی (جهت پیش بینی پاسخ سیستم) برای استخراج قواعد فازی نیازمند است [11]. در سال های اخیر شبکه عصبی و منطق فازی هر یک به‌طور مستقل یا ترکیبی، در سیستم‌های کنترل ربات و بازوهای مکانیکی به‌کار گرفته شده‌اند و زمینه تحقیقاتی بسیاری از پژوهشگران بوده اند [13,12].

هو و همکاران، کنترل کننده عصبی را برای بازوهای مکانیکی مقید پیشنهاد کردند [14]. شبکه به‌صورت حلقه پیشخورد برای جبران عدم قطعیت‌ها در دینامیک ربات استفاده شده بود و وزن‌های آن، روی خط[4] به روزرسانی می‌گردید. میرشکاران و همکاران از کنترل کننده مود لغزشی[5] نوع PID که در آن بهره‌ها با استفاده از منطق فازی تنظیم می‌شدند، برای کاهش ارتعاشات پنجه استفاده کردند [15]. عبدالهی و همکاران، دو نوع کنترل کننده، یکی با تکنیک جایدهی قطب (براساس مدل) و دیگری بر پایه منطق فازی طراحی نمودند. سپس نتایج تعقیب مسیر و ارتعاش حاصل از شبیه سازی را بین دو کنترل کننده، مورد مقایسه قرار دادند [16]. ژانگ و همکاران مدل عصبی جفتی تک لایه را ارایه دادند [17]. این شبکه یک روش محاسباتی توزیع شده موازی است که بازوی مکانیکی با درجه آزادی اضافی[6] را بر روی خط کنترل می‌کند. سهامی جو و همکاران از نوعی PID که به کنترل کننده فازی شبیه بود، استفاده کردند [18]. در این روش، کنترل کننده سه ورودی P، D و I دارد که هر یک از این ورودی‌ها از چندین متغیر زبانی برای توصیف رفتارشان بهره می‌برند. آن‌ها به‌کمک شبیه‌سازی، نتایج روش خود را با کنترل کننده PID مقایسه نمودند.

در تحقیقاتی که روی کنترل کننده‌های نروفازی صورت گرفته، قسمت فازی وظیفه تولید فرمان کنترل را به عهده دارد. شبکه عصبی نیز برای مدل سازی و تخمین دینامیک معکوس دستگاه استفاده شده و تلاشی جهت بکارگیری (همزمان) آن به‌عنوان بهبود دهنده گشتاور فرمان نشده است. همچنین توابع عضویت از شروع فرآیند کنترل ثابت بوده و در اکثر آنها از شبکه عصبی یا الگوریتم های تکاملی برای تنظیم بهره‌ها استفاده شده است و هوشمندسازی واحد فازی ساز مورد توجه جدی قرار نگرفته است. در حالی‌که با کوچک شدن مقادیر خطا، نرخ خطا و تغییر شکل خمشی، عملکرد توابع عضویت کاهش می‌یابند و لزوم استفاده از توابع عضویتی که با تغییر ورودی بطور خودکار به‌روزرسانی شوند، ضروری به‌نظر می‌رسد. در این مقاله، کنترل کننده نروفازی جدیدی برای کنترل بازوی مکانیکی صلب- انعطاف‌پذیر ارایه می‌شود. این سیستم شامل یک کنترل کننده فازی است که در یک چهارچوب پسخوردی، برای تولید سیگنال‌های کنترل به‌کار گرفته می‌شود. قسمت دیگر کنترل کننده که وظیفه اصلاح و بهبود سیگنال کنترل را به‌عهده دارد، یک شبکه عصبی بازگشتی پویا[7] به‌نام DRN است که خروجی حالت سیستم را دریافت کرده و دینامیک معکوس را مدل‌سازی می‌کند. وزن‌های این واحد عصبی، با استفاده از خروجی FLC به روزرسانی می‌شوند. با این روش، قابلیت سیستم برای سازگاری با عدم قطعیت‌های دینامیکی افزایش می‌یابد. بلافاصله بعد از به‌روزرسانی وزن‌ها، بردار حالت مطلوب به عنوان سیگنال ورودی وارد شبکه DRN شده و گشتاور فرمان را تولید و کارایی FLC را ارتقاء می‌بخشد. شبکه DRN از نوع بازگشتی پویا بوده و نسبت به شبکه‌های پس انتشار خطا از قدرت محاسباتی بیشتری برخوردار است. همچنین با توجه به حضور عنصر حافظه دار در این نوع شبکه، سرعت همگرایی در آن به مقدار قابل توجهی افزایش یافته است.

اکثر مقالات برای هوشمندسازی کنترل کننده فازی نوع PD و PID به تنظیم کردن بهره‌های P، D و یا I پرداخته‌اند و هوشمندسازی واحد فازی‌ساز مورد توجه جدی قرار نگرفته است. به این معنی که به‌جای استفاده از توابع عضویت ثابت (در طول فرایند کنترل) این توابع به‌صورت خودکار در هر مرحله تنظیم و به‌روزرسانی می‌شوند. در این تحقیق هوشمند کردن واحد فازی‌ساز، با کمک دو شبکه عصبی بازگشتی بنام‌های NNE و NNCE انجام می‌گیرد. این شبکه‌ها وظیفه تنظیم ضرایب اصلی توابع عضویت خطا و تغییر خطا را در کنترل کننده فازی به عهده دارند. خطا و نرخ تغییر خطا به عنوان ورودی وارد شبکه‌ها شده و وزن‌های شبکه با استفاده از یک الگوریتم پس انتشار خطا، بر روی خط به روزرسانی می‌شوند. جهت تصدیق و کارآمدی روش ارایه شده، شبیه‌سازی برای بازوی مکانیکی ماهر با سه رابط که رابط انتهایی انعطاف‌پذیر است، انجام شده است. پاسخ‌های سیستم به ورودی های پله و سینوسی به‌طور مجزا برای کنترل کننده‌های فازی و کنترل کننده پیشنهادی استخراج و سپس با یکدیگر مقایسه شده‌اند. مقایسه و بررسی‌های انجام شده، نشان از کارآمدی روش ارایه شده دارند.

در بخش 2 با استفاده از انرژی سیستم و با کمک معادلات لاگرانژ و روش مود فرضی[8]، معادلات حرکت دینامیکی بازوی مکانیکی استخراج می‌شوند. بخش 3 به کنترل کننده فازی اختصاص داده شده است. بخش 4 فرمول بندی شبکه عصبیDRN انجام شده است. بخش 5 به هوشمند کردن توابع عضویت FLC در واحد فازی‌ساز و معادلات شبکه‌های NNE و NNCE می پردازد. در فصل 6 شبیه سازی بازوی مکانیکی ماهر با سه رابط انجام شده است و پاسخ سیستم به کنترل کننده فازی و کنترل کننده پیشنهادی مورد مقایسه قرار گرفته اند. بخش 7 به نتیجه‌گیری اختصاص داده شده است.

2- معادلات حاکم

"شکل 1" بازوی مکانیکی با N رابط که رابط انتهایی آن انعطاف‌پذیر است را نشان می‌دهد. M_i، τ_i و θ_i به ترتیب هاب، گشتاور هاب و زاویه نسبی مفصل رابط i ام می‌باشند. XOY چهارچوب مختصات اینرسیال و $x_iO_iy_i$ چهارچوب

[1] uncertainty
[2] model base controller
[3] linguistic
[4] on-line
[5] sliding mode controller
[6] Redundant Manipulator
[7] Dynamic Recurrent Neural Network
[8] Assumed Modes Method

مختصاتی متحرک است که مرکز آن هاب رابط i ام است. تیر انعطاف‌پذیر به‌صورت تیر اولر- برنولی در نظر گرفته شده است، به این معنی که از تاثیر تغییر شکل برشی و اینرسی چرخشی صرف‌نظر شده است. به‌علت وجود انعطاف‌پذیری، ابعاد سیستم نامحدود است. یکی از روش‌های مناسب جهت گسسته‌سازی، روش مود فرضی است. در این تحقیق از روش مود فرضی جهت تخمین تغییر شکل الاستیک تیر استفاده شده است. در این روش، تغییر شکل الاستیک تیر انعطاف‌پذیر به‌صورت ترکیب خطی حاصل ضرب توابع مودی و توابع زمانی در نظر گرفته می‌شود:

$$\delta(x_N,t) = \sum_{j=1}^{M} \psi_j(x_N)\phi_j(t) \tag{1}$$

$\delta(x_N,t)$ تغییر شکل خمشی تیر انعطاف‌پذیر در فاصله x_N از مفصل N ام در دستگاه مختصاتی $x_N O_N y_N$ و لحظه t است. ψ_j توابع مودی، ϕ_j توابع تعمیم یافته وابسته-زمانی و M تعداد مودهای ارتعاشی می‌باشند. در مرجع [19] طریقه محاسبه توابع مودی و فرکانس‌های طبیعی تیر انعطاف‌پذیر با شرایط مرزی تیر یک سر درگیر-یک سر آزاد با بار انتهایی، ارایه گردیده است. توابع مودی برای رابط انعطاف‌پذیر به‌صورت ذیل تعیین می‌شوند:

$$\phi_j(x_N) = \left(\cos\beta_j x_N - \cosh\beta_j x_N\right) - \frac{\cos\beta_j l_N + \cosh\beta_j l_N}{\sin\beta_j l_N + \sinh\beta_j l_N} \times \left(\sin\beta_j x_N - \sinh\beta_j x_N\right) \tag{2}$$

l_N طول رابط انعطاف‌پذیر است. β_jها از حل معادله ذیل حاصل می‌گردند:

$$1 + \cos\beta_j l_N \times \cosh\beta_j l_N - \frac{m}{m_N}\beta_j l_N \times \left(\sinh\beta_j l_N \times \cos\beta_j l_N - \sin\beta_j l_N \times \cosh\beta_j l_N\right) = 0 \tag{3}$$

m و m_N به‌ترتیب جرم بار و جرم رابط انعطاف‌پذیر است. فرکانس‌های طبیعی ω_j نیز با استفاده از از رابطه (4) به‌دست می‌آیند:

$$\omega_j = \sqrt{\frac{E_N I_N}{\rho_N A_N}}\beta_j^2 \tag{4}$$

که ρ_N، A_N، I_N و E_N به ترتیب چگالی، سطح مقطع، ممان اینرسی و مدول یانگ رابط N ام و ω_j ها فرکانس‌های طبیعی تیر هستند. انرژی جنبشی بازوی مکانیکی، برابر با مجموع انرژی جنبشی رابط‌ها، موتورها و بار است.

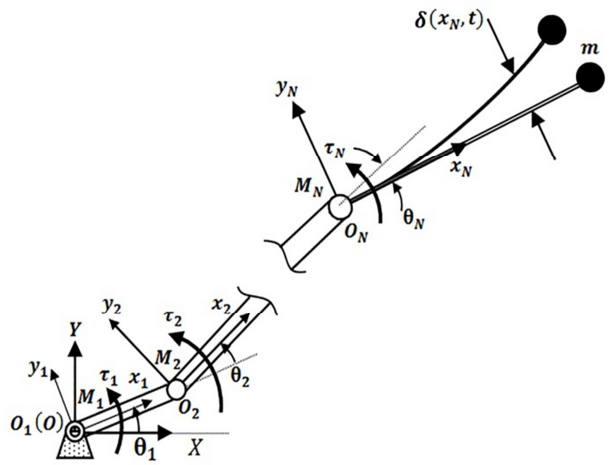

Fig. 1 Manipulator with the last flexible arm

شکل 1 بازوی مکانیکی با رابط انتهایی انعطاف پذیر

لذا داریم:

$$T = \frac{1}{2}\sum_{i=1}^{N}\int_0^{L_i}\rho_i A_i \dot{R}_i^{\mathrm{T}}\dot{R}_i dx_i + \frac{1}{2}m\,\dot{R}_m^{\mathrm{T}}\dot{R}_m + \frac{1}{2}\sum_{i=1}^{N}\left(m_{M.i}\dot{R}_{M.i}^{\mathrm{T}}\dot{R}_{M.i} + I_{M.i}\omega_{M.i}^2\right) \tag{5}$$

$R_{M.i}$ بردار مکان و $\omega_{M.i}$ سرعت زاویه‌ای مرکز موتور مفصل رابط i ام و $m_{M.i}$ و $I_{M.i}$ جرم و ممان اینرسی آن‌ها هستند. همچنین R_m بردار مکان بار و R_i بردار مکان نقطه‌ای عمومی روی رابط انعطاف‌پذیر می‌باشد. ρ_i و A_i به ترتیب چگالی و سطح مقطع رابط i ام هستند. انرژی پتانسیل بازوی مکانیکی از مجموع انرژی پتانسیل گرانشی و انرژی حاصل از تغییر شکل الاستیک در رابط انعطاف‌پذیر حاصل می‌گردد. لذا انرژی پتانسیل را می‌توان به‌صورت ذیل محاسبه نمود:

$$Q = \frac{1}{2}E_N I_N\int_0^{l_N}\left[\frac{\partial^2\delta(s,t)}{\partial s^2}\right]^2 ds + \sum_{i=1}^{N}\int_0^{l_i}\rho_i A_i Y_i\, g\, dx_i \tag{6}$$

جائی‌که E_N و I_N به‌ترتیب ضریب سختی و ممان اینرسی رابط انعطاف‌پذیر و g شتاب ثقل است. با جای‌گذاری رابطه (1) در (6) مقدار انرژی پتانسیل محاسبه می‌گردد.

کار مجازی گشتاور τ_i برابر است با $\delta\mathcal{W}_i = \tau_i\delta\theta_i$، می‌توان معادلات حرکت را با استفاده از روش لاگرانژ به‌دست آورد:

$$\frac{d}{dt}\left(\frac{\partial\mathcal{L}}{\partial\dot{\theta}_i}\right) - \frac{\partial\mathcal{L}}{\partial\theta_i} = \tau_i \quad ; \quad i = 1,2,\dots,N \tag{7-الف}$$

$$\frac{d}{dt}\left(\frac{\partial\mathcal{L}}{\partial\dot{\phi}_j}\right) - \frac{\partial\mathcal{L}}{\partial\phi_j} = 0 \quad ; \quad j = 1,2,\dots,M \tag{7-ب}$$

که $\mathcal{L} = T - Q$ لاگرانژین و θ_i و ϕ_j مختصات تعمیم یافته هستند. با محاسبه مشتق لاگرانژین نسبت به مختصات تعمیم یافته و مشتقات زمانی آن‌ها و جای‌گذاری در روابط (7)، معادلات حرکت استخراج می شوند. با مرتب کردن معادلات به شکل ماتریسی، $n = N + M$ معادله دینامیکی بازوی مکانیکی به‌صورت ذیل خواهند شد:

$$\begin{bmatrix} C_{\theta\theta}(\theta,\phi) & C_{\theta\phi}(\theta,\phi) \\ C_{\theta\phi}^{\mathrm{T}}(\theta,\phi) & C_{\phi\phi}(\theta,\phi)\end{bmatrix}\begin{bmatrix}\ddot{\theta}\\ \ddot{\phi}\end{bmatrix} + G(\theta,\phi,\dot{\theta},\dot{\phi}) = \begin{bmatrix}\tau\\ 0\end{bmatrix} \tag{8-الف}$$

$$G = D(\theta,\phi)\begin{bmatrix}\dot{\theta}\\ \dot{\phi}\end{bmatrix} + K(\theta,\phi)\begin{bmatrix}\theta\\ \phi\end{bmatrix} + F(\theta,\phi,\dot{\theta},\dot{\phi}) \tag{8-ب}$$

ماتریس اینرسی $C \in \Re^{n\times n}$ متقارن بوده و شامل ماتریس‌های $C_{\theta\theta} \in \Re^{N\times N}$ ، $C_{\theta\phi} \in \Re^{N\times M}$ و $C_{\phi\phi} \in \Re^{M\times M}$ است. همچنین $D \in \Re^{n\times n}$ ماتریس میرایی، $K \in \Re^{n\times n}$ ماتریس سختی و $F \in \Re^{n}$ بردار مجموع نیروهای غیرخطی مثل کریولیس، جاذبه و گریز از مرکز است. $\ddot{\theta},\dot{\theta},\theta \in \Re^{N}$ به‌ترتیب بردارهای زاویه، سرعت و شتاب مفاصل و $\tau \in \Re^{N}$ بردار گشتاور موتورها می‌باشد. علامت T به‌عنوان اندیس بالا، نشانه ماتریس ترانهاده است.

3- کنترل کننده فازیFLC

تئوری منطق فازی این امکان را ایجاد می‌کند تا ادراک انسانی در غالب قوانین ریاضی به‌کار گرفته شوند. معمولا FLC شامل عبارات شرطی زبانی است که توسط نیروی انسانی ماهر استخراج شده و ارایه کننده دانش او در ارتباط با سیستم کنترل است. FLC جزو دسته محاسبات سطح بالا است و از دانش فرد خبره بهره می‌برد و به‌علت عدم حساسیت به تغییرات محیطی،

جزو کنترل کننده‌های مقاوم محسوب می‌شود [20].

در "شکل 2" مراحل اصلی کنترل کننده فازی نشان داده شده است. این مراحل شامل فازی‌سازی، دانش پایه، استنتاج و غیرفازی سازی است. به‌علت این‌که ورودی حاصل از سنسورها به‌صورت عددی است، ابتدا هر ورودی باید فازی‌سازی شود. این کار با متناظر کردن هر ورودی به یک مجموعه متغیر فازی صورت می‌گیرد. سپس به هر متغیر یک تابع عضویت اختصاص می‌یابد که محدوده این تابع از صفر تا یک خواهد بود. توابع مثلثی و توانی دو نوع تابع عضویت معمول هستند که در این مقاله از تابع توانی استفاده می‌شود. همچنین با استفاده از دانش پایه که شامل مجموعه‌های فازی در قالب عبارات زبانی است، مجموعه ای از قوانین کنترل به‌صورت "اگر-آنگاه" استخراج خواهد شد. در ادامه واحد استنتاج که یک واحد فرآیندی است، خروجی را براساس قوانین فازی تولید می‌کند. خروجی واحد استنتاج به شکل فازی بوده و برای استفاده در عملگر ها باید در واحد غیرفازی‌ساز به داده قطعی (crisp) تبدیل گردد. روش مرکز جرم و روش متوسط وزن دار دو روش شناخته شده و پر کاربرد در غیرفازی‌سازی هستند [21]. محاسبه گشتاور فرمان در واحد غیرفازی‌ساز با استفاده از روش متوسط وزن‌دار به صورت ذیل به‌دست می‌آید:

$$u = \frac{\sum_{h=1}^{r} U_h \prod_{j=1}^{b} \mu_j(x_h)}{\sum_{h=1}^{r} \mu_j(x_h)} \tag{9}$$

x_j ورودی و μ_j مقدار عضویت سیگنال ورودی x_j در مجموعه زبانی $E(j)$ و r تعداد عضوهای این مجموعه هستند. b تعداد ورودی ها (خطا و تغییر خطا)، U_h مرکز سطح محدوده‌های مثلثی تابع عضویت خروجی و u سیگنال گشتاور هستند.

4- شبکه DRN

شبکه عصبی مصنوعی یک سیستم پردازش داده‌ها است که توسط شبکه‌ای از المان‌های عملیاتی به نام نورون انجام می‌شود. از ویژگی‌های مهم شبکه عصبی می‌توان به قابلیت یادگیری، تخمین شرایط پیچیده غیرخطی و محاسبات موازی اشاره نمود. علاوه بر این موارد، به‌علت سرعت مناسب همگرایی، تلاش‌های مهم و مستمری برای توسعه آن در کنترل سیستم‌های غیرخطی انجام شده و در حال انجام است [22].

در شبکه‌های ایستای عصبی چند لایه، خروجی هر نورون با اعمال تابع فعال‌ساز غیرخطی بر روی مجموع ورودی‌های وزن‌دار به آن نورون، ایجاد شده و به لایه بعدی منتقل می‌شود.

در این شرایط پسخورد برای نورون‌ها وجود ندارد و خروجی آن‌ها به‌صورت پیشخورد به لایه بعدی منتقل می‌شود. شبکه عصبی بازگشتی پویا

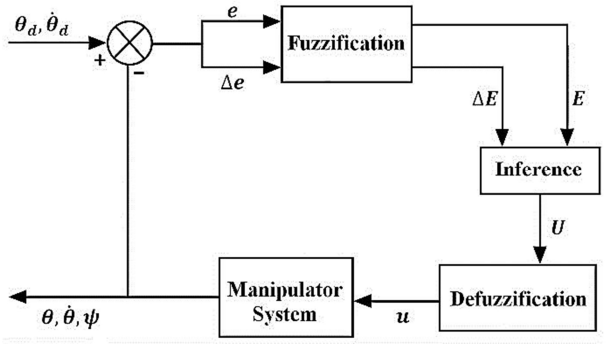

Fig. 2 Diagram of FLC

شکل 2 نمودار کنترل کننده فازی

هر دو نوع اتصال پیشخورد و پسخورد بین لایه‌ها و نورون‌ها را به‌کار می‌گیرد.

یکی از مزیت‌های این نوع شبکه، در تخمین سیستم‌های پیوسته و گسسته غیرخطی است. این تخمین توسط معادلات غیرخطی مجموعه نورون های دینامیکی صورت می‌گیرد که باعث افزایش سازگاری شبکه با چنین سیستم هایی می شود. این شبکه به‌صورت یک سیستم یادگیرنده روی خط عمل کرده و به شکل یک زیرسیستم در کنترل کننده تعبیه می‌گردد. در این شرایط، وزن‌های شبکه با استفاده از الگوریتم یادگیری پویا در طول فرایند کنترل به‌روزرسانی می‌شوند.

"شکل 3" ساختار شبکه عصبی بازگشتی پویا را نشان می‌دهد. شبکه شامل چهار لایه ورودی، میانی (پنهان)، خروجی و بازگشتی[1] است. نقش لایه بازگشتی، اضافه کردن خروجی لایه دوم مرحله قبلی در روابط به روزرسانی وزن‌های این لایه است. شبکه عصبی DRN وظیفه مدل‌سازی دینامیک معکوس را به‌عهده دارد. وزن‌های شبکه، با استفاده از خروجیFLC به‌روزرسانی می‌شوند. بعد از بروزرسانی وزن‌ها، این شبکه در قسمت پیشخورد قرار گرفته و با دریافت بردار حالت مطلوب سیستم، گشتاور مفاصل را تولید و کارایی FLC را ارتقاء می‌بخشد.

"شکل 4" نمایی شماتیک از محل قرارگیری و شرایط ورودی-خروجی DRN را نشان می‌دهد.

شبکه از سه لایه ورودی، مخفی و خروجی تشکیل شده است. لایه میانی (لایه مخفی) شامل نورون‌هایی است که با اتصالات بازگشتی به هم مرتبط می‌شوند.

ورودی لایه اول به‌صورت زیر می‌باشد:

$$IP_i^{(1)}(k) = x_i(k)\ ; \quad i = 1, 2, \dots, N \tag{10}$$

$IP_i^{(1)}$ ورودی لایه اول است که i شماره نورون در لایه ورودی و k

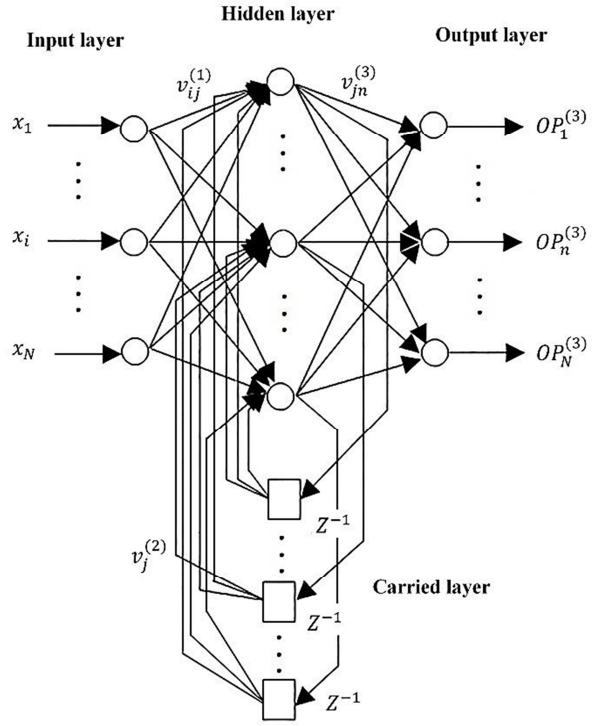

Fig. 3 Dynamic Recurrent Neural Network

شکل 3 ساختار شبکه عصبی بازگشتی پویا

[1] carried layer

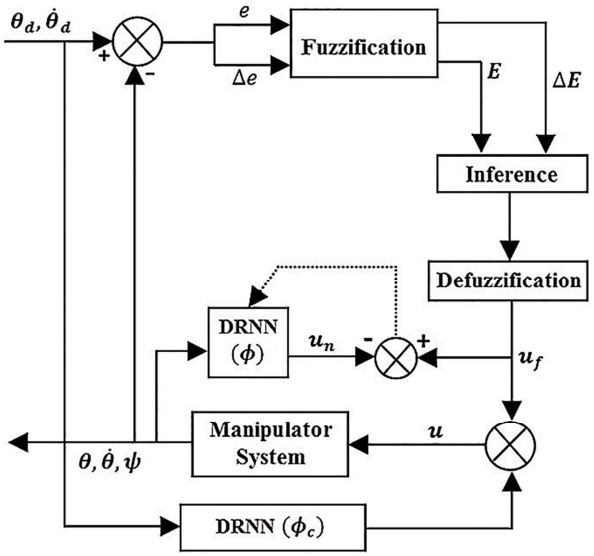

Fig. 4 DRN neural network

شکل 4 شبکه عصبی DRN

مرحله کنترل است. بردار ورودی X^{T} برابر است با:

$$X^{\mathrm{T}}(k) = (x_1, x_2, \dots, x_N) \qquad \text{(11- الف)}$$

$$x_i = (\theta_i, \dot{\theta}_i, \ddot{\theta}_i) \qquad \text{(11- ب)}$$

لایه های میانی (مخفی) را به‌صورت ذیل تعریف می‌کنیم:

$$OP_j^{(2)}(k) = f(IP_j(k))\,; \quad j = 1, 2, \dots, p \qquad (12)$$

$$IP_j(k) = v_j^{(2)} OP_j^{(2)}(k-1) + \sum_{i=1}^{3N} v_{ij}^{(1)}\, x_i(k) \qquad (13)$$

جائی‌که p تعداد نورون‌های لایه میانی، j شماره نورون، $IP_j(k)$ و $OP_j^{(2)}(k)$ به‌ترتیب ورودی و خروجی jامین نورون در لایه مخفی، $v_{ij}^{(1)}$ وزن‌های ورودی‌ها به لایه میانی و $v_j^{(2)}$ وزن نورون‌های لایه بازگشتی هستند. تابع فعال‌سازی f به‌صورت ذیل می‌باشد:

$$f(IP) = \frac{2}{1 + e^{-\alpha . IP}} - 1 \qquad (14)$$

برای لایه خروجی داریم:

$$OP_n^{(3)}(k) = u_n(k) = \sum_{j=1}^{p} v_{jn}^{(3)}\, OP_j^{(2)}(k)\ ;\ n = 1, 2, \dots, N \qquad (15)$$

که $OP_n^{(3)}(k)$ خروجی لایه سوم و $v_{jn}^{(3)}$ وزن‌های نورون‌های لایه خروجی هستند. تابع هدف به‌صورت ذیل است:

$$J_{\mathrm{DRN}} = \frac{1}{2}\sum_{n=1}^{N} \epsilon_n^2(k) \quad ; \quad i = 1, 2, \dots, N \qquad \text{(16- الف)}$$

$$\epsilon_n = u_{f,n}(k) - u_n(k) \qquad \text{(16- ب)}$$

که u_n و $u_{f,n}$ به ترتیب خروجی i ام شبکه DRN و واحد فازی است. برای به‌روزرسانی لایه‌ها از روش نزولی گرادیان یا الگوریتم یادگیری تطبیقی براساس قانون دلتای توسعه یافته استفاده می‌کنیم [23]. در این نوع الگوریتم، بردارهای وزن در جهت منفی گرادیان تابع هدف و برای کمینه کردن آن به‌روزرسانی می‌گردند. ابتدا برای وزن‌های $v_{jn}^{(3)}$ داریم:

$$\frac{\partial J_{\mathrm{DRN}}}{\partial v_{jn}^{(3)}} = \epsilon_n \frac{\partial \epsilon_n}{\partial v_{jn}^{(3)}}$$

$$= -\epsilon_n(k) \frac{\partial OP_n^{(3)}(k)}{\partial v_{jn}^{(3)}} = -\epsilon_n(k) OP_j^{(2)}(k) \qquad (17)$$

برای وزن‌های $v_j^{(2)}$ داریم:

$$\frac{\partial J_{\mathrm{DRN}}(k)}{\partial v_j^{(2)}(k)} = \epsilon_n \frac{\partial \epsilon_n(k)}{\partial v_j^{(2)}(k)} = \epsilon_n(k) \frac{\partial \epsilon_n(k)}{\partial u_n(k)} \frac{\partial OP_n^{(3)}(k)}{\partial OP_n^{(2)}(k)} \times \frac{\partial OP_n^{(2)}(k)}{\partial v_j^{(2)}} = -\epsilon_n(k) v_{jn}^{(3)}(k) \zeta_{jn}(k) \qquad (18)$$

که ζ_{jn} به‌صورت ذیل به‌دست می‌آید:

$$\zeta_{jn}(k) = \frac{\partial OP_n^{(2)}(k)}{\partial v_j^{(2)}} = f'\left(IP_j^{(2)}(k)\right) \times \left(OP_j^{(2)}(k-1) + v_j^{(2)} \frac{\partial OP_j^{(2)}(k-1)}{\partial v_j^{(2)}}\right) = f'\left(IP_j^{(2)}(k)\right)\left(OP_j^{(2)}(k-1) + v_j^{(2)} \zeta_{jn}(k-1)\right) \qquad (19)$$

جائی‌که $f'(IP(k))$ با استفاده از رابطه (14) به‌صورت زیر محاسبه می‌گردد:

$$f'(IP) = \frac{1}{2}\alpha . \left(1 - f^2(IP)\right) \qquad (20)$$

با توجه به بازگشتی بودن رابطه (19) می‌توان برای $k = 1$ با $\zeta_{jn}(0) = 0$ شروع نمود. برای وزن های $v_{ij}^{(1)}$ داریم:

$$\frac{\partial J_{\mathrm{DRN}}}{\partial v_{ij}^{(1)}(k)} = \sum_{n=1}^{N} \epsilon_n \frac{\partial \epsilon_n(k)}{\partial v_{ij}^{(1)}(k)} = \sum_{n=1}^{N} \epsilon_n(k) \frac{\partial \epsilon_n(k)}{\partial u_n(k)} \frac{\partial OP_n^{(3)}(k)}{\partial \partial v_{ij}^{(1)}(k)} = -\sum_{n=1}^{N}\sum_{j=1}^{p} \epsilon_n(k) \frac{\partial OP_n^{(3)}(k)}{\partial OP_j^{(2)}(k)} \frac{\partial OP_j^{(2)}(k)}{\partial v_{ij}^{(1)}(k)} = -\sum_{n=1}^{N}\sum_{j=1}^{p} \epsilon_n(k) v_{jn}^{(3)}(k) \frac{\partial OP_j^{(2)}(k)}{\partial v_{ij}^{(1)}(k)} \qquad (21)$$

جائی‌که $\varsigma_{ij}(k)$ به‌صورت ذیل به‌دست می‌آید:

$$\varsigma_{ij}(k) = \frac{\partial OP_j^{(2)}(k)}{\partial v_{ij}^{(1)}(k)} = \left(x_i(k) + v_j^{(2)} \frac{\partial OP_j^{(2)}(k-1)}{\partial v_{ij}^{(1)}}\right) = f'\left(IP_j(k)\right)\left(x_i(k) + v_j^{(2)} \varsigma_{ij}(k-1)\right) \qquad (22)$$

در این‌جا نیز مشابه رابطه (19) با توجه به بازگشتی بودن رابطه(22) می‌توان برای $k = 1$ با $\varsigma_{ij}(0) = 0$ شروع نمود. به‌روزرسانی وزن‌ها از روش نزولی گرادیان، به‌صورت زیر انجام می‌شود:

$$\Delta v = -\kappa_D \left(\frac{\partial J_{\mathrm{DRN}}}{\partial v}\right) \qquad (23)$$

که κ_D نرخ یادگیری و $\partial J_{\mathrm{DRN}}/\partial v$ از روابط (17)، (18) و (21) به‌دست می‌آید.

5- شبکه‌های NNE و NNCE

برای هوشمندسازی توابع عضویت، ابتدا این توابع پارامتری شده و سپس با استفاده از الگوریتم بازگشتی پویا، مقادیر بهینه پارامترها به روزرسانی خواهند شد. "شکل 5" یک تابع عضویت مثلثی که با استفاده از پارامتر P تشکیل شده است را نشان میدهد. "شکل 6" طرح شماتیک کنترل کننده پیشنهادی را نشان می‌دهد. وظیفه شبکه‌های NNE، NNCE تولید پارامتر P برای توابع عضویت خطا و تغییر خطا در قسمت فازی‌ساز هستند.

تابع هدف را به صورت زیر در نظر می‌گیریم:

$$J_r = \frac{1}{2}[A\, e_r^2(t) + B\, \dot{e}_r^2(t) + C\, \delta^2(l_3, t)] \tag{24}$$

جائی‌که J_r تابع هدف و A، B و C به‌ترتیب بردار وزن اهمیت خطا، مشتق خطا و تغییر شکل الاستیک برای رابط‌های بازوی مکانیکی است. مقدار خطا و تغییر خطا را می‌توان به‌صورت ذیل به‌دست آورد:

$$e_{r,i}(k) = \theta_{d,i}(k) - \theta_i(k) \tag{25}$$

$$\Delta e_{r,i}(k) = e_{r,i}(k) - e_{r,i}(k-1) \tag{26}$$

جائی‌که $e_{r,i}(k)$ و $\Delta e_{r,i}(k)$ به‌ترتیب خطا و تغییر خطای زاویه‌ای مفصل i ام بوده، k مرحله کنترل θ_i و $\theta_{d,i}$ به‌ترتیب زاویه اندازه‌گیری شده و زاویه مطلوب مفصل i ام می‌باشد.

حال به محاسبه مشتق جزیی تابع هدف نسبت به وزن‌های شبکه می‌پردازیم:

$$\frac{\partial J_r}{\partial w} = \frac{\partial J}{\partial e_r}\frac{\partial e_r}{\partial w} + \frac{\partial J}{\partial \dot{e}_r}\frac{\partial \dot{e}_r}{\partial w} + \frac{\partial J_r}{\partial \delta}\frac{\partial \delta}{\partial w} \tag{27}$$

که w وزن لایه‌های شبکه هستند.

با مشتق گیری از رابطه (24) و جای‌گذاری در رابطه (27) داریم:

$$\frac{\partial J_r}{\partial w} = A\frac{\partial e_r}{\partial w} + B\, \dot{e}\frac{\partial \dot{e}_r}{\partial w} + C\, \delta\frac{\partial \delta}{\partial w} \tag{28}$$

با استفاده از قانون زنجیری رابطه (28) را باز نویسی می کنیم:

$$\frac{\partial J_r}{\partial w} = -Ae_r\frac{\partial \theta}{\partial u_f}\frac{\partial u_f}{\partial P}\frac{\partial P}{\partial w}$$
$$-B\, \dot{e}_r\frac{\partial \dot{\theta}}{\partial u_f}\frac{\partial u_f}{\partial P}\frac{\partial P}{\partial w} + C\, \psi\frac{\partial \delta}{\partial u_f}\frac{\partial u_f}{\partial P}\frac{\partial P}{\partial w} \tag{29}$$

اصلاح وزن ها به سمت پایین ترین نقطه تابع هدف در فضای وزن ها می باشد، لذا داریم:

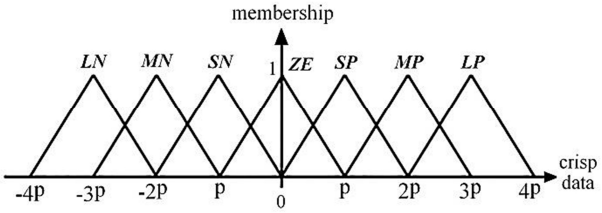

Fig. 5 Parametric membership function

شکل 5 تابع عضویت پارامتری

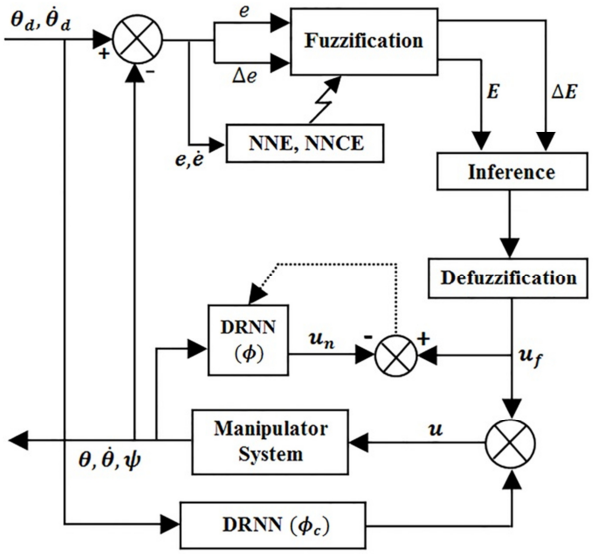

Fig. 6 Diagram of proposed controller

شکل 6 نمودار کنترل کننده پیشنهادی

$$\Delta w = -\kappa_r\left(\frac{\partial J_r}{\partial w}\right)^{\mathrm{T}} \tag{30}$$

جائی‌که κ_r نرخ یادگیری بوده و مثبت است. مطابق با پیشنهاد لایتبادی و همکاران [24] علامت عبارات $\partial\theta/\partial u_f$ ، $\partial\dot{\theta}/\partial u_f$ و $\partial\delta/\partial u_f$ بر مقادیر حقیقی آن‌ها ترجیح دارند.

لذا با اصلاح رابطه (29) و جای‌گذاری در رابطه (30) داریم:

$$\Delta w = \kappa_r\, S\frac{\partial u_f}{\partial P}\frac{\partial P}{\partial w} \quad \text{(31- الف)}$$

$$S = (Ae_r + B\dot{e}_r + C\delta) \quad \text{(31- ب)}$$

$IP_i(k)$ ورودی لایه اول بوده و برابر است با:

$$I_i(k) = y_i(k) \quad ; \quad i = 1,2,\dots,N \quad \text{(32- الف)}$$

$$y^{\mathrm{T}}(k) = (\Lambda_1, \Lambda_2, \dots, \Lambda_N) \quad \text{(32- ب)}$$

$$\Lambda_i = (e_{r,i}, \dot{e}_{r,i}) \quad \text{(32- ج)}$$

y ورودی شبکه بوده و دارای $2N$ مولفه است. خروجی لایه پنهان برابر است با:

$$O_j^{(2)}(k) = f\left(I_j(k)\right) \quad ; \quad j = 1,2,\dots,q \tag{33}$$

q تعداد نورون‌ها و $O_j^{(2)}(k)$ خروجی لایه پنهان هستند. $I_j(k)$ ورودی لایه پنهان بوده و به‌صورت ذیل به‌دست می‌آید:

$$I_j(k) = \sum_{i=1}^{2N} w_{ij}^{(1)} x_i(k) \tag{34}$$

که $w_{ij}^{(1)}$ وزن‌های لایه اول هستند. ورودی لایه سوم (خروجی) برابر است با:

$$O_m^{(3)}(k) = P_m = \sum_{j=1}^{q} w_{jm}^{(3)} O_j^{(2)}(k) \;;\; m = 1,2,\dots,N \tag{35}$$

که $w_{jm}^{(3)}$ وزن لایه سوم است. با استفاده از روابط (33) تا (35) و استفاده از قانون زنجیری داریم:

$$\frac{\partial P_m}{\partial\left(w_{jm}^{(3)}(k)\right)} = O_j^{(2)}(k) \tag{36}$$

$$\frac{\partial P_m}{\partial\left(w_{ij}^{(1)}(k)\right)} = w_{mj}^{(3)}\, f'\left(I_j(k)\right) x_i(k) \tag{37}$$

با جای‌گذاری روابط (36) و (37) در (31)، روابط اصلاح وزن‌ها استخراج می‌شوند.

6- شبیه‌سازی

در این بخش جهت صحه‌گذاری و کارآمدی کنترل کننده طراحی شده، شبیه‌سازی انجام و نتایج مورد بحث و بررسی قرار خواهند گرفت. جهت نمونه مطالعاتی، رباتی با $N = 3$ رابط را در نظر بگیرید که رابط سوم انعطاف‌پذیر است. جدول 1 مشخصات ابعادی و جرم هر بازو را براساس این‌که سطح مقطع رابط‌ها مستطیلی هستند، مشخص می‌کند. جنس رابط‌های ربات از آلومینیوم بوده و چگالی و مدول یانگ آن‌ها به ترتیب 2710 کیلوگرم بر متر مکعب و 71 گیگاپاسکال هستند. جرم و ممان اینرسی موتورهای محرک مفصل‌ها به ترتیب0.1 کیلوگرم و 0.025 کیلوگرم-متر مربع و جرم بار، 300 گرم هستند. دو مود ارتعاشی برای توصیف دینامیک سیستم انتخاب شده است. فرکانس طبیعی اول و دوم به ترتیب 6.46 و 128.22 هرتز هستند. در این بخش پاسخ های سیستم با توجه به دو نوع کنترل کننده فازی و کنترل کننده پیشنهادی مورد مقایسه قرار خواهند گرفت. هفت تابع عضویت LN، MN، SN، ZE، SP، MP و LP به ترتیب بزرگ منفی، متوسط منفی، کوچک

منفی، تقریبا صفر، کوچک مثبت، متوسط مثبت و بزرگ مثبت برای قسمت فازی‌ساز کنترل کننده فازی در نظر گرفته شده اند. در مورد انتخاب نوع و شکل توابع عضویت، هر یک از این توابع باید تابعی از پارامتر P باشند و به تبعیت از طبیعت متقارن خطا، نرخ خطا و گشتاور، می‌توان توابع عضویت را متقارن انتخاب کرد. همچنین به‌علت محدودیت در اعمال گشتاور و اشباع عملگرها، استفاده از تابع عضویت ذوزنقه‌ای که قادر است این محدودیت را اعمال کند، مناسب خواهد بود. در عمل چنین وضعیتی برای خطا و نرخ خطا نیز وجود دارد و لذا استفاده از توابع ذوزنقه‌ای برای آن‌ها نیز مناسب می‌باشد. از طرفی در توابع عضویتی که در بین این دو تابع عضویت قرار دارند، این الزام وجود نداشته و می‌توان از توابع مثلثی یا ذوزنقه‌ای استفاده کرد. بنا به دلایل ذکر شده، محدوده LN و LP ذوزنقه‌ای و مابقی توابع عضویت به شکل مثلث متساوی‌الساقین در نظر گرفته می‌شوند. جدول 2 و 3 مقادیر هر محدوده را به‌ترتیب برای ورودی خطا و تغییر خطا برای مفاصل سه‌گانه مشخص می‌کند. واحد خطا و تغییر خطا، رادیان است. توابع عضویت LN، MN، SN متقارن توابع LP، MP، SP هستند. قوانین فازی نیز در "شکل 7" نمایش داده شده است. این جدول براساس 49 قانون "اگر-آنگاه" تشکیل شده است. در مورد انتخاب نرخ یادگیری، نظر به این‌که اگر نرخ یادگیری بزرگ باشد (در حدود 0.8) در آن صورت بردار وزن در هر مرحله از کنترل، قدم‌های بزرگی برداشته و نقطه کمینه را سریع‌تر پیدا کرده و سرعت همگرایی افزایش می‌یابد. ولی اگر الگوی داده‌های ورودی نزدیک به نقطه ایده‌آل نباشد بزرگ بودن نرخ یادگیری امکان پرش شدید در شبکه را افزایش می‌دهد. از طرفی اگر نرخ یادگیری کوچک باشد (در حدود 0.1) بردار وزنی قدم‌های کوچکی را به‌سوی نقطه کمینه برمی‌دارد ولی شبکه به زمان بیشتری برای یادگیری احتیاج داشته و تکرارهای بیشتری برای رسیدن به نقطه ایده‌آل لازم دارد. در این‌جا با توجه به این‌که مساله کنترل بازوهای مکانیکی ماهر در روی خط مطرح است، به‌علت طبیعت ناشناخته الگوی داده‌ها، بهتر است از مقادیر کوچک نرخ یادگیری استفاده شود. با توجه به این توضیحات نرخ یادگیری در روابط (23) و (30) را $\kappa_D = \kappa_r = 0.1$ انتخاب می‌کنیم. ضرایب وزنی تابع هدف، 5، 3 و 2 به ترتیب برای A، B و C اختیار شده اند.ورودی شبکه DRN، به‌صورت $X^{\mathrm{T}} = (x_1, x_2, x_3)$است که x_i از رابطه(11- ب) به‌دست می‌آید. خروجی این شبکه $OP^{(3)}(k) = (u_1, u_2, u_3)$ و ورودی شبکه‌های NNE و NNCE، $y^{\mathrm{T}} = (\Lambda_1, \Lambda_2, \Lambda_3)$ است . Λ_i از رابطه (32-ج) به‌دست می‌آید. خروجی شبکه NNE ، $[P_{e1}, P_{e2}, P_{e3}]$ و خروجی شبکه NNCE، $[P_{\Delta e1}, P_{\Delta e2}, P_{\Delta e3}]$ است. تعداد نورون‌های لایه میانی $p = q = 30$ در نظر گرفته شده است. در ابتدا دو ورودی یکنواخت 0.6 و 1 به سیستم کنترل اعمال می‌شود. "شکل های 8، 9 و 10" به‌ترتیب مکان‌های زاویه‌ای مفاصل 1، 2 و 3 را در کنترل کننده های فازی و پیشنهادی برای ورودی‌های پله 0.6 و 1 نشان می دهند. "شکل 11" ارتعاش پنجه و "شکل های 12 تا 14" سرعت زاویه ای مفاصل 1 تا 3 را برای ورودی سینوسی نمایش می‌دهند. جهت مقایسه بهتر، مقادیر فراجهش برای هر دو کنترل کننده در جدول 4 نشان داده شده است. این جدول نشان می‌دهد درصد کاهش فراجهش در کنترل کننده پیشنهادی نسبت به کنترل کننده فازی برای ورودی $\theta_d = 1$ در مفاصل 1 و 2 ، 14% و مفصل 3، 7% و برای $\theta_d = 0.6$ در مفاصل 1 تا 3 به‌ترتیب 22%، 19% و 10% هستند. مقایسه دو کنترل کننده نشان می‌دهد که بیشینه تغییر شکل خمشی در کنترل کننده فازی و نروفازی به‌ترتیب 1.41 و 0.95 میلی‌متر است.

جدول 1 نمودار کنترل کننده پیشنهادی

Table 1 Mass and dimensions of manipulator arms

	مفصل1	مفصل2	مفصل3
طول (cm)	20	20	60
عرض (mm)	10	10	20
ضخامت (mm)	15	15	2
جرم (gr)	81	81	65

جدول 2 تابع عضویت خطا

Table 2 Membership function of error

	مفصل 1		مفصل 2		مفصل 3	
	حد بالا	حد پایین	حد بالا	حد پایین	حد بالا	حد پایین
ZE	0.014	-0.014	0.070	-0.070	0.070	-0.070
SP	0.020	-0.008	0.100	-0.040	0.100	-0.040
MP	0.008	0.000	0.136	0.004	0.136	-0.004
LP	+∞	0.026	+∞	0.130	+∞	0.130

جدول 3 تابع عضویت تغییر خطا

Table 3 Membership function of change in error

	مفصل1		مفصل2		مفصل3	
	حد بالا	حد پایین	حد بالا	حد پایین	حد بالا	حد پایین
ZE	0.028	-0.028	0.035	-0.035	0.035	-0.035
SP	0.040	-0.016	0.500	-0.200	0.500	-0.200
MP	0.054	0.000	0.0680	-0.020	0.680	-0.020
LP	+∞	0.052	+∞	0.650	+∞	0.650

e \ Δe	*LN*	*MN*	*SN*	*ZE*	*SP*	*MP*	*LP*
LN	*LN*	*LN*	*LN*	*LN*	*ZE*	*MP*	*SP*
MN	*MN*	*MN*	*MN*	*MN*	*ZE*	*MP*	*MP*
SN	*LN*	*MN*	*SN*	*SN*	*ZE*	*SP*	*SP*
ZE	*SN*	*ZE*	*ZE*	*ZE*	*ZE*	*ZE*	*SP*
SP	*SN*	*SN*	*ZE*	*SP*	*SP*	*MP*	*LP*
MP	*MN*	*MN*	*ZE*	*MP*	*MP*	*MP*	*MP*
LP	*SN*	*SN*	*ZE*	*LP*	*LP*	*LP*	*LP*

Fig. 7 Fuzzy role base

شکل 7 قوانین کنترل کننده فازی

همچنین متوسط تغییر شکل خمشی در کنترل کننده فازی و پیشنهادی (در 5 ثانیه اول حرکت) به ترتیب 16.81 و 10.59 هستند. در واقع علاوه بر نشست سریع‌تر، کاهش 48% و 59% را به‌ترتیب در بیشینه و متوسط تغییر شکل خمشی در کنترل کننده پیشنهادی شاهد هستیم. برای مقایسه بهتر، پاسخ سیستم را با ورودی سینوسی نیز بررسی می‌کنیم. در این حالت نیز مقدار فراجهش به مقدار قابل توجهی کاهش یافته است. درصد کاهش فراجهش کنترل کننده پیشنهادی نسبت به کنترل کننده فازی در مفاصل 1 تا 3 به ترتیب 22%، 24% و 27% هستند. جدول 5 درصد کاهش فراجهش در کنترل کننده پیشنهادی را نسبت به کنترل کننده فازی برای ورودی های 0.6 و 1 و سینوسی نشان می‌دهد. به‌عنوان یک نتیجه‌گیری کلی، مقدار فراجهش، متوسط خطا، بیشینه و متوسط تغییر شکل خمشی در کنترل

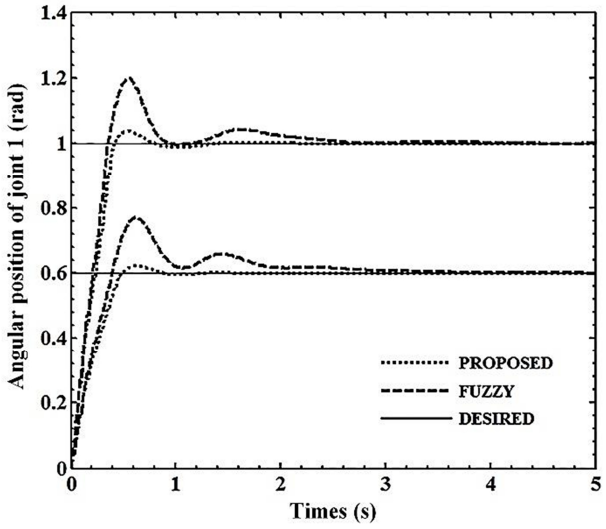

Fig. 8 Angular position of joint 1

شکل 8 مکان زاویه‌ای مفصل 1

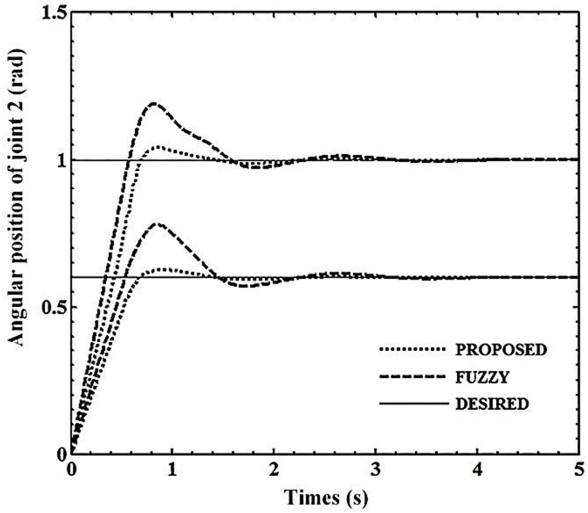

Fig. 9 Angular position of joint 2

شکل 9 مکان زاویه‌ای مفصل 2

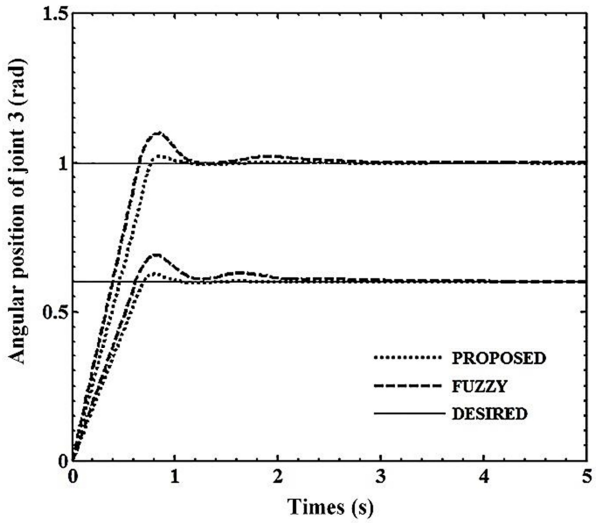

Fig. 10 Angular position of joint 3

شکل 10 مکان زاویه‌ای مفصل 3

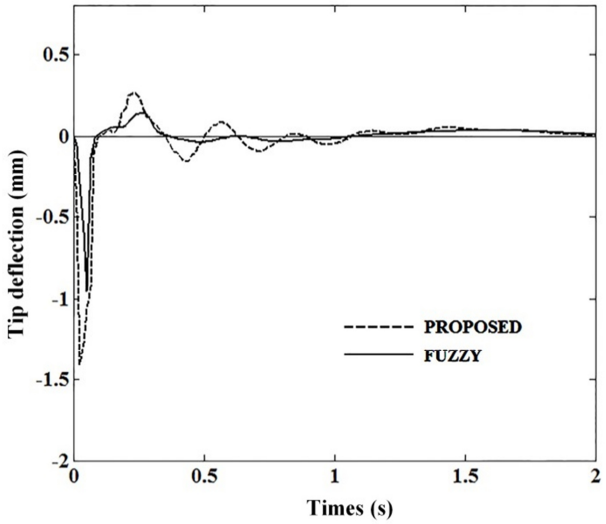

Fig. 11 Tip vibration

شکل 11 ارتعاشات پنجه

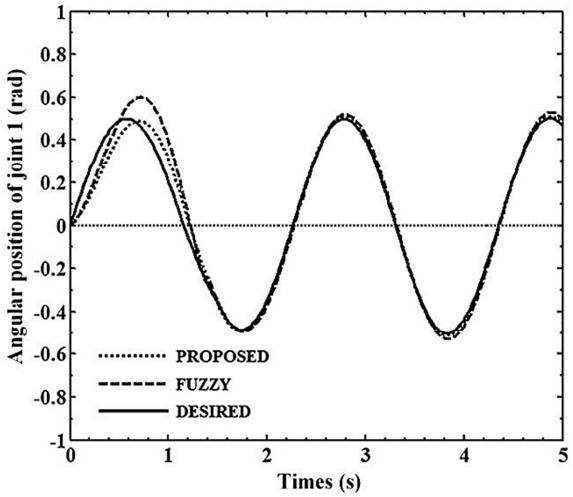

Fig. 12 Angular position of joint 1

شکل 12 مکان زاویه‌ای مفصل 1

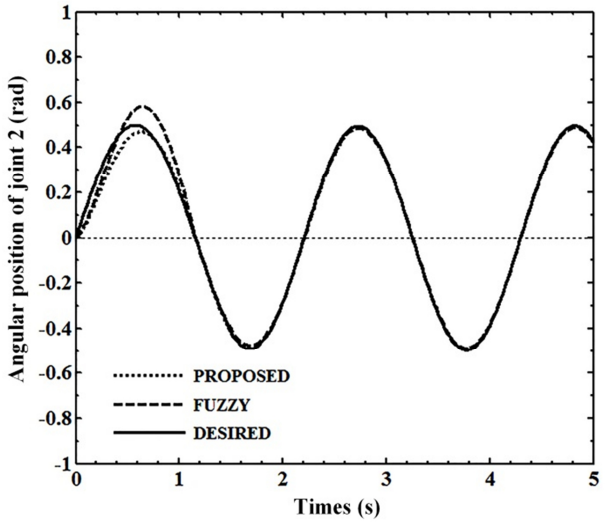

Fig. 13 Angular position of joint 2

شکل 13 مکان زاویه‌ای مفصل 2

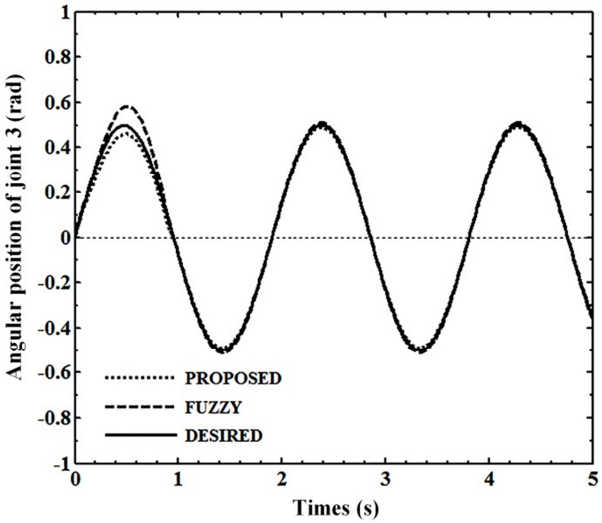

Fig. 14 Angular position of joint 3

شکل 14 مکان زاویه‌ای مفصل 3

جدول 4 مقادیر فراجهش برای ورودی‌های 0.6 و 1

Table 4 Overshoot for inputs 0.6 and 1

	فازی		نروفازی (پیشنهادی)	
	θ_d = 1	θ_d = 0.6	θ_d = 1	θ_d = 0.6
مفصل1	1.201	0.764	1.052	0.628
مفصل2	1.203	0.757	1.057	0.635
مفصل3	1.101	0.692	1.027	0.632

جدول 5 درصد کاهش فراجهش در کنترل کننده پیشنهادی نسبت به کنترل کننده فازی برای ورودی‌های 0.6 و 1 و سینوسی

Table 5 Overshoot reduction percentage in proposed controller comparison with fuzzy controllerfor inputs 0.6 , 1 and sinusoidal

ورودی	مفصل1	مفصل2	مفصل3
θ_d = 0.6	21.7	19.2	9.5
θ_d = 1	14.2	13.8	7.2
سینوسی	227	23.8	26.7

کننده پیشنهادی به مقدار قابل‌توجهی نسبت به کنترل کننده فازی کاهش یافته است که عملکرد مناسب کنترل کننده پیشنهادی و ارتقاء آن را نسبت به کنترل کننده فازی نشان می‌دهد.

7- نتیجه‌گیری

در این مقاله، کنترل‌کننده نروفازی جدیدی برای کنترل بازوهای مکانیکی ماهر صلب- انعطاف‌پذیر ارایه گردید. سیستم کنترل شامل واحد فازی با پیکربندی پسخوردی است که برای تولید سیگنال‌های کنترل دستگاه عمل می‌کند. یک شبکه عصبی بازگشتی پویا بنام DRN، ضمن مدل‌سازی دینامیک معکوس، ورودی مطلوب سیستم را دریافت کرده و گشتاور مفاصل را تولید و کارایی FLC را ارتقاء می‌بخشد. شبکه عصبی بازگشتی پویا نسبت به شبکه‌های پس انتشار خطا از قدرت محاسباتی بیشتری برخوردار است و با توجه به حضور عنصر حافظه‌دار در آن، سرعت همگرایی آن به مقدار قابل توجهی افزایش می‌یابد. شبکه از لایه‌های ورودی، مخفی، خروجی و بازگشتی تشکیل شده است. لایه بازگشتی اثر گام قبلی فرایند کنترل را در به‌روزرسانی وزن‌های شبکه لحاظ می‌کند. وزن‌های شبکه بر روی خط و براساس خروجی FLC، در طول فرایند کنترل به‌روزرسانی می‌شوند. در نتیجه سیستم کنترل این توانایی را می‌یابد که با عدم قطعیت‌ها سازگار گردد. از طرفی با کوچک شدن خطا، نرخ خطا و تغییر شکل خمشی، عملکرد توابع عضویت (اولیه) کاهش می‌یابد. در این تحقیق از توابع عضویتی که با تغییر ورودی به‌طور خودکار به‌روزرسانی می‌شوند، استفاده شده است. هوشمند کردن واحد فازی‌ساز، با کمک دو شبکه عصبی NNE و NNCE انجام می‌گیرد. این شبکه‌ها وظیفه تنظیم پارامتر اصلی توابع عضویت خطا و تغییر خطا را در کنترل کننده فازی به‌عهده دارند. خطا و نرخ تغییر خطا به‌عنوان ورودی، وارد شبکه‌ها شده و وزن‌های شبکه با استفاده از الگوریتم پس انتشار خطا به‌روزرسانی می‌شوند. جهت تصدیق و کارآمدی روش ارایه شده، شبیه‌سازی برای بازوی مکانیکی ماهر با سه رابط که رابط سوم انعطاف‌پذیر است، انجام شد. ورودی‌های پله و سینوسی به دستگاه اعمال گردید و پاسخ‌های سیستم برای کنترل کننده فازی و کنترل کننده پیشنهادی با یکدیگر مقایسه شدند. نتایج نشان از کارآمدی کنترل کننده پیشنهادی و کاهش قابل توجه فراجهش، متوسط خطا، بیشینه تغییر شکل خمشی و متوسط آن را در کنترل کننده پیشنهادی دارد.

8- مراجع

[1] N. Karami, M. Habibnejad Korayem, A. M. Shafei, S. Rafee Nekoo, Theoritical and experimental investigation of dynamic load carrying capacity of flexible-link manipulator in pointto-point motion, *Modares Mechanical Engineering*, Vol. 14, No. 15, pp. 199-206, 2015. (in Persianفارسی)

[2] F.C.Sun, Z.Q.Sun, P.Y.Woo., Neural network-based adaptive controller design of robotic manipulators with an observer,*IEEE Transaction Neural Networks*, Vol.12, No.1, pp. 54–67,2001.

[3] O.A.Bauchau,*Flexible multibody dynamics*,First Edition, pp. 617, New York:Springer, 2011.

[4] M. Tokhi, A.Azad,*Flexible robot manipulators: modeling, simulation and control, control engineering series*, First Edition, pp. 1-3, London:The Institution of Engineering and Technology, 2008.

[5] S. Dwivedy, P.Eberhard, Dynamic analysis of flexible manipulators, a literature review, *Mechanism and Machine Theory*, Vol. 41, No. 7, pp. 749–777 , 2006.

[6] R. Vidoni, A. Gasparetto, M. Giovagnoni, Design and implementation of an ERLS-based 3-D dynamic formulation for flexible-link robots, *Robotic and Computer-Integrated Manufacturing*, Vol. 29, No. 2, pp. 273-282, 2013.

[7] R. Caracciolo, D. Richiedei, A.Trevisani, Experimental validation of a model-based robust controller for multi-body mechanisms with flexible links, *Multibody System Dynamics*, Vol. 20, No. 2, pp. 129–145, 2008.

[8] P. Boscariol, A. Gasparetto, V.Zanotto, Active position and vibration control of a flexible links mechanism using model-based predictive control, *ASME Journal of Dynamic Systems, Measurement, and Control*, pp.1-4, Vol. 132, No. 1, 2010.

[9] H. Yang, H. Krishnan, M. H. AngJr, Tip trajectory tracking control of single-link flexible robots by output redefinition, *IEE Proceedings-Control Theory and Applications*, Vol. 147, No. 6, pp. 580–587, 2000.

[10] J. B. Mbede, X. Huang, M.Wang, Robust neural-fuzzy sensor-based motion control among dynamic obstacles for robot manipulators, *IEEE Transactions on Fuzzy Systems*, Vol. 11, No. 2, pp. 249–261, 2003.

[11] K. Lochan, B.K. Roy, Control of two-link 2-DOF manipulator using fuzzy logic techniques:A Review, *Proceedings of Fourth International Conference on Soft Computing for Problem Solving*, Springer India, Vol. 1, pp. 499-511, 2015.

[12] S. Mallikarjunaiah, S. Narayana Reddy, Adaptive neuro-fuzzy interface system controller for flexible link manipulator, *ACTA Electrotechnica*, Vol. 54, No. 2, pp. 91-98, 2013.

[13] Y. Gao, M. J. Er, W. E. Leithead, , & D. J. Leith, Online adaptive control of robot manipulators using dynamic fuzzy neural networks, *American Control Conference Proceedings of the 2001*, Vol. 6, pp. 4828-4833, 2001.

[14] S. Hu, M. H. AngJr, H.Krishnan, Neural network controller for constrained robot manipulators, *Proceedings of the 2000 IEEE International Conference on Robotics and Automation*, San Francisco,USA, Vol. 2, pp. 1906-1911, 2000.

[15] M. Mirshekaran, F. Piltan, Z. Esmaeili, T. Khajeaian, M. Kazeminasab, Design sliding mode modified fuzzy linear controller with application to flexible robot manipulator, *International Journal of Modern Education and Computer Science*, Vol. 5, No. 10, pp. 53-63, 2013.

[16] A. M. Abdullahi, Z. Mohamed, M. Muhammad, A. A. Bature, Vibration control comparison of asingle link flexible manipulator between fuzzy logic

control and pole placement control, *International Journal of Technology Enhancements and Emerging Engineering Research*, Vol. 2, No. 12, pp. 236-241, 2013.

[17] Y. Zhang, J. Wang, Y. Xu, A dual neural network for bi-criteria kinematic control of redundant manipulators,*IEEE Transactionon Robot and Automation*, Vol.18, No.6, pp. 923–931,2002.

[18] G. Sahamijoo, O. Avatefipour, M. R. S. Nasrabad, M. Taghavi, F. Piltan, Research on minimum intelligent unit for flexible robot,*International Journal of Advanced Science and Technology*, Vol. 80,No. 6, pp. 79-104, 2015.

[19] S. S. Rao, *Vibration of Continuous Systems*, Forth Edition, pp. 335-336, New Jersey: John Wiley & Sons, 2007.

[20] F. Matia, G.N.Marichal, E. Jimenez, *Fuzzy Modeling and Control: Theory and Applications*, pp. 69, Amsterdam: Atlantis Press, 2014.

[21] T. J. Ross, *Fuzzy Logic with Engineering Application*, Second Edittion, pp. 101, New York: Wiley & Sons, 2004.

[22] R. Boucetta, M. N. Rahma, Abdelkrim, Neural network modeling of a flexible manipulator robot, *IFIP International Conference on Computer Information Systems and Industrial Management. Springer Berlin Heidelberg*, pp. 395-404, 2012.

[23] D. E. Rumelhart, J. L. McClelland, *Parallel distributed processing, Explorations in the microstructure of cognition*, pp. 444-458, Cambridge: MIT Press, , 1986.

[24] G. Lightbody, W. H. Wu, G. W. Irwin, *Control application for feedforward networks: neural networks for control*, pp. 51-71, Cambridge :MIT Press, 1990.