



طراحی کنترل کننده تطبیقی مد لغزشی مبتنی شبکه عصبی کوانتومی

سمیه چگینی¹، مجید یاراحمدی^{2*}

1- دانشجوی دکتری، ریاضی کاربردی، دانشگاه لرستان، خرم آباد
2- استادیار، ریاضی کاربردی، دانشگاه لرستان، خرم آباد
* خرم آباد، صندوق پستی 465 yarahmadi.m@lu.ac.ir

چکیده

اطلاعات مقاله

مقاله پژوهشی کامل
دریافت: 02 آذر 1395
پذیرش: 03 دی 1395
ارائه در سایت: 26 دی 1395
کلید واژگان:

کنترل مد لغزشی
لایه مرزی
شبکه عصبی کوانتومی
پارامتر عدم قبول
رگولاتور عدم قبول

در این مقاله، یک کنترل کننده مقاوم هوشمند کوانتومی مبتنی بر ترکیب روش کنترل مد لغزشی با لایه مرزی و شبکه‌های عصبی کوانتومی ارائه می‌شود. این کنترل کننده با استفاده از تابع لغزشی متغیر با زمان و در حضور اختلالات خارجی، برای سیستم‌های غیرخطی نامعین، به منظور حذف اثرات ناشی از نامعینی‌های سیستم و فرکانس‌های مدل نشده، طراحی شده است. در این روش بهره کنترل، پارامتر عدم قبول و شبکه عصبی کوانتومی به طور تطبیقی تنظیم می‌شوند و ضمن حذف اثرات نامعینی‌ها به‌طور کارا، کنترل کننده فاقد هرگونه نوسانات شدید می‌باشد. با توجه به سرعت و دقت بالای شبکه‌های عصبی کوانتومی در شناسایی سیستم، در این مقاله یک شبکه عصبی کوانتومی سه لایه برای شناسایی توابع نامعین غیرخطی دینامیک سیستم طراحی شده است. همچنین، به منظور پشتیبانی تئوری تحلیلی روش و استخراج قواعد تطبیقی یک قضیه ارائه و اثبات شده است. در پایان مثال‌های شبیه‌سازی شده نشان می‌دهند که روش پیشنهادی یک کنترل ردیاب مقاوم تطبیقی هوشمند، که در آن دامنه کنترل و شاخص انتگرال قدرمطلق خطای ردیابی مسیر بسیار کمتر از سایر روش‌ها است، ارائه می‌کند. بنابراین شناسایی مؤثر و حذف اثرات ناشی از نامعینی‌های سیستم، قابل تنظیم بودن بهره کنترل و پارامتر عدم قبول و ردیابی دقیق‌تر، از مزیت‌های روش پیشنهادی است.

Design of an adaptive sliding mode controller based on quantum neural network

Somayah Chegini, Majid Yarahmadi*

Department of Mathematics and Computer Science, Lorestan University, Khorramabad, Iran
*P.O.B. 465, Khorramabad, Iran, yarahmadi.m@lu.ac.ir

ARTICLE INFORMATION

Original Research Paper
Received 22 November 2016
Accepted 23 December 2016
Available Online 15 January 2017

Keywords:
Sliding mode control
Boundary layer
Quantum neural network
Rejection parameter
Rejection regulator

ABSTRACT

In this paper, a quantum intelligent robust controller via a combination of sliding mode control with boundary layer and quantum neural networks, for uncertain nonlinear systems in presence of external disturbances, is presented. Based on the adjustable time variant rejection regulator and rejection parameter, a time variant sliding surface as an adaptive chain of the first ordered low pass filters is defined. A three layers quantum neural network is designed to identify the uncertain nonlinear functions in system dynamics. In this method, the control gain, rejection parameter and quantum neural network are tuned adaptively. Also, the effects of uncertainties and the un-modeled frequencies are eliminated and chattering phenomenon does not occur. Also, for facilitating analytical theory of the presented method and derivation of the adaptive laws a theorem is proved. Finally, the simulated examples show that the proposed method presents an intelligent adaptive robust tracking control such that the control amplitudes and the integral absolute error index of the tracking trajectory are much less than the other methods. Therefore, effective identification, eliminating the effects of system uncertainties, adjustable control gain and rejection parameter and more accurate tracking are some of the advantages of this method.

1- مقدمه

عصبی خودتنظیم [2] و روش فازی تطبیقی برای یافتن پهنای لایه مرزی مناسب [3] استفاده شده‌اند. همچنین با رویکردی تحدیدی، قواعد خودتنظیم براساس خطای کراندار مدل، برای تطبیق پهنای لایه مرزی و سایر پارامترها ارائه شده است [4]. در [5] یک کنترل مد لغزشی فازی تطبیقی برای حذف نوسانات شدید سیستم‌های غیرخطی تک ورودی- تک خروجی ارائه شده است. یک روش کنترل مد لغزشی تطبیقی برای هم‌زمانی سیستم‌های آشوب با مرتبه اعشاری در [6] ارائه شده و به‌منظور اصلاح مد لغزشی متداول، تضعیف اثرات نامعینی‌ها و جایگزینی عمل کنترل سوئیچینگ، از شبکه عصبی فازی بهره‌گیری شده است. در [7] یک کنترل کننده مد لغزشی فازی

کنترل سیستم‌های غیرخطی نامعین در کنترل سیستم و کاربردهای آن بسیار اهمیت دارد. به‌منظور طراحی یک کنترل کننده مقاوم برای سیستم‌های غیرخطی نامعین در حضور اختلالات خارجی، کنترل مد لغزشی به‌عنوان یک روش کارا به کار برده شده است. کنترل مد لغزشی به‌منظور هدایت حالت سیستم برای رسیدن به سطح لغزشی و سپس حفظ آن روی سطح، یک قانون کنترل ناپیوسته را به کار می‌گیرد. در [1] یک کنترل فازی تطبیقی خودساختار مستقیم برای سیستم‌های غیرخطی آفین ارائه شده است. برای طراحی کنترل مد لغزشی، محاسبات

Please cite this article using:

S. Chegini, M. Yarahmadi, Design of an adaptive sliding mode controller based on quantum neural network, *Modares Mechanical Engineering*, Vol. 17, No. 1, pp. 305-310, 2017 (in Persian)

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

باشد، قانون کنترل لغزشی

$$u = \hat{g}^{-1} \left[-\hat{f} + \dot{x}_d^{(n)} - \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} - T \operatorname{sgn}(s) \right], \quad (7)$$

که در آن

$$T \geq \frac{\hat{g}(x)}{G_L(x)} \left[F + \frac{(M(x, \delta) + |\hat{f}|)G}{\hat{g}(x)} + D + \eta \right], \quad (8)$$

شرط لغزشی $\operatorname{sgn}(s)\dot{s} < -\eta$ را تضمین می کند [10].

لم 1.

اگر $R_j^n(\delta)$ و δ به ترتیب رگولاتور و پارامتر عدم قبول باشند در این صورت داریم [10]:

$$\frac{\partial^k}{\partial \delta^k} R_j^n(\delta) = (-1)^k \frac{(n-1)!}{(n-k-1)!} R_{j-k}^{n-k}(\delta). \quad (9)$$

در کنترل مد لغزشی تغییر ناگهانی علامت جمله $T \operatorname{sgn}(s)$ نوسانات شدید ایجاد می کند. برای غلبه بر این مشکل یک سطح لغزشی با لایه مرزی در نظر گرفته می شود. بنابراین به جای جمله $T \operatorname{sgn}(s)$ از $T \operatorname{sat}(s/\varphi)$ استفاده می شود که در آن φ ضخامت لایه مرزی است. اگر حالت خارج از لایه مرزی باشد با استفاده از شرط رسیدن، حالت به درون لایه مرزی می رسد. دقت ردیابی با استفاده از تابع اشباع تضمین نمی شود لذا در این مقاله از تابع تانژانت هیپربولیک به جای تابع اشباع استفاده می شود. در بخش بعد قوانین تنظیم برای طراحی کنترل مد لغزشی کوانتومی غیرمستقیم با استفاده از معادله لغزشی متغیر با زمان معرفی می شود.

3- طراحی مد لغزشی کوانتومی غیرمستقیم با لایه مرزی

3-1- شبکه عصبی کوانتومی

کیوبیت ها در کامپیوترهای کوانتومی جایگزین بیت ها در کامپیوترهای کلاسیک هستند و برای ذخیره کردن حالت های مدارها که در محاسبات کوانتومی استفاده می شوند به کار می روند. دو حالت کوانتومی که بیانگر یک بیت از اطلاعات هستند را با $|0\rangle$ و $|1\rangle$ نامگذاری می کنیم. $|0\rangle$ متناظر با بیت کلاسیک 0 و $|1\rangle$ متناظر با بیت کلاسیک 1 است. کیوبیت حالت $|\phi\rangle$ یک انطباق همدوس از حالت های $|0\rangle$ و $|1\rangle$ است و به صورت زیر بیان می شود:

$$|\phi\rangle = \alpha|0\rangle + \beta|1\rangle, \quad (10)$$

که در آن α و β اعدادی مختلط هستند و دامنه های احتمال نامیده می شوند. یعنی حالت $|\phi\rangle$ با احتمال $|\alpha|^2$ به حالت $|0\rangle$ و با احتمال $|\beta|^2$ به حالت $|1\rangle$ فرو می ریزد و داریم: $|\alpha|^2 + |\beta|^2 = 1$.

در ادامه یک شبکه عصبی کوانتومی بر مبنای پردازش اطلاعات کوانتومی معرفی می شود. ابتدا مدل نرون کوانتومی به صورت زیر تعریف می شود [14]:

$$u = \sum_k f(\theta_k) \cdot x_k - f(\lambda) = \sum_k f(\theta_k) \cdot f(y_k) - f(\lambda), \quad (11)$$

$$y = \frac{\pi}{2} g(\gamma) - \arg(u), \quad (12)$$

$$z = f(y), \quad (13)$$

که در آن $f(x) = e^{ix} = \cos x + i \sin x$ و g یک تابع سیگموئید است که برد آن $[0, 1]$ است. مدل یک نرون عصبی کوانتومی در "شکل 1" نشان داده شده است.

موجکی عصبی تطبیقی برای طراحی کنترل مد لغزشی هموار برای دسته ای از سیستم های غیرخطی مرتبه بالا در حضور نامعینی ها ارائه شده است. استفاده از مد لغزشی تطبیقی مدل مرجع با استفاده از شبکه عصبی تابع پایه ای شعاعی به منظور کنترل فیلتر قدرت فعال تک فاز پیشنهاد شده است [8]. در [9] یک روش کنترل تطبیقی مقاوم بر مبنای تقریب عصبی برای سیستمی با نامعینی های پارامتری ارائه شده است و برای کاهش حجم محاسبات از یک شبکه عصبی با دو تابع شعاعی پایه استفاده شده است. در [11, 10] یک کنترل مد لغزشی مقاوم موجکی با لایه مرزی فازی و سطح لغزشی متغیر با زمان پیشنهاد شده است. در [12] از کنترل مقاوم مد لغزشی برای کنترل ربات موازی 3-RPR در ردیابی مسیر استفاده شده است. در [13] با استفاده از کنترل مد لغزشی یک کنترل کننده مقاوم تطبیقی برای یک کوادراتور بدون سرشنین طراحی شده است.

این مقاله در 5 بخش ارائه می شود. در بخش 2 کنترل مد لغزشی مبتنی بر مفاهیم پارامتر و رگولاتور عدم قبول ارائه می شود. این بخش با دو قضیه و یک لم کامل می شود. در بخش 3 کنترل مد لغزشی غیرمستقیم عصبی کوانتومی با لایه مرزی طراحی و با اثبات یک قضیه کامل می شود. در بخش 4 برای نشان دادن اثربخشی روش پیشنهادی دو مثال ارائه می شود. بخش 5 نتیجه گیری حاصل از نوآوری و عملکرد روش پیشنهاد شده در مقاله را ارائه می دهد.

2- کنترل مد لغزشی و رگولاتور عدم قبول

سیستم دینامیکی غیرخطی مرتبه n -امی را که با معادله حالت زیر داده می شود در نظر بگیرید:

$$\dot{x}^{(n)} = f(x, \dot{x}, \dots, x^{(n-1)}) + g(x, \dot{x}, \dots, x^{(n-1)})u + d \quad (1)$$

که در آن f و g توابع غیرخطی کراندار و مجهول هستند و $u \in \mathbb{R}$ ورودی کنترل سیستم و d اختلال خارجی کراندار است. هدف کنترل یافتن قانون کنترلی است که حالت x بتواند مسیر مطلوب x_d را ردیابی کند. قرار دهید:

$$x = [x_1, x_2, \dots, x_n]^T = [x, \dot{x}, \dots, x^{(n-1)}]^T \in \mathbb{R}^n, \quad (2)$$

$$x_d = [x_d, \dot{x}_d, \dots, x_d^{(n-1)}]^T \in \mathbb{R}^n. \quad (3)$$

حال خطا را به صورت زیر تعریف می کنیم:

$$e = x - x_d \in \mathbb{R}, \quad (4)$$

$$e = [e, \dot{e}, \dots, e^{(n-1)}]^T. \quad (5)$$

برای رسیدن به هدف کنترل خطای ردیابی مستقل از نامعینی های سیستم به یک باقیمانده خطای کوچک کاهش می یابد. کنترل مد لغزشی بر مبنای تعریف یک سطح لغزشی $s = \sum_{j=0}^{n-1} R_j^n(\delta) e^{(n-j-1)}$ است که در آن $R_j^n(\delta)$ و δ به ترتیب رگولاتور و پارامتر عدم قبول هستند [10].

فرض 1.

کران های بالای G, F, D و توابع $M(x, \delta)$ و G_L معلومند و داریم:

$$|\Delta f| \leq F, |\Delta g| \leq G, |d| \leq D, 0 < G_L(x) < g(x),$$

$$M(x, \delta) = \left| x_d^{(n)} - \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} \right|, \quad (6)$$

که در آن $\Delta g = (g - \hat{g})$ و $\Delta f = (f - \hat{f})$

قضیه 1.

معادله دینامیکی سیستم (1) را در نظر بگیرید. اگر مقادیر M, D, G, F مشابه فرض 1 تعریف شوند و سطح لغزشی $s = \sum_{j=0}^{n-1} R_j^n(\delta) e^{(n-j-1)}$ داده شده

زیر در نظر گرفته می‌شود:

$$E_{\text{total}} = \frac{1}{2} \sum_p \sum_n \left(t_{p,n} - \text{output}_{p,n} \right)^2 \quad (22)$$

هدف این الگوریتم حداقل‌سازی E_{total} است. P تعداد الگوهای یادگیری، $t_{p,n}$ سیگنال هدف برای n -امین نرون و $\text{output}_{p,n}$ نشان دهنده n -امین خروجی در الگوی p -ام است.

3-2- سطح لغزشی کوانتومی متغیر با زمان

واضح است که عملکرد مد لغزشی به ضرایب معادله لغزشی حساس است. حال اگر پارامتر عدم قبول را متغیر با زمان در نظر بگیریم سطح لغزشی متغیر با زمان به صورت زیر خواهد بود [10]:

$$s = \sum_{j=0}^{n-1} R_j^n(\delta(t)) e^{(n-j-1)} \quad (23)$$

که در آن $\delta(t)$ پارامتر عدم قبول متغیر با زمان است. با تنظیم پارامتر عدم قبول عملکرد کل سیستم در مقایسه با کنترل مد لغزشی کلاسیک می‌تواند بهتر شود. از اینجا به بعد معادله لغزشی متغیر با زمان در نظر گرفته می‌شود و مطابق با معادله (23) تعریف می‌شود. حال با توجه به معادله (23) داریم:

$$s = e^{n-1} + \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j-1)} \quad (24)$$

از آن جایی که

$$\frac{\partial}{\partial t} \left(\sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j-1)} \right) = \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} + \frac{\partial}{\partial t} \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j-1)} \quad (25)$$

طبق لم 1 می‌توان نوشت:

$$\sum_{j=1}^{n-1} \frac{\partial}{\partial \delta} R_j^n(\delta) e^{(n-j-1)} = -(n-1) \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \quad (26)$$

بنابراین

$$\dot{s} = e^n + \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} - (n-1) \delta \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \quad (27)$$

با جایگذاری رابطه (1) در رابطه (27) خواهیم داشت:

$$\dot{s} = f(x) + g(x)u + d - x_d^{(n)} + \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} - (n-1) \delta \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \quad (28)$$

حال تعریف می‌کنیم:

$$u = \frac{1}{\hat{g}(x)} \left[-\hat{f}(x) + x_d^{(n)} - \sum_{j=1}^{n-1} R_j^n(\delta) e^{(n-j)} - T\Phi(\sigma, s) \right] \quad (29)$$

که در آن $\Phi(\sigma, s) = \tanh(\sigma s)$ و \hat{f} و \hat{g} به ترتیب تقریب‌های توابع غیرخطی f و g هستند که با استفاده از شبکه عصبی کوانتومی محاسبه شده‌اند. برای بهبود عملکرد کنترل، T و $\delta(t)$ با استفاده از قواعد تطبیقی که در قضیه بعد آورده می‌شوند، تنظیم خواهند شد.

نکته.

در قاعده کنترل (29)، با استفاده از تقریب‌های کوانتومی f و g لزومی به

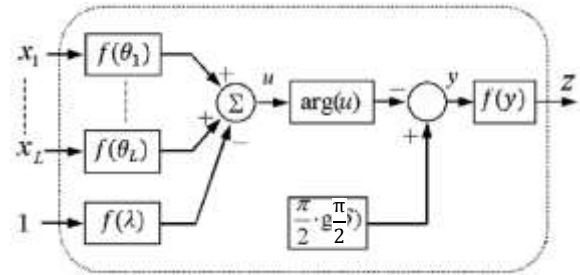


Fig. 1 The quantum neuron model

شکل 1 مدل یک نرون عصبی کوانتومی

همچنین ساختار یک شبکه عصبی کوانتومی در "شکل 2" نشان داده شده است.

مجموعه‌های

$$\{I_l\} \quad (l = 0, 1, \dots, L), \quad (14)$$

$$\{H_m\} \quad (m = 0, 1, \dots, M), \quad (15)$$

$$\{O_n\} \quad (n = 0, 1, \dots, N), \quad (16)$$

نشان دهنده اجزای نرون هستند. متغیرهای H, I و O به ترتیب نشان دهنده لایه‌های ورودی، پنهان و خروجی هستند. لایه ورودی مقادیر ورودی از بازه $[0, 1]$ را به حالت‌های کوانتومی با مقادیر فاز در بازه $[0, \pi/2]$ تبدیل می‌کند. خروجی نرون I_l از لایه ورودی به صورت زیر است [14]:

$$z_l' = f\left(\frac{\pi}{2} \cdot \text{input}_l\right) \quad (17)$$

لایه‌های پنهان و خروجی با توجه به معادلات (11)، (12) و (13) مدل می‌شوند. حال اگر احتمال مشاهده $\{1\}$ را به عنوان خروجی شبکه در نظر بگیریم، خروجی n -امین نرون به صورت زیر است:

$$\text{output}_n = |\text{Im}(z_n^0)|^2 \quad (18)$$

برای بالا بردن توانایی یادگیری شبکه از نسخه‌ای از الگوریتم معروف پس-انتشار خطا استفاده می‌کنیم. در این صورت الگوریتم یادگیری شبکه با معادلات زیر داده می‌شود [14]:

$$\theta_k^{\text{new}} = \theta_k^{\text{old}} - \eta \frac{\partial E_{\text{total}}}{\partial \theta_k} \quad (19)$$

$$\lambda_k^{\text{new}} = \lambda_k^{\text{old}} - \eta \frac{\partial E_{\text{total}}}{\partial \lambda_k} \quad (20)$$

$$\delta_k^{\text{new}} = \delta_k^{\text{old}} - \eta \frac{\partial E_{\text{total}}}{\partial \delta_k} \quad (21)$$

که در آن η نرخ یادگیری شبکه و E_{total} تابع مربع خطا است که به صورت




Fig. 2 The three layer quantum neural network structure

شکل 2 ساختار شبکه عصبی کوانتومی سه لایه

دانستن کران‌های عدم قطعیت در فرض 1 نیست.

قضیه 2.

سیستم غیرخطی و سطح لغزشی که به ترتیب در معادله‌های (1) و (23) توصیف می‌شوند را در نظر بگیرید. اگر قانون کنترل معادله (29) به کار گرفته شود و T و $\delta(t)$ طبق قواعد زیر تطبیق داده شوند:

$$\dot{T} = \eta_1 s \tanh(\sigma s) \quad \eta_1 > 0, \quad (30)$$

$$\delta = \eta_2 \operatorname{sgn}(s) \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)}, \quad \eta_2 > 0, \quad (31)$$

خطای ردیابی به صورت مجانبی به صفر میل خواهد کرد.

اثبات.

تابع لیاپانوف زیر را در نظر بگیرید:

$$V(s, t) = \frac{1}{2} s^2 + \frac{1}{2\eta_1} T^2, \quad (32)$$

با مشتق‌گیری نسبت به زمان از دو طرف معادله (32) داریم:

$$\dot{V}(s, t) = s\dot{s} + \frac{1}{\eta_1} T\dot{T}, \quad (33)$$

حال با جایگزینی رابطه (28) در رابطه (33) به دست می‌آوریم:

$$\begin{aligned} \dot{V} = & s(f(x) + g(x)u + d - x_d^{(n)} + \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \\ & - (n-1)\delta \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)}) + \frac{1}{\eta_1} T\dot{T}. \end{aligned} \quad (34)$$

بنابراین با جایگذاری معادله (29) در معادله (34) خواهیم داشت:

$$\begin{aligned} \dot{V} = & s \left(-(n-1)\delta \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} - T \tanh(\sigma s) \right) \\ & + \frac{1}{\eta_1} T\dot{T}, \end{aligned} \quad (35)$$

حال اگر معادله‌های (30) و (31) را در معادله (35) جایگزین کنیم داریم:

$$\dot{V} \leq -|s|(n-1) \left[\sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \right]^2. \quad (36)$$

اگر $e(0)$ کراندار باشد طبق قضیه 1 سطح s کراندار است. لذا $e(t)$ و $\sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)}$ هر دو کراندار هستند و این یعنی $s \in L_\infty$. حال فرض کنید $\left| \sum_{j=1}^{n-1} R_{j-1}^{n-1}(\delta) e^{(n-j-1)} \right| \leq M_\delta / \sqrt{n-1}$ بنا براین رابطه (36) را می‌توان به صورت $\dot{V} \leq -|s|M_\delta^2$ نوشت و این اثبات را کامل می‌کند.

4- نتایج شبیه‌سازی

در این بخش دو مثال برای نشان دادن اعتبار روش پیشنهادی مطرح می‌شود. نشان داده خواهد شد که روش ارائه شده عملکرد ردیابی بهتری در مقایسه با روش‌های متداول دارد. بدون کاستن از کلیت مسئله قرار می‌دهیم $v = 20$ شاخص عملکرد را انتگرال قدرمطلق خطا یعنی

$$IAE = \int_{t_0}^{t_f} |e(t)| dt \quad (37)$$

در نظر می‌گیریم.

مثال 1

معادله دینامیکی پاندول معکوس به صورت زیر است:

$$\ddot{x} = \frac{g \sin(x) - \frac{mL\dot{x}^2 \cos(x) \sin(x)}{M+m}}{L \left(\frac{4}{3} - \frac{m \cos^2(x)}{M+m} \right)} + \frac{\frac{\cos(x)}{M+m}}{L \left(\frac{4}{3} - \frac{m \cos^2(x)}{M+m} \right)} u + d,$$

که در آن

$$g = 9.8 \frac{m}{s^2}, \quad M = 1 \text{kg}, \quad m = 0.1 \text{kg}, \quad L = 0.5 \text{m},$$

و d یک موج مربعی با دامنه ± 1.5 است. هدف کنترل این است که حالت سیستم، ورودی مرجع

$$x_d = \frac{\pi(\sin(t) + 0.3 \sin(3t))}{10},$$

را ردیابی کند. قرار دهید:

$$\eta_1 = 0.01, \quad \eta_2 = 0.1, \quad \sigma = 3.5, \quad T(0) = 8, \\ \delta(0) = 5.$$

نتایج شبیه‌سازی نشان می‌دهد که در این روش حالت سیستم سریع‌تر از روش‌های [11,5] مسیر مطلوب را ردیابی می‌کند. به علاوه، دامنه سیگنال کنترل بسیار کمتر از سایر روش‌ها است. ورودی کنترل نوسانات شدید ندارد و همه فرکانس‌های مدل نشده حذف شده‌اند. برای نشان دادن کارایی روش ارائه شده نتایج این مثال با سایر روش‌ها در جدول 1 مقایسه شده است. همچنین نتایج شبیه‌سازی در "شکل‌های 3، 4 و 5" نشان داده شده است.

مثال 2

سیستم نوسانگر دافینگ زیر را در نظر بگیرید:

$$\ddot{x} = -0.1\dot{x} - x^3 + 12 \cos t + u(t) + d(t),$$

که در آن $d(t)$ یک موج مربعی با دامنه ± 1.5 است. این سیستم بدون کنترل یک سیستم آشوب‌ناک است. هدف کنترل این است که حالت سیستم مسیر مرجع $x_d = \sin t$ را ردیابی کند. قرار دهید:

$$\eta_1 = 0.1, \quad \eta_2 = 0.1, \quad \sigma = 3.5, \quad T(0) = 8, \\ \delta(0) = 5.$$

نتایج شبیه‌سازی این مسئله در "شکل‌های 6، 7 و 8" و جدول 2 آورده شده است.

جدول 1 نتایج شبیه‌سازی مثال 1

IAE	سیگنال کنترل u	روش
0.2745	$-7.201 \leq u \leq 8.011$	AFSMC [5]
0.1279	$-4.979 \leq u \leq 7.536$	IFSMC [11]
0.0782	$-2.422 \leq u \leq 1.673$	روش ارائه شده




Fig. 3 The control input for example 1

شکل 3 سیگنال کنترل u مثال 1




Fig. 7 The tracking error for example 2


شکل 7 خطای ردیابی e ، مثال 2

Fig. 8 The tracking result for example 2

شکل 8 نتیجه ردیابی مثال 2

5- نتیجه گیری

در این مقاله یک کنترل کننده مقاوم تطبیقی هوشمند کوانتومی برای سیستم‌های غیرخطی و نامعین طراحی شد. پارامتر عدم قبول، شبکه عصبی کوانتومی و بهره کنترل به طور تطبیقی تنظیم شدند. سطح لغزشی مانند زنجیره‌ای از فیلترهای پایین گذر عمل و همه فرکانس‌های مدل نشده را فیلتر می‌کند. برای غلبه بر نامعینی‌های ساختاری در توابع غیرخطی موجود در دینامیک سیستم، در این مقاله از شبکه عصبی کوانتومی استفاده شد که این امر سبب افزایش سرعت فرایند کنترل و عملکرد بهتر شبکه نسبت به شبکه عصبی کلاسیک می‌شود. نتایج شبیه‌سازی نشان می‌دهد که سرعت و دقت ردیابی به طور چشم‌گیری افزایش داشته است. همچنین دامنه کنترل، خطای شبکه و ردیابی به طور قابل توجهی کاهش یافته است.

6- مراجع

- [1] P. A. Phan, T. J. Gale, Direct adaptive fuzzy control with a self-structuring algorithm, *Fuzzy Sets and Systems*, Vol. 159, No. 8, pp. 871- 899, 2008.
- [2] R. Babuska, H. Verbruggen, Neuro-fuzzy method for nonlinear system identification, *Annual Review in Control*, Vol. 27, No. 1, pp. 73- 85, 2003.
- [3] H. Lee, E. Kim, H. J. Kang, A new sliding mode control with fuzzy boundary layer, *Fuzzy Sets and Systems*, Vol. 120, No. 1, pp. 135- 143, 2001.
- [4] T. C. Kuo, S. H. Shang, Sliding mode control with self-tuning law for uncertain nonlinear systems, *ISA Transactions*, Vol. 47, No. 2, pp.




Fig. 4 The tracking error for example 1


شکل 4 خطای ردیابی e ، مثال 1

Fig. 5 The tracking result for example 1

شکل 5 نتیجه ردیابی مثال 1

جدول 2 نتایج شبیه‌سازی مثال 2

Table 2 The simulation results for example 2

IAE	سیگنال کنترل u	روش
2.9104	$-15 \leq u \leq 15$	AFSMC [5]
2.7601	$-13.63 \leq u \leq 13.67$	IFSMC [11]
0.0830	$-1.701 \leq u \leq 6.2$	روش ارائه شده




Fig. 6 The control signal for example 2

شکل 6 سیگنال کنترل u مثال 2

- mode control via time-variant sliding function, *IEICE Transaction Fundamentals*, Vol. E93, No. 1, pp. 1-9, 2010.
- [11] M. Yarahmadi, *Design of intelligent robust controllers for nonlinear control systems*, PhD Thesis, Department of Mathematical Sciences, Yazd University, Yazd, 2010. (in Persian فارسی)
- [12] S. A. Moezi, M. Rafeeyan, S. Ebrahimi, Sliding mode control of 3-RPR parallel robot on the optimal path using cuckoo optimization algorithm, *Modars Mechanical Engineering*, Vol. 15, No. 2, pp. 147-158, 2014. (in Persian فارسی)
- [13] A. Mottahedi, A. Akbarzadeh Kalat, Adaptive robust sliding mode control of quadrotor in the presence of wind/disturbance, *Modars Mechanical Engineering*, Vol. 99, No. 9, pp. 9-99, 2016. (in Persian فارسی)
- [14] N. Kouda, N. Matsui, H. Nishimura, F. Peper, Qubit neural network and its learning efficiency, *Neural Computing and Applications*, Vol. 14, No. 2, pp. 114-121, 2005.
- 171-178, 2008.
- [5] H. F. Ho, Y. K. Wong, A. B. Rad, Adaptive fuzzy sliding mode control with chattering elimination for nonlinear SISO systems, *Simulation Modeling Practice and Theory*, Vol. 17, No. 7, pp. 1199-1210, 2009.
- [6] A. Mohammadzadeh, S. Ghaemi, A modified sliding mode approach for synchronization of fractional-order chaotic hyper chaotic systems by using new self-structuring hierarchical type-2 fuzzy neural network, *Neurocomputing*, Vol. 191, No. 1, pp. 200-213, 2016.
- [7] M. S. Kahkeshin, F. Sheikholeslam, M. Zekri, Design of adaptive fuzzy wavelet neural sliding mode controller for uncertain nonlinear systems, *ISA Transactions*, Vol. 52, No. 3, pp. 342-350, 2013.
- [8] F. Yunmei, F. Juntao, M. Kaiqi, Model reference adaptive sliding mode control using RBF neural network for active power filter, *Electrical Power and Energy Systems*, Vol. 73, No. 1, pp. 249-258, 2015.
- [9] W. D. Chang, R. C. Hwang, J. G. Hsieh, Application of an auto-tuning neuron to sliding mode control, *IEEE Transaction on System*, Vol. 32, No. 4, pp. 517-529, 2002.
- [10] M. Yarahmadi, S. M. Karbassi, A. Mirzaei, Robust wavelet sliding-