

## عملکرد مقاوم و بهینه در کنترل کننده‌ی عصبی مدل مرجع با حل یک مسئله‌ی بهینه‌سازی مقید

حمیدرضا کوفی‌گر محمد رضا احمدزاده

دانشگاه صنعتی اصفهان - دانشکده برق و کامپیوتر

E-mail: koofigar@ec.iut.ac.ir

چکیده- در این مقاله، از یک الگوریتم مقاوم تطبیق پارامترها مبتنی بر خطای نرمالیزه جهت تطبیق وزنه‌های کنترل کننده‌ی عصبی استفاده و همگرایی آن با وجود سیگنال اختلال نشان داده می‌شود. در این روش، نرمالیزه کردن خطا با استفاده از یک ضریب متغیر انجام گردیده و اعمال شرایط مختلف از جمله شرایط لازم جهت همگرایی و سرعت پاسخ زمانی مطلوب، محدودیت در نحوه‌ی انتخاب این ضریب را مشخص می‌نماید. تابع هدف برای حل مسئله‌ی بهینه‌سازی مربعات خطای تعقیب، در سه حالت خطای لحظه‌ای، خطای انباشته‌ی سراسری و یک فرم پیشنهادی موسوم به خطای انباشته‌ی جزئی برای کاهش دامنه‌ی نوسانات سیگنال کنترل، معرفی می‌گردد. حل مسئله‌ی بهینه‌سازی با تابع هدف مربوطه و قید بدست آمده روی ضریب نرمالیزه کننده‌ی خطا، پاسخ بهینه و مقاوم سیستم کنترل را بدست می‌دهد. نتایج شبیه‌سازی نشان می‌دهد که با استفاده از الگوریتم مقاوم پیشنهاد شده، پایداری سیستم حلقه بسته با وجود سیگنال اختلال و تغییرات پارامترهای سیستم بدست می‌آید؛ نقش ضریب نرمالیزه کننده و تغییرات آن در تعقیب بهینه‌ی مسیر مرجع و کاهش دامنه‌ی نوسانات سیگنال کنترل نیز با در نظر گرفتن توابع هدف مختلف نشان داده شده است.

کلید واژه- الگوریتم مقاوم تطبیق پارامترها، بهینه‌سازی مقید، خطای انباشته، خطای تعقیب نرمالیزه، کنترل کننده عصبی مدل مرجع.

### ۱- مقدمه

هدف مهمی که در سیستم‌های کنترل تطبیقی مطرح می‌گردد، تعقیب سیگنال مرجع با خطای قابل قبول در حالت گذرا و خطای صفر در حالت دائمی می‌باشد. نحوه‌ی دستیابی به این هدف، بدون حضور اختلال و نامعینی‌ها در مراجع مختلف از جمله در [۱] و [۲] آمده است. وجود تغییرات در پارامترهای سیستم و حضور اختلال در مورد سیستم‌های واقعی باعث گردیده تا روش‌های استاندارد معرفی شده به صورت‌های گوناگون اصلاح شوند تا برآورده شدن اهداف طراحی با وجود نامعینی‌ها و اغتشاشات نیز تضمین شود [۳] تا [۶].

سیستم‌های کنترل تطبیقی به طور کلی شامل یک مکانیزم تطبیق پارامترها و یک قانون کنترل است. در روش‌های تطبیقی مستقیم که در این مقاله مورد نظر است، پارامترهای کنترل کننده توسط قانون تطبیق به روز می‌شوند. عملکرد سیستم حلقه بسته به مکانیزم تطبیق پارامترها و نیز ساختار کنترل کننده وابسته است [۱]. از

طرف دیگر، عدم در نظر گرفتن سیگنال‌های اختلال و نیز تغییرات پارامترهای سیستم در مراحل طراحی باعث ایجاد پرش یا نوسانات گذرا یا ماندگار حول سیگنال مرجع گردد که معمولاً با توجه به محدوده‌ی مجاز خطای تعقیب و نیز محدودیت‌های اعمال شده روی سیگنال کنترل قابل قبول نیست. در مواردیکه پارامترهای سیستم در محدوده‌ی وسیعی تغییر کنند و یا نرم سیگنال اختلال وارد شده به سیستم (نسبت به نرم سیگنال‌های سیستم حلقه بسته) بزرگ باشد، روش اتخاذ شده برای تطبیق پارامترها برای سیستم نامی همگرا نشده و در نهایت به ناپایداری سیستم منجر می‌گردد. از روش‌های مؤثر در دستیابی به پایداری و عملکرد مقاوم و برآوردن اهداف کنترل با وجود نامعینی‌ها و اغتشاشات، استفاده از خطای تعقیب نرمالیزه شده در مکانیزم تطبیق می‌باشد [۷].

تناظر موجود بین شرایط لازم برای قوانین تطبیق جهت تخمین پارامترها و لزوم همگرایی الگوریتم‌های آموزش شبکه‌های عصبی باعث گردیده تا ایده‌های مطرح شده و

سیگنال اختلال، بردار  $\theta^*$  تخمین زده شود. مدل تخمین به صورت زیر نوشته می‌شود:

$$\hat{z} = \theta^T \varphi \quad (3)$$

استفاده از الگوریتم گرادیان برای یافتن بردار تخمین  $\theta = [\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_n]^T$ ، نتیجه می‌دهد [۲]:

$$\hat{\theta} = \Gamma e \varphi \quad (4)$$

که در آن ماتریس  $\Gamma > 0$  بهره‌ی تطبیق و  $e$  خطای تخمین را نشان می‌دهد و برابر است با:

$$e = z - \hat{z}$$

در تحلیل سیستمهای زمان پیوسته، پریود نمونه‌برداری  $T_s$  عددی خیلی کوچک اختیار می‌گردد تا بتوان همگرایی الگوریتم گرادیان را نشان داد، حال آنکه در عمل به دلیل محدودیت پهنای باند، کران پایینی برای  $T_s$  بدست می‌آید. باید توجه داشت که پهنای باند وسیع باعث کاهش مقاومت سیستم حلقه بسته نسبت به نویز و خطاهای مدل‌سازی می‌گردد. در قوانین تطبیق موسوم به هیبرید که در آن از خطای تخمین نرمالیزه استفاده می‌شود، رابطه‌ی بین  $\Gamma$  و  $T_s$  برای تضمین همگرایی الگوریتم بدست می‌آید. در ادامه به توصیف این الگوریتم و شرایط همگرایی آن می‌پردازیم.

## ۲-۱- قوانین تطبیق هیبرید

برای بدست آوردن بردار  $\theta$ ، قانون تطبیق هیبرید به صورت زیر نوشته می‌شود:

$$\theta_{k+1} = \theta_k + \Gamma \int_k^{k+1} e_n(\tau) \varphi(\tau) d\tau, \quad \theta_0 = \theta(0) \quad (5)$$

که در آن  $k = 0, 1, 2, \dots$  در واقع با الگوریتم فوق، دنباله‌ای از بردار تخمین مشابه زیر حاصل می‌گردد:

$$\hat{z}(t) = \theta_k^T \varphi(t) \quad \forall t \in [t_k, t_{k+1}] \quad (6)$$

که در آن  $\theta_k = \theta(t_k)$  در رابطه‌ی (۵)، خطای تخمین نرمالیزه برابر است با:

$$e_n(t) = \frac{z(t) - \hat{z}(t)}{m^2(t)} \quad (7)$$

که  $m(t)$  سیگنال نرمالیزه‌کننده بوده و در این مقاله به صورت زیر در نظر گرفته می‌شود:

$$m^2(t) = 1 + \alpha \varphi^T(t) \varphi(t), \quad \alpha > 0 \quad (8)$$

در ادامه ضمن تحلیل همگرایی الگوریتم معرفی شده برای آموزش شبکه‌ی عصبی، نقش ضریب نرمالیزه‌کننده‌ی  $\alpha > 0$  در تضمین همگرایی با وجود اختلالات وارد شده به سیستم نشان داده می‌شود.

پیشرفتهای انجام گرفته در زمینه‌ی تخمین پارامترها با وجود اختلال و نامعینیهای سیستم، در نحوه‌ی آموزش شبکه‌ها نیز مورد استفاده قرار گیرد. با توجه به این ویژگی، در دو دهه اخیر شبکه‌های عصبی در پیاده‌سازی الگوریتمهای کنترل و از جمله سیستمهای کنترل مدل مرجع کاربرد وسیعی یافته‌اند [۸] و [۹].

هدف دیگری که در مورد مسئله‌ی تعقیب مورد توجه قرار می‌گیرد، حداقل کردن مربعات خطای تعقیب می‌باشد [۱۰] و [۱۱]. در این مقاله دستیابی به این هدف با استفاده از ضریب نرمالیزاسیون بهینه مورد نظر است. به طور کلی تابع هدف برای این مسئله به صورت زیر بیان می‌گردد:

$$J = \frac{1}{2} \sum_{k=1}^N [Q e^2(k) + R u^2(k)] \quad (1)$$

که  $e(\cdot)$  خطای تعقیب و  $u(\cdot)$  سیگنال کنترل را نشان می‌دهد؛ ضرایب وزنی  $R$  و  $Q$  اهمیت کوچک بودن سیگنال کنترل و مربعات خطای تعقیب را نسبت به هم نشان می‌دهند. با مشخص کردن حد بالای مجموع فوق یعنی عدد  $N$  و ضرایب  $R$  و  $Q$ ، مسئله‌ی بهینه‌سازی به صورتهای مختلف در می‌آید.

در بخش (۲)، یک الگوریتم مقاوم تطبیق پارامترها با استفاده از خطای تخمین نرمالیزه معرفی گردیده و همگرایی آن با وجود سیگنال اختلال نشان داده می‌شود. تعریف مسئله‌ی تعقیب در سیستم کنترل عصبی مدل مرجع با خاصیت مقاوم و بهینه بودن پاسخ خروجی در بخش (۳) ارائه و حالات مختلفی که با انتخاب دقیق  $N$  بوجود می‌آید بررسی می‌شود. در بخش (۴)، شبیه‌سازی سیستم در حضور سیگنال اختلال و تغییرات در پارامترهای سیستم انجام و حالات مختلف بهینه‌سازی پاسخ با ضریب نرمالیزه‌کننده خطا بررسی می‌گردد. در بخش (۵)، به مهمترین نتایج بدست آمده در مقاله اشاره می‌شود.

## ۲-۲- قانون تطبیق پارامترها

یک مدل پارامتری با وجود اختلال  $v$  به صورت زیر قابل نمایش است:

$$z = \theta^{*T} \varphi + v \quad (2)$$

که در آن  $\theta^*$  بردار پارامترها و  $\varphi = [\varphi_1, \varphi_2, \dots, \varphi_n]^T$  بردار رگرسیون شامل اندازه‌گیریهای ورودی-خروجی می‌باشد. مکانیزم تطبیق به گونه‌ای طراحی می‌گردد که با وجود

$$\begin{aligned} \Delta V(k) \leq & -2 \int_{t_k}^{t_{k+1}} e_n^2(\tau) m^2(\tau) d\tau \\ & + 2 \int_{t_k}^{t_{k+1}} e_n(\tau) v(\tau) d\tau \\ & + \frac{\gamma_m T_s}{\alpha} \int_{t_k}^{t_{k+1}} e_n^2(\tau) m^2(\tau) d\tau \end{aligned} \quad (12)$$

برای بدست آوردن شرایط همگرایی الگوریتم دو حالت مجزا در نظر می‌گیریم. در حالت اول مدل پارامتری (۲) بدون اختلال و در حالت دیگر با وجود سیگنال اختلال کراندار بررسی می‌گردد.

حالت (۱) بدون اختلال ( $v(t) = 0$ )

در این حالت رابطه (۱۲) به صورت زیر قابل بازنویسی است:

$$\Delta V(k) \leq -\left(2 - \frac{\gamma_m T_s}{\alpha}\right) \int_{t_k}^{t_{k+1}} e_n^2(\tau) m^2(\tau) d\tau$$

برای همگرایی الگوریتم لازم است  $\Delta V(k) \leq 0$  برقرار باشد (تابع لیپانف افزایشی نباشد). بنابراین شرط کافی برای رسیدن به این هدف برقراری رابطه‌ی زیر است:

$$\frac{\gamma_m}{\alpha} < \frac{2}{T_s}$$

با برقراری رابطه‌ی فوق،  $\theta_k$  و  $\tilde{\theta}_k$  سیگنالهایی کراندار و الگوریتم همگراست.

حالت (۲) وجود اختلال کراندار  $\|v(t)\| \leq D$

بازنویسی رابطه‌ی (۱۲) برای این حالت نتیجه می‌دهد:

$$\begin{aligned} \Delta V(k) \leq & - \int_{t_k}^{t_{k+1}} \left( e_n(\tau) m(\tau) - \frac{v(\tau)}{m(\tau)} \right)^2 d\tau \\ & - \left(1 - \frac{\gamma_m T_s}{\alpha}\right) \int_{t_k}^{t_{k+1}} e_n^2(\tau) m^2(\tau) d\tau \\ & + \int_{t_k}^{t_{k+1}} \frac{v^2(\tau)}{m^2(\tau)} d\tau \end{aligned} \quad (13)$$

طبق نامساوی فوق، می‌توان شرط کافی برای  $\Delta V(k) \leq 0$  جهت تضمین همگرایی الگوریتم و کراندار بودن سیگنالها را برقراری دو شرط زیر دانست:

(۱) پارامترهای  $\gamma_m$ ،  $\alpha$  و  $T_s$  به نحوی انتخاب شوند که رابطه‌ی زیر برقرار گردد:

$$\frac{\gamma_m}{\alpha} \leq \frac{1}{T_s} \quad (14)$$

(۲) سیگنال نرمالیزه‌کننده  $m(t)$  به اندازه‌ی کافی بزرگ انتخاب گردد تا عبارت سوم در سمت راست نامساوی فوق، از مجموع دو عبارت دیگر کوچکتر باشد؛ این انتخاب با افزایش  $\alpha$  در رابطه (۸) صورت می‌گیرد.

## ۲-۲- تحلیل همگرایی با وجود اختلال

در این بخش با انتخاب تابع لیپانف زیر همگرایی الگوریتم هیبرید معرفی شده را بررسی می‌نماییم:

$$V(k) = \tilde{\theta}_k^T \Gamma^{-1} \tilde{\theta}_k$$

که در آن  $\tilde{\theta}_k = \theta_k - \theta^*$ ، در ادامه، فرضیات زیر در نظر گرفته می‌شود:

۱- سیگنال نرمالیزه‌کننده طبق (۸) انتخاب می‌گردد.

۲- بزرگترین مقدار ویژه‌ی ماتریس  $\Gamma$  با  $\gamma_m$  نشان داده می‌شود.

۳- زمان نمونه‌برداری برابر است با  $T_s = t_{k+1} - t_k$ .

تشکیل عبارت  $\Delta V(k) = V(k+1) - V(k)$  بدست می‌دهد:

$$\Delta V(k) = (2\tilde{\theta}_k + \Delta\theta_k)^T \Gamma^{-1} \Delta\theta_k$$

که  $\Delta\theta_k = \theta_{k+1} - \theta_k$ . با استفاده از رابطه‌ی (۵) می‌توان عبارت فوق را بصورت زیر بازنویسی کرد:

$$\begin{aligned} \Delta V(k) = & 2\tilde{\theta}_k^T \int_{t_k}^{t_{k+1}} e_n(\tau) \varphi(\tau) d\tau \\ & + \left( \int_{t_k}^{t_{k+1}} e_n(\tau) \varphi(\tau) d\tau \right)^T \Gamma \int_{t_k}^{t_{k+1}} e_n(\tau) \varphi(\tau) d\tau \end{aligned} \quad (9)$$

همچنین روابط (۲)، (۳) و (۷) نتیجه می‌دهد:

$$e_n(t) m^2(t) = -\tilde{\theta}_k^T \varphi(t) + v(t)$$

با توجه به اینکه  $\gamma_m$  بزرگترین مقدار ویژه‌ی ماتریس  $\Gamma$  است لذا داریم  $\gamma_m \leq \|\Gamma\|$ . بنابراین با توجه به رابطه‌ی (۹) می‌توان نوشت:

$$\begin{aligned} \Delta V(k) \leq & -2 \int_{t_k}^{t_{k+1}} e_n^2(\tau) m^2(\tau) d\tau \\ & + 2 \int_{t_k}^{t_{k+1}} e_n(\tau) v(\tau) d\tau \end{aligned} \quad (10)$$

$$+ \gamma_m \left( \int_{t_k}^{t_{k+1}} |e_n(\tau) m(\tau)| \cdot \left| \frac{\varphi(\tau)}{m(\tau)} \right| d\tau \right)^2$$

انتخاب سیگنال نرمالیزه‌کننده (۸) نتیجه می‌دهد:

$$\frac{\varphi^T \varphi}{m^2} \leq \frac{1}{\alpha} \quad (11)$$

برای بازنویسی نامساوی (۱۰) به فرم ساده‌تر، از نامساوی شوارتز یعنی

$$\left( \int f(\tau) g(\tau) d\tau \right)^2 \leq \int f^2(\tau) d\tau \cdot \int g^2(\tau) d\tau$$

استفاده می‌کنیم که بر این اساس می‌توان نوشت:

وجود نامعینیهای سیستم و اختلالات خارجی می‌تواند به واگرایی الگوریتم تطبیق و نهایتاً ناپایداری سیستم منجر شود. همانگونه که در بخش (۲) نشان داده شد، استفاده از خطای تخمین نرمالیزه در قانون تطبیق می‌تواند مقاوم بودن این الگوریتم را که برای به روز کردن وزنه‌های کنترل‌کننده‌ی عصبی به کار می‌رود تضمین کند. به طور خلاصه دو هدف زیر را به عنوان معیارهای مقاوم بودن می‌شناسیم:


۱- همگرایی الگوریتم آموزش شبکه، کراندار بودن سیگنالها و پایداری سیستم حلقه بسته با وجود تغییرات در پارامترهای سیستم و اختلالات خارجی تضمین گردد.

۲- سیگنال  $y_p$  دارای بالازدگی و پرشهای ناگهانی نبوده و حتی‌الامکان بدون نوسانات حول مسیر مرجع  $y_m$  باشد. این پرشها و نوسانات معمولاً در اثر دینامیکهای سیستم  $G_p(s)$  و یا اختلالات وارد شده به سیستم رخ می‌دهد و ممکن است دامنه‌ی آنها بیش از حد مجاز باشد. محدودیتهای پیاده‌سازی و دامنه‌ی مجاز سیگنالها برای اعمال به محرکها در کاربردهای مختلف از عوامل تعیین‌کننده‌ی این محدودیتها می‌باشد. همانگونه که در بخش (۲-۲) اشاره شد برای همگرایی الگوریتم و برآورده شدن معیارهای مقاوم بودن پاسخ خروجی لازم است در هر بازه‌ی زمانی، مقدار  $\alpha$  از یک کران پایین  $L$  بزرگتر باشد. از طرف دیگر، انتخاب  $\alpha$  های بزرگ نیز سرعت پاسخ زمانی سیستم را کاهش می‌دهد لذا یک کران بالای  $U$  برای این ضریب در نظر گرفته می‌شود. بنابراین در هر بازه‌ی  $[t_k, t_{k+1}]$  محدودیت زیر را داریم:

$$L_k \leq \alpha_k \leq U_k \quad (15)$$

### ۲-۳- تابع هدف برای بهینگی پاسخ مسئله‌ی تعقیب

حل مسئله‌ی بهینه سازی مقید با تابع هدف کلی (۱) و قید (۱۵) پاسخ بهینه را بدست می‌دهد. همانگونه که در گذشته اشاره گردید، با انتخاب دقیق  $N$ ،  $Q$  و  $R$  در (۱)، بهینه بودن مسیر تعقیب بدست آمده از کنترل‌کننده‌ی عصبی مدل مرجع تعابیر متفاوتی دارد. در ادامه، تابع هدف به صورت خطای لحظه‌ای و نیز خطای انباشته‌ی سراسری در نظر گرفته شده و سپس یک فرم پیشنهادی موسوم به خطای انباشته‌ی جزئی به عنوان تابع هدف ارائه و مزیت آن نسبت به حالات قبلی بیان می‌شود.



شکل (۱): ساختار کلی کنترل‌کننده عصبی مدل مرجع

### ۳- تعریف مسئله‌ی تعقیب با ویژگیهای مقاوم و


#### بهینه بودن پاسخ

ساختار کلی یک سیستم کنترل تطبیقی مدل مرجع با کنترل‌کننده‌ی عصبی در شکل (۱) نشان داده شده است. سیگنال کنترل  $u_p$  که توسط کنترل‌کننده‌ی عصبی تولید می‌شود چنان است که خروجی  $y_p$  بتواند مسیر  $y_m$  که توسط مدل مرجع  $G_m(s)$  تولید می‌شود را تعقیب کند.

برای تولید سیگنال  $u_p$  به نحو مطلوب، لازم است وزنه‌های شبکه توسط یک الگوریتم آموزش، به روز شوند. ساختار کلی شبکه‌ی مربوط به کنترل‌کننده و مکانیزم تنظیم وزنه‌های آن در شکل (۲) ترسیم گردیده است.

### ۳-۱- مقاوم بودن الگوریتم آموزش

عملکرد سیستم حلقه بسته به ساختار کنترل‌کننده‌ی عصبی و قانون آموزش به کار رفته در مورد آن بستگی دارد. به طور کلی هدف در سیستم کنترل تطبیقی مدل مرجع آن است که کنترل‌کننده و قانون تطبیق پارامترها که در اینجا وظیفه‌ی آموزش وزنه‌های شبکه را به عهده دارد به گونه‌ای طراحی شوند که اولاً تمام سیگنالهای سیستم حلقه بسته شکل (۱) کراندار بوده و ثانیاً خروجی  $y_p$  سیگنال مرجع  $y_m$  را با یک خطای تعقیب مجاز تعقیب کند.



شکل (۲): تطبیق وزنه‌های شبکه با الگوریتم آموزش هیبرید

$$J_{PA} = \frac{1}{2} \left( \sum_{k=1}^{n_1} [Qe^2(k) + Ru_p^2(k)] + \sum_{k=n_1+1}^{n_2} [Qe^2(k) + Ru_p^2(k)] + \dots + \sum_{k=n_t+1}^{N_s} [Qe^2(k) + Ru_p^2(k)] \right) \quad (18)$$

با توجه به تابع هدف معرفی شده، کل بازه‌ی مورد نظر برای  $k$  از ۱ تا  $N_s$  به زیر بازه‌های متعدد افراز می‌گردد. یعنی  $[1 \ N_s] = [1 \ n_1] \cup [n_1+1 \ n_2] \cup \dots \cup [n_t+1 \ N_s]$  در مسئله بهینه‌سازی مقید، ضریب نرمالیزاسیون  $\alpha_k$  برای یافتن پاسخ بهینه در هر یک از زیر بازه‌های مربوطه محاسبه می‌شود. تعداد زیر بازه‌ها با توجه به کاربرد الگوریتم در موارد مختلف، متفاوت بوده و توسط طراح مشخص می‌گردد. مزیت اتخاذ تابع هزینه‌ی معرفی شده بر دو روش قبلی آن است که می‌توان با انتخاب مناسب تعداد زیر بازه‌های بهینه‌سازی، هر دو شرط محدودیت بر روی سیگنال کنترل و سرعت پاسخ زمانی مناسب را بدست آورد.

#### ۴- نتایج شبیه‌سازی

در این بخش، بهینه‌سازی مسئله‌ی تعقیب در سیستم کنترل عصبی مدل مرجع با در نظر گرفتن توابع هدف معرفی شده در بخش (۳) و استفاده از الگوریتم آموزش هیبرید انجام می‌گیرد. بدین منظور، بردار رگرسیون مشابه آنچه در مرجع [۷] آمده است اتخاذ گردیده و شبیه‌سازی برای یک سیستم مرتبه‌ی دو به فرم زیر انجام می‌گیرد:

$$G_p(s) = \frac{s + z_0}{(s + p_0)(s + p_1)}$$

مدل مرجعی که برای تولید مسیر مرجع  $y_m$  در نظر گرفته می‌شود به صورت زیر است:

$$G_m(s) = \frac{0.5}{s + 0.5}$$

شکل (۱) را در نظر بگیرید. سیگنال اختلال به صورت  $d(t) = 5 + 5\sin 0.02t$  و پریود نمونه‌برداری برابر  $0.1$  ثانیه انتخاب می‌شود. ورودی سیستم به صورت  $r(t) = 4\sin 2t$  بوده و فرایند  $G_p(s)$  به صورت زیر مشخص می‌گردد:

$$z_0 = 2, p_0 = 1, p_1 = 0.02(1 + \sin 0.02t)$$

با در نظر گرفتن (۱۶) به عنوان تابع هدف برای بدست آوردن پاسخ بهینه و اعمال محدودیت (۱۵) پاسخ سیستم

#### ۳-۲-۱- خطای لحظه‌ای

با انتخاب  $N=1$ ،  $Q=1$  و  $R=0$  تابع هدف به صورت زیر در می‌آید:

$$J_I(k) = \frac{1}{2} e^2(k) \quad (16)$$

که در آن  $e(k) = y_m(k) - y_p(k)$  با انتخاب تابع فوق که به خطای لحظه‌ای موسوم است. هدف یافتن ضریب  $\alpha_k$  در هر بازه‌ی زمانی  $[t_k \ t_{k+1}]$  به گونه‌ای است که  $J_I(k)$  در آن بازه حداقل گردد. تغییرات  $\alpha_k$  از بازه‌ای به بازه‌ی دیگر باعث می‌گردد که ورودی کنترل  $u_p$  با دامنه‌ی بیش از حد مجاز تولید شود و یا دارای پرشهای ناگهانی باشد. در این حالت هیچ کنترلی بر روی نوسانات بوجود آمده بر روی سیگنال کنترل و در نهایت سیگنال خروجی وجود ندارد. این امر انگیزه‌ی مطرح کردن فرم دیگری از تابع هدف است که در ادامه به آن اشاره می‌شود.

#### ۳-۲-۲- خطای انباشته‌ی سراسری

در این حالت حد بالای مجموع خطا با توجه به زمان نشست سیستم یا زمانیکه پاسخ به حالت دائمی رسیده است تنظیم می‌شود یعنی

$$J_A = \frac{1}{2} \sum_{k=1}^{N_s} [Qe^2(k) + Ru_p^2(k)] \quad (17)$$



که در آن  $N_s$  زمانی مربوط به بعد از رسیدن پاسخ به حالت دائمی می‌باشد. با انتخاب تابع هدف فوق برای مسئله‌ی بهینه‌سازی، برای سراسر مسیر یک  $\alpha$  بهینه یافت می‌شود و آموزش شبکه با این ضریب انجام می‌گیرد. در این حالت، به دلیل امکان انتخاب مناسب  $Q$  و  $R$  که به ترتیب، اهمیت کوچک بودن خطای تعقیب و سیگنال کنترل را نشان می‌دهد، پاسخ سیستم دارای پرشهای شدید نیست ولی نوسانات حول مسیر مرجع ممکن است تا مدت زمان طولانی‌تری نسبت به حالت قبلی تداوم داشته باشد؛ به عبارت دیگر سرعت پاسخ زمانی سیستم کاهش می‌یابد. تابع هدفی که در ادامه پیشنهاد می‌گردد می‌تواند علاوه بر مزیت انتخاب تابع هدف (۱۷)، سرعت پاسخ زمانی سریعتری بدست دهد.

#### ۳-۲-۳- خطای انباشته‌ی جزئی

تابع هدفی که در این مقاله برای حل مسئله و یافتن ضریب نرمالیزاسیون بهینه پیشنهاد می‌گردد به صورت زیر است:

مشابه شکل (۳) آمده است. مطابق شکل (۳-الف)، سیستم با سرعت مناسب و خطای کم مسیر مرجع سینوسی را دنبال کرده است ولی همانگونه که در شکل (۳-ب) نشان داده شده، سیگنال کنترل  $u_p$  دارای پرشهای مداوم و نوسانات با دامنه‌ی زیاد می‌باشد که در عمل قابل قبول نیست. علت این پدیده، تغییرات سریع ضریب نرمالیزاسیون  $\alpha_k$  از بازه‌ای به بازه‌ی دیگر می‌باشد که در شکل (۳-ج) ترسیم گردیده است. مطابق شکل، کران بالا و پایین در (۱۵) برای  $\alpha_k$  به ترتیب مقدار  $U_k = 1$  و  $L_k = 0$  انتخاب شده است.




مطابق شکل (۳) آمده است. مطابق شکل (۳-الف)، سیستم با سرعت مناسب و خطای کم مسیر مرجع سینوسی را دنبال کرده است ولی همانگونه که در شکل (۳-ب) نشان داده شده، سیگنال کنترل  $u_p$  دارای پرشهای مداوم و نوسانات با دامنه‌ی زیاد می‌باشد که در عمل قابل قبول نیست. علت این پدیده، تغییرات سریع ضریب نرمالیزاسیون  $\alpha_k$  از بازه‌ای به بازه‌ی دیگر می‌باشد که در شکل (۳-ج) ترسیم گردیده است. مطابق شکل، کران بالا و پایین در (۱۵) برای  $\alpha_k$  به ترتیب مقدار  $U_k = 1$  و  $L_k = 0$  انتخاب شده است.



شکل (۴): پاسخ مسئله بهینه‌سازی با تابع هدف خطای انباشته سراسری

الف- پاسخ خروجی  $y_p$

ب- سیگنال کنترل  $u_p$



شکل (۳): پاسخ مسئله بهینه‌سازی با تابع هدف خطای تعقیب لحظه‌ای

الف- پاسخ خروجی  $y_p$

ب- سیگنال کنترل  $u_p$

ج- تغییرات ضریب  $\alpha_k$  بر حسب مرحله‌ی اجرای الگوریتم آموزش

الگوریتم تطبیق مورد توجه قرار گرفت. تابع هدف در مسئله‌ی بهینه‌سازی مقید مربوطه در سه حالت متفاوت معرفی و مزایای هر مورد بیان گردید. شبیه‌سازیهای انجام شده، نقش نوع تابع هدف تعریف شده در میزان نوسانات و پرشهای موجود در پاسخ سیستم و سیگنال کنترل را نشان می‌دهد. تابع هدف پیشنهادی که به صورت خطای انباشته‌ی جزئی در نظر گرفته شد، باعث کاهش قابل توجه در دامنه‌ی نوسانات سیگنال کنترل گردید.


### مراجع

- [1] G. C. Goodwin and K. S. Sin, *Adaptive Filtering Prediction and Control*. Englewood Cliffs, NJ: Prentice-Hall, 1984.
- [2] A. S. Sastry and M. Bodson, *Adaptive Control: Stability, Convergence and Robustness*. Englewood Cliffs, NJ: Prentice-Hall, 1989.
- [3] Z. Qu, J. F. Dorsey and D.M. Dawson, "Model Reference Robust Control of a Class of SISO Systems", *IEEE Trans. Automat. Contr.*, vol. 39, no. 11, pp. 2219-2234, 1994.
- [4] N. Barabanov, R. Ortega and A. Astolfi, "Is Normalization Necessary for Stable Model Reference Adaptive Control?", *IEEE Trans. Automat. Contr.*, vol. 50, no. 9, pp. 1384-1390 Sep. 2005.
- [5] M. Fukumoto, H. Kubota and S. Tsujii, "Improvement in Stability and Convergence Speed on Normalized LMS Algorithm", in *proc. IEEE Int. Symp. On Circuits and systems*, 1995, pp. 1243-1246.
- [6] T. Tsao and P. A. Ioannou, "On the Stability Proof of Adaptive Schemes with Static Normalizing Signals and Parameter Projection", *IEEE Trans. Automat. Contr.*, vol. 38, no. 1, pp. 170-173, Jan. 1993.
- [7] P. A. Ioannou and J. Sun, *Robust Adaptive Control*, NJ: Prentice-Hall, 1996.
- [8] S. Kamalasadan and A. A. Ghandakly, "A Neural Network Based Intelligent Model Reference Adaptive Controller", in *Proc. IEEE int. conf. on Computational Intelligence for Measurement Systems and Applications*, Boston, MA, 2004, pp. 174-179.
- [9] J. Li, Y. Mizukami, Y. Wakasa and K. Tanaka, "Intelligent Control for Pneumatic Servo System", in *Proc. SICE Annual Conference*, Fukui, 2003, pp. 3193-3198.
- [10] Y. M. Park, M.S. Choi and K. Y. Lee, "An Optimal Tracking Neuro-Controller for Non-linear Dynamic Systems", *IEEE Trans. Neural Networks*, vol. 7, no. 5, pp. 1099-1110, 1996.
- [11] L. Yan and J. Xu, "Tracking Performance Improvement of a Model Reference Robust Control", in *Proc. 43<sup>rd</sup> IEEE Conf. on Decision and Control*, Paradise Island, Bahamas, Dec. 2004, pp. 189-194.


در واقع، تغییرات  $\alpha_k$  پس از بازه‌های زمانی افزاز شده و تثبیت آن در طول بازه‌ها طبق شکل (۵-ج)، باعث کاهش دامنه نوسانات در سیگنال کنترل گردیده است.

### ۵- نتیجه‌گیری


در این مقاله، ابتدا یک الگوریتم تطبیق هیبرید جهت به روز کردن وزنه‌های کنترل‌کننده‌ی عصبی مدل مرجع ارائه گردید. ضریب متغیری که خطای تخمین را نرمالیزه کرده و در اختیار الگوریتم قرار می‌دهد مقاوم بودن الگوریتم نسبت به اختلالات و نامعینیهای سیستم را تضمین می‌کند. سپس بهینه‌سازی پاسخ سیستم کنترل عصبی مدل مرجع با اعمال محدودیت روی ضریب نرمالیزاسیون متغیر به کار رفته در



(الف)



(ب)



(ج)

شکل (۵): پاسخ مسئله‌ی بهینه‌سازی با تابع هدف خطای انباشته‌ی جزئی

الف- پاسخ خروجی  $y_p$

ب- سیگنال کنترل  $u_p$

ج- تغییرات ضریب  $\alpha_k$  در بازه‌های افزاز شده به طول ۰/۱ ثانیه

(۱۰ مرحله از اجرای الگوریتم آموزش)