

## کنترل تطبیقی سیستم الکتروسرویدرولیک دو عملگره بر مبنای شبکه عصبی موجک بازگشتی

محمدعلی علیرضاپوری<sup>۱</sup>، احمدرضا ولی<sup>۲</sup>

<sup>۱</sup> دکتری برق کنترل، دانشگاه صنعتی مالک اشتر، Maa\_Pouri@mut.ac.ir  
<sup>۲</sup> دانشیار مجتمع دانشگاهی برق و کامپیوتر، دانشگاه صنعتی مالک اشتر

### چکیده

سیستم‌های کنترل حرکت مبتنی بر هیدروموتورها، دارای دینامیکی غیرخطی و متغیر با زمان هستند که کنترل دقیق آنها را دچار چالش می‌نماید. در این مقاله بر مبنای شبکه عصبی موجک بازگشتی، کنترل‌کننده‌ای تطبیقی برای کنترل سیستم الکتروسرویدرولیک دو عملگره ارائه می‌گردد. به دلیل نیاز به پهنای باند و گشتاور بالا از دو عملگر هیدرولیکی دوار برای کنترل حرکت بار استفاده شده است. کنترل‌کننده پیشنهادی نیازی به مدل دینامیکی دقیق سیستم ندارد و به همین جهت برای کنترل سیستم غیرخطی الکتروسرویدرولیک مناسب است. شبکه عصبی به کار گرفته شده در فرآیند آموزش علاوه بر شناسایی دینامیک سیستم، پیش‌بینی خروجی سیستم در نمونه بعدی را نیز فرا می‌گیرد و طرح پیشنهادی علاوه بر خاصیت تطبیقی، از الگوی پیش‌بین نیز بهره می‌برد. جهت آموزش شبکه عصبی از الگوریتم بهینه‌سازی اجتماع ذرات انعطاف‌پذیر استفاده شده است. کنترل‌کننده ارائه شده برای سیستم الکتروسرویدرولیک با توجه به عدم استفاده از مدل دقیق سیستم و در حضور اغتشاش بار، شبیه‌سازی شده و نتایج تأییدکننده توانایی کنترل‌کننده پیشنهادی در ردیابی فرمان‌های ورودی است.

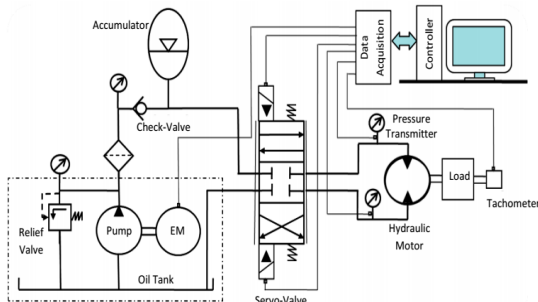
### کلیدواژه

الکتروسرویدرولیک، دو عملگره، شبکه عصبی موجک، کنترل‌کننده تطبیقی

### مقدمه

می‌گیرد. مشخصات روغن هیدرولیک تاثیر قابل توجهی بر عملکرد سیستم الکتروسرویدرولیک دارد و عوامل مختلفی می‌توانند باعث تغییر مشخصات روغن مانند چگالی، ویسکوزیته و مدول بالک (تغییرات چگالی) گردند. تغییرات پارامترهای روغن، می‌تواند موجب نامعینی‌هایی در دینامیک سیستم شده و عملکرد سیستم الکتروسرویدرولیک را با مشکلاتی مواجه سازد [۳، ۴]. همچنین وجود عوامل غیرخطی مانند رابطه فشار و دبی شیر، اشباع شیر و موتور هیدرولیک، جریان نشتی شیر و موتور هیدرولیک، اصطکاک در موتور هیدرولیک، مشخصات و هندسه لوله‌های ارتباطی و تغییر بهره سیستم متناسب با فشار منبع می‌توانند دینامیک سیستم را تحت تأثیر قرار دهند [۵].

امروزه شاهد توسعه روزافزون کاربردهای علم کنترل حرکت در صنایع مختلف هستیم. عملگرهای الکتروسرویدرولیک به دلیل مزیت‌های فراوان، کاربرد چشم‌گیری در صنعت پیدا کرده است. از مهم‌ترین مزیت‌های این عملگرها می‌توان به نسبت بالای قدرت به وزن<sup>۱</sup>، سرعت پاسخ<sup>۲</sup>، پهنای باند بالا<sup>۳</sup> و امکان دسترسی به دقت‌های بالا با استفاده از این عملگرها اشاره کرد [۱]. این مزیت‌ها، باعث شده است که عملگرهای الکتروسرویدرولیک کاربردهای فراوانی در حوزه‌های مختلف صنعتی مانند ماشین‌آلات ریخته‌گری<sup>۴</sup>، ماشین‌آلات راه‌سازی، رباتیک<sup>۵</sup> و تجهیزات معدنی<sup>۶</sup> [۲] پیدا کنند. شکل ۱ نمونه‌ای از این عملگر را نشان می‌دهد که از اجزاء مختلفی مانند پمپ، شیر سرویدرولیک، موتور الکتریکی، اکومولاتور، مخزن روغن، لوله‌هایی برای انتقال روغن هیدرولیک و قطعات مکانیکی و هیدرولیکی مورد نیاز تشکیل شده است. در یک مکانیسم هیدرولیکی، انتقال نیرو با واسطه سیال روغن هیدرولیک انجام



شکل ۱. ساختار سیستم الکتروسرویدرولیک [۲۴]

- <sup>1</sup> high power-to-weight ratio
- <sup>2</sup> rapid response
- <sup>3</sup> High bandwidth
- <sup>4</sup> injection molding machines
- <sup>5</sup> robotics
- <sup>6</sup> mining

شبکه عصبی روی آورند. عملکرد کنترل‌کننده‌های هوشمند در کاربردهایی که مدل دقیقی از سیستم در دسترس نیست، مناسب‌تر از کنترل‌کننده‌های کلاسیک است و علاوه بر این می‌توانند طیف گسترده‌ای از شرایط را پوشش دهند و در شرایط نويز و اختلال به‌خوبی عمل کنند [۱۹]. شبکه‌های عصبی که با الگوگیری از سیستم‌های بیولوژیکی طراحی شده‌اند، توانایی تطبیق‌پذیری مناسبی در سیستم‌های غیرخطی از خود نشان داده‌اند. توانایی یادگیری شبکه‌های عصبی، آن‌ها را به یک ابزار قدرتمند برای مدل‌سازی و کنترل سیستم‌های پیچیده مانند سیستم الکتروسرویدرولیک تبدیل کرده است [۲-۲۳].

در این مقاله کنترل‌کننده‌ای تطبیقی مبتنی بر شناسایی‌کننده شبکه عصبی برای کنترل سیستمی متشکل از دو عملگر الکتروسرویدرولیک که برای کنترل موقعیت زاویه‌ای یک محور حرکتی استفاده می‌شوند، ارائه شده است. شبکه عصبی به کار گرفته شده از نوع موجک بازگشتی است که توانایی مناسبی در تخمین توابع غیرخطی دارد. آموزش این شبکه عصبی در دو مرحله انجام می‌گیرد. در گام اول، شبکه عصبی در فرآیند غیربرخط با به‌کارگیری الگوریتم بهینه‌سازی ازدحام ذرات بهبودیافته آموزش می‌بیند. در این مرحله شبکه عصبی یاد می‌گیرد که علاوه بر شناسایی دینامیک سیستم، خروجی سیستم را پیش‌بینی کند. این شبکه عصبی در پروسه کنترل سیستم، ضرایب کنترل‌کننده را با توجه به تابع حساسیت به‌صورت برخط به‌روز می‌کند و الگوی تطبیقی طرح کنترلی را محقق می‌سازد. بخش‌های بعدی مقاله به شکل زیر سازمان‌دهی شده است: در بخش دوم مدل دینامیکی سیستم الکتروسرویدرولیک ارائه می‌شود. طرح کنترلی پیشنهادی در بخش سوم معرفی می‌شود و همچنین جزئیات شبکه عصبی و چگونگی آموزش آن بیان می‌شود و سپس روابط کنترل‌کننده تطبیقی موردبحث قرار می‌گیرد. نتایج مربوط به شبیه‌سازی در بخش چهارم ارائه خواهد شد و بخش نتیجه‌گیری در انتهای مقاله ارائه خواهد شد.

## مدل فضای حالت سیستم الکترو سرو هیدرولیک

طرح کلی یک سیستم سرویدرولیک در شکل ۱ نشان داده شده است [۲۴]. با اندازه‌گیری موقعیت زاویه‌ای توسط حس‌گر و مقایسه آن با سیگنال مرجع، سیگنال کنترلی محاسبه شده توسط کنترل‌کننده به شیر سروو اعمال می‌شود. شیر نیز متناسب با این سیگنال کنترلی فشار دو طرف هیدروموتور را تنظیم می‌کند. با تنظیم مناسب این فشارها، موقعیت زاویه‌ای هیدروموتور کنترل می‌شود. شیرهای سرو برای تنظیم دبی سیال هیدرولیک و به‌موجب آن کنترل حرکت

با توجه به رفتار غیرخطی و پارامترهای متغییر با زمان این سیستم، لازم است تا؛ مدل ریاضی دقیق و مناسبی از سیستم استخراج گردد و کنترل‌کننده مناسبی طراحی گردد که قابلیت کنترل این سیستم غیرخطی و متغییر با زمان را دارا باشد. از آنجایی که این سیستم دینامیکی دارای عوامل غیرخطی بسیاری است و پارامترهای مدل در اثر شرایط محیطی و کارکرد سیستم دارای تغییرات شدیدی است، استخراج مدل ریاضی دقیق آن، بسیار مشکل است و حتی با استخراج مدل امکان استفاده از آن در طراحی کنترل‌کننده مقدور نخواهد بود. بنابراین لازم است با استخراج مدلی مناسب از سیستم، کنترل‌کننده‌ای را برای این سیستم طراحی نمود که قادر باشد بر دینامیک غیر خطی و متغییر با زمان این سیستم غلبه نماید. با نگاهی بر تاریخچه مدل‌سازی این سیستم، مشاهده می‌شود که ابتدا تنها مدل ساده این سیستم دینامیکی مورد استفاده قرار می‌گرفته است [۶]. سپس، مدل‌های خطی از این سیستم دینامیکی ارائه گردید [۷] و در نهایت مدل‌های دینامیکی غیرخطی از آن ارائه شد [۸-۱۰]. با توجه به اهمیت کنترل دقیق مکانیسم‌های حرکتی مبتنی بر عملگرهای هیدرولیکی در صنعت، مطالعه و تحقیق جهت ارائه مدلی دقیق برای سیستم هیدرولیک همچنان ادامه دارد. روش‌های کنترل خطی مانند روش جایابی قطب و PID، که بر اساس مدل خطی طراحی می‌شوند در بسیاری از کاربردها به کار گرفته شده‌اند [۱۱، ۱۲]. با توجه به عملکرد نامناسب روش‌های کنترلی مبتنی بر مدل خطی سیستم، محققان روش‌های کنترل غیرخطی کلاسیک را مورد استفاده قرار دادند که به‌طور قابل‌ملاحظه‌ای عملکرد رضایت‌بخش‌تری را دارا هستند. از جمله این کنترل‌کننده‌ها می‌توان به روش‌های مُد لغزشی [۱۱، ۲]، پس‌گام [۱۴]، خطی-ساز و ورودی-خروجی [۱۲]، تطبیقی [۱۵] و مقاوم [۱۳، ۱۲] اشاره کرد. یکی از مشکلات استفاده از این روش‌های کنترلی آن است که به اندازه‌گیری حالت‌های سیستم و مشتقات آن‌ها نیاز دارند. به همین خاطر به‌کارگیری آن‌ها در عمل با مشکلاتی همراه خواهد بود [۱۶]. کنترل‌کننده‌های مُد لغزشی، در برابر تغییرات زیاد پارامترهای سیستم مقاوم هستند، ولی از آنجایی که باعث ایجاد پدیده چترینگ<sup>۷</sup> می‌شوند، ممکن است مدهای مدل نشده فرکانس بالا سیستم را تحریک کنند و باعث افت عملکرد سیستم شوند [۱۷، ۱۸].

استفاده از این مدل‌ها و کنترل‌کننده‌هایی که بر اساس این مدل‌ها طراحی و پیاده‌سازی می‌شوند در بسیاری از سیستم‌های صنعتی به خصوص در سیستم‌هایی که به‌دقت و پهنای باند بالا نیاز دارند، کارایی مناسبی ندارد. این مشکل، محققین را بر آن داشت تا به کنترل‌کننده‌های هوشمند مانند منطق فازی و

<sup>7</sup> Back stepping  
<sup>8</sup> Chattering

گره برمی‌گرداند و از اینرو شبکه انعطاف‌پذیری و عملکرد مناسبی جهت شناسایی رفتار دینامیکی سیستم ارائه خواهد داد. جهت اعمال تبدیل موجک در تابع فعال‌سازی از مشتق اول تابع گوسین استفاده می‌شود. ورودی این شبکه با  $x_k(n)$  معرفی شده است که  $k$  معرف ورودی  $k$ ام شبکه است. ورودی این لایه به صورت زیر محاسبه می‌شود:

$$u_{ik}(n) = x_k(n) + \varphi_{ik}(n-1)\theta_{ik} \quad (2)$$

با اعمال این ورودی به لایه موجک مادر، خروجی هر گره رابطه زیر محاسبه می‌گردد:

$$\varphi_{ik}(z_{ik}) = \varphi\left(\frac{u_{ik} - m_{ik}}{d_{ik}}\right) \quad (3)$$


که  $ik$  معرف ورودی  $k$ ام از لایه مادر آم است. همچنین جملات  $m_{ik}$  و  $d_{ik}$  جملات مربوط به تأخیر و گسترش تابع فعال‌سازی می‌باشند. خروجی لایه تولید به صورت زیر به دست می‌آید:

$$\psi_i = \prod_{k=1}^{N_i} \varphi(z_{ik}) = \prod_{k=1}^{N_i} \left[ \exp\left(-\frac{z_{ik}^2}{2}\right) \right] \quad (4)$$

و خروجی شبکه به صورت زیر محاسبه می‌شود:

$$y(n) = \sum_{i=1}^{N_n} w_i \psi_i \quad (5)$$

که  $w_i$  وزن‌های بین لایه تولید و لایه خروجی است.



شکل ۳. شبکه عصبی موجک بازگشتی

شبکه به کار گرفته شده در دو مرحله آموزش می‌بیند. در گام اول شبکه به کمک الگوریتم تکاملی از دحام ذرات بهبودیافته، آموزش می‌بیند. در این مرحله، وزن‌های بهینه سیستم جهت عملکرد مناسب شبکه به دست می‌آید. در گام دوم، این وزن‌ها به عنوان وزن‌های اولیه در آموزش برخط به کار گرفته می‌شوند. در روند آموزش برخط از الگوریتم پس‌انتشار استفاده شده است که سرعت مناسبی جهت شناسایی در لحظه از خود نشان می‌دهد. کنترل‌کننده PID تطبیقی، جهت این‌که در روند آموزش خروجی سیستم واگرا نشود در نظر گرفته شده است. در روند آموزش پنج ورودی به شبکه اعمال می‌شود:

$$[u(n-1), u(n-2), y(n), y(n-1), y(n-2)]$$


در هر گام، شبکه عصبی چهار ورودی از سیستم که شامل دو نمونه قبلی ورودی و خروجی سیستم می‌باشد را دریافت و

سیستم‌های هیدرولیک به کار می‌روند. معادله فضای حالت غیرخطی سیستم الکتروسرو هیدرولیک در رابطه (۱) ارائه شده است [۲۴]. که در این رابطه،  $x_1$  موقعیت زاویه‌ای هیدروموتور، سرعت زاویه‌ای هیدرو موتور،  $x_3$  فشار بار و  $x_4$  بازشدگی شیر سرو است. همچنین  $x_1, p_1, w_2, p_2, p_3, r_1, r_2$  پارامترهای ثابت سیستم می‌باشند.

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= w_1 x_3 - w_2 x_2 - w_3 \\ \dot{x}_3 &= p_1 x_4 \sqrt{p_s - x_3 \text{sign}(x_4)} - p_2 x_3 \\ &\quad - p_3 x_2 \\ \dot{x}_4 &= -r_1 x_4 + r_2 u \end{aligned} \quad (1)$$

### طرح کنترل کننده پیشنهادی

ساختار کلی کنترل‌کننده پیشنهادی برای سیستم الکتروسرو هیدرولیک دورانی در شکل ۲ ارائه شده است. سیستم تحت کنترل نامعلوم فرض شده است. از یک کنترل‌کننده تطبیقی کلاسیک PID برای تولید سیگنال کنترل استفاده می‌گردد که پارامترهای آن با بلوک شناسایی کننده مبتنی بر شبکه عصبی موجک بازگشتی تنظیم می‌گردند. وظیفه این شبکه عصبی شناسایی دینامیک سیستم غیرخطی الکتروسرو هیدرولیک و به روز کردن ضرایب کنترل‌کننده است. شبکه به کار گرفته شده در فرآیند یادگیری آفلاین به گونه‌ای آموزش می‌بیند که علاوه بر شناسایی دینامیک لحظه‌ای سیستم، خروجی سیستم را نیز پیش‌بینی می‌کند. در ادامه جزئیات طرح کنترلی پیشنهادی ارائه خواهد شد.



شکل ۲. بلوک دیاگرام آموزش شبکه عصبی موجک بازگشتی

شبکه عصبی موجک بازگشتی یک شبکه عصبی ۴ لایه است که در ساختار خود از تابع فعال‌سازی موجک بهره می‌برد. نمایی از ساختار شبکه عصبی را در شکل ۳ مشاهده می‌کنید. چهار لایه شبکه عصبی مطابق شکل بدین صورت است: لایه ورودی، لایه موجک مادر، لایه تولیدی و لایه خروجی. مطابق نام‌گذاری در لایه اول ورودی‌های موردنظر به شبکه اعمال شده و در لایه دوم بسته‌هایی مشاهده می‌شود که هر کدام شامل گره‌هایی است که تعداد این گره‌ها به تعداد ورودی‌های سیستم بستگی دارد. برای مثال اگر شبکه پنج ورودی داشته باشد هر بسته شامل پنج گره خواهد بود و همچنین هر گره شامل یک تابع فعال‌سازی موجک است و یک پسخور نیز در هر گره در نظر گرفته می‌شود. این پسخور نمونه قبلی خروجی گره را به

در الگوریتم بهینه‌سازی ازدحام ذرات بهبودیافته یک دوره حذف به نوع کلاسیک آن اضافه شده است [۲۵،۲۶]. در ابتدای هر دوره تعدادی مشخص از بدترین جواب‌ها حذف و جایگزین آن جواب‌های جدیدی در فضای جستجوی انتخاب خواهند شد. با این تغییرات در الگوریتم احتمال قرار گرفتن در کمینه‌های محلی کاهش و سرعت پیدا کردن جواب‌های بهینه افزایش می‌یابد. مراحل اجرای الگوریتم بهینه‌سازی ازدحام ذرات بهبود داده شده بصورت زیر می‌باشد:

۱- انتخاب فضای جستجو اولیه برای پارامترهای هر ذره، تعداد جمعیت اولیه، ماکزیمم تعداد تکرار،  $c_1$ ،  $c_2$ ،  $w$ ،<sup>۹</sup> و  $et$ <sup>۱۰</sup>.

۲- ایجاد جمعیت اولیه در فضای جستجوی تعیین شده

۳- محاسبه تابع معیار برای هر ذره

۴- تعیین  $pbest$  هر ذره و

۵- در صورتی که تعداد تکرار مضرری از  $ep$  شود؛ تغییرات زیر انجام شود (مرحله حذف)

- در صورتی که اندازه پارامترهای هر ذره بزرگ‌تر از یک آستانه شد یک واحد به فضای جستجو آن عضو ذره اضافه شود.

- تعیین  $et$  درصد از جمعیت اولیه که دارای بدترین تابع معیار هستند.

- حذف  $et$  درصد از جمعیت و تولید جمعیت جدید در فضای جستجوی. سرعت حرکت ذره-های جدید صفر انتخاب شود.

- محاسبه تابع معیار برای ذره‌های جدید.

- تعیین  $pbest$  برای هر ذره و

۶- به‌روزرسانی موقعیت همه ذره‌ها با استفاده از روابط (۵) و (۶).

۷- به مرحله ۳ برو و تا رسیدن به شروط خاتمه مراحل (۳) و ۴ و ۵ و ۶ و ۷ را تکرار کن.

تابع هزینه جهت بهینه‌سازی در رابطه (۸) ارایه شده است.  $y_d(n)$  خروجی واقعی سیستم به ازای اعمال ورودی اتفاقی و  $\hat{y}(n)$  خروجی شبکه عصبی در هر لحظه است و الگوریتم تکاملی در هر گام با انتخاب وزن‌های متفاوت تلاش می‌کند بهترین وزن‌های ممکن را جهت داشتن حداقل خطا ارائه نماید. در این ساختار از آموزش با توجه به وزن‌هایی که از آموزش آفلاین به دست می‌آید آموزش شروع می‌شود. در این ساختار از آموزش الگوریتم پس انتشار به کار گرفته می‌شود. مانند حالت آفلاین تابع هزینه به صورت زیر تعریف می‌شود:

$$J(n) = \frac{1}{2}(y_d(n) - \hat{y}(n))^2 = \frac{1}{2}e(n)^2 \quad (9)$$

سپس شبکه عصبی آموزش دیده تا خروجی را به گونه‌ای تولید کند که به خروجی سیستم نزدیک باشد. این روند ادامه می‌یابد تا شبکه عصبی رفتار سیستم را با حداقل خطا تخمین بزند. شبکه عصبی علاوه بر اینکه رفتار دینامیکی سیستم را شناسایی می‌کند، یاد می‌گیرد تا خروجی سیستم را در یک گام جلوتر پیش‌بینی نماید. شبکه عصبی موجک بازگشتی به کار گرفته شده چهار وزن دارد  $[w, m, d, \theta]$  که این چهار وزن که با توجه به ابعاد ورودی و لایه‌های میانی در نظر گرفته شده می‌تواند ماتریسی باشند.

علاوه بر این، از الگوریتم ازدحام ذرات بهبودیافته به کار گرفته می‌شود تا با توجه به تابع هزینه در نظر گرفته شده وزن‌های مطلوب شبکه عصبی را بیابد. روش بهینه‌سازی ازدحام ذرات، یک الگوریتم جستجو است که از رفتار اجتماعی دسته‌های پرندگان الهام گرفته است [۲۵]. نتیجه مدل‌سازی این رفتار اجتماعی فرایند جستجویی است که ذرات به سمت نواحی موفق میل می‌کنند. ذرات از یکدیگر می‌آموزند و بر مبنای دانش به دست آمده به سمت بهترین همسایگان خود می‌روند. در ساختار این الگوریتم گروهی از پرندگان در فضایی به صورت تصادفی دنبال غذا می‌گردند. تنها یک تکه غذا در فضای مورد بحث وجود دارد. هیچ‌یک از پرندگان محل غذا را نمی‌دانند. یکی از بهترین استراتژی‌ها می‌تواند دنبال کردن پرنده‌ای باشد که کمترین فاصله را تا غذا داشته باشد. هر ذره یک مقدار شایستگی دارد که توسط یک تابع شایستگی محاسبه می‌شود. هر چه ذره در فضای جستجو به نزدیک‌تر باشد، شایستگی بیشتری دارد. همچنین هر ذره دارای سرعتی است که هدایت حرکت ذره را بر عهده دارد. هر ذره با دنبال کردن ذرات بهینه در حالت فعلی، به حرکت خود در فضای مسئله ادامه می‌دهد. گروهی از ذرات در آغاز کار الگوریتم به صورت تصادفی به وجود می‌آیند و با به‌روز کردن نسل‌ها سعی در یافتن راه‌حل بهینه می‌نمایند. در هر گام، هر ذره با استفاده از دو بهترین مقدار بروز می‌شود. اولین، بهترین موقعیتی است که تاکنون ذره موفق به رسیدن به آن شده است. موقعیت مذکور شناخته و نگهداری می‌شود که با  $pbest$  نام‌گذاری می‌شود. مقدار دیگر، بهترین موقعیتی است که تاکنون توسط جمعیت ذرات به دست آمده است. این موقعیت با  $gbest$  نمایش داده می‌شود. پس از یافتن بهترین مقادیر، سرعت و مکان هر ذره با استفاده از روابط (۶) و (۷) به‌روز می‌شود [۲۵-۲۷].

$$v = w \times v +$$

$$c_1 \times rand \times (pbest - position) + c_2 \times rand \times (gbest - position) \quad (6)$$

$$position = position + v \quad (7)$$

$$J(n) = \frac{1}{2}(y_d(n) - \hat{y}(n))^2 = \frac{1}{2}e(n)^2 \quad (8)$$

<sup>9</sup> Elimination Period

<sup>10</sup> Elimination percent

$$\frac{\partial u(n)}{\partial k_d} = \frac{de_c}{dt} \quad (25)$$

در محاسبه  $\frac{\partial y(n)}{\partial u(n)}$ ، عملکرد شبکه عصبی نقش مهمی را ایفا می‌کند. اگر ورودی شبکه عصبی به صورت بردار زیر تعریف شود:

$$x = [u(n), u(n-1), \dots, u(n-p)], \quad (26)$$

$$(y(n), y(n-1), \dots, y(n-p))$$

با توجه به این که شبکه عصبی در پروسه آموزش یاد می‌گیرد تا خروجی سیستم را در یک گام جلوتر پیش‌بینی کند، داریم:

$$\frac{\partial y(n+1)}{\partial u(n)} = \frac{\partial y(n+1)}{\partial x} \square \frac{\partial x}{\partial u(n)} \quad (27)$$

$$\frac{\partial x}{\partial u(n)} = [1, f_1(z), \dots, f_p(z)]^T \quad (28)$$

$$\frac{\partial y(n+1)}{\partial x_k} = \sum_{i=1}^{N_w} W_i \psi_i \left( \frac{1}{d_{ik}} \right) \left( \frac{1}{z_{ik}} - z_{ik} \right) \quad (29)$$

### نتایج شبیه‌سازی

بلوک دیاگرام کلی سیستم کنترل در شکل ۲ ارائه شده است. بنا به ملاحظاتی و برای افزایش گشتاور و پهنای باند سیستم، در کاربرد خاص مد نظر، از دو هیدروموتور برای کنترل یک محور حرکتی استفاده شده است. بلوک دیاگرام سیستم دو عملگره مورد مطالعه در این بخش، در شکل ۴ و شماتیک اتصال مکانیکی این دو عملگر در شکل ۵ نمایش داده شده است. سنکرون کردن دو هیدروموتور برای کنترل حرکت یکبار مکانیکی، زمینه تحقیقاتی جذابی برای کاربردهای مختلف است. وجود تغییرات در بار، خصوصیات غیرخطی در دینامیک سیستم، تغییر در مشخصات اجزا سیستم هیدرولیک، تراکم-پذیری سیال و ... مشکلاتی را برای سنکرون سازی دو عملگر ایجاد می‌کنند. با توجه به این که این دو موتور به هم متصل می‌گردند، معادلات دینامیکی ارائه شده در بخش دوم را بایستی اصلاح نمود. به این صورت که اختلاف زاویه دو موتور (اختلاف دو حالت اول سیستم) به دینامیک مشتق حالت دوم دو سیستم وارد می‌شود. دینامیک سیستم مرجع با اندیس  $m$  و دینامیک سیستم تحت فرمان با اندیس  $s$  معرفی می‌شود.

$$\begin{aligned} \dot{x}_{m1} &= x_{m2} \\ \dot{x}_{m2} &= \omega_1 x_{m3} - \omega_2 x_{m2} + G_s (x_{m1} - x_{s1}) \\ \dot{x}_{m3} &= p_1 x_{m4} \sqrt{P_s - x_{m3} \text{sign}(x_{m4})} \\ &- p_2 x_{m3} - p_3 x_{m2} \end{aligned} \quad (30)$$

$$\begin{aligned} \dot{x}_{s1} &= x_{s2} \\ \dot{x}_{s2} &= \omega_1 x_{s3} - \omega_2 x_{s2} + G_s (x_{m1} - x_{s1}) \\ \dot{x}_{s3} &= p_1 x_{s4} \sqrt{P_s - x_{s3} \text{sign}(x_{s4})} - p_2 x_{s3} - p_3 x_{s2} \\ \dot{x}_{s4} &= -r_1 x_{s4} + r_2 u \end{aligned} \quad (31)$$

اگر وزن‌های شبکه عصبی را  $W$  در نظر بگیریم با توجه به الگوریتم پس‌انتشار خواهیم داشت:

$$W(n+1) = W(n) - \eta \left( \frac{\partial J(n)}{\partial W(n)} \right) = \quad (10)$$

$$W(n) - \eta \left( -e(n) \frac{\partial \hat{y}(n)}{\partial W(n)} \right)$$

در رابطه بالا  $\eta$  نرخ یادگیری شبکه عصبی است. با توجه به این که بردار وزن شبکه عصبی چهار جمله دارد رابطه ۸ به صورت زیر بسط داده می‌شود:

$$\frac{\partial \hat{y}(n)}{\partial m_{ik}(n)} = w_i \psi_i \left( \frac{-1}{d_{ik}} \right) \left( \frac{1}{z_{ik}} - z_{ik} \right) \quad (11)$$

$$\frac{\partial \hat{y}(n)}{\partial d_{ik}(n)} = z_{ik} \left( \frac{\partial \hat{y}(n)}{\partial m_{ik}(n)} \right) \quad (12)$$

$$\frac{\partial \hat{y}(n)}{\partial \theta_{ik}(n)} = -(\varphi_{ik}(n-1)) \left( \frac{\partial \hat{y}(n)}{\partial m_{ik}(n)} \right) \quad (13)$$

$$\frac{\partial \hat{y}(n)}{\partial w_i(n)} = \psi_i \quad (14)$$

هم‌چنین با توجه به روابطی که در [۲۱] ارائه شده است، نرخ یادگیری شبکه به صورت برخط و تطبیقی به صورت زیر به روزرسانی می‌شود:

$$\eta_I^{w, \max} = \frac{1}{N_{I,w}} \quad (15)$$

$$\eta_I^{m, \max} = \frac{1}{N_{I,w} N_{I,d}} \left[ \frac{|d_I|_{\min}}{|w_I|_{\max} \times 2 \exp(-0.5)} \right]^2 \quad (16)$$

$$\eta_I^{d, \max} = \frac{1}{N_{I,w} N_{I,d}} \left[ \frac{|d_I|_{\min}}{|w_I|_{\max} \times 2 \exp(0.5)} \right]^2 \quad (17)$$

$$\eta_I^{\theta, \max} = \frac{1}{N_{I,w} N_{I,d}} \left[ \frac{|d_I|_{\min}}{|w_I|_{\max} \times 2 \exp(-0.5)} \right]^2 \quad (18)$$

همان‌طور که اشاره شد، کنترل‌کننده به کار گرفته شده از نوع تناسبی-انترگالی-مشتق‌گیر و با فرم زیر است:

$$u(t) = k_p e(t) + k_i \int_0^t e(\tau) d\tau + k_d \frac{de(t)}{dt} \quad (19)$$

حال برای داشتن الگوی تطبیقی این کنترل‌کننده، تابع هزینه-ای جهت به دست آوردن ساختار بهینه تطبیق ارائه می‌شود:

$$J_c(n) = \frac{1}{2} e_c^2(n) = \frac{1}{2} (r(t) - y(t))^2 \quad (20)$$

مطابق رابطه بهینه‌سازی پس‌انتشار داریم:

$$W_c(n+1) = W_c(n) - \eta_c \left( \frac{\partial J_c(n)}{\partial W_c(n)} \right) \quad (21)$$

که در رابطه بالا  $W_c = [k_p, k_i, k_d]$  است. حال داریم:


$$\frac{\partial J_c(n)}{\partial W_c(n)} = \frac{\partial J_c(n)}{\partial u(n)} \square \frac{\partial u(n)}{\partial W_c(n)} = \quad (22)$$

$$[-e_c(n) \frac{\partial y(n)}{\partial u(n)}] \square \frac{\partial u(n)}{\partial W_c(n)} \quad (23)$$

$$\frac{\partial u(n)}{\partial k_p} = e_c \quad (23)$$


$$\frac{\partial u(n)}{\partial k_i} = \int_0^t e_c dt \quad (24)$$

در شکل ۶ خروجی یا موقعیت زاویه‌ای عملگرهای اصلی و پیرو و سیگنال مرجع ترسیم شده است که نشان‌دهنده عملکرد مناسب سیستم در ردیابی فرمان ورودی است. خروجی مدل شناسایی شده توسط شبکه عصبی نیز در شکل ۷ با خروجی مدل واقعی سیستم مقایسه شده است که نشان‌دهنده عملکرد مناسب روش ارائه شده در شناسایی مدل نامعلوم سیستم دارد.




شکل ۷. خروجی موقعیت زاویه‌ای مدل شناسایی شده

سیگنال کنترلی اعمال شده به سیستم نیز در شکل ۸ ارائه شده است. هم‌چنین تغییر نرخ یادگیری تطبیقی در شکل ۹ ارائه شده است.



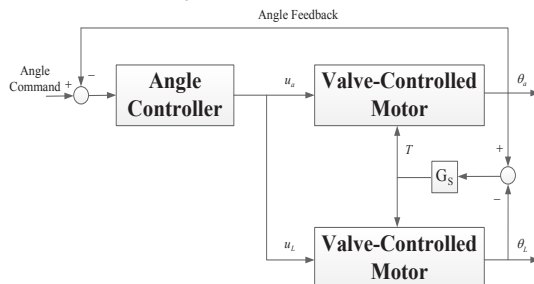
شکل ۸. سیگنال خروجی کنترل‌کننده PID تطبیقی




شکل ۹. تغییرات نرخ یادگیری

بر اساس این مدل دینامیکی، مقادیر پارامترهای مدل به صورت زیر انتخاب شده است.

$$w_1 = 9.61e-5; w_2 = 2.56; p_1 = 1.91e10; \\ p_2 = 7.92; p_3 = 6e6; r_1 = 100; r_2 = 3e-4$$




شکل ۴. بلوک دیاگرام هم‌زمان‌سازی دو سیستم



شکل ۵. شماتیک کلی بخش مکانیکی سیستم تحت کنترل [۲۸]

برای شبیه‌سازی، عملکرد سیستم مورد نظر را در ردیابی سیگنال موقعیت زاویه‌ای مطلوب که به شکل فرمانی سینوسی با دامنه ۵۰ درجه و فرکانس 0.67 rad/sec است، مورد ارزیابی قرار می‌دهیم. فرض بر آن است که ساختار شبکه عصبی و کنترل‌کننده ثابت است و مدلی از سیستم تحت کنترل در اختیار نداریم و با استفاده از شبکه عصبی مدل سیستم دینامیکی را شناسایی می‌کنیم. در فرایند آموزش شبکه عصبی روش‌های مختلف تکاملی را برای محاسبه وزن‌ها مورد بررسی قرار داده و با یکدیگر مقایسه می‌کنیم. لازم به ذکر است یک سیگنال سینوسی هم فرکانس با سیگنال مرجع به‌عنوان اغتشاش بار نیز به سیستم اعمال می‌گردد.



شکل ۶. موقعیت خروجی زاویه‌ای سیستم

روند همگرایی الگوریتم بهینه‌سازی در آموزش شبکه، در شکل ۱۱ نمایش داده شده است. روش مورد استفاده برای بهینه‌سازی آفلاین، روش PSO است. در این شبیه‌سازی روند همگرایی الگوریتم بهینه‌سازی با دیگر روش‌های بهینه‌سازی مقایسه و در شکل ۱۱ نمایش داده شده است. در این شکل مشخص است که الگوریتم بهینه‌سازی به کار گرفته شده از نظر روند همگرایی و سرعت همگرایی در مقایسه با سایر الگوریتم‌های هم‌کلاس خود عملکرد بهتری از خود نشان می‌دهد.




### نتیجه گیری

در این مقاله کنترل‌کننده تطبیقی مبتنی بر شبکه عصبی موجک بازگشتی برای کنترل سیستم الکتروسرویدرولیک دو عملگره ارائه گردید. سیستم‌های کنترل حرکتی مبتنی بر هیدروموتورها عموماً سیستم‌های غیرخطی و با پارامترهای متغیر با زمان هستند که این موضوع طراحی کنترل‌کننده‌های کلاسیک خطی و غیرخطی مناسب را به امری بسیار مشکل و معمولاً غیرممکن تبدیل می‌کند. در این مقاله، شبکه عصبی به کار گرفته شده در پروسه آموزش علاوه بر شناسایی دینامیک سیستم، یاد می‌گیرد که خروجی سیستم را در یک گام جلوتر پیش‌بینی کند. با توجه به این خاصیت، شبکه عصبی در فرآیند کنترل با استفاده از روابط تطبیقی ارائه شده، ضرایب کنترل‌کننده کلاسیک PID را به صورت برخط به‌روز می‌کند. از این رو بدون نیاز به در اختیار داشتن مدل سیستم، طراحی و تطبیق کنترل‌کننده صورت می‌پذیرد. عملکرد طرح کنترلی پیشنهادی در شبیه‌سازی مورد بررسی قرار گرفت و نتایج شبیه‌سازی موید قابلیت کنترل‌کننده هوشمند ارائه شده در کنترل سیستم غیرخطی بدون استفاده از مدل دینامیکی سیستم و در حضور اغتشاش بار است.


### مراجع

- [1] J. Watton, "Fluid Power Systems," Prentice Hall, New Jersey, 1989.
- [2] Chen, Hong-Ming, Jyh-Chyang Renn, and Juhng-Perng Su. "Sliding mode control with varying boundary layers for an electro-hydraulic position servo system." The International Journal of Advanced Manufacturing Technology 26.1-2 (2005): 117-123.
- [3] Jelali, Mohieddine, and Andreas Kroll. Hydraulic servo-systems: modelling, identification and control. Springer Science & Business Media, 2012.

کنترل‌کننده مورد استفاده یک کنترل تطبیقی است و تغییرات ضرایب کنترل‌کننده PID تطبیقی در شکل ۱۰ ارائه شده است.



شکل ۱۰. تغییرات ضرایب کنترل‌کننده



شکل ۱۱. همگرایی الگوریتم بهینه‌سازی

- the electrohydraulic servo systems." IEEE transactions on control systems technology 5.2 (1997): 163-177.
- [16] J. E. Bobrow and K. Lum, "Adaptive, High Bandwidth Control of a Hydraulic Actuator," Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME, Vol. 118, No. 4, 1996, pp. 714-720.
- [17] Su JP (2001) Robust control of a class of nonlinear cascade systems: a novel sliding mode approach. Proc IEE Control Theory Appl 149(2):131-136.
- [18] Utkin VJ (1997) Variable structure systems: a survey. IEEE Trans Automat Contr 22:212-222
- [19] Lucas C, Milasi RM, Araabi BN. Intelligent modeling and control of washing machine using locally linear neuro-fuzzy (LLNF) modeling and modified brain emotional learning based intelligent controller (BELBIC). Asian J Control 2005; 8(4):393-400
- [20] N. Kandil, S. LeQuoc, and M. Saad, "On-line trained neural controllers for nonlinear hydraulic system," in Proc. 14th World Congr. Int. Fed. Autom. Control, 1999, pp. 323-328.
- [21] Malekzadeh, M., Sadati, J. and Alizadeh, M., 2016. Adaptive PID controller design for wing rock suppression using self-recurrent wavelet neural network identifier. *Evolving Systems*, 7(4), pp.267-275.
- [22] Malekzadeh, M., Khosravi, A., Rasouli, H. and Noei, A.R., 2015, November. A Genesio-Tesi chaotic control using an adaptive-neural observer based RISE controller. In *Knowledge-Based Engineering and Innovation (KBEI), 2015 2nd International Conference on* (pp. 787-791). IEEE.
- [23] Malekzadeh, M., Khosravi, A., Noei, A.R. and Ghaderi, R., 2014. Application of adaptive neural network observer in chaotic systems. *International Journal of Intelligent Systems and Applications*, 6(2), p.37.
- [24] Sadeghieh, A., Sazgar, H., Goodarzi, K., & Lucas, C. (2012). Identification and real-time position control of a servo-hydraulic rotary actuator by means of a neurobiologically motivated algorithm. *ISA transactions*, 51(1), 208-219.
- [4] Sadeghieh, Ali, et al. "Identification and real-time position control of a servo-hydraulic rotary actuator by means of a neurobiologically motivated algorithm." *ISA transactions* 51.1 (2012): 208-219.
- [5] Kim, Min Young, and Chung-Oh Lee. "An experimental study on the optimization of controller gains for an electro-hydraulic servo system using evolution strategies." *Control Engineering Practice* 14.2 (2006): 137-147.
- [6] H. E. Merrit, *Hydraulic Control Systems*. New York: Wiley, 1967.
- [7] S. Habibi and A. Goldenberg, "Design of a new high-performance electrohydraulic actuator," *IEEE/ASME Trans. Mechatronics*, vol. 5, no. 2, pp. 158-164, Jun. 2000.
- [8] P. Y. Li, "Dynamic redesign of a flow control servo-valve using a pressure control pilot," presented at the ASME Int. Mech. Eng. Congr. Expos., New York, NY, Nov 11-16, 2001.
- [9] M. K. Zavarehi, P. D. Lawrence, and F. Sassani, "Nonlinear modeling and validation of solenoid-controlled pilot-operated servovalves," *IEEE/ASME Trans. Mechatronics*, vol. 4, no. 3, pp. 324-334, Sep. 1999.
- [10] S. LeQuoc, R.M.H. Cheng, and K.H. Leung, "Tuning an electrohydraulic servovalve to obtain a high amplitude ratio and a low resonance peak," *J. Fluid Control*, vol. 20, pp. 30-49, 1990.
- [11] Lee, Kyo-II, and Dong-Kwon Lee. "Tracking control of a single-rod hydraulic cylinder using sliding mode." *Proceedings of the 29th IEEE Conference*. 1990.
- [12] Fales R, Kelkar A. Robust control design for a wheel loader using H-infinity and feedback linearization based methods. *ISA Trans* 2009;48(3):312-20.
- [13] Milić V, Šitum Ž, Essert M. Robust H-infinity position control synthesis of an electro-hydraulic servo system. *ISA Trans* 2010;49(4):535-42.
- [14] Kaddissi C, Kenné J-P, Saad M. Identification and real-time control of an electrohydraulic servo system based on nonlinear backstepping. *IEEE/ASME Trans Mechatron* 2007;12(1):12-22.
- [15] Yu, Wen-Shyong, and Te-Son Kuo. "Continuous-time indirect adaptive control of

- swarm optimization. *Evolving Systems*, pp.1-15.
- [28] Dong, W., Han, S., Jiao, Z., Wu, S. and Zhao, Y., 2014, August. Compound angle-synchronizing control strategy for dual electro-hydraulic motors in hydraulic flight motion simulator. In Proceedings of 2014 IEEE Chinese Guidance, Navigation and Control Conference (pp. 2219-2224). IEEE.
- [25] Salahshour, E., Malekzadeh, M., Gordillo, F. and Ghasemi, J., 2018. Quantum neural network-based intelligent controller design for CSTR using modified particle swarm optimization algorithm. *Transactions of the Institute of Measurement and Control*, p.0142331218764566.
- [26] Pourmousa, N., Ebrahimi, S.M., Malekzadeh, M. and Alizadeh, M., 2019. Parameter estimation of photovoltaic cells using improved Lozi map based chaotic optimization Algorithm. *Solar Energy*, 180, pp.180-191.
- [27] Salahshour, E., Malekzadeh, M., Gholipour, R. and Khorashadizadeh, S., 2018. Designing multi-layer quantum neural network controller for chaos control of rod-type plasma torch system using improved particle

