

# کنترل سرعت عملگرهای سرو هیدرولیک، با استفاده از شبکه‌های عصبی انعطاف‌پذیر و ثابت و الگوریتم یادگیری خطای پس‌خور

سید حسین ساداتی<sup>۱</sup>، مجید کریمی ماسوله<sup>۲</sup> و فرید نجفی<sup>۳</sup>

آزمایشگاه عملگرها، دانشکده مهندسی مکانیک، دانشگاه صنعتی خواجه نصیرالدین طوسی

## چکیده

در این مقاله، کنترل سرعت سیستم‌های سرو هیدرولیک با استفاده از شبکه‌های عصبی مورد بررسی قرار گرفته است. ساختار کنترلی عصبی مورد استفاده ساختار آموزش خطای پس‌خور FEL می‌باشد و اساس آن مبتنی بر یادگیری دینامیک معکوس سیستم تحت کنترل و کمینه کردن خروجی کنترلر کلاسیک به عنوان تابع هزینه شبکه است. در این مقاله، از شبکه‌های پیش‌خور سه لایه استفاده شده و در لایه میانی آن، توابع سیگموئید انعطاف‌پذیر به کار رفته است. آموزش کلیه وزن‌های شبکه و پارامترهای توابع سیگموئید به صورت همزمان و با استفاده از الگوریتم پس انتشار خطا با ممنوع انجام شده است. نتایج شبیه‌سازی‌ها با استفاده از نرم‌افزار مطلب-سیمولینک<sup>۴</sup> روی مدل کامپیوتری نشانگر قابلیت بالای شبکه‌های عصبی انعطاف‌پذیر در مقایسه با شبکه‌های عصبی ساختار ثابت و کنترلر کلاسیک در یادگیری دینامیک معکوس و کنترل سیستم سرو هیدرولیک به صورت همزمان و در زمان واقعی می‌باشد.

**واژه‌های کلیدی:** عملگر سرو هیدرولیک، شبکه عصبی انعطاف‌پذیر، کنترل تطبیقی عصبی، یادگیری خطای پس‌خور

## Speed Control of a Servo Hydraulic Actuator, Using Artificial Neural Networks and Feedback Error Learning Algorithm

S. H. Sadati, M. Karimi-Masooleh, and F. Najafi

Mech. Eng. Dep't., K.N. Toosi Univ. of Tech.

### ABSTRACT

In this article, speed control of a servo hydraulic rotary actuator is investigated, using flexible structure neural network (NN). The applied architecture of NN is a feedback error learning (FEL), whose underlying learning strategy is based on the inverse dynamics of the system under control. The classic control output was taken as the cost function to be minimized by the NN. A three-layer feedforward NN was applied and a flexible sigmoid activation function was used for the hidden layer nodes. The learning paradigm was online, making use of the back propagation of error with momentum. A simulation was performed and the results obtained indicated the high capability of the flexible NN in learning inverse dynamics in real time in controlling servo hydraulic systems.

**Key Words:** Servo Hydraulic Actuator, Flexible Neural Network, Adaptive-Neural Control, Feedback Error Learning

۱- استادیار (نویسنده پاسخگو): sadati@kntu.ac.ir

۲- کارشناس ارشد: majidkarimi@me.kntu.ac.ir

۳- استادیار: fnajafi@kntu.ac.ir

۴- Matlab-Simulink

## ۱- مقدمه

امروزه، سیستم‌های رانش هیدرولیکی به دلیل برخورداری از مزایای بسیار، کاربرد گسترده‌ای در صنعت یافته‌اند. از جمله این مزایا می‌توان به بالا بودن نسبت قدرت انتقالی به وزن قطعات، روغنکاری و انتقال حرارت خودبه‌خودی به دلیل خواص سیال، قابلیت اعمال گشتاورهای بزرگ، سرعت پاسخ بالا، پهنای باند بالا و نسبت اینرسی به گشتاور بالا اشاره کرد. ضمن اینکه در این سیستم‌ها پدیده‌هایی نظیر اشباع مغناطیسی ماشین‌های الکتریکی وجود ندارد و در نتیجه دقت این سیستم‌ها به‌ویژه در کنترل موقعیت بالا خواهد بود. عمده‌ترین دلیل عملکرد نامطلوب این سیستم‌ها، ناپایداری آنهاست. در این حالت، در نقاط کارکرد سیستم، نوسانات شدید فشار رخ می‌دهد که ممکن است به صدمه دیدن قطعات بینجامد. بنابراین پایداری سیستم، مهم‌ترین نکته در طراحی محسوب می‌شود. کلیه عوامل گفته شده باعث می‌شوند که سیستم‌های هیدرولیکی، دینامیکی کاملاً غیرخطی داشته باشند و تغییرات عواملی نظیر فشار و سرعت و دما به این نقیصه شدت می‌بخشد. اگر این تغییرات کنترل نشود، ممکن است به نوسانات شدید و صدمه خوردن قطعات منجر شود.

سیستم‌های سروهیدرولیک شامل اجزای مختلفی مانند شیرهای سرو، عملگرها و پمپ‌ها هستند که مشخصات دینامیکی بسیار پیچیده، غیرخطی و متغیر با زمان دارند. به‌عنوان مثال، با تغییر دمای کارکرد، پارامترهای حساس به دما مانند چگالی، ویسکوزیته و مدول بالک تغییر می‌کنند. برای سیستم‌های هیدرولیکی که در مدت زمان طولانی و یا در دماهای متغیر کار می‌کنند این تغییرات پارامترها، قابل چشم‌پوشی نیست [۱] و لازم است از کنترلرهای مختلفی برای جبران این تغییرات و تضمین عملکرد مطلوب سیستم استفاده کرد. در این زمینه تحقیقات گسترده‌ای در مراکز تحقیقاتی صورت گرفته و روشها و الگوریتم‌های مختلفی از جمله کنترلرهای مقاوم، تطبیقی، هوشمند، و ... برای کنترل این سیستم‌ها ارائه شده است [۱۲-۲].

مطلوب سیستم را تضمین نمی‌کند. حتی در یک نقطه کارکرد، پارامترهای سیستم ممکن است تغییر کند. بنابراین یافتن کنترلی که بتواند با تغییرات پارامترهای سیستم، به‌سرعت خود را تطبیق دهد، بسیار مطلوب خواهد بود. بدیهی است در این میان، ساختارهای کنترل هوشمند و به‌ویژه شبکه‌های عصبی مصنوعی، انتخاب مناسبی برای رسیدن به این هدف هستند. امروزه استفاده از شبکه‌های عصبی مصنوعی توسعه بسیاری در شناسایی و کنترل سیستم‌های سروهیدرولیک یافته است. در اکثر کارهایی که تاکنون با استفاده از شبکه‌های عصبی در زمینه کنترل سیستم‌های سروهیدرولیک انجام شده است، شبکه‌های عصبی به صورت غیر متصل<sup>۱</sup> تحت آموزش قرار گرفته‌اند. این امر باعث صرف زمان نسبتاً طولانی برای آموزش شبکه می‌شود. آنی و همکارانش [۱۳] از این روش برای کنترل یک سیستم سروهیدرولیک استفاده نمودند و نتایج را با یک کنترلر بهینه مقایسه کردند. نوهل و آنهوان [۱۴] از یک شبکه تابع پایه شعاعی<sup>۲</sup> برای شناسایی باند مرده یک سیستم ارزان قیمت سروهیدرولیک و معکوس آن استفاده کردند. کلیه آموزش‌ها به صورت غیر متصل صورت گرفت و از شبکه عصبی به عنوان جبران‌ساز در کنار یک کنترلر بهینه استفاده شد. این روش توسط یانگ و همکاران [۱۵] بهبود داده شد و آنها توانستند با استفاده از بهینه‌سازی در گروه‌ها، وزن‌های شبکه را به صورت همزمان<sup>۳</sup> آموزش داده و با استفاده از ترکیب این شبکه با منطق کنترلی PID یک سیستم سروهیدرولیک را کنترل نمایند. کیان و همکارانش [۱۶] کنترل سرعت یک سیستم سروهیدرولیک با شبکه‌های عصبی را مورد بررسی قرار دادند. آنها به صورت غیر متصل یک کنترلر PID برنامه‌ریزی شده<sup>۴</sup> را به یک شبکه آموزش دادند و از یک کنترلر کمکی مولد پالس برای غلبه بر اصطکاک استفاده کردند. به منظور آموزش غیر متصل در سیستم سروهیدرولیک، هانگ و همکاران [۱۷] از الگوریتم آموزشی گرادیان مرتبه دوم بهره گرفتند. با استفاده از سیستم‌های کنترلی ساختار متغیر و به‌کارگیری منطق فازی در مدل مغزی کنترلی شبکه عصبی، زمینگ و همکاران [۱۸] توانستند همگرایی سریع در آموزش وزن‌های شبکه را اثبات نمایند. آنها همچنین به منظور کاهش

طراحی کنترلرهای رایج بر اساس مدل‌های خطی شده و نامتغیر با زمان، در هنگام تغییر نقطه کارکرد، عملکرد

- 1-Off Line
- 2-Radial Basis Function
- 3-On Line
- 4-Scheduled

برای مدل سازی سیستم فوق با توجه به معادلات حاکم بر اوریفیس ها، می توان از روابط موجود در [۲۲] استفاده کرد. شیر سرو: برای شیر سرو تاکنون روابط بسیاری استخراج شده است. یکی از روابط اصلی در مدل سازی این شیرها که به صورت تجربی به دست آمده است عبارت است از:

$$Q_1 = K_f i \sqrt{P_s - P_1} \quad (1)$$

$$Q_2 = K_f i \sqrt{P_2} \quad (2)$$

که در آن،  $K_f$  ضریب شیر می باشد و به صورت تجربی معین می شود.  $i$  شدت جریان الکتریکی ورودی شیر،  $P_s$  فشار تغذیه،  $P_1$  و  $P_2$  به ترتیب فشار ورودی و خروجی هیدروموتور،  $Q_1$  دبی خروجی از دهانه شیر که به عملگر فرستاده می شود و  $Q_2$  دبی برگشتی از عملگر به شیر می باشد.

**هیدروموتور:** روابط حاکم بر دبی ورودی و سرعت زاویه ای خروجی هیدروموتور عبارتند از:

$$Q_1 = D_m \omega + \frac{P_1}{R_e} + \frac{CdP_1}{dt} \quad (3)$$

$$Q_2 = D_m \omega - \frac{P_2}{R_e} - \frac{CdP_2}{dt} \quad (4)$$

که در آن،  $D_m$  نسبت حجم جابه جا شده روغن به زاویه دوران هیدروموتور،  $C$  ظرفیت هیدروموتور (برابر با نسبت حجم جابجا شده به مدول بالک  $\frac{V}{\beta}$ ) و  $R_e$  مقاومت ناشی موتور می باشد. رابطه گشتاور حاصل و سرعت و شتاب زاویه ای موتور بدین صورت است:

$$D_m (P_1 - P_2) = T_l + B_v \omega + J_m \frac{d\omega}{dt} \quad (5)$$

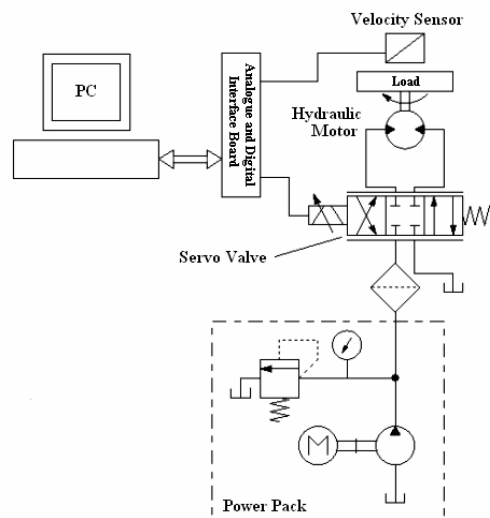
در رابطه فوق،  $T_l$  گشتاور بار،  $B_v$  ضریب میرایی و  $J_m$  ممان اینرسی اجزای گردشی هیدروموتور است. به طور کلی با وجود آنکه شیرهای سرو دارای دقت و حساسیت بالایی هستند، اما دارای عوامل غیرخطی بسیاری نظیر بیش پوشی و کم پوشی اسپول، هیستریزس، پس زنی

نوسانات و افزایش قابلیت کنترل موقعیت، کنترلر مد لغزشی تطبیقی را بر اساس روش مذکور ارائه نمودند. در کلیه روشهای یاد شده از توابع ثابت تحریک در شبکه عصبی استفاده شده و محققان برای افزایش سرعت در آموزش وزن های شبکه، از روشهای ترکیبی پیچیده با شبکه عصبی (استفاده از منطق فازی، توابع پایه شعاعی و ...) استفاده نموده اند.

در این تحقیق، به منظور ایجاد قابلیت یادگیری بهتر با ساختار ساده شبکه، حتی با تعداد نرون های کمتر در لایه میانی، از توابع تحریک سیگموئید انعطاف پذیر [۱۹] در لایه میانی شبکه استفاده شده است. همچنین برای یادگیری دینامیک معکوس و کنترل سرعت سیستم سرو هیدرولیک به صورت همزمان و در زمان واقعی<sup>۱</sup> ساختار آموزش پس خور خطا (FEL) [۲۰ و ۲۱] به کار گرفته شده است. نتایج با یک کنترلر شبکه عصبی ساختار ثابت و کلاسیک PI مورد مقایسه قرار گرفته است.


## ۲- مدل سازی سیستم های سرو هیدرولیک

سیستمی که در این تحقیق مورد بررسی قرار می دهیم از یک منبع توان، یک شیر سرو هیدرولیک، یک هیدروموتور به عنوان عملگر و اجزای جانبی مانند فیلتر تشکیل شده است. شکل ۱ مدار هیدرولیکی این سیستم را نشان می دهد.



شکل (۱): مدار سیستم سرو هیدرولیکی مورد بررسی.

مطلب دیگری که در شکل ۳ پیداست، وجود یک منطقه مرده در نقطه صفر است که نشانگر بیش پوش بودن این نوع شیر می باشد. با استفاده از یک بلوک نقطه مرده<sup>۴</sup> با مقدار ۰/۱ که به صورت سعی و خطا به دست آمده است، تابع تبدیل سیستم به صورت شکل ۴ در نرم افزار سیمولینک<sup>۵</sup> مدل سازی می شود.



شکل (۴): دیاگرام بلوکی تابع تبدیل سیستم بین سرعت و ولتاژ.

### ۳- شبکه های عصبی انعطاف پذیر

در شبکه های عصبی معمولی، فقط وزن های ارتباطی، عناصر قابل تغییر و تنظیم هستند و سایر عناصر از جمله توابع غیرخطی، ثابت فرض می شوند اما چنین مدلی برای سلول عصبی کامل نیست؛ زیرا در سلول های عصبی طبیعی در طی فرایند آموزش، علاوه بر وضعیت سیناپس ها که با وزن های ارتباطی مدل می شوند، خود سلول نیز تغییراتی می کند. با توجه به این واقعیت، تلاش های جدیدی برای ارائه مدل های کامل تر و نزدیک تر به سلول عصبی طبیعی انجام گرفته است. از آن جمله مدلی است که توسط تشنه لب و واتانابه ارائه گردیده است [۱۹]. تفاوت این مدل با مدل معمولی قبلی در این است که در مدل جدید به جای استفاده از یک تابع غیرخطی ثابت از یک تابع غیرخطی انعطاف پذیر از نوع سیگموئید است و به دو صورت تک قطبی و دو قطبی می باشد.


#### ۳-۱- توابع سیگموئید تک قطبی انعطاف پذیر

یک سیگموئید تک قطبی انعطاف پذیر به صورت رابطه (۶) تعریف می شود.

$$g(x, a) = \frac{2|a|}{1 + e^{-2|a|x}} \quad (6)$$


4-Dead Zone  
5-Simulink

(اصطکاک بین اسپول و غلاف آن)، اشباع و جابه جایی صفر<sup>۱</sup> می باشند [۱ و ۲۲]. برای شیر سرو مورد بررسی مقادیر مختلف جابجایی صفر در دمای ۲۵ درجه سانتی گراد به وسیله آزمایش به ازای فرکانس های مختلف بدست آمده است (شکل ۲).



شکل (۲): مقادیر جابجایی صفر در دمای ۲۵ درجه سانتی گراد.

با اعمال یک سیگنال شیب رفت و برگشتی به سیستم، می توان نموداری را که بیانگر حد اشباع و هیستریزس سیستم می باشد، به دست آورد (شکل ۳).



شکل (۳): نمودار هیستریزس شیر سرو.

بنابراین برای این سیستم حد اشباع  $\pm 40mA$  در نظر گرفته شده و با استفاده از نرم افزار متلب سیمولینک<sup>۲</sup> از یک بلوک بلک لاش<sup>۳</sup> برای ایجاد هیستریزس و پس زنی استفاده شده است.

1-Null Shift  
2-Matlab-Simulink  
3-Backlash

خصوصیات آن عبارتند از:

$$g^*(x, a) = \frac{1}{|a|} [g(x, a) + g'(x, a)x] \quad (11)$$

$$\lim_{x \rightarrow +\infty} g(x, a) = \frac{2|a|}{1 + e^{-2|a|x}} = 2|a|, \quad (7)$$

۳-۲- توابع سیگموئید دو قطبی انعطاف پذیر

یک تابع تانژانت هیپربولیک را به صورت رابطه (۱۲) در نظر می گیریم.

$$\lim_{x \rightarrow -\infty} g(x, a) = \frac{2|a|}{1 + e^{-2|a|x}} = 0, \quad (8)$$


$$f(x, a) = \frac{1 - e^{-2xa}}{a(1 + e^{-2xa})} \quad (12)$$

این تابع با متغیر  $\alpha$  اشکال مختلفی می یابد (شکل ۶) و حد آن وقتی  $\alpha$  به سمت بی نهایت برود برابر است با:


$$\lim_{x \rightarrow 0} g(x, a) = \frac{2|a|}{1 + e^{-2|a|x}} = |a|. \quad (9)$$

شکل تابع با مقادیر مختلف  $a$  به صورت شکل ۵ می باشد.

$$\lim_{a \rightarrow 0} f(x, a) = \lim_{a \rightarrow 0} \frac{(1 - e^{-2xa})'}{[a(1 + e^{-2xa})]'} = x. \quad (13)$$



شکل (۶): تابع سیگموئید دو قطبی.



شکل (۵): تابع سیگموئید تک قطبی.

هنگامی که  $a \rightarrow 0$ ، تابع به یک تابع خطی تبدیل شده و با افزایش  $\alpha$  کاملاً غیر خطی می شود. مشتقات آن عبارتند از:

$$f'(x, a) = 1 - a^2 f^2(x, a), \quad (14)$$

$$f^*(x, a) = \frac{1}{a} [f'(x, a)x - f(x, a)]. \quad (15)$$

یکی از خصوصیات جالب سیگموئید دو قطبی بودن آن است و علامت  $\alpha$  تأثیری در مقدار آن ندارد. بنابراین، در خلال آموزش، پارامتر  $\alpha$  می تواند مقداری مثبت یا منفی داشته باشد.


همان گونه که در شکل ۵ مشاهده می شود شکل تابع با تغییر مقدار  $\alpha$  تغییر می کند. با آموزش پارامتر  $\alpha$  می توان شکل دلخواه در هر نرون را با توجه به مقدار مطلوب به دست آورد. توجه شود که محدوده این تابع همواره مثبت است و میزان غیر خطی بودن آن به  $\alpha$  بستگی دارد ( $x \geq 0$ ) مشتقات تابع نسبت به متغیر  $x$  یعنی  $g'(x, a)$  به صورت رابطه (۱۰) به دست می آید.

$$g'(x, a) = g(x, a)[2|a| - g(x, a)] \quad (10)$$

همچنین، مشتق آن نسبت به  $\alpha$ ، یعنی  $g^*(x, a)$ ، به صورت رابطه (۱۱) به دست می آید.

## ۴- آموزش شبکه عصبی مصنوعی


ساختار کلی شبکه‌های عصبی پیش‌خور در شکل ۷ نمایش داده شده است. همان‌گونه که شکل نشان می‌دهد چنین ساختاری از چندین لایه تشکیل شده است که پشت سرهم قرار گرفته‌اند و خروجی عصب‌های هر لایه تنها به ورودی عصب‌های لایه بعد متصل می‌گردد. در این ساختار، لایه اول، لایه ورودی و لایه آخر، لایه خروجی و لایه‌های مابین این دو لایه، لایه‌های میانی یا پنهانی نامیده می‌شوند.



شکل (۷): شبکه عصبی پیش‌خور سه لایه.

## ۴-۱- آموزش عمومی

در مواردی که تابع هزینه شبکه عصبی، تابعی از خروجی شبکه است و خطا از مقایسه خروجی شبکه با خروجی مطلوب به دست می‌آید (و بنابراین می‌تواند مستقیماً در اصلاح پارامترهای قابل تنظیم شبکه مورد استفاده قرار گیرد) از روش آموزش عمومی استفاده می‌کنیم. شکل ۸ نمونه‌ای از آموزش عمومی را برای یادگیری دینامیک معکوس نشان می‌دهد.



شکل (۸): آموزش عمومی.

## ۴-۱-۱- آموزش وزن‌های شبکه

برای حالت آموزش عمومی، تابع هزینه به صورت زیر انتخاب می‌شود [۲۳]:

$$J_g = \frac{1}{2} \sum_{i=1}^L (t_i - O_i^M)^2, \quad (16)$$

که در آن،  $M$  نشانگر لایه خروجی،  $L$  بیانگر تعداد واحدهای لایه خروجی،  $t_i$  سیگنال آموزش متناظر با خروجی  $i$ ام و  $O_i^M$  خروجی  $i$ ام شبکه است. بر اساس الگوریتم گرادیان نزولی، برای آنکه تغییرات وزن ارتباطی  $w_{ij}^{M-1,M}$ ، وزن‌های لایه خروجی  $M$ ، در جهت کاهش تابع هزینه  $J_g$  باشد، باید:

$$\Delta w_{ij}^{M-1,M} = -\eta_1 \frac{\partial J_g}{\partial w_{ij}^{M-1,M}} = -\eta_1 \frac{\partial J_g}{\partial O_j^M} \cdot \frac{\partial O_j^M}{\partial i_j^M} \cdot \frac{\partial i_j^M}{\partial w_{ij}^{M-1,M}} = \eta_1 \delta_j^M O_i^{M-1}, \quad (17)$$

$$i_j^M = \sum_i w_{ij}^{M-1,M} o_i^{M-1}, \quad (18)$$

که در آن،  $\eta_1$  یک اسکالر مثبت کوچک (بین صفر تا یک) است و نرخ آموزش خوانده می‌شود. ضمناً:

$$\delta_j^M = -\frac{\partial J_g}{\partial O_j^M} \cdot \frac{\partial O_j^M}{\partial i_j^M} = (t_j - O_j^M) f'(i_j^M), \quad (19)$$

که در آن،  $f'(\cdot)$  برابر با  $\frac{\partial f(i_j^M)}{\partial i_j^M}$ ، و  $i_j^M$  ورودی نرون  $j$  در

لایه خروجی  $M$  است. همچنین، تغییرات وزن‌های ارتباطی  $w_{ij}^{k-1,k}$  بین لایه  $k$  و لایه  $k+1$ ، به همین ترتیب به دست می‌آید:

$$\Delta w_{ij}^{k-1,k} = \eta_1 \delta_j^k o_i^{k-1}, \quad (20)$$

$$\delta_j^k = f'(i_j^k) \sum_i \delta_i^{k+1} w_{ji}^{k,k+1}. \quad (21)$$

بنابراین، تغییرات وزن‌های لایه میانی در هر گام زمانی به صورت زیر به دست می‌آید:

$$\sigma_i^k = -\frac{\partial J_g}{\partial o_i^k}, \quad (29)$$

خواهیم داشت:

$$\begin{aligned} \frac{\partial J_g}{\partial o_i^k} &= \sum_l \frac{\partial J_g}{\partial o_l^{k+1}} \frac{\partial o_l^{k+1}}{\partial o_i^k} = \\ &= -\sum_l \sigma_l^{k+1} \frac{\partial o_l^{k+1}}{\partial o_i^k} = -\sum_l \sigma_l^{k+1} f'(i_l^{k+1}, a_l^{k+1}) w_{i,l}^{k,k+1} \end{aligned} \quad (30)$$

$$\sigma_i^k = \sum_l \sigma_l^{k+1} f'(i_l^{k+1}, a_l^{k+1}) w_{i,l}^{k,k+1}. \quad (31)$$

بنابراین، معادلات بروز کردن  $\alpha$  در لایه خروجی و میانی را می‌توان به ترتیب به صورت معادلات (۳۲) و (۳۳) جمع‌بندی کرد.

$$a_i^M(t+1) = a_i^M(t) + \eta_2 \sigma_i^M f^*(i_i^M, a_i^M) + \alpha_2 \Delta a_i^M(t) \quad (32)$$

$$a_i^k(t+1) = a_i^k(t) + \eta_2 \sigma_i^k f^*(i_i^k, a_i^k) + \alpha_2 \Delta a_i^k(t). \quad (33)$$

### ۵- نتایج شبیه‌سازی‌ها

در ساختارهای کنترلی عصبی متداول، تابع هزینه‌ای که شبکه در جهت کاهش آن حرکت می‌کند، از اختلاف خروجی مطلوب و خروجی واقعی به‌دست می‌آید. اما در روشی که در این مقاله مورد استفاده قرار می‌گیرد، تابع هزینه برابر با خروجی کنترلر فیدبک است. به عبارت دیگر کنترلر عصبی با یادگیری دینامیک معکوس سیستم تحت کنترل، به تدریج خطا و به تبع آن خروجی کنترلر فیدبک را به سمت صفر میل می‌دهد. روش FEL توسط کاواتو و همکارانش [۱۹-۲۰] برای کنترل یک بازوی مکانیکی ماهر ارائه شد. از مهم‌ترین مزایای این روش، عدم نیاز به محاسبه ژاکوبین سیستم تحت کنترل است. ساختار کنترلی مورد استفاده در شکل ۹ نشان داده شده است.

$$w_{ij}^{k-1,k}(t+1) = w_{ij}^{k-1,k}(t) + \eta_1 \delta_j^k o_i^{k-1} + \alpha_1 \Delta w_{ij}^{k-1,k}(t). \quad (22)$$

برای وزن‌های لایه خروجی روابط به صورت زیر می‌باشد:

$$w_{ij}^{M-1,M}(t+1) = w_{ij}^{M-1,M}(t) + \eta_1 \delta_j^M o_i^{M-1} + \alpha_1 \Delta w_{ij}^{M-1,M}(t). \quad (23)$$

در روابط فوق، ترم  $\alpha$  مومنتوم نام دارد و باید به طور مناسب بین صفر و یک انتخاب شود.

### ۴-۱-۲- آموزش پارامترهای تابع سیگموئید

در تنظیم پارامتر تابع تعریف شده با معادله (۱۲) نیز هدف مینیمم کردن تابع هزینه  $J_g$  است. در اینجا نیز در حالت کلی برای اینکه تغییرات  $a_i^k$  در جهت کاهش  $J_g$  باشد، باید:

$$\Delta a_i^k = -\eta_2 \frac{\partial J_g}{\partial a_i^k}, \quad (24)$$

که در آن،  $\eta_2$  نرخ آموزشی است و به‌صورت یک عدد مثبت کوچک در نظر گرفته می‌شود. با بسط معادله (۲۴) با استفاده از قانون زنجیره‌ای برای لایه خروجی  $M$ ، به رابطه زیر می‌رسیم:

$$\frac{\partial J_g}{\partial a_i^M} = \frac{\partial J_g}{\partial O_i^M} \cdot \frac{\partial O_i^M}{\partial a_i^M}. \quad (25)$$

اگر  $\sigma_i^M$  را به‌صورت زیر تعریف کنیم:

$$\sigma_i^M = -\frac{\partial J_g}{\partial o_i^M}, \quad (26)$$

خواهیم داشت:

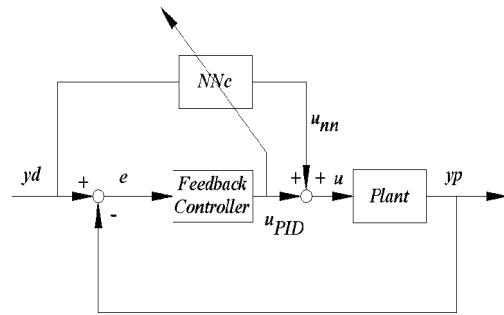
$$\sigma_i^M = (d_i - o_i^M), \quad (27)$$

و برای لایه میانی داریم:

$$\frac{\partial J_g}{\partial a_i^k} = \frac{\partial J_g}{\partial o_i^k} \frac{\partial o_i^k}{\partial a_i^k} = \frac{\partial J_g}{\partial o_i^k} f^*(i_i^k, a_i^k). \quad (28)$$

بنابراین، با تعریف  $\sigma_i^k$  به صورت زیر:


به منظور بررسی عملکرد کنترلر شبکه عصبی با ساختار ثابت (توابع سیگموئید ثابت) و شبکه عصبی انعطاف پذیر، ابتدا نتایج تحلیل شبکه عصبی با ساختار ثابت را ارائه می کنیم. این نتایج در شکل ۱۱ نشان داده شده اند. این شبکه از توابع سیگموئید معمولی به عنوان توابع محرک لایه میانی استفاده می نماید و تابع محرک لایه خروجی از نوع خطی است.



شکل (۹): ساختار کنترلی FEL.


شبکه کنترلر از سه لایه تشکیل شده است. در لایه میانی سه نرون با تابع سیگموئید انعطاف پذیر و یک نرون خطی در لایه خروجی در نظر گرفته شده است. کلیه وزن های شبکه به صورت تصادفی، بین صفر و ۱، انتخاب شده اند. مقدار اولیه پارامتر  $a$  نیز برابر ۱ در نظر گرفته شده است.

عملکرد کنترلر عصبی با یک کنترلر PI که ضرایب آن با روش زیگلر و نیکولز به دست آمده است، مورد مقایسه قرار می گیرد. شکل ۱۰ پاسخ کنترلر PI به ورودی سینوسی با دامنه ۵ rad/sec و فرکانس های مختلف در فاصله ۶-۱ rad/sec را نشان می دهد. ضرایب کنترلر برای فرکانس ۱ rad/sec تنظیم شده اند. همان گونه که مشاهده می شود، با دور شدن از فرکانس تنظیم ضرایب، عملکرد کنترلر ضعیف تر می شود.




شکل (۱۱): پاسخ کنترلر عصبی ساختار ثابت.

شکل ۱۲ سیگنال کنترلی شبکه عصبی و کنترلر فیدبک را نشان می دهد. واضح است که پس از مدت کمی خروجی کنترلر فیدبک به سمت صفر میل می کند؛ چرا که شبکه، دینامیک معکوس سیستم را فرا گرفته است. این مطلب را با توجه به شکل ۱۳ که همگرایی تعدادی از وزن های شبکه را نشان می دهد، می توان دریافت.



شکل (۱۲): سیگنال کنترلی به سیستم.



شکل (۱۰): پاسخ کنترلر PI به ورودی سینوسی.



به منظور مقایسه نتایج کنترلرهای مورد بحث انتگرال خطای مطلق<sup>۱</sup> برای هر کدام از آنها در جدول ۱ ارائه شده است.


جدول (۱): انتگرال خطای مطلق.

Frequency (rad/sec)	Integral of Absolute Errors [rad/sec]		
	Flexible FEL	Fixed Structure FEL	PI
1	0.39	0.40	1.507
2	0.59	0.61	2.854
3	0.71	0.82	4.173
4	0.82	1.08	5.37
5	1.23	1.37	6.378
6	1.44	1.66	7.317

مشاهده می شود که در فرکانس های پایین، عملکرد کنترلر عصبی با ساختار ثابت نزدیک به کنترلر عصبی با ساختار انعطاف پذیر است، اما با افزایش فرکانس، عملکرد کنترلر عصبی با ساختار انعطاف پذیر بهتر می شود.


### ۶- نتیجه گیری

در این مقاله، شبکه های عصبی با ساختار ثابت و انعطاف پذیر و روش *FEL* برای کنترل سیستم های سرویدرولیک مورد بررسی قرار گرفته است. ساختار *FEL* از یک شبکه کنترلر به همراه یک کنترلر فیدبک کلاسیک تشکیل شده است. از مزایای این روش عدم نیاز به محاسبه ژاکوبین سیستم تحت کنترل می باشد. نتایج شبیه سازی کنترلر عصبی با ساختار ثابت و انعطاف پذیر و کلاسیک از نوع *PI* بر روی این مدل ارائه شده که حاکی از عملکرد رضایت بخش کنترلر عصبی در شناسایی و کنترل سیستم سرویدرولیک به صورت همزمان می باشد.



شکل (۱۳): تغییرات وزن های شبکه.

بدین ترتیب، روش *FEL* با توابع سیگموئید ثابت - که آن را *Fixed FEL* می نامیم - به خوبی ورودی مرجع را تعقیب می کند. شکل ۱۴ پاسخ کنترلر عصبی با ساختار انعطاف پذیر را به همین ورودی ها نشان می دهد. همان گونه که مشاهده می شود کنترلر عصبی با تغییر فرکانس ورودی، خود را با آن تطبیق می دهد و شاهد بهبود عملکرد کنترلر نسبت به روش قبلی هستیم.



شکل (۱۴): پاسخ کنترلر *FEL* انعطاف پذیر.

این امر ناشی از انعطاف پذیری بالای شبکه با ساختار مورد بررسی می باشد.

1-Integral of Absolute Errors

9. Niksefat, N., Wu, C.Q., and Sepehri, N. "Design of a Lyapunov Controller for an Electro-hydraulic Actuator During Contact Tasks", ASME J. Dynamic Systems, Measurement, and Control, Vol. 123, pp. 299-307, 2001.
10. Abbot, R.D., Mclain, T.W., and Beard, R.W., "Application of Optimal Synthesis Strategy to an Electro-hydraulic Positioning System", ASME J. Dynamic Systems, Measurement, and Control, Vol. 123, No. 2, pp. 377-384, 2001.
11. Eryilmaz, B. and Wilson, B.H. "Improved Tracking Control of Hydraulic Systems", ASME J. Dynamic Systems, Measurement, and Control, Vol. 123, No. 4, pp. 457-462, 2001.
12. Ziaei, K. and Sepehri, N. "Design of a Non-linear Adaptive Controller for an Electrohydraulic Actuator", ASME J. Dynamic Systems, Measurement, and Control, Vol. 123, No. 2, pp. 449-456, 2001.
13. Anyi, H., Yiming, R., Zhongfu, Z., and Jianjun, H. "Identification and Adaptive Control for Electro-hydraulic Servo-system, Using Neural Networks", IEEE Int. Conf. on Intelligent Processing System, Beijing, China, pp. 688-692, 1997.
14. Knohl, T. and Unbehauen, H. "Adaptive Position Control of Electrohydraulic Servo-system, Using ANN", J. Mechatronics, Elsevier Science Ltd, Vol. 10, No. 3, pp. 127-143, 2000.
15. Yang, P., Xu, J., He, J., Liang, L., and Li, G. "Hybrid Control Based on Improved Radial Basis Function Network for Electro-hydraulic Servo-system", The First Int. Conf. on Innovative Computing, Information and Control, Vol. 1, No. 1, pp.117-120, Beijing, China, 2006
16. Qian, W., Burton, R., and Schoenau, G. "Model Based Evaluation of Neural Net Control of an Inertial System with Non-linear Friction", The 48th National Conf. on Fluid Power, Milwaukee, pp. 541-545, 2000.
17. Hong, Z., Kaifang, D., and Tingqi, L. "An Online-Trained Neural Network Controller for Electro-hydraulic Servo System", The 4th World Congress on Intelligent Control and Automation, Shanghai, China, pp. 2983-2986, 2002.
18. Zhiming, J., Shengwei, W., and Tingqi, L. "Variable Structure Control of Electrohydraulic Servo-system, Using Fuzzy CMAC Neural

## تشکر و قدردانی

این تحقیق با حمایت مالی معاونت پژوهشی دانشگاه صنعتی خواجه نصیرالدین طوسی به انجام رسیده که بدینوسیله از مساعدت‌های مسئولان آن معاونت سپاسگزاری می‌شود.

## مراجع

1. Merritt, H.E. "Hydraulic Control Systems", John Wiley & Sons, New York, 1967.
2. Kim, D.H. and Tsao, T.C "A Linearized Electrohydraulic Servo Valve Model for Valve Dynamic Sensitivity and Control System Design", ASME J. Dynamic Systems, Measurement, and Control, Vol. 122, No. 1, pp. 179-187, 2000.
3. Eryilmaz, B. and Wilson, B.H. "Combining Leakage and Orifice Flows in a Hydraulic Servo-valve Model", ASME J. Dynamic Systems, Measurement, and Control, Vol. 122, No. 2, pp. 576-579, 2000.
4. Li, P.Y. "Dynamic Redesign of a Flow Control Servo-valve, Using a Pressure Control Pilot", ASME J. Dynamic Systems, Measurement, and Control, Vol. 124, No. 2, pp. 428-434, 2002.
5. Fitzsimons, P.M. and Palazzolo, J.J. "Part II: Control of a One-Degree-of-Freedom Active Hydraulic Mount", ASME J. Dynamic Systems, Measurement, and Control, Vol. 118, No. 13, pp. 443-448, 1996.
6. Bobrow, J.E. and Lum, K. "Adaptive, High Bandwidth Control of a Hydraulic Actuator", ASME J. Dynamic Systems, Measurement, and Control, Vol. 118, No. 3, pp. 714-720, 1996.
7. Liu, R, and Alleyne, A. "Non-linear Force/Pressure Tracking of an Electro-Hydraulic Actuator", ASME J. Dynamic Systems, Measurement, and Control, Vol. 122, No. 1, pp. 232-237, 2000.
8. Hayase, T., Hayashi, S., Kojima, K., and Iimura, I. "Suppression of Micro Stick-Slip Vibration in Hydraulic Servo-system", ASME J. Dynamic Systems, Measurement, and Control, Vol. 122, No. 24, pp. 249-256, 2000.

- Network”, Transactions of the Institute of Measurement and Control, Vol. 25, No. 3, pp. 185-201, 2003.
19. Teshnelab, M. and Watanabe, K. “Intelligent Control Based on Flexible Neural Networks”, Kluwer Academic Publishers, Dordrecht, Netherlands, 1999.
  20. Kawato, M., Uno, Y., Isobe, M., and Suzuki, R. “Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics”, IEEE Control System Magazine, Vol. 8, No 2, pp. 8-16, 1988.
  21. Kawato, M., Furukawa, K., and Suzuki, R. “A Hierarchical Neural Network Model for Control and Learning of Voluntary Movement”, Biological Cybernetics, Vol. 57, No. 1, pp. 169-185, 1987.
  22. Watton, J. “Fluid Power Systems: Modeling, Simulation, Analog and Microcomputer Control”, Prentice Hall, New York, 1989.
  23. NG, G.W. “Application of Neural Networks to Adaptive Control of Non-linear Systems”, John Wiley & Sons, New York, 1997.