

طراحی و شبیه‌سازی مدل پیش‌بین مکان عمودی پلازما در توکامک دماوند با استفاده از شبکه‌های مختلف عصبی

رسولی، حسین*؛ فاتحی، علیرضا^۲

^۱ پژوهشکده فیزیک پلازما و گداخت هسته‌ای، پژوهشگاه علوم و فنون هسته‌ای؛ ^۲ دانشگاه صنعتی خواجه نصیرالدین طوسی

چکیده

اندازه‌گیری سریع و دقیق مکان پلاسمای چنبره توکامک به منظور طراحی سیستم کنترل مکان و شکل پلازما در مدت زمان تخلیه از مباحث مهم و اساسی در توکامک محسوب می‌شود. بنابراین پیش‌بینی و تخمین مکان پلازما امکان طراحی کنترل کننده دقیق و تغییر ضرایب آن را قبل از ناپایداریهای پلازما در مدت تخلیه فراهم می‌آورد. در این تحقیق سعی شده است تا با استفاده از شبکه‌های مختلف عصبی مدل مناسبی برای پیش‌بینی عملکرد جابجایی عمودی مکان پلازما در توکامک دماوند ارائه شود. بر این اساس ساختار کلی جهت ارائه مدل پیش‌بین در حالت بدون کنترل و همچنین حالت کنترلی بررسی شده است و مدل‌های پیش‌بین با استفاده از شبکه‌های عصبی *RBF*، *MLP* و تخمین‌های *RLS* و *Kalman Filter* شبیه‌سازی گردیده‌اند و مدل‌های بهینه شده از لحاظ خطای ماکزیمم و درصد خطای *RMS* در فرکانسهای مختلف مقایسه شده‌اند. به منظور یادگیری مناسب دینامیک حرکت عمودی، آموزش شبکه از طریق داده‌های چندین تخلیه الکتریکی انجام پذیرفت. لذا نتایج سازگاری بسیار مناسبی را میان مدل پیش‌بین و مقادیر اندازه‌گیری شده برای مکان پلاسمای محصور شده نشان می‌دهند.

کلمات کلیدی: توکامک، کنترل مکان پلازما، مدل پیش‌بین، شبکه‌های عصبی.

مقدمه

در چند سال اخیر شبکه‌های عصبی (Neural Network) با داشتن ساختار غیرخطی و همچنین قابلیت یادگیری، مسیر جدیدی را برای بدست آوردن کنترل بهینه حلقه بسته در مسائل کلی و غیرخطی مطرح نموده‌اند [۱]. سیستم‌های مذکور همچنین ابزار مناسبی برای تخمین پارامترهای مسائل غیرخطی و پیچیده محسوب گردیده و از اینرو می‌توانند مشخصات و ویژگیهای سیستم را بدلیل دارا بودن قابلیت یادگیری آماری و غیر فیزیکی، بطور سریع ارائه نمایند. بر اساس این خصوصیات مفید، شبکه عصبی به عنوان ابزاری مهم برای شناسایی و تخمین مکان و شکل پلازما در توکامک‌های پیشرفته مطرح می‌گردد. استفاده از شبکه عصبی اولین بار توسط Lister به جهت شناسایی و پیش‌بینی پارامترهای پلازما در توکامک DIII-D مطرح شده [۲] و در ادامه بطور موفقیت آمیز برای کنترل مکان پلازما در توکامک COMPASD-D نمود عملی به خود گرفت [۳]. در سالهای اخیر نیز برای شناسایی و پیش‌بینی مکان و شکل پلازما در توکامک‌های ITER، JT-60، ASDEX-U و KSTAR بررسی و مطالعه شده است [۲].

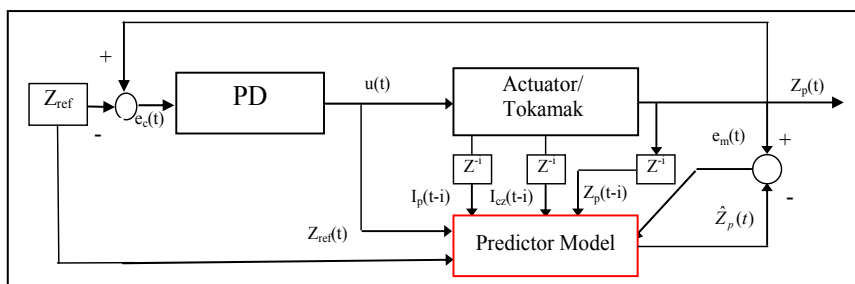
در توکامک دماوند نیز با تغییر و بهینه‌سازی مدارات کنترلی و تشکیل پایگاه داده، امکان بررسی و مطالعه برای شناسایی و پیش‌بینی مکان و شکل پلازما که در نهایت منجر به طراحی کنترل کننده هوشمند می‌گردد،

فراهم شده است. در این مقاله برای نخستین بار پیش‌بینی مکان عمودی پلاسما در توکامک دماوند با استفاده از شبکه‌های عصبی بررسی می‌گردد. در بخش اول آن کنترل جابجایی عمودی و ساختار مدل پیش‌بین بررسی می‌شود. بخش دوم آن ساختارهای شبکه‌های مورد استفاده را شامل بوده و در بخش سوم عملکرد مدل‌های بهینه شده در مقایسه با داده‌های عملی بررسی می‌شود و در بخش آخر نتایج تحقیق ارائه می‌گردد.

سیستم کنترل جابجایی عمودی پلاسما در توکامک دماوند و ساختار کلی مدل پیش‌بین

سیستم کنترل جابجایی عمودی مکان پلاسما در توکامک دماوند سیستم حلقه بسته‌ای است که شامل اندازه‌گیر مکان با کمک حلقه‌های زینی (Saddle Loop)، راه‌انداز جریان کنترل شده و کنترل کننده آنالوگ PD می‌باشد. در این خصوص می‌توان به پارامترهای اصلی توکامک دماوند از جمله شعاع اصلی چنبره $R=36\text{cm}$ ، شعاع فرعی $a=7\text{cm}$ ، ارتفاع عمودی $Z=12\text{cm}$ ، پلاسمایی 35kA در مدت زمان 21ms اشاره کرد.

در شکل ۱ سیستم حلقه بسته کنترل جابجایی عمودی پلاسما به همراه ساختار کلی مدل پیش‌بین نشان داده شده است. که در آن Z_p مکان عمودی پلاسما، Z_{ref} مرجع مکان عمودی، I_p جریان پلاسما، I_{cz} جریان کنترل شده در پیچ‌های قطبی، $e_c=Z_{ref}-Z_p$ خطای کنترل کننده و u سیگنال کنترلی توکامک دماوند را معرفی می‌کنند. سیگنال‌های مذکور، بعنوان داده‌های عملی سیستم برای مدل‌سازی محسوب می‌شوند. بلوک Z^{-1} تاخیر زمانی نام سیگنال مورد استفاده در مدل بوده که i از مقدار خطا و همبستگی داده‌ها انتخاب می‌گردد. برای طراحی و آموزش مدل پیش‌بین، از سیگنال e_m بعنوان خطای مدل با تابع $E_m(t) = .5(Z_p(t) - \hat{Z}_p(t))^2$ استفاده



می‌شود که در آن \hat{Z}_p خروجی مدل است.

$$\hat{Z}_p = \sum_{i=0}^M \theta_i \phi_i(x, \alpha_i) \quad (1)$$

$$\phi_i(0,0)=1$$

$$\phi_i(0, \alpha_i) = \phi(0, \alpha_i) \quad (2)$$

شکل ۱: بلوک دیاگرام کنترل مکان عمودی پلاسما در توکامک دماوند و

ساختار کلی مدل پیش‌بین

خروجی مکان عمودی پلاسما را می‌توان بصورت رابطه ۱، تابعی از ورودیهای سیستم فرض کرد که در آن \underline{x} ماتریس ورودیها، ϕ_i توابع پایه غیرخطی (M تعداد آن)، پارامترهای غیرخطی، θ_i پارامترهای خطی، می‌باشند. به دلیل ویژگی غیرخطی بودن α_i ناگزیر به استفاده از روشهای غیرخطی یادگیری هستیم و برای انتخاب این روشها ϕ_i و M پارامترهایی می‌باشند که نقش مهمی در تعیین ساختار ایفا می‌کنند. در حالت کلی انتخابهای زیادی برای ϕ_i وجود دارد و برای حجم محاسبات کمتر و ساده‌تر ϕ_i ها را یکسان انتخاب می‌کنیم (رابطه ۲). علی‌رغم این کار هنوز ساختاری داریم که به اندازه کافی برای تخمین هر تابعی عمومیت

دارد. با انتخابهای مختلف ϕ_i به شبکه‌های عصبی متفاوت و شبکه‌های نرو-فازی مختلف خواهیم رسید. مهمترین دلیل استفاده از شبکه‌های عصبی در کنترل پیش‌بین، استفاده از آن به عنوان ابزار مدل‌سازی پروسه پیش‌بینی خروجی آینده می‌باشد. علاوه بر آن دارای خواصی چون امکان پیاده‌سازی موازی نیز می‌باشد که باعث کاهش بار محاسباتی و پیچیدگی سیستم می‌شود. یکی از اشکالات و نواقص این روشها گیرکردن فرآیند آموزش در کمینه‌های محلی و زیاد بودن خطای ماکزیمم می‌باشد و این مسئله در کنترل توکامک بسیار پرخطر می‌نماید [۵]. برای جلوگیری از اشکالات مذکور، شبکه‌های عصبی پرسپترون چند لایه (MLP) به دلیل پارامترهای گسترده آن (تعداد لایه‌ها، گره‌ها، نرخ آموزش متغیر، ثابت ممتنم، محدوده وزنه‌های اولیه و توابع آن) و شبکه‌های (Radial Basis Function) RBF بدلیل کاهش اثر نویز مفید واقع می‌گردند. ذکر این نکته ضروری است که پارامترهای یاد شده باید با دقت فراوان به طور مناسب انتخاب گردند [۵]. بنابراین کل مسئله به تعیین مناسب ϕ ، α_i و M و همچنین بهینه‌سازی آنها مرتبط می‌شود. در ادامه برای تعیین این پارامترها به دلایل مذکور از شبکه‌های چند لایه MLP (با روشهای آموزشی مختلف (Marquardt (LM), Levenberg, Conjugate Gradient Powell BP (CGB), RProp (RP), شبکه‌های RBF، مدل‌های خطی با روش حداقل مربعات خطا (RLS) و همچنین فیلتر کالمن پیش‌بین استفاده کردیم.

شبکه‌ها و روشهای مورد استفاده

۱- شبکه عصبی MLP: مطابق روابط ۳ و ۴ روش پس انتشار خطا (BP) برای آموزش وزنها (W_{ji}) و بایاسها (b_j) بکار برده شده و در آن μ ممتنم، η نرخ یادگیری، E_m تابع خطای خروجی مدل و τ مربوط به مرحله تکرار آموزش می‌باشد و همچنین تابع فعالیت در این ساختار مطابق رابطه ۵ است [۴].

$$\Delta W_{ji}^{\tau} = -\eta_{ji} \left(\frac{\partial E_m}{\partial W_{ji}} \right) + \mu \Delta W_{ji}^{\tau-1} \quad (3) \quad \Delta b_j^{\tau} = -\eta_j \left(\frac{\partial E_m}{\partial b_j} \right) + \mu \Delta b_j^{\tau-1} \quad (4) \quad f(\theta) = \frac{1}{1 + e^{-a\theta}} \quad (5)$$

۲- شبکه عصبی RBF: توابع گوسی مورد استفاده در این شبکه مطابق رابطه ۶ می‌باشند در آن V مرکز تابع گوسی و δ ضریب پهن‌شدگی آن تابع می‌باشد و آموزش پارامترها مطابق با روابط ۷ و ۸ بیان می‌گردد [۴].

$$f_m(\theta) = \exp\left(-\frac{\|\theta - V_m\|^2}{2\delta_m^2}\right) \quad (6) \quad \Delta W_{ji}^{\tau} = -\eta_{ji} \left(\frac{\partial E_m}{\partial W_{ji}} \right) \quad (7) \quad \Delta \delta_j^{\tau} = -\eta_{\delta j} \left(\frac{\partial E_m}{\partial \delta_j} \right) \quad (8)$$

۳- روش حداقل مربعات خطا (RLS) با فاکتور فراموشی متغیر: در این روش خروجی به صورت $\hat{y}(t) = x(t)^T \hat{\theta}(t)$ می‌باشد و ضرایب $\hat{\theta}(t+1)$ مطابق با رابطه (۹) پیش‌بینی می‌شود. که در آن ε خطای پیش‌بینی است [۴].

$$\hat{\theta}(t+1) = \hat{\theta}(t) + P(t+1)x(t+1)\varepsilon(t+1) \quad (9)$$

$$P(t+1) = \left(P(t) - \frac{P(t)x(t+1)x(t+1)^T P(t)}{\lambda + x(t+1)^T P(t)x(t+1)} \right) \times \frac{1}{\lambda} \quad (10) \quad \varepsilon(t+1) = x(t+1)^T \hat{\theta}(t) - y(t+1) \quad (11)$$

۴- مدل پیش‌بین Kalman Filter: در این مدل نیز پارامترهای $\theta(t+1)$ با داشتن خروجیها تا لحظه t برآورد می‌شود. لذا با فرض رابطه ۱۲ به عنوان یک معادله حالت و حل آن با معادلات فیلتر کالمن، روابط بازگشتی

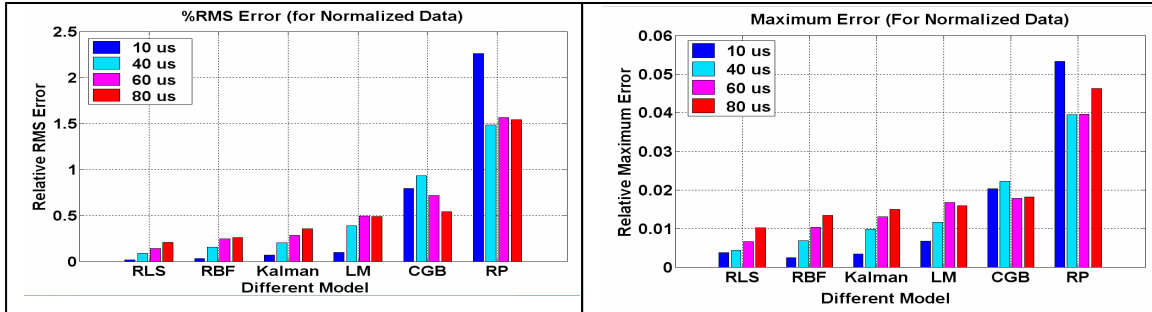
به صورت (۱۳-۱۵) بدست می‌آید [۴]. (۱۳) $\hat{\theta}(t+1) = \hat{\theta}(t) + k(t)(y(t) - x^T(t)\hat{\theta}(t))$ (۱۲) $\left\{ \begin{array}{l} \theta(t+1) = \theta(t) \\ y(t) = x^T(t)\theta(t) + n(t) \end{array} \right.$

$$k(t) = \frac{P(t)x(t)}{x^T(t)P(t)x(t) + 1} \quad (14) \quad P(t+1) = P(t) - k(t)(x^T(t)P(t)x(t) + 1)K^T(t) \quad (15)$$

نتایج مدل پیش‌بین و مقایسه آن با داده‌های عملی

به منظور بهینه‌سازی مناسب پارامترهای مدل، تمام داده‌های عملی سیستم با زمان نمونه‌برداری ۱۰ μs ذخیره شده‌اند و به دلیل وجود نویز زیاد در سیستم، فیلتر ۳kHz مناسب (فیلتر بدون تغییر فاز با قابلیت عدم حذف اطلاعات فیزیکی) به داده‌ها اعمال می‌گردد. برای آموزش و یادگیری شبکه‌ها، داده‌های آموزش (Train) شامل داده‌های چندین تخلیه الکتریکی (شات) توکامک بوده و به منظور اعتبارسنجی مدل، داده‌های تست (Test) از یک شات انتخاب می‌گردند. برای آموزش و تست مدلها، تمام داده‌های عملی مربوط به جریان پلاسما با مقدار حداکثر آن و داده‌های مربوط به جابجایی نیز با مقدار حداکثر سیگنال مکان نرمالیزه شده‌اند. در حالت بدون کنترل با توجه به ساختار مدل (شکل ۱)، ورودیهای شبکه شامل جریان پلاسما، تاخیر یافته آن و همچنین تاخیر یافته‌های مکان عمودی پلاسما است. پس از آموزش مدلها با داده‌های ورودی/خروجی توکامک، به منظور تصدیق و بررسی نحوه عملکرد مدل از سیگنالهای مجزای دیگر آن استفاده کردیم. بر اساس عملکرد آنها پارامترهای مدلها بهینه شده است و برای شبکه‌های عصبی تعداد لایه‌ها و نرونها در جدول شکل ۲ آورده شده است. جهت مقایسه عملکرد مدلهای مختلف شاخص درصد rms خطا با رابطه (۱۶) و ماکزیمم خطا معیار گرفته شده است. نمودارهای شکل ۲ از اجرای داده‌های تست نرمالیزه شده بر روی مدلها و ثبت نتایج عملکرد آنها فراهم آمده است و با توجه به آن می‌توان ویژگی مدلها را بر اساس حداکثر خطا، درصد خطای rms و فرکانس نمونه برداری مقایسه نمود. به منظور بررسی و مقایسه مدلها در فرکانسهای متفاوت، شبکه را با نمونه برداریهای زمانی مختلف آموزش دادیم و بر اساس این نوع تست با مصالحه بین عملکرد شبکه از لحاظ خطا و سرعت نمونه برداری داده‌ها می‌توان به یک انتخاب مناسبی جهت پیاده سازی سخت افزاری رسید.

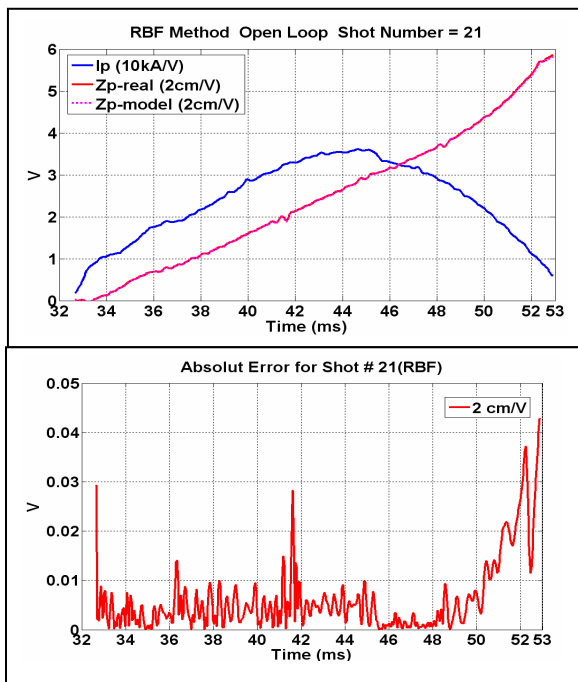
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Z}_p(i) - Z_p(i))^2} \quad (16)$$



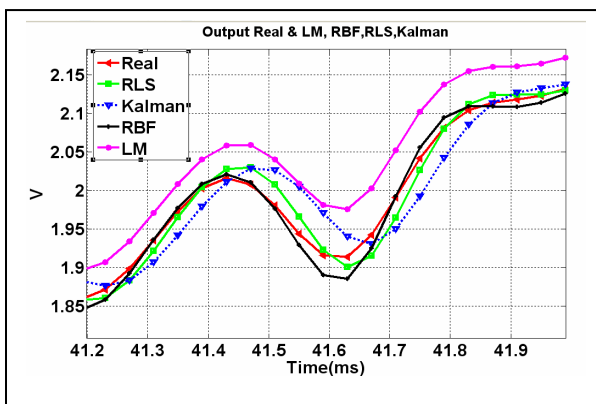
شکل ۱: درصد خطای RMS و خطای ماکزیمم شبکه‌های

مورد استفاده در نمونه برداریهای مختلف زمانی، و ساختار کلی شبکه‌ها

با توجه به شکل ۲، تخمینها سازگاری مناسبی با نتایج اندازه‌گیری شده دارند و در آن تخمین‌های روش RLS، RBF، Kalman و LM با نونه برداری ۸۰ μs تا ۴۰ μs قابل پیاده‌سازی مناسبی می‌باشد. در صورتی که داده‌های عملی با ۴۰ μs نمونه برداری شده باشند و شبکه RBF نیز بر اساس همین فرکانس آموزش ببیند با اجرای داده‌های تست در مدل درصد خطای rms برابر ۰/۹۵۴۴cm و حداکثر خطا برابر ۰/۸۵۶cm حاصل می‌شود و در شکل ۳ نیز خروجی زمانی مدل پیش‌بین و خروجی واقعی مکان پلازما



شکل ۳: خروجی واقعی و پیش‌بینی شده و خطای پیش‌بینی

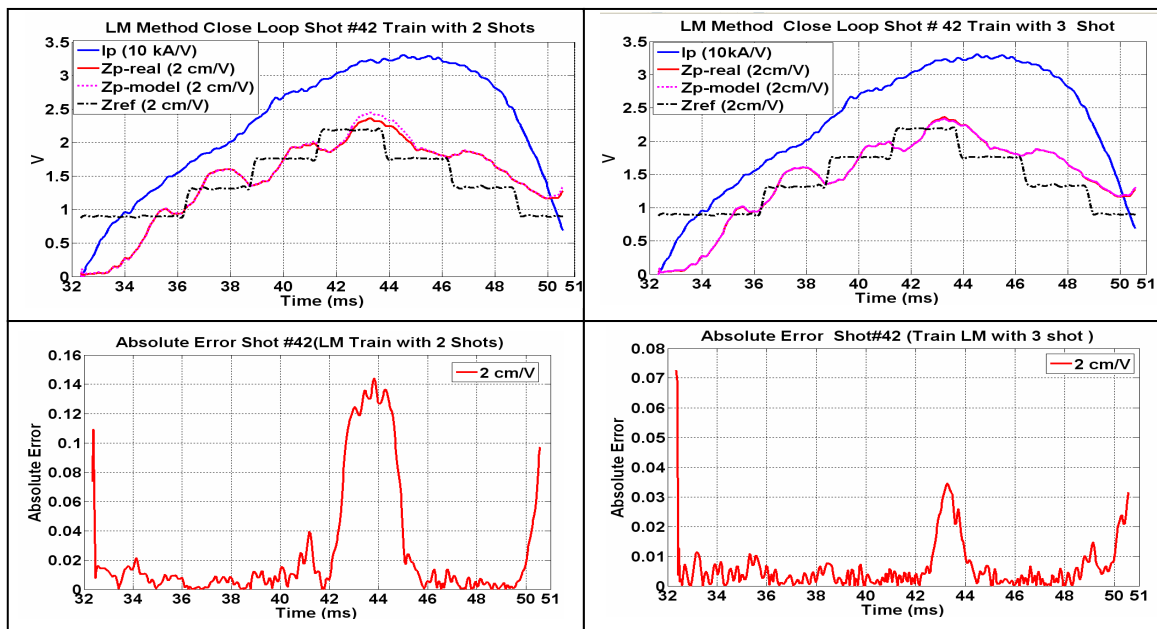


شکل ۴: خروجی واقعی و تخمین مدل در فاصله زمانی

مقایسه شده است که در آن نمودارهای پیش‌بین و مکان بر هم منطبق هستند لذا قدرمطلق خطای تخمین بر حسب زمان آورده شده است. به منظور مقایسه دقیق تطابق زمانی خروجی مدل‌های پیش‌بین با خروجی اندازه‌گیری شده سیستم در شکل ۴ قسمتی از ناهمواری جابجایی موجود در نمودار قبلی در نمایش بزرگی آورده شده است. واضح است که تخمین‌های روش LM، RBF و RLS از لحاظ زمانی کاملا

درست بوده ولی مدل مبتنی بر کالمن این تخمین را به همراه شیفت فازی انجام داده است. لذا این تخمین خطی مناسب نبوده است.

در حالت کنترل با توجه به ساختار مدل در شکل ۲، ورودیهای شبکه عبارتند از: جریان پلاسما (I_p) و تاخیر یافته آن، تاخیر یافته (Z_p) جریان کنترل کننده (I_{CZ}) و مکان مرجع (Z_{ref}). برای شناسایی و طراحی مدل کامل پیش‌بین لازم است مکان عمودی پلاسما با کنترل کننده PD و ورودیهای مختلف مرجع در سطوح مختلف کنترل شود و به کمک داده‌های آن دینامیکهای مختلف سیستم به شبکه آموزش داده شود. بنابراین لازم است با استفاده از ورودی مکان مرجع عمودی اکثر دینامیکهای حرکت پلاسما را ایجاد کنیم ولی به دلیل محدودیتهای توکامک این امکان در یک شات وجود نداشته از اینرو باید آموزش شبکه با تعداد شاتهای متنوع و بیشتری صورت گیرد. لذا براساس پایگاه داده ایجاد شده، شبکه‌ها با همان ساختار قبلی (جدول شکل ۲) مورد آموزش قرار گرفتند. در بکارگیری تخمینگرها لازم است پارامترهای طراحی به درست انتخاب گردند. بعنوان مثال مدل پیش‌بین شبکه LM، در آموزش با دو شات درصد خطای $rms = 9/36 \text{ cm}$ و حداکثر خطای $0/288 \text{ cm}$ داشت ولی در آموزش با ۳ شات درصد خطا $rms = 2/039 \text{ cm}$ و حداکثر خطا $0/1452$ حاصل شد که دلیل آن شناخت اکثر دینامیکهای سیستم با آموزش کافی از طریق شاتهای دارای مد متغییر دینامیکی بوده است. نمودار خروجی واقعی با خروجی مدل و خطای مدل در شکل ۵ نشان داده شده است.



شکل ۵: مقایسه خروجی واقعی با خروجی مدل پیش‌بین LM به همراه قدرمطلق خطای مدل در حالت کنترلی با آموزش ۲ شات و ۳ شات.

نتایج

در این تحقیق با استفاده از شبکه‌های مختلف عصبی و همچنین مدل‌های خطی مدل پیش‌بین غیرخطی برای عملکرد جابجایی عمودی مکان پلاسما در حالت بدون کنترل و همچنین حالت کنترلی ارائه گردید. بدین منظور با پردازش اولیه داده‌های عملی سیستم، مدل‌های مختلفی طراحی گردید و بر اساس آن تخمین مناسبی از مکان عمودی پلاسما حاصل گردید که خطای کمتری داشته است. در آموزش شبکه برای حلقه بسته مدهای متغیر دینامیکی در هر شات و مجموعه‌ای از آنها بکار گرفته شد. برای کنترل دقیق مکان پلاسما در توکامک لازم است پارامترهای کنترلی در طول شات بهینه شوند. یکی از کاربردهای مدل پیش‌بین مکان، ارائه کنترل کنترل کننده پیش‌بین برای این منظور است.

مراجع

- [1] K.S.Narendra and K.Parthasarathy, "Identification and Control Dynamical Systems Using Neural Networks", IEEE Trans. Neural Networks, Vol.1, pp4-24, Mar.1990.
- [2] Yong-Su Na, Young-Mu Jeon, S. H. Hong, and Y. S. Hwang, "Real-time extraction of plasma equilibrium parameters in KSTAR tokamak using statistical methods", Review of Scientific Instruments, Volume 72, Number 2, February 2001.
- [3] Christopher M. Bishopz, Paul S. Haynesy, "Real-time Control of a Tokamak Plasma Using Neural Networks", Published in Neural Computation 7, No. 1 (1995) 206-217.
- [4] Oliver Nelles, "Nonlinear System Identification", 2001.
- [5] Young-Mu Jeon, Yong-Su, Myun-Rak kim. "Newly developed double neural network concept for reliable fast plasma position control", Review of Scientific instruments, Volume 72 Number 1. July 2001.