

# طراحی کنترل کننده پیش‌بین سیستم بویلر - توربین

سید سجاد رضوی<sup>۱</sup> سید مجید اسماعیل‌زاده<sup>۲</sup>

۱- دانش‌آموخته کارشناسی ارشد- دانشکده مهندسی برق- دانشگاه علم و صنعت

[Sajad.rkz@gmail.com](mailto:Sajad.rkz@gmail.com)

۲- استادیار- دانشکده مهندسی برق- دانشگاه علم و صنعت

[smailzadeh@iust.ac.ir](mailto:smailzadeh@iust.ac.ir)

**چکیده:** در این نوشتار یک الگوریتم کنترل مدل پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی در سیستم بویلر- توربین طراحی شده است. سیستم بویلر توربین یک سیستم با رفتار پیچیده غیرخطی و دارای اندرکنش بین اجزای تشکیل دهنده خود می‌باشد که کنترل آن را با چالش‌های زیادی روبرو ساخته است. ابتدا سیستم غیرخطی مورد نظر با استفاده از شبکه‌های عصبی پرسپترون چند لایه شناسایی شده و سپس بر اساس مدل به دست آمده کنترل کننده پیش‌بین طراحی می‌گردد. استفاده از شبکه‌های عصبی به عنوان مدل پیش‌بین به علت انباشته شدن خطاهای هر مرحله‌ی پیش‌بینی، خطای ماندگار در خروجی سیستم را به دنبال خواهد داشت. برای غلبه بر این مشکل از یک جبران کننده خطا در مدل پیش‌بین شبکه‌های عصبی استفاده شده است. نتایج شبیه‌سازی سیستم حلقه بسته نشان می‌دهد که سیستم بدون خطای حالت ماندگار سیگنال مرجع را دنبال نموده و نیز اغتشاش‌های وارد شده به سیستم را دفع می‌نماید.

**کلمات کلیدی:** کنترل مدل پیش‌بین، بویلر- توربین، شبکه‌های عصبی پرسپترون چندلایه، شبکه جبران خطا

تاریخ ارسال مقاله: ۱۳۹۲/۱۲/۱

تاریخ پذیرش مشروط مقاله: ۱۳۹۴/۰۸/۰۹

تاریخ پذیرش مقاله: ۱۳۹۴/۱۱/۱

نشانی نویسنده‌ی مسئول: ایران - تهران - خیابان رسالت - خیابان حیدرخانی - دانشگاه علم و صنعت - دانشکده‌ی مهندسی برق - گروه مهندسی کنترل

کرد که در آن دو کنترل کننده PI و فیدبک حالت طراحی شده و ضرایب مناسب کنترل کننده‌ها به وسیله الگوریتم ژنتیک به دست آمده است.

کنترل مدل پیش‌بین<sup>۱</sup> (MPC) یکی از روش‌های کنترل پیشرفته فرایند است که در سال‌های اخیر در کنترل فرایندهای صنعتی کاربردهای بسیار زیادی پیدا کرده و تحقیقات بسیار گسترده‌ای در مورد آن انجام شده است. کنترل مدل پیش‌بین در واقع به محدوده وسیعی از روش‌ها اطلاق می‌شود که در آن از یک مدل صریح فرایند به منظور به دست آوردن سیگنال کنترلی به وسیله مینیمم کردن یک تابع هزینه استفاده می‌شود [۷]. در بسیاری از فرایندها رفتار غیر خطی سیستم و پیچیدگی آن بسیار شدید بوده و خطی سازی حول یک نقطه کار و استفاده از مدل خطی برای سیستم نمی‌تواند پاسخ‌گوی نیازهای کنترلی سیستم باشد. کنترل مدل پیش‌بین غیرخطی<sup>۲</sup> (NMPC) یکی از توسعه‌های کنترل پیش‌بین است که در آن از مدل غیرخطی سیستم استفاده می‌شود و در اواسط دهه ۱۹۹۰ ارائه شد [۸]. NMPC با استفاده از یک مدل صریح غیر خطی سیستم رفتار

سیستم غیرخطی را به خوبی پیش‌بینی کرده و نسبت به کنترل پیش‌بین خطی عملکرد مناسب‌تری دارد اما مشکل اصلی NMPC استفاده از آن در زمان واقعی است که ناشی از حجم محاسباتی زیاد این روش می‌باشد و باعث شده این روش در سیستم‌های با دینامیک کند استفاده شود. در روش‌های کنترلی مبتنی بر مدل، عملکرد کنترل کننده به شدت وابسته به دقت مدل استفاده شده است. در کنترل پیش‌بین نیز شناسایی مدل دقیقی از سیستم امری ضروری است. در NMPC شناسایی و مدل سازی سیستم به مراتب از اهمیت بیشتری برخوردار است. شبکه‌های عصبی یکی از مدل‌های تجربی غیر خطی بر اساس داده‌های ورودی و خروجی سیستم است و کاربردهای بسیار زیادی در تشخیص خطا، شناسایی، پیش‌بینی، شبیه‌سازی و کنترل سیستم‌های دینامیکی دارد [۹]، [۱۰]. شبکه‌های پرسپترون چند لایه<sup>۳</sup> (MLP) شناخته شده‌ترین و پرکاربردترین معماری شبکه‌های عصبی هستند [۹] یک شبکه MLP می‌تواند هر تابع غیرخطی نرمی را با دقت دلخواه تقریب زند. این دقت وابسته به تعداد نرون‌های لایه پنهان شبکه می‌باشد. این ویژگی باعث محبوبیت این ساختار در شناسایی سیستم‌های غیر خطی است. یکی از ساختارهای پرکاربرد شبکه‌های MLP در شناسایی سیستم‌های غیرخطی شبکه عصبی دینامیکی پیش-خور<sup>۴</sup> (DFNN) است [۱۲]. کنترل پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی یکی از انواع کنترل پیش‌بین غیر خطی است

سیستم بویلر- توربین یکی از مهمترین و در واقع اصلی‌ترین بخش در نیروگاه‌های حرارتی تولید برق می‌باشد. فرایند بویلر- توربین یک سیستم به هم پیوسته از بویلر و توربین بخار می‌باشد. وظیفه اولیه سیستم بویلر توربین این است که انرژی خروجی مکانیکی سیستم را با درخواست بار الکتریکی شبکه در تعادل نگاه دارد و متغیرهای دیگر سیستم مانند فشار مخزن و سطح آب موجود در مخزن را در محدوده مطلوب که مربوط به عملکرد نامی سیستم است، حفظ کند. همچنین فشار مخزن باید متناسب با نقاط کاری سیستم و درخواست بار شبکه تنظیم شود. این سیستم دارای رفتار پیچیده غیرخطی با دینامیک کند بوده و همچنین میان اجزای تشکیل دهنده آن اندرکنش وجود دارد. سیستم دارای سه ورودی و سه خروجی می‌باشد که متغیرهای ورودی از نوع موقعیت شیرکنترلی بوده و دارای محدودیت در اشباع و نیز محدودیت در نرخ تغییرات ورودی هستند [۱].

هدف کنترلی در سیستم بویلر- توربین ردیابی درخواست بار الکتریکی متغیر شبکه با حفظ توان خروجی و فشار مخزن و تنظیم سطح آب مخزن در سطح مطلوب است اما با توجه به رفتار شدید غیرخطی سیستم و نیز گستره عملکردی وسیع آن، دستیابی به اهداف کنترلی مذکور با چالش‌های بسیاری مواجه است. در مرجع [۲] به منظور تحلیل دینامیک سیستم از یک روش اندازه‌گیری فاصله استفاده شده و فاصله بین سیستم خطی و غیر خطی در حالت‌های توان ثابت و فشار ثابت مشخص شده است نقطه کاری مناسب سیستم برای طراحی کنترل کننده خطی بر اساس روش شکل‌دهی حلقه در  $\infty H$  مشخص شده است. مرجع [۳] یک کنترل کننده چند منظوره را با توجه به محدودیت ورودی‌ها پیشنهاد کرده است. در این تحقیق سیستم غیرخطی توسط یک سیستم متغیر پارامتری مدل شده، که در آن فشار مخزن بخار پارامتر متغیر سیستم است و به صورت یک پارامتر عدم قطعیت در معادلات لحاظ شده است. در [۴] نیز یک استراتژی مدل بهینه چندگانه برای طراحی کنترل کننده پیشنهاد شده و تعداد بهینه توابع محلی به دست می‌آید. در [۵] از یک کنترل کننده منطبق فازی خودسازمانده استفاده شده است. قانون کنترل و توابع عضویت در این کنترل کننده بدون استفاده از مدل فرایند و به صورت خودکار به دست می‌آیند و کنترل کننده در برابر تغییر پارامترها مقاوم می‌باشد. از نمونه‌های دیگر طراحی کنترل کننده خطی می‌توان به [۶] اشاره

که دارای محبوبیت بسیاری می‌باشد [۱۵-۱۳]. توانایی شبکه‌های عصبی در شناسایی سیستم‌های غیرخطی و نیز کاهش بار محاسباتی بهینه‌سازی غیرخطی به واسطه استفاده از آن‌ها، از عوامل این محبوبیت می‌باشد.

کنترل پیش‌بین نیز یکی از استراتژی‌های کنترلی در سیستم بویلر-توربین می‌باشد که به دلیل ویژگی‌های آن و نیز مشخصات سیستم بویلر توربین مانند تاخیر، محدودیت در متغیرهای ورودی و نیز برهم‌کنش متغیرها بسیار مورد توجه قرار گرفته است. برای نمونه می‌توان به [۱۶] اشاره کرد که در آن ابتدا یک مدل فازی از سیستم به منظور توضیح رفتار غیرخطی سیستم به دست آمده و سپس توسط الگوریتم ژنتیک مسئله کنترل پیش-بین مربوطه حل شده است. همچنین به منظور استفاده از افق زمانی کوتاه برای کاهش بار محاسباتی از یک هزینه نهایی در تابع هزینه استفاده شده است. مرجع [۱۷] از یک مدل‌سازی داده‌محور استفاده کرده و کنترل کننده پیش‌بین بر اساس شناسایی چندمدله طراحی شده است. در [۱۸] مدل‌سازی تکه-ای گسسته زمان با استفاده از نقاط کار سیستم پیشنهاد شده و از کنترل پیش‌بین صریح برای طراحی کنترل کننده استفاده شده است. در [۱۹] پاسخ پله سیستم برای استفاده در روش کنترل ماتریس پویا<sup>۵</sup> (DMC) توسط دو روش به دست آمده و با هم مقایسه شده‌اند. روش اول خطی‌سازی حول نقطه کار و به دست آوردن پاسخ پله و روش دوم استفاده از داده‌های پاسخ پله سیستم غیرخطی که در آن برتری روش دوم به اثبات رسیده است.

در این نوشتار یک کنترل کننده پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی برای سیستم بویلر توربین طراحی شده است. با استفاده از کنترل پیش‌بین می‌توان محدودیت‌های موجود در متغیرهای سیستم‌هایی نظیر بویلر-توربین را به صورت سیستماتیک مد نظر قرار داد اما استفاده از این روش مستلزم وجود یک مدل دقیق از فرایند می‌باشد. در کنترل کننده پیشنهادی از مدل شبکه‌های عصبی MLP استفاده شده که می‌تواند رفتار شدید غیرخطی سیستم مذکور را به خوبی شناسایی کند. به منظور شناسایی هرچه بهتر فرایند از یک سیگنال تحریک شبه تصادفی با سه ثابت زمانی مختلف استفاده شده است. همچنین استفاده از این مدل می‌تواند مشکل افزایش شدید بار محاسباتی ناشی از بهینه‌سازی برخط را به صورت قابل ملاحظه‌ای کاهش دهد. با این حال استفاده از مدل شبکه‌ای عصبی در کنترل پیش‌بین موجب انباشتگی خطای پیش‌بینی و در نتیجه بروز خطا در پاسخ حالت ماندگار می‌شود که برای غلبه

بر این مشکل از یک مدل اغتشاش یا جبران‌ساز خطا استفاده شده است.

این مقاله در پنج بخش ارائه گردیده است. در بخش دوم به معرفی سیستم بویلر-توربین پرداخته شده و ویژگی‌های این فرایند بررسی شده است. در بخش سوم مراحل مختلف شناسایی سیستم غیرخطی موردنظر مبتنی بر شبکه‌های عصبی بررسی شده و در بخش چهارم کنترل کننده پیش‌بین عصبی طراحی شده و بخش‌های مختلف کنترل کننده مورد بررسی قرار می‌گیرد. بخش پنجم شامل شبیه‌سازی سیستم حلقه‌بسته و تفسیر نتایج به دست آمده می‌باشد.

## ۲- سیستم بویلر - توربین

به طور کلی نحوه ارتباط بویلر و توربین در نیروگاه‌های حرارتی می‌تواند به دو صورت زیر باشد [۲]

- بخار تولید شده توسط چند بویلر در یک جا جمع شده و سپس بین توربین‌های مختلف توزیع می‌شود. ظرفیت بویلرهای استفاده شده در این ساختار معمولاً پایین است

- هر بویلر وظیفه تولید بخار برای یک توربین را دارا می‌باشد. به عبارت دیگر تمام توربین‌ها دارای بویلر جداگانه-ای می‌باشند. این ساختار معمولاً با نام واحد بویلر-توربین شناخته می‌شود که در آن بویلرها دارای ظرفیت بیشتری نسبت به ساختار اول هستند.

به طور کلی ساختار استفاده شده در اغلب نیروگاه‌های تولید برق ساختار دوم می‌باشد زیرا ظرفیت بویلرها در این ساختار بالاتر بوده و همچنین کنترل ساختار ذکر شده به علت وجود یک بویلر برای هر توربین ساده‌تر می‌باشد [۲]. در این نوشتار ساختار دوم مدنظر می‌باشد. شکل (۱) نمای شماتیک سیستم بویلر-توربین را نشان می‌دهد.

### ۱-۲- معادلات سیستم

معادلات سیستم بویلر-توربین مورد مطالعه از مدل به دست آمده در [۱] گرفته شده که توسط Bell و Asrom سال ۱۹۸۷ ارائه شده است. این مدل مربوط به یک سیستم بویلر-توربین در نیروگاهی در مالما سوئد می‌باشد. در جدول (۱) برخی از ویژگی‌های این فرایند نمایش داده شده است. معادلات حالت غیرخطی ارائه شده در این مرجع یک سیستم سه ورودی-

$$(6) \begin{cases} 0 \leq u_1, u_2, u_3 \leq 1 \\ -0.007 \leq \dot{u}_1 \leq 0.007 \\ -2 \leq \dot{u}_2 \leq 0.02 \\ -0.05 \leq \dot{u}_3 \leq 0.05 \end{cases}$$

همانگونه که اشاره شد سیستم بویلر- توربین دارای رفتار به شدت غیر خطی و محدوده گسترده کاری می باشد به گونه ای که خطی سازی حول یک نقطه کار نمی تواند بیان کننده رفتار سیستم در کل محدوده عملکرد آن باشد. در مراجع مختلف تعداد ۷ نقطه کار برای سیستم بویلر- توربین بیان شده است [۲]، [۳] و [۱۶].

جدول (۱): مشخصات سیستم بویلر - توربین ۱۶۰ مگاواتی [۱]

ظرفیت نامی سیستم	۱۶۰ MW
نوع سوخت	نفت
نرخ ورود بخار در ظرفیت نامی	۱۴۰ Kg/sec
دمای بخار نهایی	۵۳۵ C
فشار مخزن بخار	۱۴۰ Kg/cm <sup>2</sup>
حجم مخزن	۴۰ m <sup>3</sup>
حجم Downcomer	۱۱ m <sup>3</sup>
حجم Riser	۳۸ m <sup>3</sup>
جرم آب موجود در سیستم	۴۰ ton
جرم بخار موجود در سیستم	۲ ton
دمای آب پیش گرم شده	۳۰۰ C


با توجه به مقادیر نقاط کار می توان دریافت افزایش توان خروجی سیستم مستلزم افزایش فشار مخزن بخار می باشد. بنابراین به منظور ردیابی تقاضای بار شبکه باید فشار مخزن در یک محدوده خاص نسبت به توان خروجی تغییر کند. لذا باید به این نکته توجه داشت که در سیگنال مرجع اعمال شده به سیستم فشار مخزن و توان خروجی از رابطه مذکور پیروی کنند.

### ۳- شناسایی سیستم

در روش های کنترلی مبتنی بر مدل، عملکرد کنترل کننده به شدت وابسته به دقت مدل استفاده شده است. در کنترل پیش بین نیز شناسایی مدل دقیقی از سیستم امری ضروری است. در NMPC شناسایی و مدل سازی سیستم به مراتب از اهمیت بیشتری برخوردار است. حلقه شناسایی سیستم شامل بخش های مختلفی است که انتخاب معماری مدل، سیگنال تحریک، ورودی های مدل، ساختار دینامیکی برخی از این بخش ها را تشکیل می دهند. در ادامه به مراحل مختلف شناسایی سیستم بویلر- توربین پرداخته خواهد شد.

سه خروجی را معرفی می کند. معادلات (۱) تا (۵)، معادلات فضای حالت سیستم مذکور می باشند [۱۶].

$$(1) \begin{cases} \dot{x} = F(x, u) \\ y = G(x, u) \end{cases}$$



شکل (۱): دیاگرام شماتیکی از سیستم بویلر - توربین [۱۶]

$$(2) \begin{cases} \dot{x}_1 = -0.0018u_2x_1^{9/8} + 0.9u_1 - 0.15u_3 \\ \dot{x}_2 = (0.073u_2 - 0.016)x_1^{9/8} - 0.1x_2 \\ \dot{x}_3 = (14lu_3 - (1.1u_2 - 0.19)x_1) / 85 \end{cases}$$

$$(3) \begin{cases} y_1 = x_1 \\ y_2 = x_2 \\ y_3 = 0.05(0.13073x_3 + 100a_{cs} + q_e / 9 - 67.975) \end{cases}$$

$$(4) q_e = (0.854u_2 - 0.147)x_1 + 45.59u_1 - 2.514u_3 - 2.096$$

$$(5) a_{cs} = \frac{(1 - 0.001538x_3)(0.8x_1 - 25.6)}{x_3(1.0394 - 0.0012304x_1)}$$

در معادلات (۱) تا (۵)،  $x_1$  فشار مخزن بر حسب ( $kg/cm^2$ )،  $x_2$  توان خروجی بر حسب ( $MW$ ) و  $x_3$  چگالی سیال بر حسب ( $kg/m^3$ ) می باشد. خروجی اول و دوم سیستم همان حالت های اول و دوم سیستم بوده و خروجی سوم  $y_3$  سطح آب مخزن بر حسب ( $m$ ) می باشد که بر حسب دو پارامتر  $a_{cs}$  کیفیت بخار و نیز  $q_e$  نرخ تبخیر بر حسب ( $kg/s$ ) محاسبه شده است. همانگونه که ذکر شد ورودی های سیستم بر اساس موقعیت شیرهای کنترلی بوده و بین صفر و یک تغییر می کند که  $u_1$ ،  $u_2$  و  $u_3$  به ترتیب موقعیت شیرهای کنترلی سوخت، بخار و آب می باشد. رابطه (۶) نمایانگر محدودیت متغیرهای ورودی سیستم است که شامل محدودیت های اشباع و محدودیت در نرخ تغییر موقعیت شیرهای کنترلی می باشد.

### ۳-۱- معماری مدل

معماری استفاده شده برای مدل سازی سیستم بویلر-توربین در این مقاله، شبکه های عصبی MLP می باشد. یک شبکه MLP می تواند به عنوان یک تقریبگر عمومی استفاده شود. بدین معنی که یک شبکه MLP می تواند هر تابع غیرخطی نرمی را با دقت دلخواه تقریب زند. این دقت وابسته به تعداد نرون های لایه ی پنهان شبکه می باشد. این ویژگی باعث محبوبیت این ساختار در شناسایی سیستم های غیر خطی است [۱۱]. توابع فعال سازی شبکه مورد نظر در لایه پنهان تابع  $\tanh$  می باشد که یکی از توابع فعال سازی مرسوم در شبکه های عصبی است [۱۲]. شبکه ی عصبی MLP مورد نظر به صورت پیش خور (FNN) هستند و. رابطه زیر خروجی شبکه ی عصبی را بر حسب وزن های لایه خروجی و لایه پنهان نمایش می دهد.

$$\hat{y}_i(k) = \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_\phi} W_{j,l} \varphi_l + W_{j,0} \right) + W_{i,0} \quad (7)$$

در عبارت بالا  $W_{i,j}$  وزن های لایه خروجی،  $W_{j,l}$  وزن های لایه ورودی،  $f_j$  تابع فعال سازی نرون  $j$ ام در لایه پنهان،  $n_h$  تعداد نرون های لایه پنهان و  $n_\phi$  تعداد ورودی شبکه عصبی می باشد.

### ۳-۲- ساختار دینامیکی

ساختار دینامیکی مدل در واقع نشان دهنده ی نوع ورودی های مدل و نحوه ارتباط آن با ورودی و خروجی های فرایند می باشد. تمام مدل های دینامیکی غیرخطی ورودی-خروجی را می توان به صورت معادله (۸) نوشت.

$$\hat{y}(k) = f(\varphi(k)) \quad (8)$$

که بردار رگرسیون نامیده شده و بسته به نوع نمایش دینامیکی شامل ورودی ها و خروجی های تاخیر یافته و نیز خطای بین خروجی مدل و خروجی فرایند می باشد. از مدل های با فیدبک خروجی می توان به ساختارهای  $NARX$ ،  $NARMAX$  و  $NOE$  اشاره کرد.

در این نوشتار از یک ساختار  $NARX$  چند ورودی-چند خروجی استفاده شده که در [۲۰] به آن اشاره شده است و بردار رگرسیون آن در معادله (۹) نمایش داده شده است.

$$\varphi(k) = [Y_1(k-1), U_1(k-1), \dots, U_p(k-1), Y_2(k-1), U_1(k-1), \dots, U_p(k-1), Y_l(k-1), U_1(k-1), \dots, U_p(k-1)]^T \quad (9)$$

در رابطه (۹)  $Y_i(k-1)$  و  $U_i(k-1)$  بردارهای خروجی و ورودی تاخیر یافته ی فرایند به فرم رابطه (۱۰) و (۱۱) هستند.

$$Y_i(k-1) = [y_i(k-1), y_i(k-2), \dots, y_i(k-n_a)] \quad (10)$$

$$U_i(k-1) = [u_i(k-1), u_i(k-2), \dots, u_i(k-n_b)] \quad (11)$$


### ۳-۳- سیگنال تحریک

یکی از مراحل مهم و تاثیر گذار در شناسایی سیستم های غیرخطی طراحی سیگنال تحریک مناسب به منظور جمع آوری داده های شناسایی از سیستم است. داده های به دست آمده در سیستم های غیر خطی به دلیل پیچیدگی سیستم باید حاوی اطلاعات جامعی از فرایند باشند و تمامی نواحی کاری سیستم را پوشش دهند. سیگنال تحریک مورد استفاده در این نوشتار برای شناسایی سیستم بویلر-توربین سیگنال شبه تصادفی دو سطحی با تلفیق دامنه  $APRBS$  می باشد. در این سیگنال علاوه بر طول پله ها، دامنه پله ها نیز متناسب با طول سیگنال تحریک به صورت تصادفی تغییر می کند. در این سیگنال علاوه بر ویژگی های فرکانسی، دامنه های مختلف نیز مدنظر قرار داده شده است. در کنار طول سیگنال تحریک و حداقل و حداکثر دامنه سیگنال پارامتر مهم دیگر در  $APRBS$ ، کوچکترین زمانی است که سیگنال در یک سطح ثابت باقی می ماند که این پارامتر با مشخصات فرکانسی سیگنال تحریک در ارتباط است. سیگنال تحریک مورد نظر از دو بخش تشکیل شده است [۲۱] که بخش اول شامل مولفه های فرکانس بالا و به منظور آموزش مدل در حالت گذرا می باشد و کوچکترین زمانی که سیگنال ثابت می باشد به اندازه ۱۰ ثانیه انتخاب شده است. شکل (۲) این سیگنال را نمایش می دهد.

### ۳-۴- الگوریتم آموزش شبکه ی عصبی

روش های آموزش در شبکه های عصبی به طور کلی به دو دسته روش های مرتبه اول و مرتبه دوم دسته بندی می شوند

نوشتار برای مدل‌سازی سیستم بویلر-توربین بر اساس شبکه‌های عصبی بوده و ساختار دینامیکی مدل بر پایه NARX چند ورودی-چند خروجی می‌باشد که در آن، مدل برای پیش‌بینی رفتار آینده فرایند از ورودی‌ها و




شکل (۳): مدل پیش‌بین شبکه عصبی

خروجی‌های تاخیر یافته سیستم استفاده می‌کند. شکل (۳) نمایانگر مدل پیش‌بین عصبی می‌باشد. مدل پیش‌بین عصبی رفتار یک گام به جلوی فرایند را پیش‌بینی کرده و برای پیش‌بینی رفتار فرایند در افق پیش‌بینی نیاز به استفاده متوالی از چند مدل پیش‌بین است. به عبارت دیگر برای پیش‌بینی چندگام به جلوی رفتار فرایند، ابتدا مدل شبکه عصبی خروجی آینده سیستم را پیش‌بینی می‌کند و سپس خروجی به دست آمده به عنوان ورودی مدل بعد استفاده شده و به همین ترتیب رفتار سیستم در افق زمانی معین پیش‌بینی می‌شود. با توجه به این نکته می‌توان دریافت که خروجی پیش‌بینی شده فرایند در  $N_p$  لحظه بعد در واقع تابع غیرخطی از ورودی‌های آینده سیستم هستند. به طور کلی در کنترل پیش‌بین افق پیش‌بینی بزرگتر از افق کنترلی انتخاب می‌شود و به همین دلیل ورودی‌های آینده سیستم که بزرگتر از افق کنترلی هستند ثابت و به اندازه آخرین سیگنال کنترلی در افق کنترلی (  $u(k+N_u-1)$  ) در نظر گرفته می‌شود که در آن  $N_u$  افق کنترلی می‌باشد. شکل (۴) نشان دهنده چگونگی پیش‌بینی رفتار آینده سیستم توسط مدل‌های متوالی شبکه عصبی است.

## ۲-۴- تابع هزینه

تابع هزینه در کنترل پیش‌بین می‌تواند شامل بخش‌های متفاوتی باشد که هر بخش یکی از وظایف کنترل‌کننده را بر عهده می‌گیرند. تابع معیار بسته به اهداف کنترلی می‌تواند شامل بخش‌های مختلفی باشد. تابع معیار استفاده شده در کنترل پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی در این نوشتار به صورت رابطه (۱۲) انتخاب شده است.



شکل (۲): سیگنال تحریک APRBS به منظور آموزش مدل شبکه عصبی

در روش‌های مرتبه اول تنها از گرادیان مرتبه اول تابع معیار استفاده می‌شود و در روش‌های مرتبه دوم از گرادیان مرتبه دوم و ماتریس هسیان استفاده می‌شود. الگوریتم استفاده شده در این بخش، الگوریتم L-M خواهد بود. این الگوریتم که یک روش مرتبه دوم محسوب می‌شود جزء سریعترین الگوریتم‌ها در آموزش شبکه‌های عصبی می‌باشد و نسبت به روش‌هایی مانند الگوریتم نیوتن از پایداری بیشتری برخوردار است. در این الگوریتم برای اطمینان از معکوس پذیر بودن تقریب ماتریس هسیان، ضریبی از ماتریس واحد به نام ضریب ترکیب به آن اضافه می‌شود [۲۰].

## ۴- کنترل‌کننده پیش‌بین عصبی


کنترل پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی یکی از انواع کنترل پیش‌بین غیر خطی است که دارای محبوبیت بسیاری می‌باشد. توانایی شبکه‌های عصبی در شناسایی سیستم‌های غیرخطی و نیز کاهش بار محاسباتی بهینه‌سازی غیرخطی به واسطه استفاده از آن‌ها، از عوامل این محبوبیت می‌باشد. کنترل پیش‌بین دارای اجزای مختلفی مانند مدل پیش‌بین، الگوریتم بهینه‌سازی و تابع هزینه است که در ادامه به بررسی آن‌ها پرداخته خواهد شد.

## ۱-۴- مدل پیش‌بین عصبی


در کنترل مدل پیش‌بین وظیفه مدل پیش‌بینی رفتار آینده سیستم است و کنترل‌کننده بر اساس پیش‌بینی انجام شده و بهینه‌سازی تابع معیار سیگنال کنترلی مناسب را به فرایند اعمال می‌کند. همانگونه که ذکر شد معماری مدل استفاده شده در این

### ۳-۴- مدل اغتشاش

در بخش‌های قبل به این نکته اشاره شد که استفاده از شبکه‌های عصبی در کنترل پیش‌بین باعث ایجاد خطای حالت ماندگار در خروجی سیستم می‌شود. این مساله به دلیل انباشته شدن خطاهای پیش‌بینی مدل شبکه‌ی عصبی در هر گام پیش‌بینی است. زیرا خروجی مدل در یک گام پیش‌بینی به عنوان ورودی مدل بعد در گام



شکل (۵): رفتار تابع  $f(u)$  به ازای مقادیر مختلف  $S$



شکل (۶): بلوک دیاگرام مدل اغتشاش


بعدی پیش‌بینی استفاده شده و به دلیل عدم تطبیق مدل و فرایند خطاهای به‌وجود آمده در هر گام انباشته شده و باعث ایجاد خطای حالت ماندگار می‌شود. در این نوشتار از مدل اغتشاشی که در مرجع [۲۲] به آن اشاره شده، استفاده می‌شود. بلوک دیاگرام این شبکه در شکل (۶) مشاهده می‌شود.

در روش ذکر شده به منظور جبران خطای عدم تطبیق مدل و فرایند در پیش‌بینی رفتار آینده سیستم، خروجی مدل شبکه‌ی عصبی در هر گام پیش‌بینی با خروجی شبکه‌ی جبران‌کننده‌ی خطا یا مدل اغتشاش جمع می‌شود و از خطای باقیمانده بین خروجی فرایند و مجموع خروجی مدل عصبی و خروجی مدل اغتشاش، پارامترهای شبکه جبران‌کننده‌ی خطا توسط یک مکانیزم گرادیان کاهشی برای مرحله بعد به‌روز می‌شوند. مجموع خروجی‌های شبکه‌ی عصبی و شبکه‌ی جبران‌کننده خطا را می‌توان به صورت معده (۱۴) توصیف کرد [۲۲].

$$\hat{y}_i(k) = \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_p} W_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} + d_{M_i}(k) \quad (14)$$

$$J(k) = \sum_{j=1}^{N_p} \|Y(k+j) - Y_r(k+j)\|_R^2 + \sum_{j=1}^{N_u} \|U(k+j) - U(k+j-1)\|_Q^2 + \sum_{j=1}^{N_u} f(u(k+j)) \quad (12)$$

در رابطه (۱۲)  $N_p$  افق پیش‌بینی،  $N_u$  افق کنترلی،  $R$  و  $Q$  ماتریس‌های وزنی،  $Y(k+j)$  بردار خروجی‌های پیش‌بینی شده،  $Y_r(k+j)$  بردار خروجی‌های مطلوب در گام‌های آینده و



شکل (۴): پیش‌بینی چند گام آینده توسط مدل‌های متوالی شبکه عصبی

$U(k+j)$  بردار ورودی‌های آینده سیستم می‌باشند.  $R$  و  $Q$  ماتریس‌های مثبت معین و به ترتیب وزن‌های نرم دوم اختلاف خروجی پیش‌بین شده و نرخ تغییرات ورودی می‌باشند.  $R$  و  $Q$  می‌توانند به عنوان یک پارامتر مهم طراحی محسوب شوند. بخش اول تابع هزینه در واقع اختلاف خروجی‌های فرایند و خروجی‌های مرجع را کمینه می‌کند و وظیفه تولید سیگنال کنترلی مناسب به منظور ردیابی خروجی مرجع را برعهده دارد. بخش دوم تابع هزینه اختلاف ورودی‌های هر گام را با ورودی-های گام قبلی کمینه می‌کند و در واقع وظیفه کنترل نرخ تغییر سیگنال ورودی را بر عهده دارد. بخش سوم در تابع هزینه یک تابع غیرخطی از ورودی‌های آینده سیستم است که در مرجع [۲۲] به آن اشاره شده و کمینه کردن آن به عنوان بخشی از تابع هزینه باعث می‌شود سیگنال کنترلی به دست آمده محدود به مقادیر مجاز حداکثر و حداقل دامنه ورودی باشد. رابطه این تابع در معادله (۱۳) ذکر شده است.

$$f(u) = \exp\left(\frac{2S(u - \bar{u}) \text{sign}(u - \bar{u})}{u_{\max} - u_{\min}}\right) / \exp(S) \quad (13)$$

$u_{\min}$  و  $u_{\max}$  حداکثر و حداقل دامنه سیگنال مجاز ورودی به سیستم،  $\bar{u}$  میانگین حداکثر و حداقل دامنه سیگنال و متغیر  $S$  به عنوان پارامتر طراحی می‌باشد. در شکل (۵) رفتار تابع  $f(u)$  به ازای سه مقدار مختلف برای پارامتر  $S$  مشاهده می‌شود. با کاهش مقدار  $S$  تابع  $f(u)$  نرم‌تر شده و سیگنال کنترلی محدودتر خواهد شد.

محدود کردن هزینه کنترلی و اعمال محدودیت اشباع در متغیرهای ورودی، در تابع هدف لحاظ شده است.

در این نوشتار از الگوریتم SQP به منظور بهینه‌سازی تابع معیار استفاده شده است. الگوریتم SQP در دهه هفتاد رایج شد و می‌توان گفت یکی از کارآمدترین روش‌ها در حل مسائل بهینه‌سازی غیرخطی دارای محدودیت می‌باشد [۲۳]. روش‌های مبتنی بر الگوریتم SQP در واقع توسعه یافته‌ی روش‌های نیوتن هستند که به منظور برآورده شدن شروط بهینه‌سازی مرتبه اول در مسائل بهینه‌سازی ارائه شده‌اند [۱]. در این مقاله به منظور پیاده‌سازی الگوریتم SQP از جعبه ابزار بهینه‌سازی نرم‌افزار MATLAB استفاده شده است.

در نهایت می‌توان سیستم کنترلی طراحی شده را در قالب یک بلوک دیاگرام به نمایش درآورد که در شکل (۷) آمده است.

در بلوک دیاگرام فوق  $Yr(K)$  بردار سیگنال مرجع بوده که در واقع شامل بار درخواستی شبکه و مقدار مطلوب فشار و سطح آب مخزن بخار می‌باشد. بر اساس مطالب ذکر شده در بخش‌های ساختار دینامیکی و مدل شبکه‌ی عصبی،  $Y(K-1)$  و  $U(K-1)$  به ترتیب خروجی‌ها و ورودی‌های تاخیر یافته فرایند می‌باشند که به مدل شبکه‌ی عصبی اعمال می‌شوند.  $Y(K+1)$  خروجی پیش‌بینی شده توسط مدل شبکه‌ی عصبی می‌باشد که وارد بخش بهینه‌سازی کنترل‌کننده می‌شود. در نهایت  $U(K)$  ورودی بهینه اعمال شده به فرایند و  $Y(K)$  خروجی به‌دست آمده از فرایند می‌باشد.

## ۵- نتایج شبیه‌سازی

در این بخش نتایج شبیه‌سازی بخش‌های مختلف کنترل‌کننده پیش‌بین عصبی طراحی شده بررسی خواهد شد و عملکرد کنترل‌کننده مورد ارزیابی قرار می‌گیرد. در شبیه‌سازی‌های انجام شده باید به برخی نکات توجه داشت که در ادامه بررسی می‌شود. به طور کلی زمان نمونه برداری باید به گونه‌ای باشد که تا حد امکان اطلاعات کمتری از دست رود. در سیستم‌های چند ورودی - چند خروجی غیر خطی انتخاب زمان نمونه برداری با چالش‌های متفاوتی مواجه است. در سیستم‌های چند متغیره معمولاً خروجی‌ها دارای دینامیک‌های مختلفی هستند و انتخاب زمان نمونه برداری باید با در نظر گرفتن دینامیک‌های مختلف انتخاب شود. با توجه به کارگیری کنترل پیش‌بین غیر خطی برای کنترل این سیستم باید زمان نمونه‌برداری به گونه‌ای انتخاب شود که محاسبات کنترلی در بازه زمان نمونه برداری پایان یابد.

با خروجی شبکه عصبی جمع شده تا اختلاف بین خروجی فرایند و خروجی مدل در هر گام پیش‌بینی جبران شود. خروجی مدل اغتشاش ذکر شده در بالا به صورت رابطه (۱۵) می‌باشد.

$$d_{Mi}(k) = w_{di} \hat{e}_i(m) + b_i \quad (15)$$

که در آن اندیس  $i$  متناظر با خروجی  $i$  ام و  $\hat{e}_i(t)$  اختلاف بین خروجی فرایند و خروجی مدل شبکه‌ی عصبی می‌باشد. همچنین  $w_{di}$  و  $b_i$  پارامترها یا وزن‌های مدل اغتشاش می‌باشند که در هر گام از زمان نمونه برداری توسط یک روش گرادیان کاهش می‌یابند. بر اساس روابط (۱۶) و (۱۷) به روز می‌شوند.

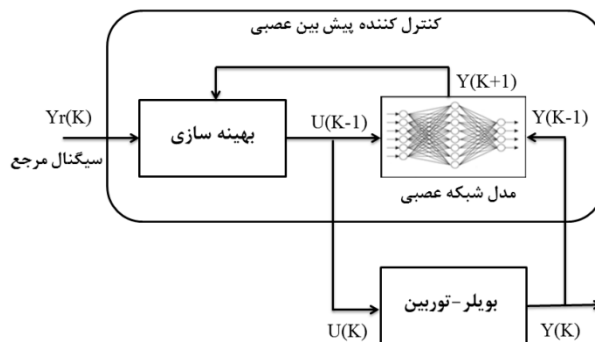
$$w_{di}(k+1) = w_{di}(k) + \eta_i \hat{e}_i(m)^2 \quad (16)$$

$$b_i(k+1) = b_i(k) + \eta_i \hat{e}_i(k) + k_{pi} (\hat{e}_i(k) - \hat{e}_i(k-1)) \quad (17)$$

در عبارات بالا  $\eta_i$  و  $k_{pi}$  نرخ‌های یادگیری پارامترهای شبکه می‌باشند.


## ۴-۴- الگوریتم بهینه‌سازی

الگوریتم بهینه‌سازی مورد استفاده در کنترل‌کننده پیشنهادی در این نوشتار، در هر گام زمانی تابع هدف ذکر شده در رابطه (۱۲) را نسبت

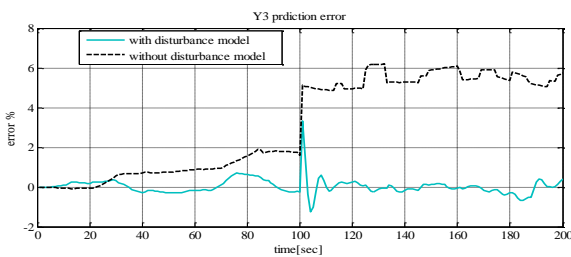


شکل (۷): بلوک دیاگرام سیستم کنترلی پیش‌بین عصبی طراحی شده


به بردار ورودی‌های کنترلی آینده  $U(k+j)$ ، بهینه‌سازی کرده و بردار ورودی‌های کنترلی بهینه را به‌دست می‌آورد که طول این بردار وابسته به افق کنترلی  $N_u$  می‌باشد. سپس اولین گام از بردار کنترلی به‌دست آمده به فرایند اعمال شده و این روند در گام زمانی بعدی تکرار خواهد شد. همانگونه که به طور کامل در بخش تابع هزینه اشاره شد، تابع هدف مورد نظر در رابطه (۱۲) دارای سه بخش می‌باشد که تمامی آن‌ها تابعی از بردار کنترلی  $U(k+j)$  بوده و به ترتیب برای ردیابی مسیر مطلوب خروجی،




شکل (۹): پیش‌بینی در حضور اغتشاش و شبکه جبران کننده خطا



شکل (۱۰): خطای پیش‌بینی سطح آب مخزن به همراه اغتشاش در حضور و عدم حضور مدل اغتشاش



شکل (۱۱): پاسخ سیستم حلقه بسته بدون مدل اغتشاش




شکل (۱۲): سطح آب مخزن بدون مدل اغتشاش

در بخش بعد به شبیه‌سازی سیستم حلقه بسته پرداخته خواهد شد. سیگنال مرجع برای فشار مخزن متناسب با سیگنال مرجع برای توان می‌باشد. از این سیگنال مرجع به عنوان مبنای شبیه‌سازی سیستم حلقه بسته در حالت‌های مختلف شبیه‌سازی‌های

زمان نمونه برداری سیستم بویلر-توربین در مراجع مختلف بین ۰/۵ تا ۵ ثانیه بوده [۵] و [۲۴] که بسته به کنترل کننده و پردازنده مورد استفاده انتخاب شده است. زمان نمونه برداری سیستم بویلر-توربین در این نوشتار با توجه به مباحث مطرح شده برابر یک ثانیه انتخاب شده است. انتخاب مناسب پارامترهای یک کنترل کننده می‌تواند تاثیر بسزایی در عملکرد آن داشته باشد. در کنترل پیش‌بین خطی روش‌هایی برای انتخاب پارامترهای کنترل کننده معرفی شده [۲۵] اما در کنترل پیش‌بین غیرخطی انتخاب این پارامترها معمولاً بر اساس سعی و خطا انجام می‌شود. در شبیه‌سازی‌های انجام شده افق پیش‌بینی برابر ۱۰ و افق کنترلی برابر ۵ در نظر گرفته شده است. همچنین ماتریس‌های وزنی به صورت  $R = [3 \ 10 \ 1000]$  و  $Q = [200 \ 100 \ 150]$  انتخاب شده‌اند. در این بخش توانایی مدل اغتشاش در کاهش خطای پیش‌بینی بررسی شده است. در شکل‌های (۸) تا (۱۰) پیش‌بینی ۲۰۰ گام آینده برای خروجی‌های سیستم در حضور و عدم حضور مدل اغتشاش نمایش داده شده است.

در شکل (۹) پیش‌بینی با حضور مدل اغتشاش انجام شده و ملاحظه می‌شود که شبکه که خوبی اغتشاش وارد شده را دفع کرده و مانع از افزایش خطای پیش‌بینی می‌شود. همچنین در شکل (۱۰) خطای پیش‌بینی در حضور اغتشاش برای سطح آب مخزن در دو حالت حضور و عدم حضور شبکه‌ی جبران‌ساز خطا نشان داده شده است.




شکل (۸): پیش‌بینی در حضور اغتشاش و بدون مدل اغتشاش


آتی استفاده می‌شود [۵]. در ابتدا پاسخ سیستم حلقه‌بسته بدون مدل اغتشاش در شکل‌های (۱۱) و (۱۲) نمایش داده شده است. با توجه به شکل (۱۱) و (۱۲) می‌توان دریافت که عدم وجود شبکه‌ی جبران‌کننده خطا باعث ایجاد خطای حالت ماندگار در خروجی‌های سیستم می‌شود.

در مرحله بعد شبیه‌سازی سیستم حلقه بسته در حضور شبکه جبران‌کننده خطا در شکل‌های (۱۳) و (۱۴) بررسی می‌گردد. همانگونه که در شکل (۱۳) ملاحظه می‌شود خطای حالت ماندگار سیستم در حضور شبکه جبران‌کننده خطا کاهش پیدا کرده است. در شکل‌های (۱۵) و (۱۶) توانایی دفع اغتشاش وارد شده به بار درخواستی شبکه به میزان ۲ مگاوات در لحظه‌های ۲۰۰، ۶۰۰ و ۱۰۰۰ مورد ارزیابی قرار گرفته است. همانگونه که ملاحظه می‌شود سیستم به خوبی توانسته اغتشاش وارد شده به فرایند را دفع کند.


در نهایت به منظور ارزیابی بهتر، مقایسه عملکرد پاسخ حلقه بسته کنترل‌کننده طراحی شده با کنترل‌کننده طراحی شده در مرجع [۶]




شکل (۱۵): پاسخ سیستم در حضور اغتشاش



شکل (۱۶): سطح آب مخزن در حضور اغتشاش




شکل (۱۷): مقایسه پاسخ سیستم حلقه بسته در دو کنترل‌کننده پیش‌بین عصبی و PI (توان الکتریکی و فشار مخزن)




شکل (۱۸): مقایسه پاسخ سیستم حلقه بسته در دو کنترل‌کننده پیش‌بین عصبی و PI (سطح آب مخزن)

در شکل‌های (۱۷) و (۱۸) آورده شده است. در مرجع [۶] یک کنترل‌کننده PI طراحی شده و ضرایب مناسب کنترل‌کننده به وسیله الگوریتم ژنتیک به دست آمده است. با توجه به مقایسه پاسخ حلقه بسته در شکل‌های فوق می‌توان دریافت کنترل‌کننده طراحی شده به مراتب عملکرد بهتری نسبت به کنترل‌کننده PI دارد. همانگونه که ملاحظه می‌شود



شکل (۱۹): پاسخ سیستم حلقه بسته در حضور مدل اغتشاش



شکل (۲۰): سیگنال کنترلی در حضور مدل اغتشاش

- [6] R. Dimeo, K. Y. Lee, "Boiler-Turbine Control System Design Using a Genetic Algorithm", IEEE Transactions on Energy Conversion, Vol. 10, No. 4, December 1995.
- [7] E.F. Camacho, B. Alba, Model Predictive Control, Springer, 2nd ed. 2004.
- [8] E. Carlos Garda, M. David Preti, M. Morari, "Model Predictive Control: Theory and Practice a Survey" Automatica, Vol. 25, No. 3, pp. 335-338, 1989.
- [9] M. Nørgaard, O. Ravn, N.K. Poulsen, L.K. Hansen. Neural Networks For Modeling and Control of Dynamic Systems: a practitioner's handbook. London: Springer-Verlag; 2000.
- [10] H. Yaghoobi, H. Rajabi Mashhadi, K. Ansari, 'Application of Radial Basis Neural Network in Fault Diagnosis of Synchronous Generator' Journal of Iranian Association of Electrical and Electronics Engineers - Vol.10- No.2- Fall & Winter 2013.
- [11] Jawad Faiz, A. R. Ghaffari, 'Adaptive Position control of Permanent Magnet Synchronous Motor Drives using Neural Networks', Journal of Iranian Association of Electrical and Electronics Engineers - Vol.1 - No.2 - Summer & Fall 2004.
- [12] V.A. Akpan, G.D. Hassapis, "Nonlinear Model Identification and Adaptive Model Predictive Control Using Neural Networks" ISA Transactions 50, pp. 177-194, 2011.
- [13] D.L. Yu, J.B. Gomm "Implementation of Neural Network Predictive Control to A Multivariable Chemical Reactor", Control Engineering Practice 11, pp. 1315-1323, 2003.
- [14] C. Lul, C. Tsai, "MIMO Neural-Network Predictive Controller Design", The 30th Annual Conference of the IEEE Industrial Electronics Society, November, Busan, Korea, pp. 2-6, 2004.
- [15] U. Yüzgeç, Y. Becerikli, M. Türker, "Dynamic Neural-Network-Based Model-Predictive Control of an Industrial Baker's Yeast Drying Process" IEEE Transactions on Neural Network, Vol. 19, NO. 7, July 2008.
- [16] Y. Li, J. Shen, K. Y. Lee, X. Liu, "Offset-free Fuzzy Model Predictive Control of A Boiler-Turbine System Based on Genetic Algorithm", Simulation Modelling Practice and Theory 26, pp. 77-95, 2012.
- [17] X. Wu, J. Shen, Y. Li, K. Y. Lee, "Data-Driven Modeling and Predictive Control for Boiler-Turbine Unit", IEEE Transactions on Energy Conversion, Vol. 28, No. 3, September 2013.
- [18] M. Keshavarz, M. Barkhordari Yazdi, M.R. Jahed-Motlagh "Piecewise Affine Modeling and Control of A Boiler-turbine Unit," Applied Thermal Engineering, 30, pp. 781-791, 2010.
- [19] U. Moon, K.Y. Lee, "Step-Response Model Development for Dynamic Matrix Control of a Drum-Type Boiler-Turbine System", IEEE Transactions on Energy Conversion, June 2009, Vol. 24, No. 2.

بر خلاف کنترل کننده PI، پاسخ حلقه بسته سیستم کنترلی پیشنهادی در زمان تغییر سیگنال مرجع بدون نوسان بوده و دارای زمان نشست بسیار کمتری است و نیز سطح آب مخزن به خوبی در نزدیکی مقدار مرجع (صفر) حفظ شده و دارای نوسان نمی‌باشد.

## ۶- نتیجه گیری

در این مقاله با توجه به اهمیت سیستم بویلر-توربین در صنعت تولید برق و جایگاه مهم آن در نیروگاه‌های حرارتی و همچنین وجود چالش‌های کنترلی ذکر شده در این فرایند، به طراحی یک کنترل کننده پیش‌بین غیرخطی مبتنی بر شبکه‌های عصبی پرداخته شده است. در بخش پنجم به شبیه‌سازی قسمت‌های مختلف کنترل پیش‌بین غیرخطی پرداخته و توانایی مدل اغتشاش در جلوگیری از افزایش خطای پیش‌بینی ملاحظه گردید. همچنین تاثیر اضافه کردن تابع  $f(u)$  در محدودیت اشباع سیگنال کنترلی ملاحظه گردید. با شبیه‌سازی سیستم حلقه بسته مشاهده گردید سیستم حلقه بسته در حضور مدل اغتشاش دارای پاسخ بدون خطای حالت ماندگار می‌باشد و به خوبی اغتشاش وارد شده به سیستم را دفع می‌کند. همچنین با مقایسه عملکرد سیستم حلقه بسته مشاهده شد که کنترل کننده پیشنهادی نسبت به کنترل کننده PI مبتنی بر الگوریتم ژنتیک معرفی شده در مرجع [۶]، عملکرد بسیار مناسبتری داشته و اهداف کنترلی مدنظر را بهتر محقق می‌کند.

## مراجع

- [1] R. D. Bell, K. J. Astrom, "Dynamic Models for Boiler-turbine-alternator Units: Data Logs and Parameter estimation for a 160 MW unit", Department of automatic control Lund institute of technology, report, TFRT 3192, pp. 1-137, 1987
- [2] W. Tan, H. J. Marquez, T. Chen, "Analysis and Control of A Nonlinear Boiler-Turbine unit", Journal of Process Control 15, pp. 883-891, 2005.
- [3] P. Chen, "Multi-objective control of nonlinear boiler turbine dynamics with actuator magnitude and rate constraints", ISA Transactions, 52, pp. 115-128, 2013.
- [4] A.A. Jalali, H. Golmohammad, "An Optimal Multiple-model Strategy to Design A Controller for Nonlinear Processes: A Boiler-turbine Unit", Computers and Chemical Engineering 46, pp. 48-58, 2012.
- [5] U. Moon, K.Y. Lee, "A Boiler-Turbine System Control Using A Fuzzy Auto-Regressive Moving Average (FARMA) Model", IEEE Transaction on Energy Conversion, Vol. 18, NO. 1, March 2003.

- [20] M. Nørgaard, "Neural Network Based System Identification Toolbox For Use with MATLAB, Version 2" Technical Report 00-E-891, Department of Automation Technical University of Denmark, January , 2000.
- [21] B. Vatankehah, A. Fatehi, A. KhakiSedigh "Neural Network Model-Based Predictive Control for Multivariable Nonlinear Systems", IEEE Multi-conference on Systems and Control, Yokohama, Japan, pp. 8-10, September, 2010.
- [22] A. Jazayeri, A. Fatehi, H. Sadjadian , A. Khaki-Sedigh: "Disturbance Rejection in Neural Network Model Predictive Control", Proceeding of the 17th IFAC World Congress, Korea, 2008.
- [23] p. T.bogges, j.W.tole, "Sequential Quadratic Programming", Acta Numerica , pp.1 , 1996
- [24] J. L. Garriga, M. Soroush, "Model Predictive Controller Tuning via Eigenvalue Placement", American Control Conference, Seattle, WA, pp. 11-13, June 2008.
- [25] U.Moon, S. Lee, K. Y. Lee, " An Adaptive Dynamic Matrix Control of a Boiler-Turbine System Using Fuzz Inference", Intelligent Systems Applications to Power Systems International Conference on, ISAP 2007.

## زیر نویس ها

- 
- <sup>1</sup> - Model predictive control
  - <sup>2</sup> - Nonlinear model predictive control
  - <sup>3</sup> - Multilayer perceptron
  - <sup>4</sup> - Dynamic feed forward neural network
  - <sup>5</sup> - Dynamic matrix control
  - <sup>6</sup> - Nonlinear autoregressive exogenous
  - <sup>7</sup> - Nonlinear autoregressive moving average exogenous
  - <sup>8</sup> - Nonlinear output error
  - <sup>9</sup> - Amplitude modulated pseudo random binary signal

