

مدلسازی خطی سیستمهای غیر خطی با کمک شبکه های عصبی مصنوعی بر پایه داده های ورودی - خروجی و کاربرد آن در بویلر نیروگاه

علی غفاری

دانشیار دانشکده مهندسی مکانیک - دانشگاه صنعتی خواجه نصیرالدین طوسی

منصور نیکخواه بهرامی

استاد گروه مهندسی مکانیک - دانشکده فنی - دانشگاه تهران

مرتضی محمدظاهری

فارغ التحصیل کارشناسی ارشد مهندسی مکانیک - دانشکده فنی - دانشگاه تهران

(تاریخ دریافت ۸۳/۹/۷، تاریخ تصویب ۸۴/۳/۷)

چکیده

در این مقاله روش جدیدی برای مدلسازی خطی سیستمهای غیر خطی ارائه می گردد. اساس روش پیشنهادی طراحی یک شبکه عصبی مصنوعی دو لایه و آموزش آن بر مبنای داده های ورودی- خروجی است. وزنه های اتصالات این شبکه ضرایب تابع تبدیل هستند. در سیستمهایی که رفتار آنها خطی باشد، روش حداقل کردن مربعات خطا (LSE) بهترین نتایج مدلسازی را ارائه می نماید. در سیستمهایی که رفتار غیر خطی دارند، نظیر بعضی قسمتهای بویلر نیروگاهها، روش مدلسازی خطی به کمک شبکه های عصبی مصنوعی نسبت به روش LSE ارجحیت دارد. در مورد اجزای غیر خطی بویلر نیروگاه، تابع تبدیلهای به دست آمده از روش شبکه عصبی مصنوعی، بهتر از تابع تبدیلهای به دست آمده از روش حداقل مربعات خطا با داده های حقیقی ثبت شده مطابقت دارند.

واژه های کلیدی: مدلسازی، نیروگاه بخار، شبکه عصبی مصنوعی، تابع تبدیل

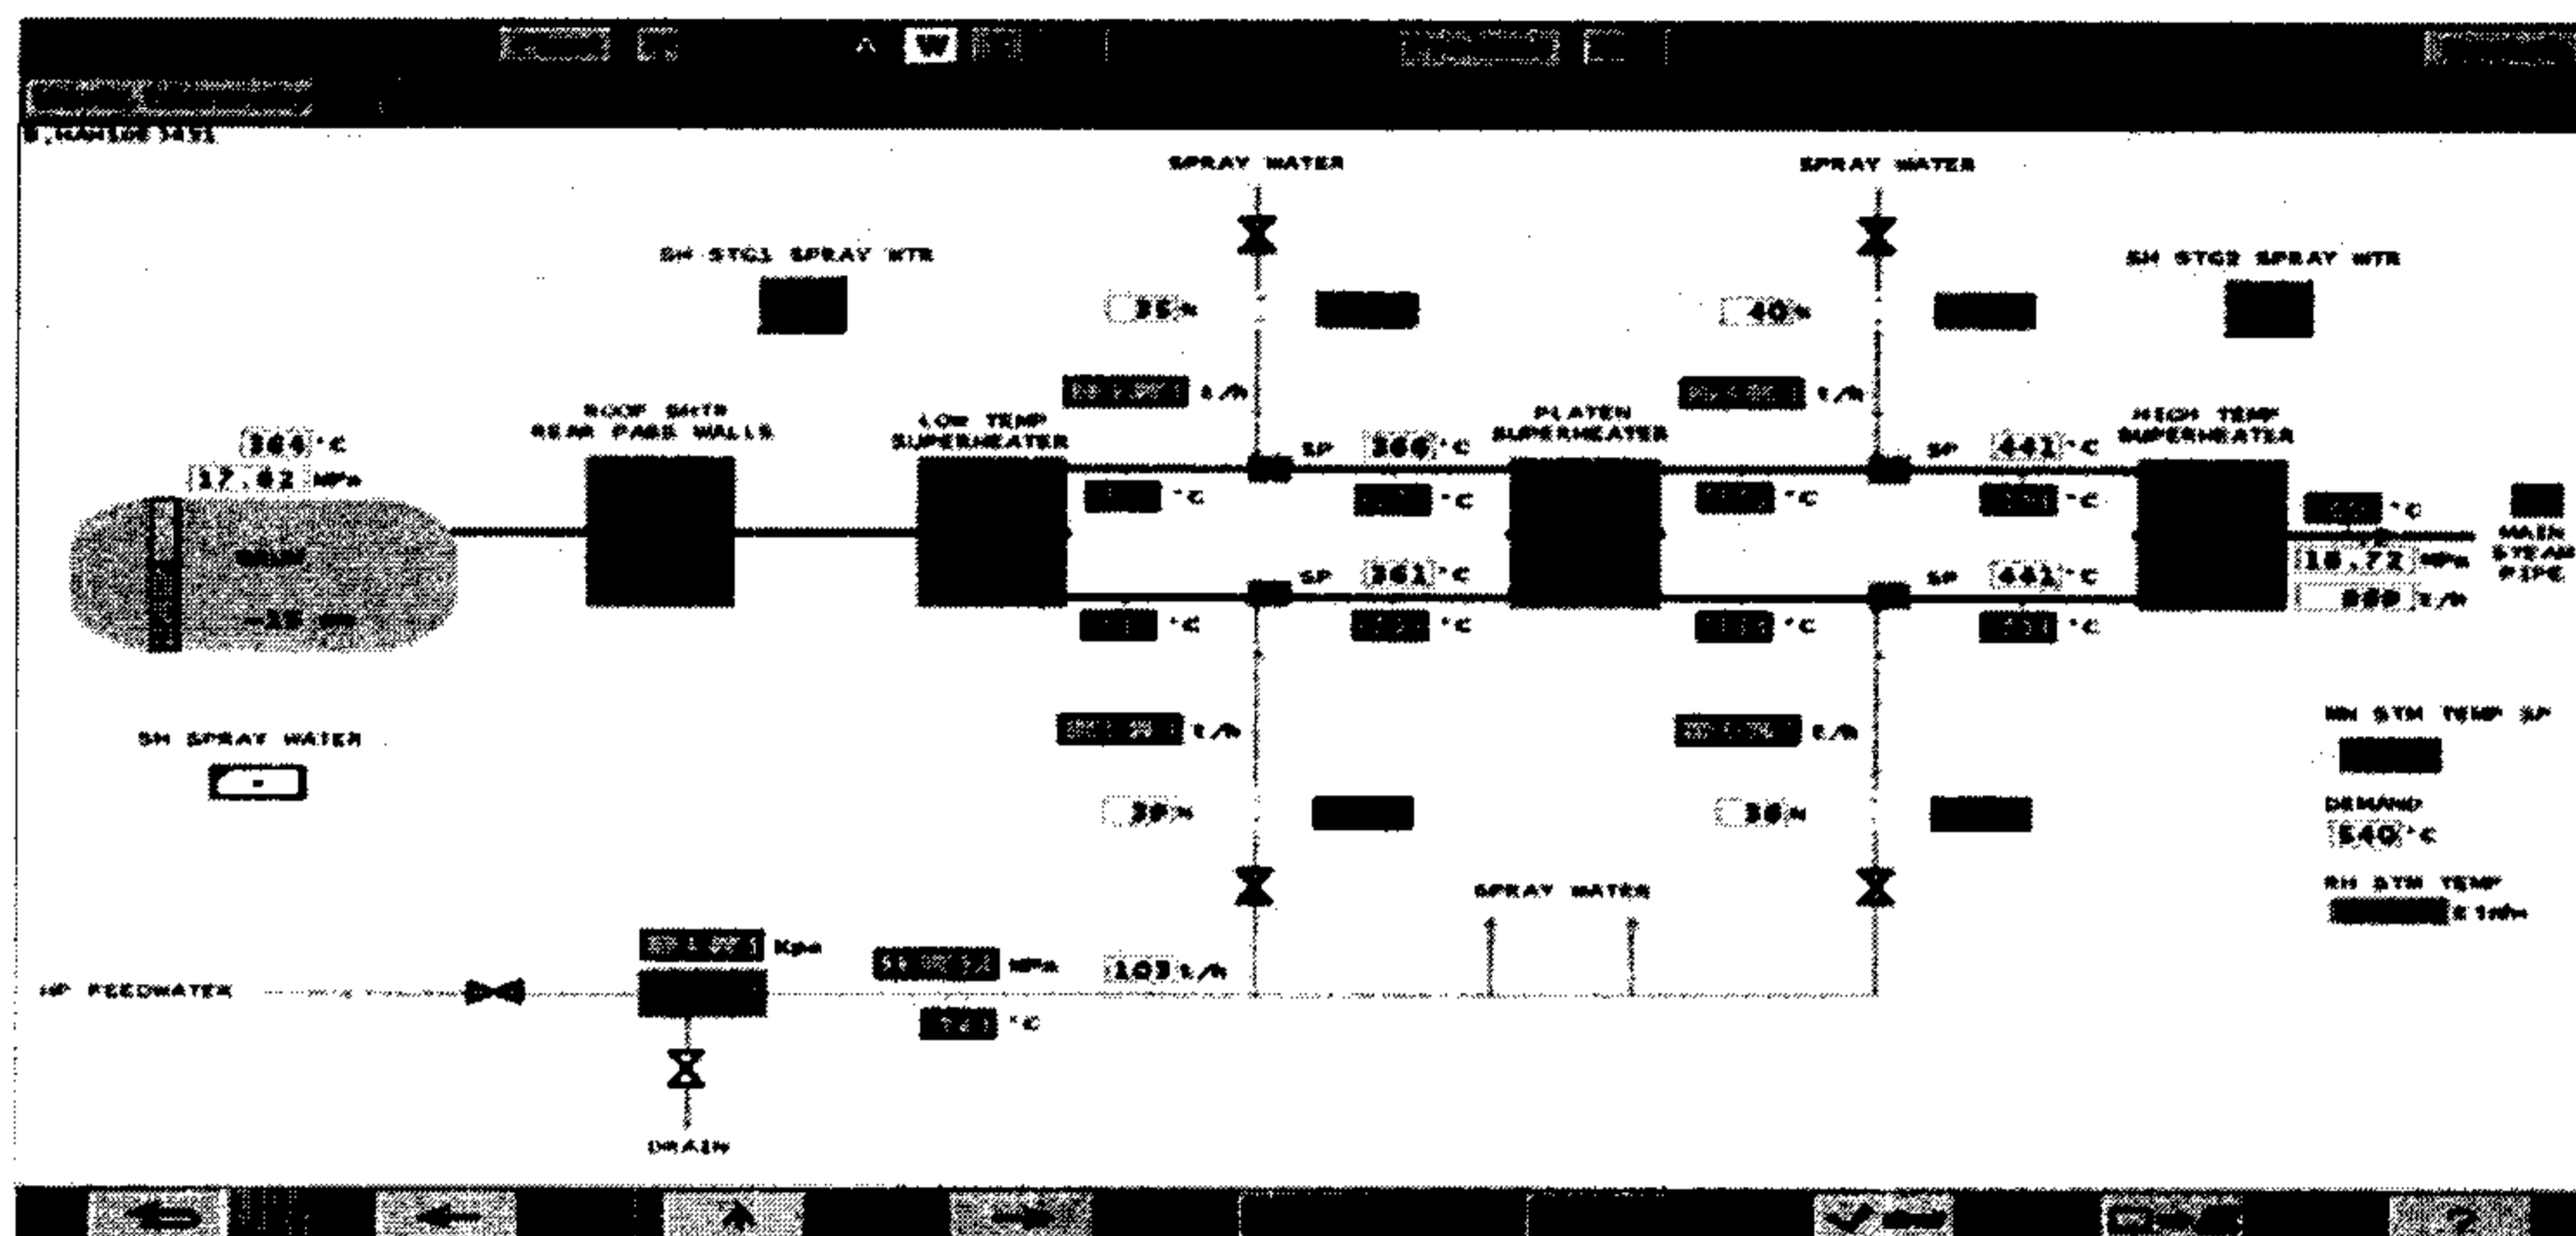
مقدمه

روشهای قابل استفاده هستند. اگر بتوان با استفاده از فیزیک مسأله یک مدل ریاضی به صورت معادله دیفرانسیل غیر خطی از سیستم به دست آورد. روش feedback linearization، در وضعیت مدار بسته قابل استفاده است.

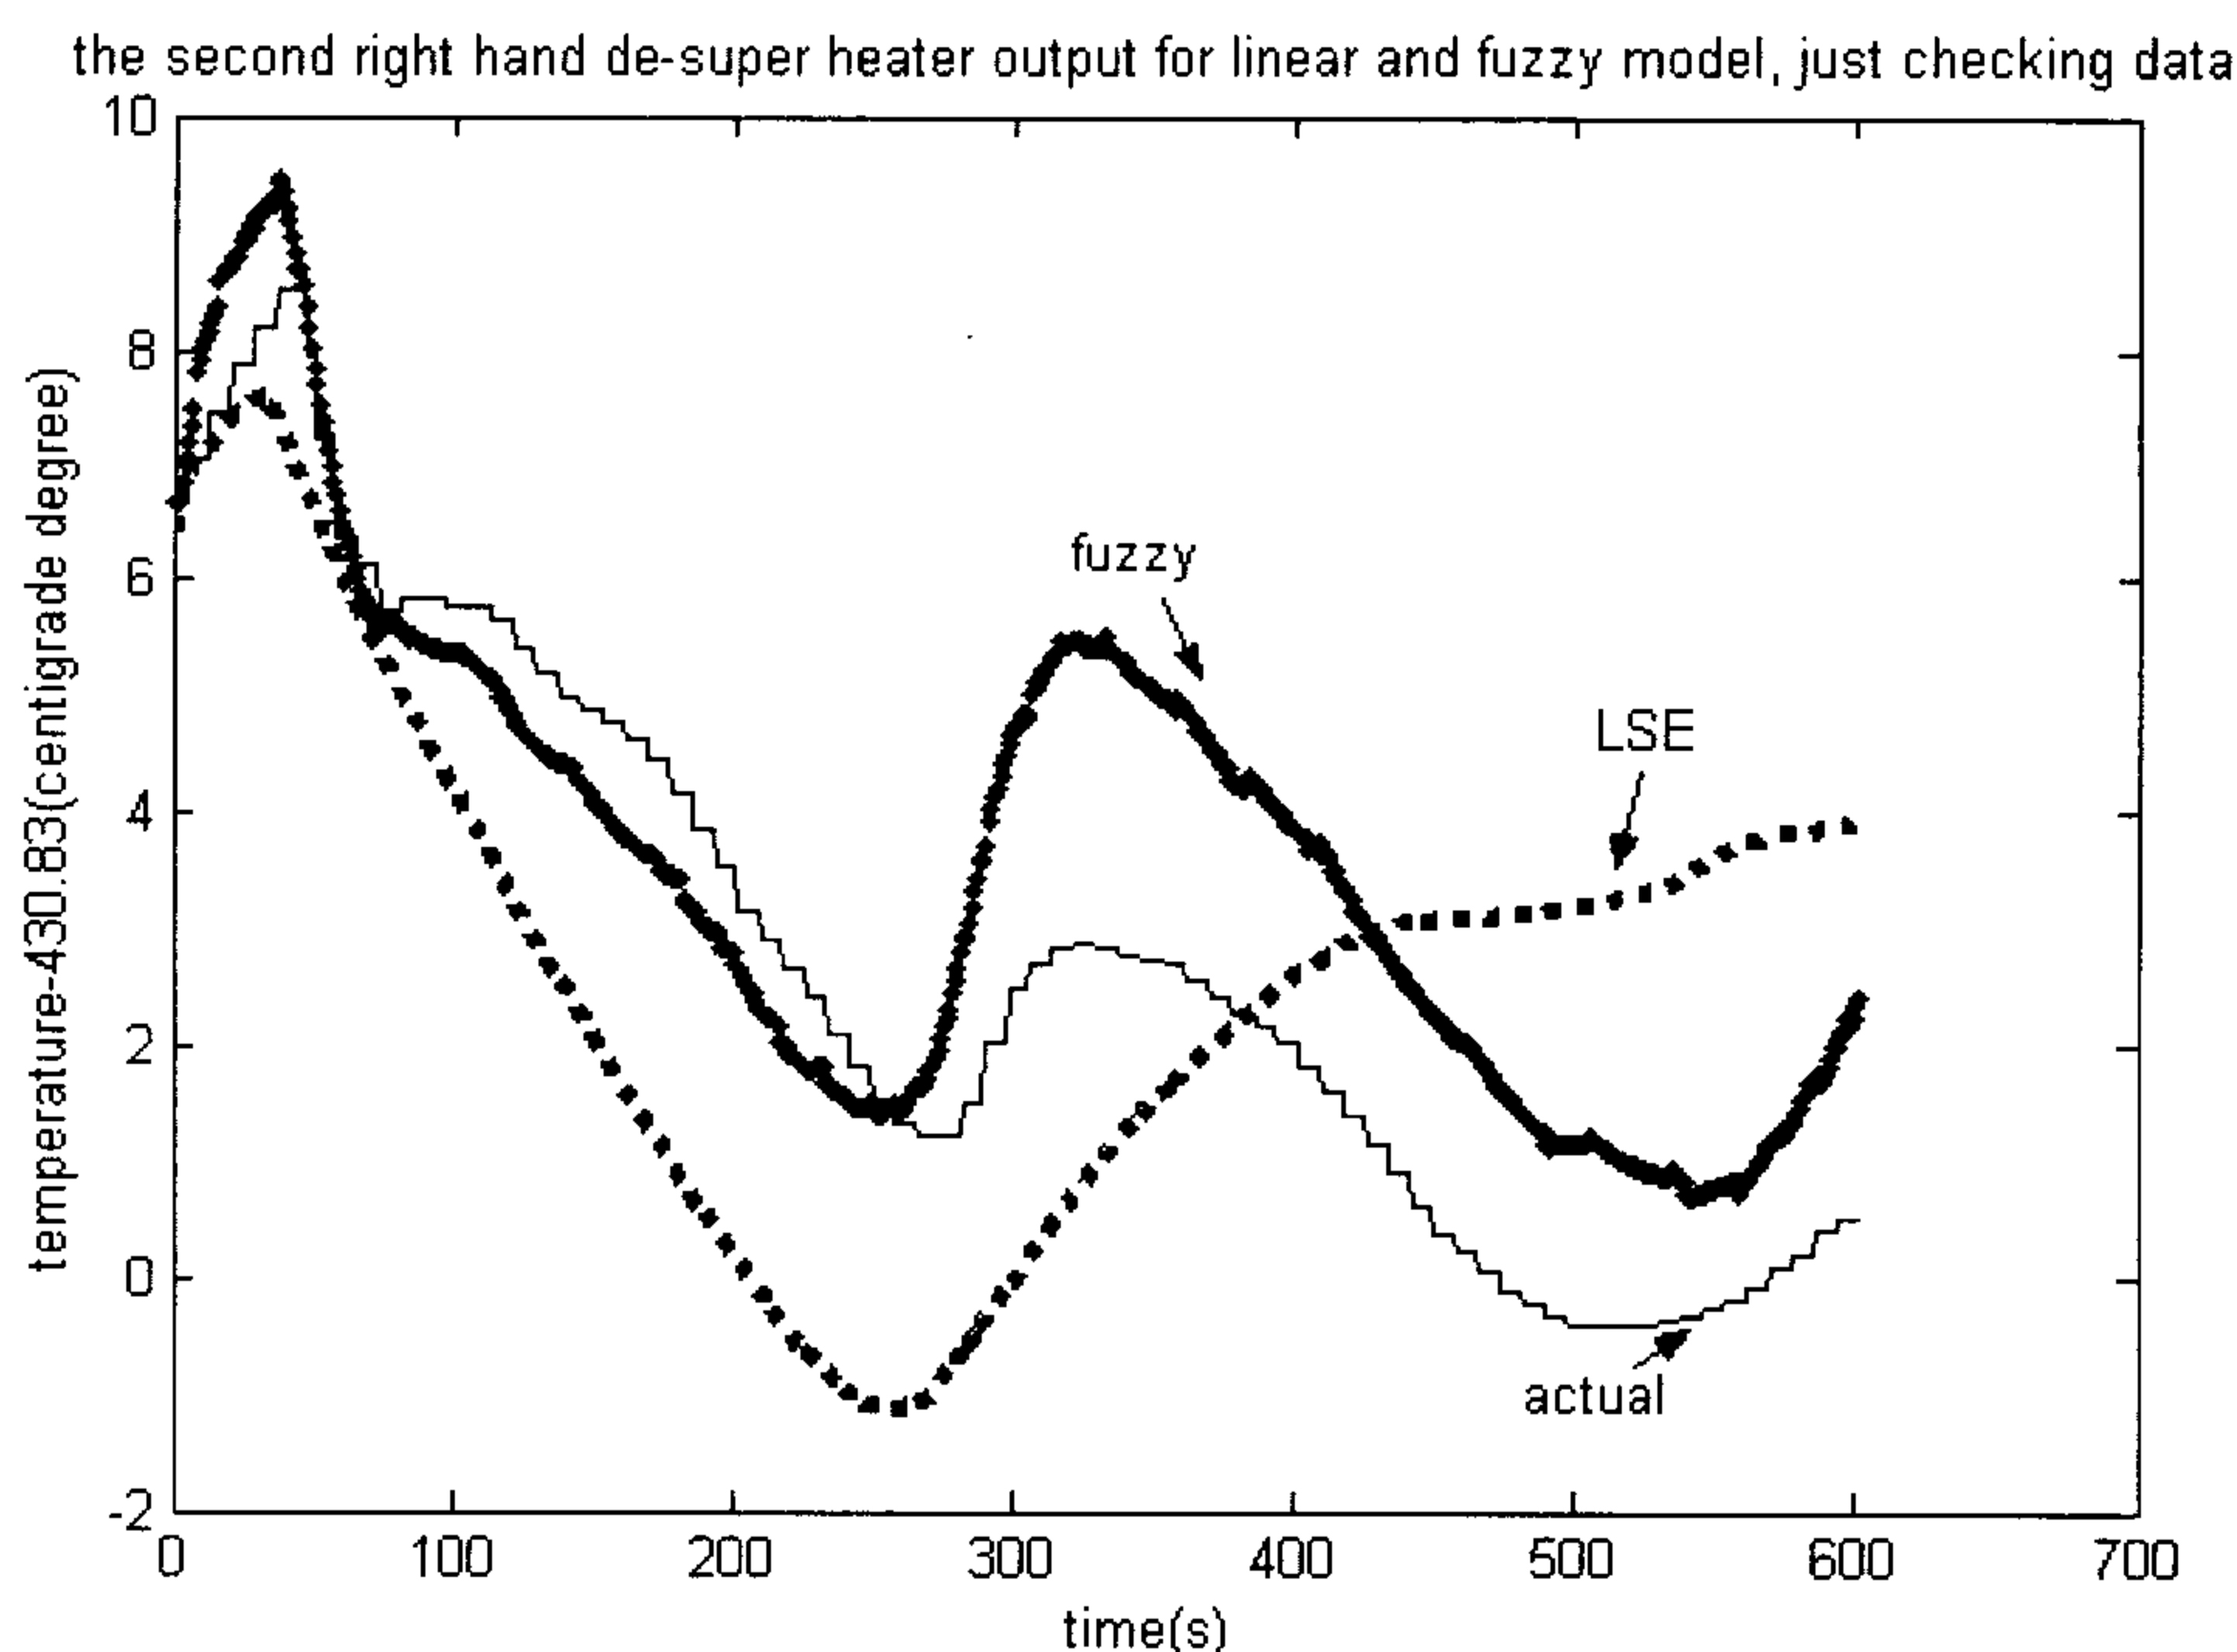
در این مقاله، محدوده ای از بویلر نیروگاه بخار سازند، از ورودی درام تا ورودی توربین فشار بالا (شکل ۱) مورد بررسی قرار گرفته است.

به علت دقت کم مدلهای ترمودینامیکی [۵، ۶]، بررسی ها بر پایه داده های ورودی- خروجی ثبت شده اجزا، در بار بالای ۳۰٪ (وضعیت کار عادی)، انجام شده است. در مدلسازیها از داده های روز ۲۷ شهریور ۱۳۸۳ واحد اول نیروگاه سازند، استفاده شده است. که داده ها در آن روز از تغییرات بیشتری نسبت به سایر داده های در دسترس برخوردار بودند.

در حال حاضر در تمامی نیروگاههای کشور از کنترلرهای خطی استفاده می شود و معتبرترین شرکتهای طراح و سازنده سیستمهای کنترلی نیروگاهی در جهان، هنوز به طور گسترده و جدی سیستمهای کنترل خطی خود را برای کاربردهای نیروگاهی ارائه می کنند. هر چند روشهای کلاسیک مبتنی بر مدل، تنها مرجع طراحان سیستمهای کنترلی نیروگاهی، در طراحی کنترلرهای خطی، نیست. با این وجود برای بررسی و بهینه سازی این سیستمها و تنظیم مجدد دوره ای ضرایب کنترلر ها، داشتن مدلهای خطی (توابع تبدیل) مربوط به اجزای نیروگاه ضروری به نظر می رسد. برای مدلسازی خطی یا خطی سازی روشهای گوناگونی وجود دارد، اگر داده های ورودی- خروجی در دست باشد، روش حداقل کردن مربعات خطا، استفاده از الگوریتمهای تطبیقی و به کار بردن روشهای بهینه سازی (نظیر الگوریتم ژنتیک) برای حداقل کردن خطای مدلسازی با اصلاح ضرایب، از



شکل ۱: شماتیک مجموعه مورد بررسی برای مدل‌سازی.



شکل ۲: دمای خروجی دی سوپر هیتر دوم سمت راست و تخمینهای مدل‌های فازی و خطی.

میانگین قدر مطلق آنها به حداقل می‌رسد. این امر موجب افزایش قدر مطلق نسبت خطا به مقدار اولیه داده و افزایش حساسیت الگوریتم نسبت به خطاها و در نتیجه بهبود مدل‌سازی می‌شود. تفاوت در بزرگی اعداد نشان دهنده کمیت‌های مختلف نیز در مدل‌سازی اثر منفی می‌گذارد، برای اجتناب از این مورد، داده‌های هر ستون، قبل از مدل‌سازی نرمالیزه شده‌اند. در روشی تکراری^۱ هم توجه شده است، که خطای مدل‌سازی کمتر به معنای دقت بیشتر نیست و ممکن است مدل، در عین اینکه خود را با داده‌های مدل‌سازی بیشتر تطبیق می‌دهد، از شناخت دینامیک کلی سیستم دور شود.

در همه مدل‌سازیها، نکاتی لحاظ شده است، از جمله، در نظر گرفتن تأخیرها، مثلاً "دمای ورودی به یک سوپر هیتر، پس از گذشت حدود ۲۰ ثانیه بر روی دمای خروجی آن تأثیر می‌گذارد. پس در تخمین دمای خروجی، باید، دمای ورودی با ۲۰ ثانیه تأخیر لحاظ گردد. با توجه به این که در نیروگاه سازند زمان نمونه‌گیری یک ثانیه است، در نظر نگرفتن این تأخیرها، موجب افت شدید توان مدل‌سازی می‌شود.

ضمناً هر ستون داده، قبل از استفاده در مدل‌سازی آزمایشی همان ستون کم شده است. با این کار داده‌ها حول خط «مقدار داده = صفر» تقارن یافته و در نتیجه

عصبی در الگوریتمهای تطبیقی است [۱۰، ۷، ۶] یا استفاده از شبکه عصبی در عملیاتی است که منتهی به feedback linearization می شود [۸، ۹، ۱۱].

در مدلسازی مدار باز سیستمهای غیر خطی، ورودی کنترلی در کار نیست تا ترمهای غیر خطی را خنثی کند و به همین دلیل نمی توان از خطی سازی به کمک بازخورد^۲ بهره برد. در مباحث ریاضیات غیر خطی هم، خطی سازی عموماً^۳ حول نقطه تعادل صورت می گیرد. که برای یک سیستم مرتبه n چنین تعریف می شود [۳]:

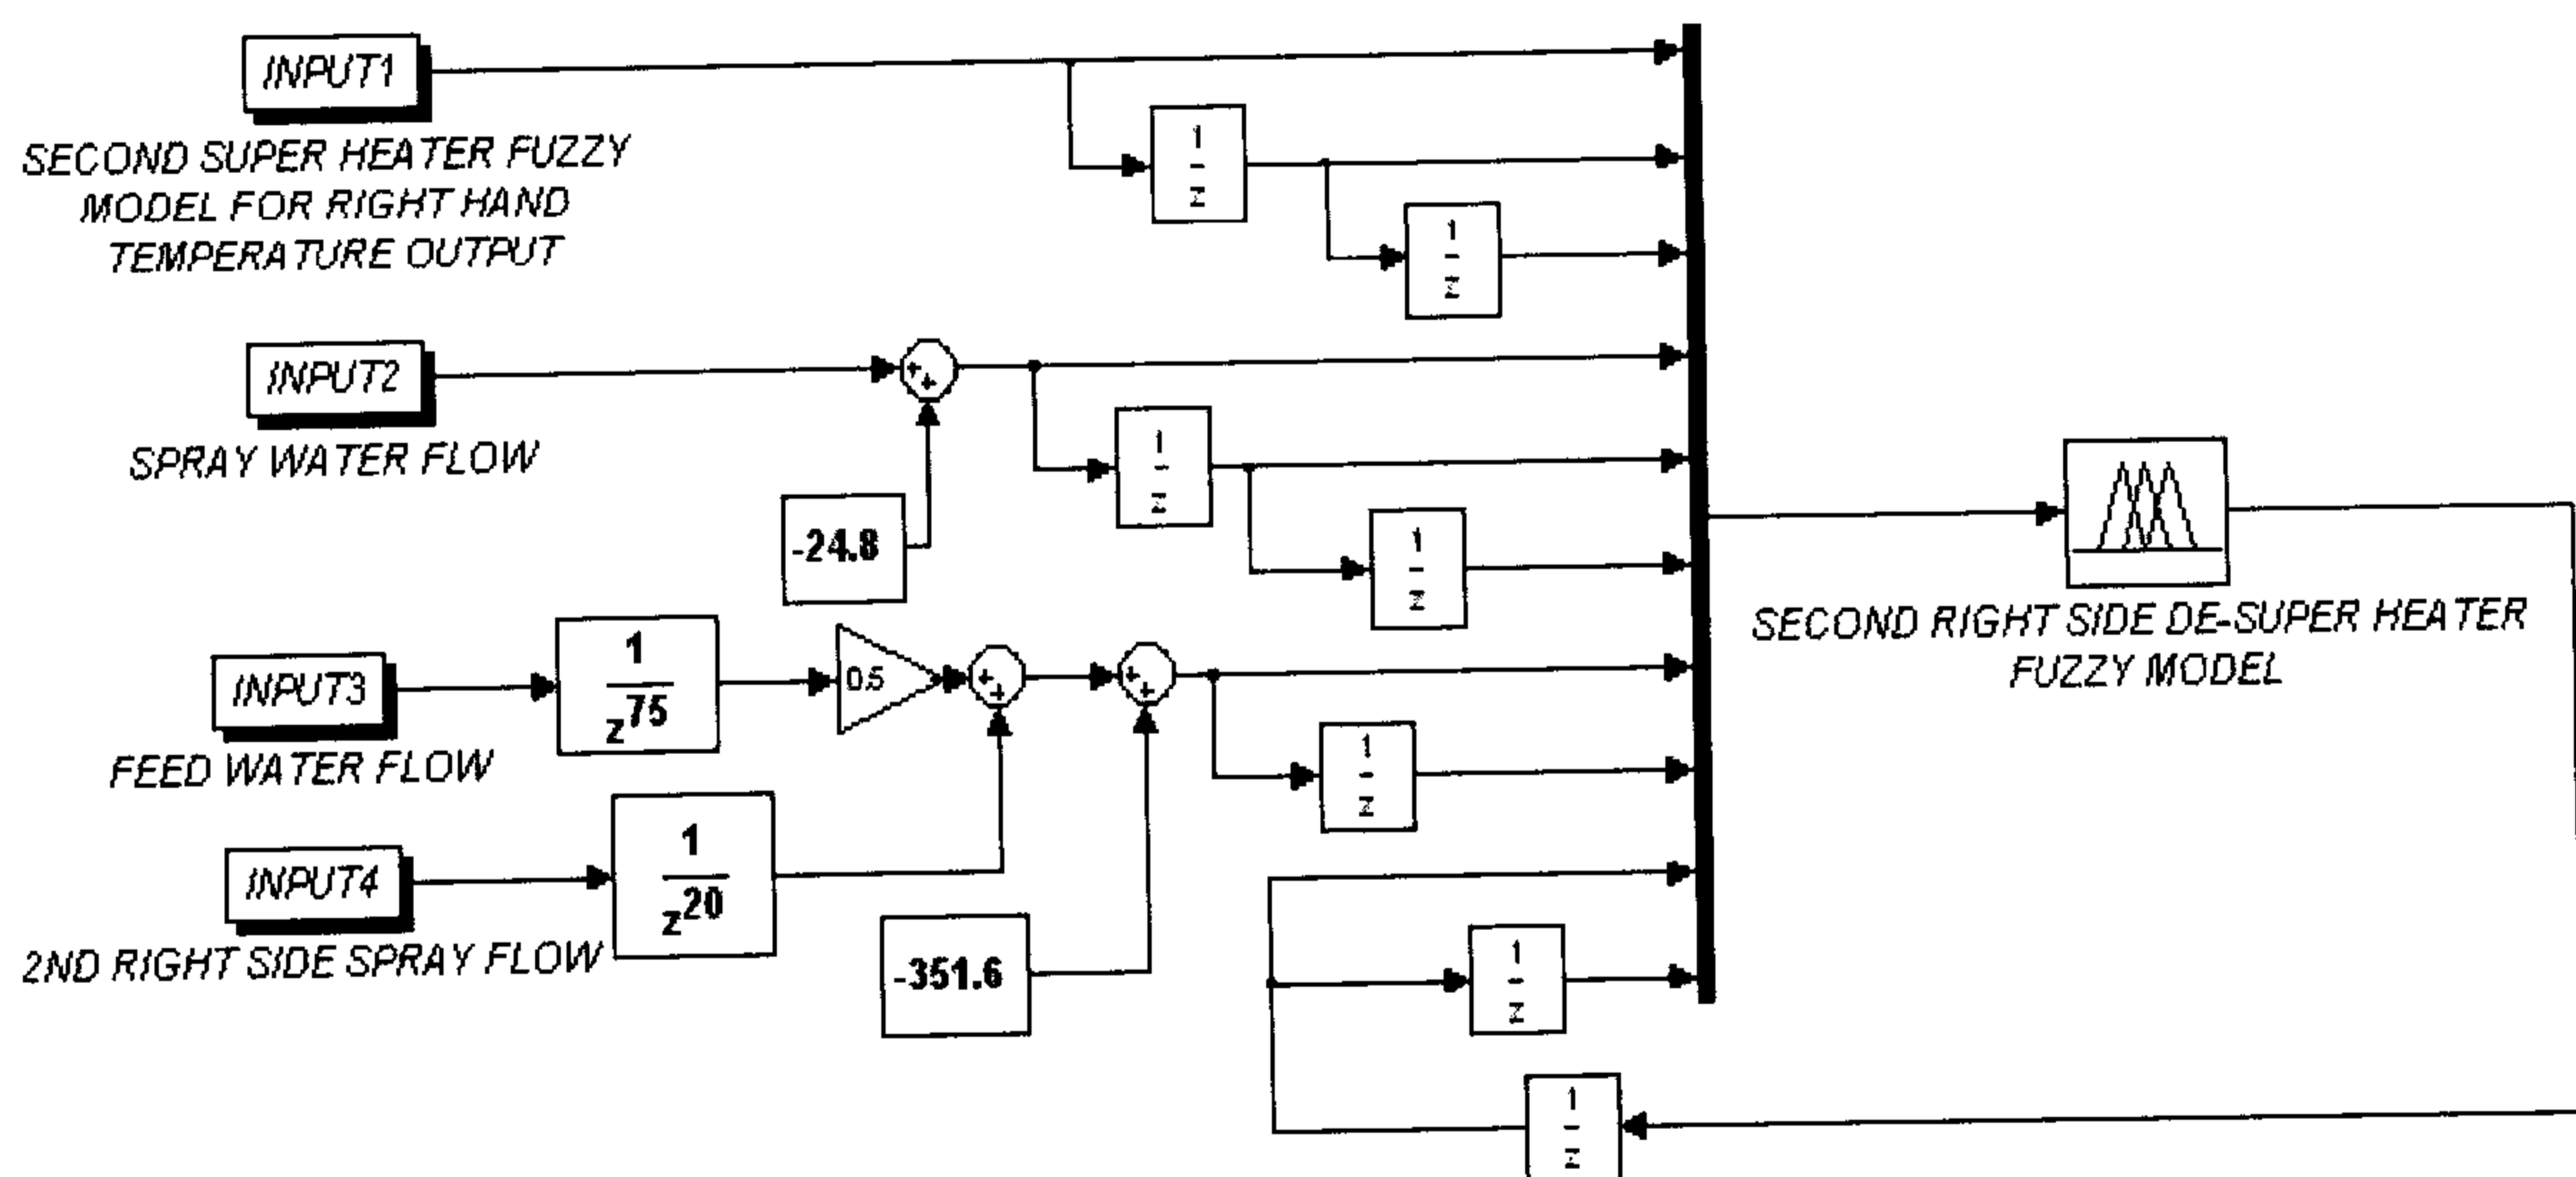
$$\dot{x} = 0, \dots, x^{(n-1)} = 0 \quad (1)$$

اما در مواردی که صرفاً بر اساس داده های ورودی-خروجی مدلسازی انجام می شود، هیچ معادله دیفرانسیلی هم در دست نیست. در چنین وضعی برای مدلسازی خطی، در دامنه مشخصی حول خط «مقدار داده = صفر» (مثلاً $[-30^{\circ}\text{C} \quad 30^{\circ}\text{C}]$ برای یک ورودی و دامنه های اینچنینی برای سایر ورودیها و خروجی)، استفاده از شبکه های عصبی دو لایه با تابع فعالیت^۳ همانی پیشنهاد می شود. برای توضیح بیشتر به مثال زیر توجه کنید:

برای سیستمهای خطی ایده آل، روش حداقل مربعات خطا (LSE)، بهترین مدل (خطی) را به دست می دهد. اما واقعیت اینست که بسیاری از اجزای نیروگاه ماهیتی غیر خطی دارند [۶ و ۸]، شکل (۲)، نشان دهنده مقایسه نتیجه مدلسازی خطی مرتبه سه به روش LSE با مدلسازی فازی-عصبی (با مدل فازی نوع سوگنو با مرتبه حداکثر دو و با ده قانون فازی (از هزاران قانون ممکن)، برای یکی از دی سوپرهیترهای نیروگاه شازند است [۱۴]. شکل (۳) نیز، سیمولینک نشان دهنده داده های ورودی-خروجی مدل فازی مورد بحث است. اگر سیستم خطی بود روش LSE بهترین تخمین (مدل) از سیستم را به دست می داد. با توجه به شکل (۲)، می توان نتیجه گرفت که سیستم غیر خطی است. پس احتمالاً^۳ می توان مدلی خطی بهتر از مدل به دست آمده از روش LSE، برای چنین سیستمهایی یافت. در ادامه روشی برای بررسی این موضوع پیشنهاد شده است.

خطی سازی به کمک شبکه های عصبی مصنوعی

آنچه امروزه به عنوان خطی سازی با شبکه عصبی از آن یاد می شود، عموماً^۳ یا به کار گرفتن شبکه های



شکل ۳: نمایی از داده های ورودی و خروجی از مدل فازی دی سوپر هیتر دوم سمت راست.

نیستند و آنچه موجود است داده های ورودی- خروجی سیستمهاست. مدل‌های به دست آمده با روش پیشنهادی؛ همانطور که گفته شد، در دامنه مشخصی (که برابر محدوده معمول کاری در نظر گرفته شده) اعتبار دارند (و نه حول نقطه تعادل). مثلاً فرض کنید، دمای خروجی سوپرهیتر دوم در یکی از واحدهای نیروگاه، در یک بازه زمانی که اطلاعات آن در دسترس است، از حدود 420°C تا حدود 480°C تغییر می کند و میانگین آن هم 450°C است. شبکه عصبی که با چنین داده هایی آموزش می بیند، در همین محدوده هم اعتبار دارد و اگر کم کردن داده ها از میانگین را هم در نظر بگیریم، دامنه اعتبار آن، حول خط «مقدار داده = صفر» $[30^{\circ}\text{C} - 3^{\circ}\text{C}]$ خواهد بود یا $[450^{\circ}\text{C} - 480^{\circ}\text{C}]$.

اجزای بررسی شده به لحاظ ساختار فیزیکی، به سه دسته قابل تقسیم هستند: درام که ساختاری بسیار پیچیده و غیر خطی دارد، و در مدلسازی، ورودیهای آن: دبی سوخت، دمای جریانهای آب ورودی از دو اکتونومایزر، دبی آب تغذیه و سطح درام (با یک ثانیه تأخیر) در نظر گرفته شده اند و خروجی درام هم فشار بخار خروجی فرض شده، که به علت دو فازه بودن درام، با معلوم بودن آن دمای جریان بخار خروجی درام هم مشخص می شود. سوپر هیترها، که مبدل‌های حرارتی نسبتاً ساده هستند و تا حدود زیادی رفتاری خطی دارند و ورودی آنها دمای جریان بخار ورودی، دبی بخار عبوری (که در هر سوپرهیتر به روش خاصی محاسبه می شود) و دبی سوخت و خروجی آنها دمای بخار خروجی در نظر گرفته شده است. دسته آخر دی سوپر هیترها (مناطق پاشش آب) هستند که ورودی آنها دمای قبل از پاشش، دبی بخار عبوری و میزان پاشش و خروجی آنها دمای بخار، بعد از پاشش، فرض شده است. در مورد تمام ورودیها، همانطور که قبلاً گفته شد، تأخیرها و سایر نکات مدلسازی، مورد توجه بوده است. در مورد درام، به علت، شدیداً غیر خطی بودن آن، یافتن تابع تبدیلی که بهتر از تابع تبدیلی به دست آمده از روش LSE نتایج را تخمین بزند، بسیار ساده است خروجی سیستم واقعی، خروجی تابع تبدیلی به دست آمده از روش LSE و طبق روش پیشنهادی، برای داده های استفاده نشده در


فرض کنید هدف به دست آوردن یک تابع تبدیل خطی مرتبه ۲ برای یک سیستم دو ورودی و یک خروجی باشد. چنین مدلی را به این صورت در نظر می گیریم:

$$y = \frac{(n_{11}z^{-1} + n_{10})u_1 + (n_{21}z^{-1} + n_{20})u_2}{-d_2z^{-2} - d_1z^{-1} + 1} \quad (2)$$

یا:

$$y(k) = n_{10}u_1(k) + n_{11}u_1(k-1) + n_{20}u_2(k) + n_{21}u_2(k-1) + d_1u(k-1) + d_2u(k-2) \quad (3)$$

چنین رابطه ای را می شود به صورت یک شبکه عصبی پرسپترون دولایه با تابع فعالیت همانی و بدون bias نشان داد.



شکل ۴: نمایی از شبکه عصبی فرضی که برای خطی سازی کاربرد دارد.

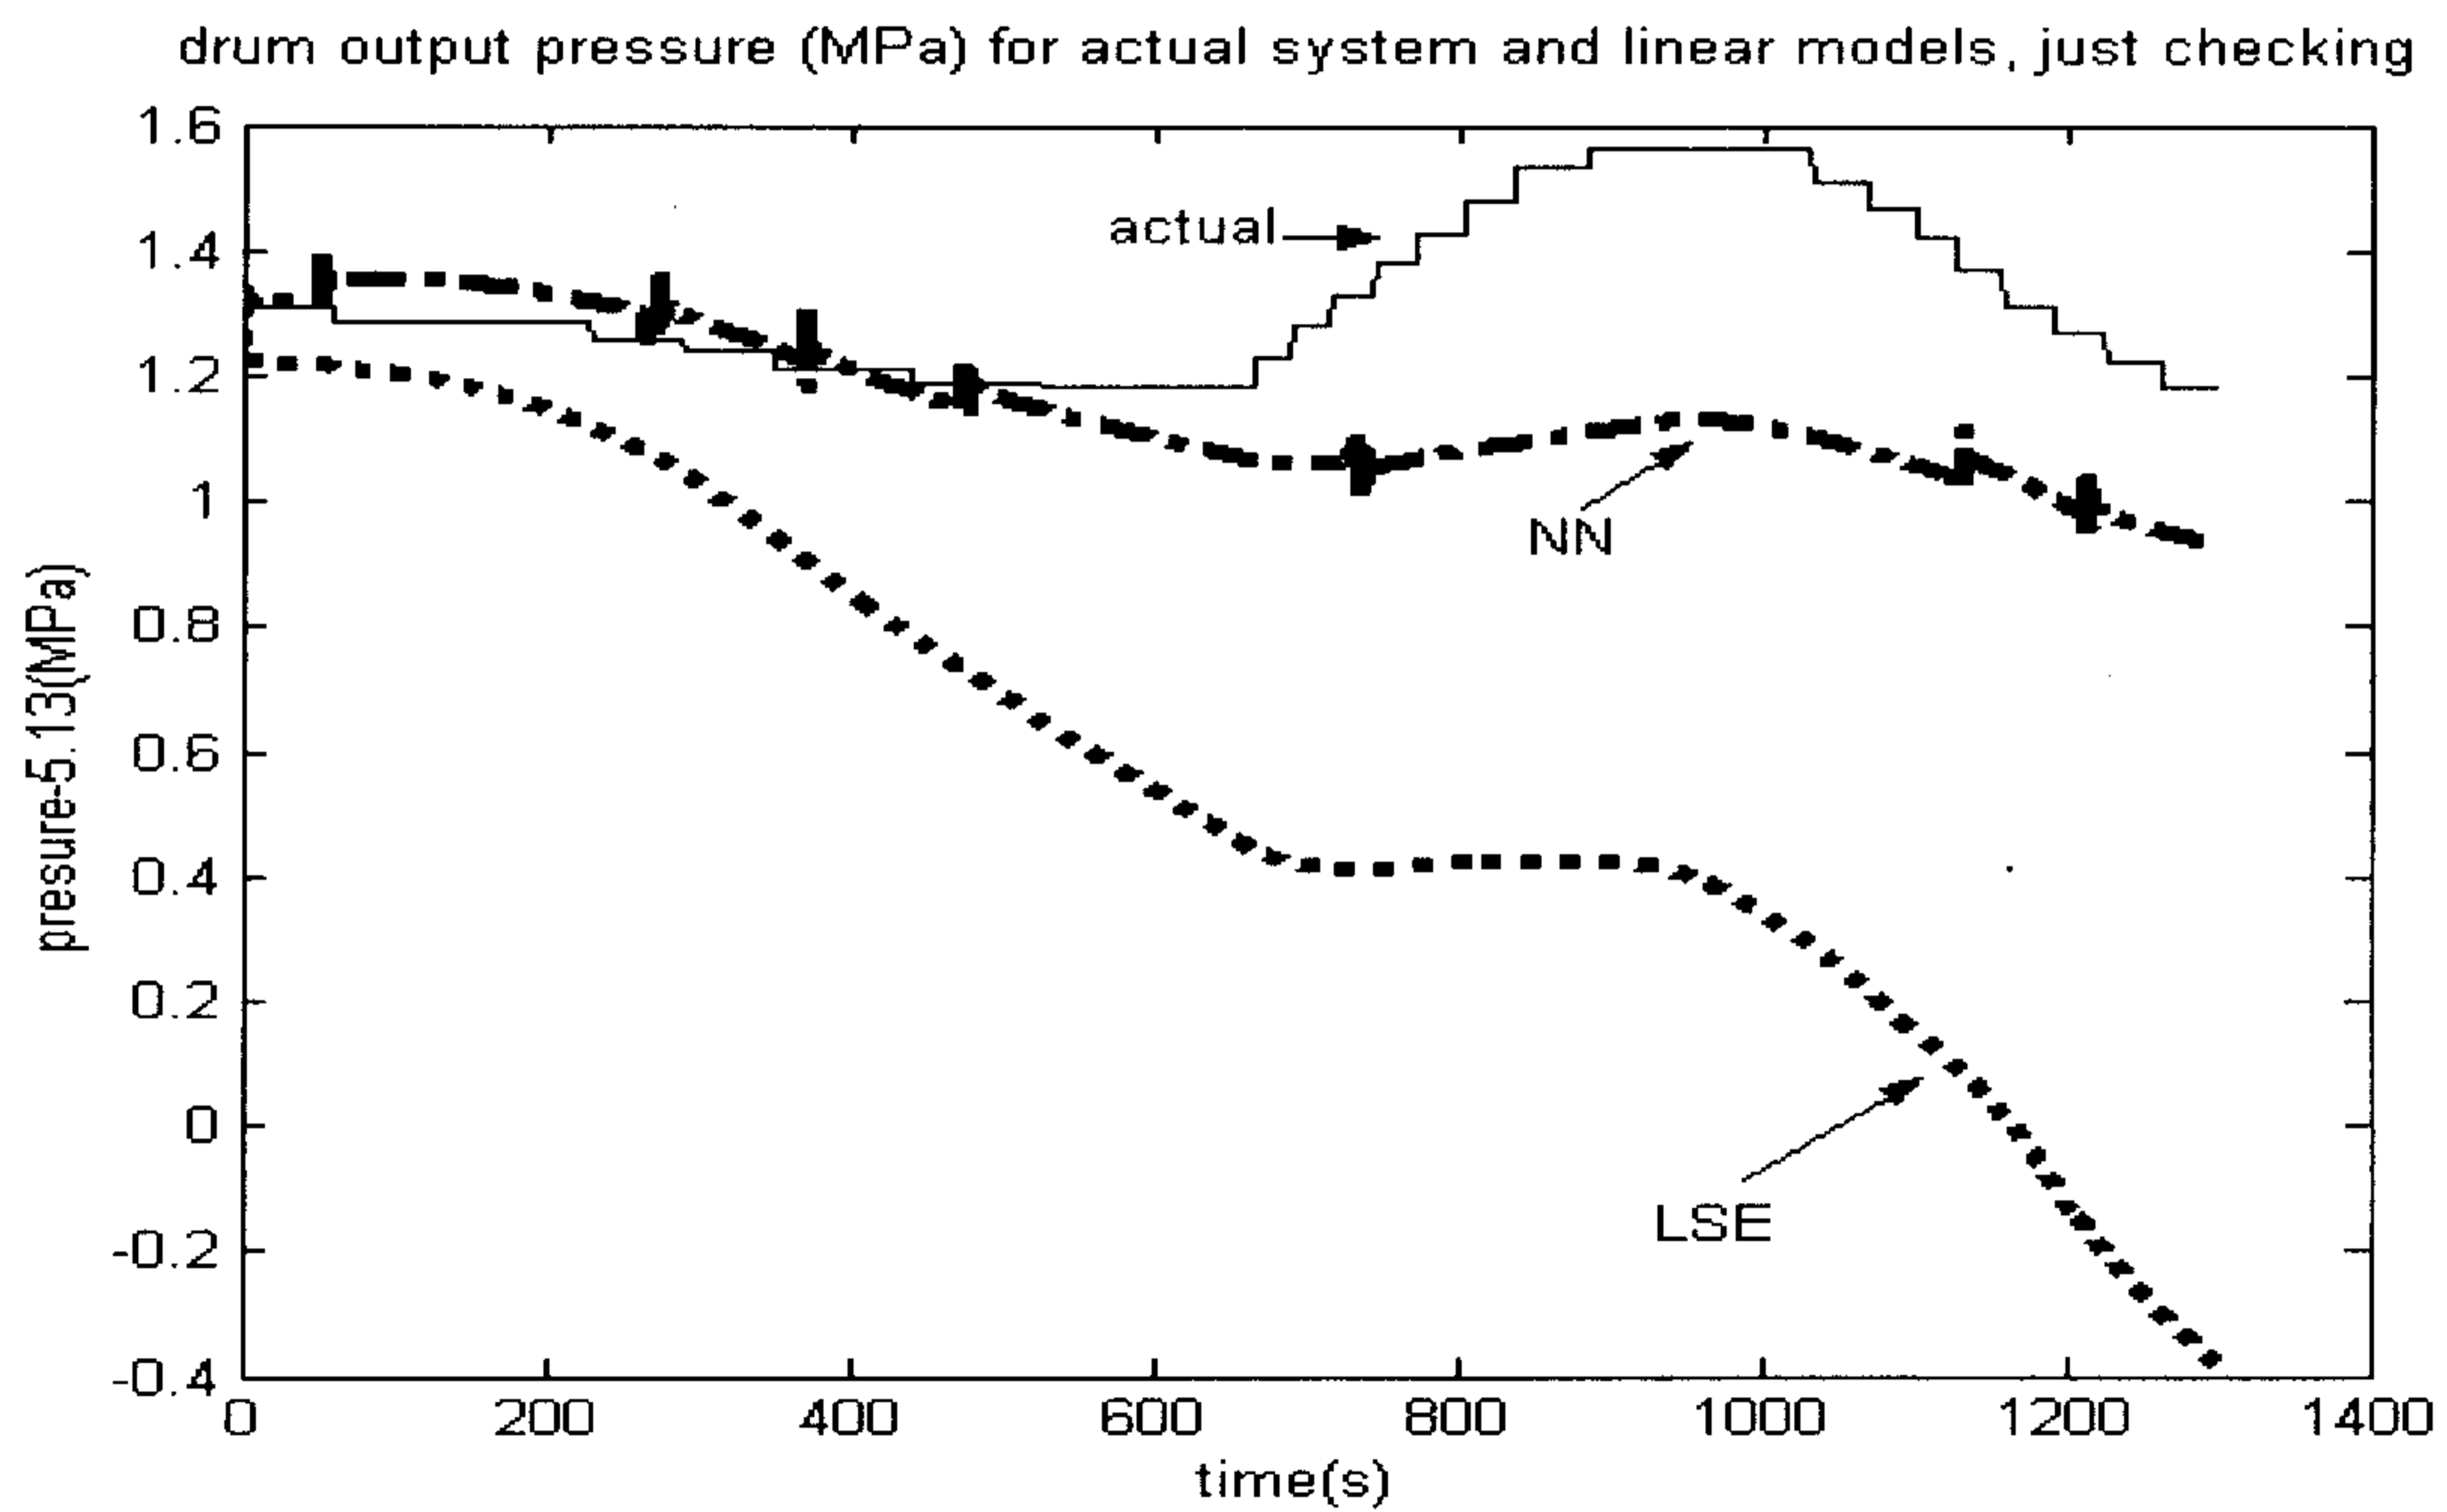
با آموزش داده های ثابت شده به شبکه، وزنهای شبکه که همان پارامترهای تابع تبدیل گسسته باشند، در حد دقت شبکه، به دست می آیند.

نتایج

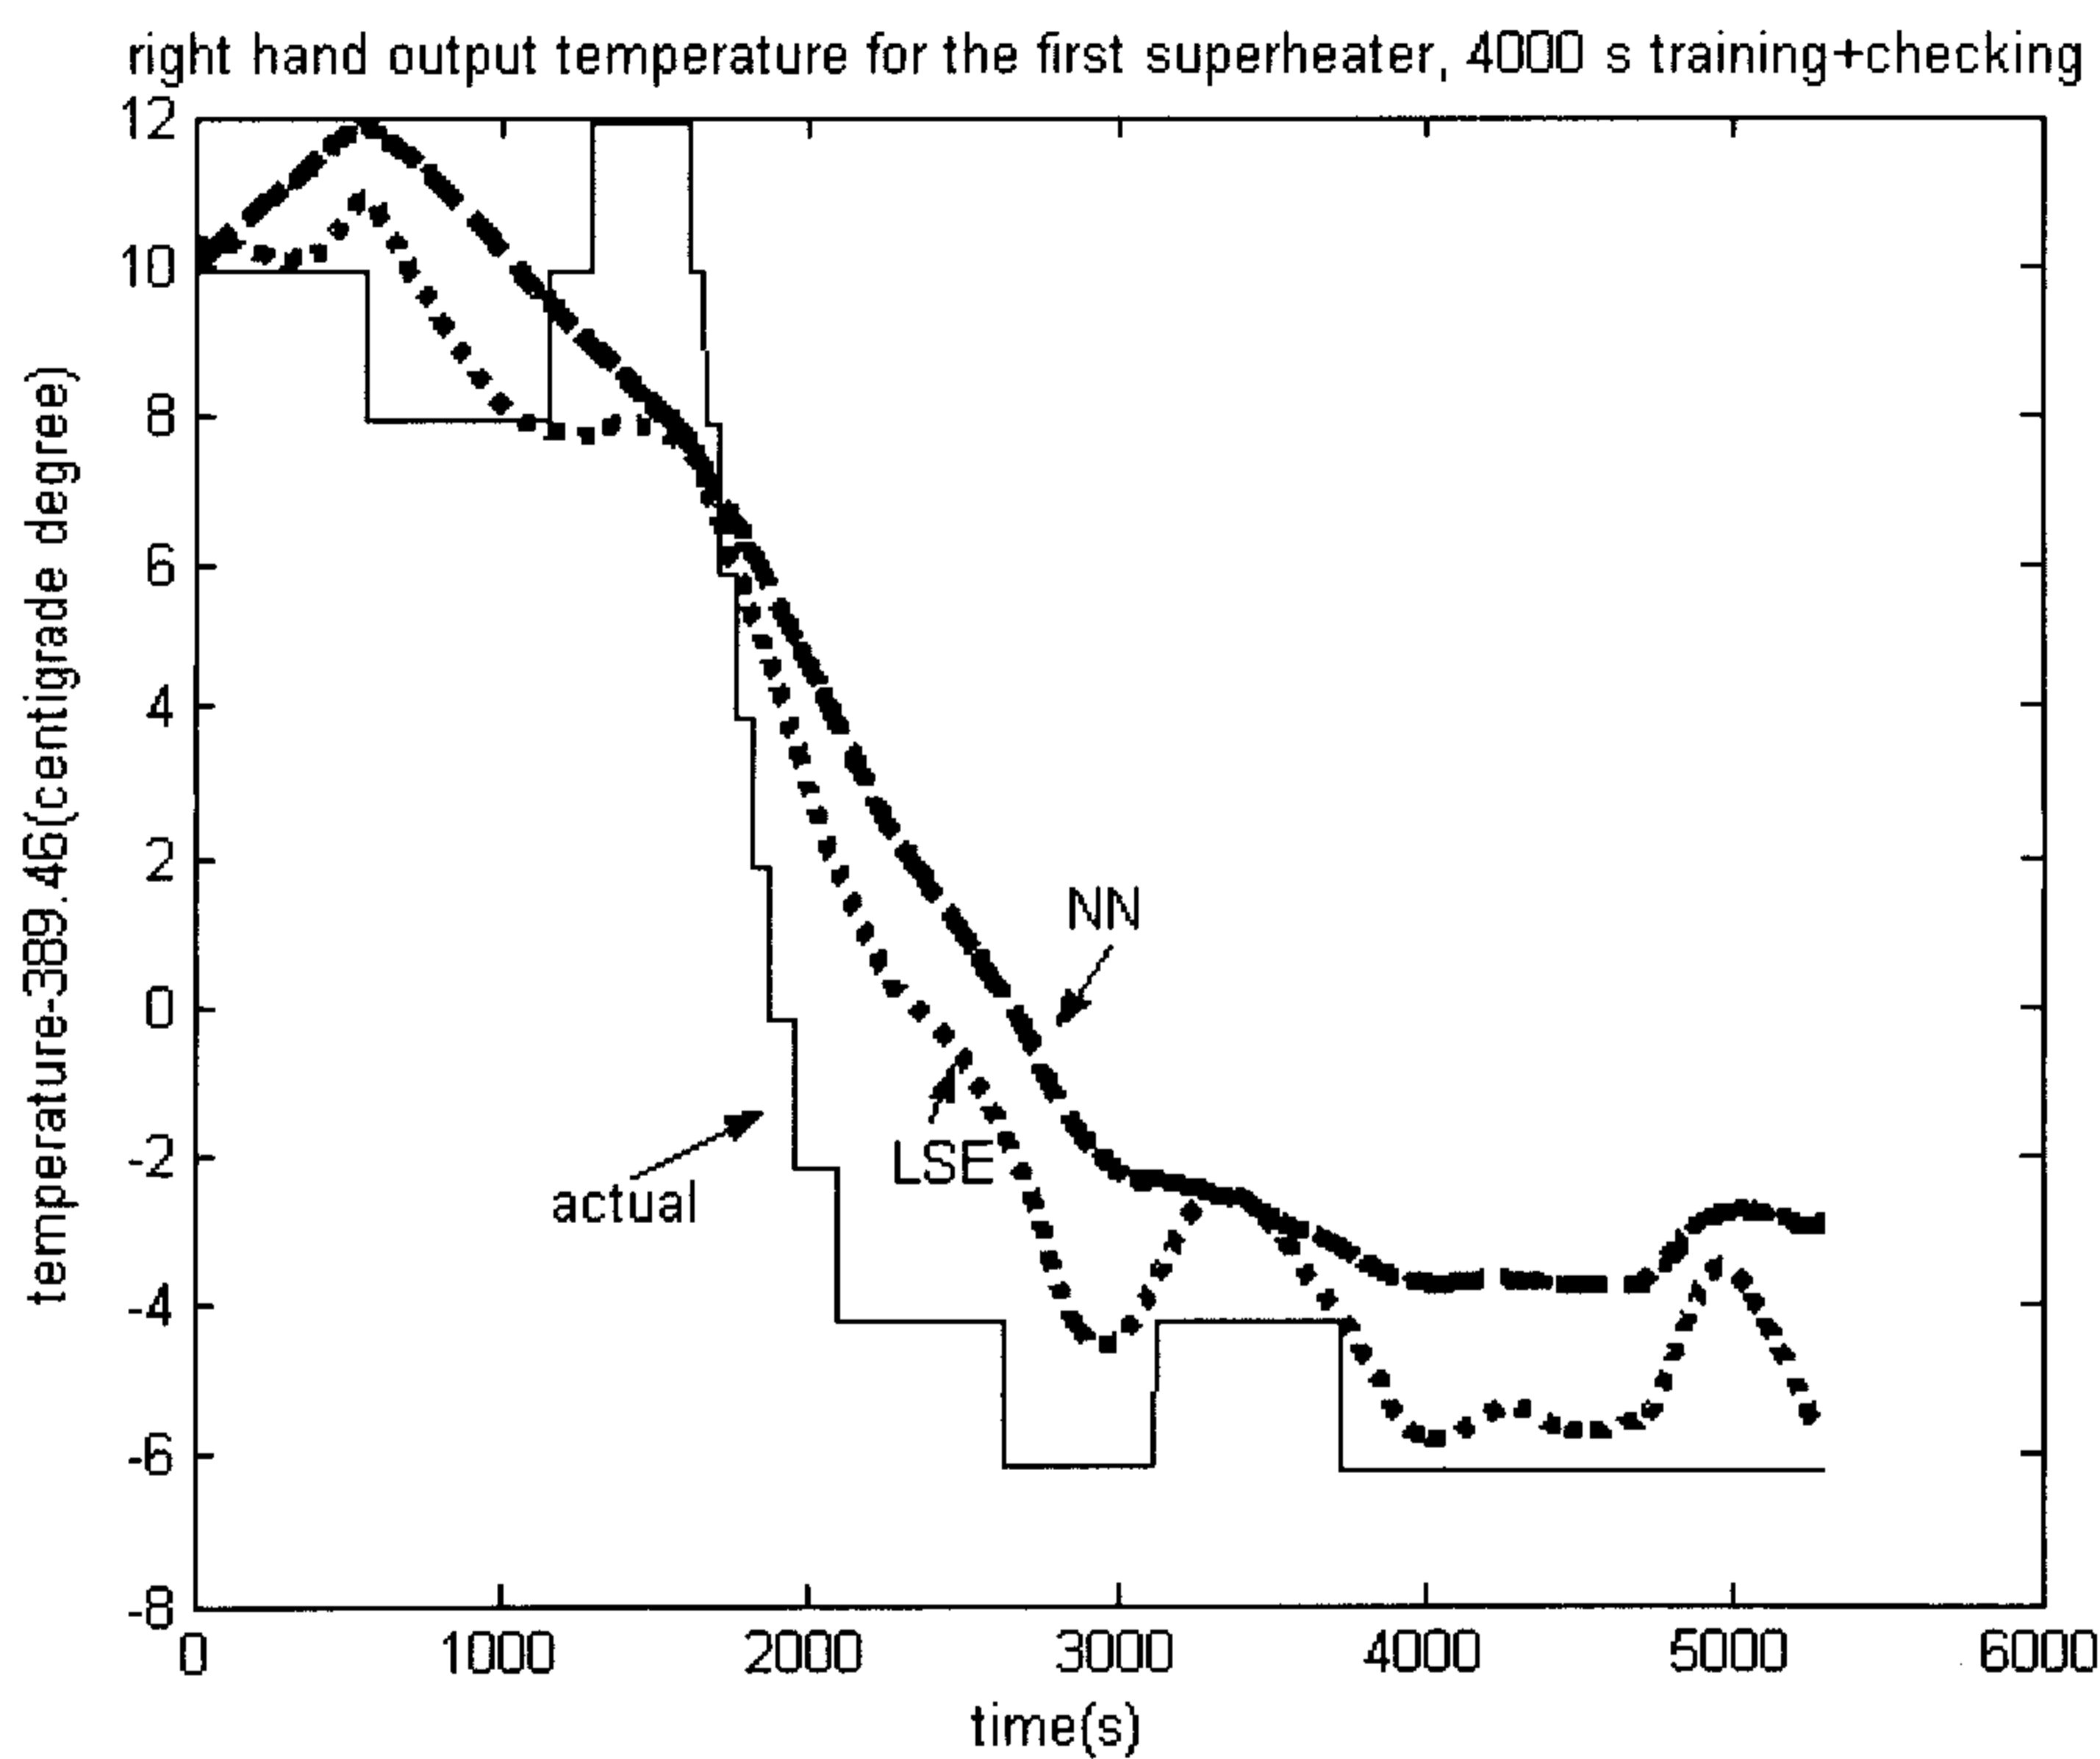
این روش مدلسازی در مورد قسمتهای مورد بررسی نیروگاه امتحان شده است. از ۴۰۰۰ دسته داده ورودی- خروجی با فواصل یک ثانیه ای (از مبدأ ساعت ۱۳ روز ۸۳/۶/۲۷) در آموزش شبکه های عصبی استفاده شده است.

در واقع برای اجزای نیروگاه، مدل‌های ریاضی به دست آمده از ترمو دینامیک از دقت و عمومیت کافی برخوردار

مدلسازی، در شکل (۵) ارائه شده اند. اما در مورد سوپر هیترها، به علت ساختار خطی آنها، به نظر نمی رسد ، هیچ شبکه عصبی ، طبق روش پیشنهادی ، بتواند در مدلسازی با LSE رقابت کند(شکل ۶).




شکل ۵: نتیجه مدلسازی خطی درام با شبکه عصبی و روش LSE.




شکل ۶: مقایسه نتیجه مدلسازی خطی (با شبکه عصبی و به روش LSE) با داده های واقعی برای یک سوپر هیتر.

The second left hand de-super heater output for actual and linear models for checking data



شکل ۷: مقایسه نتیجه مدل‌سازی خطی (با شبکه عصبی و به روش LSE) با داده های واقعی برای یک دی سوپر هیتر.

The second left hand de-super heater output for actual and linear models for checking data



شکل ۸: مقایسه نتیجه مدل‌سازی خطی (با شبکه عصبی و به روش LSE) با داده های واقعی برای یک دی سوپر هیتر.

ارائه شده است. اگر برای این دی سوپر هیتر دمای قبل از پاشش را با T_b ، دبی پاشش را با V و جریان بخار تقریبی گذرنده از آن را با f نمایش دهیم و دمای جریان بخار بعد از پاشش را T_a بنامیم. و طبق روش پیشنهادی، ورودیها را بدون تأخیر (این تأخیر جدا از تأخیری است که در آماده سازی داده ها، لحاظ شده است) و با یک و دو ثانیه تأخیر به ترتیب وارد شبکه کنیم

در مورد دی سوپر هیترها گرچه تابع تبدیل به دست آمده از روش LSE، بر خلاف درام، کاملاً بی ارزش نیست، ولی به دست آوردن شبکه های عصبی خطی، طبق روش پیشنهادی، که نتایجی بهتر از روش LSE بدهند، چندان مشکل به نظر نمی رسد. در شکل‌های (۷) و (۸)، نتایج مدل‌سازی دی سوپر هیتر دوم سمت چپ واحد اول نیروگاه شازند، برای داده های استفاده نشده در مدل‌سازی،

$$T_a = \left(\frac{0.14z^{-1} - 0.15}{-0.01z^{-3} + 0.02z^{-2} - 0.99z^{-1} + 1} \right) T_b + \left(\frac{-0.02z^{-1}}{-0.01z^{-3} + 0.02z^{-2} - 0.99z^{-1} + 1} \right) V + \left(\frac{0}{-0.01z^{-3} + 0.02z^{-2} - 0.99z^{-1} + 1} \right) f \quad (۶)$$

آنچه در همه این توابع تبدیل مشترک است. ناچیز بودن اثر دبی بخار گذرنده از محدوده پاشش (f) بر دمای بخار در محدوده بعد از پاشش (T_a)، است. این موضوع در طراحی کنترلی که، در کنار خروجی یا بازخورد، سایر عوامل مؤثر بر سیستم، را هم در تعیین ورودی کنترلی لحاظ می کند [۱۴]، در نظر گرفته شد. به طوری که دمای قبل از پاشش (T_b) در آن لحاظ گردید ولی از در نظر گرفتن اثر دبی بخار گذرنده (f) در طراحی کنترل صرف نظر شد. به نظر نمی رسد، دیگر مدلها، به این وضوح، چنین موضوعی را نشان دهند. این مزیتی دیگر در کنار، مزیت اصلی مدلهای خطی، یعنی امکان استفاده از آنها در طراحی کنترلهای خطی می باشد.

نتیجه گیری و بحث

با توجه به مطالب ارائه شده، روش پیشنهادی، که به طراحی و آموزش یک شبکه عصبی دو لایه بر اساس داده های ورودی- خروجی می انجامد. برای به دست آوردن مدلهای خطی از اجزای غیرخطی بویلر نیروگاه، که در محدوده کاری اعتبار داشته باشند، کارآمد و مناسب به نظر می رسد. با در نظر گرفتن، عدم وجود مدلهای ریاضی دقیق و کلی، برای اکثر اجزای بویلر و لزوم دستیابی به توابع تبدیل آنها برای اصلاح دوره ای ضرایب کنترلهای خطی، استفاده از این روش، در عملیات بهینه سازی سیستمهای کنترلی نیروگاهی، قابل توصیه است.

و خروجی هم با یک، دو و سه ثانیه تأخیر به شبکه عصبی وارد نماییم (یک شبکه 1×12). پس از آموزش شبکه با داده های تجربی، به وسیله الگوریتم پس انتشار خطا و روش سریعترین کاهش با نرخ آموزش تنظیم شونده و ممنوم، ضرایب وزنها چنین به دست می آیند: (از سمت راست)

$$\begin{matrix} -0.4282 & -0.2336 & 0.3433 & 0.5024 & -0.1376 \\ 0.0033 & 0.0093 & 0.3924 & & \\ 0.5144 & 0.4987 & -0.0382 & -0.0110 & \end{matrix}$$

و این بدین معنی است که تابع تبدیل زیر برای این سیستم به دست می آید:

$$T_a = \left(\frac{-0.34z^{-2} + 0.50z^{-1} - 0.43}{-0.51z^{-3} - 0.50z^{-2} + 0.04z^{-1} + 1} \right) T_b + \left(\frac{0.39z^{-2} - 0.43z^{-1} - 0.02}{-0.51z^{-3} - 0.50z^{-2} + 0.04z^{-1} + 1} \right) V + \left(\frac{0.01z^{-2} + 0.00z^{-1} - 0.01}{-0.51z^{-3} - 0.50z^{-2} + 0.04z^{-1} + 1} \right) f \quad (۴)$$

نتیجه مدلسازی با این شبکه (NN1) در شکل (۷) دیده می شود. برای شبکه عصبی دیگر (NN2)، نشان داده شده در شکل (۸) هم این تابع تبدیل به دست می آید:

$$T_a = \left(\frac{0.11z^{-2} + 0.04z^{-1} - 0.13}{0.14z^{-3} - 0.52z^{-2} - 0.60z^{-1} + 1} \right) T_b + \left(\frac{0.40z^{-2} - 0.05z^{-1} + 0.40}{0.14z^{-3} - 0.52z^{-2} - 0.60z^{-1} + 1} \right) V + \left(\frac{0.01z^{-2} - 0.07z^{-1} + 0.06}{0.14z^{-3} - 0.52z^{-2} - 0.60z^{-1} + 1} \right) f \quad (۵)$$

تابع تبدیل به دست آمده از روش LSE نیز چنین است:

مراجع

- 1 - Simon Haykin, (1999). *Neural Networks A Comprehensive Foundation*, 2nd edition, Prentice-Hall, Inc.
- 2 - Jyh-Shing Roger Jang, Chuen-sai Sun, Eiji Mizutani. (1997). *Neuro-Fuzzy and Soft Computing*. Prentice-Hall, Inc.
- 3 - Slotine, J. J. E. and Li, W. (1991). *Applied Nonlinear Control*. Printice Hall Inc.

- ۴ - فاضلی، ع. خ. (مترجم). "تجربیات پیشرفته نیروگاهی، جلد ۱۴، کنترل و ابزار دقیق." انتشارات دانشگاه علم و صنعت ایران، (۱۳۷۷).
- ۵ - حسینعلی پور، س. م. "طراحی و مدلسازی مدار باز نیروگاه حرارتی." پروژه کارشناسی ارشد دانشگاه تربیت مدرس دانشکده فنی و مهندسی، (۱۳۶۹).
- 6 - Alessandri, A. and Parisini, (1995). "Nonlinear modeling and state estimation in a real power plant using neural networks and stochastic approximation." *Proceedings of American Control Conference*, Seale, Washington, PP. 1561-1567.
- 7 - Lingji chen, Kumpati S. Narendra, (2004). "Identification and control of nonlinear discrete systems based on its linearization: a unified frame work." *IEEE Transaction on Neural Networks*, Vol. 15, No.3, PP. 663-673.
- 8 - Fazlur Rahman, M.H.R., Rajagopalan Devanathen, and Zha Kuanyi, (2000). "Neural network approach for linearizing control of nonlinear process plants." *IEEE Transaction Industrial Electronics*, Vol. 47, No.2, PP. 470-477.
- 9 - Tosuio Tsuji, Nan Bu, Osamu Fakuda and Makoto Kaneko, (2003). "A recurrent log-linearized gaussian mixture network." *IEEE Transaction on Neural Networks*, Vol. 14, No. 2, PP. 304-316.
- 10 - Jin-Hao Juang, Hao-Hiang Chang, and Kai-Chang Cheng, (2002). "Intelligent landing control using linearized inverse air craft model." *Proceedings of American Control Conference*, Anchorage, AK May 8-10, PP. 3269-3274 .
- 11 - Qiang Gao and Harris, Chris J. (1999). "Linearization and state estimation of unknown discrete-time nonlinear dynamic systems using recurrent neurofuzzy networks." *IEEE Transaction on System, Man, Cybernetics. Part B: Cybernetics*, Vol. 29, No.6, PP. 802-817.
- 12 - Ghezelayagh, Kwang, H. and Lee, Y. (1999). "Training neuro-fuzzy boiler identifier with genetic algorithm and error-back propagation." *Power Engineering Society Summer Meeting, IEEE*, Vol. 2, PP. 978 – 982.
- 13 - Xiang-Jie Lin, Felipe Lara-Rosano, and Chan, C.W (2003). "Neurofuzzy network modeling and control of steam pressure in 300 MW steam-boiler system." *Engineering Application of Artificial Intelligence Conference* , Vol. 16, PP. 431-440.
- ۱۴ - غفاری، ع.، محمدظاهری، م. و مهرابی، د. "طراحی کنترلر فازی برای یکی از دی سوپرهیترهای نیروگاه شازند با روش دینامیک معکوس." لوح فشرده ششمین کنفرانس تخصصی قدرت، دانشگاه صنعت آب و برق، ۲۱-۲۳ مهرماه (۱۳۸۳).

واژه های انگلیسی به ترتیب استفاده در متن

- 1 - Iterative
- 2 - Feedback Linearization
- 3 - Activation Function