

## شناسایی فرایند برج اسپلیتر واحد پنتان پالایشگاه کرمانشاه

محسن آزادی<sup>۱</sup>، مهدی علیاری شوره دلی<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد مهندسی کنترل، دانشگاه آزاد اسلامی واحد تهران جنوب، مهندس ارشد شرکت پالایش نفت کرمانشاه

<sup>۲</sup> استادیار دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی برق و کامپیوتر، گروه مکترونیک

دریافت: ۹۱/۱۰/۱۲ پذیرش: ۹۲/۲/۲۴

### چکیده

واحد پنتان یکی از واحدهای فرعی پالایشگاه کرمانشاه است. هدف اصلی این واحد جداسازی گاز پنتان از بنزین سبک به عنوان محصولی ارزشمند و دارای ارزش افزوده است. آگاهی از کیفیت محصول در این واحد از ضروریات است زیرا باعث کمک به کنترل صحیح فرایند، تولید و فروش بیشتر و نهایتاً حاشیه سود بالاتر خواهد شد. برای نیل به این منظور شناسایی این واحد ضروری است. در این تحقیق برج اسپلیتر که محصول نهایی از آن خارج می شود بر اساس مدل های دینامیکی هوشمند توسط شبکه های عصبی MLP و RBF مورد شناسایی قرار گرفته است. نتیجه شبیه سازی برج موفقیت آمیز بوده و خروجی های بالا و پائین برج اسپلیتر به عنوان دو محصول واحد، مورد شبیه سازی قرار گرفته اند. برای خروجی اول شبکه MLP و برای خروجی دوم شبکه RBF دارای کمترین میانگین مربعات خطا بوده و نتیجه مطلوبی داده اند بنابراین چنانچه در عمل بخواهیم از این شبیه سازی استفاده کنیم با رعایت شرایط فوق می توانیم از نتایج این تحقیق استفاده کنیم.

**کلمات کلیدی:** شناسایی غیر خطی، واحد پنتان، برج اسپلیتر

### مقدمه

واحد پنتان شامل بخش هایی از جمله: برج فرکچنیاتور<sup>۱</sup>، برج اسپلیتر<sup>۲</sup>، واحد تولید نیتروژن با خلوص بالا برای بلنکتینگ<sup>۳</sup> و واحد ذخیره سازی گاز پنتان است. بعلاوه گرماگیر بودن واکنش جداسازی، حرارت مورد نیاز از طریق تشعشع در مبدل های حرارتی<sup>۴</sup> و با استفاده از بخار آب دریافت می شود که با هزینه بالایی تولید می شود.

\* aliyari@eetd.kntu.ac.ir

<sup>۱</sup> Fractionator Tower

<sup>۲</sup> Splitter Tower

<sup>۳</sup> Blanketing

<sup>۴</sup> Heat Exchanger

بخش اعظمی از تلاش مهندسان در صنعت این است که بر اساس مدل‌های ریاضی طراحی‌های خوبی انجام دهند. آنها همچنین این مدل‌ها را برای شبیه‌سازی و یا پیش‌بینی رفتار سیستم‌های طراحی شده به کار می‌گیرند. [۱۲]

بنابراین برای بررسی و بهینه‌سازی امر تولید، ایجاد یک مدل که بتواند این فرایند را شناسایی کند بسیار ضروری است. به همین منظور مدل‌سازی انجام می‌شود. در نتیجه هنگام راه اندازی واحد و در جریان تولید، به جای تغییرات مکرر در واحد که مستلزم زمان و هزینه بالایی است، تغییرات را در مدل اعمال کرده و سپس سیستم را بهینه‌سازی می‌کنند. با ثبت اطلاعات ورودی و خروجی سیستم تحت آزمایش و با استفاده از الگوریتم‌های شناسایی سیستم<sup>۱</sup>، مدل سیستم تعیین می‌شود. مدل به دست آمده لزوماً بیانگر سیستم واقعی به صورت دقیق نیست و در حقیقت تقریبی از آن است. اما آنچه مهم است این است که این مدل تا چه حد رفتار سیستم را به خوبی توصیف می‌کند. در مدل‌سازی با هدف شبیه‌سازی، ملاک ارزیابی مدل، مربع خطای بین خروجی مدل و خروجی فرآیند واقعی است. [۳]

شناسایی غیرخطی سیستم‌ها کار بسیار مشکلی است زیرا هر سیستم غیرخطی، رفتار مربوط به خود را دارد، کیفیت مدل‌سازی توسط به دست آوردن یک تابع خطا بین خروجی سیستم و خروجی مدل سنجیده می‌شود. این خطا برای تنظیم پارامترهای مدل استفاده می‌شود. [۴]

برای شناسایی این سیستم غیر خطی نیاز به یک ابزار مناسب وجود دارد و این ابزار، شبکه‌های عصبی است. شبکه‌های عصبی بطور موفقیت آمیزی برای مدل‌سازی سیستم‌های دینامیکی مورد استفاده قرار گرفته‌اند. [۵] به عبارت دیگر بکارگیری تکنولوژی کنترل هوشمند بر پایه روش محاسبات نرم-که شبکه عصبی از نمونه‌های آن است- می‌تواند به طور قابل ملاحظه‌ای قابلیت‌های متنوع استفاده از کنترل پیشرفته را در صنایع فرایندی از قبیل پالایشگاه‌ها بهبود بخشد. [۱۴] - [۶]

در این پژوهش به منظور شناسایی غیر خطی سیستم<sup>۲</sup> از شبکه‌های عصبی MLP و RBF استفاده شده است. واحد پنتان پالایشگاه کرمانشاه

واحد پنتان پالایشگاه کرمانشاه نتیجه یک طراحی و اجرای موفق داخلی توسط پژوهشگاه صنعت نفت است که برای اولین بار در کشور در مقیاس تجاری در این پالایشگاه احداث شده است. هدف عملیاتی این واحد جداسازی پنتان از بنزین سبک<sup>۳</sup> است. ورودی واحد، بنزین سبک خروجی از واحد پلاتفرمیت<sup>۴</sup> و محصول آن نرمال پنتان با خلوص بالای ۹۸ درصد است. مشتری این محصول واحدهای پتروشیمی هستند. خلوص بالای محصول، یک پارامتر کلیدی برای خرید آن توسط مشتری است. بنابراین حفظ جریان تولید و سودده بودن محصول مشروط به حفظ کیفیت آن است. برج‌های فرکچنیتور و اسپلیتر به عنوان جداکننده‌های محصول از بنزین سبک عمل می‌-

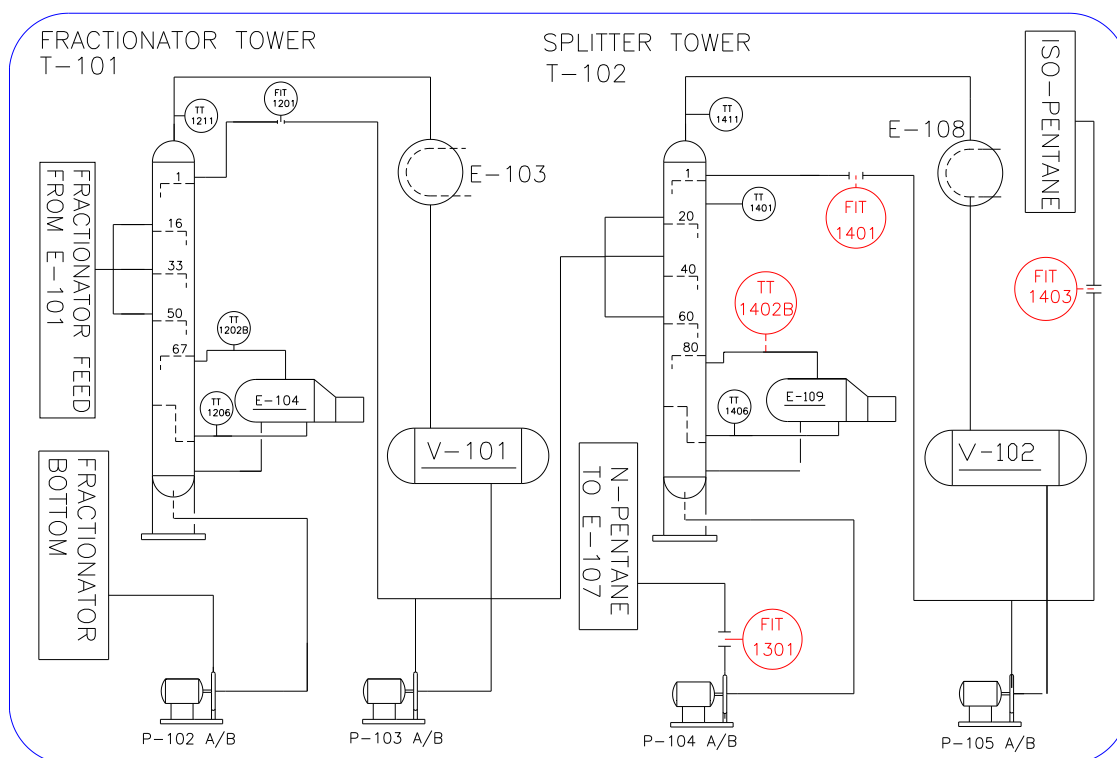
<sup>1</sup> System Identification

<sup>2</sup> Non Linear System Identification

<sup>3</sup> Light Straight Run Gasoline (LSRG)

<sup>4</sup> Platfornate

کنند. خروجی برج اول، پنتان با خلوص حدود ۵۰ درصد است که ترکیبی از نرمال و آیزوپنتان و هگزان و هپتان است. ترکیبات سبکتر از بالای برج خارج می‌شوند و به عنوان ورودی به برج دوم وارد می‌شوند. این برج نقش کلیدی در جداسازی نهائی و تولید محصول باکیفیت دارد، محصول نهائی محتویات ته این برج است. در شکل ۱ فلوریداگرام ساده شده واحد نشان داده شده است.




شکل ۱. فلوریداگرام ساده شده واحد پنتان

### مدل سازی


**پیش پردازش داده‌ها:** هنگامی که از فرایند نمونه برداری شده و داده‌ها جمع آوری می‌شوند، این داده‌ها لزوماً برای شناسایی سیستم مناسب نیستند و نیاز به پیش پردازش دارند. این داده‌ها ممکن است دارای معایبی باشند. از جمله این معایب می‌توان به ثبت نامنظم داده‌ها اشاره کرد. زیرا ممکن است نمونه برداری از داده‌ها (ورودی‌ها و خروجی‌ها) با فواصل زمانی یکسانی صورت نگرفته باشد. بنابراین با انتخاب آن دسته از داده‌هایی که در زمان‌های یکسان نمونه‌برداری شده‌اند می‌توان داده‌های مناسب برای شناسایی را گزینش کرد. به بیان علمی‌تر، با انتخاب بزرگترین زمان نمونه‌برداری بین دسته داده‌ها این امر محقق می‌شود. برای مثال، زمان نمونه-برداری برای ورودی اول (FT-1401)، خروجی اول (FT-1403) و خروجی دوم (FT-1301)، ۵ ثانیه و برای

ورودی دوم (TT-1402B)، ۳۰ ثانیه است. از این رو به منظور شناسایی فرایند، زمان ۳۰ ثانیه به عنوان زمان نمونه‌برداری انتخاب می‌شود. مساله دیگری که در پیش پردازش داده‌ها باید مورد توجه قرار داد تفاوت داده‌ها از لحاظ نوع کمیت و گستره عددی آن‌ها است. برای مثال، ورودی اول (FT-1401)، خروجی اول (FT-1403) و خروجی دوم (FT-1301) از جنس فلو ( $m^3/Hr$ ) هستند و ورودی دوم (TT-1402B) از جنس دما ( $^{\circ}C$ ) است. به عنوان راه حل می‌توان به جای استفاده از داده‌های با مقادیر واقعی، مقدار نرمالیزه شده آن‌ها استفاده نمود. بدین صورت که برای داده  $D$  (که می‌تواند هر یک از دو ورودی و یا دو خروجی باشد) و برای نمونه  $d$  از آن، مقدار نرمالیزه شده  $d$  را از رابطه زیر به دست آوریم:


$$d_{norm} = \frac{d - D_{min}}{D_{max} - D_{min}}$$
 که در آن  $d_{norm}$  به ترتیب مقدار نرمالیزه شده نمونه  $d$ ، حداقل و حداکثر مقدار  $D$  هستند. این ورودی‌ها و خروجی‌های نرمالیزه و گزینش شده در شکل ۲ تا ۵ نشان داده شده است.




شکل ۲. خروجی اول (FT-1403) و ورودی اول (FT-1401) برای ۶۰۰۰ نمونه



شکل ۳. خروجی اول (FT-1403) و ورودی دوم (TT-1402B) برای ۶۰۰۰ نمونه

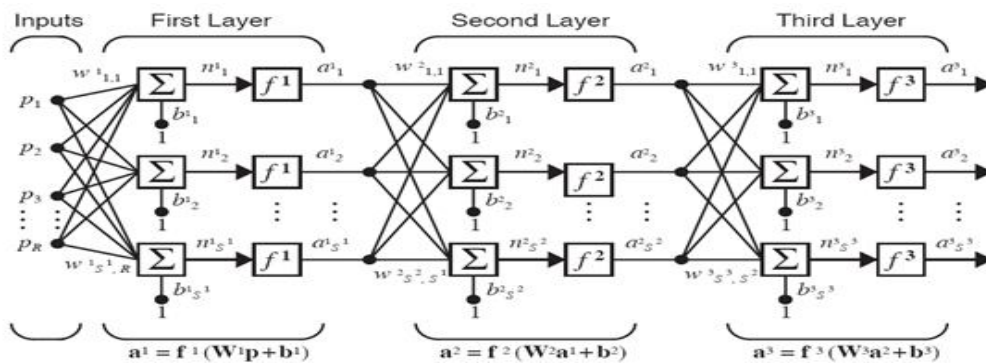


شکل ۴. خروجی دوم (FT-1301) و ورودی اول (FT-1401) برای ۶۰۰۰ نمونه



شکل ۵. خروجی دوم (FT-1301) و ورودی دوم (TT-1402B) برای ۶۰۰۰ نمونه

شناسایی و مدل سازی برج Splitter با استفاده از شبکه های عصبی MLP شبکه عصبی MLP، در زمره پرکاربردترین شبکه های عصبی است. شکل ۶ ساختار شبکه MLP را نشان می دهد.




شکل ۶. ساختار شبکه MLP چندلایه [۱۶]

این شبکه از چندین لایه تشکیل شده است که هر کدام از لایه‌ها دارای تعدادی نرون هستند و خروجی این شبکه نیز از معادله زیر بدست می‌آید:

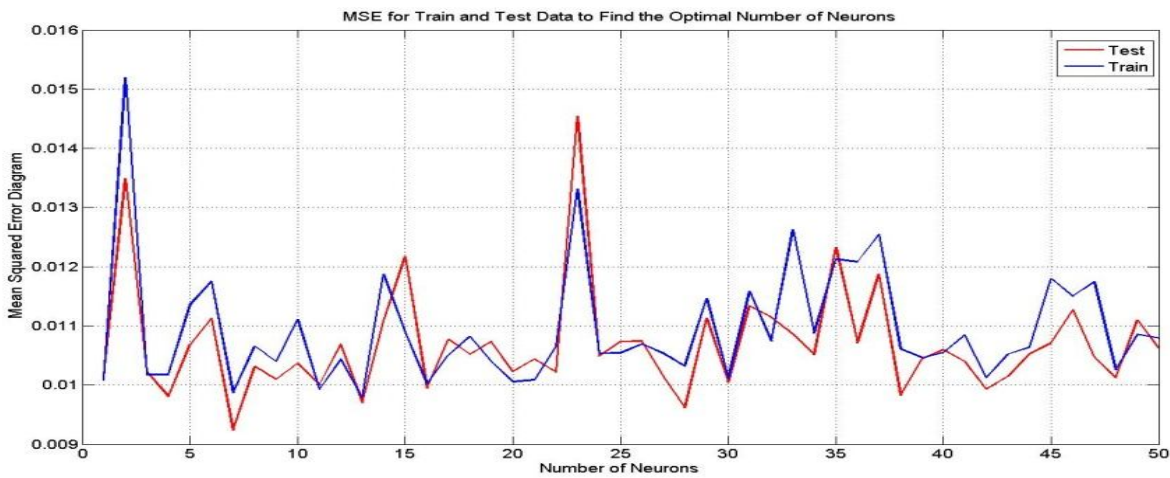
$$a^3 = f^3(w^3f^2(w^2f^1(w^1p + b^1) + b^2) + b^3)$$

با تنظیم درست پارامترها، ضرایب، بایاس‌ها و پارامترهای توابع، ثابت می‌شود که شبکه‌ی عصبی MLP توانایی تقریب هر تابعی با هر دقتی را دارد. [۱۵] در کار شناسایی معمولاً یک یا دو لایه میانی در نظر گرفته می‌شود. در این تحقیق فرایند برج اسپلیتر را به صورت دو سیستم دو ورودی- یک خروجی در نظر می‌گیریم. مسئله مهم در استفاده از شبکه عصبی پرسپترون چند لایه، انتخاب تعداد نرون بهینه می‌باشد چراکه اگر تعداد نرون‌ها بیش از حد باشد باعث پیچیدگی محاسبات و افزایش بیش از حد پارامترها<sup>۱</sup> می‌گردد. برای تعیین تعداد نرون بهینه، ابتدا با تعداد مشخصی نرون شبکه را طراحی کرده و داده‌های آموزش را در آن قرار می‌دهیم تا آموزش ببینند. خروجی مدل بدست آمده دارای میانگین مربعات خطایی خواهد بود. داده‌های تست را نیز در همان شبکه قرار داده و میانگین مربعات خطای آن را نیز بدست می‌آوریم. سپس تعداد نرون‌ها بطور افزایشی زیاد می‌شود و مراحل قبل تکرار می‌شوند تا جایی که مقدار میانگین مربعات خطای داده‌های تست و آموزش در حالت ترسیمی از هم جدا شوند در این صورت تعداد نرون‌های بهینه شبکه عصبی بدست می‌آیند. با استفاده از این روش و با توجه به شکل ۷ و شکل ۸ به این نتیجه می‌رسیم که برای خروجی اول (FT-1403) تعداد بهینه نرون در لایه میانی ۲۲ عدد و برای خروجی دوم (FT-1301) این تعداد برابر با ۱۳ عدد است.




شکل ۷. تعیین تعداد نرون بهینه با استفاده از مقادیر میانگین مربعات خطای داده‌های تست و آموزش برای خروجی FT\_1403

<sup>۱</sup>Over Parametrized



شکل ۸. تعیین تعداد نرون بهینه با استفاده از مقادیر میانگین مربعات خطای داده‌های تست و آموزش برای خروجی FT\_1301

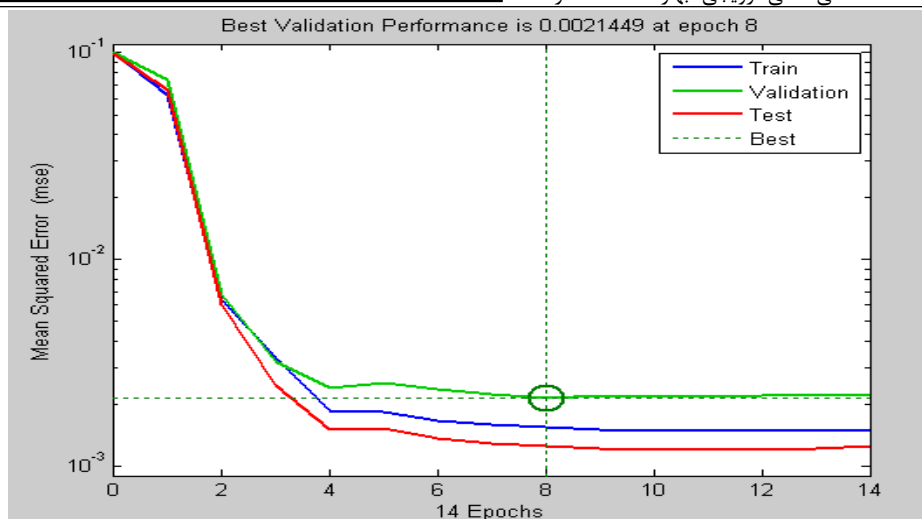
برای تعیین تعداد دفعات آموزش<sup>۱</sup> میانگین مربعات خطا برای داده‌های آموزش و تست با دفعات آموزش مختلف که بصورت افزایشی در حال زیاد شدن هستند محاسبه و رسم می‌شود. محلی که مقدار میانگین مربعات خطای داده‌های آموزش و تست از هم جدا می‌شود بعنوان تعداد دفعات آموزش بهینه انتخاب می‌شود. (شکل ۹، شکل ۱۰)



شکل ۹. نمودار میانگین مربعات خطای تست و آموزش برای افزایش تعداد دفعات آموزش برای خروجی FT-1403

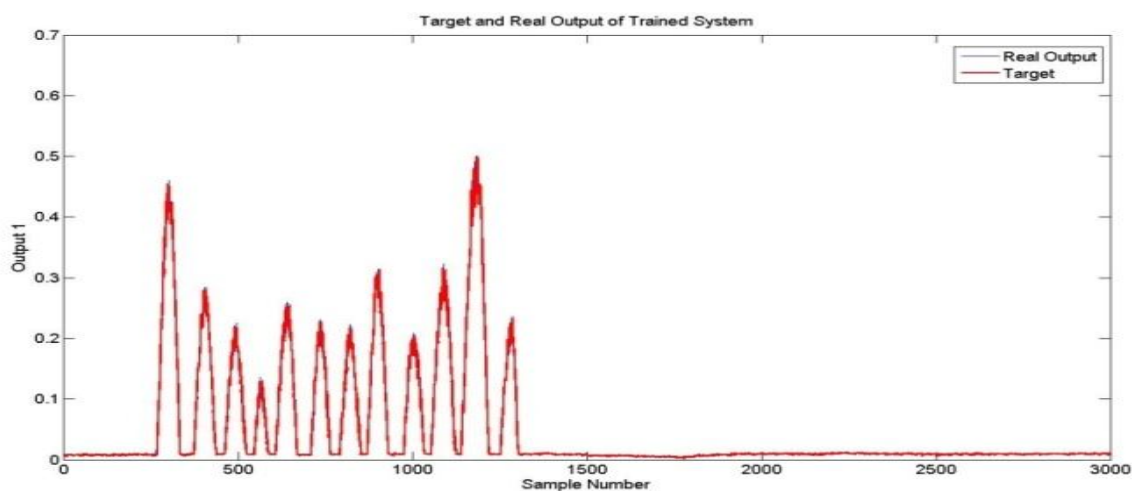
<sup>۱</sup>Epoch






شکل ۱۰. میانگین مربعات خطای تست و آموزش بازای افزایش تعداد دفعات آموزش برای خروجی FT-1301

تعداد دفعات آموزش بهینه شبکه MLP برای زیر سیستم اول (شامل ورودی ها و خروجی اول) برابر با ۴ و این تعداد برای زیرسیستم دوم (شامل ورودی ها و خروجی دوم) برابر با ۸ است. برای زیر سیستم اول، شبکه MLP را با تعداد نرون بهینه ۲۲ و تعداد دفعات آموزش ۴، آموزش می‌دهیم. در ای‌نصورت عملکرد شبکه برای مدلسازی خروجی FT\_1403 بازای داده‌های آموزش و تست و میزان خطای آنها مطابق شکل ۱۱ و شکل ۱۲ است.

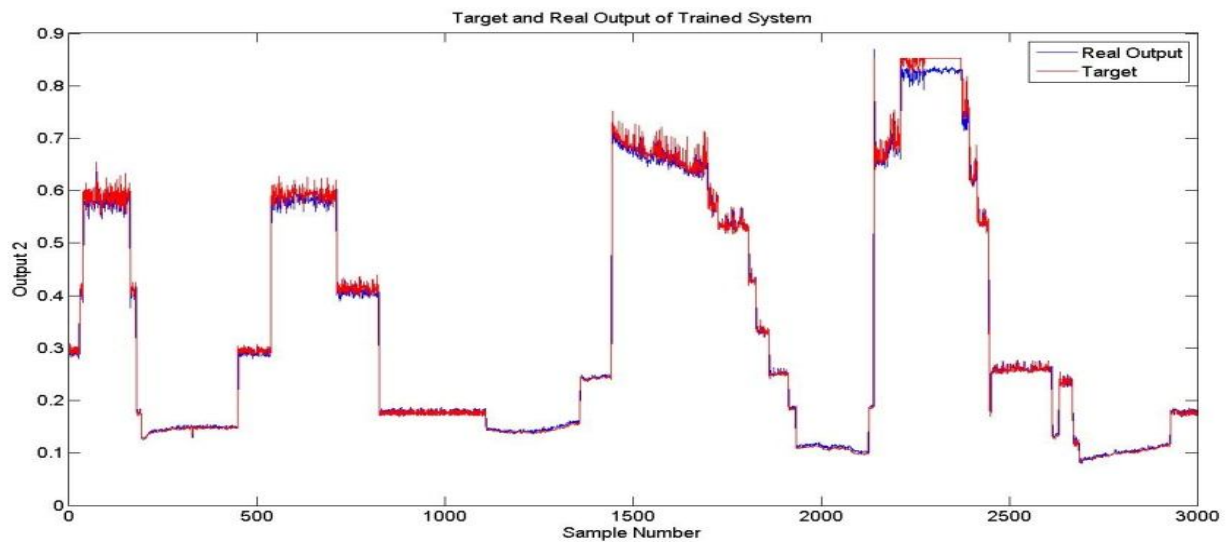


شکل ۱۱. عملکرد شبکه MLP برای مدلسازی خروجی FT\_1403 به ازای داده‌های آموزش

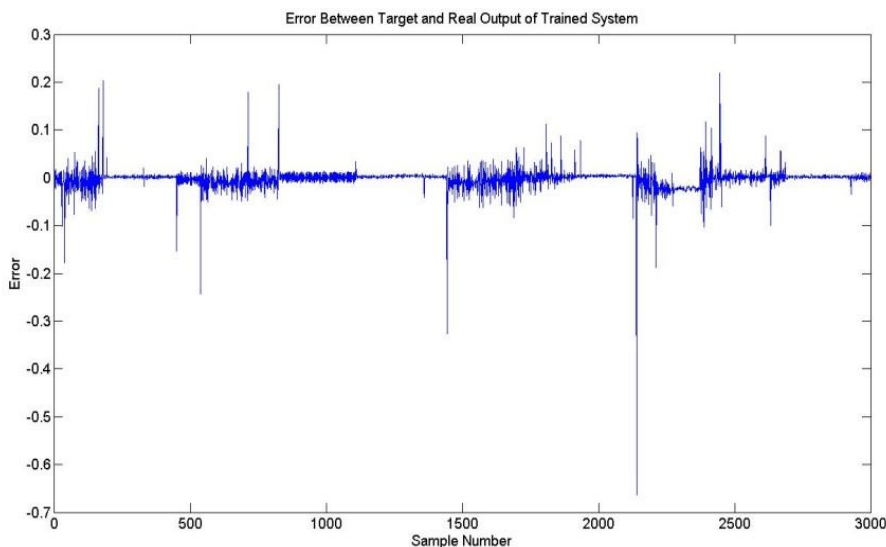


شکل ۱۲. میزان خطا در عملکرد شبکه MLP برای مدل‌سازی خروجی FT\_1403

برای زیر سیستم دوم، شبکه MLP را با مفروضات اولیه، تعداد نرون بهینه ۱۳ و تعداد دفعات آموزش ۸، آموزش می‌دهیم. در اینصورت عملکرد شبکه برای مدل‌سازی خروجی FT\_1301 به ازای داده‌های آموزش و تست مطابق شکل ۱۳ و شکل ۱۴ است.




شکل ۱۳. عملکرد شبکه MLP برای مدل‌سازی خروجی FT\_1301 به ازای داده‌های آموزش



شکل ۱۴. میزان خطا در عملکرد شبکه MLP برای مدل سازی خروجی FT\_1301

شناسایی و مدل سازی برج اسپلیتر با استفاده از شبکه های عصبی RBF این شبکه نسبت به شبکه عصبی MLP تفاوت هایی دارد بدین صورت که این شبکه، شبکه ای با توابع شعاعی حول یک مرکز می باشد. شکل ۱۵ ساختار یک شبکه توابع پایه شعاعی با یک لایه میانی و توابع گوسی را نشان می دهد.



شکل ۱۵. ساختار شبکه عصبی [۱۶]

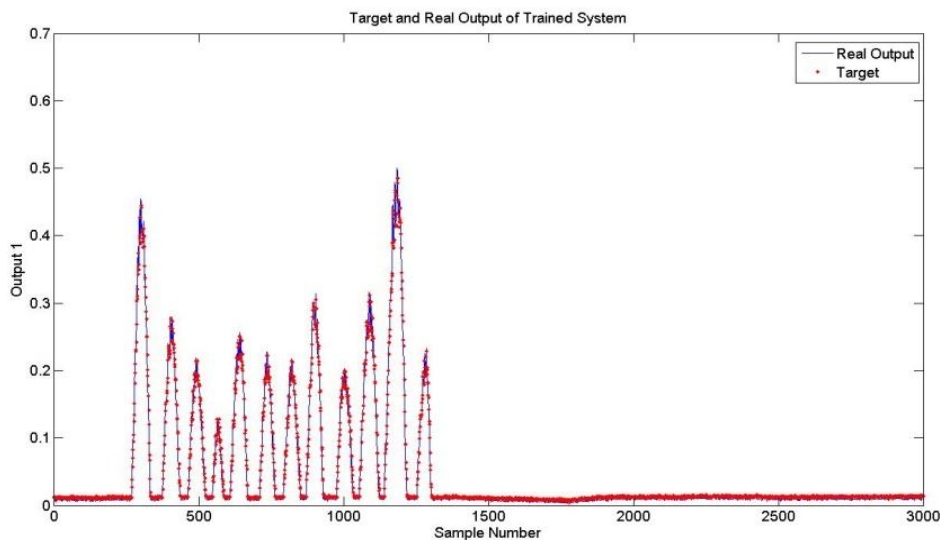
نرون های RBF بصورت موازی با هم استفاده می شوند و همگی به نرون های خروجی متصل می شوند که در این صورت خروجی شبکه عصبی به صورت زیر خواهد بود.

که  $W_i$  ها وزن های لایه خروجی می باشند. برای پیدا کردن تعداد نرون بهینه در طراحی شبکه عصبی ابتدا با تعداد مشخصی نرون شبکه را طراحی کرده و داده های آموزش را در آن قرار می دهیم تا آموزش ببینند. خروجی

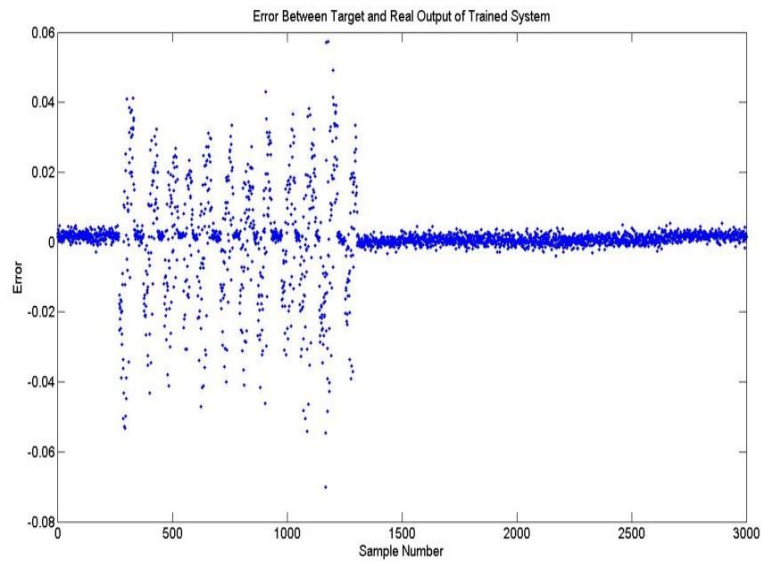
مدل بدست آمده یک میانگین مربعات خطایی پیدا می‌کند. سپس داده‌های تست را نیز در همان شبکه قرار می‌دهیم و میانگین مربعات خطای آن را نیز بدست می‌آوریم. حال تعداد نرون‌ها را افزایش می‌دهیم و همه مراحل قبل را تکرار می‌کنیم تا جایی که میانگین مربعات خطای داده‌های تست و آموزش در حالت ترسیمی از هم جدا شوند در این صورت تعداد نرون‌های بهینه شبکه عصبی بدست می‌آید. [۱۷]

با استفاده از شبکه‌های عصبی توابع پایه شعاعی مدلسازی را برای دو خروجی FT-1403 و FT-1301 به صورت تک تک انجام می‌دهیم.

با توجه به این فرضیات عملکرد شبکه RBF برای مدلسازی زیر سیستم اول به ازای داده‌های آموزش و تست و میزان خطای آنها در شکل ۱۶ و شکل ۱۷ آورده شده است.

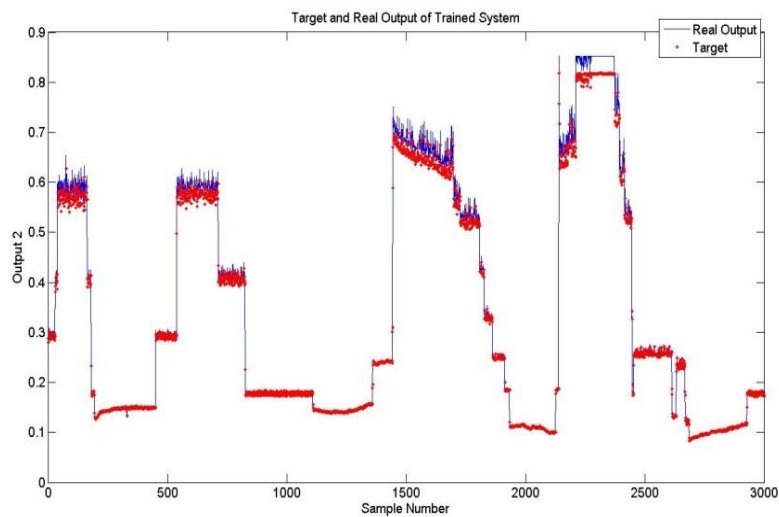


شکل ۱۶. عملکرد شبکه RBF برای مدلسازی خروجی FT-1403 بازای داده‌های آموزش و میزان خطای آن

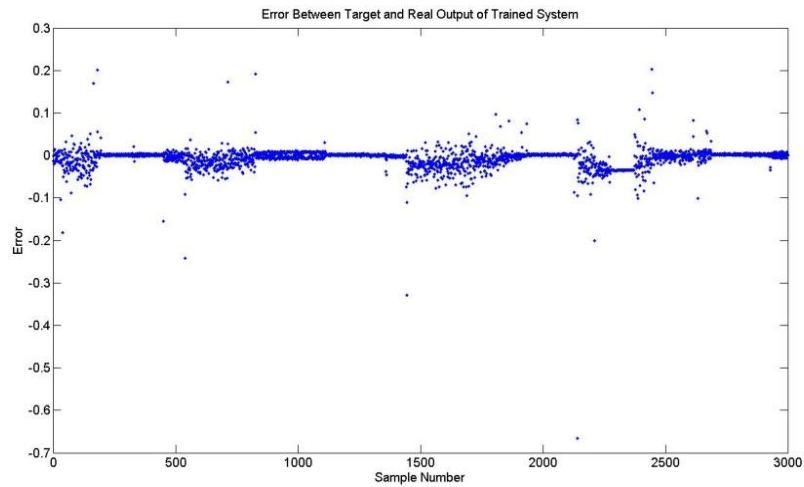


شکل ۱۷. میزان خطا در عملکرد شبکه RBF برای مدل‌سازی خروجی FT\_1403

عملکرد شبکه RBF برای مدل‌سازی زیر سیستم دوم به ازای داده‌های آموزش و تست و میزان خطای آنها در شکل ۱۸ و شکل ۱۹ آورده شده است.



شکل ۱۸. عملکرد شبکه RBF برای مدل‌سازی خروجی FT-1301 به ازای داده‌های آموزش و میزان خطای آن



شکل ۱۹. میزان خطا در عملکرد شبکه RBF برای مدلسازی خروجی FT\_1301

#### مقایسه

میانگین مربعات خطا برای شبکه MLP و RBF طراحی شده برای دو ورودی و دو خروجی به ازای داده‌های آموزش و تست، معیار ارزیابی شبکه خواهد بود و نتایج آن در جدول ۱ آورده شده است. همان‌گونه که مشاهده می‌شود، برای خروجی اول شبکه MLP پاسخ بهتری می‌دهد (میانگین مربعات خطای پائین‌تری دارد) و برای خروجی دوم شبکه RBF نتیجه بهتری دارد.

جدول ۱: نتایج ارزیابی و مقایسه شبکه‌های MLP و RBF طراحی شده بر حسب میانگین مربعات خطا برای داده‌های تست و آموزش

خروجی مدل	MSE for (MLP)	MSE for (RBF)
FT-1301	$7/7709e-5$	$1/98e-2$
FT-1403	$5/4410e-4$	$1/5718e-4$

## نتیجه گیری

در این پژوهش روش‌های مبتنی بر شبکه‌های عصبی شناسایی و مدل‌سازی واحد پنتان پالایشگاه ارائه و نتایج شبیه‌سازی آن آورده شده است. با توجه به اینکه واحد پنتان دارای سیستم‌های غیر خطی می‌باشد و شناسایی و مدل‌سازی در این سیستم پیچیده بوده و مدل‌های معتبر ریاضی برای این کار وجود ندارد. بنابراین از روش‌های نوین شناسایی که شامل پیاده سازی کنترل هوشمند بر پایه محاسبات نرم از قبیل شبکه‌های عصبی استفاده می‌شود. روش‌های پیشنهادی شناسایی واحد پنتان پالایشگاه روش‌های مبتنی بر مدل می‌باشد. با توجه به میانگین مربعات خطای پائین بدست آمده، شبیه سازی برج اسپلتر موفقیت آمیز بوده است و بنابراین می‌توان در عمل از این تحلیل برای مطالعه و بهبود کنترل فرایند استفاده نمود یعنی بدون سعی و خطای عملی در سیستم کنترل در هنگام راه اندازی - که به عنوان یک مشکل، اپراتورها با آن سر و کار دارند - و به حالت پایدار رسیدن فرایند، زمان و در نتیجه هزینه زیادی تلف می‌کند، اگر با تغییر داده‌ها در این شبیه‌سازی بتوان خروجی‌های مطلوب‌تری دریافت کرد و سپس با اعمال نتایج تحلیل در ورودی‌های سیستم بتوان به خروجی مطلوب در عمل دست یافت ارزش افزوده مهمی برای بهره‌برداری از واحد حاصل شده است.

## تشکر و قدردانی

این مطالعه تحت حمایت و پشتیبانی شرکت پالایش نفت کرمانشاه انجام پذیرفته است. در این راستا از مدیریت محترم شرکت و پرسنل محترم واحد پنتان مخصوصاً مسئول محترم این واحد برای همکاری و کمک بی‌دریغشان به مدت دو ماه جهت جمع آوری داده از این واحد اعلام می‌دارد.

## منابع

1. Katayama T., "Subspace Methods for System Identification", Springer, Berlin, 2005.
2. Kinnaert M., "Fault diagnosis based on analytical models for linear and nonlinear News, systems- a tutorial", Proc. of IFAC Safe process, 2003, pp. 37-50.
3. Bezdek J.C. and Dunn J.C., "Optimal fuzzy partitions, 1975A heuristic for estimating the parameters in a mixture of normal dustrubutions". IEEE Transactions on Computers, pp. 835-838.
4. Nelles O., "Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models", Springer Press, 2001.
5. Chen T. and Francis B., "Optimal Sampled-data Control Systems", Springer, New York, 1995.
6. Bawazeer, K. H., "Prediction of Crude Oil Product Quality Parameters Using Neural Networks", MS Thesis, Florida Atlantic University, Boca Raton, FL, August, 1996.
7. Bawazeer, K.H. and Zilouchian, A., "Prediction of Crude Oil Production Quality Parameters Using Neural Networks", Proc. of 1997 IEEE Int. Conf. on Neural Networks, New Orleans, 1997.



8. Borman, S., "Neural Network Applications in Chemistry Begin to Appear", Chemical Eng. News, Vol. 67, No. 17, 1989, pp. 24-29.
9. Parlos, A. G., Chong, K.T., and Atiya, A.F., "Application of Recurrent Neural Multilayer Perceptron in Modeling Complex Process Dynamic", IEEE Trans. on Neural Networks, Vol. 5, No. 2, March, 1994.
10. Nekovie, R., and Sun, Y., "Back Propagation Network and its Configuration for Blood Vessel Detection in Angiograms", IEEE Trans. on Neural Networks, Vol. 6, No. 1, 1995.
11. Berkan, R.C., Upadhyaya, B., Tsoukalas, L., Kisner, R., and Bywater, R. "Advanced Automation Concepts for Large-Scaled Systems", IEEE Control Syst. Mag., Vol. 11, No. 6, 4-13, Oct., 1991.
12. Draeger, A., Engell, S., and Ranke, H., "Model Predictive Control Using Neural Networks", IEEE Control Mag., Vol. 15, No. 5, 1995, pp. 61-67.
13. Ray, W., "Polymerization Reactor Control", IEEE Control Syst. Mag., Vol. 6, No. 4, 3-9, August, 1986.
14. Bhat, N., Minderman, P., McAvoy, T., and Wang, N., "Modeling Chemical Process Systems via Neural Network Computation", IEEE Control Syst.
15. Nelles O., Ernst S., and Isermann R., "Neural network models for identification of nonlinear dynamic systems", Adzeti, Germany, 1996.
16. Hagan, M., Demuth, H.B., Beale, M.H., "Neural Network Design. PWS Publishing", Boston, 1996.
17. Nekoui M A., Sajadifar S. M., "Nonlinear System Identification using Locally Linear Model Tree and Particle Swarm Optimization", IEEE, 2006, pp. 1563-1568.