

## \* شبیه سازی خشک کن بستر سیال غیر مداوم به روش مدلسازی عصبی سری های زمانی \*

علی میرسپاهی<sup>(۱)</sup> محمد تقی حامد موسویان<sup>(۲)</sup> مرتضی محمد ظاهری<sup>(۳)</sup>

**چکیده** در این مقاله روشی مبتنی بر شبکه های عصبی مصنوعی برای مدلسازی سیستم های غیر خطی که داده های ورودی خروجی آنها به صورت سری زمانی قابل اندازه گیری هستند، ارائه شده است. شبکه عصبی از نوع با پسخور طراحی شده تا بتواند مشخصات و رفتار دینامیکی سیستم را در مدلسازی ملاحظه نماید. روش یاد شده برای مدلسازی یک خشک کن بستر سیال غیر مداوم به کار رفته است. نشان داده شده است که این روش برخلاف روش های کلاسیک قادر به تخمین رفتار سیستم در همه مراحل عملکرد، شامل مرحله افزایش رطوبت و مراحل کم شیب و پر شیب کاهش رطوبت می باشد. افزون بر مزیت فوق الذکر، روش ارائه شده دارای دقت قابل توجه، بی نیازی از کاربرد مشخصات فیزیکی در محاسبات و سرعت بسیار بالای تخمین است. صحنه گذاری مدل با داده های کاملاً "مجزا" از داده های مورد استفاده در آموزش شبکه، نشان دادند نتایج مدلسازی برای این نوع فرآیند دینامیکی غیر خطی کاملاً قابل اعتماد است.

**واژه های کلیدی** مدلسازی، شبکه های عصبی مصنوعی، سری زمانی، خشک کن بستر سیال غیر مداوم

## Simulation of batch fluidized bed drier using time series neural network

A.Mirsepahi

M.T.Hamed Mosavian

M.Mohamad Zaheri

**Abstract** In this paper a method of using neural network in order to model nonlinear systems whose input and output data are measurable by time series is being considered. Feed back neural network technique is applied in order to consider the specifications and dynamic behavior of the system in the modeling process. This method is applied to model a batch fluidized bed drier. In present report it is shown that unlike the classic techniques, this method is able to predict the system behavior in all the stages of the process, such as; high humidity increase, high and low humidity decrease. In addition, the proposed technique has considerable accuracy and is free from using physical specifications in calculations and also using a very fast computation technique. The model is tested by applying a totally different set of data from those which used for training the network; it is observed that the modeling results for this nonlinear dynamic process is totally authentic.

**Key Words** Modeling, Artificial neural network, Time series, Batch fluidized bed drier.

---

\* نسخه اولیه مقاله در تاریخ ۱۴۰۲/۱۵/۸ و نسخه نهایی آن در تاریخ ۱۴۰۹/۱۸/۸۵ به دفتر نشریه رسیده است.

(۱) دانشجو، گروه مهندسی شیمی، دانشکده مهندسی، دانشگاه فردوسی مشهد

(۲) استادیار، گروه مهندسی شیمی، دانشکده مهندسی، دانشگاه فردوسی مشهد

(۳) مربی، دانشگاه آزاد اسلامی - واحد سمنان

## مقدمه

لحاظ صنعتی مقبولیت گستردہ ای پیدا نکرده بود. کاربردهای مختلف خشک کردن با بخار شامل خشک کردن تفالہ چغnder قند، الوار، تفالہ کاغذ، لجن، ذغال سنگ، چیپس سیب زمینی و تورتیلا، سبزی، علوفہ وادویہ جات می باشد [16,17]. استفادہ از بخار فوق داغ در مقایسه با هوای داغ تا ۹۰٪ مصرف انرژی را کاهش می دهد [17,18]. افزون بر آن کیفیت محصول نهایی نیز افزایش خواهد یافت و محیط زیست نیز صدمه کمتری می بیند [19]. خشک کن بستر سیال با توجه ویژگی هایی نظیر ظرفیت بالا، هزینه ساخت نسبتاً پائین و راندمان حرارتی بالا گزینه مناسبی برای عمل خشک کردن با بخار می باشد [20]. از این نوع خشک کن دو دسته، مداوم (با ورود مداوم ماده خشک شونده) و غیر مداوم، وجود دارد.

قدیمی ترین مطالعه در مورد خشک کردن مواد به سال ۱۹۰۸ باز می گردد که هازبراند دانشمند آلمانی در کتاب خشک کردن به وسیله هوا و بخار by (Drying by means of air and steam) به آن اشاره کرده است. در سال ۱۹۲۰، کارر، مهندس سوئیسی، آزمایشاتی را بر روی یک خشک کن که با برق گرم می شد گزارش نمود [21].

اما پس از بحران نفت در سال ۱۹۷۳ اقبال بیشتری به این موضوع مشاهده گردید. پس از این بحران بیش از ۳۰۰ مقاله در این زمینه منتشر شده است اس. ینسن در سال های ۱۹۸۷ تا ۲۰۰۳ مقالاتی در این زمینه و برای مواد مختلف منتشر نموده است [19]. س. پرویک و ز. تانگ در همین سال ها مقالات زیادی در مورد مزایای خشک کردن با بخار به ویژه در مورد تفالہ چغnder قند منتشر نموده اند [16,21]. از سال ۱۹۹۹ ز. چن، م. ایزد فر، ج. برگ شوایگر، س. تمپل و دیگران درباره مدلسازی این فرآیند مقالاتی را منتشر نموده اند.

برای مدلسازی سری های زمانی روش های متعددی وجود دارد. در متداول ترین تعریف یک سری زمانی آرایه ای از اطلاعات است که دو ستون زمان و داده را در بر می گیرد. از جمله روش های استفاده شده برای مدل کردن سری های زمانی روش های خود برگشتی Singular (Auto-regressive) [1,2]، تجزیه مقدار منفرد (Auto-decomposition) [3] و مدلسازی (Value Decomposition) [4] می باشند. مدلسازی سری های زمانی با شبکه های عصبی (Artificial Neural Networks (ANN)) یکی دیگر از روش های مورد استفاده است. کاربرد این روش از اوایل دهه ۱۹۹۰ و اندکی پس از فرآیند شدن کاربرد شبکه های عصبی آغاز شد [5,6]. شبکه های عصبی در پردازش داده های سری زمانی به دو منظور عمده به کار رفته اند. نخست دسته بندی و مرتب کردن داده ها با شبکه های بدون نظارت (Unsupervised) [7] و دیگری مدلسازی به قصد پیش بینی که بسیار بیشتر مورد توجه قرار دارد [5,6,8]. این شیوه مدلسازی عموماً برای کاربردهای زیست محیطی [1,8,9,10] و اقتصادی [4,7,11] به کار رفته است. در کاربردهای صنعتی، به خاطر نیاز به دقت های بالا از مدل های عصبی سری زمانی استقبال نشده است. در حال حاضر، برای بهبود دقت این طریقه مدلسازی تلاش ها همچنان ادامه دارد [15,11,12,13,14,15]. در این مقاله روشی برای مدلسازی سری های زمانی با شبکه عصبی ارائه شده و در مدلسازی خشک کن چغnder قند به کار رفته است.

هدف اصلی خشک کردن مواد غذایی حفظ و نگهداری طولانی مدت آنهاست. کم کردن میزان رطوبت باعث جلوگیری و یا کاهش واکنش های آنزیمی و میکروبی می شود. خشک کردن با بخار که از اواسط قرن گذشته رایج شده است، تا همین اوآخر از

یک متغیر و مشتقات آن (در مورد سیستم های گسسته، یک متغیر در زمان حال و زمان های قبلی) در دینامیک سیستم ظاهر شوند. به منظور بیان تأثیر دینامیکی بودن سیستم (حافظه دار بودن آن) در مدل سری زمانی، می توان ورودی های سیستم در هر لحظه را همان خروجی های سیستم در لحظات قبل در نظر گرفت. متغیر خروجی سیستم در زمان  $t$  با  $x(t)$  نشان داده می شود. با فرض این که فاصله نمونه گیری ها  $T$  باشد و  $t = kT$ . خروجی سیستم واقعی را با  $x_k$  و خروجی مدل سری زمانی را با  $\tilde{x}_k$  نشان می دهیم. در این حالت می توان  $\tilde{x}_k$  را به صورت تابعی از مقادیر خروجی های اندازه گیری شده در چند قدم قبل نشان داد.

$$\tilde{x}_k = F(x_{k-r}, x_{k-r+1}, \dots, x_{k-1}) \quad (2)$$

در این رابطه مقدار خروجی مدل سری زمانی در یک مرحله به صورت تابعی از خروجی سیستم واقعی در  $r$  مرحله قبل در آمد است که در آن  $x_{k-r}$  مقدار خروجی واقعی سیستم در یک مرحله قبل و  $x_{k-r+1}$  مقدار خروجی در  $r$  مرحله قبل است. پارامتر  $r$  یا تعداد لحظاتی که داده های آنها در تخمین داده یک لحظه استفاده می شود مرتبه مدل سری زمانی نامیده می شود. اگر  $\tilde{x}_k$  به خروجی واقعی سیستم ( $x_k$ ) نزدیک باشد، می توان با کمک این خروجی تخمینی، خروجی در لحظه  $k+1$  را نیز تخمین زد.

$$\tilde{x}_{k+1} = F(x_{k-r+1}, \dots, x_{k-1}, \tilde{x}_k) \quad (3)$$

به همین ترتیب می توان خروجی سیستم را در لحظات آینده نسبت به زمان هایی که داده های آنها ثبت شده است، تخمین زد. درنهایت می توان چنین مدلی به دست آورد:

$$\tilde{x}(t) = G(t, [x_1, \dots, x_r]) \quad (4)$$

در این مقاله عملیات خشک کردن مواد مختلف به روش های کلاسیک (موازنۀ جرم و انرژی) مدلسازی شده است [22,23,24,25].

مدلسازی خشک کن بستر سیال (از نوع مداوم) به کمک شبکه های عصبی مصنوعی برای اولین بار توسط سن-شاتیش و همکارش در سال ۲۰۰۵ ارائه شد [26]. اشکال عمده پژوهش یاد شده آن است که چون در مدلسازی از شبکه های عصبی بدون پسخور استفاده شده است، دینامیکی بودن سیستم در مدلسازی "عملما" در نظر گرفته نشده است. همچنین صحه گذاری مدل به دست آمده تنها با داده های مورد استفاده در مدلسازی انجام شده است از این رو، مدل به دست آمده از قابلیت اعتماد کافی برای نشان دادن دینامیک رفتاری سیستم برخوردار نیست. در مقاله حاضر شبکه عصبی مصنوعی با پسخور (دینامیکی) برای مدلسازی یک خشک کن بستر سیال غیر مداوم به کار رفته است. به عبارت دیگر، شبکه عصبی پس از طراحی و آموزش مناسب، قادر خواهد بود با استفاده از اطلاعات اندازه گیری شده محتوای رطوبت، محتوای رطوبت در زمان های آینده را پیش بینی کند.

### معرفی روش ارائه شده

یک سری زمانی از یک داده خاص، آرایه ای از اطلاعات است که دو ستون زمان و داده را در بر می گیرد. اگر زمان را با  $t$  و داده را با  $x$  و تعداد داده ها را با  $n$  نشان دهیم، یک سری زمانی را می توان به صورت زیر نشان داد:

$$\begin{bmatrix} t_1 & t_2 & \dots & t_n \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \quad (1)$$

برای مدلسازی سیستم های دینامیکی غیر خطی با استفاده از داده های سری زمانی می توان مجموعه متغیرهای حالت را در ترکیب جدیدی ارائه داد که تنها

شبیه سازی خشک کن بستر سیال غیرمایم ...

آموزش شبکه به این صورت مرتب می شوند:

$$q = r+1, \dots, n \\ (x_{q-r}, x_{q-r+1}, \dots, x_q) \quad (8)$$

برای هر مقدار  $q$  یک سطر داده نظیر آنچه در رابطه (۱) نشان داده شده است، به دست می آید. در نتیجه داده ها در یک آرایه با  $n-r$  سطر و  $r+1$  ستون چیزه می شوند. با فرض اینکه داده های شش لحظه متفاوت ( $x_i, i=1, \dots, r$ ) را برای کاربرد در یادداشته شبکه عصبی با مرتبه دو مرتب کنیم، خواهیم داشت:

$$\begin{bmatrix} x_1 & x_2 & x_3 \\ x_2 & x_3 & x_4 \\ x_3 & x_4 & x_5 \\ x_4 & x_5 & x_6 \end{bmatrix} \quad (9)$$

پس از به دست آمدن آرایه داده ها، ستون آخر به عنوان خروجی و ستون های دیگر به عنوان ورودی در آموزش به کار گرفته می شوند. به عبارت دیگر، با آموزش داده های ثبت شده، به شبکه یاد داده می شود که با داشتن داده های چند لحظه متوالی، خروجی در لحظه آینده را تخمین بزند. چینش داده های یادداشته به صورت زیر هم می توان نوشت:

$$\left. \begin{array}{c} x_{k-r} \\ x_{k-r+1} \\ \vdots \end{array} \right\} \Rightarrow x_k \quad (10)$$

ساختار انتخابی برای شبکه «پرسپترون با پسخور» (Recurrent perceptron) است. ساختار پرسپترون برای مدلسازی با داده های ثبت شده مناسب است. «با پسخور» بودن شبکه هم اجازه مدلسازی سیستم های دینامیکی یا حافظه دار را می دهد. منظور از شبکه عصبی با پسخور شبکه ای است که خروجی آن در یک

که  $[x_r, x_{r-1}, \dots, x_1]$  شرایط اولیه سیستم یا مقادیر  $x$  در لحظات اولیه ثبت داده هستند و  $t$  زمان است. با داشتن چنین مدلی در هر لحظه، امکان پیش بینی رفتار سیستم در فواصل زمانی قابل توجه وجود دارد. مشروط بر اینکه هیچ گونه اختشاش یا نویزی در این فاصله زمانی رخ ندهد. اگرتابع  $F'$  طبق رابطه (۵) تعریف شود:

$$F'(x_{k-r}, \dots, x_{k-1}) = \\ (x_{k-r+1}, x_{k-r+2}, \dots, x_{k-1}, \tilde{x}_k) \quad (5)$$

خواهیم داشت:

$$G(t, [x_1, \dots, x_r]) = F(F'(k-r)(x_1, \dots, x_r)) \quad (6)$$

که  $F'(k-r)$  به معنی  $k-r$  مرتبه تکرار تابع  $F'$  است. مثلاً "برای تخمین خروجی در شش ثانیه بعد از آغاز ثبت داده ها، با یک مدل مرتبه دو و فاصله زمانی دو ثانیه ( $t=4, r=2, T=2$ ) خواهیم داشت:

$$G(6, [x(0), x(2)]) = F(F'(x(0), x(2))) \quad (7)$$

نتیجه هر بار تخمین (اعمال تابع  $F$  یا  $F'$ ) به عنوان ورودی یا آرگومان تخمین بعدی مورد استفاده قرار خواهد گرفت. هر خطای تخمین اثر خود را به ناچار در تخمین های بعدی می گذارد. به این پدیده اصطلاحاً «انباشت خط» گویند.

در این مقاله شبکه های مصنوعی با پسخور برای مدلسازی به کار رفته اند. در واقع یک شبکه عصبی با پسخور به عنوان تابع  $F$  استفاده شده است. شبکه عصبی با یادگیری تعدادی داده ثبت شده قادر به تخمین یا پیش بینی رفتار سیستم خواهد بود. مدلسازی با شبکه عصبی، شامل مرتب کردن داده ها، تعیین ساختار و تعیین روش یادداشته است که ذیلاً "ارائه خواهد شد. اگر  $n$  تعداد کل داده های مورد استفاده در آموزش و  $r$  مرتبه شبکه عصبی باشد، داده های ثبت شده برای

در بعضی مدلسازی های پیچیده و از جمله مدلسازی موجود، این روش یاددهی از بهترین روش های دیگر نظریه گرادیان مزدوج هم بهتر جواب می دهد.

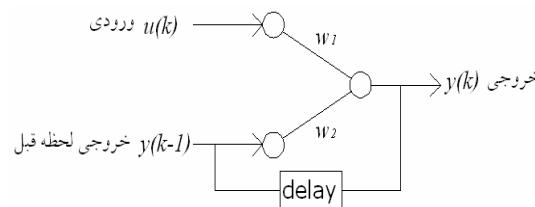
پس از طی مراحل آماده سازی اطلاعات، تعیین ساختار و آموزش شبکه، کارایی شبکه باید با استفاده از داده هایی که در آموزش دخالت نداشته اند (Checking data) سنجیده شود. در صورت به دست آمدن دقت مناسب، شبکه برای استفاده در تخمین و پیش بینی قابل اعتماد است.

### کاربرد روش ارائه شده در مدلسازی خشک کن بستر سیال غیر مداوم

در این پژوهش، داده های تجربی ثبت شده «محتوای رطوبت- زمان» یک خشک کن بستر سیال غیر مداوم چندر قند با دماهای بخار خشک کن  $120^{\circ}\text{C}$  و  $110^{\circ}\text{C}$  او سرعت بخار  $0.32\text{ m/s}$  بر ثانیه استفاده شده است. با داده های مربوط به هر کدام از دماهای بخار خشک کن، یک شبکه آموزش دیده است زمان نمونه گیری (Sampling time) ۲ ثانیه است و در دماهای بخار خشک کن  $110^{\circ}\text{C}$  و  $120^{\circ}\text{C}$  به ترتیب ۵۰۰ و ۳۰۰ پاره داده برای یاددهی به کار رفته است که مربوط به هر سه محدوده عملکرد خشک کن می باشند.

عملکرد خشک کن ها نسبتاً پیچیده است و در ابتدای عمل خشک کردن در اثر پدیده جذب بخار، رطوبت افزایش می یابد و سپس به صورت تقریباً خطی کاهش یافته و در نهایت با کاهش محتوای رطوبت، شب آن هم به طور آشکاری تغییر می کند. در نتیجه به طور کلی با سیستمی غیر خطی مواجه هستیم. با توجه به پیچیدگی رفتار سیستم، استفاده از داده های

لحظه ورودی (یا یکی از ورودی های) آن در لحظه بعد است. یک نمونه ساده شبکه عصبی دو لایه با پسخور در شکل (۱) نشان داده شده است.



شکل ۱ نمایی از یک شبکه عصبی دو لایه با پسخور

در این شبکه ورودی لحظه جاری و خروجی در لحظه قبل وارد شبکه شده و پس از ضرب شدن در وزن اتصال مربوطه (یک عدد حقیقی،  $w$ ) با هم جمع شده و حاصل جمع از تابع فعالیت (Activation function) لایه خروجی عبور می کند. برای لایه ورودی معمولاً تابع فعالیتی در نظر گرفته نمی شود. اگر تابع فعالیت لایه خروجی را  $F$  بنامیم، خواهیم داشت [27]:

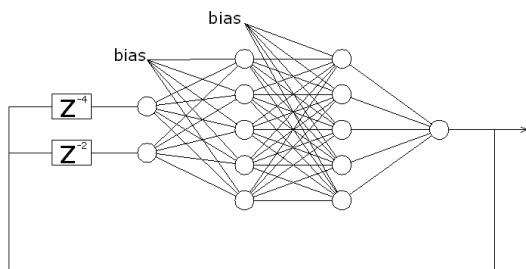
$$y(k) = F(w_1 u(k) + w_2 y(k-1)) \quad (11)$$

اختلاف خروجی به دست آمده از شبکه و خروجی واقعی، خطای شبکه است. بهینه سازی (Optimization) وزن ها به گونه ای که خطای شبکه به حداقل برسد، آموزش یا یاددهی (Training) شبکه نامیده می شود [27].

در این پژوهش یاددهی از روش پس انتشار خطای انعطاف پذیر Resilient back propagation صورت گرفته است. در این روش اصلاح وزن ها با استفاده از علامت گرادیان خطأ و یک ضریب اصلاح شونده ( $\eta$ ) صورت می گیرد و گرادیان خطأ مستقیماً در یاددهی دخالت نمی کند.

$$\Delta W_{ij} = \eta \times \text{sign} \left( \frac{\partial E}{\partial W_{ij}} \right) \quad (12)$$

شبیه سازی خشک کن بستر سیال غیرمدادوم ...



شکل ۲ شبیه سازی شبکه عصبی مورد استفاده در مدلسازی

به منظور محدود کردن دامنه خطای تابع فعالیت نورون های لایه میانی اول، تاثرانت هذلولوی در نظر گرفته شده است [27]. یعنی برای هر نورون در این لایه:

$$\text{output} = \tanh(\sum \text{inputs}) \quad (13)$$

برای سایر لایه ها تابع فعالیت تابع همانی در نظر گرفته شده است. در آموزش این شبکه از یاددهی یکباره داده ها (Batch training) استفاده شده است. به این صورت که کل داده ها به شبکه وارد شده و خطای مورد استفاده در آموزش برابر مجموع خطای به دست آمده برای همه داده هاست. در مورد شبکه هایی که نتایج آن ذیلاً ارائه می گردد، عملیات یاددهی ۵۰۰ بار تکرار شده است. الگوریتم مورد استفاده پس انتشار خطای انعطاف پذیر است که مقدار اولیه  $\eta$  در آن  $0.01$  می باشد، هر بار که خطای کاهش می یابد  $\eta$  در عدد  $1/1$  ضرب شده و هر بار خطای افزایش می یابد  $\eta$  در عدد  $0.95$  ضرب می شود و به این ترتیب اصلاح می شود. خاطر نشان می سازد یاددهی بیش از حد تأثیر منفی داشته و باعث می شود شبکه در تخمین داده هایی غیر از داده های یاددهی (Training data) دچار اشکال شود.

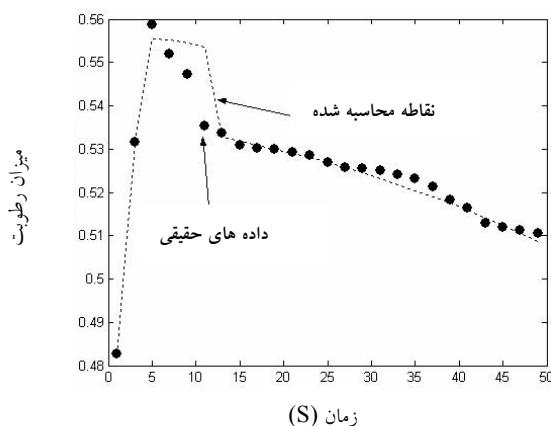
حداقل دو لحظه قبل برای مدلسازی و تخمین خشک کن در کل محدوده عملکرد لازم به نظر می رسد. در نتیجه، مرتبه ۲ برای شبکه عصبی در نظر گرفته شده است و به همین جهت برای دمای بخار خشک کن  $110^{\circ}\text{C}$  و  $120^{\circ}\text{C}$  داده های خام اولیه به ۴۹۸ و ۲۹۸ ردیف سه تایی متوالی داده، نظیر رابطه ۱ تبدیل شده اند.

بر خلاف آنچه در اولین تلاش برای مدلسازی خشک کن ها با شبکه عصبی صورت گرفته است [26]، در پژوهش حاضر، از شبکه های عصبی با پسخور استفاده شده است. کاربرد شبکه های بدون پسخور در این نوع مدلسازی کارایی لازم را ندارد. علت آن است که محتوای رطوبت در هر لحظه به محتوای رطوبت در لحظه قبل وابسته است. این بیان دیگری از دینامیکی بودن سیستم است.

از آنجا که این سیستم غیرخطی و دارای چند محدوده عملکرد با رفتار متفاوت است، یک شبکه چهار لایه با لایه های ورودی و خروجی و دو لایه میانی برای مدلسازی آن در نظر گرفته شده است [11]. برای دو لایه میانی، ورودی های کمکی (Bias) برابر عدد ثابت ۱ لحاظ شده است. چون هیچ داده ای غیر از محتوای رطوبت در یاددهی وارد نمی شود، تعداد نورون های لایه ورودی برابر مرتبه سیستم است (مرتبه سیستم برابر است با تعداد لحظاتی که محتوای رطوبت آنها در تخمین محتوای رطوبت لحظه بعد استفاده می شود). در لایه های میانی، تعداد لایه ها  $2m+1$  در نظر گرفته شده که  $m$  تعداد ورودی هاست [27]. تابع  $z^{-p}$  هم به معنی ایجاد  $p$  ثانیه تأخیر است. چون مرتبه سیستم ۲ و فاصله زمانی (طول هر لحظه) هم ۲ ثانیه است. خروجی تخمینی در ۲ و ۴ ثانیه قبل به عنوان ورودی برای تخمین خروجی لحظه جاری استفاده می شوند. نمایی از شبکه به کار رفته در شکل (۲) نشان داده شده است:

خشک کن های بستر سیال مداوم، دبی جریان ماده خشک شونده، هر لحظه تغییر کرده و می تواند به عنوان یک ورودی شبکه استفاده شود، مدلسازی آنها با شبکه عصبی ساده تر به نظر می رسد.

شکل های (۴,۵,۶) نتیجه تخمین شبکه های آموزش دیده برای دماهای بخار خشک کن  $10^{\circ}\text{C}$  و  $120^{\circ}\text{C}$  را در مقایسه با رفتار سیستم واقعی نشان می دهد. در ترسیم این نمودارها از داده های آزمایشی استفاده شده است؛ بدین معنی که اطلاعاتی که در نمودارها نشان داده شده اند در آموزش شبکه ها استفاده نشده اند. نکته جالب توجه این که در مدلسازی های دیگر، معمولاً "برای هر محدوده عملکرد سیستم یک مدل جداگانه ارائه می شود. اما در این روش یک شبکه عصبی برای پیش بینی رفتار سیستم در کل محدوده عملکرد آن آموزش دیده و به کار می رود. جدول (۱)، نشان دهنده میانگین قدر مطلق خطای نمودارهای ۳ تا ۶ است.



شکل ۳ نتایج تخمین شبکه عصبی در مقایسه با داده های واقعی برای  $50^{\circ}\text{C}$  (داده ها مربوط به دمای بخار خشک کن  $110^{\circ}\text{C}$  و متفاوت از داده های آموزشی می باشند)

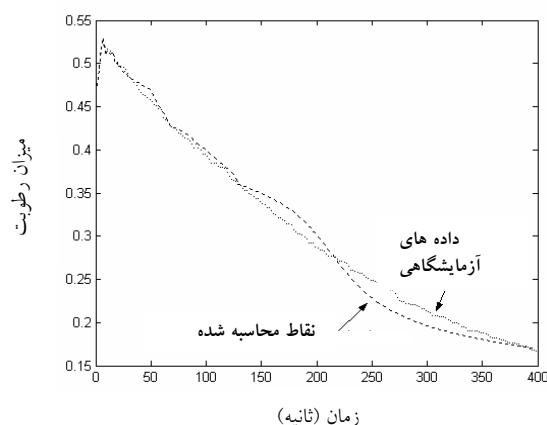
## نتایج شبیه سازی

برای بررسی دقیق مدلسازی با شبکه عصبی، از یک سیستم کامل داده با فاصله ۲ ثانیه که در یادداشت شبکه عصبی به کار نرفته اند، استفاده می شود. برای دماهای بخار خشک کن  $110^{\circ}\text{C}$  و  $120^{\circ}\text{C}$  به ترتیب ۵۰۰ و ۳۰۰ پاره داده برای آزمایش توان تخمین شبکه ها به کار رفته است که مربوط به هر سه محدوده عملکرد خشک کن می باشند. به این ترتیب که با دادن دو داده اول به شبکه (مربوط به ثانیه های ۱ و ۳) داده سوم (مربوط به ثانیه ۵) را تخمین می زنیم. سپس با داده ثانیه ۳ و خروجی تخمینی ثانیه ۵، خروجی ثانیه ۷ را تخمین می زنیم. از این به بعد کلیه ورودی های شبکه، خروجی های تخمینی خود آن هستند. این شبیه سازی دو امتیاز عمدی دارد:

(۱) داده های آزمایش کاملاً با داده هایی که به شبکه یاد داده جدا هستند. در نتیجه در صورت به دست آمدن دقیق مناسب، نتایج تا حدود زیادی قابل اعتماد است.

(۲) در این شبکه، پس از تنها چند ثانیه تمام ورودی ها در اصل خروجی های لحظات قبل شبکه خواهند بود. اگر خطای قابل توجهی در هر لحظه حادث شود خروجی غیر دقیق به دست آمده در لحظات بعد به عنوان ورودی دوباره به شبکه وارد شده و تأثیر این خطای خروجی های بعدی هم منتقل می شود. در واقع در شبکه های با پسخور پذیده «انباست خطای وجود دارد. تنها در صورت دقیق بسیار بالای شبکه می توان از ایجاد خطاهای بزرگ اجتناب کرد. دقیق مناسب شبکه حتی پس از صد ها ثانیه نشانه ای از ساختار مناسب و آموزش موفقیت آمیز آن است. مشخص است اگر داده های دیگر در کنار خروجی شبکه موجود بود، این داده ها به عنوان راهنمای باعث دقیق بیشتر شبکه شده و از اشر پذیده انباست خطای می کاستند. از آنجا که در

شبیه سازی خشک کن بستر سیال غیرمدادوم ...

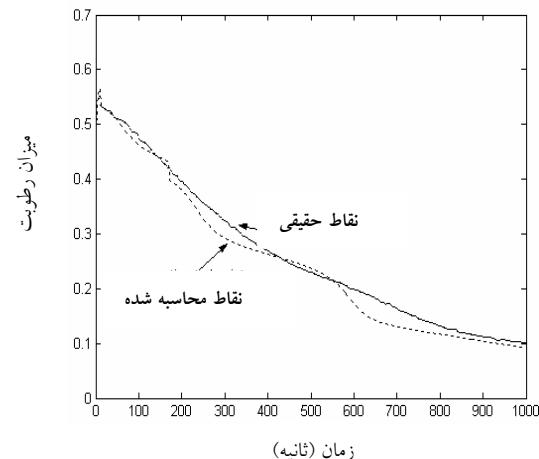


شکل ۶ نتایج تخمین شبکه عصبی در مقایسه با داده های واقعی برای ۴۰۰ ثانیه (داده ها مربوط به دمای بخار خشک کن  $120^{\circ}\text{C}$  و متفاوت از داده های آموزشی می باشند)

نکته دیگر این که گرچه آموزش شبکه عصبی امری نسبتاً وقت گیر است، اما از آن رو که یاددهی و تخمین عملیاتی جداگانه هستند، تخمین با شبکه عصبی بسیار سریع و معمولاً "سریعتر از روش های دیگر است. علت سریعتر بودن این است در تخمین با شبکه عصبی تنها عملیات ساده ریاضی نظیر جمع و ضرب یا حداکثر محاسبه توابع ساده صورت می گیرد و هیچ گونه عملیات بازگشتی، مشتق گیری یا انتگرال گیری در آن انجام نمی شود. به طور مثال زمان مورد نیاز برای یک بار تخمین محتوای رطوبت با استفاده از یک کامپیوتر خانگی با سرعت  $1\text{ گیگا هرتز}/0.013\text{ ثانیه}$  است.

### نتیجه گیری

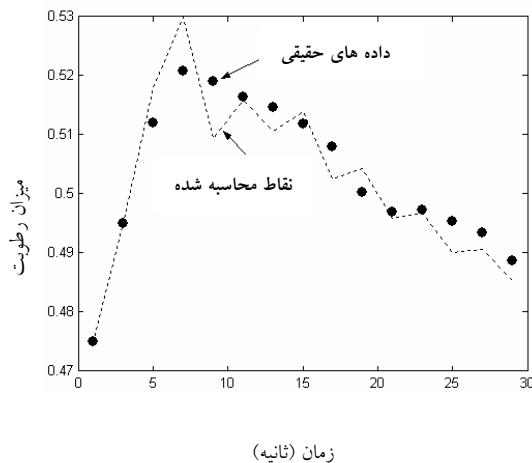
در این پژوهش شبکه های عصبی مصنوعی با پسخور برای مدلسازی سیستم های دینامیکی غیر خطی که داده های ورودی-خروجی آنها به صورت سری زمانی ارائه شده اند، طراحی شده و مورد استفاده قرار گرفته اند. روش ارائه شده برای مدلسازی یک خشک کن بستر سیال چندر قند به کار گرفته شده است. مقایسه رفتار سیستم اصلی با مدل به دست آمده نشان می دهد که



شکل ۴ نتایج تخمین شبکه عصبی در مقایسه با داده های واقعی برای ۱۰۰۰ ثانیه (داده ها مربوط به دمای بخار خشک کن  $110^{\circ}\text{C}$  و متفاوت از داده های آموزشی می باشند)

جدول ۱ میانگین قدر مطلق خطای برای داده های آزمایشی (مرحله تخمین)

میانگین قدر مطلق خطای (محتوای رطوبت)	شماره شکل
۰.۰۰۲	۳
۰.۰۱۷	۴
۰.۰۰۳	۵
۰.۰۱۲	۶



شکل ۵ نتایج تخمین شبکه عصبی در مقایسه با داده های واقعی برای ۳۰ ثانیه (داده ها مربوط به دمای بخار خشک کن  $120^{\circ}\text{C}$  و متفاوت از داده های آموزشی می باشند)

سیستم اصلی بسیار نزدیک و خطای مدل که تفاوت رفتار آن با رفتار سیستم اصلی است در همه مراحل عملکرد کوچک باقی می ماند. در نتیجه مدل طراحی شده از قابلیت اعتماد و اعتبار مناسبی برخوردار است. روش حاصله در این پژوهش را در سایر سیستم های دینامیکی غیر خطی با داده های سری زمانی نظری مدلسازی قیمت نفت یا بازار سهام و یا دیگر فرآیندهای صنعتی می توان مورد استفاده قرار داد.

روش مورد استفاده از دقت بالایی برخوردار است و برخلاف روش های معمول مدلسازی خشک کن ها، برای کل محدوده فرآیند تخمین قابل قبولی ارائه می دهد. داده های صحه گذاری مدل با داده های آموزش شبکه متفاوت است و هنگام صحه گذاری پس از چند ثانیه اول، ورودی های شبکه همان خروجی های شبکه در لحظات قبل می باشند که این امر به پدیده انباشت خطا منجر می شود؛ با این حال رفتار مدل به رفتار

## مراجع

1. S. Petaccia, R. Serravall and F. Pellicano, "Improved method of sea level forecasting at Venice (Northern Adriatic Sea)", Communications in Nonlinear Science and Numerical Simulation, Volume 11, Issue 3 , Pages 281-296, (2006).
2. T. Teräsvirta, , D. van Dijk and M. C. Medeiros, "Linear models, smooth transition auto-regressions, and neural networks for forecasting macroeconomic time series: A re-examination", International Journal of Forecasting ,Volume 21, Issue 4 , October-December 2005, Pages 755-774
3. P. P. Kanjilal and Sarbani Palit, "Modelling and prediction of time series using singular value decomposition and neural networks", Computers & Electrical Engineering ,Volume 21, Issue 5 , Pages 299-309, (1995).
4. J.M. Dias and J.F. Lopes, "Implementation and assessment of hydrodynamic, salt and heat transport models: The case of Ria de Aveiro Lagoon (Portugal)", Environmental Modelling & Software Volume 21, Issue 1 , Pages 1-15, (2006).
5. K. Chakraborty, K. Mehrotra, C. K. Mohan and S. Ranka, "Forecasting the behavior of multivariate time series using neural networks", Neural Networks , Volume 5, Issue 6 , Pages 961-970, (1992).
6. F. S. Wong, "A new time series classification approach", Signal Processing, Volume 54, Issue 2 , Pages 191-199, (1996).
7. K. N. Plataniotis, D. Androutsos, A. N. Venetsanopoulos and D. G. Lainiotis, "A new time series classification approach" , Signal Processing Volume 54, Issue 2 , Pages 191-199, (1996).
8. M. J. Aitkenhead, A. J. S. McDonald, J. J. Dawson, G. Couper, R. P. Smart, M. Billett, D. Hope and S. Palmer, "A novel method for training neural networks for time-series prediction in environmental systems", Ecological Modeling Volume 162, Issues 1-2 , Pages 87-95, (2003).

9. M. H. Nour ,D. W. Smith, M. G. El-Din and E. E. Prepas, "The application of artificial neural networks to flow and phosphorus dynamics in small streams on the Boreal Plain, with emphasis on the role of wetlands", Ecological Modeling Volume 191, Issue 1 , Pages 19-32, (2006).
10. H. Niska, T. Hiltunen, A. Karppinen, J. Ruuskanen and M. Kolehmainen, "Evolving the neural network model for forecasting air pollution time series", Engineering Applications of Artificial Intelligence ,Volume 17, Issue 2 , Pages 159-167, (2004).
11. P. Doganis, A. Alexandridis, P. Patrinos and H. Sarimveis, "Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing", Journal of Food Engineering ,Article in Press, Corrected Proof
12. D. Gao, Y. Kinouchi, K. Ito and X. Zhao, "Neural networks for event extraction from time series: a back propagation algorithm approach", Future Generation Computer Systems ,Volume 21, Issue 7 , Pages 1096-1105, (2005).
13. T.G. Barbounis and J.B. Theocaris , "Locally recurrent neural networks for long-term wind speed and power prediction" , Neurocomputing ,Volume 69, Issues 4-6 , Pages 466-496, (2006)
14. K. Huarng and T. Hui-Kuang Yu, "The application of neural networks to forecast fuzzy time series", Physica A: Statistical Mechanics and its Applications Article in Press, Corrected Proof
15. A. Palmer , J.J. Montaño , and A. Sesé, "Designing an artificial neural network for forecasting tourism time series", Tourism Management , Article in Press, Corrected Proof
16. C. Proyk, S. Cenkowski, W.E. Muir, "Drying foodstuffs with super-heated steam", Drying Technology; vol 22. No.5; pp.899-916, (2004)
17. K. Urbaniec and J. Malczewski, "Experimental investigations of beet pulp drying in super-heated steam under pressure", Drying Technology, 15(6-8), 2005-2013(1997).
۱۸. محمد تقی حامد موسویان، علی میرسپاهی، « بررسی روش های کاهش مصرف انرژی در کارخانه های قند و شکر ایران» ، بیست و هفتمین دوره سمینارهای کارخانه های قند و شکر ایران، ادبیهشت ماه ۱۳۸۴
19. A. Jensen,"Industrial applications for new steam drying process in forest and agricultural industry", International sugar journal 2003, vol.105, No 1250.
۲۰. سزا استرا میلو، تادادیوز کودرا، ترجمه حسن پهلوانزاده، «خشک کردن، اصول، کاربرد و طراحی»، انتشارات دانشگاه تربیت مدرس ۱۳۷۸
21. Z. Tang, S. Cenekowski, W.F. Muir, "Dehydration of sugar-beet pulp in super-heated steam and hot air", Transactions of the ASAE, Vol 43(3): 685-689(2002)
22. Z. Chen, W. Wu, P.K. Agarwal, "Modeling the operation of a fluidized bed drying unit", Fuel 80 (2001) 209-223
23. M. Izadifar, D. Mowla, "Simulation of a cross-flow continuous fluidized bed dryer for paddy rice", Journal of Food Engineering 58, 325–329 (2003).

24. J.Burgschweiger, E.Tsotsas, "Experimental investigation and modelling of continuous fluidized bed drying under steady-state and dynamic conditions", Chemical Engineering Science, 57, 5021– 5038 (2002).
25. S.J.Temple1, A.J.B.van Boxtel, "Modelling of Fluidized-bed Drying of Black Tea", J. agric. Engng Res. (1999) 74, 203}212.
- 26.S.Satish, Y.Pydi Setty, "Modeling of a continuous fluidized bed dryer using artificial neural networks", Heat and Mass Transfer, 32, 539–547 (2005).
27. Simon Haykin, Neural Networks A Comprehensive Foundation, 2<sup>nd</sup> edition, Prentice-Hall , Inc 1999547
۲۸. علی غفاری، منصور نیکخواه بهرامی و مرتضی محمد ظاهری، «مدلسازی خطی سیستم های غیر خطی با کمک شبکه های عصبی مصنوعی بر پایه داده های ورودی- خروجی و کاربرد آن در بویلر نیروگاه، نشریه دانشکده فنی دانشگاه تهران- ویژه مهندسی مکانیک و متالورژی، جلد ۳۹، شماره ۱، اردیبهشت (۱۳۸۴).