



مقایسه شبکه‌های عصبی دینامیکی و استاتیکی در پیش‌بینی عملکرد آب شیرین کن خورشیدی سهموی

احمد بناکار¹، علی متولی^{2*}، مهدی منتظری³، سیدرضا موسوی سیدی²

1 - استادیار، مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران

2- استادیار، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری

3- دانشجوی دکتری، مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس، تهران

* ساری، صندوق پستی 578، a.motevali@sanru.ac.ir

چکیده

اطلاعات مقاله

مقاله پژوهشی کامل

دریافت: 19 مهر 1395

پذیرش: 19 آبان 1395

ارائه در سایت: 21 آذر 1395

کلید واژگان:

پیش‌بینی

مدل سازی شبکه عصبی

آب شیرین کن خورشیدی

در این پژوهش با به کارگیری مدل‌های مختلف شبکه عصبی، به بررسی ارتباط میان میزان تولید آب شیرین و دمای بخار آب در اثر شرایط مختلف جوی و چندین دبی آب ورودی در شرایط مختلف روز در یک آب شیرین کن مجهز به متمرکز کننده خطی سهموی خورشیدی پرداخته شد. نتایج نشان داد که شبکه‌های استاتیک و دینامیک با دقت بالایی می‌توانند فرآیندهای تولید آب شیرین را مدل سازی کنند. شبکه عصبی استاتیک با سرعت بالاتر نسبت به شبکه‌های دینامیکی می‌تواند فرآیند مدل سازی را انجام دهد در عین حال به نظر می‌رسد که میزان خطا در فرآیند مدل سازی با به کارگیری شبکه‌های دینامیک کاهش می‌یابد. ضریب تبیین برای الگوهای آموزش، ارزیابی و تست در شبکه استاتیک به ترتیب 0.9898، 0.9899 و 0.9889 می‌باشد. در حالی که ضریب تبیین برای الگوهای آموزش، ارزیابی و تست در شبکه دینامیک به ترتیب 0.9922، 0.9894 و 0.9901 می‌باشد. همچنین میزان خطای شبکه در شبکه استاتیک برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.0011، 0.0027 و 0.0024 و برای شبکه‌های دینامیک به ترتیب 0.0018، 0.0007 و 0.0004 می‌باشد. مقایسه شبکه‌های استاتیک و دینامیک نشان داد که شبکه‌های دینامیک با دقت بیشتری نسبت به شبکه‌های استاتیک می‌تواند میزان تولید آب شیرین و دمای بخار آب را با توجه به تغییرات پارامترهای جوی پیش‌بینی کند.

Comparison of dynamic and static neural networks in predicting performance of parabolic solar desalination

Ahmad Banakar¹, Ali Motevali^{2*}, Mehdi Montazeri¹, Seyed Reza Mousavi Seyed²

1- Biosystems Engineering Department, Faculty of Agriculture, Tarbiat Modares University (T.M.U), Tehran, Iran

2- Department of Mechanics of Biosystem Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

* P.O.B. 578, Sari, Iran, a.motevali@sanru.ac.ir

ARTICLE INFORMATION

Original Research Paper
Received 10 October 2016
Accepted 09 November 2016
Available Online 11 December 2016

Keywords:
Prediction
Neural networks modelling
solar desalination

ABSTRACT

In this research with utilization of various neural networks models, the relationship between the amount of water production and the temperature of the vapor with different weather conditions, time of day and several water debits in desalination system equipped with linear solar parabolic concentrator was investigated. The results showed that static and dynamic networks can model the process of producing fresh water with high accuracy. Static neural network can perform the modelling process with higher speed than dynamic neural network. However, it seems that the amount of error using dynamic networks was reduced in process modeling. Coefficient of determination (R^2) for training, validation and testing in static networks was 0.9898, 0.9899 and 0.9889, respectively. While coefficient of determination (R^2) for training, validation and testing in dynamic networks was 0.9922, 0.9894 and 0.9901, respectively. Also, the amount of mean square error (MSE) in static network for training, validation and testing was 0.0011, 0.0027 and 0.0024, respectively and for dynamic networks was 0.0018, 0.0007 and 0.0004, respectively. Comparison between dynamic and static networks show that the dynamic networks can predict the production of fresh water and vapor temperature according to changes in atmospheric parameters more accurately than the static networks.

1- مقدمه

جمعیت و توسعه‌ی صنایع، تامین آب سالم و شیرین یکی از مسائل اساسی در مناطق مختلف جهان، بخصوص در مناطق خشک و دور افتاده است [1]. رقابت بین بخش‌های مختلف کشاورزی، صنعت و خانگی برای مصرف آب منجر به استفاده بیشتر از آب‌های زیرزمینی شده است. یکی از رویکردها برای

آب موجود روی کره‌ی زمین متشکل از آب دریا به مقدار 96.54% و آب شیرین به مقدار 2.53% می‌باشد که از این مقدار آب شیرین موجود، فقط 0.36% به صورت مستقیم در دسترس انسان می‌باشد. با توجه به افزایش

Please cite this article using:

A. Banakar, A. Motevali, M. Montazeri, S. R. Mousavi Seyed, Comparison of dynamic and static neural networks in predicting performance of parabolic solar desalination, *Modares Mechanical Engineering*, Vol. 16, No. 12, pp. 291-299, 2016 (in Persian)

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

تامین آب شیرین در آینده فرآیند نمک‌زدایی از آب شور می‌باشد. نمک‌زدایی¹ یا شیرین کردن آب راه حل خوبی به منظور تامین نیازهای آبی بشر به شمار می‌آید. بنابر آمارهای موجود تعداد 14451 واحد شیرین‌سازی فعال در سطح دنیا با ظرفیت نزدیک به 60 میلیون مترمکعب در روز وجود دارد [1]. در هر یک از واحدهای شیرین‌سازی آب شور فن‌آوری‌های گرمایی از جمله تقطیر ناگهانی چند مرحله‌ای²، تقطیر چندمرحله‌ای³، تراکم بخار⁴ و فن‌آوری‌های غشایی شامل میکروفیلتراسیون⁵، اولترافیلتراسیون⁶، نانوفیلتراسیون⁷ و اسمز معکوس⁸ به کار گرفته شده است. از بین این موارد تقطیر ناگهانی چندمرحله‌ای، تقطیر چندمرحله‌ای و اسمز معکوس به صورت تجاری و در مقیاس بزرگ استفاده می‌شوند که البته در کنار بازده بالای این روش‌ها باید به مصرف انرژی الکتریکی نیز اشاره نمود [2]. استفاده از این روش‌ها هزینه زیادی دارد مخصوصاً زمانی که به مقادیر کم تولید آب نیاز باشد. از سوی دیگر برای تولید الکتریسته و کاربرد آن در آب شیرین‌کن‌ها باید انرژی‌های فسیلی را در نیروگاه‌ها به انرژی الکتریسته تبدیل کرد که خود این انرژی‌های فسیلی می‌توان اثرات مخربی روی محیط زیست داشته باشد [3].

در حال حاضر مصرف انرژی جهان بر پایه‌ی سوخت‌های فسیلی است به طوری که 76 میلیون بشکه نفت روزانه در جهان مصرف می‌گردد و با وجود آگاهی از عواقب مصرف سوخت‌های فسیلی و اثرات آن بر محیط‌زیست، انتظار می‌رود این میزان تا 123 میلیون بشکه در سال 2025 افزایش یابد. باید دانست که استفاده از این حجم عظیم سوخت‌های فسیلی در آینده نزدیک مقادیر زیادی از گازهای آلاینده وارد محیط‌زیست می‌گردد. این میزان حجم از آلودگی به علت اثرات گلخانه‌ای گازهای تولید شده سبب 3 مشکل بزرگ زیست‌محیطی که عبارتند از باران اسیدی، تخریب لایه اوزن و تغییر اقلیم جهانی می‌گردد [4]. با توجه مطالب یاد شده، در سال‌های اخیر استفاده از انرژی خورشیدی به علت ارزان بودن، تجدیدپذیر بودن، دوست‌دار محیط زیست بودن، پایان ناپذیر بودن، فراوان بودن و ... برای ساخت آب‌شیرین‌کن‌ها، خشک‌کن‌ها و ... بسیار مورد توجه قرار گرفته است [5].

دستگاه‌های تقطیر خورشیدی می‌توانند راه حل مناسبی برای مناطقی که در آن‌ها مقادیر زیادی تابش خورشیدی وجود دارد، اما آب از کیفیت پایینی برخوردار است، ارائه دهند. با توجه به شرایط اقلیمی کشور ایران، نیاز به تولید آب شرب در ظرفیت‌های پایین و برای مناطق کم جمعیت و دورافتاده، موضوعی است که تاکنون کمتر مورد توجه قرار گرفته است؛ در حالی که در مناطق خشک و کویری که وسعت زیادی در نقاط مرکزی ایران دارند، از یک طرف نیاز به آب شیرین به‌عنوان یکی از مشکلات اساسی مردم این مناطق به شمار می‌آید و از طرف دیگر انرژی خورشید با شدت تابش مناسب در این مناطق در دسترس است. در کنار نیاز آب آشامیدنی، در این مناطق در بخش‌های کشاورزی و دامپروری نیز به شدت کمبود آب احساس می‌گردد. استفاده از سیستم‌های آب شیرین‌کن در کنار بهینه‌سازی مصرف آب در بخش کشاورزی و استفاده از کشت‌های گلخانه‌ای راهکار مناسبی به نظر می‌رسد.

بررسی منابع نشان می‌دهد که پژوهش‌های گسترده‌ای در مورد طراحی، ساخت و عملکرد آب‌شیرین‌کن‌های خورشیدی از جمله افزایش نرخ تولید دستگاه‌های تقطیری خورشیدی [6]، افزایش عملکرد دستگاه تقطیر خورشیدی [8,7] دستگاه تقطیر خورشیدی چند مرحله‌ای [9-11]، دستگاه تقطیر خورشیدی دو حوضچه‌ای تک شیب [13,12]، دستگاه تقطیر خورشیدی سه حوضچه‌ای تک شیب (یک طرفه) [14]، و دستگاه تقطیر خورشیدی هرمی [15]، دستگاه تقطیر خورشیدی با کلکتور صفحه تخت [8]، دستگاه تقطیر خورشیدی فعال دو طرفه (با دو شیب) [16]، استفاده از دستگاه‌های متمرکزکننده خورشیدی [18,17] و ... انجام شده است.

روش‌های متداول ریاضی برای بهینه‌سازی و مدل‌سازی فرایندهای حرارتی مورد استفاده قرار می‌گیرد. امکان ایجاد یک مدل مناسب برای بسیاری از فرایندهای حرارتی آب شیرین‌کن به صورت نظری وجود دارد، اما امکان توسعه این مدل‌ها برای برخی فرایندها با متغیرها و روابط غیرخطی وجود ندارد. در فرایند تقطیر، عواملی مانند شدت تابش خورشید، سرعت جریان باد، میزان تمرکز، طول متمرکزکننده، دمای آب ورودی، دمای محیط، دبی آب ورودی، دمای صفحه جاذب، دمای شیشه و ... مؤثرند. توسعه یک مدل ریاضی برای پیش‌بینی و بهینه‌سازی متغیرهای وابسته این مسأله در ارتباط با همه متغیرهای مستقل بسیار مشکل است [19].

مدل‌های دینامیکی فرآیندهای حرارتی نیز با در نظر گرفتن پیچیدگی فرایند از طریق ترکیب معادلات دیفرانسیل غیرخطی با مشتقات جزئی ایجاد می‌شوند که از طریق شبیه‌سازی عددی انجام می‌شود. حل این معادلات و اجرای آن‌ها در فرایند کنترل بسیار زمان بر است [20]. در شرایطی که روابط بین پارامترهای مستقل و وابسته پیچیده باشد، بهترین انتخاب، استفاده از روش‌های مدل‌سازی هوشمند است. یکی از این روش‌ها، شبکه‌های عصبی مصنوعی است که یک روش غیرالگوریتمی بوده و اساس آن بر مبنای آموزش و یادگیری به کمک داده‌های موجود است و قابلیت پیش‌بینی مقادیر متغیرهای وابسته را براساس متغیرهای مستقل در محدوده یادگیری دارد [21]. در چنین مواردی به‌علت تعدد متغیرها و فرایندهایی که تعریف دقیق و درک خاصی از آن‌ها وجود ندارد، مدل‌های شبکه عصبی مصنوعی بسیار مؤثر عمل می‌کنند و قادر هستند که هر تابع ریاضی را با دقت قابل قبولی تخمین بزنند [21]. کاهش تأثیر خطای داده‌ها و داده‌های از دست رفته و توانایی پیش‌بینی دو یا چند متغیر وابسته به‌طور همزمان از جمله مزیت‌های شبکه‌های عصبی است. همچنین نیاز به محاسبات طولانی برای حل معادلات دیفرانسیل با استفاده از روش‌های عددی نیست، در حالی که در یک شبکه عصبی مصنوعی، نتایج به صورت ضرب ساده ماتریس ورودی در ماتریس وزن به دست می‌آید [23,22].

بررسی منابع در مورد کاربرد شبکه‌های عصبی در فرآیند تقطیر در آب شیرین‌کن‌های خورشیدی نشان داد که شبکه‌های عصبی قابلیت بالا در پیش‌بینی و مدل‌سازی فرآیند تقطیر دارند. نتایج برخی از پژوهش‌ها از جمله پیش‌بینی تعیین عملکرد و بهینه‌سازی آب شیرین‌کن‌های خورشیدی تحت شرایط خشک آب و هوایی با استفاده از شبکه‌های عصبی [24]، تعیین مدل‌های مناسب بین تولید آب شیرین‌کن خورشیدی و شرایط آب هوایی محلی [25]، آنالیز عملکرد آب شیرین‌کن خورشیدی با استفاده از شبکه عصبی تحت شرایط مختلف (شدت تابش خورشید، دمای ورودی آب سرد و دبی‌ها مختلف) [26]، به‌کارگیری شبکه‌های عصبی مختلف برای یافتن سه برابری عملکرد آب شیرین‌کن‌های خورشیدی تحت شرایط آب و هوایی کشور اردن [27] و ... حاکی از عملکرد خوب شبکه‌های عصبی در فرآیند تولید آب

¹ Desalination² Multi Stage Flash³ Multi Effect Distillation⁴ Vapor Compression⁵ Microfiltration⁶ Ultrafiltration⁷ Nanofiltration⁸ Reverse Osmosis

شیرین در آب شیرین کن‌ها دارد.

گردید.

در این پژوهش از دو مدل شبکه‌های عصبی مصنوعی استاتیکی و دینامیکی به منظور پیش‌بینی عملکرد یک آب شیرین کن آبشاری مجهز به متمرکز کننده سهموی خطی استفاده گردید. تفاوت شبکه‌های عصبی مصنوعی استاتیک و دینامیک، مربوط به استفاده از خروجی شبکه به عنوان ورودی می باشد (شکل 2 و 3). در شبکه‌های دینامیک، خروجی شبکه با تاخیر، خروجی مدل یک ورودی وارد شبکه می‌شود ولی در شبکه‌های استاتیکی از خروجی مدل به عنوان ورودی شبکه استفاده نمی‌شود [28-30].

2- مواد و روش‌ها

"شکل 1" سامانه آب شیرین کن مورد استفاده در این تحقیق را نشان می‌دهد. این سامانه در شهر تهران (دانشکده کشاورزی دانشگاه تربیت مدرس) با مشخصات عرض و طول جغرافیایی 35.67 درجه شمالی و 51.43 درجه شرقی، با ارتفاع 1100 متر از سطح دریا مورد ارزیابی قرار گرفت. کلیه آزمایش‌ها در مرداد ماه از ساعت 8 صبح تا 19 عصر در فصل تابستان انجام



Fig. 1 Set up used in this study

شکل 1 سامانه مورد استفاده در این پژوهش




Fig. 2 Input and output neural network with static structure in this study

شکل 2 ورودی و خروجی‌های شبکه عصبی با ساختار استاتیک در این پژوهش




Fig. 3 Input and output neural network with dynamic structure in this study

شکل 3 ورودی و خروجی‌های شبکه عصبی با ساختار دینامیک در این پژوهش

$$\text{tansig} = \frac{2}{1 + \exp(-2z)} - 1 \quad (2)$$

تعداد کل الگوهای ورودی به شبکه 135 بود، که بصورت تصادفی به سه گروه آموزش (60%)، ارزیابی (25%) و تست (15%) تقسیم بندی شدند. همچنین نرخ آموزش برای تمامی حالات 0.2 و میزان مومنتم 0.1 در نظر گرفته شد. بهترین توپولوژی شبکه عصبی براساس دو معیار ضریب تعیین¹⁰ و میانگین مربعات خطا¹¹ مشخص گردید. بهترین برازشی که می‌تواند ارتباط بین متغیرهای مستقل (ورودی‌های شبکه) و متغیرهای وابسته (خروجی‌های شبکه) را توصیف کند آن توپولوژی است که دارای بیشترین ضریب تعیین و کمترین میزان میانگین مربعات خطا باشد [24].

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_{p,i} - x_{o,i})^2}{\sum_{i=1}^n (x_{p,i} - \bar{x}_{p,i})^2} \quad (3)$$

$$MSE = \frac{\sum_{i=1}^n (x_{p,i} - x_{o,i})^2}{n} \quad (4)$$

در رابطه بالا $x_{p,i}$ مقادیر همبسته (پیش‌بینی)، $x_{o,i}$ مقادیر مشاهده‌ای، $\bar{x}_{p,i}$ میانگین مقادیر مشاهده‌ای می‌باشد.

3- نتایج و بحث

3-1- شبکه عصبی استاتیک

"شکل 4" منحنی آموزش (خطا) بهترین شبکه را برای هر سه قسمت آموزش، ارزیابی و تست در حالت استاتیک نشان می‌دهد. خطای شبکه میانگین مربعات خطا برای این توپولوژی برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.0011، 0.0027 و 0.0024 می‌باشد. این شبکه در 10 تکرار¹² در مدت 0.45 ثانیه همگرا می‌شود. تحلیل رگرسیونی نشان داد، ضریب تبیین نیز برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.9898، 0.9899 و 0.9889 می‌باشد.

پایه‌ای‌ترین روش استفاده شده برای آموزش شبکه‌های عصبی، روش‌های مبتنی بر گرادین می‌باشند. تکنیک کاربردی گرادین نزولی جهت تنظیم پارامترهای شبکه‌های عصبی کاربرد گسترده‌ای داشته است. هر شبکه عصبی از سه لایه ورودی، میانی یا مخفی و خروجی تشکیل شده است. تعداد نرون در لایه اول یا ورودی، به تعداد عوامل اولیه و تعداد نرون در لایه خروجی به تعداد عوامل نهایی موردنظر، بستگی دارد. لایه مخفی می‌تواند از یک یا چندین لایه تشکیل شود که تعداد نرون‌های هر لایه آن متغیر است و عموماً به روش سعی و خطا تعیین می‌شود. در این تحقیق ساختار شبکه عصبی با 5 عامل شدت تابش خورشید، دمای محیط، دبی آب ورودی، دمای آب ورودی و زمان بصورت پنج نرون در لایه ورودی و دو عامل میزان آب شیرین تولیدی و دمای جاذب به‌عنوان نرون‌های لایه خروجی مدل‌سازی گردید. پارامترهای ترکیبی مانند تعداد لایه‌های پنهان، تعداد نرون‌ها و تعداد چرخه آموزش در طی فرآیند آموزش شبکه عصبی مصنوعی به روش آزمون و خطا تعیین شد. در این تحقیق شبکه‌های پس انتشار پیشخور¹ برای حالت استاتیک و شبکه‌های بازگشتی² برای حالت دینامیک و الگوریتم‌های لوببرگ-مارکوارت³، نرخ یادگیری متغیر پس انتشار⁴، پس انتشار ارتجاعی (انعطاف‌پذیر)⁵ و گرادین درهم آمیخته مدرج⁶ برای بهنگام‌سازی وزن‌های شبکه‌های موردنظر، به کار گرفته شدند. برای بهینه‌سازی ساختار شبکه از سه تابع فعال‌سازی تابع سیگموئید لگاریتمی⁷، تابع خطی⁸ و تانژانت هایپربولیک سیگموئید⁹ استفاده شد [31,29].

$$\text{logsig} = \frac{1}{1 + \exp(-z)} \quad (1)$$

¹ Feed Forward Back Propagation

² Recurrent

³ Levenberg-Marquardt

⁴ traingdx

⁵ trainrp

⁶ trainscg

⁷ logsig

⁸ purelin

⁹ tansig

¹⁰ R2

¹¹ MSE

¹² epoch

این ساختار نشان می‌دهد که شبکه در لایه میانی به صورت تک لایه و از 20 نرون تشکیل شده است. با افزایش تعداد لایه‌های میانی میزان خطا در آموزش شبکه تغییر قابل ملاحظه‌ای نداشت و بسیاری از موارد نیز میزان خطا افزایش یافت. همچنین اثرات به‌کارگیری توابع فعالیت مختلف نشان داد که تابع فعالیت سیگموئید لگاریتمی با الگوریتم یادگیری لونیگ-مارکوارت می‌تواند دقت بالایی در پیش‌بینی را داشته باشد. خلاصه استفاده از شبکه‌های عصبی استاتیک با توابع آستانه و الگوریتم‌های مختلف در جدول (1) آمده است.

با توجه به جدول 1 بیشترین مدت زمان لازم برای همگرا شدن الگوریتم‌های مختلف مربوط به الگوریتم گرادیان درهم‌آمیخته مدرج و کمترین زمان لازم مربوط به الگوریتم لونیگ-مارکوارت می‌باشد. همچنین با توجه به جدول بالا بیشترین و کمترین میزان خطا در هنگام آموزش شبکه نیز به ترتیب مربوط به الگوریتم‌ها لونیگ-مارکوارت و گرادیان درهم‌آمیخته مدرج می‌باشد. بنابراین با توجه به نتایج بدست آمده در جدول 1 می‌توان نتیجه گرفت که بهترین الگوریتم برای این پژوهش در ساختار شبکه عصبی استاتیک، الگوریتم لونیگ-مارکوارت می‌باشد.




Fig. 4 MSE for static neural network

شکل 4 میانگین مربعات خطا برای شبکه عصبی استاتیک

نتایج حاصل از استفاده شبکه عصبی استاتیکی با الگوریتم‌ها و توابع آستانه مختلف (جدول 1) نشان داد که شبکه‌ای که می‌تواند بهترین پیش‌بینی میزان تولید و درجه حرارت بخار آب را داشته باشد، دارای ساختار 20-5 می‌باشد.

جدول 1 ضرایب و شاخص‌های آماری شبکه استاتیک با استفاده از الگوریتم‌ها و توابع آستانه مختلف

Table 1 Coefficients and statistical indicators of static network by using various algorithms and threshold functions

تابع فعالیت	نرون در لایه مخفی 1	نرون در لایه مخفی 2	ضریب تبیین آموزش	ضریب تبیین اعتبار سنجی	ضریب تبیین ارزیابی	میانگین مربعات خطا آموزش	میانگین مربعات خطا اعتبار سنجی	میانگین مربعات خطا ارزیابی	چرخه تکرار	زمان (ثانیه)
الگوریتم لونیگ-مارکوارت										
لگاریتم	5	0	0.9891	0.9653	0.9646	0.0427	0.1395	0.4596	24	3
لگاریتم	10	0	0.9885	0.9776	0.9689	0.0170	0.0827	0.2701	14	2.36
لگاریتم	20	0	0.9898	0.9899	0.9889	0.0011	0.0027	0.0034	10	0.45
لگاریتم	30	0	0.9795	0.9693	0.9739	0.0020	0.2371	0.2411	15	2.75
لگاریتم/تانژانت	20	10	0.9789	0.9781	0.9795	0.0021	0.0056	0.0020	14	2.25
لگاریتم/تانژانت	10	5	0.9693	0.9566	0.9658	0.0019	0.0461	0.0351	12	1.98
الگوریتم نرخ یادگیری متغیر پس انتشار										
لگاریتم	10	0	0.7762	0.8058	0.7762	0.0545	0.0586	0.0476	93	4.35
لگاریتم	20	0	0.8479	0.7794	0.7615	0.0379	0.0168	0.0702	78	4.01
لگاریتم	35	0	0.8314	0.7883	0.8782	0.0442	0.1110	0.0338	68	3.72
لگاریتم/خطی	10	5	0.7652	0.8200	0.8515	0.0606	0.0559	0.0304	84	4.78
لگاریتم/تانژانت	20	15	0.8017	0.7547	0.6875	0.0355	0.0658	0.0938	75	4.59
تانژانت/لگاریتم	15	10	0.9735	0.9683	0.9851	0.0073	0.0041	0.0019	97	5.12
الگوریتم پس انتشار ارتجاعی										
لگاریتم	10	0	0.9639	0.9618	0.9638	0.0039	0.0040	0.0014	39	2.85
تانژانت	15	0	0.9611	0.9570	0.9417	0.0071	0.0087	0.0049	30	2.24
تانژانت	50	0	0.8889	0.9230	0.8762	0.0037	0.0113	0.2160	49	3.08
لگاریتم/خطی	20	10	0.9698	0.7326	0.9837	0.0042	0.0095	0.0039	40	2.88
لگاریتم/تانژانت	25	15	0.9868	0.9776	0.9850	0.0021	0.0021	0.0069	43	3.01
لگاریتم/لگاریتم	35	20	0.9535	0.9594	0.9716	0.0008	0.0004	0.0039	29	2.87
الگوریتم گرادیان درهم‌آمیخته مدرج										
لگاریتم	35	0	0.9648	0.9229	0.9323	0.0043	0.0243	0.0121	52	2.21
تانژانت	30	0	0.9701	0.9453	0.9108	0.0021	0.0345	0.0547	64	2.99
خطی	45	0	0.8611	0.8953	0.8946	0.0267	0.0413	0.0240	19	1.88
لگاریتم/خطی	15	10	0.8845	0.8789	0.8769	0.0155	0.0597	0.0431	38	3.04
لگاریتم/لگاریتم	20	10	0.9789	0.9174	0.9413	0.0024	0.0017	0.0085	33	3.31
لگاریتم/تانژانت	15	5	0.9473	0.9274	0.9555	0.0088	0.0071	0.0086	20	2.67




Fig. 5 Correlation between experimental data and forecasting data A) in production of fresh water B) Steam temperatures by using static network

شکل 5 همبستگی داده‌های تجربی با داده‌های پیش‌بینی شده (A) در میزان تولید آب شیرین (B) برای درجه حرارت بخار آب برای شبکه استاتیک

مختلف می‌توان به این نتیجه دست یافت که شبکه‌ها با الگوریتم یادگیری لونیگ-مارکوارت با سرعت بالا همگرا شده و در عین حال شبکه‌ها با الگوریتم یادگیری گرادیان درجه‌نیز به زمان بالایی برای همگرا شدن دارند. در عین حال دقت و میزان خطای خروجی الگوریتم‌های لونیگ-مارکوارت نسبت به سایر الگوریتم‌های به کار گرفته شده در این تحقیق بالاتر می‌باشد.




Fig. 6 variation of gradient descent versus the converging time for static neural network

شکل 6 تغییرات گرادیان نزولی در مقابل زمان همگرا شدن شبکه استاتیک




Fig. 7 MSE for dynamic neural network (NEWLRN)

شکل 7 مجموع مربعات خطا برای شبکه عصبی دینامیک بازگشتی

"شکل‌های 5" نشان می‌دهد که داده‌های واقعی با داده‌های پیش‌بینی انطباق بیشتری برای میزان آب تولید و درجه حرارت بخار آب دارد. با بررسی "اشکال 5 و 6" می‌توان دریافت که داده‌های عملی و داده‌های پیش‌بینی شده با دقت بالایی به خط 45 درجه نزدیک می‌باشند که این امر نشان‌دهنده توانایی بالای شبکه‌های عصبی در پیش‌بینی داده‌های میزان تولید آب شیرین و دمای بخار آب می‌باشد.

همچنین "شکل 6" تغییرات گرادیان نزولی را با گذشت زمان در بهترین شبکه با توپولوژی 2-20-5 نشان می‌دهد. همان‌طور که مشاهده می‌شود با گذشت زمان کاهش یافته تا به کمترین مقدار خود رسیده و شبکه با توپولوژی موردنظر همگرا می‌گردد.

2-3- شبکه‌های عصبی دینامیک

"شکل 7" منحنی آموزش (خطا) شبکه دینامیک برگشتی¹ که بهترین نتیجه را در فرآیند تولید آب شیرین و دمای بخار آب داشت را برای هر سه قسمت آموزش، ارزیابی و تست داشته است را نشان می‌دهد. خطای میانگین مربعات شبکه برای این توپولوژی برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.0018، 0.0007 و 0.0004 می‌باشد. این شبکه در 13 تکرار در مدت 8.11 ثانیه همگرا می‌شود. تحلیل رگرسیونی نشان داد، ضریب تبیین نیز برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.9922، 0.9894 و 0.9901 می‌باشد.

با توجه به جدول 2 و 3 مشخص می‌شود در این تحقیق مدل‌های شبکه عصبی مصنوعی دینامیک به کار رفته به دلیل تأثیر تأخیر خروجی به عنوان ورودی شبکه و افزایش قدرت یادگیری شبکه، نسبت به مدل‌های شبکه عصبی مصنوعی استاتیک در هر دو مرحله آموزش و پیش‌بینی، برتری دارند. نتایج استفاده از شبکه‌های عصبی دینامیک با توابع آستانه و الگوریتم‌های مختلف به ترتیب برای شبکه پیشخور آشناری در جدول 2 و شبکه دینامیکی برگشتی در جدول 3 آمده است. مقایسه نتایج بدست آمده حاصل از استفاده شبکه‌های دینامیک نشان داد که شبکه دینامیکی برگشتی با دقت و قدرت بیشتری نسبت به شبکه پیشخور آشناری² می‌تواند فرآیند تولید و دمای بخار آب را پیش‌بینی کند. با مقایسه زمان همگرا شدن شبکه‌ها با الگوریتم‌های

¹ NEWLRN

² NEWCF

جدول 2 ضرایب و شاخص‌های آماری شبکه دینامیک پیش‌خور آبخاری با استفاده از الگوریتم‌ها و توابع آستانه مختلف

Table 2 Coefficients and statistical indicators of dynamic network NEWCF by using various algorithms and threshold functions

تابع فعالیت	نرون در لایه مخفی 1	نرون در لایه مخفی 2	ضریب تبیین آموزش	ضریب تبیین اعتبار سنجی	ضریب تبیین ارزیابی	میانگین مربعات خطا آموزش	میانگین مربعات خطا اعتبار سنجی	میانگین مربعات خطا ارزیابی	چرخه تکرار	زمان (ثانیه)
الگوریتم لونبرگ-مارکوارت										
لگاریتم	5	0	0.9655	0.9724	0.9457	0.0452	0.0242	0.1322	34	5.4
لگاریتم	10	0	0.9521	0.9821	0.9537	0.0475	0.0991	0.0824	37	5.91
لگاریتم	20	0	0.9677	0.9729	0.9766	0.0632	0.0728	0.0456	44	6.27
لگاریتم	30	0	0.9699	0.9811	0.9724	0.0845	0.0124	0.0347	46	6.87
لگاریتم/تانزان	20	10	0.9572	0.9469	0.9612	0.1314	0.1998	0.1001	87	7.55
لگاریتم/تانزان	10	5	0.9768	0.9702	0.9628	0.0314	0.0941	0.0989	81	7.01
الگوریتم نرخ یادگیری متغیر پس انتشار										
لگاریتم	10	0	0.9139	0.9532	0.7786	0.0183	0.0451	0.0474	89	8.14
لگاریتم	20	0	0.9200	0.8977	0.8840	0.0455	0.0559	0.0526	69	6.99
لگاریتم	35	0	0.9001	0.9430	0.8564	0.0270	0.0385	0.0337	99	8.21
لگاریتم/خطی	10	5	0.9328	0.9319	0.8871	0.0306	0.0553	0.0805	89	8.99
لگاریتم/تانزان	20	15	0.8825	0.8495	0.9022	0.0372	0.0343	0.0421	86	8.36
تانزان/لگاریتم	15	10	0.8882	0.8801	0.8050	0.0417	0.0533	0.0484	78	7.96
الگوریتم پس انتشار ارتجاعی										
لگاریتم	10	0	0.9627	0.9475	0.9231	0.0057	0.0150	0.0269	40	6.55
تانزان	15	0	0.9700	0.9114	0.9147	0.0049	0.0104	0.0278	124	7.64
تانزان	50	0	0.9196	0.9058	0.9015	0.0294	0.0337	0.0457	24	5.01
لگاریتم/خطی	20	10	0.9537	0.8624	0.8643	0.0085	0.0240	0.0222	36	5.71
لگاریتم/تانزان	25	15	0.9278	0.8846	0.8931	0.0201	0.0181	0.0185	39	5.54
لگاریتم/لگاریتم	35	20	0.9665	0.9364	0.9434	0.0058	0.0183	0.0428	35	6.27
الگوریتم گرادیان درهم آمیخته مدرج										
لگاریتم	35	0	0.9193	0.9501	0.8497	0.0051	0.0087	0.0113	36	5.21
تانزان	30	0	0.9633	0.9218	0.8770	0.0043	0.0022	0.0084	74	6.64
خطی	45	0	0.8934	0.9109	0.9008	0.0198	0.0087	0.0178	21	4.77
لگاریتم/خطی	15	10	0.8365	0.8647	0.8741	0.0247	0.0091	0.0082	58	5.71
لگاریتم/لگاریتم	20	10	0.9621	0.9232	0.9455	0.0058	0.0098	0.0077	46	5.09
لگاریتم/تانزان	15	5	0.8844	0.9134	0.8978	0.0128	0.0099	0.0011	37	4.38

های استاتیک دارای توانایی بالاتر در پیش‌بینی میزان تولید آب شیرین و دمای بخار آب در آب شیرین‌کن‌های خورشیدی می باشد، اما باید توجه داشت که شبکه‌های عصبی استاتیک با سرعت بالاتری نسبت به شبکه‌های دینامیک می‌توانند همگرا شده و فرآیند مدل‌سازی را انجام دهند که این نشان از برتری شبکه‌های استاتیکی نسبت به شبکه‌های دینامیکی در این بخش (مدت زمان مدل‌سازی) می‌باشد. بنابراین می‌توان با توجه به ماهیت شبکه‌های دینامیک و نتایج بدست آمده بیان کرد که این شبکه‌ها توانایی بالایی را در شبیه‌سازی فرآیندهای غیر خطی و پیچیده مانند عملیات انتقال جرم و حرارت در فرآیند تولید آب شیرین در آب شیرین‌کن‌ها را دارا می باشند. در واقع می‌توان با توجه به نتایج بدست آمده در جداول 1، 2 و 3 ادعا کرد که برای مدل‌سازی شرایط مختلف و پیچیده از جمله شرایط مختلف جوی مانند شدت تابش، دمای محیط و ... که بر عملکرد سامانه‌های آب‌شیرین‌کن تاثیرگذار هستند، شبکه‌های عصبی ابزار قدرتمندی هستند که با دقت بالا، هزینه و زمان کم می‌توانند این فرآیندها را مدل‌سازی کنند. نتایج بدست آمده در این پژوهش با نتایج پژوهش‌های نازقلیچی و همکاران [29]، بنی‌حبیب و همکاران [28]، همدان و همکاران [27] مطابقت دارد.

"شکل‌های 8" همبستگی بین داده‌های واقعی و پیش‌بینی شده را برای میزان تولید آب شیرین و دمای بخار آب را در شبکه دینامیک نشان می‌دهد. با بررسی این دو شکل می‌توان دریافت که داده‌های واقعی و داده‌های پیش‌بینی برای میزان آب تولید و درجه حرارت بخار آب به خط 45 درجه نزدیکی زیادی دارند و این موید خطای کم شبکه دینامیک در فرآیند پیش‌بینی می‌باشد.

"شکل 9" تغییرات گرادیان نزولی را با افزایش گذشت زمان در بهترین حالت پیش‌بینی شبکه دینامیک بازگشتی با توپولوژی 2-30-5 نشان می‌دهد. همانطور که مشاهده می‌شود گرادیان نزولی با گذشت زمان در ابتدا به سرعت کاهش یافته و با گذشت زمان به کمترین مقدار خود رسیده و شبکه با توپولوژی مورد نظر همگرا می‌گردد.

3-3- مقایسه شبکه‌های استاتیک و دینامیک

نتایج حاصل از کاربرد شبکه‌های عصبی نشان داد که استفاده از شبکه‌های عصبی دینامیک می‌تواند با دقت بالاتری نسبت به شبکه‌های عصبی استاتیک فرآیند تولید آب شیرین و دمای بخار آب را پیش‌بینی کند. مقایسه نتایج جداول 1، 2 و 3 نشان می‌دهد شبکه‌های دینامیک نسبت به شبکه




Fig. 8 Correlation between experimental data and forecasting data A) in production of fresh water B) Steam temperatures by using dynamic network NEWLRN

شکل 8 همبستگی داده‌های تجربی با داده‌های پیش‌بینی شده (A) در میزان تولید آب شیرین (B) درجه حرارت بخار آب با استفاده از شبکه دینامیک بازگشتی




Fig. 9 Variations of gradient descent versus the converging time for dynamic neural network NEWLRN

شکل 9 تغییرات گرادیان نزولی در مقابل زمان همگرا شدن شبکه دینامیک بازگشتی

می‌باشند.

4- نتیجه‌گیری

نتایج حاصل از ارزیابی مدل‌های شبکه عصبی استاتیکی و دینامیکی در پیش‌بینی میزان آب شیرین تولیدی و دمای بخار آب در یک آب شیرین کن خورشیدی به شرح زیر می‌باشد:

1- به کارگیری الگوریتم‌های مختلف در شبکه عصبی استاتیک نشان داد که الگوریتم لوبنبرگ-مارکوارت نسبت به الگوریتم‌های دیگر با سرعت کمتر و با دقت بالاتری می‌تواند فرآیند مدل سازی را انجام دهد.

2- مقایسه الگوریتم‌های مختلف در شبکه‌های استاتیکی و دینامیکی نشان داد که بالاترین زمان برای همگرا شدن شبکه مربوط به الگوریتم نرخ یادگیری متغیر پس انتشار و کمترین زمان مربوط به الگوریتم لوبنبرگ-مارکوارت می‌باشد.

3- تغییرات گرادیان نزولی در هر دو شبکه استاتیکی و دینامیکی نشان داد که شبکه عصبی به خوبی با کاهش میزان خطا می‌تواند روند پیش‌بینی را انجام دهد.

4- شبکه‌های عصبی دینامیکی به علت بازخورد داده‌ها مدت زمان فرآیند مدل سازی را طولانی‌تر می‌کنند و در عین حال از دقت بالاتری برخوردار هستند.

5- با توجه به شرایط بسیار پیچیده مابین متغیرهای ورودی و خروجی در سامانه‌های آب شیرین کن و با توجه به نتایج به دست آمده در این پژوهش به نظر می‌رسد که شبکه‌های عصبی ابزار قدرتمندی در مدل سازی این پارامترها

5- تقدیر و تشکر

نویسندگان از صندوق حمایت از پژوهشگران و فناوران کشور به خاطر پشتیبانی مالی از این طرح کمال تشکر و قدردانی را دارند.

6- مراجع

- [1] C. Gasson, *Forecast Trends in Desalination: A River Flowing Backwards from the Sea*, Presented at the IDA World Congress, Dubai, UAE, 2009.
- [2] G. Xiao, X. Wang, M. Ni, F. Wang, W. Zhu, Luo, Z. K. Cen, A review on solar stills for brine desalination, *Applied Energy*, Vol. 103, pp. 642-652, 2013.
- [3] F. Farshchi Tabrizi M. Dashtban, H. Moghaddam, K. Razzaghi, Effect of water flow rate on internal heat and mass transfer and daily productivity of a weir-type cascade solar still, *Desalination*, Vol. 26, pp. 239-247, 2010.
- [4] S. A. Kalogirou, Solar thermal collectors and applications, *Progress in Energy and Combustion Science*, Vol. 30, No. 3, pp. 231-295, 2004.
- [5] E. K. Akpinar, Drying of mint leaves in a solar dryer and under open sun: modelling, performance analyses, *Energy Conversion and Management*, Vol. 51, No. 12, pp. 2407-2018, 2010.
- [6] S. Kalogirou, *Solar Energy Engineering: Processes and Systems*, pp. 421-468, Elsevier Press, Netherlands, 2009.
- [7] T. Arjunan, H. Aybar, N. Nedunchezian, Status of solar desalination in India, *Renewable and Sustainable Energy Reviews*,

- [21] A.P. Engelbrecht, *Computational Intelligence, an Introduction*, pp. 27-54, John Wiley & Sons Ltd, the Atrium, Southern Gate, Chichester, West Sussex PO19 8SQ, England, 2007.
- [22] M.R. Islam, S.S. Sablain, A.S. Mujumdar, An artificial network model for prediction of drying rate, *Drying Technology*, Vol. 21, No.9, pp. 325-334, 2003.
- [23] S. Gorjian, T. Tavakkol Hashjin, M. Khoshtaghaza, Designing and optimizing a back propagation neural network to model a thin layer drying process, *International Agrophysics*, Vol. 25, No. 1, pp. 13-39, 2011.
- [24] A.F. Mashaly, A.A. Alazba, A.M. Al-Awaadh, M.A. Mattar, Predictive model for assessing and optimizing solar still performance using artificial neural network under hyper arid environment, *Solar Energy*, Vol. 118, pp. 41-58, 2015.
- [25] N.I. Santos, A.M. Said, D.E. James, N.H. Venkatesh, Modeling solar still production using local weather data and artificial neural networks, *Renewable Energy*, Vol. 40, No. 1, pp. 71-79, 2012.
- [26] R. Porrazzo, A. Cipollina, M. Galluzzo, G. Micale, A neural network-based optimizing control system for a seawater-desalination solar-powered membrane distillation unit, *Computer and Chemical Engineering*, Vol. 54, pp. 79-96, 2013.
- [27] M. A. Hamdan, Haj R. A. Khalil, E. A. M. Abdelhafez, Comparison of neural network models in the estimation of the performance of solar still under jordanian climate, *Journal of Clean Energy Technologies*, Vol. 1, No.3, pp. 238-242, 2013.
- [28] M.E. Banihabib, M. Valipour, M Behbahani, Comparison of autoregressive static and artificial dynamic neural network for the forecasting of monthly inflow of dez reservoir, *Quarterly journal of Environmental Science and Technology*, Vol. 13, No. 4, pp. 1-14, 2012 (in Persian فارسی).
- [29] T. Nazghelichi, M.H. Kianmehr, M. Aghbashlo, Prediction of carrot cubes drying kinetics during fluidized bed drying by artificial neural network. *Journal of Food Science and Technology*, Vol. 48, No. 5, pp. 542-550, 2011.
- [30] A. Banakar, M.F. Azeem, Local Recurrent Sigmoidal-Wavelet Neurons in Feed-Forward Neural Network for Forecasting of Dynamic Systems: Theory, *Applied Soft Computing*, Vol. 12, No. 3, pp. 1187-1200, 2012.
- [31] M. Khayet, C. Cojocar, M. Essalhi, 2011. Artificial neural network modeling and response surface methodology of desalination by reverse osmosis. *Journal of Membrane Science*, Vol. 368, No. 1-2, pp. 202-214.
- Vol. 13, No. 9, pp. 2408-2418, 2009.
- [8] K. Sampathkumar, T. Arjunan, P. Pitchandi, P. Senthilkumar, Active solar distillation-A detailed review, *Renewable and Sustainable Energy Reviews*, Vol. 14, No. 6, pp. 1503-1526, 2010.
- [9] R. Adhikari, A. Kumar, G. Sootha, Simulation studies on a multi-stage stacked tray solar still, *Solar Energy*, Vol. 54, pp. No. 5, 317-325, 1995.
- [10] H. Tanaka, multiple-effect coupled solar still, *Desalination*, Vol. 130, No. 3, pp. 279-293, 2000.
- [11] H. Tanaka, T. Nosoko, T. Nagata, Parametric investigation of a basin-type-multiple-effect coupled solar still, *Desalination*, Vol. 130, No. 3, pp. 295-304, 2000b.
- [12] A. Al-Karaghoul, W. Alnaser, Experimental comparative study of the performances of single and double basin solar-stills, *Applied Energy*, Vol. 77, No. 3, pp. 317-325, 2004a.
- [13] A. Al-Karaghoul, W. Alnaser, Performances of single and double basin solar-stills, *Applied Energy*, Vol. 78, No. 3, pp. 347-354, 2004b.
- [14] A. El-Sebaai, Thermal performance of a triple-basin solar still, *Desalination*, Vol. 174, No. 1, pp. 23-37, 2005.
- [15] H.E.S. Fath, M. El-Samanoudy, K. Fahmy, A. Hassabou, Thermal-economic analysis and comparison between pyramid-shaped and single-slope solar still configurations, *Desalination*, Vol. 159, No. 1, pp. 69-79, 2003.
- [16] V. Dwivedi, G. Tiwari, Experimental validation of thermal model of a double slope active solar still under natural circulation mode, *Desalination*, Vol. 250, No. 1, pp. 49-55, 2010.
- [17] A. Scrivani, T. El Asmar, U. Bardi, Solar trough concentration for fresh water production and waste water treatment, *Desalination*, Vol. 206, No. 1-3, pp. 485-493, 2007.
- [18] B. Chaouchi, A. Zrelli, S. Gabssi, Desalination of brackish water by means of a parabolic solar concentrator, *Desalination*, Vol. 217, No. 1-3, pp. 118-126, 2007.
- [19] C. Bonazzi, M.A. Du Peuty, A. Themelin, Influence of drying conditions on the processing quality of rough rice, *Drying Technology*, Vol. 15, No. 3-4, pp. 1141-1157, 1997.
- [20] F. Courtois, A. Lebert, A. Duquenoy, J. C. Lasseran, J. J. Bimbenet, Modeling of drying in order to improve processing quality of maize, *Drying Technology*, Vol. 9, No.4, pp. 927-945, 1991.