ماهنامه علمى پژوهشى



mme.modares.ac.ir

مقایسه شبکههای عصبی دینامیکی و استاتیکی در پیشبینی عملکرد آب شیرین *ک*ن 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- دانشجوى دكترى، مهندسى مكانيك بيوسيستم، دانشگاه تربيت مدرس، تهران

* سارى، صندوق يستى a.motevali@sanru.ac.ir، 578

چکیدہ	اطلاعات مقاله
در این پژوهش با بهکارگیری 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 مدلسازی کنند. شبکه عصبی	مقاله پژوهشی کامل دریافت: 19 مهر 1395 پذیرش: 19 آبان 1395 ارائه در سایت: 21 آذر 1395
استاتیک با سرعت بالاتر نسبت به شبکههای دینامیکی میتواند فرآیند مدلسازی را انجام دهد در عین حال به نظر میرسد که میزان خطا در فرآیند مدل سازی با به کارگیری شبکههای دینامیک کاهش می یابد. ضریب تبیین برای الگوهای آموزش، ارزیابی و تست در شبکه استاتیک به	کلید واژگان: پیش بینی
ترتیب 0.9898، و 1998، و 2008، میاشد. در حالی که ضریب تبیین برای الگوهای آموزش، از یابی و تست در شبکه دینامیک به ترتیب 2000 0.9894، و 2000 ماده میاشد. در حالی که ضریب تبیین برای الگوهای آموزش، از یابی و تست در شبکه دینامیک به ترتیب	به عبدی مدلسازی شبکه عصبی آب شیدین کن خوبشیدی
0.9922، 90.984 و 0.9921 میباشد. همچنین میزان خطای شبخه در سبخه استانیک برای الخوهای امورش، ارزیابی و نست به ترتیب 0.0011 و 0.0024 و برای شبکههای دینامیک به ترتیب 0.0018، 0.0007 و 0.0004 میباشد. مقایسه شبکههای استاتیک و	اب سیرین کل خورسیدی
دینامیک نشان داد که شبکههای دینامیک با دقت بیشتری نسبت به شبکههای استاتیک میتواند میزان تولید اب شیرین و دمای بخار اب را با توجه به تغییرات پارامترهای جوی پیشربینی 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 Seyedi²

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 ABSTRACT In this research with utilization of various neural networks models, the relationship between the amount Original Research Paper Received 10 October 2016 of water production and the temperature of the vapor with different weather conditions, time of day and Accepted 09 November 2016 several water debits in desalination system equipped with linear solar parabolic concentrator was Available Online 11 December 2016 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 Keywords: speed than dynamic neural network. However, it seems that the amount of error using dynamic Prediction networks was reduced in process modeling. Coefficient of determination (R^2) for training, validation Neural networks modelling solar desalination and testing in static networks was 0.9898, 0.9899 and 0.9889, respectively. While coefficient of determination (R²) 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% بهصورت مستقیم در دسترس انسان میباشد. با توجه به افزایش

Please cite this article using:

A. Banakar, A. Motevali, M. Montazeri, S. R. Mousavi Seyedi, 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)



تامین آب شیرین در آینده فرآیند نمکزدایی از آب شور میباشد. نمکزدایی 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 تقطير ناگهاني چند مرحلهاي²، تقطير چندمرحلهاي³، تراكم بخار⁴و فن آورى هاى غشايى شامل ميكروفيلتراسيو ن⁵ ، اولترافيلتراسيو ن⁶ ، نانوفیلتراسیون⁷ و اسمز معکوس⁸ به کار گرفته شده است. از بین این موارد تقطیر ناگهانی چندمرحله ای، تقطیر چندمرحله ای و اسمز معکوس به صورت تجاری و در مقیاس بزرگ استفاده می شوند که البته در کنار بازده بالای این روشها باید به مصرف انرژی الکتریکی نیز اشاره نمود[2]. استفاده از این روشها هزینهی زیادی دارد مخصوصا زمانی که به مقادیر کم تولید آب نیاز باشد. از سوی دیگر برای تولید الکتریسته و کاربرد آن در آب شیرین کنها 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 می گردد 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 می گردد. این میزان حجم از آلودگی به علت اثرات گلخانهای گازهای تولید شده سبب 3 مشکل بزرگ زیستمحیطی که عبارتند از باران اسیدی، تخریب لایه ازون و تغییر اقلیم جهانی می گردد [4]. با توجه مطالب یاد شده، در سالهای اخیر استفاده از انرژی خورشیدی بهعلت ارزان بودن، تجدیدپذیر بودن، دوستدار محیط زیست بودن، پایان ناپذیر بودن، فراوان بودن و ... برای ساخت آبشیرین کن-ها، خشک کنها 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 آبشیرین کن های 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 [13,1]، 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 [18,1] و ... انجام شده است.

روشهای متداول ریاضی برای بهینهسازی و مدلسازی فرایندهای حرارتی مورد استفاده قرار می گیرد. امکان ایجاد یک مدل مناسب برای بسیاری از فرایندهای حرارتی آب شیرین کن 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 متمرکز کننده، دمای آب ورودی، دمای محیط، دبی آب ورودی، دمای صفحه جاذب، دمای شیشه و ... مؤثرند. توسعهٔ یک مدل ریاضی برای پیشبینی و بهینهسازی متغیرهای وابستهٔ این مسأله در ارتباط با همهٔ 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 جزیی ایجاد می شوند که از طریق شبیهسازی عددی انجام می شود. 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، شبکه های عصبی مصنوعی است که یک روش غیرالگوریتمی بوده و اساس آن برمبنای آموزش و یادگیری به کمک داده های موجود است و قابلیت پیش بینی مقادیر متغیرهای وابسته را براساس متغیرهای مستقل در محدودهٔ 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 كه هر تابع رياضي را با دقت قابل قبولي تخمين بزنند [21]. کاهش تأثیر خطای دادهها و داده های از دست رفته و توانایی پیشبینی دو یا چند متغیر وابسته به طور همزمان از جمله مزیت های شبکه های عصبی است. همچنین نیاز به محاسبات طولانی برای حل معادلات دیفرانسیل با استفاده از روشهای عددی نیست، در حالی که در یک شبکهٔ عصبی مصنوعی، نتایج به صورت ضرب سادهٔ ماتریس ورودی در ماتریس وزن به دست می آید [23,22].

بررسی منابع در مورد کاربرد شبکههای عصبی در فرآیند تقطیر در آب شیرین کنهای 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 شیرین کنهای خورشیدی تحت شرایط خشک آب و هوایی با استفاده از شبکههای عصبی [24]، تعیین مدلهای مناسب بین تولید آب شیرین کن خورشیدی و شرایط آب هوایی محلی [25]، آنالیز عملکرد آب شیرین کن خورشیدی با استفاده از شبکه عصبی تحت شرایط مختلف (شدت تابش خورشید، دمای ورودی آب سرد و دبیها مختلف) [26]، به کارگیری شبکههای عصبی مختلف برای یافتن سه برابری عملکرد آب شیرین کن خورشیدی تحت شرایط آب و هوایی کشور

¹ Desalination ² Multi Stage Flash

³Multi Effect Distillation

⁴Vapor Compression

⁵ Microfiltration

⁶ Ultrafiltration

⁷ Nanofiltration ⁸ Reverse Osmosis

شیرین در آبشیرین کنها دارد.

2- مواد و روشها

"شکل 1" سامانه آب شیرین کن مورد استفاه در این تحقیق را نشان می دهد. 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 آزمایش ها در مرداد ماه از ساعت 8 صبح تا 19 عصر در فصل تابستان انجام

گردید.

در این پژوهش از دو مدل شبکههای عصبی مصنوعی استاتیکی و دینامیکی به منظور پیش بینی 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 بهعنوان ورودی می باشد (شکل 2 و 3). در شبکههای دینامیک، خروجی شبکه با تاخیر، خروجی مدل یک ورودی وارد شبکه می شود ولی در شبکههای استاتیکی از خروجی مدل به عنوان ورودی شبکه استفاده نمی شود [20-30].



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

$$tansig = \frac{2}{1 + \exp(-2z)} - 1$$
 (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].

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

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

 $ar{x}_{p,i}$ در رابطه بالا $x_{p,i}$ مقادیر همبسته (پیش.بینی)، $x_{o,i}$ مقادیر مشاهدهای، $ar{x}_{p,i}$ میانگین مقادیر مشاهدهای می،باشد.

3- نتايج و بحث

1-3- 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، 20007 و 0.0024 میباشد. این شبکه در 10 تکرار¹² در مدت 0.45 ثانیه همگرا میشود. تحلیل رگرسیونی نشان داد، ضریب تببین نیز برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.9898، 0.9899 و 0.9889 **شکل 3** ورودی و خروجیهای شبکه عصبی با ساختار دینامیک در این پژوهش

پایهایترین روش استفاده شده برای آموزش شبکههای عصبی، روشهای مبتنی بر گرادیان میباشند. تکنیک کاربردی گرادیان نزولی جهت تنظیم پارامترهای شبکه های عصبی کاربرد گسترده ای داشته است. هر شبکه عصبی از سه لایه ورودی، میانی یا مخفی و خروجی تشکیل شده است. تعداد نرون در لايه اول يا ورودي، به تعداد عوامل اوليه و تعداد نرون در لايه خروجي 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 نرون های 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 شبکه-های بازگشتی² برای حالت دینامیک و الگوریتمهای لونبرگ -مارکوارت⁸، نرخ یادگیری متغیر پس انتشار⁴، پسانتشار ارتجاعی (انعطافیذیر)⁵ و گرادیان درهم آمیخته مدرج⁶ برای بهنگامسازی وزنهای شبکههای موردنظر، بهکار گرفته شدند. برای بهینهسازی ساختار شبکه از سه تابع فعالسازی تابع سيگموئيد لگاريتمي⁷، تابع خطي⁸ و تانژانت هايپربوليک سيگموئيد⁹ استفاده شد [31,29].

$$\log sig = \frac{1}{1 + exp(-z)}$$
(1)

⁸ purelin ⁹ tansig

DOR: 20.1001.1.10275940.1395.16.12.54.9

Downloaded from mme.modares.ac.ir on 2024-05-25

¹⁰ R2 ¹¹ MSE

¹² epoch

¹ Feed Forward Back Propagation

² Recurrent

³ Levenberg-Marquardt

⁴ traingdx ⁵ trainrp

⁶ trainscg

⁷ logsig





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 5-20-2 میباشد.

این ساختار نشان می دهد که شبکه در لایه میانی به صورت تک لایه و از 20 نرون تشکیل شده است. با افزایش تعداد لایه های میانی میزان خطا در آموزش شبکه تغییر قابل ملاحظه ای نداشت و بسیاری از موارد نیز میزان خطا افزایش یافت. همچنین اثرات به کارگیری توابع فعالیت مختلف نشان داد که تابع فعالیت سیگموئید لگاریتمی با الگوریتم یادگیری لونبرگ-مارکوارت می-تواند دقت بالایی در پیش بینی را داشته باشد. خلاصه استفاده از شبکه های عصبی استاتیک با توابع آستانه و الگوریتم های مختلف در جدول (1) آمده است.

با توجه به جدول ۱ بیشترین مدت زمان لازم برای همگرا شدن الگوریتم های مختلف مربوط به الگوریتم گرادیان درهمآمیخته مدرج و کمترین زمان لازم مربوط به الگوریتم لونبرگ-مارکوارت میباشد. همچنین با توجه به جدول بالا بیشترین و کمترین میزان خطا در هنگام آموزش شبکه نیز به ترتیب مربوط به الگوریتمها لونبرگ-مارکوارت و گرادیان درهم آمیخته مدرج می باشد. بنابراین با توجه به نتایج بدست آمده در جدول ۱ میتوان نتیجه گرفت که بهترین الگوریتم برای این پژوهش در ساختار شبکه عصبی استاتیک، الگوریتم لونبرگ-مارکوارت میباشد.

مختلف	ما و توابع آستانه ،	تفاده از الگوريتمه	استاتیک با اس	آماری شبکه	و شاخصهای	جدول 1 ضرايب
atresault have see		: 41	thread old for	nationa		

Table 1 Coefficients and statistical indicators of static network by using various algorithms and threshold functions										
:مان	43.3	ميانگين	ميانگين	ميانگين	ضريب	ضرب تربین	ضريب	نيمن در لايه	نيم: در لايه	
(ثانيه)	چر - تکرا	مربعات خطا	مربعات خطا	مربعات خطا	تبيين	اءتيا، سن ح	تبيين	-رون -ر - <u>ب</u> م خ ف 2	مخفا	تابع فعاليت
()	عترار	ارزيابى	اعتبار سنجى	آموزش	ارزيابى	العبار سنابي	آموزش	با على <u>م</u>	1 22 2	
الگوريتم لونبرگ- ماركوارت										
3	24	0.4596	0.1395	0.0427	0.9646	0.9653	0.9891	0	5	لگاريتم
2.36	14	0.2701	0.0827	0.0170	0.9689	0.9776	0.9885	0	10	لگاريتم
0.45	10	0.0034	0.0027	0.0011	0.9889	0.9899	0.9898	0	20	لگاريتم
2.75	15	0.2411	0.2371	0.0020	0.9739	0.9693	0.9795	0	30	لگاريتم
2.25	14	0.0020	0.0056	0.0021	0.9795	0.9781	0.9789	10	20	لگاريتم/تانژانت
1.98	12	0.0351	0.0461	0.0019	0.9658	0.9566	0.9693	5	10	لگاريتم/تانژانت
				یر پس انتشار	یادگیری متغ	الگوريتم نرخ				
4.35	93	0.0476	0.0586	0.0545	0.7762	0.8058	0.7762	0	10	لگاريتم
4.01	78	0.0702	0.0168	0.0379	0.7615	0.7794	0.8479	0	20	لگاريتم
3.72	68	0.0338	0.1110	0.0442	0.8782	0.7883	0.8314	0	35	لگاريتم
4.78	84	0.0304	0.0559	0.0606	0.8515	0.8200	0.7652	5	10	لگاريتم/خطي
4.59	75	0.0938	0.0658	0.0355	0.6875	0.7547	0.8017	15	20	لگاريتم/تانژانت
5.12	97	0.0019	0.0041	0.0073	0.9851	0.9683	0.9735	10	15	تانژانت/لگاريتم
				تجاعى	م پسانتشار ار	الگوريتم				
2.85	39	0.0014	0.0040	0.0039	0.9638	0.9618	0.9639	0	10	لگاريتم
2.24	30	0.0049	0.0087	0.0071	0.9417	0.9570	0.9611	0	15	تانژانت
3.08	49	0.2160	0.0113	0.0037	0.8762	0.9230	0.8889	0	50	تانژانت
2.88	40	0.0039	0.0095	0.0042	0.9837	0.7326	0.9698	10	20	لگاريتم اخطى
3.01	43	0.0069	0.0021	0.0021	0.9850	0.9776	0.9868	15	25	لگاريتم/تانژانت
2.87	29	0.0039	0.0004	0.0008	0.9716	0.9594	0.9535	20	35	لگاریتم/لگاریتم
الگوريتم گراديان درهمآميخته مدرج										
2.21	52	0.0121	0.0243	0.0043	0.9323	0.9229	0.9648	0	35	لگاريتم
2.99	64	0.0547	0.0345	0.0021	0.9108	0.9453	0.9701	0	30	تانژانت
1.88	19	0.0240	0.0413	0.0267	0.8946	0.8953	0.8611	0	45	خطى
3.04	38	0.0431	0.0597	0.0155	0.8769	0.8789	0.8845	10	15	لگاريتم/خطي
3.31	33	0.0085	0.0017	0.0024	0.9413	0.9174	0.9789	10	20	لگاريتم/لگاريتم
2.67	20	0.0086	0.0071	0.0088	0.9555	0.9274	0.9473	5	15	لگاريتم/تانژانت



Fig. 5 Correlation between experimental data and forecasting data A) in production of fresh water B) Steam temperatures by using static network (م ميزان توليد آب شكل 5 همبستگى دادههاى تجربى با دادههاى پيش،ينى شده A) در ميزان توليد آب شيرين B) براى درجه حرارت بخار آب براى شبكه استاتيك

"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 می دهد. همانطور که مشاهده میشود با گذشت زمان کاهش یافته تا به کمترین مقدار خود رسیده و شبکه با توپولوژی موردنظر همگرا می گردد.

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 و 0.0004 میباشد. این شبکه در 13 تکرار در مدت 8.11 ثانیه همگرا میشود. تحلیل رگرسیونی نشان داد، ضریب تببین نیز برای الگوهای آموزش، ارزیابی و تست به ترتیب 0.9922، 49804 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 پیش بینی، برتری دارند. نتایج استفاده از شبکه های عصبی دینامیک با توابع آستانه و الگوریتمهای مختلف به ترتیب برای شبکه های عصبی دینامیک با توابع آستانه و الگوریتمهای مختلف 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 آبشاری² میتواند فرآیند تولید و دمای بخار آب را پیش بینی کند. با مقایسه زمان همگرا شدن شبکهها با الگوریتمهای

¹ NEWLRN ² NEWCF

مختلف می توان به این نتیجه دست یافت که شبکهها با الگوریتم یادگیری لونبرگ-مارکوارت با سرعت بالا همگرا شده و در عین حال شبکهها با الگوریتم یادگیری گرادیان درهم آمیخته مدرج نیاز به زمان بالایی برای همگرا شدن دارند. در عین حال دقت و میزان خطای خروجی الگوریتمهای لونبرگ-مارکوارت نسبت با سایر الگوریتمهای به کار گرفته شده در این تحقیق بالاتر می باشد.



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





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

احمد بناکار و همکاران

ول 2 ضرایب و شاخصهای آماری شبکه دینامیک پیشخور آبشاری با استفاده از الگوریت _م ها و توابع آستانه مختلف	جد
Table 2 Coefficients and statistical indicators of dynamic network NEWCF by using various algorithms and threshold functions	

.1.	14.5	ميانگين	ميانگين	ميانگين	ضريب		ضريب				
زمان (هان ر	چرخه	مربعات خطا	مربعات خطا	مربعات خطا	تبيين	صريب تبيين	تبيين	ىرون در لايە · · •	ترون در لایه ۰۰ ۱	تابع فعاليت	
(نانيه)	نكرار	ارزيابى	اعتبار سنجى	آموزش	ارزيابى	اغتبار سنجى	آموزش	محقی ۷	محقی ۱		
۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔۔											
5.4	34	0.1322	0.0242	0.0452	0.9457	0.9724	0.9655	0	5	لگاريتم	
5.91	37	0.0824	0.0991	0.0475	0.9537	0.9821	0.9521	0	10	لگاریتم	
6.27	44	0.0456	0.0728	0.0632	0.9766	0.9729	0.9677	0	20	لگاريتم	
6.87	46	0.0347	0.0124	0.0845	0.9724	0.9811	0.9699	0	30	لگاريتم	
7.55	87	0.1001	0.1998	0.1314	0.9612	0.9469	0.9572	10	20	لگاريتم/تانژانت	
7.01	81	0.0989	0.0941	0.0314	0.9628	0.9702	0.9768	5	10	لگاريتم/تانژانت	
	ریا ہے۔ الگوریتم نرخ یادگیری متغیر پس انتشار										
8.14	89	0.0474	0.0451	0.0183	0.7786	0.9532	0.9139	0	10	لگاريتم	
6.99	69	0.0526	0.0559	0.0455	0.8840	0.8977	0.9200	0	20	لگاریتم	
8.21	99	0.0337	0.0385	0.0270	0.8564	0.9430	0.9001	0	35	لگاريتم	
8.99	89	0.0805	0.0553	0.0306	0.8871	0.9319	0.9328	5	10	لگاريتم/خطي	
8.36	86	0.0421	0.0343	0.0372	0.9022	0.8495	0.8825	15	20	لگاريتم/تانژانت	
7.96	78	0.0484	0.0533	0.0417	0.8050	0.8801	0.8882	10	15	تانژانت/لگاریتم	
				رتجاعى	م پسانتشار ا	الگوريت					
6.55	40	0.0269	0.0150	0.0057	0.9231	0.9475	0.9627	0	10	لگاریتم	
7.64	124	0.0278	0.0104	0.0049	0.9147	0.9114	0.9700	0	15	تانژانت	
5.01	24	0.0457	0.0337	0.0294	0.9015	0.9058	0.9196	0	50	تانژانت	
5.71	36	0.0222	0.0240	0.0085	0.8643	0.8624	0.9537	10	20	لگاریتم/خطی	
5.54	39	0.0185	0.0181	0.0201	0.8931	0.8846	0.9278	15	25	لگاريتم/تانژانت	
6.27	35	0.0428	0.0183	0.0058	0.9434	0.9364	0.9665	20	35	لگاريتم/لگاريتم	
الگوريتم گراديان درهمآميخته مدرج											
5.21	36	0.0113	0.0087	0.0051	0.8497	0.9501	0.9193	0	35	لگاريتم	
6.64	74	0.0084	0.0022	0.0043	0.8770	0.9218	0.9633	0	30	تانژانت	
4.77	21	0.0178	0.0087	0.0198	0.90.08	0.9109	0.8934	0	45	خطى	
5.71	58	0.0082	0.0091	0.0247	0.8741	0.8647	0.8365	10	15	لگاریتم/خطی	
5.09	46	0.0077	0.0098	0.0058	0.9455	0.9232	0.9621	10	20	لگاريتم/لگاريتم	
4.38	37	0.0011	0.0099	0.0128	0.8978	0.9134	0.8844	5	15	لگاريتم/تانژانت	

"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 می-باشد.

"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 می شود 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 می گردد.

3-3- مقایسه شبکههای استاتیک و دینامیک

نتایج حاصل از کاربرد شبکههای عصبی نشان داد که استفاده از شبکه های عصبی دینامیک می تواند 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

های استاتیک دارای توانایی بالاتر در پیشبینی میزان تولید آب شیرین و دمای بخار آب در آب شیرین کن های 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 می توان با توجه به ماهیت شبکههای دینامیک و نتایج بدست آمده بیان کرد که این شبکه ها توانایی بالایی را در شبیهسازی فرآیندهای غیر خطی و پیچیده مانند عملیات انتقال جرم و حرارت در فرآیند تولید آب شیرین در آب شیرین کنها را دارا می باشند. در واقع مى توان با توجه به نتايج به دست 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 آبشیرین کن تاثیرگذار هستند، شبکههای عصبی ابزار قدرتمندی هستند که با دقت بالا، هزینه و زمان کم میتوانند این فرآیندها را مدلسازی کنند. نتایج بهدست آمده در این پژوهش با نتایج پژوهشهای نازقلیچی و همکاران [29]، بنى حبيب و همكاران [28]، همدان و همكاران [27] مطابقت دارد.



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 پیشربینی 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

4- نتیجه گیری

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

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

2- مقایسه الگوریتم های 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 لونبرگ-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 مدلسازی را طولانی تر 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 بهدست آمده در این پژوهش به نظر میرسد که شبکههای عصبی ابزار قدرتمندی در مدلسازی این پارامترها

مىباشند.

5- تقدير و تشكر

6- مراجع

- 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. Nedunchezhian, 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 seawaterdesalination 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. Valipoor, 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 نفارسی).
- [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. Cojocaru, 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 multistage 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-Karaghouli, 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-Karaghouli, W. Alnaser, Performances of single and double basin solar-stills, *Applied Energy*, Vol. 78, No. 3, pp. 347-354, 2004b.
- [14] A. El-Sebaii, 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, Thermaleconomic 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. Gabsi, 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.