



## مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در کوچک مقیاس سازی دما

مجید شیداایان<sup>۱\*</sup>، میر خالق ضیاتبار احمدی<sup>۲</sup> و رامین فضل اولی<sup>۳</sup>

<sup>۱\*</sup> - نویسنده مسئول، دانشجوی دکتری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان majid\_sheidaeyan@yahoo.com

<sup>۲</sup> - استاد دانشگاه علوم کشاورزی و منابع طبیعی ساری.

<sup>۳</sup> - دانشیار دانشگاه علوم کشاورزی و منابع طبیعی ساری.

تاریخ پذیرش: ۹۴/۹/۲۲

تاریخ دریافت: ۹۳/۹/۱۸

### چکیده

در این پژوهش کوچک مقیاس سازی دما در دشت تاجن واقع در استان مازندران انجام گرفت. نتایج مدل‌های گردش عمومی جو با مدل اقلیمی HadCM3 تحت سناریوی A2 به دست آمد. از آنجایی که خروجی مدل‌های گردش عمومی جو دارای وضوح مکانی پایینی است می‌بایست در سطح منطقه یا حوزه کوچک مقیاس شوند که این کار به روش آماری انجام شد. روش‌های آماری مورد استفاده شامل مدل کوچک مقیاس سازی SDSM5.5.1 و مدل شبکه عصبی مصنوعی است. در این پژوهش، با استفاده از اطلاعات میانگین دمای روزانه ایستگاه کردخیل در طول دوره آماری ۳۰ ساله (۱۹۷۱-۲۰۰۱) و متغیرهای بزرگ مقیاس NCEP، به عنوان ورودی‌های شبکه عصبی و مدل SDSM، شبیه سازی و کوچک مقیاس سازی دمای بیشینه و کمینه در دوره گذشته به منظور تعیین خطای مدل‌ها صورت گرفت. بدین منظور از امکانات و توابع موجود در محیط برنامه‌نویسی متلب، بهره گرفته شد. سپس برای ارزیابی عملکرد مدل‌ها، از معیارهای آماری از جمله ضریب همبستگی، ضریب تبیین و جذر میانگین مربعات خطا بین مقادیر مشاهداتی و پیش‌بینی شده‌ی دما استفاده شد. نتایج به دست آمده نشان دهنده کارایی مناسب مدل SDSM برای کوچک مقیاس سازی دما نسبت به مدل شبکه عصبی مصنوعی است. به طوری که درصد خطای مدل SDSM کمتر از شبکه عصبی و ضریب همبستگی آن بیشتر است. همچنین بهترین ساختار شبکه عصبی برای شبیه سازی دمای بیشینه مدل پرسپترون چهار لایه پنهان با معماری ۶-۵-۵-۵ و برای متغیر دمای کمینه مدل پرسپترون سه لایه پنهان با معماری ۱-۳-۵ می‌باشد.

کلید واژه‌ها: استان مازندران، مدل HadCM3، محیط متلب، مدل گردش عمومی جو.

## Comparison of Artificial Neural Network (ANN) and SDSM Model to Downscaling of Temperature

M. Sheidaaian<sup>1\*</sup>, M. Kh. Ziatabar Ahmadi<sup>2</sup> and R. Fazloul<sup>3</sup>

<sup>1\*</sup> - Corresponding Author, Ph.D. Student, Gorgan University of Agricultural Sciences and Natural Resources.

<sup>3</sup> - Professor, Agricultural Sciences and Natural Resources Sari University.

<sup>2</sup> - Associate Professor, Agricultural Sciences and Natural Resources Sari University.

Received: 9 December 2014

Accepted: 13 December 2015

### Abstract

In this study downscaling of temperature was down in Tajan Plain located in the province of Mazandaran. The result of atmospheric general circulation models was obtained with HadCM3 climate model under scenario A2. Since the output of atmospheric general circulation models has a low locative resolution, should be downscaled in the area or Basin level that it was conducted with statistical method. The statistical methods used included of downscaling SDSM5.5. And

artificial neural network model. In this study, by using the average daily temperature data of Kordkheil Station during the 30-year statistic Period (1971-2001) and the large-scale variables NCEP, as inputs to the neural network and SDSM model, simulation and downscaling was done respectively of the maximum and minimum temperature in the last period to determine models error. To this end were used of the features and functions available in the programming software MATLAB. Then To evaluate the performance of the models, were used the statistical criteria including of correlation coefficient, coefficient of declaration and root mean square error between observed and predicted values of temperature. The obtained results show the appropriate performance of SDSM model for downscaling temperature Than the ANN model. So that the error percentage of SDSM model is lower and the correlation coefficient is more than the ANN model. The best Structure of neural network to simulate of maximum temperature is perceptron model with four hidden layer with the 5-5-6-6 architecture and for the minimum temperature Variable is perceptron model with three hidden layer with 5.3.1 architecture.

**Keywords:** Province of Mazandaran, Hadcm3 model, MATLAB, Atmospheric General Circulation Model.

و شناسایی روابط بین سیستم‌ها از روی داده‌های مشاهداتی توسعه داده شده‌اند. در حقیقت این مدل‌ها روابطی را بین پیش‌بینی کننده‌ها<sup>۲</sup> که همان متغیرهای جوی بزرگ مقیاس هستند و پیش‌بینی‌شونده‌ها<sup>۳</sup> که همان متغیرهای سطحی محلی می‌باشند، گسترش می‌دهند و سپس متغیرهای اقلیمی محلی را برای آینده پیش‌بینی می‌کنند (کریستیانسن، ۲۰۰۴). کوچک مقیاس سازی آماری شامل بسط روابط کمی بین متغیرهای اتمسفری بزرگ مقیاس GCM<sup>۴</sup> و متغیرهای محلی RCM<sup>۵</sup> می‌باشد. بیشتر مطالعات کوچک مقیاس کردن آماری در مقیاس نقطه‌ای (ایستگاهی) انجام شده و از متغیرهای اقلیمی چون بارش و درجه حرارت استفاده می‌شود. با برقراری ارتباط آماری مناسب بین متغیرهای پیش‌بینی کننده و متغیرهای پیش‌بینی شونده می‌توان به روابط مناسب جهت پیش‌بینی متغیرهای اقلیمی در آینده تحت تأثیر پدیده تغییر اقلیم دست یافت (صمدی و همکاران، ۱۳۸۶). مدل‌های نگاشتی به صورت خطی و یا غیرخطی، ارتباطات بین پیش‌بینی شونده‌ها و پیش‌بینی کننده‌ها را نشان می‌دهند. این روش شامل مدل‌های نگاشت خطی، تحلیل همبستگی (کانونیکال)، شبکه عصبی مصنوعی که یک نگاشت غیر خطی می‌باشد و روش کریجینگ است. این مدل‌ها اکثراً با ایجاد روابط نگاشتی بین متغیرهای بزرگ مقیاس و کوچک مقیاس تعریف می‌شوند. عمده‌ترین مزیت این روش‌ها، کاربرد آسان و کم هزینه بودن آنها می‌باشد (سلیمانی نادگانی، ۱۳۸۹). تحقیقات متعددی در این زمینه انجام گرفته که از جمله: اسفندیاری و همکاران (۱۳۸۹)، پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج را با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)<sup>۷</sup> انجام دادند. آنها از

## مقدمه

طی سال‌های اخیر، دانشمندان به منظور تجزیه و تحلیل الگوهای اقلیمی توجه ویژه‌ای به سری‌های دمایی معطوف می‌دارند. دما در کنار بارش از مهم‌ترین عناصر اقلیمی محسوب می‌گردد که در تعیین نقش و پراکندگی دیگر عناصر اقلیمی نیز موثر است، همچنین دما از عوامل اصلی و اساسی در پهنه‌بندی و طبقه‌بندی اقلیمی محسوب می‌گردد و بر این اساس نوسانات و تغییرپذیری دما دارای اهمیت زیادی است که عوامل اقلیمی و جغرافیایی زیادی از قبیل رطوبت، ابرناکی، سرعت باد، ارتفاع، دوری و نزدیکی به دریا و غیره در تغییرات آن نقش دارند. تغییرات معنی دار دمای کره‌ی زمین یا گرمایش جهانی به عنوان مهم‌ترین نمودهای تغییر اقلیم در قرن حاضر مورد توجه قرار گرفته است (خورشید دوست و همکاران، ۱۳۸۵)، لذا پیش‌بینی عناصر اقلیمی، قطعاً فرصت بیشتری را برای برنامه‌ریزی و ارائه تمهیدات لازم در اختیار برنامه‌ریزان قرار می‌دهد. مدل‌های قدیمی در زمینه شبیه‌سازی و پیش‌بینی مدل‌های نگاشتی هستند. امروزه با پیشرفت علوم و ابداع روش‌های هوشمند در علوم مختلف، ضرورت جانشینی آن مطرح می‌شود. مدل‌های گردش عمومی هیچ‌گاه نمی‌توانند مستقیماً برای پیش‌بینی‌های منطقه‌ای یا نقطه‌ای استفاده شوند، آنها نیازمند ریزمقیاس نمایی هستند تا با اعمال رفتارهای محلی در آنها پیش‌بینی‌هایشان در مقیاس‌های محلی بهبود یابند. ریزمقیاس نمایی به دو صورت دینامیکی و آماری انجام می‌شود. در روش آماری یک ارتباط آماری با استفاده از نگاشت ساده، چند متغیره، شبکه عصبی و... بین رفتار واقعی ایستگاه و برونداد مدل گردش عمومی ایجاد می‌شود. بعد از صحت سنجی، این معادله‌ها می‌توانند در ریزمقیاس نمایی پیش‌بینی‌های آینده با استفاده از سناریوهای انتشار مورد استفاده قرار گیرند (زو<sup>۱</sup>، ۱۹۹۹). روش‌های آماری با هدف توسعه روابط بین متغیرهای اقلیمی بزرگ مقیاس و متغیرهای اقلیمی منطقه‌ای

- 2-Predictors
- 3- Predictants
- 4- General Circulation Models
- 5-Regional Circulation Model
- 6-Canonical Correlation Analysis
- 7- Multi Layer Perceptron

شبکه عصبی به خوبی رابطه غیر خطی بین مقادیر ماهانه بارش را با توجه به آموزش شبکه پیش‌بینی می‌کند. در عین حال، نتایج حاصل از تصادفی کردن داده‌ها تفاوت چندانی با مرتب بودن داده‌ها برای آموزش شبکه ندارد (حلبیان و دارند، ۱۳۹۱). آپهیشک و همکاران<sup>۴</sup> (۲۰۱۲)، با استفاده از مدل شبکه عصبی مصنوعی با الگوریتم پس انتشار خطا<sup>۵</sup> با وزن‌های متفاوت پارامتر بارش در حوزه Udupi از Karnataka را به وسیله آموزش و آزمون داده‌ها و لایه‌های پنهان و تعداد نورون‌های متفاوت در لایه‌ها شبیه سازی کردند. نتایج نشان داد که بهترین ساختار شبکه با الگوریتم مذکور سه لایه پنهان با نورون‌های متفاوت می‌باشد (آپهیشک و همکاران، ۲۰۱۲). فیسه‌ها و همکاران<sup>۶</sup> (۲۰۱۲)، دو مدل SDSM و LARS-WG را برای کوچک مقیاس سازی و شبیه سازی داده‌های بارندگی با داده‌های بزرگ مقیاس HadCM3<sup>۷</sup> GCM از سناریوهای A2 و B2 برای حوزه رودخانه Tiber Upper ایتالیای مرکزی مقایسه کردند. برای این کار چهار دوره زمانی پایه (۱۹۹۰-۱۹۶۱)، دوره ۲۰۲۰، ۲۰۵۰ و ۲۰۸۰ در نظر گرفته شد. مدل SDSM افزایش روند را در دمای مینیمم و ماکزیمم به خوبی بارندگی در منطقه مطالعاتی برای دوره ۲۰۸۰ نشان داد. مدل LARS-WG هم یک همانندی با مدل SDSM برای کوچک مقیاس سازی دما و بارندگی نشان داد. که نشان دهنده کاهش روند مشخص در فصل تابستان که از ۶۰ درصد داده‌ها در دوره ۲۰۸۰ به عنوان مقایسه با اقلیم کنونی (۱۹۹۰-۱۹۶۱) استفاده شد. اگرچه دو روش کوچک مقیاس سازی همان نتایج عددی یکسان را نشان ندادند ولی هر دو مدل تأثیر تغییر اقلیم در حوزه مطالعاتی در تمام سری‌های زمانی از بارندگی و دما را یکسان نشان دادند (فیسه‌ها و همکاران، ۲۰۱۲). در این پژوهش جهت شبیه سازی دمای بیشینه و کمینه روزانه ایستگاه کردخیل دشت تجن واقع در استان مازندران از سال ۱۹۷۱ تا سال ۲۰۰۱ میلادی، دو مدل کوچک مقیاس SDSM و ANN به کار رفته است. سپس با استفاده از معیارهای ارزیابی عملکرد دو مدل مورد مقایسه قرار گرفت.

این پژوهش برای اولین بار در دشت تجن واقع در استان مازندران به منظور مقایسه دو مدل شبکه عصبی مصنوعی و SDSM در کوچک مقیاس سازی دمای بیشینه و کمینه و به منظور مقایسه با مدل اقلیمی کانادایی HadCM3 انجام گرفت که نتایج متفاوتی با دیگر پژوهش‌ها در زمینه انتخاب حوضه مطالعاتی و رودخانه مورد نظر و مدل شبیه ساز و مدل اقلیمی منتخب داشت که در ادامه به طور مفصل به بیان آن پرداخته می‌شود.

میانگین دمای ماهانه ۳۸ سال آماری (۲۰۰۱-۱۹۶۴) به عنوان ورودی‌های شبکه پرسپترون چند لایه، میانگین دمای ماهانه در طی سال‌های (۲۰۰۵-۲۰۰۲) به منظور تعیین میزان خطای مدل، پیش بینی شد. بدین منظور از امکانات و توابع موجود در محیط برنامه نویسی متلب بهره گرفته شد. نتایج به دست آمده نشان دهنده کارایی مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی در پیش‌بینی دما می‌باشد. به طوری که ضریب همبستگی برابر با ۰/۹۹ و میانگین درصد خطای مدل برابر با ۱/۹۷ درصد است (اسفندیاری و همکاران، ۱۳۸۹). خان و همکاران<sup>۱</sup> (۲۰۰۶) از طریق بررسی عدم قطعیت‌های مشاهده شده در نتایج کوچک مقیاس شده بارش روزانه و دمای حداقل و حداکثر روزانه حاصل سه روش کوچک مقیاس کردن را مورد ارزیابی قرار دادند. مدل SDSM، مدل LARS-WG و شبکه عصبی مصنوعی. آنها برای ارزیابی عدم قطعیت، برای مطالعه موردی منطقه‌ای در کانادا، میانگین و واریانس مقادیر کوچک مقیاس شده با داده‌های مشاهداتی را مقایسه نمودند. نتایج حاصل از ارزیابی عدم قطعیت نشان دهنده آن است که مدل SDSM توانسته است خصوصیات مختلف آماری داده‌های مشاهداتی را بهتر از سایر مدل‌ها در مقادیر ریز مقیاس شده حفظ نماید، مدل شبکه عصبی مصنوعی به عنوان مدل دارای ضعیف‌ترین عملکرد طبقه بندی شد و مدل LARS-WG در مرتبه دوم قرار گرفت (خان و همکاران، ۲۰۰۶). کارآموز و همکاران<sup>۲</sup> (۲۰۰۹)، داده‌های مدل GCM را با استفاده از مدل SDSM و شبکه عصبی مصنوعی را برای شبیه سازی بارندگی استفاده کردند. این مدل‌ها برای شبیه سازی بارندگی برای پنج ماه (از دسامبر تا آوریل) در منطقه مطالعاتی در جنوب شرق ایران استفاده شدند. نتایج نشان داد که مدل SDSM سناریوهای تغییر اقلیم را با استفاده از پارامترهای اقلیمی انتخاب شده برای شبیه سازی بارندگی اجرا می‌کند ولی مدل ANN بوسیله داده‌های مشاهداتی شبیه سازی می‌کند و روابط فیزیکی بین متغیرها را در نظر نمی‌گیرد. نتایج نشان داد که مدل SDSM کارایی بهتری نسبت به مدل ANN در شبیه سازی داده‌های بارندگی در منطقه‌ای مطالعاتی دارد (کارآموز و همکاران، ۲۰۰۹). حلبیان و همکاران (۲۰۱۳)، برای پیش‌بینی بارش اصفهان در بازه (۲۰۰۹-۱۹۵۱) به مدت ۵۹ سال از شبکه‌های عصبی مصنوعی بهره گرفتند. نتایج حاصل نشان داد که استفاده از شبکه‌های عصبی مصنوعی با یک پرسپترون با دو لایه پنهان و ضریب یادگیری ۰/۴ نسبت به سایر حالت‌ها و معماری شبکه، مدل نسبتاً بهتری را ارائه می‌کند. آموزش مجدد شبکه و آزمون شبکه با لایه‌های پنهان و ضرایب مختلف یادگیری در ترکیب با الگوریتم ژنتیک باعث کاهش خطا و افزایش سرعت محاسبات شده و نتایج بهتری را ارائه می‌کند. به طور کلی می‌توان گفت که

4- Abhishek et al.

5-Back-Propagation

6- Fiseha

7-Hadley Coupled Atmosphere-Ocean General Circulation Model


1- Khan et al.

2- Statistical Downscaling Model

3- Karamouz et al.

### جدول ۱- مشخصات جغرافیایی ایستگاه مورد مطالعه

نام و مشخصات ایستگاه	مختصات جغرافیایی	ارتفاع از سطح دریا (متر)
	طول شرقی	عرض شمالی
کردخیل (هیدرومتری- بارانسنجی)	۵۳° ۱۷' - ۶' - ۱۷/۱"	۳۶° ۳۶' - ۳۵/۹" - ۵



شکل ۱- ساختار مدل چند لایه

خصوصیات سناریوهای اقلیمی مدل کوچک مقیاس شده تاثیرگذار است. در چنین مرحله‌ای یکی از فاکتورهای لازم برای انتخاب صحیح متغیرهای پیش‌بینی کننده، تجربه کاربر می‌باشد. کاربر باید با تکیه بر تجربه خود و مقایسه‌های ارائه شده توسط مدل، متغیرهای پیش‌بینی کننده را برای مدل انتخاب کند. در مرحله بعد مدل با توجه به متغیرهای انتخاب شده توسط کاربر واسنجی می‌شود و پس از آن صحت سنجی مدل واسنجی شده با تولید داده‌های تاریخی و مقایسه آنها با داده‌های مشاهداتی انجام و در صورت صحت واسنجی‌ها مدل برای آینده داده‌های اقلیمی را تولید می‌کند (ویلسی و داوسون، ۲۰۰۷). در این پژوهش برای روش کوچک مقیاس سازی آماری از نرم افزار SDSM5.1.1 برای بررسی تغییرات دما در منطقه مورد مطالعه استفاده شد.

#### تئوری ریاضی شبکه‌های عصبی مصنوعی

ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی یا پنهان و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه است و لایه پنهان محل پردازش داده‌هاست. شمار لایه‌ها و شمار نرون‌ها در هر لایه پنهان، به طور معمول به وسیله روش آزمون و خطا مشخص می‌شود (اصغری مقدم و همکاران، ۱۳۸۷).

#### معماری شبکه‌های پرسپترون چند لایه (MLP)

شبکه‌های پرسپترون چند لایه از نوع شبکه‌های عصبی پیشخور<sup>۳</sup> هستند که یکی از پرکاربردترین مدل‌های شبکه‌های

#### مواد و روش‌ها

##### منطقه مطالعاتی

حوضه آبریز تچن با مساحت تقریبی ۴۰۰۵/۲۲ کیلومتر مربع بوده که ۳۹۸۰/۷۵ کیلومتر مربع آن در داخل استان مازندران و حدود ۲۵ کیلومتر مربع آن در خارج از استان قرار دارد و با مختصات ۵۳ درجه و ۷ دقیقه تا ۵۳ درجه و ۴۲ دقیقه طول شرقی و بین ۳۵ درجه و ۵۶ دقیقه تا ۳۶ درجه و ۱۷ دقیقه عرض شمالی در استان مازندران جنوب شرق شهرستان ساری واقع شده است، که حداکثر ارتفاع آن ۳۷۸۲ متر از سطح دریا و حداقل آن ۲۶- متر است. این حوزه از شمال به دریای خزر، از جنوب به حوزه کسپیلیان، از شرق به کیاسر و از غرب به حوزه لولاک کسپیلیان محدود می‌گردد. منطقه مورد مطالعه در این تحقیق ایستگاه هیدرومتری- بارانسنجی کردخیل می‌باشد. متوسط بارندگی سالیانه اندازه‌گیری شده در ایستگاه کردخیل ۶۰۹/۳ میلی متر و میانگین دمای سالیانه منطقه ۱۵/۹ درجه سانتی گراد است.

#### ساختار مدل کوچک مقیاس سازی SDSM

مدل SDSM از روش‌های آماری نگاشتی به منظور عملیات کوچک مقیاس کردن استفاده می‌کند. در این مدل ابتدا روابط بین پیش‌بینی کننده‌ها (خروجی‌های مدل‌های گردش عمومی و داده‌های بزرگ مقیاس ناحیه‌ای NCEP<sup>۱</sup>) و پیش‌بینی شونده‌ها مورد بررسی و تحلیل قرار می‌گیرد و روابط تجربی بین آنها تعیین می‌شود و به کاربر اعلام می‌گردد. هدف اصلی این بخش کمک به کاربر در انتخاب متغیرهای پیش‌بینی کننده موثر در کوچک مقیاس کردن خروجی‌های مدل گردش عمومی می‌باشد. این مرحله پرچالش‌ترین گام در توسعه هر مدل کوچک مقیاس کننده آماری است، زیرا انتخاب متغیر پیش‌بینی کننده کاملاً بر

2-Multi Layer Percpetron  
3-Feed Forward

1- National Center on Environmental Prediction

سناریوهای انتشار (A<sub>2</sub>) برای دوره زمانی ۱۹۷۱ تا ۲۱۰۰ به مختصات ایستگاه کردخیل از سایت شبکه بندی تغییر اقلیم کانادایی به دست آمد (سایت اقلیم کانادایی، منبع ۱۴). علت انتخاب مدل فوق کاربرد وسیع آن در مطالعات تغییر اقلیم و سهولت دسترسی به اطلاعات آن می باشد. مدل HadCM3 در مرکز پژوهش و پیش بینی اقلیمی هادلی<sup>۲</sup> انگلستان توسعه یافته و دارای شبکه بندی با ابعاد ۲/۵×۳/۷۵ (طول در عرض جغرافیایی) درجه می باشد. از آنجایی که ویژگی های سناریوی انتشار A2 بر صنعتی شدن و رشد سریع کشورها بدون توجه به محیط زیست و انتشار گازهای گلخانه ای بیشتر تأکید می کند و از طرفی در سطح دنیا برای بررسی تأثیرات تغییر اقلیم بر کشاورزی، منابع آب، هیدرولوژی و محیط زیست از این سناریو استفاده می کنند، این سناریو از میان سناریوهای موجود انتخاب شد. از آنجایی که ۲۵ متغیر پیش بینی کننده می تواند روابط مختلفی با داده های پیش بینی شونده داشته باشد لذا متغیری برای انجام مطالعات حائز اهمیت است که ضمن معرفی به دو مدل دارای بالاترین ضریب همبستگی و پائین ترین واریانس خطا باشد. در اکثر مطالعات انجام گرفته متغیرهای geopotential height 850 hpa (ارتفاع ژوپتانسیل در تراز ۸۵۰ هکتوپاسکال)، Near surface specific humidity (رطوبت ویژه در سطح زمین)، 500hpa geopotential height (ارتفاع ژوپتانسیل در تراز ۵۰۰ هکتوپاسکال) و at500 hpa Specific humidity (رطوبت ویژه در تراز ۵۰۰ هکتوپاسکال) مهم ترین پیش بینی کننده ها شناخته شده اند. با برقراری روابط نگاشتی مناسب بین مدل GCM منتخب و ۲۵ متغیر پیش بینی کننده بهترین پیش بینی کننده انتخاب و برای کوچک مقیاس کردن داده های دمای کمینه و بیشینه در دوره پایه ایستگاه مورد نظر حوزه به دو مدل ANN<sup>۳</sup> و SDSM معرفی می شود.

#### داده های ورودی و خروجی شبکه عصبی مصنوعی

در مرحله اول داده های مربوط به دمای بیشینه و کمینه از ایستگاه بارانسنجی کردخیل تهیه و همچنین داده های بزرگ مقیاس NCEP از سایت شبکه اقلیمی کانادایی دریافت شد. لایه ورودی شبکه را شش نرون شامل دمای بیشینه و کمینه و پنج متغیر بزرگ مقیاس بهینه که از مدل SDSM بهترین ضریب همبستگی را با متغیر روزانه دما داشتند انتخاب شدند. از ۱۱۳۱۶ داده دمای موجود (۲۰۰۱-۱۹۷۱)، ۷۹۲۱ داده برای آموزش شبکه و مابقی در مرحله آزمون شبکه به کار رفتند. در واقع ۳۰ درصد داده ها برای آزمون و ۷۰ درصد برای آموزش استفاده شده است.

#### نرمال نمودن داده ها

عصبی مصنوعی در مدل سازی و پیش بینی عناصر اقلیمی است (حسینی، ۱۳۸۸). در شبکه های پرسپترون چند لایه هر نرون در هر لایه به تمام نرون های لایه قبل متصل می باشد. به چنین شبکه هایی، شبکه های کاملاً مرتبط گویند (منهاج، ۱۳۸۴). در مورد مسئله برآورد عناصر جوی، شبکه عصبی باید قادر به نگهداری اطلاعات و دیده بانی های گذشته باشد به همین دلیل و با توجه به توانایی های شبکه پرسپترون و قابلیت آموزش و یادگیری زیاد این نوع شبکه عصبی، استفاده از آن به منظور برآورد عناصر جوی در تحقیقات گذشته توصیه شده است (حسینی، ۱۳۸۸). در سال های اخیر چندین تقریب گر عمومی تابع پیشنهاد شده است که از آن جمله می توان پرسپترون چند لایه را نام برد. یک نقطه قدرت عملی این سیستم ها، این است که می توانند توابع غیر خطی را با تعداد زیادی متغیر، تقریب بزنند و از اطلاعات موجود در مجموعه های بسیار بزرگ عددی استفاده کنند (تشنه لب و منشی، ۱۳۸۹). به دلیل آنکه الگوریتم آموزش در شبکه های چند لایه معمولاً پس انتشار است (BP<sup>۱</sup>) و نیز در این پژوهش از آن استفاده شده، ذیلاً به محاسبات شبکه های عصبی در حالت پیشرو پرداخته می شود:

#### داده ها و اطلاعات منطقه

برای بررسی و ارزیابی تأثیرات تغییرات اقلیم در آینده نیازمند یک دوره مرجع به عنوان دوره پایه می باشیم. لذا سازمان جهانی هواشناسی پیشنهاد کرده است که به منظور هماهنگی در انتخاب دوره پایه در مطالعات مختلف تغییر اقلیم و امکان مقایسه آنها، دوره پایه دوره ۱۹۶۰-۱۹۶۱ در نظر گرفته شود. از طرف دیگر به سفارش همین سازمان، در مواردی که داده های ثبت شده در ایستگاه های منطقه مورد مطالعه برای این دوره موجود نباشد، می بایست دوره ۲۰۰۰-۱۹۷۱ جایگزین شود (هالوم و همکاران، ۱۹۹۹). با توجه به اینکه آمار متغیرهای اقلیمی ایستگاه هیدرومتری - بارانسنجی کردخیل در دوره ۱۹۶۰-۱۹۶۱ کامل نمی باشد، دوره ۲۰۰۱-۱۹۷۱ بعنوان دوره پایه در نظر گرفته شد. داده های مورد نیاز در این روش پژوهش به چند دسته تقسیم می شوند:

۱- داده های حداکثر و حداقل درجه حرارت روزانه ثبت شده در ایستگاه کردخیل که از طریق سازمان آب منطقه ای استان مازندران واقع در شهرستان ساری برای دوره پایه ۲۰۰۱-۱۹۷۱ تهیه شد.

۲- داده های شبیه سازی شده، که خروجی مدل های جهانی اقلیم هستند. با توجه به اینکه مدل های جهانی اقلیم، گران قیمت و بسیار پیچیده اند و در اختیار تعداد اندکی از کشورهای پیشرفته قرار دارند اما خروجی بعضی از این مدل ها در اختیار محققان سراسر دنیا قرار می گیرد. لذا داده های مورد نیاز که شامل ۲۵ متغیر بزرگ مقیاس NCEP و مدل اقلیمی HadCM3 با توجه به

2-Hadley

3-Artificial Neural Network

1- Back Propagation

شیدائیان و همکاران: مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در ...

$$RMSE = \sqrt{\sum_{i=1}^n \left( \frac{obs-pre}{n} \right)^2} \quad (3)$$

که در رابطه فوق  $obs$  مقادیر مشاهده‌ای و  $pre$  مقادیر شبیه سازی شده توسط مدل و  $n$  تعداد کل داده‌ها می‌باشد

### ۳- ضریب همبستگی: R

بیان کننده میزان همبستگی بین نتایج پیش بینی شده مدل و داده‌های واقعی می‌باشد که بر اساس رابطه زیر محاسبه می‌شود:

$$R = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}} \quad (4)$$

که در آن،  $y_{act}$ : مقادیر واقعی،  $\bar{y}_{act}$ : میانگین مقادیر واقعی،  $y_{est}$ : مقادیر برآورد شده،  $\bar{y}_{est}$ : میانگین مقادیر برآورد شده می‌باشد. هر چه مقدار RMSE به صفر و مقدار  $R^2$  به یک نزدیک تر باشد نشان دهنده نزدیک تر بودن مقادیر مشاهده شده و پیش بینی شده به یکدیگر و دقیق تر بودن جواب‌ها در هر مرحله است.

## نتایج و بحث

### نتایج کوچک مقیاس سازی دما با مدل SDSM در دوره پایه (۲۰۰۱-۱۹۷۱)

درجه حرارت شبیه سازی شده در دوره پایه ۲۰۰۰-۱۹۷۱، با استفاده از کوچک مقیاس سازی خروجی مدل HadCM3، و مقایسه آن با مقادیر مشاهداتی، در شکل (۲) نمایش داده شده است. همچنین در جدول (۲) عملکرد مدل در پیش بینی درجه حرارت بر اساس شاخص‌های ضریب تبیین  $R^2$  و جذر میانگین مربعات خطا RMSE، به صورت خلاصه آورده شده است. مقادیر شاخص‌های ارزیابی عملکرد مدل در دوره پایه ۲۰۰۱-۱۹۷۱ نشان می‌دهد که مدل در شبیه سازی درجه حرارت از قابلیت نسبتاً خوبی برخوردار است. همچنین مدل در شبیه سازی درجه حرارت حداقل به دلیل خطای کمتر، نسبت به دمای حداکثر عملکرد بهتری دارد.

یکی از مهم‌ترین گام‌ها در پیشبرد رضایت بخش مدل پیش بینی ANN انتخاب متغیرهای ورودی مناسب می‌باشد. سعی بر این است که شبکه‌ای با کمترین خطا و بالاترین همبستگی معرفی شود. در این پژوهش برای شبیه سازی دمای بیشینه و کمینه با شش متغیر ورودی شامل یک متغیر دمای روزانه کمینه یا بیشینه، و پنج متغیر بزرگ مقیاس بهینه NCEP نرمال شده با برنامه نویسی در محیط متلب مقادیر ضریب تبیین، ضریب همبستگی و جذر میانگین مربعات خطا را با جایگزین کردن مقادیر متفاوت لایه‌های پنهان و نرون‌ها و انتخاب بهترین ساختار شبکه و بهینه ترین تعداد لایه و نرون به کار رفته در یادگیری، بدست آمد. متغیرهای NCEP به کار رفته برای شبیه سازی شامل موارد نام برده در جدول (۳) و (۴) می‌باشند.

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود از این رو داده‌های ورودی به شبکه بایستی استاندارد شوند. در این بررسی برای استاندارد کردن داده‌ها از رابطه زیر استفاده شده و این رابطه در محیط متلب ۲۰۱۰ کدنویسی شد، و ورودی‌ها را بین ۰/۱ تا ۰/۹ استاندارد می‌نماید (ساجیکومار، ۱۹۹۹). در نهایت می‌توان خروجی‌های شبکه را با معکوس نمودن الگوریتم استاندارد سازی، به حالت اولیه برگرداند.

$$T_i = 2 \times \left[ \frac{x_i - x_{max}}{x_{min} - x_{max}} \right] - 1 \quad (1)$$

در معادله فوق  $T_i$  مقدار استاندارد شده،  $x_i$  مقادیر واقعی و  $x_{min}$  و  $x_{max}$  مقادیر حداقل و حداکثر واقعی هستند.

تعداد لایه‌های پنهان تا حد امکان باید کم باشد. ابتدا شبکه با یک لایه پنهان آموزش داده می‌شود که در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش خواهد یافت. در این پژوهش از یک لایه پنهان تا حداکثر ۵ لایه پنهان برای آزمون و خطا استفاده شده است. در این پژوهش در لایه‌های پنهان از یک نرون تا ۱۲ نرون برای سعی و خطای مدل استفاده شده است. همچنین از تابع محرک ورودی Tansig یا تانژانت سیگموئیدی و تابع محرک خروجی purelin یا خطی استفاده شد. الگوریتم مارکوارت- لونیبرگ از سال ۱۹۹۳ تا به امروز به عنوان سریع ترین روش آموزش شبکه‌های عصبی شناخته شده است (۳). در این پژوهش نیز از این الگوریتم استفاده شد. همچنین از آموزش الگو به الگو (پاک) استفاده شد و برای هر شبکه ۳۰۰ دور یا سیکل در نظر گرفته شد.

### ارزیابی عملکرد مدل‌های کوچک مقیاس سازی


در پایان برای بررسی و آزمون اعتبار مدل‌ها، به ارزیابی عملکرد آنها پرداخته شد. برای ارزیابی عملکرد، از سه روش زیر استفاده گردید:

۱- ضریب تبیین ( $R^2$ ) معیاری بدون بعد و بهترین مقدار آن برابر یک می‌باشد. رابطه زیر نحوه محاسبه آن را نشان می‌دهد:

$$R^2 = \frac{\sum_{k=1}^k X_k Y_k}{\sqrt{\sum_{k=1}^k X_k^2 \sum_{k=1}^k Y_k^2}} \quad (2)$$

در این رابطه  $X_k$  مقادیر مشاهداتی،  $Y_k$  مقادیر برآورد شده و  $k$  تعداد داده‌ها می‌باشد.

### ۲- جذر میانگین مربعات خطا (RMSE):



شکل ۲- مقادیر حداقل و حداکثر درجه حرارت مشاهداتی و شبیه سازی شده توسط مدل HadCM3 (۲۰۰۱-۱۹۷۱)

جدول ۲- مقادیر شاخص های ارزیابی مدل HadCM3 در شبیه سازی بارندگی و دما در دوره پایه

حداکثر درجه حرارت		حداقل درجه حرارت		مدل
R <sup>2</sup>	RMSE (%)	R <sup>2</sup>	RMSE (%)	
۹۹/۴۶	۱/۰۶	۹۹/۹۳	۱/۳۴	HadCM3

جدول ۳- ارتباط و همبستگی در هر ماه بین داده دمای مشاهداتی پیشینه و متغیرهای بزرگ مقیاس NCEP

DEC	NOV	OCT	SEP	AUG	JUL	JUN	MAY	APR	MAR	FEB	JAN	Predictors
۰/۰۱۴	۰/۰۳۳	۰/۱۴۰	۰/۱۵۵	۰/۱۳۶	۰/۱۰۵	۰/۰۳۲	۰/۰۰۹	۰/۰۱۸	۰/۰۲۳	۰/۰۷۹	۰/۰۱۷	Ncep5_uaf.dat
۰/۰۲۰	۰/۰۲۰	۰/۰۲۴	۰/۰۸۵	۰/۱۴۰	۰/۱۲۲	۰/۰۸۱	۰/۰۱۱	۰/۰۱۹	۰/۰۴۹	۰/۰۴۰	۰/۰۸۴	Ncep5_zaf.dat
۰/۱۸۴	۰/۱۱۳	۰/۰۹۲	۰/۲۴۸	۰/۳۵۳	۰/۳۷۹	۰/۳۳۱	۰/۱۳۹	۰/۱۷۶	۰/۳۷۴	۰/۳۷۸	۰/۳۹۳	Ncep500af.dat
	۰/۰۳۰	۰/۰۸۱	۰/۲۲۷	۰/۲۵۵	۰/۱۸۹	۰/۰۱۶		۰/۱۴۵	۰/۲۰۶	۰/۱۳۶	۰/۰۵۱	Ncep850af.dat
۰/۱۶۵	۰/۱۱۶	۰/۱۱۰	۰/۳۱۱	۰/۳۹۱	۰/۳۹۱	۰/۳۲۶	۰/۰۷۷	۰/۰۱۳	۰/۲۰۳	۰/۳۰۲	۰/۳۳۲	Nceptempaf.dat

لازم به ذکر است، قوی ترین ارتباط و همبستگی در هر ماه بین داده دمای مشاهداتی و پنج متغیر بزرگ مقیاس NCEP در سطح معنی داری پنج درصد بر طبق جدول های زیر وجود دارد. جاهای خالی نشان دهنده همبستگی ناچیز میان متغیرها است. نتیجه نشان می دهد که در ارتباط بین حداکثر دما و حداقل دما و Ncep5\_uaf.dat (ارتفاع ژئوپتانسیل در تراز پنج هکتوپاسکال در شبکه مورد نظر uaf)، Ncep5\_zaf.dat، (ارتفاع ژئوپتانسیل در تراز پنج هکتوپاسکال در شبکه مورد نظر zaf)، Ncep500af.dat، (ارتفاع ژئوپتانسیل در تراز ۵۰۰ هکتوپاسکال در شبکه مورد نظر af) Ncep850af.dat (ارتفاع ژئوپتانسیل در تراز ۸۵۰ هکتوپاسکال در شبکه مورد نظر af) و Nceptem\_paf.dat (متوسط دمای روزانه در شبکه مورد نظر paf) قوی ترین ارتباط و همبستگی در سطح احتمال ۹۵ درصد وجود دارد.

برای شبیه سازی متغیر دمای پیشینه در دوره ۲۰۰۱-۱۹۷۱ مرتبه با تعداد حداقل یک لایه پنهان با یک نورون و حداکثر پنج لایه پنهان به صورت ۱-۲-۳-۴-۵ این برنامه با تکرار epoch= ۳۰۰، اجرا شد، که بهینه ترین میزان خطا و ضریب همبستگی برای چهار لایه پنهان با ساختار نورون ۶-۶-۵-۵ بدست آمد. همچنین برای شبیه سازی دمای کمینه ۲۴ مرتبه با حداقل یک لایه پنهان با سه نورون و حداکثر چهار لایه پنهان با ساختار ۱-۲-۳-۴ برنامه با تکرار epoch= ۳۰۰، اجرا شد، که بهینه ترین میزان خطا و ضریب تبیین و همبستگی برای ساختار ۱-۳-۵ یعنی سه لایه پنهان است. نتایج عددی این مدل شبکه عصبی در جداول زیر برای شبیه سازی دمای پیشینه و کمینه و مشخصات معماری شبکه آورده شده است. که هر چه ضریب همبستگی و تبیین به یک و ضریب خطا به صفر نزدیک تر و کمتر از پنج درصد باشد عملکرد مدل در شبیه سازی بهتر است.

شیدائیان و همکاران: مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در ...

متغیر بزرگ مقیاس دیگر بیشتر است. بنابراین این ۵ متغیر به عنوان متغیرهای ورودی مدل شبکه عصبی با متغیرهای دما در نظر گرفته شده است. و بر اساس آن دمای بیشینه و کمینه برای دوره مشاهداتی شبیه‌سازی شد.

همچنین جدول (۵) میزان همبستگی جزئی بین متغیرها با متغیر دمای بیشینه و کمینه را مشخص می‌کند. هر چه میزان همبستگی جزئی متغیرها بزرگ‌تر باشد، نشان‌دهنده همبستگی قوی‌تری بین پارامترها است همانطور که از جدول زیر مشاهده می‌کنیم میزان همبستگی جزئی متغیرهای منتخب زیر از ۲۵

جدول ۴- ارتباط و همبستگی در هر ماه بین داده دمای مشاهداتی کمینه و متغیرهای بزرگ مقیاس NCEP

DEC	NOV	OCT	SEP	AUG	JUL	JUN	MAY	APR	MAR	FEB	JAN	Predictors
	۰/۰۲۰	۰/۱۲۷	۰/۱۸۸	۰/۱۲۲	۰/۱۱۷	۰/۰۳۲	۰/۰۱۸	۰/۰۰۶	۰/۰۲۷	۰/۰۸۴	۰/۰۴۲	Ncepp5_uaf.dat
۰/۰۱۱	۰/۰۱۹	۰/۰۰۹	۰/۰۹۲	۰/۱۴۲	۰/۰۹۲	۰/۰۷۴	۰/۰۲۱	۰/۰۱۵	۰/۰۶۲	۰/۰۶۰	۰/۱۰۰	Ncepp5_zaf.dat
۰/۱۵۰	۰/۰۶۵	۰/۰۵۳	۰/۲۳۸	۰/۳۸۱	۰/۳۹۰	۰/۲۹۰		۰/۱۳۹	۰/۴۱۰	۰/۵۰۷	۰/۴۶۰	Ncepp500af.dat
۰/۰۲۳		۰/۰۶۶	۰/۲۹۶	۰/۲۹۳	۰/۱۹۵	۰/۰۲۸		۰/۱۱۲	۰/۲۳۱	۰/۱۸۰	۰/۰۷۱	Ncepp850af.dat
۰/۱۲۶	۰/۰۴۲	۰/۰۵۹	۰/۳۱۳	۰/۴۱۲	۰/۴۵۵	۰/۳۰۳	۰/۰۹۲	۰/۰۱۳	۰/۲۴۲	۰/۴۱۱	۰/۳۸۶	Nceptempaf.dat

جدول ۵- ماتریس همبستگی و میزان Partial Correlation و P-Value بین متغیرهای NCEP

و دمای بیشینه و دمای کمینه				
P Value دمای کمینه	P-Value دمای بیشینه	Partial- r همبستگی جزئی متغیر دمای کمینه	Partial- r همبستگی جزئی متغیر دمای بیشینه	Predictors پیش‌بینی کننده‌ها
۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۵۶	۰/۰۵۴	Ncepp5_uaf.dat
۰/۰۰۰۰	۰/۰۰۰۰	۰/۱۶۴	۰/۱۵۳	Ncepp5_zaf.dat
۰/۰۰۰۰	۰/۰۰۰۰	۰/۳۹۶	۰/۳۷۳	Ncepp500af.dat
۰/۰۰۰۰	۰/۰۰۰۰	۰/۲۴۰	۰/۱۵۹	Ncepp850af.dat
۰/۵۰۹۱	۰/۰۲۹۹	۰/۰۰۴	۰/۰۲۳	Ncepr850af.dat
۰/۰۰۰۰	۰/۰۰۰۰	۰/۳۲۱	۰/۳۴۱	Nceptempaf.dat



جدول ۶- مشخصات و مقادیر ساختار مدل شبکه عصبی به کار رفته برای شبیه سازی دمای بیشینه

نوع مدل	الگوریتم آموزش	تابع محرک لایه پنهان	تابع محرک لایه خروجی	تعداد تکرار	ساختار لایه‌ها	ضریب همبستگی $r_1^2sq$	جذر میانگین مربعات خطا RMSE	ضریب تبیین $R_1^2$
ANN1	LM	tansig	pureline	۳۰۰	۱	۰/۱۸	۷/۰۶	۰/۴۲
ANN2	LM	tansig	pureline	۳۰۰	۳	۰/۲۴	۶/۷۹	۰/۴۹
ANN3	LM	tansig	pureline	۳۰۰	۴	۰/۲۵	۶/۷۲	۰/۵۰
ANN4	LM	tansig	pureline	۳۰۰	۵	۰/۲۵	۶/۷۲	۰/۵۰
ANN5	LM	tansig	pureline	۳۰۰	۷	۰/۲۶	۶/۷۱	۰/۵۱
ANN6	LM	tansig	pureline	۳۰۰	۸	۰/۲۶	۶/۷۱	۰/۵۱
ANN7	LM	tansig	pureline	۳۰۰	۹	۰/۲۷	۶/۶۷	۰/۵۲
ANN8	LM	tansig	pureline	۳۰۰	۱۰	۰/۲۵	۶/۷۷	۰/۵۰
ANN9	LM	tansig	pureline	۳۰۰	۱۱	۰/۲۵	۶/۷۸	۰/۵۰
ANN10	LM	tansig	pureline	۳۰۰	۱۲	۰/۲۵	۶/۷۵	۰/۵۰
ANN11	LM	tansig	pureline	۳۰۰	۷-۸	۰/۲۵	۶/۷۴	۰/۵۰
ANN12	LM	tansig	pureline	۳۰۰	۵-۳	۰/۲۷	۶/۶۷	۰/۵۲
ANN13	LM	tansig	pureline	۳۰۰	۲-۳	۰/۱۸	۷/۰۵	۰/۴۳
ANN14	LM	tansig	pureline	۳۰۰	۶-۷	۰/۲۴	۶/۷۸	۰/۴۹
ANN15	LM	tansig	pureline	۳۰۰	۴-۳	۰/۲۵	۶/۷۱	۰/۵۰
ANN16	LM	tansig	pureline	۳۰۰	۵-۴	۰/۲۵	۶/۷۴	۰/۵۰
ANN17	LM	tansig	pureline	۳۰۰	۵-۲	۰/۲۶	۶/۶۹	۰/۵۱
ANN18	LM	tansig	pureline	۳۰۰	۹-۸	۰/۲۴	۶/۷۹	۰/۴۹
ANN19	LM	tansig	pureline	۳۰۰	۱۱-۸	۰/۲۵	۶/۷۷	۰/۵۰
ANN20	LM	tansig	pureline	۳۰۰	۵-۵	۰/۲۶	۶/۷۱	۰/۵۱
ANN21	LM	tansig	pureline	۳۰۰	۵-۱	۰/۲۵	۶/۷۱	۰/۵۰
ANN22	LM	tansig	pureline	۳۰۰	۵-۳-۲	۰/۲۷	۶/۶۵	۰/۵۲
ANN23	LM	tansig	pureline	۳۰۰	۱۱-۸-۵	۰/۲۳	۶/۸۷	۰/۴۸
ANN24	LM	tansig	pureline	۳۰۰	۵-۳-۱	۰/۲۲	۷/۵۹	۰/۰۵
ANN25	LM	tansig	pureline	۳۰۰	۵-۳-۳	۰/۲۴	۶/۸۰	۰/۴۹
ANN26	LM	tansig	pureline	۳۰۰	۵-۳-۴	۰/۲۵	۶/۷۲	۰/۵۰
ANN27	LM	tansig	pureline	۳۰۰	۵-۳-۵	۰/۲۴	۶/۸۰	۰/۴۹
ANN28	LM	tansig	pureline	۳۰۰	۵-۳-۶	۰/۲۴	۶/۷۸	۰/۴۹
ANN29	LM	tansig	pureline	۳۰۰	۵-۲-۳	۰/۲۵	۶/۷۵	۰/۵۰
ANN30	LM	tansig	pureline	۳۰۰	۹-۳-۲	۰/۰۱۲	۷/۷۲	۰/۱۱
ANN31	LM	tansig	pureline	۳۰۰	۵-۵-۵	۰/۲۷	۶/۶۶	۰/۵۱
ANN32	LM	tansig	pureline	۳۰۰	۵-۶-۶	۰/۲۶	۶/۶۷	۰/۵۱
ANN33	LM	tansig	pureline	۳۰۰	۵-۵-۶	۰/۲۷	۶/۶۶	۰/۵۲
ANN34	LM	tansig	pureline	۳۰۰	۵-۶-۵	۰/۲۶	۶/۶۹	۰/۵۱
ANN35	LM	tansig	pureline	۳۰۰	۵-۲-۴	۰/۲۴	۶/۷۸	۰/۴۹
ANN36	LM	tansig	pureline	۳۰۰	۵-۵-۴	۰/۱۹	۷/۰۵	۰/۴۳
ANN37	LM	tansig	pureline	۳۰۰	۵-۲-۱	۰/۲۶	۶/۶۷	۰/۵۱
ANN38	LM	tansig	pureline	۳۰۰	۶-۲-۴	۰/۲۶	۶/۶۸	۰/۵۱
ANN39	LM	tansig	pureline	۳۰۰	۵-۵-۳	۰/۲۶	۶/۶۸	۰/۵۱
ANN40	LM	tansig	pureline	۳۰۰	۶-۶-۶	۰/۲۶	۶/۶۸	۰/۵۱
ANN41	LM	tansig	pureline	۳۰۰	۵-۳-۲-۱	۰/۲۵	۶/۷۰	۰/۵۰
ANN42	LM	tansig	pureline	۳۰۰	۵-۵-۵-۵	۰/۲۶	۶/۶۹	۰/۵۱
ANN43	LM	tansig	pureline	۳۰۰	۵-۵-۶-۶	۰/۲۷	۶/۶۲	۰/۵۷
ANN44	LM	tansig	pureline	۳۰۰	۵-۶-۶-۶	۰/۲۶	۶/۶۹	۰/۵۱
ANN45	LM	tansig	pureline	۳۰۰	۶-۶-۶-۶	۰/۲۶	۶/۶۶	۰/۵۱
ANN46	LM	tansig	pureline	۳۰۰	۵-۶-۵-۶	۰/۲۶	۶/۶۹	۰/۵۱

شیدائیان و همکاران: مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در ...

۰/۰۴۲	۷/۷۶	۰/۰۰۱	۵-۶-۵-۵	۳۰۰	pureline	tansig	LM	ANN47
۰/۴۹	۶/۷۷	۰/۲۴	۵-۵-۵-۶	۳۰۰	pureline	tansig	LM	ANN48
۰/۵۰	۶/۷۶	۰/۲۵	۵-۴-۳-۲-۱	۳۰۰	pureline	tansig	LM	ANN49

**جدول ۷- مشخصات و مقادیر ساختار مدل شبکه عصبی به کار رفته برای شبیه سازی دمای کمینه**


انواع مدل	الگوریتم یادگیری	تابع محرک لایه پنهان	تابع محرک لایه خروجی	تعداد تکرار	ساختار لایه‌ها	ضریب همبستگی $r_1^2 sq$	جذر میانگین مربعات خطا RMSE	ضریب تبیین $R_1^2$
ANN1	LM	tansig	pureline	۳۰۰	۳	۰/۲۶	۵/۷۷	۰/۵۱
ANN2	LM	tansig	pureline	۳۰۰	۵	۰/۲۶	۵/۸۰	۰/۵۱
ANN3	LM	tansig	pureline	۳۰۰	۹	۰/۲۶	۵/۸۴	۰/۵۱
ANN4	LM	tansig	pureline	۳۰۰	۱-۲	۰/۲۱	۵/۹۹	۰/۴۶
ANN5	LM	tansig	pureline	۳۰۰	۳-۲	۰/۲۶	۵/۷۶	۰/۵۱
ANN6	LM	tansig	pureline	۳۰۰	۳-۱	۰/۲۷	۵/۷۵	۰/۵۲
ANN7	LM	tansig	pureline	۳۰۰	۳-۳	۰/۲۸	۵/۷۴	۰/۵۲
ANN8	LM	tansig	pureline	۳۰۰	۵-۳	۰/۲۷	۵/۷۴	۰/۵۲
ANN9	LM	tansig	pureline	۳۰۰	۵-۱	۰/۲۸	۵/۷۰	۰/۵۳
ANN10	LM	tansig	pureline	۳۰۰	۵-۲	۰/۲۸	۵/۷۳	۰/۵۲
ANN11	LM	tansig	pureline	۳۰۰	۱-۲-۳	۰/۲۱	۶/۰۰۵۹	۰/۴۶
ANN12	LM	tansig	pureline	۳۰۰	۳-۲-۱	۰/۲۸	۵/۷۲	۰/۵۳
ANN13	LM	tansig	pureline	۳۰۰	۳-۲-۲	۰/۲۹	۵/۶۹	۰/۵۳
ANN14	LM	tansig	pureline	۳۰۰	۳-۳-۳	۰/۲۲	۵/۹۷	۰/۴۷
ANN15	LM	tansig	pureline	۳۰۰	۵-۳-۲	۰/۳	۵/۶۵	۰/۵۴
ANN16	LM	tansig	pureline	۳۰۰	۵-۳-۳	۰/۲۸	۵/۷۲	۰/۵۳
ANN17	LM	tansig	pureline	۳۰۰	۱-۱-۳	۰/۲۱	۶/۰۱	۰/۴۶
ANN18	LM	tansig	pureline	۳۰۰	۵-۳-۱	۰/۳	۵/۶۳	۰/۵۵
ANN19	LM	tansig	pureline	۳۰۰	۵-۲-۲	۰/۲۸	۵/۷۱	۰/۵۳
ANN20	LM	tansig	pureline	۳۰۰	۱-۳-۵	۰/۲۱	۶/۰۱	۰/۴۶
ANN21	LM	tansig	pureline	۳۰۰	۳-۵-۱	۰/۲۸	۵/۷۰	۰/۵۳
ANN22	LM	tansig	pureline	۳۰۰	۳-۱-۵	۰/۲۲	۵/۹۸	۰/۴۷
ANN23	LM	tansig	pureline	۳۰۰	۵-۳-۵	۰/۲۹	۵/۷۰	۰/۵۴
ANN24	LM	tansig	pureline	۳۰۰	۵-۳-۲-۱	۰/۲۸	۵/۷۰	۰/۵۳

**جدول ۸- پارامترهای شبکه بهینه آموزش داده شده پس از سعی و خطا**

پارامترهای مدل شبکه عصبی	دمای بیشینه	دمای کمینه
مدل و یا نوع شبکه	پرسپترون چند لایه‌ای	پرسپترون چند لایه‌ای
تعداد لایه‌های مخفی	۴	۳
تابع تحریک یا فشردگی	در لایه‌های پنهان تانژانت سیگموئید	در لایه‌های پنهان تانژانت سیگموئید
تعداد نرون‌ها در لایه‌های مخفی	۵-۵-۶-۶	۵-۳-۱
تعداد اپاک	۳۰۰	۳۰۰
نوع مدل	ANN43	ANN18
الگوریتم آموزش مدل	مارکوارت-لونیبرگ	مارکوارت-لونیبرگ
ضریب همبستگی	۰/۲۷	۰/۳
ضریب تبیین	۰/۵۷	۰/۵۵
جذر میانگین مربعات خطا	۶/۶۲	۵/۶۳
تابع آموزش شبکه پیشخور	newff	newff


همانطور که از جداول و اشکال می‌بینیم، مقادیر خطا و ضریب همبستگی  $R^2$  به دست آمده از شبیه سازی مدل شبکه عصبی مصنوعی مقدار مناسبی برای درجه حرارت حداکثر و حداقل نشان نمی‌دهد. حداکثر مقدار مناسب RMSE برای مدل شبکه عصبی ۵ می‌باشد که مقدار RMSE بدست آمده از مدل بیشتر از این مقدار و بیشتر از مدل شبیه ساز SDSM می‌باشد. و همچنین ضریب همبستگی به دست آمده از این مدل کمتر از مدل SDSM و از عدد یک اختلاف زیادی دارد. در نهایت با توجه به نتایج تحقیق و ارزیابی مدل می‌توان اظهار داشت که استفاده از روش شبکه عصبی مصنوعی پرسپترون چند لایه به عنوان روشی غیر خطی در شبیه سازی دمای بیشینه و کمینه در این پژوهش با توجه به خطای مدل نمی‌تواند به عنوان گزینه‌ای سودمند مورد توجه و بررسی قرار گیرد.

همانطور که در جداول بالا مشاهده می‌شود بهترین معماری برای دمای بیشینه مدل پرسپترون چهار لایه پنهان ANN43 با ساختار ۶-۵-۶-۶ می‌باشد که کمترین جذر میانگین مربعات خطا ۶/۶۲ در بین ساختارهای دیگر و بیشترین ضریب تبیین و همبستگی به ترتیب ۰/۵۷ و ۰/۲۷ است. و همچنین برای متغیر دمای کمینه بهترین ساختار شبکه با مدل پرسپترون سه لایه پنهان ANN18 با معماری ۵-۳-۱ که دارای کمترین جذر میانگین مربعات خطا ۵/۶۳ و بیشترین میزان ضریب تبیین و همبستگی به ترتیب برابر ۰/۵۵ و ۰/۳ است، می‌باشد. جدول ۶ مشخصات پارامترهای بهترین معماری شبکه آموزش داده شده پس از سعی و خطا به مدل را برای دمای بیشینه و کمینه نشان می‌دهد. همچنین نمودارهای سری زمانی و پراکنش نقاط نشان دهنده عملکرد پائین مدل در شبیه سازی دمای بیشینه و کمینه می‌باشد جدول (۹) ارزیابی عملکرد دو ساختار شبکه را بر اساس ضریب همبستگی نشان می‌دهد.



شکل ۳- نمودار پراکنش دمای حداقل مشاهده شده و پیش‌بینی شده توسط مدل با ساختار بهینه

شکل ۳- نمودار پراکنش دمای حداقل مشاهده شده و پیش‌بینی شده توسط مدل با ساختار بهینه



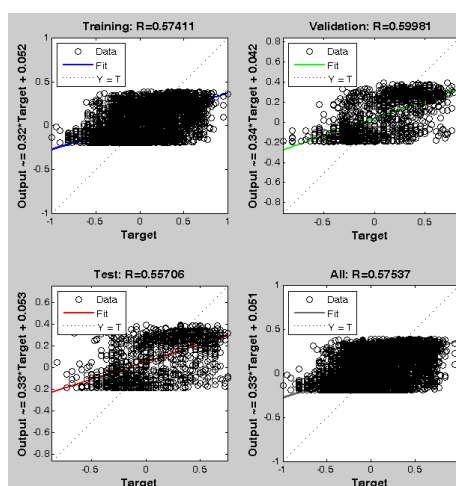
شکل ۴- نمودار پراکنش دمای حداکثر مشاهده شده و پیش‌بینی شده توسط مدل با ساختار بهینه

شکل ۴- نمودار پراکنش دمای حداکثر مشاهده شده و پیش‌بینی شده توسط مدل با ساختار بهینه

شیدائیان و همکاران: مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در ...

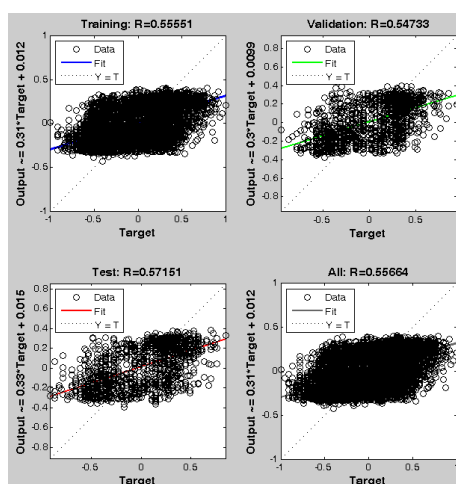
جدول ۹- مقادیر ارزیابی شبکه پرسپترون چند لایه بر اساس ضریب همبستگی در شبیه سازی متغیر درجه حرارت

R All	R Test	R Training	R Validation	معماری شبکه	متغیر شبیه سازی شده
۰/۵۷۵۳۷	۰/۵۵۷۰۶	۰/۵۷۴۱۱	۰/۵۹۹۸۱	۵-۵-۶-۶	دمای بیشینه
۰/۵۵۶۶۴	۰/۵۷۱۵۱	۰/۵۵۵۵۱	۰/۵۴۷۳۳	۵-۳-۱	دمای کمینه



- محورهای افقی پایین: تابع هدف محورهای افقی بالا میزان ضریب همبستگی صحت سنجی، تست و آموزش و کل، محورهای عمودی: معادله رگرسیونی خروجی تابع هدف

شکل ۵- نمودار همبستگی آموزش، آزمون، صحت سنجی و کل عملکرد مدل در مقابل تابع هدف مدل Target و خروجی مورد نظر شبکه برای دمای بیشینه



- محورهای افقی پایین: تابع هدف محورهای افقی بالا میزان ضریب همبستگی صحت سنجی، تست و آموزش و کل، محورهای عمودی: معادله رگرسیونی خروجی تابع هدف

شکل ۶- نمودار همبستگی آموزش، آزمون، صحت سنجی و کل عملکرد مدل در مقابل تابع هدف مدل Target و خروجی مورد نظر شبکه برای دمای کمینه

## جدول ۱۰- مقایسه نتایج آماری دو مدل شبیه سازی شبکه عصبی مصنوعی و SDSM

حداقل درجه حرارت		حداکثر درجه حرارت		مدل
RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	
۱/۰۶	۰/۹۹۴۶	۱/۳۴	۰/۹۹۹۳	SDSM
۵/۶۳	۰/۳	۶/۶۲	۰/۲۷	ANN

در جدول (۱۰) نتایج دو مدل مشاهده می‌شود نتایج کلی بیانگر این است که مدل SDSM در دوره پایه ۲۰۰۱-۱۹۷۱ در شبیه سازی درجه حرارت از قابلیت خوبی برخوردار است. همچنین مدل در شبیه سازی درجه حرارت حداقل به دلیل خطای کمتر، نسبت به دمای حداکثر عملکرد بهتری دارد و افزایش درجه حرارت را در سالهای آینده نشان می‌دهد، که در مقایسه با نتایج تحقیق فیسه ها (۲۰۱۲) که نشان دهنده افزایش دما با مدل SDSM و LARS-WG می‌باشد همخوانی دارد. در این تحقیق بهترین معماری شبکه عصبی مصنوعی برای شبیه سازی دمای بیشینه مدل پرسپترون چهار لایه پنهان ANN43 با ساختار ۶-۵-۵ می‌باشد که کمترین جذر میانگین مربعات خطا در بین ساختارهای دیگر و بیشترین ضریب تبیین و همبستگی را داراست. و برای متغیر دمای کمینه بهترین ساختار شبکه با مدل پرسپترون سه لایه پنهان ANN18 معماری ۱-۳-۵ که دارای کمترین جذر میانگین مربعات خطا و بیشترین میزان ضریب تبیین و همبستگی است، می‌باشد در صورتی که نتایج پژوهش حلییان (۲۰۱۳) نشان داد که استفاده از مدل MLP با ۲ لایه پنهان و ضریب یادگیری ۰/۴ نتایج بهتری در شبیه سازی دارد. همچنین نتایج تحقیق آبهشیک (۲۰۱۲) بهترین ساختار شبکه را برای پیش بینی متغیر بارش، الگوریتم پس انتشار خطا و با سه لایه پنهان با نورون متفاوت نشان می‌دهد و نتایج ایشان همخوانی بیشتری با نتایج تحقیق حاضر دارد. در ادامه نتایج این تحقیق نشان داد استفاده از روش شبکه عصبی مصنوعی پرسپترون چند لایه به دلیل مقدار خطای RMSE بالا و ضریب همبستگی R<sup>2</sup> پایین به عنوان روشی غیر خطی در شبیه سازی دمای بیشینه و کمینه نمی‌تواند به عنوان گزینه‌ای سودمند مورد توجه و بررسی قرار گیرد. نتایج به دست آمده در مقایسه با نتایج خان (۲۰۰۶) به دلیل کارایی بهتر مدل SDSM نسبت به شبکه عصبی و LARS-WG همخوانی دارد. ایشان به این نتیجه دست یافتند که مدل شبکه عصبی دارای ضعیف ترین عملکرد در شبیه سازی دما است. برخلاف نتایج ایشان اسفندیاری (۱۳۸۹) نشان داد که مدل چند لایه کارایی و دقت مناسبی در پیش بینی دما با ضریب همبستگی ۰/۹۹ و درصد خطای ۱/۹۷ دارد در صورتیکه در تحقیق حاضر در بهترین حالت ضریب همبستگی ۰/۳ و درصد خطا ۶/۶۲ می‌باشد.

## تشکر و قدردانی

بدینوسیله از شرکت آب منطقه‌ای استان مازندران و سازمان جهاد کشاورزی استان که اطلاعات لازم را در اختیار محققان این پژوهش قرار دادند قدردانی می‌گردد.

## شیدائیان و همکاران: مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در ...

- ۱- اسفندیاری درآباد، ف. حسینی، ا. آزادی مبارکی، م. حجازی زاده، ز. ۱۳۸۹. پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنج با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چند لایه (MLP). فصلنامه علمی - پژوهشی انجمن جغرافیای ایران. دوره جدید. ۸(۲۷): ۴۵-۶۵.
- ۲- اصغری مقدم، الف. نورانی، و. و ندیری، ع. ۱۳۸۷. مدل سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی. مجله دانش کشاورزی دانشگاه تبریز. ۱۸(۱): ۱-۱۵.
- ۳- اصلاح، پ. ۱۳۸۳. آنالیز برگشتی در آزمایش SASW با استفاده از شبکه‌های عصبی مصنوعی. پایان نامه کارشناسی ارشد عمران، دانشکده فنی دانشگاه ارومیه.
- ۴- تشنه لب، م. و منشی، م. ۱۳۸۹. پیش‌بینی اقلیمی پارامترهای هواشناسی با استفاده از شبکه‌های عصبی - فازی بر اساس آموزش پارامترهای بخش تالی. صفحه ۸. سومین کنفرانس منطقه‌ای تغییر اقلیم. دانشگاه اصفهان.
- ۵- حسینی، س الف. ۱۳۸۸. برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی. پایان نامه کارشناسی ارشد جغرافیای طبیعی (اقلیم شناسی). دانشگاه محقق اردبیلی.
- ۶- حلبیان، الف. م. و دارند، م. ۱۳۹۱. پیش‌بینی بارش اصفهان با استفاده از شبکه‌های عصبی مصنوعی. نشریه تحقیقات کاربردی علوم جغرافیایی. ۱۲(۲۶): ۴۷-۶۳.
- ۷- خورشید دوست، ن. خدانشناس، س. و داوری، ک. ۱۳۸۵. پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی. دومین کنفرانس مدیریت منابع آب.
- ۸- سلیمانی نادگانی، م. ۱۳۸۹. بررسی اثر تغییر اقلیم بر نیاز خالص آبیاری گندم. پایان نامه کارشناسی ارشد، دانشکده مهندسی فناوری و کشاورزی. پردیس کشاورزی و منابع طبیعی دانشگاه تهران.
- ۹- صمدی، س. ز. مساح بوانی، ع. ر. و مهدوی، م. ۱۳۸۶. بررسی تأثیر روش‌های کوچک مقیاس کردن رگرسیون بر رژیم سیلاب رودخانه. کارگاه آموزشی تغییر اقلیم و منابع آب. کمیته ملی آبیاری و زهکشی.
- ۱۰- منهای، م. ب. ۱۳۸۴. مبانی شبکه‌های عصبی (هوش محاسباتی). مرکز نشر دانشگاه صنعتی امیرکبیر. چاپ سوم. جلد ۱. ۷۱۲ ص.
- 11- Abhishek K., Kumar A, Ranjan R, and KumarS, 2012. A Rainfall Prediction Model using Artificial Neural Network. IEEE Control and System Graduate Research Colloquium. (ICSGRC).
- 12- Christensen N.S, Wood A.W, Voisin N, Lettenmaier D. P, and Palmer R. N, 2004. The effects of climate change on the hydrology and water resources of the Colorado River basin. Journal of Climatic change, 62 ( 1-3): 337-363.
- 13- Fisseha B, Melesse M, Romano A.M, Volpi E, and Fiori E.A, 2012. Statistical Downscaling of Percipitation and Temperature for the Upper Tiber Basin in Central Italy. I international. journal. of water Sciences. DOI: 10.5772/52890. Vol. 1.3:2012.
- 14- <http://www.cccsn.ec.gc.ca/?page=dd-gcm>
- 15- Hulme T.R, and Lal M, 1999. IPCC-TGCIAGuidelines on the use of scenario data for climate impact and adaptation assessment. Version 1. Carter Intergovernmental Panel on Climate Change, Task Group on Scenarios for Climate Impact Assessment. 69pp.
- 16- Karamouz M, Fallahi M, Nazif S, and Rahimi Farahani M, 2009. Long Lead Rainfall Prediction Using Statistical Downscaling and Artificial Neural Network Modeling, Transaction A: Civil Engineering, Sharif University of Technology Press, 16(2): pp. 165-172. (Translated in English)
- 17- Khan Ms, Coulibaly P, and Dibike Y, 2006. Uncertainty analysis of statistical downscaling methods, Journal of Hydrology, 319: 357-382.
- 18- Sajikumar N, Thandaveswara B.S, 1999. Non Liner rainfall runoff Model using artificial neural network. Journal of Haydrology, 216: 32-35.

- 19- Wilby R.L, and Dawson C. W, 2007 .Hadnbook of SDSM4.2-User Manual.Department of Geography.Lancaster Univ, Press,UK. 94Pp.
- 20-Xu C.Y, 1999. From GCMs to river flow: A review of downscaling methods and hydrologic modeling approaches. J.of Progress in physical Geography j.Pp: 23:2. 229-249.