



فصلنامه علوم محیطی، دوره بیستم، شماره ۴، زمستان ۱۴۰۱

۲۴۳-۲۵۸  
مقاله پژوهشی

## ارزیابی کارایی مدل‌های هوش مصنوعی در ریزمقیاس‌نمایی دما (منطقه مورد مطالعه: استان اردبیل)

محمد حسین جهانگیر\* و سید محمد احسان عظیمی

گروه انرژی‌های نو و محیط زیست، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران

تاریخ دریافت: ۱۳۹۹/۶/۱۰      تاریخ پذیرش: ۱۴۰۱/۷/۳۰

جهانگیر، م.ح. و س.م.ا. عظیمی. ۱۴۰۱. ارزیابی کارایی مدل‌های هوش مصنوعی در ریزمقیاس‌نمایی دما (منطقه مورد مطالعه: استان اردبیل).  
فصلنامه علوم محیطی. (۴) ۲۰-۲۴۳-۲۵۸.

**سابقه و هدف:** پیش‌بینی بلند و کوتاه مدت آب و هوا از جمله چالش‌های سیار مهم محققان آب و اقلیم بوده است. به منظور فائق آمدن بر این چالش، ابزارهای متعددی از جمله مدل‌های گردش عمومی جوی-اقیانوسی، سناریوهای پیش‌بینی و مدل‌های ریزمقیاس نمایی توسعه و استفاده شده است. این ابزارها با ایجاد همبستگی بین داده‌های بزرگ مقیاس مدل‌های گردش عمومی و داده‌های کوچک مقیاس سینوپتیک، به ریزمقیاس‌نمایی سناریوهای پیش‌بینی اقدام می‌کنند.

**مواد و روش‌ها:** در این مطالعه پارامترهای پیش‌بینی‌کننده بزرگ مقیاس دوره آماری ۱۹۶۱ تا ۲۰۰۳ از پایگاه داده مراکز ملی پیش‌بینی محیط زیست (NCEP)، داده‌های بزرگ مقیاس سناریوهای پیش‌بینی A1B و A2 مدل HadCM3 دوره آماری ۲۰۰۱ تا ۲۰۰۰ از مرکز ارزیابی و مدلسازی اقلیم کانادا موسوم به CCCma، و داده‌های سینوپتیک هواشناسی ایستگاه‌های اردبیل از سازمان هواشناسی دریافت شده است. در این مطالعه سه روش (SDSM)، حداقل مربعات ماشین بردار پشتیبان (LS-SVM) و پرسپترون چند لایه (MLP) برای ریزمقیاس‌نمایی، و از سنجنده‌های آماری CC، NMSE، RMSE، MSE، Nash-Sutcliffe و دیاگرام تیلور به منظور ارزیابی کارایی روش‌های ریز مقیاس‌نمایی مورد استفاده قرار گرفت.

**نتایج و بحث:** نتایج نشان داده است که مدل MLP بر اساس میانگین ایستگاه‌ها بهترین نتیجه را با مقادیر (CC=0/85)، (NMSE=0/63)، (MAE=0/52) و (NSH=0/73) کسب کرده و در رتبه‌های دوم و سوم به ترتیب مدل‌های LS-SVM و SDSM قرار گرفته‌اند. دیاگرام تیلور نیز مدل SDSM را ضعیف ترین مدل شناسایی و نتایج دو مدل LS-SVM و MLP را با اختلاف کمی با یکدیگر به عنوان مدل‌های برتر معرفی کرد. بر اساس نتایج ریزمقیاس‌نمایی، تمامی سناریوهای پیش‌بینی افزایش دمای میانگین روزانه تا سال ۲۱۰۰ در تمامی ایستگاه‌های مورد مطالعه را پیش‌بینی کرده‌اند.

**نتیجه گیری:** بر اساس نتایج مطالعه، در تمامی سناریوهای پیش‌بینی و بر اساس تمامی روش‌های ریز مقیاس‌نمایی، افزایش دمای میانگین

\* Corresponding Author: Email Address. mh.jahangir@ut.ac.ir  
<http://dx.doi.org/10.48308/envs.2022.35101>  
<http://dorl.net/dor/20.1001.1.17351324.1401.20.4.11.6>

روزانه پیش‌بینی شده است، لذا لازم است تا در تهیه سیاست‌های توسعه‌ای و محیط زیستی این موضوع در نظر گرفته بشود.

**واژه‌های کلیدی:** SDSM, LS-SVM, MLP, ریز مقیاس نمایی، دما میانگین روزانه، سناریوهای تغییر اقلیم، استان اردبیل.

## مقدمه

محققان قرار گرفته است. ریز مقیاس نمایی آماری به طور کلی در سه دسته مولد آب و هوا، طبقه بندی آب و هوا و رگرسیون به مدل‌سازی می‌پردازند (Murphy, 1999; Wilby *et al.*, 2002). از میان این سه دسته، مدل رگرسیونی با ایجاد رابطه آماری بین پارامترهای بزرگ مقیاس (پیش‌بینی کننده‌ها) و ریز مقیاس (پیش‌بینی شونده‌ها) بر اساس یک معادله رگرسیونی خطی یا غیر خطی، در سال‌های اخیر مقبولیت پیدا کرده است (Wilby *et al.*, 2002). از روش‌های رگرسیون غیر خطی می‌توان به متدهای الهام‌گرفته شده از طبیعت (به طور مثال، شبکه‌های عصبی و الگوریتم ژنتیک و ...) و انواع بردارهای پشتیبان که ماهیت تقریب تابع دارند نام برد که با استفاده از مشتق رابطه بین سناریوهای بزرگ مقیاس و مقادیر مشاهده‌ای در سطح ایستگاه سینوپتیک، وضعیت پارامترهای اقلیمی آینده را پیش‌بینی می‌کنند. این تکنیک از ریز مقیاس نمایی توانایی درک و حذف نویزها از داده‌ها را دارد و یک مزیت بزرگ برای یادگیری مدل تلقی می‌شود (Schoof and Pryor, 2001). از جمله محققانی که از شبکه‌های عصبی در ریز مقیاس نمایی مدل سناریوهای تغییر اقلیم استفاده کرده اند می‌توان به (Sailor *et al.*, 2000; Hewitson and Crane, 1994) اشاره داشت. در جدول ۱ نیز مطالعات مطرحی که در ایران صورت گرفته به اختصار معرفی شده است.

دما و بارش از جمله پارامترهای موثر در مطالعه تغییرات اقلیم می‌باشند، لذا داشتن یک تصویر از آینده توزیع مکانی و زمانی این پارامترها، می‌تواند نقش بسیار موثری در مدیریت منابع آبی هر منطقه ایفا کند (Mearns *et al.*, 2003; Dibike and Coulibaly, 2007). از جمله ابزارهایی که در سال‌های اخیر جهت پیش‌بینی احتمالی وضعیت آب و هوا استفاده شده سناریوهای گردش عمومی جوی و اقیانوسی بوده است. این سناریوهای عددی از جمله ابزارهای قابل اعتماد بوده که با در نظر گرفتن فرایندهای اقلیمی در واحد سنگ کره، هوا کره و آب کره در مقیاس‌های مختلف مکانی و با به کارگیری داده‌های گذشته، وضعیت آینده را به صورت احتمالی نشان می‌دهند (Sailor *et al.*, 2000; Grotch and MacCracken, 1991). این سناریوها اطلاعات را در مقیاس-کارهای محلی و منطقه‌ای به عنوان معیار ارزنده کاربرد ندارد.

برای آنکه بتوانیم بر اساس سناریوهای تغییر اقلیم، تاثیرات اقلیم آینده را در مقیاس مکانی کوچکتر بسنجدیم نیاز است. تا این سناریوها ریز مقیاس شوند (Wilby *et al.*, 2002). متدهای ریز مقیاس نمایی آماری و دینامیکی بسیاری وجود دارد که از بین آنها ریز مقیاس نمایی آماری به دلیل هزینه کم و کاربردی تر بودنشان به طور فراگیر مورد استفاده

جدول ۱- خلاصه‌ای از بهترین مطالعات کارشنده در ایران  
Table 1. A summary of the best conducted studies in Iran

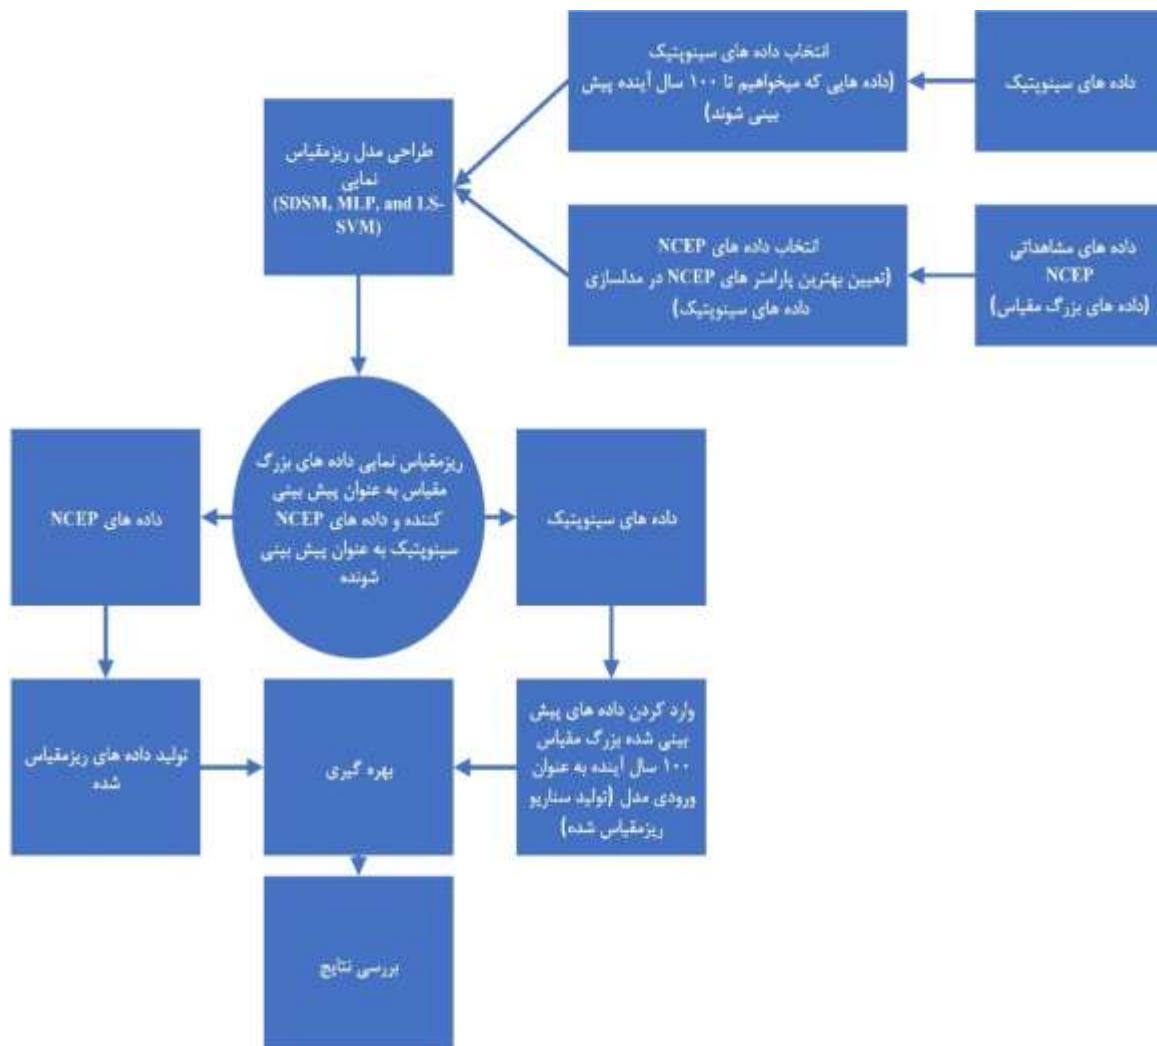
پیش‌بینی شونده‌ها Predicted(s)	مدل Models	تکنیک Technique	منطقه Study area	نویسنده‌گان Authors	شماره Number
بارش Precipitation	ECHAM5	1.Neural network 2.Regression model	پهنه جنوبی ایران Northern Iran	(Ahmadi <i>et al.</i> , 2014)	1
۱. بارش ۲. دمای بیشینه و کمینه ۱.Precipitation 2.Maximum and minimum temperature	HadCM3	1.SDSM 2.Lars-WG 3.Neural network	شمال غرب ایران Northwestern Iran	(Sobhani <i>et al.</i> , 2017)	2

ادامه جدول ۱- خلاصه ای از بهترین مطالعات کارشده در ایران  
Table 1. Cont. A summary of the best conducted studies in Iran

شماره Number	نویسنده‌ان Authors	منطقه Study area	تکنیک Technique	مدل Models	پیش‌بینی شونده‌ها Predicted(s)
3	(Dehghani <i>et al.</i> , 2017)	حوضه آبخیز بازفت صمصانی Bazoft-e- Samsami Watershed	1.Decision tree 2.K Nearest neighbor 3.Neural network 4.Linear regression	AOGCM	بارش و دمای ماهانه Monthly precipitation and temperature
4	(Omidvar <i>et al.</i> , 2019)	استان کرمان Kerman province	Neural network	CanESM2	بارش و دمای ماهانه Monthly precipitation and temperature
5	(Rezaee <i>et al.</i> , 2015)	استان کرمان Kerman province	1.Neural network 2.SDSM	HadCM3	بارش Precipitation

هدف مقاله حاضر، ارزیابی کارایی مدل‌های ریز مقیاس نمایی در پیش‌بینی دمای میانگین سه ایستگاه سینوپتیک استان اردبیل بر اساس سناریوهای تغییر اقلیم

IPCC در مدل HadCM3 می‌باشد که در سال ۲۰۰۷ در معرض محققان قرار گرفته است. به منظور درک بهتر، فرایند ریز مقیاس نمایی در شکل ۱ ارائه شده است.

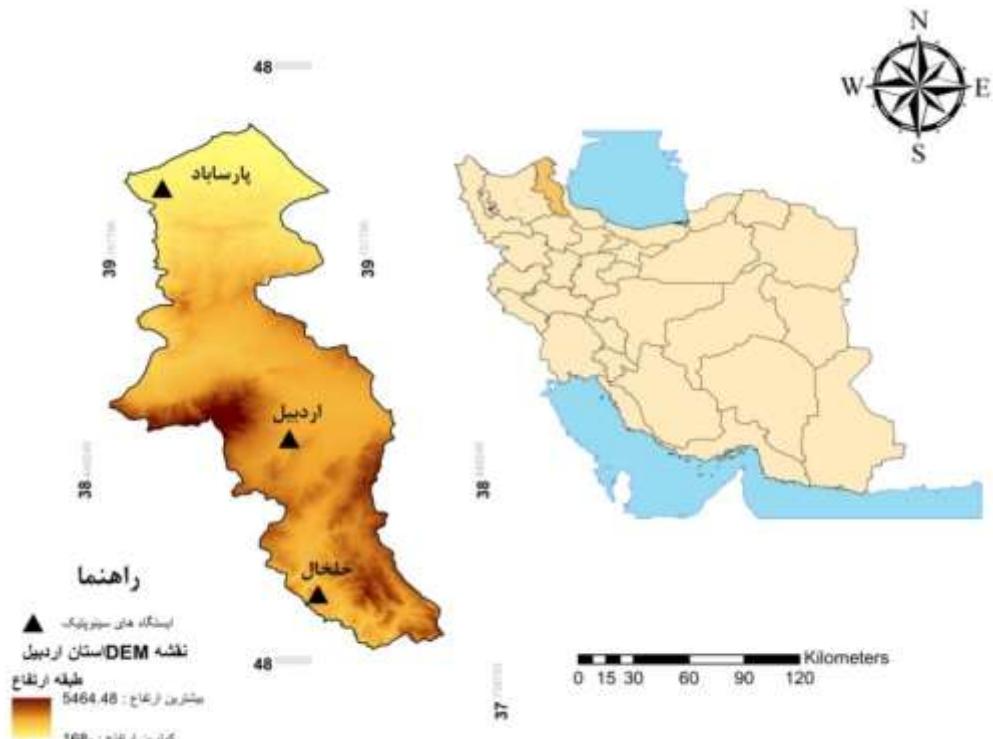


کیلومتر مرز مشترک بین المللی دارد لذا مطالعات اقلیمی در این منطقه برای استان‌های داخلی و کشورهای هم‌جوار حائز اهمیت می‌باشد. استان اردبیل، به دلیل کشیدگی طولی آن، دارای تغییرات آب و هوایی قابل توجهی است به طوری که شهرستان اردبیل با آب و هوای سرد و خشک تقریباً ۸ ماه از سال را در وضعیت یخ‌بندان سپری می‌کند. به منظور بررسی وضعیت گذشته و پیش‌بینی آینده از سه ایستگاه هواشناسی سینوپتیک استفاده شده است که در شکل ۲ موقعیت این ایستگاه‌ها در استان و همچنین موقعیت استان نسبت به کشور ایران نشان داده شده است.

## مواد و روش‌ها

### منطقه مورد مطالعه

استان اردبیل یکی از سرد ترین استان‌های کشور با دمای میانگین سالانه حدود  $20^{\circ}\text{C}$  درجه سانتیگراد می‌باشد که در شمال غربی ایران واقع شده است. این استان دارای مساحتی در حدود ۱۷۹۵۳ کیلومتر مربع بوده که در موقعیت جغرافیایی  $39^{\circ}37' \text{N}$  تا  $56^{\circ}47' \text{N}$  و  $42^{\circ}47' \text{E}$  تا  $15^{\circ}47' \text{E}$  واقع شده است. این منطقه با استان‌های آذربایجان غربی، زنجان و گیلان مرز مشترک داخلی و با کشور آذربایجان نیز در حدود ۳۶۹ کیلومتری است.



شکل ۲- منطقه مورد مطالعه و موقعیت جغرافیایی ایستگاه‌های سینوپتیک

Fig. 2- Study area and geographical location of synoptic stations

بندی قرار می‌گیرد.

**داده‌های مشاهده‌ای (داده‌های ایستگاه سینوپتیک)**  
داده‌های میانگین دما ثبت شده این منطقه از سه ایستگاه سینوپتیک پارسآباد، اردبیل و خلخال گرفته شده است. دوره آماری این اطلاعات از سال ۱۹۸۷ تا ۲۰۱۷ به صورت روزانه بوده است که اطلاعات اجمالی این ایستگاه‌ها در جدول ۲ آورده شده است.

### درآمدی بر داده‌ها

داده‌های روزانه پارامترهای مدل بزرگ مقیاس اقلیمی از سایت مرکز بین المللی محیط زیست (NCEP/NCAR) برای دوره ۱۹۶۱ تا ۲۰۰۳ گرفته شد. این داده‌ها مربوط به یک سلول  $2.5^{\circ}\text{N}$  درجه طولی و  $2.5^{\circ}\text{E}$  درجه عرضی است که بر اساس اندازه گیری ۱۷ سطح هوایی ثبت شده است که بدین ترتیب استان اردبیل در سه پیکسل از این تقسیم

جدول ۲- اطلاعات کلی ایستگاه های سینوپتیک منتخب  
Table 1. General information of the selected synoptic stations

ایستگاه Station	ارتفاع(متر) Height (m)	طول جغرافیایی Longitude	عرض جغرافیایی Latitude	میانگین Mean	انحراف میار Std. Deviation	ضریب تغییرات Coefficient of variation	Temperature (yearly) سالانه دما
اردبیل Ardabil	1332	48.172	38.152	10	1.19	%12.6	
پارسآباد Parsabad	73	47.553	39.391	15.3	0.62	%64	
خلخال KhalKhal	1796	48.311	37.380	8.5	0.96	%11.27	

سطح زمین باشند، ۲- آن‌ها باید از لحاظ آماری و فرایند فیزیکی ارتباط و پیوستگی خودشان را با پارامترهای پیش‌بینی شونده برقرار کرده باشند، و در نهایت ۳- آنها بتوانند تغییرات مقدار کربن در اتمسفر را برای سال‌های آینده به نمایش بگذارند ( Hewitson and Crane, 1994 ; Hellström *et al.*, 2001). به همین منظور، در تعیین این پیش‌بینی کننده‌ها، با قرار دادن پیش‌بینی کننده‌های احتمالی به عنوان ورودی، کارایی مدل‌های ریزمقياس نمایی برای هر پارامتر سنجیده و بهترین آنها در ریز مقياس نمایی هر سناریو استفاده می‌شود. لازم به ذکر است این سنتجش به صورت ایستگاه به ایستگاه و کاملاً مجرزاً انجام می‌شود. در جدول ۳. پیش‌بینی کننده‌های قطعی برای دمای میانگین روزانه به همراه تعاریف‌شان ارائه شده است.

جدول ۳- لیست متغیرهای NCEP استفاده شده به عنوان پیش‌بینی کننده برای ریزمقياس نمایی  
Table 3. List of NCEP variables used as predictors for downscaling average daily temperature

نماد Symbol	تعریف Definition
p_u	Zonal velocity component @ surface
p_v	Meridional velocity component @ surface
p_z	Vorticity @ surface
p500	Pa Geopotential height
s500	Specific humidity @ 850Pa
s850	Specific humidity @ 850Pa
sphu	Specific humidity @ surface
temp	Mean surface temperature

مقیاسی که آینده را پیش بینی کرده اند استفاده کرد. به منظور ایجاد یک مدل ریزمقیاس نمایی، مراحل متعددی باید طی شود تا نتایج قابل انکا و معتبر باشد که در ادامه، به معرفی مراحل آن پرداخته شده است. در شکل ۳ نیز نمایی از تبدیل داده بزرگ مقیاس به کوچک مقیاس ارئه شده است.

**ریزمقیاس نمایی**  
ریزمقیاس نمایی فرایندی است که در آن از طریق ایجاد یک رابطه ریاضی، بین داده‌های مدل گردش عمومی و داده‌های سینوپتیک منطقه‌ای یک مدل آماری یا دینامیکی بدست می‌آید. از این مدل می‌توان به پیش بینی پارامترهای سینوپتیکی بر اساس سناریوهای بزرگ

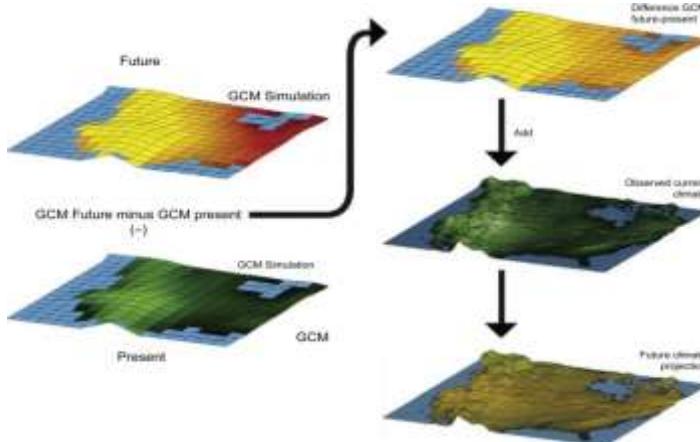
(Masson *et al.*, 2021)

Fig. 3- The process of downscaling

### نرم‌السازی

نرم‌السازی از جمله تکنیک‌هایی است که پس از PCA بر روی داده‌ها با هدف بالا بردن کارایی مدل‌ها به کار می‌رود. از آنجا که داده‌های ورودی دارای مقیاس‌های عددی مختلفی هستند، لذا توابع نرم‌السازی داده‌ها را به یک مقیاس عددی مشخص تبدیل می‌کند. از جمله محسن این روش می‌توان به بالا بردن همبستگی بین پیش‌بینی شونده و پیش‌بینی کننده در مدل‌های ریز مقیاس نمایی اشاره داشت. در مطالعه حاضر، داده‌ها در مقیاس عددی به میانگین ۰ و واریانس ۱ تبدیل شده اند.

### تقسیم‌بندی داده‌ها

در مدل‌سازی نیاز است تا داده‌ها به طور کلی به دو دسته آموزش و تست تقسیم‌بندی شوند. در این مطالعه ۷۰ درصد داده‌ها به دو دسته آموزش و مابقی به دسته تست اختصاص داده شده است. به عبارت دیگر از سال ۱۹۸۷ تا پایان سال ۱۹۹۸ برای آموزش و از سال ۱۹۹۹ تا پایان سال ۲۰۰۱ برای تست انتخاب شده است.

### پیش‌پردازش داده‌ها

پیش‌پردازش از جمله قدم‌هایی است که برای آماده‌سازی داده‌ها جهت معرفی به مدل‌ها به منظور بالا بردن کارایی مدل‌ها پیموده می‌شود. در این مرحله فرآیندهایی از قبیل حذف نویز از داده، جداسازی داده موثر از سایر داده‌ها، طبقه‌بندی و خوشه‌بندی داده‌ها و مواردی از این دست صورت می‌گیرد (Jahangir *et al.*, 2019). در این مطالعه به اجرای فرآیند آنالیز مولفه اصلی، نرم‌السازی و تقسیم‌بندی داده پرداخته شده است که در ادامه این تکنیک‌ها به طور مبسوط معرفی می‌شوند.

### آنالیز مولفه اصلی

آنالیز مولفه اصلی<sup>۱</sup> همان‌طور که از نامش پیداست می‌تواند مولفه‌های اصلی را شناسایی و کمک می‌کند تا به جای اینکه تمامی ویژگی‌ها مورد بررسی قرار گیرد، یک سری ویژگی‌هایی که ارزش بیشتری دارند، تحلیل شود. در واقع PCA آن ویژگی‌هایی را که ارزش بیشتری دارند را استخراج و به عنوان داده‌های اصلی به مدل معرفی می‌کند.

عنوان ورودی تعریف می‌شود. خروجی نورون‌ها با نام  $Y$ ،  
توسط معادله ۱. محاسبه می‌شوند.

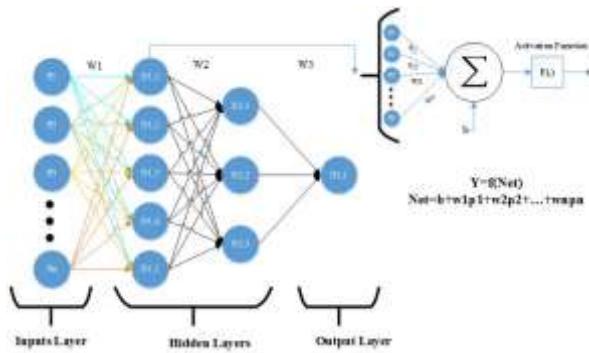
$$Y = f \left( \sum_{i=0}^{N-1} w_i x_i + b \right) \quad (1)$$

در این معادله،  $w$  بردار وزن،  $x$  بردار ورودی و  $b$  برابر بایاس نورون می‌باشد که وزن و بایاس توسط الگوریتم یادگیری تخمین زده می‌شود. لازم به ذکر است با افزایش تعداد نورون‌ها در لایه (ها) مخفی، این شبکه می‌تواند قابلیت حل مسائل پیچیده تر را پیدا کند. شکل ۳ ساختار یک شبکه عصبی با دو لایه مخفی را نشان می‌دهد.

### مدل‌های ریزمقیاس نمایی

#### پرسپترون چند لایه

پرسپترون چند لایه<sup>۲</sup> یکی از مدل‌های ریزمقیاس نمایی در شبکه‌های عصبی می‌باشد. این شبکه در مجموع از سه لایه ورودی، مخفی و خروجی تشکیل شده است که نورون‌ها در لایه (ها) مخفی نقش تقریب تابع را به عهده دارند (Hornik, 1991). در این مرحله، نورون‌ها بردارهای ورودی را در بردارهای وزن ضرب کرده و پس از جمع نتایج، بردار حاصل جمع را با مقدار بایاس جمع می‌کنند که حاصل عملیات انجام شده به تابع انتقال تعیین شده توسط کاربر به



شکل ۴- معماری شبکه عصبی پرسپترون چند لایه  
Fig. 4- Multilayer perceptron neural network architecture

همراه با پارامترهای رگرسیونی تولید شده به منظور پیش‌بینی وضعیت اقلیمی هر ایستگاه سینوپتیک تا سال ۲۱۰۰ با استفاده از سناریوهای پیش‌بینی تولید شده می‌پردازد. لازم به ذکر است در مطالعه حاضر از ورژن نرم افزار SDSM 5.3 استفاده شده است (Wilby *et al.*, 2002).

#### حداقل مربعات ماشین بردار پشتیبان

حداقل مربعات ماشین بردار پشتیبان<sup>۳</sup> یکی از ورژن‌های ماشین بردار پشتیبان است که بر اساس یادگیری نظرارت شده به تقریب تابع داده‌ها می‌پردازد. الگوریتم حداقل مربعات ماشین بردار پشتیبان، یک الگوریتم بهبود یافته از ماشین بردار پشتیبان می‌باشد (Mellit *et al.*, 2013)، که برپایه کرنل بنا شده است (Kundu *et al.*, 2017)، ابداع ابتدا توسط (Suykens and Vandewalle, 1999) ابداع شد. در مقایسه با SVM معمولی که نیازمند تابع هزینه غیر حساس می‌باشد، الگوریتم LS-SVM تنها به ضریب

همانطور که در تصویر ۳ قابل مشاهده است،  $W$  های بزرگ برابر بردار وزن در لایه‌ها است و همچنین برای هر ورودی در هر نورون یک وزن اختصاص داده شده است. در مطالعه حاضر از یک شبکه با معماری ۲ لایه مخفی و یک لایه خروجی بهره برده شده است.

#### مدل ریزمقیاس نمایی آماری

مدل ریزمقیاس نمایی آماری<sup>۴</sup> از جمله تکنیک‌های ریز مقیاس نمایی است که به صورت جهانی مورد استقبال عموم محققان علوم آب و اقلیم قرار گرفته شده است. این مدل برای اولین بار توسط (Wilby *et al.*, 2002) به عنوان یک مدل رگرسیون خطی هیبریدی با نگرش تولید داده‌های آب و هوایی تصادفی ارائه شد. تکنیک رگرسیون خطی هیبریدی به تخمین داده‌های تجربی-آماری بین NCEP به عنوان داده‌های بزرگ مقیاس و سینوپتیک به عنوان داده‌های کوچک مقیاس می‌پردازد. مدل طراحی شده

بسنجند. از این رو اکتفا کردن به تعداد محدودی از این سنجنده‌ها به آن دلیل که هر کدامشان جنبه خاصی از بردار داده‌ها را مورد تجزیه و تحلیل قرار می‌دهد، کار صحیحی نمی‌باشد. برای این منظور از ضربی همبستگی (CC)، میانگین مربع خطای (MSE)، میانگین ریشه مربع خطای (RMSE)، میانگین مربع نرمال خطای (NMSE)، شاخص بهره‌وری Nash-Sutcliffe و میانگین مطلق خطای (MAE)، برای اندازه گیری عملکرد مدل‌های مختلف مورد استفاده قرار گرفته شده است. فرمول‌های این سنجنده‌های آماری در جدول ذیل ارائه شده است.

Suykens و پارامترهای شکل بسته کرده است (Suykens, 2001). به عبارت دیگر، الگوریتم LS-SVM از مجموعه ای از معادله‌های خطی درجه یک به جای درجه دو محاسب که در SVM استفاده می‌شود، تشکیل شده است (Teegavarapu and Goly, 2018) (الگوریتم‌ها وتابع مدل LS-SVM به مطالعه Suykens et al., 2002) مراجعه شود.

### سنجش کارایی مدل‌ها

سنجنده‌های آماری بسیار متنوعی وجود دارند که میزان انحراف یا همبستگی مجموعه‌هایی از اعداد را بتوانند

جدول ۴- سنجنده‌های آماری

Table 4. Statistical analyzer

فرمول Equation	نام Name	شماره Number
$\frac{\sum_{i=1}^N (Y_T - \bar{Y}_T)(Y_S - \bar{Y}_S)}{[\sum_{i=1}^N (Y_T - \bar{Y}_T)^2 \sum_{i=1}^N (Y_S - \bar{Y}_S)^2]^{1/2}}$	CC	1
$\frac{\sum_{i=1}^N (Y_S - \bar{Y}_T)^2}{N}$	MSE	3
$\sqrt{\frac{\sum_{i=1}^N (Y_S - Y_T)^2}{N}}$	RMSE	4
$\frac{1}{N} \sum_{i=1}^N (Y_S - Y_T)^2$	NMSE (Zhang and Govindaraju, 2000)	5
$1 - \frac{\sum_{i=1}^N (Y_S - Y_T)^2}{\sum_{i=1}^N (Y_T - \bar{Y}_T)^2}$	Nash-Sutcliffe (Nash and Sutcliffe, 1970)	6
$1 - \frac{\sum_{i=1}^N  Y_S - Y_T }{\sum_{i=1}^N  Y_T - \bar{Y}_T }$	MAE (Johnson et al., 2003)	7

\* در معادلات بالا، S به معنای بردار مشاهده ای و T به معنای بردار مدل شده است.

مقدار CC برابر ۰/۸۵، مقدار NMSE برابر ۰/۶۳، مقدار NSH برابر ۰/۷۳ و مقدار MAE برابر ۰/۵۲، بهترین نتایج را کسب کرده است. همچنین بهترین مقدار RMSE مربوط به مدل LS-SVM بوده که برابر ۴/۲ محاسبه شده است. از این رو بر اساس میانگین گیری نتایج سنجنده‌های آماری در مدل‌ها، بهترین مدل با قاطعیت بالا مربوط به MLP بوده است که در ادامه مدل‌های LS-SVM و SDSM نیز در رتبه‌های دوم و سوم جای گرفته اند. بر

### نتایج و بحث

نتایج مطالعات انجام شده در قالب ۵ سنجنده آماری، سه مدل ریزمقیاس نمایی و سه ایستگاه سینوپتیک در جدول ۵ ارائه شده است. در این جدول مقادیر بدست آمده بر اساس نتایج تست شبکه بوده و از اعلام نتایج آموزش و کل داده به دلیل اهمیت نه چندان بالای آنها صرف نظر شده است. بر اساس نتایج بدست آمده، مدل MLP از میانگین ۵ سنجنده آماری در ۴ سنجنده به طوری که

ترتیب مقدار ۰/۷۹ و ۰/۵۹ را کسب کرده اند که در نوع خود بهترین دستاورده را داشته اند.

برای سنجش بهتر مدل ها نیاز است تا نمودار هایی ترکیبی از چند سنجده تهیه و بر اساس آن تصمیم درست گرفته شود. در همین راستا، مطالعه حاضر از دیاگرام تیلور نیز برای ارزیابی عملکرد مدل ها استفاده کرده است. این دیاگرام با در نظر گرفتن همبستگی و انحراف معیار، اقدام به رتبه بندی مدل ها در یک فضای پیوسته آماری می کند. نتایج ارزیابی مدل ها بر اساس دیاگرام تیلور در شکل ۴ قابل مشاهده است.

اساس ارزیابی ایستگاهها نسبت به سنجنده های آماری، بهترین نتیجه در سنجنده CC مربوط به ایستگاه پارسabad در مدل MLP با مقدار ۸۹/۰ بوده است. بر اساس سنجنده RMSE ایستگاه اردبیل در مدل LS-SVM و ایستگاه پارسabad در مدل MLP هر دو با ثبت مقدار ۴ بهترین نتایج را کسب کرده اند. مشابه سنجنده RMSE، سنجنده LS در ایستگاه پارسabad برای دو مدل MLP و SVM با ثبت مقدار ۷۴/۰ نیز بهترین نتیجه حاصل شده است. دو سنجنده بعدی که شامل NSH و MAE می باشد، هر دو در ایستگاه پارسabad بر اساس مدل MLP به

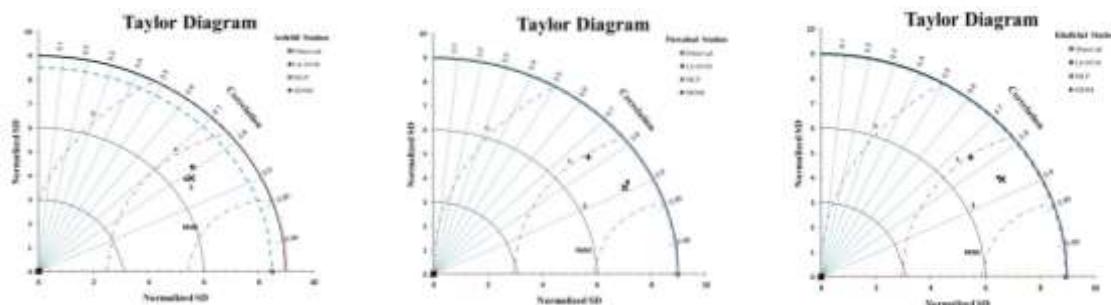
**جدول ۵- نتایج ارزیابی کارایی مدل ها**  
Table 5. Results of evaluating models' performance

سنجدنده های آماری Statistical analyzer					ایستگاهها Stations	مدل ها Models
MAE	Nash-Sutcliffe	NMSE	RMSE	CC		
0.46	0.66	0.45	4	0.81	اردبیل Ardabil پارس اباد Parsabad خال KhalKhal	LS-SVM
0.58	0.78	0.74	4.1	0.88		
0.52	0.73	0.63	4.5	0.85		
0.52	0.72	0.6	4.2	0.84		
0.46	0.66	0.46	4.8	0.79	اردبیل Ardabil پارس اباد Parsabad خال KhalKhal	SDSM
0.55	0.75	0.71	4.5	0.84		
0.52	0.7	0.63	4.7	0.8		
0.51	0.7	0.6	4.6	0.81		
0.47	0.67	0.51	4.8	0.82	اردبیل Ardabil پارس اباد Parsabad خال KhalKhal	MLP
0.59	0.79	0.74	4	0.89		
0.53	0.74	0.65	4.2	0.86		
0.53	0.73	0.63	4.3	0.85		

\*در جدول ارائه شده، اعداد بولد شده بیانگر نتایج شاخص می باشد.

و LS-SVM به طور نزدیکی نتایج مدلسازی را شبیه به هم دانسته اما در تمامی سه ایستگاه مورد مطالعه، نتایج از LS-SVM قدری بهتر کسب شده است.

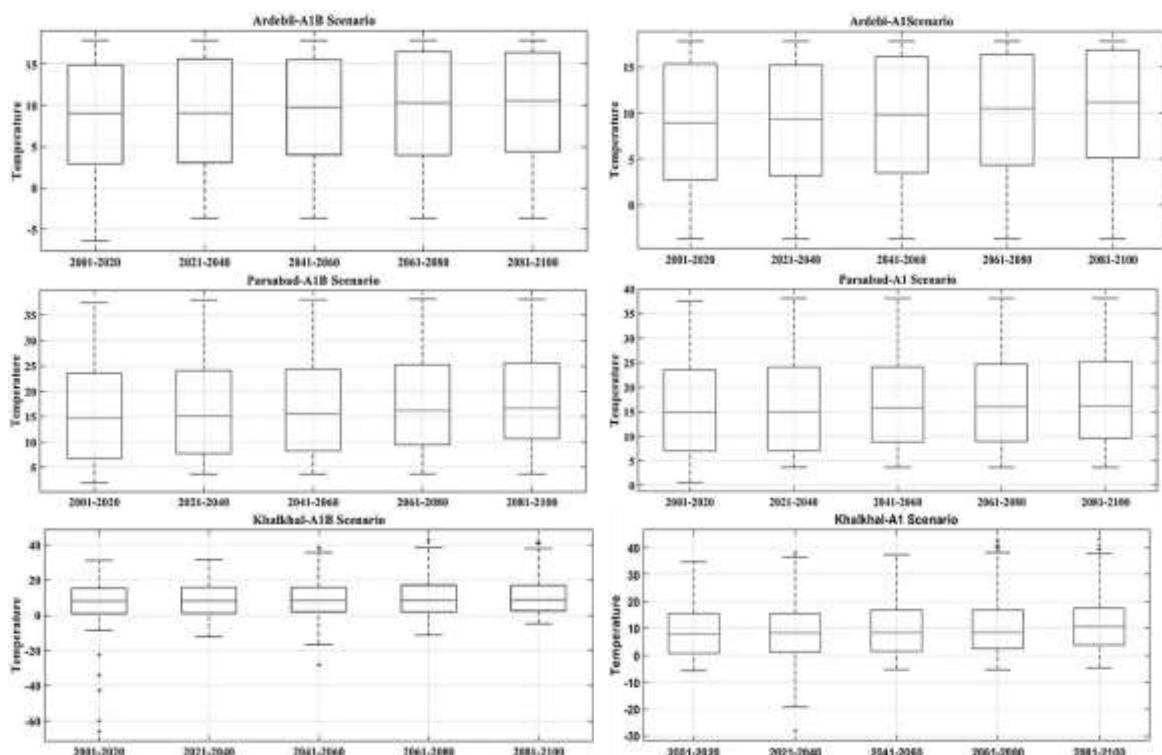
بر اساس نتایج بدست آمده از دیاگرامها، مدل SDSM با اختلاف معنی داری از سایر مدل ها در ریز مقیاس نمایی عملکرد ضعیف تری داشته است. همچنین دو مدل MLP



شکل ۵- دیاگرام تیلور مدل ها  
Fig. 5- Taylor diagrams of the models

۷۵ درصد بالایی به نرخ چارک داخلی شناخته می‌شود. نتایج مرسوم از داده‌های ریزمقیاس شده بر اساس دمای میانگین در شکل ۵ نشان داده شده است. در این نمودارها که بر اساس دو سناریو A1 و A1B رسم شده است هر سه ایستگاه مورد مطالعه مورد ارزیابی قرار گرفته است. بر اساس نتایج بدست آمده دما در هر دو سناریو بدون استثنای در تمامی ایستگاه‌ها تا ۱۰۰ سال آینده به طور چشم گیری افزایش خواهد یافت. همچنین می‌توان اشاره داشت که میزان افزایش دما در سناریو A1 بیشتر پیش‌بینی شده است.

پس از آنکه مدل‌های ریزمقیاس نمایی طراحی و اعتبار سنجی شد، قدم بعدی استفاده از مدل برتر در ریز مقیاس نمایی داده‌های بزرگ مقیاس به منظور پیش‌بینی داده‌های کوچک مقیاس در سال‌های آتی می‌باشد. از این جهت نمودارهای جعبه‌ای در مقاله حاضر در نظر گرفته شده است که سال‌های پیش‌بینی شده را به ۵ قسمت ۲۰ ساله تقسیم بندی کرده است. خط وسط جعبه‌ها در این نمودارها میانه است و مرز بالایی و پایینی جعبه‌ها به ترتیب نشان دهنده ۲۵ و ۷۵ درصد مجموعه داده‌ها است. همچنین تفاضل بین ۲۵ درصد پایینی و



شکل ۶- نمودار جعبه‌ای سناریوهای A1 و A1B در ایستگاه‌های منتخب  
Fig. 6- Boxplot of A1 and A1B scenarios of selected stations

توانسته این مسیر را هدایت بخشد. یکی از ابزارهایی که به آگاهی بخشی در مورد وضعیت آینده آب و هوا کمک میکند، پیش‌بینی بر اساس سناریوهای تغییر اقلیم است. مقاله حاضر به مقایسه سه مدل ریزمقیاس نمایی SDSM و MLP و LS-SVM بر روی سه ایستگاه سینوپتیک استان اردبیل بر اساس مدل گردش عمومی HadCM3 روی داده دمای میانگین پرداخت. به منظور پیش‌بینی دما تا سال ۲۱۰۰ سه مدل مذکور به ایجاد یک مدل ریاضی بین داده‌های سینوپتیک ایستگاه‌های مدنظر با داده‌های بزرگ مقیاس در همان واحد زمانی پرداختند و در نهایت با تعیین بهترین پارامترهای بزرگ مقیاس، بهترین مدل ریزمقیاس نمایی تعیین گردید که در ادامه با اجرای داده‌های سناریو پیش‌بینی تا سال ۲۱۰۰، روند دمای میانگین روزانه محاسبه و پیش‌بینی شد. در بین مدل‌های بررسی شده، MLP توانست کارایی بهتری را از خود نشان دهد که بر این اساس در بین سه مدل درنظر گرفته شده در ایستگاه‌های مورد مطالعه این مدل در مطالعات آینده ارجح خواهد بود. در آخر نیز بر اساس تمامی سناریوهای پیش‌بینی در تمامی ایستگاه‌های مورد مطالعه بر اساس سه مدل ریزمقیاس نمایی، افزایش محسوس دما تا سال ۲۱۰۰ پیش‌بینی شده است، لذا نیاز است تا طرح‌های آمایش سرزمین با در نظر گرفتن افزایش دما برنامه ریزی شود.

## پی‌نوشت‌ها

<sup>1</sup> Principal Component Analysis

<sup>2</sup> Multilayer Perceptron(MLP)

<sup>3</sup> Statistical Downscaling Model (SDSM)

<sup>4</sup> Least Square Support Vector Machine(LS-SVM)

Ahmadi, B.N., Shirvani, A. and Nazemosadat, M., 2014. The Application of and for downscaling GCMS outputs for prediction of precipitation in across Southern Iran. Journal of Water and Soil (Agricultural sciences and technology). 28(5), 1037-1047. (In Persian with English abstract)

مطالعات بسیاری به بررسی مدل‌های مختلف ریزمقیاس نمایی بر داده‌های دما در مناطق مختلف پرداختند که به دلیل داشتن ماهیت عدم قطعیت، نتایج مختلفی حاصل شده است. در این راستا میتوان به مطالعه (Asakereh and Motallebi-Zadeh, 2017) که به مدلسازی و پیش‌بینی بارش روزانه، دمای کمینه و بیشینه در منطقه شمال غرب ایران با استفاده از مدل‌های SDSM و LARS-WG, ANN پرداخته اند، اشاره داشت. آنان به این نتیجه رسیدند که مدل ANN در مدلسازی و ریزمقیاس نمایی دما بهتر از سایر مدل‌ها نتیجه گرفته است که این موضوع مهر تاییدی بر مطالعه حاضر زده است اما از سوی دیگر (Sobhani *et al.* (2017) به پیش‌بینی دمای حداقل در ایستگاه سینوپتیک ارومیه در استان ارومیه بر اساس مدل‌های SDSM و ANN پرداخته و نتیجه گرفته اند که مدل SDSM نتایجی نزدیک تر به واقعیت را ارائه داده است. همچنین بر اساس نتایج مطالعه حاضر، افزایش دما برای سال‌های آینده در این منطقه پیش‌بینی شده است که مطالعاتی از جمله (Etemadi *et al.*, 2016; Emami *et al.*, 2018; Farajzadeh *et al.*, 2015, Mirdashtvan *et al.*, 2018) نیز در مناطق مختلف ایران بر اساس سناریو‌های اجرا شده در این مطالعه افزایش دمای محسوس را در سال‌ها آینده پیش‌بینی کرده اند.

## نتیجه‌گیری

برای برنامه ریزی جهت توسعه در تمامی زمینه‌های مرتبط با آب و اقلیم، همواره داشتن یک نگرش به آینده

## منابع

Asakare, H., 2017. Comparing the performance of the SDSM models and those based on artificial neural networks in predicting the changes in minimum temperatures (station in case: urmia). The Journal of Spatial Planning. 21(4), 140-160. (In Persian with English abstract).

- Dehghani, N., Ghasemieh, H., Sadatnejad, S.J., Ghorbani, Kh. and Besalatpour, A.A., 2017. Comparative comparison of data mining models in downscaling rainfall and temperature (Case Study: Bazoft-e- Samsami Watershed). *Journal of Water and Soil Conservation*. 24(5), 227-240. (In Persian with English abstract)
- Dibike, Y.B. and Coulibaly, P., 2007. Validation of hydrological models for climate scenario simulation: the case of Saguenay watershed in Quebec. *Hydrological Processes: An International Journal*. 21(23), 3123-3135.
- Etemadi, H., Samadi, S.Z., Sharifkia, M. and Smoak, J.M., 2016. Assessment of climate change downscaling and non-stationarity on the spatial pattern of a mangrove ecosystem in an arid coastal region of southern Iran. *Theoretical and Applied Climatology*. 126(1-2), 35-49.
- Emami, F. and Koch, M., 2018. Evaluation of statistical-downscaling/bias-correction methods to predict hydrologic responses to climate change in the zarrine river basin, Iran. *Climate*. 6(2), 30.
- Farajzadeh, M., Oji, R., Cannon, A.J., Ghavidel, Y. and Bavani, A.M., 2015. An evaluation of single-site statistical downscaling techniques in terms of indices of climate extremes for the Midwest of Iran. *Theoretical and Applied Climatology*. 120(1-2), 377-390.
- Grotch, S.L. and MacCracken, M.C., 1991. The use of general circulation models to predict regional climatic change. *Journal of Climate*. 4(3), pp.286-303.
- Hewitson, B.C. and Crane, R.G., 1994. Precipitation controls in southern Mexico. In *Neural Nets: Applications in Geography*. 121-143.
- Hewitson, B.C. and Crane, R.G. eds., 1994. Neural nets: applications in geography: applications for geography. Springer Science & Business Media. (Vol. 29).
- Hellström, C., Chen, D., Achberger, C. and Räisänen, J., 2001. Comparison of climate change scenarios for Sweden based on statistical and dynamical downscaling of monthly precipitation. *Climate Research*. 19(1), 45-55.
- Hornik, K., 1991. Approximation capabilities of multilayer feedforward networks. *Neural Networks*. 4(2), 251-257.
- Jahangir, M.H., Noorazar, L. and Azimi, E., 2019. Analyzing time series of SPI, SPEI and SPTI drought indices by using artificial neural network SOFM method and numerical comparison in chaharmahal va bakhtiari. *Iranian Journal of Ecohydrology*. 6(3), 837-847. (In Persian with English abstract).
- Johnson, M.S., Coon, W.F., Mehta, V.K., Steenhuis, T.S., Brooks, E.S. and Boll, J., 2003. Application of two hydrologic models with different runoff mechanisms to a hillslope dominated watershed in the northeastern US: a comparison of HSPF and SMR. *Journal of hydrology*. 284(1-4), 57-76.
- Kundu, S., Khare, D. and Mondal, A., 2017. Future changes in rainfall, temperature and reference evapotranspiration in the central India by least square support vector machine. *Geoscience Frontiers*. 8(3), pp.583-596.
- Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S.L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M.I. and Huang, M., 2021. Climate change 2021: the physical science basis. Contribution of working group I to the sixth assessment report of the intergovernmental panel on climate change. p.2.
- Mearns, L.O., Giorgi, F., Whetton, P., Pabon, D.,

- Hulme, M. and Lal, M., 2003. Guidelines for use of climate scenarios developed from regional climate model experiments. Data Distribution Centre of the Intergovernmental Panel on Climate Change. p.38.
- Mirdashtvan, M., Najafinejad, A., Malekian, A. and Sa'doddin, A.J.M.A., 2018. Downscaling the contribution to uncertainty in climate-change assessments: representative concentration pathway (RCP) scenarios for the south alborz range, Iran. Meteorological Applications. 25(3), 414-422.
- Mellit, A., Pavan, A.M. and Benghanem, M., 2013. Least squares support vector machine for short-term prediction of meteorological time series. Theoretical and Applied Climatology. 111(1-2), 297-307.
- Murphy, J., 1999. An evaluation of statistical and dynamical techniques for downscaling local climate. Journal of Climate. 12(8), 2256-2284.
- Nash, JE, and Sutcliffe, JV., 1970. River flow forecasting through conceptual models part I—A discussion of principles. Journal of hydrology. 10(3), 282-90.
- Omidvar, E., Rezaei, M. and Pirnia, A., 2019. Performance Evaluation of Artificial Neural Network Models for Downscaling and Predicting of Climate Variables. Journal of Watershed Management Research. 9(18), pp.80-90. (In Persian with English abstract)
- Rezaee, M., Nahtaj, M., Moghadamniya, A. and Abkar, A., 2015. Comparison of artificial neural network and SDSM methods in the downscaling of annual rainfall in the HadCM3 modelling (case study: Kerman, Ravar and Rabor). Water Resources Engineering. 8(24), pp.25-40. (In Persian with English abstract)
- Sailor, D.J., Hu, T., Li, X. and Rosen, J.N., 2000. A neural network approach to local downscaling of GCM output for assessing wind power implications of climate change. Renewable Energy. 19(3), 359-378.
- Schoof, J.T. and Pryor, S.C., 2001. Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks. International Journal of Climatology: A Journal of the Royal Meteorological Society. 21(7), 773-790.
- Suykens, J.A. and Vandewalle, J., 1999. Least squares support vector machine classifiers. Neural processing letters. 9(3), 293-300.
- Suykens, J.A., 2001, May. Nonlinear modelling and support vector machines. In IMTC 2001. Proceedings of the 18th IEEE instrumentation and measurement technology conference. Rediscovering measurement in the age of informatics (Cat. No. 01CH 37188) (1, 287-294).
- Suykens, J.A., De Brabanter, J., Lukas, L. and Vandewalle, J., 2002. Weighted least squares support vector machines: robustness and sparse approximation. Neurocomputing. 48(1-4), 85-105.
- Sobhani, B., Eslahi, M., Babaeian, 2017. Comparison of statistical downscaling in climate change models to simulate climate elements in Northwest Iran. Physical Geography Research Quarterly. 49, 301-325. (In Persian with English abstract)
- Teegavarapu, R.S. and Goly, A., 2018. Optimal selection of predictor variables in statistical downscaling models of precipitation. Water resources management. 32(6), 1969-1992.
- Wilby, R.L., Dawson, C.W. and Barrow, E.M., 2002. SDSM—a decision support tool for the assessment of regional climate change impacts. Environmental Modelling & Software. 17(2), 145-157.

Zhang, B. and Govindaraju, R.S., 2000. Prediction of watershed runoff using Bayesian concepts and modular neural networks. Water Resources Research. 36(3), 753-762





Environmental Sciences Vol.20 / No.4 / Winter 2023

243-258

Original Article

## Evaluating the performance of artificial intelligence models for temperature downscaling (Study area: Ardabil province)

Mohammad Hossein Jahangir\* and Seyed Mohammad Ehsan Azimi

Department of Renewable Energies and Environment, Faculty of New Sciences and Technologies, University of Tehran, Tehran, Iran

Received: 2020.08.31 Accepted: 2022.10.22

**Jahangir, M.H. and Azimi, S.M.E., 2023.** Evaluating the performance of artificial intelligence models for temperature downscaling (Study area: Ardabil province). Environmental Sciences. 20(4): 243-258.

**Introduction:** Long and short term weather forecasting have been as two of the most important challenges to water and climate researchers. In order to overcome this challenge, several tools, including atmospheric-ocean general circulation model forecasting scenarios, and downscaling models have been developed and used. These tools downscale forecasting scenarios by creating relationship between parameters of synoptic stations and Large-scale data of general circulation models.

**Material and methods:** In this study large-scale predictor parameters from 1961 to 2003 from the database of National Centers for Environmental Prediction (NCEP), large-scale data for the A1B and A2 forecast scenarios of the HadCM3 model from 2001 to 2100 from the Canadian Centre for Climate Modelling and Analysis (CCCMA), and the meteorological synoptic data of Ardabil stations from the Meteorological Organization were gathered. To this end, three downscaling models such as Statistical Downscaling Model (SDSM), least squares support vector machine (LS-SVM) and multi-layer perceptron (MLP) were determined for downscaling; and correlation coefficient (CC), Mean Squared Error (MSE), Root Mean Square Error (RMSE), Normalized mean square error (NMSE), Nash-Sutcliffe, Mean Absolute Error (MAE), and Taylor diagram were used to evaluate the efficiency of the models.

**Results and discussion:** The results showed that the MLP obtained the best results based on the average of the stations with the values of (CC=0.85), (NMSE=0.63), (NSH=0.73) and (MAE=0.52), and LS-SVM and SDSM are ranked second and third, respectively. Taylor's diagram also identified the SDSM as the weakest and the LS-SVM and MLP as superior models with a slight difference. Based on downscaling results of all forecasting scenarios, an increase in average daily temperature is also predicted by 2100 in all studied stations.

\* Corresponding Author: Email Address. mh.jahangir@ut.ac.ir

**Conclusion:** Based on the results of the study, all forecasting scenarios and all methods of downscaling show increasing the daily average temperature by 2100. Hence, it is necessary to be taken this issue account for making environmental and developing policies in this area.

**Keywords:** MLP, LS-SVM, SDSM, Downscaling, Average daily temperature, Climate change scenarios, Ardabil province.