

Estimation of Prediction Interval in ANN-Based GCM Downscaling

E. Sharghi^{1*}, V. Nourani², and N. Jabbarian Paknezhad³

Abstract

In this paper, point prediction and prediction intervals (PIs) of artificial neural network (ANN) based downscaling for mean monthly precipitation and temperature of two stations (Tabriz and Ardabil in North West of Iran) were evaluated using general circulation models (GCMs). PIs were constructed by novel Upper Lower Bound Estimation (LUBE) method in which an ANN with two outputs was constructed for estimating the prediction bounds. Also, Bootstrap method as a classic technique for assessing uncertainty of ANN was used to further examine the proposed LUBE method. In this way, the accuracy of PIs was quantified by coverage and width criteria. Three GCMs, Can-ESM2, BNU-ESM, INM-CM4 and ensemble-GCM (ensemble of mentioned models) were used in four grid points around each of station for evaluating ANN-based downscaling of precipitation and temperature parameters. Comparison between the results of two methods indicated that LUBE method could lead to more reliable results than the Bootstrap method. PIs width and coverage probability were 10% to 40% lower and 2% to 10% higher than the Bootstrap method for different GCMs, respectively. Ensemble-GCM led to more accurate results so that computed PIs width and coverage probability were 10% to 60% lower and 2% to 20% higher than those for the single GCMs.

Keywords: General Circulation Models; Downscaling; Prediction Interval; Artificial Neural Network.

Received: May 13, 2019

Accepted: July 26, 2019

تخمین فواصل پیش‌بینی در ریزمقیاس‌نمایی مدل گردش عمومی بر پایه شبکه عصبی

الناز شرقی^{۱*}، وحید نورانی^۲ و ناردین جباریان پاک‌نژاد^۳

چکیده

در این مطالعه پیش‌بینی نقطه‌ای و فواصل پیش‌بینی ریزمقیاس‌نمایی مدل‌های گردش عمومی (GCM) با استفاده از شبکه عصبی مصنوعی، برای بارش ماهانه و میانگین دمای ماهانه دو ایستگاه (تبریز و اردبیل در شمال غربی ایران) مورد ارزیابی قرار گرفته است. فواصل پیش‌بینی به وسیله روش جدید حد بالا و پایین (LUBE) محاسبه می‌شوند، که در آن شبکه عصبی با دو خروجی برای تخمین حدود پیش‌بینی ساخته شده است. همچنین روش کلاسیک بوت‌استرپ، روشی برای ارزیابی عدم قطعیت پیش‌بینی مورد استفاده قرار گرفته و نتایج حاصل از دو روش مقایسه شده است. بنابراین دقت فواصل پیش‌بینی به وسیله دو معیار همگرایی فواصل پیش‌بینی و عرض فواصل کمیت‌سنجی شده است. سه GCM، BNU-ESM، INM-CM4، Can-ESM2 و ترکیب آنها در این مطالعه استفاده شده است. چهار نقطه‌ی شبکه بر روی هر یک از دو ایستگاه تبریز و اردبیل در شمال غربی ایران، برای ارزیابی فواصل پیش‌بینی ریزمقیاس‌نمایی بارش ماهانه و دما در نظر گرفته شده است. مقایسه بین نتایج دو مدل نشان داده است که روش LUBE، قابلیت اطمینان بیشتری نسبت به بوت‌استرپ دارد. عرض فواصل پیش‌بینی و احتمال همگرایی، به ترتیب ۱۰٪ تا ۴۰٪ کمتر و ۲٪ تا ۱۰٪ بیشتر از روش بوت‌استرپ برای GCM بوده است. ترکیب GCMها به نتایج دقیق‌تری منجر شده است و عرض فواصل پیش‌بینی و احتمال همگرایی، به ترتیب ۱۰٪ تا ۶۰٪ کمتر و ۲٪ تا ۲۰٪ بیشتر از مدل‌های تکی GCM بوده است.

کلمات کلیدی: مدل گردش عمومی؛ ریزمقیاس‌نمایی؛ فواصل پیش‌بینی؛ شبکه عصبی مصنوعی.

تاریخ دریافت مقاله: ۹۸/۲/۲۳

تاریخ پذیرش مقاله: ۹۸/۵/۴

1- Assistant Professor, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. E-mail: sharghi@tabrizu.ac.ir

2- Professor, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. E-mail: nourani@tabrizu.ac.ir

3- M.Sc. Student in Water Resource Engineering, Department of Water Resources Engineering, Faculty of Civil Eng., University of Tabriz, Tabriz, Iran.

*- Corresponding Author

۱- استادیار گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

۲- استاد گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

۳- دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۳۹۹ امکانپذیر است.

همچنین قابلیت شبیه‌سازی غیرخطی و خصوصیات تغییرکننده با زمان برای متغیرهای اتمسفر، در مقیاس‌های مختلف را دارند که منجر به کاربردهای متعدد و موفق ANN در مورد ریزمقیاس‌نمایی می‌شود (Wilby and Wigley, 1997; Liu et al., 2019).

اگرچه استفاده از ANN در ریزمقیاس‌نمایی آماری کاربرد وسیعی دارد، پیش‌بینی نقطه‌ای ANN هیچ اطلاعاتی درباره‌ی خطای مدل‌سازی، دقت پیش‌بینی و عدم قطعیت مدل بیان نمی‌کند. به همین دلیل برخی مطالعات عدم قطعیت و قابلیت اطمینان ریزمقیاس‌نمایی مبتنی بر ANN را با استفاده از فواصل اطمینان مورد ارزیابی قرار دادند (Samadi et al., 2013). فواصل پیش‌بینی^۲ (PI) گسترده‌تر از فواصل اطمینان بوده و منابع عدم قطعیت بیشتری را شامل می‌شود. چندین روش کلاسیک برای ساختن فواصل پیش‌بینی مبتنی بر ANN وجود دارد مانند روش دلتا، بایاسین، و روش بوت استرپ. روش دلتا بر اساس ارائه و تفسیر ANN به عنوان مدل رگرسیون غیرخطی و بکارگیری تئوری تقریبی استاندارد برای ساخت PI است (Chryssoulouris et al., 1996). در این روش فواصل بر فرض این که خطا همگن بوده و از توزیع نرمال پیروی می‌کند، ساخته می‌شود که محدودیت روش دلتا در نظر گرفته می‌شود. روش بایاسین بر اساس آمار بایاسین، برای بیان عدم قطعیت وزن‌های شبکه در ترم توزیع احتمال و ادغام آنها برای بدست آوردن توزیع احتمال خروجی ANN است (Mackey, 1992). روش بایاسین نیازمند انتگرال مونت کارلو بر روی فضای وزن‌ها است، بنابراین برای کاربرد چندبعدی دنیای واقعی نامناسب است. روش بوت استرپ از جمله روش‌های ساده و رایج برای ساخت PI است که برخلاف روش‌های قبلی هیچ فرضی برای توزیع احتمالاتی داده‌ها نیاز ندارد (Efron and Tibshirani, 1993).

در این مطالعه، روش تخمین حد بالا و پایین (LUBE) که اولین بار توسط Khosravi et al. (2010) پیشنهاد شده است و روش نوین برای ساخت PI در زمینه هیدروکیلماتولوژی است، استفاده شده است. برای ساخت PI ریزمقیاس‌نمایی مبتنی بر ANN برای پارامترهای بارش و دمای ماهانه دو ایستگاه تبریز و اردبیل که در شمال غربی ایران واقع شده اند، بکاررفته است. در این روش ANN با دو نرون خروجی که نشان دهنده حد بالا و پایین هستند، آموزش داده می‌شود. احتمال همگرایی روش LUBE بهتر از سایر روش‌ها می‌باشد و بطور موثر قادر به ایجاد توازن بین صحت و شرح دقت برای PI است (Khosravi et al., 2011). به‌علاوه زمان لازم برای ساخت PI، بطور قابل ملاحظه‌ای کوچکتر از سایر روش‌های ساخت PI است (Quan et al., 2014).

مدل‌های گردش عمومی (GCM) به عنوان مدل‌های اقلیم برای پیش‌بینی آب و هوا، فهم اقلیم و پیش‌بینی تغییر اقلیم استفاده می‌شود. GCMها به صورت پیش فرض با اندازه‌های مختلف توسط هر مؤسسه برای هر مدل گردیدندی شده است و هر مؤسسه گردیدندی مشخصی برای مدل‌های ایجاد شده خود دارد در مطالعات متعددی از GCM برای بررسی تأثیر تغییر اقلیم در پارامترهای آب و هوایی استفاده شده است (Kaboosi and Kordjazi, 2017; Farahani et al., 2018; Shiravand and Dostkamiyan, 2019; Afzali-Gorouh et al., 2019; Her et al., 2019).

با وجود این که GCMها داده‌های اتمسفری قابل اطمینان تولید می‌کنند، بزرگ بودن مقیاس مکانی آنها باعث عملکرد ضعیف در مقیاس محلی به عنوان داده ورودی می‌شود. بنابراین رویکرد متناسب ریزمقیاس‌نمایی برای دسترسی به داده‌های آب و هوا در مقیاس محلی از GCMهای بزرگ مقیاس لازم است.

دو روش ریزمقیاس‌نمایی دینامیکی و آماری وجود دارد. ریزمقیاس‌نمایی دینامیکی، روشی برای کوچکتر کردن مقیاس اطلاعات اقلیم بر روی یک ناحیه مرزبندی شده بوسیله مدل‌های محلی مشتق شده از GCM با دقت بالا و شرایط مرزی است. ریزمقیاس‌نمایی آماری، شامل نسبت دادن ویژگی‌های اقلیمی بزرگ مقیاس به داده‌های اقلیمی محلی است (Wilby and Wigley, 1997). بنابراین، خصوصیت‌های فیزیکی ناحیه مطالعه می‌تواند در ریز مقیاس‌نمایی و استخراج الگوی آماری بین پیش‌بینی کننده‌ها و پیش‌بینی شونده‌ها که نشانگر مدل جعبه سیاه است، وارد شوند. با وجود وضوح بالای خروجی ریزمقیاس‌نمایی دینامیکی، روش‌های محاسباتی گسترده، استفاده از الگوهای فیزیکی برای تولید داده اقلیم‌های محلی، نیاز به حجم بالای داده، سطح بالای تجربه و تخصص برای تفسیر نتایج، کاربرد ریزمقیاس‌نمایی دینامیکی را محدود می‌کند (Danandeh Mehr and Kahya, 2016). اما در روش ریزمقیاس‌نمایی آماری هدف پیدا کردن رابطه بین GCM و داده‌های آب و هوایی محلی، بدون نیاز به هیچ اطلاعاتی در مورد فیزیک ناحیه است. بنابراین، به دلیل راحتی تفسیر نتایج روش ریزمقیاس‌نمایی آماری در برخی مطالعات از این روش استفاده شده است (Sailor and Li, 1999; Beecham et al., 2014). فرض اصلی ریزمقیاس‌نمایی آماری ایجاد رابطه بین پیش‌بینی‌کننده‌ها و پیش‌بینی شونده‌ها است. شبکه عصبی مصنوعی (ANN)^۱ کاربرد گسترده‌ای در بین روش‌های ریزمقیاس‌نمایی آماری دارد. این روش پتانسیل بالایی برای استخراج الگوهای پیچیده از بین پیش‌بینی‌کننده‌ها و پیش‌بینی شونده‌ها و

اگرچه در برخی مطالعات روش‌های مختلف برای ساخت PI برای ANN در مدل‌سازی هیدرولوژیکی استفاده شده است (مثلاً Srivastav et al., 2007; Kasiviswanathan and Sudheer, 2016) لیکن، در این مطالعه برای اولین بار روش نوین LUBE در زمینه هیدروکلماتولوژیکی و مدل‌سازی PI برای ریزمقیاس‌نمایی مبتنی بر ANN انجام گرفته است. اهداف اصلی که در این مطالعه در نظر گرفته شده است، ریزمقیاس‌نمایی آماری GCM با استفاده از ANN بوده است که پیش‌بینی‌کننده‌های مؤثر با معیار اطلاعات مشترک انتخاب شده و در بخش ۲-۳-۲ و ۱-۳-۲ به آن اشاره شده است. همچنین فواصل پیش‌بینی ریزمقیاس‌نمایی مبتنی بر ANN با استفاده از روش LUBE و بوت استرپ محاسبه شده‌اند و در بخش ۲-۳-۲ و ۴-۳-۲ آورده شده‌اند. به‌علاوه، فواصل پیش‌بینی ایجاد شده با دو معیار همگرایی و عرض فواصل پیش‌بینی مورد ارزیابی قرار گرفته است و در بخش ۳-۳-۲ توضیح داده شده است.

۲-۲- داده‌های استفاده شده

برای تبدیل داده‌های با مقیاس بزرگ به مقیاس محلی، داده‌های مشاهداتی بارش و دمای ماهانه میانگین از سازمان هواشناسی ایران برای دوره‌های ۲۰۱۲-۱۹۵۱ و ۲۰۱۲-۱۹۷۶ به ترتیب برای تبریز و اردبیل گرفته شده است.

داده‌های GCM برای آموزش از مجموعه داده‌های پنج‌مین گزارش ارزیابی IPCC (CMIP5) از سایت (<http://cera-www.dkrz.de>) گرفته شده‌اند.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

در این مطالعه، مدل‌سازی بر روی داده‌های دو ایستگاه (تبریز و اردبیل) برای مقایسه عملکرد روش پیشنهادی بر روی مناطق مطالعاتی متفاوت انجام شده است. تبریز با طول جغرافیایی $46^{\circ} 29' E$ و عرض جغرافیایی $38^{\circ} 08' N$ و ارتفاع 1364 متر و اردبیل با طول جغرافیایی



Fig. 1- Case study map and grid points around two stations

شکل ۱- نقشه منطقه مورد مطالعه و نقاط شبکه اطراف دو ایستگاه

با توجه به مطالعاتی که قبلاً برای GCM در این منطقه انجام گرفته و GCM های مختلف مورد ارزیابی قرار گرفته است (Nourani et al., 2018; Hosseini Baghanam et al., 2018). تحقیقات مختلفی کاربردی رویکرد غربالگری داده‌ها در افزایش تأثیر مدل‌های مبتنی بر داده را اثبات کرده است (Nourani et al., 2018; Hosseini Baghanam et al., 2018). در این مطالعه از روش غیرخطی MI برای انتخاب ورودی‌های مؤثر از بین داده‌های کاندیدای ورودی برای GCM های مختلف در ایستگاه‌های مطالعاتی برای ریزمقیاس‌نمایی مبتنی بر ANN استفاده شده است. از آنجا که در مدل‌سازی فرایند غیرخطی با مدل غیرخطی، امکان رابطه ضعیف خطی بین ورودی و خروجی اما رابطه قوی غیرخطی بین ورودی و خروجی وجود دارد. بنابراین پیشنهاد می‌شود تا از معیارهای غیرخطی برای مدل‌سازی غیرخطی ANN استفاده شود (Nourani et al., 2015). آنتروپی یا تئوری اطلاعات معیار آماری میزان تصادفی و عدم قطعیت در ترم توزیع احتمال است. MI بین دو متغیر تصادفی X و Y به صورت (۱) تعریف می‌شود (Yang et al., 2000):

$$MI(X,Y)=H(X)+H(Y)-H(X,Y) \quad (1)$$

که H(X) و H(Y) به ترتیب، آنتروپی X و Y هستند.

آنتروپی شانون برای متغیر تصادفی X با طول n و مقادیر (X_1, X_2, \dots, X_n) و احتمال‌های متناظر (P_1, P_2, \dots, P_n) به صورت زیر محاسبه می‌شود (Shannon, 1984):

$$H(x)=-\sum_{i=1}^n P(X_i) \log [P(X_i)] \quad (2)$$

و در رابطه (۱) $H(X,Y)$ ، آنتروپی مشترک X و Y است که به صورت زیر محاسبه می‌شود (Gao et al., 2008):

$$H(X,Y)=-\sum_{i=1}^n \sum_{j=1}^n p(X_i, Y_j) \log [P(X_i, Y_j)] \quad (3)$$

با توجه به مطالعاتی که قبلاً برای GCM در این منطقه انجام گرفته و GCM های مختلف مورد ارزیابی قرار گرفته است (Nourani et al., 2018; Hosseini Baghanam et al., 2018). تحقیقات مختلفی کاربردی رویکرد غربالگری داده‌ها در افزایش تأثیر مدل‌های مبتنی بر داده را اثبات کرده است (Nourani et al., 2018; Hosseini Baghanam et al., 2018). در این مطالعه از روش غیرخطی MI برای انتخاب ورودی‌های مؤثر از بین داده‌های کاندیدای ورودی برای GCM های مختلف در ایستگاه‌های مطالعاتی برای ریزمقیاس‌نمایی مبتنی بر ANN استفاده شده است. از آنجا که در مدل‌سازی فرایند غیرخطی با مدل غیرخطی، امکان رابطه ضعیف خطی بین ورودی و خروجی اما رابطه قوی غیرخطی بین ورودی و خروجی وجود دارد. بنابراین پیشنهاد می‌شود تا از معیارهای غیرخطی برای مدل‌سازی غیرخطی ANN استفاده شود (Nourani et al., 2015). آنتروپی یا تئوری اطلاعات معیار آماری میزان تصادفی و عدم قطعیت در ترم توزیع احتمال است. MI بین دو متغیر تصادفی X و Y به صورت (۱) تعریف می‌شود (Yang et al., 2000):

۳-۲- روش تحقیق

۳-۲-۱- انتخاب ورودی‌های مؤثر

تعداد زیاد داده‌ها، انتخاب مؤثر GCM ها و همچنین نقاط شبکه

Table 1- Used GCMs
جدول ۱- GCM های استفاده شده

| Centre | Centre Acronym | Model | Grid size | Applied climate variables in GCMs | Pressure levels |
|---|----------------|----------|--------------------------------|--|---|
| Beijing Normal University, China | BNU | BNU-ESM2 | $2.81^\circ \times 2.81^\circ$ | P_{ua} : eastward wind; P_{va} : northward wind; P_{zg} : geopotential height; P_{hur} : relative humidity; P_{hus} : specific humidity; tas: air temperature; | 100; 200; 300; 500; 700; 1,000; 2,000; 3,000; |
| Canadian Centre for Climate Modelling and analysis, Canada | CCCma | Can-ESM2 | $2.81^\circ \times 2.81^\circ$ | uas: eastward near-surface wind; vas: northward near-surface wind; psl: air pressure at sea level; hfls: surface upward latent heat flux; prc: convective precipitation flux; pr: precipitation flux; hurs: near-surface relative humidity; huss: near-surface specific humidity; evpsbl: water evaporation flux | 5,000; 7,000; 10,000; 15,000; 20,000; 25,000; 30,000; 40,000; 50,000; 60,000; 70,000; |
| Russian Academy of Sciences, Institute of Numerical Mathematics, Russia | INM | INM-CM4 | $1.5^\circ \times 2^\circ$ | | 85,000; 92,500; 100,000 |

P: variables, which vary at pressure levels

۲-۳-۳-۲- ریزمقیاس‌نمایی آماری مبتنی بر شبکه عصبی مصنوعی (ANN)

هدف اصلی ریزمقیاس‌نمایی، محلی‌سازی مقیاس با استفاده از ایستگاه‌های محلی و تبدیل مقیاس‌های بزرگ به مقیاس‌های محلی می‌باشد. ANN کاربرد زیادی در ریزمقیاس‌نمایی مسائل هیدروکلیماتولوژیکی دارد و بدون هیچ اطلاعاتی درباره‌ی فیزیک ناحیه به ایجاد ارتباط بین پیش‌بینی‌کننده‌ها و پارامترهای مورد نظر برای پیش‌بینی می‌پردازد. به صورت شبکه به هم پیوسته نرون‌ها توصیف می‌شود. ساختار رایج ANN شامل سه لایه است. اولین لایه که پارامترهای ورودی متصل است لایه ورودی است و لایه آخر مربوط به پارامترهای خروجی است لایه خروجی نامیده می‌شود. لایه بین ورودی و خروجی، لایه‌های پنهان است که می‌تواند بیشتر از یک لایه باشد. نرون‌هایی که لایه‌ها را به هم وصل می‌کنند دارای وزن هستند مجموعه بهینه وزن‌ها در فرایند آموزش تعیین می‌شوند.

۲-۳-۳-۳- معیارهای ارزیابی

۱-۳-۳-۳- ارزیابی پیش‌بینی نقطه‌ای

به منظور ارزیابی عملکرد ریزمقیاس‌نمایی و پیش‌بینی نقطه‌ای ANN معیار نش ساتکلیف^۴ (NSE) و مجذور خطای مربعات^۵ (RMSE) و ضریب همبستگی^۶ (CC) استفاده شده‌اند.

$$NSE = 1 - \frac{\sum_{i=1}^N (R_i - Z_i)^2}{\sum_{i=1}^N (R_i - \bar{R})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (R_i - Z_i)^2}{N}} \quad (5)$$

$$CC = \frac{\sum (R - \bar{R}) \cdot \sum (Z - \bar{Z})}{\sqrt{\sum (R - \bar{R})^2 \sum (Z - \bar{Z})^2}} \quad (6)$$

که R_i و Z_i به ترتیب پیش‌بینی‌کننده و پیش‌بینی شونده و R میانگین پیش‌بینی‌شونده و N تعداد کل مشاهدات است.

۲-۳-۳-۲- معیارهای ارزیابی PI

دو معیار ارزیابی کمی PI احتمال همگرایی فواصل پیش‌بینی (PICP) و عرض فواصل پیش‌بینی (MPIW)^۸ است. PICP درصدی از داده‌های مشاهداتی است که در بازه پیش‌بینی می‌افتد. هرچه عرض PI گسترده‌تر باشد، مقادیر مشاهداتی بیشتری را پوشش می‌دهد. اگر PICP به مقدار تعیین شده متناظر با سطح اطمینان نزدیکتر باشد، قابل اطمینان‌تر است (Khosravi et al., 2010; Kasiviswanathan and Sudheer, 2016):

$$PICP = \frac{1}{n} \sum_{i=1}^n c_i \quad (7)$$

$$L(X_i) < x_i < U(X_i) \rightarrow c_i = 1$$

$$\text{else} \rightarrow c_i = 0$$

عملاً، PI که بسیار گسترده است، هیچ اطلاعاتی درباره‌ی داده‌ها نمی‌دهند، به همین دلیل مقیاس دیگری نیاز است تا عرض PI را کمیت‌سنجی کند. میانگین عرض PI به صورت فرمول زیر تعریف می‌شود:

$$MPIW = \frac{1}{n} \sum_{i=1}^n L(X_i) - U(X_i) \quad (8)$$

که $L(X_i)$ و $U(X_i)$ به ترتیب حد بالا و پایین حدود پیش‌بینی متناظر با آیین نمونه است. اگر عرض داده‌های خروجی معلوم باشد، برای مقایسه PI می‌توان NMPIW را به صورت فرمول ۹ نرمال کرد:

$$NMPIW = MPIW/R \quad (9)$$

که R دامنه داده‌ها است. NMPIW، مقیاس بی‌بعدی است که نشان‌دهنده‌ی میزان باریک بودن PI است.

۲-۳-۳-۴- PI ساخته شده با استفاده از روش LUBE

ساختار ANN با دو خروجی برای تخمین حد بالا و پایین PI با روش LUBE در شکل ۲ نشان داده شده است. اولین خروجی متناظر با حد بالا و دومی نشان‌دهنده حد پایین است.




Fig. 2- ANN model for estimating upper and lower bounds of PIs (Quan et al., 2014)

شکل ۲- مدل ANN برای تخمین حد بالا و پایین PI (Quan et al., 2014)

منحصر برای هر زیرمجموعه به جای داده‌های اصلی عمل می‌کند (مراجعه شود به شکل ۳). این روش مجموعه جدیدی از نمونه‌ها را برای بیان مناسبی از میانگین و تغییرات نمونه داده‌های اصلی، که مستقل از هیچ اطلاعاتی درباره‌ی توزیع داده‌ها است ایجاد می‌کند. بوت استرپ رویکردی برای کمیت‌سنجی عدم قطعیت مرتبط با پیش‌بینی ANN است. از جمله فواید استفاده از روش بوت استرپ می‌توان به این مورد اشاره کرد که به هیچ فرضیاتی برای توزیع احتمال داده‌ها و یا توابع غیرخطی پیچیده نیاز ندارد.

اگر نمونه‌های تصادفی در روند بوت استرپ از داده‌های کلی در دسترس قرار گیرند، میانگین پیش‌بینی \hat{y}_{boot} به عنوان خروجی مدل متناظر با لامین ورودی x است. میانگین و واریانس خروجی‌ها این شبکه از معادله پیشرو برای محاسبه PI استفاده می‌شود:

$$\hat{y}_{boot}(x) = \frac{1}{B} \sum_{b=1}^B f(x_i; P_b) \quad (10)$$

$$\hat{\sigma}_{boot}^2(x) = \frac{1}{B-1} \sum_{b=1}^B (f(x_i; P_b) - \hat{y}_{boot}(x))^2 \quad (11)$$

که P_b نشان‌دهنده‌ی نمونه بدست آمده از لامین پارامتر بوت استرپ است و f نشان‌دهنده‌ی فرم تابعی مدل ANN است. برای ساخت PI پیش‌بینی برای مشاهدات آینده X با احتمال P در توزیع نرمال، با میانگین انحراف معیار مشخص، خواهیم داشت:

$$P(l < X < u) = P\left(\frac{l - \hat{y}_{boot}}{\hat{\sigma}_{boot}} < \frac{X - \hat{y}_{boot}}{\hat{\sigma}_{boot}} < \frac{u - \hat{y}_{boot}}{\hat{\sigma}_{boot}}\right) \quad (12)$$

که $Z = \frac{X - \hat{y}_{boot}}{\hat{\sigma}_{boot}}$ مقدار استاندارد X ، که از توزیع نرمال استاندارد تبعیت می‌کند (Grant and Leavenworth, 1972).

$$\frac{l - \hat{y}_{boot}}{\hat{\sigma}_{boot}} = -Z; \quad \frac{u - \hat{y}_{boot}}{\hat{\sigma}_{boot}} = Z \quad (13)$$

$$\text{Or } l = \hat{y}_{boot} - Z\hat{\sigma}_{boot}; \quad u = \hat{y}_{boot} + Z\hat{\sigma}_{boot}$$

مقادیر مختلف مطابق با Z و سطوح اطمینان مختلف در جدول ۲ نشان داده شده است.

در گام اول داده‌ها به دو دسته کالیبره و صحت‌سنجی تقسیم می‌شوند و سپس ANN با دو خروجی آموزش داده می‌شود. به عنوان حدس اولیه، می‌توان مقادیر خروجی را $\pm 5\%$ درصد مقادیر مشاهداتی برای آموزش ANN در نظر گرفته و وزن‌های متناظر پیدا شوند؛ سپس وزن‌ها به صورت تصادفی، حول حدس اولیه، برای تولید مجموعه وزن‌های جدید تغییر داده می‌شود. طبق گزارش Dhanesh and Sudhear (2010) وزن‌های ANN در محدوده $\pm 10\%$ درصد مقدار کالیبره، حساس هستند. بنابراین ANN‌های جدید با مجموعه متعددی از وزن‌های تغییر یافته شده (در محدوده $\pm 10\%$ درصد وزن‌های اولیه) ایجاد می‌شوند و ANN‌ها با این مجموعه وزن‌ها شبیه‌سازی می‌شوند تا مجموعه مختلف PI بدست آید. در این مطالعه، تعداد مجموعه وزن‌های تولید شده که بستگی به تعداد نرون‌های لایه میانی دارد، در محدوده ۷۰۰ تا ۱۲۰۰ در نظر گرفته شده است. مجموعه PI‌ای که منجر به بیشترین PICP و کمترین NMPIL می‌شود، سرانجام به عنوان نتیجه نهایی در نظر گرفته می‌شود. در ارزیابی شبکه، اول PICP بررسی می‌شود، اگر کمتر از مقدار سطح اطمینان در نظر گرفته شده باشند (در این مطالعه ۹۰٪) شبکه مورد نظر کنار گذاشته می‌شود. اگر PICP بیشتر یا مساوی مقدار تعیین‌شده سطح اطمینان باشد NMPIW با مقدار NMPIW که بهینه در نظر گرفته شده است مقایسه می‌شود، اگر کمتر بود با ANN جدید جایگزین می‌شود. این روند ادامه پیدا می‌کند تا همه شبکه‌ها بررسی شوند.

۲-۳-۵- روش بوت استرپ

روش بوت استرپ توسط Efron and Tibshirani (1994) پیشنهاد گردید که از باز نمونه‌گیری و جابه‌جایی داده‌ها و آموزش زیرمجموعه داده‌های کلی، برای تولید مدل متفاوت و آموزش شبکه به صورت




Fig. 3- Schematic of the Bootstrap method (Zio, 2006)

شکل ۳- شماتیک روش بوت استرپ (Zio, 2006)

در اطراف سایت مورد مطالعه پارامترهای غالب در سطوح فشار بالاست و رطوبت از منابع دور مثل دریای خزر در ارتفاع فشار بالا منتقل می‌شود. در مورد بارش ایستگاه اردبیل متغیرهای رطوبت از نقطه شبکه A3 و B6 مانند ua و uas بیشترین تاثیر را بر روی بارش می‌گذارند زیرا باد رطوبت را از طرف دریا به ایستگاه منتقل می‌کند. بنابراین، از متغیرهای انتخاب شده به عنوان ورودی مدل ANN استفاده شدند. با توجه به جدول ۳، پارامتر بارش (Pr) به عنوان پیش‌بینی‌کننده‌ی غالب در ریزمقیاس‌نمایی بارش انتخاب نشده است و پارامترهای مربوط به رطوبت تأثیر بیشتری در ریزمقیاس‌نمایی بارش داشته است که این نتایج با برخی مطالعات گذشته مطابقت دارد (Osman and Abdellatif, 2016; Liu et al., 2019).

به دلیل این که تابع فعال‌سازی ANN در بازه ۱- تا ۱ حساس است، داده‌ها نرمال شدند. به منظور کالیبره و صحت‌سنجی مدل، داده‌ها به دو قسمت تقسیم می‌شوند که ۷۵٪ از داده‌ها برای آموزش ANN و ۲۵٪ برای صحت‌سنجی هستند. داده‌های گذشته برای GCM تا سال ۲۰۰۵ موجود است، اما در بین GCM‌های استفاده شده در این مقاله، فقط داده‌های گذشته مدل Can-ESM2 تا سال ۲۰۱۲ موجود است که تحت عنوان داده (historical extension) در لینک <http://cera-www.dkrz.de> موجود می‌باشند. بنابراین در مدل‌های BNU-ESM و INM-CM4 برای ایستگاه تبریز، بازه داده‌های کالیبره و صحت‌سنجی، به ترتیب ۱۹۵۱-۱۹۹۱ و ۱۹۹۲-۲۰۰۵ و برای ایستگاه اردبیل، به ترتیب بازه ۱۹۷۶-۱۹۹۷ و ۲۰۰۵-۱۹۹۸ می‌باشد؛ اما در مدل CAN-ESM2 برای ایستگاه تبریز بازه داده‌های کالیبره و صحت‌سنجی، به ترتیب ۱۹۹۶-۱۹۵۱ و ۲۰۱۲-۱۹۹۷ و برای ایستگاه اردبیل ۲۰۰۳-۱۹۷۶ و ۲۰۱۲-۲۰۰۴ می‌باشد.

Table 2- values of Z for different PIs (Grant and Leavenworth, 1972)
جدول ۲- مقادیر Z برای فواصل پیش‌بینی مختلف (Grant and Leavenworth, 1972)

| PI | z |
|-----|------|
| 75% | 1.15 |
| 90% | 1.64 |
| 95% | 1.96 |
| 99% | 2.58 |

۳- نتایج و تحلیل نتایج

۳-۱- پیش‌بینی نقطه‌ای با روش ریزمقیاس‌نمایی مبتنی بر ANN

معیار MI بین مقادیر مشاهداتی بارش و دما و هر یک از پیش‌بینی‌کننده‌های اتمسفر از GCM (در سطح و ارتفاع مختلف اتمسفر) در ۶ نقطه شبکه اطراف هر ایستگاه محاسبه شدند و متغیرها با بیشترین محدوده MI برای ورودی ANN انتخاب شدند. نتایج پیش‌بینی‌کننده‌های انتخاب شده، در جدول ۳ نشان داده شده است. با توجه به جدول ۳، رطوبت نسبی (hur)، آنومالی باد به سمت شمال (va) و دمای هوا (ta) بیشترین مقادیر MI را در سه GCM با دما نشان دادند. پارامتر غالب انتخاب شده که در ایستگاه تبریز بیشترین اثر را می‌گذارد از نقطه شبکه A1 است (مانند hur). این به دلیل نزدیکی این نقطه شبکه به دریاچه ارومیه می‌باشد که رطوبت آن بر روی دما تأثیر می‌گذارد. پارامتر غالب دیگر، va است که تأثیر باد از کوه‌های سه‌پند را نشان می‌دهد. در ایستگاه اردبیل دما بیشتر از متغیرهای رطوبت مخصوصاً در نقطه شبکه A3 و B6 که در دریای خزر واقع شده‌اند، تأثیر می‌گیرد. همچنین برای بارش ایستگاه تبریز، hur و hus به دلیل اقلیم کوهستانی و خشک ناحیه تبریز و کمبود منابع رطوبت

Table 3- Selected dominant inputs by MI for different GCMs
جدول ۳- ورودی‌های غالب انتخاب شده به وسیله MI برای GCM‌های مختلف

| Model | Dominated inputs for precipitation modeling of Tabriz | Dominated inputs for precipitation modeling of Ardabil | Dominated inputs for temperature modeling of Tabriz | Dominated inputs for temperature modeling of Ardabil |
|----------|---|--|---|--|
| BNU-ESM | Hfls(A5) | Ua85000(A6) | va92500(A5) | hur100000(A6) |
| | zg3000(A2) | hus2000(A6) | va20000(A1) | hur10000(A3) |
| | uas(A2) | hus15000(A2) | hur7000(A1) | ta100000(A6) |
| | Hus10000(A4) | Hus5000(A3) | hur15000(A4) | zg70000(A6) |
| | ua1000(A5) | evspsbl(A5) | hur15000(A2) | zg3000(A2) |
| Can-ESM2 | Hus7000(A1) | Hus1000(A2) | Hur15000(A2) | Va70000(A4) |
| | hus10000(A5) | hur1000(A3) | va70000(A1) | hur10000(A2) |
| | hur700(A4) | tas(A2) | hur15000(A1) | va30000(A5) |
| | Evpspsbl(A4) | Uas(A3) | va92500(A5) | hfls(A6) |
| | hus7000(A4) | hus300(A3) | hur10000(A4) | hur7000(A6) |
| INM-CM4 | hus3000(B5) | Hus7000(B3) | Evpspsbl(B1) | hur10000(B2) |
| | Hur30000(B5) | hur1000(B3) | Evpspsbl(B2) | hur7000(B2) |
| | Hus7000(B5) | hur3000(B6) | hur15000(B1) | hfls(B3) |
| | zg3000(B1) | zg7000(B6) | va3000(B4) | va70000(B2) |
| | prc(B1) | Hus92500(B6) | va3000(B5) | ta50000(B3) |

Note: GCMs grid points are based on Fig. 1, (at A1, A2, ..., B1, B2, ...)

GCMها به عنوان ورودی شبکه دیگر برای ساخت ترکیب GCMها استفاده شده است (مراجعه به شکل ۴).

معیارهای RMSE، NSE و CC برای ارزیابی عملکرد مدل سازی محاسبه شدند و نتایج حاصل از پیش بینی نقطه ای در جدول ۴ نشان داده شده است. همانطور که در جدول ۴ نشان داده شده است، ترکیب GCMها عملکرد بهتری در هر دو ایستگاه و برای هر دو پارامتر نسبت به مدل های GCM تکی داشت. NSE برای داده های صحت سنجی، ترکیب GCMها تا ۱۱٪ بیشتر از GCMهای تکی بود.

برای ریزمقیاس نمایی بارش و دما در دو ایستگاه از ANN پیشرو^۹ با سه لایه و الگوریتم پس انتشار^{۱۰} لونیگ مارکوویت^{۱۱} با تابع فعال تانزانت سیگموئید استفاده شده است. برای تشخیص ساختار بهینه ANN، تعداد تکرار و نرون های مخفی با آزمون و خطا تعیین شدند. بهترین تعداد تکرار برای GCMها تقریباً در حدود ۳۲۰ تا ۳۶۰ و ۴-۸ نرون مخفی برای دو ایستگاه بود که در جدول ۴ نشان داده شده است. با توجه به مطالعات قبلی (Feng et al., 2011) استفاده از ترکیب GCMها باعث افزایش دقت ریزمقیاس نمایی می شود. بنابراین، برای بهبود نتایج ریزمقیاس نمایی مبتنی بر ANN، ترکیب خروجی

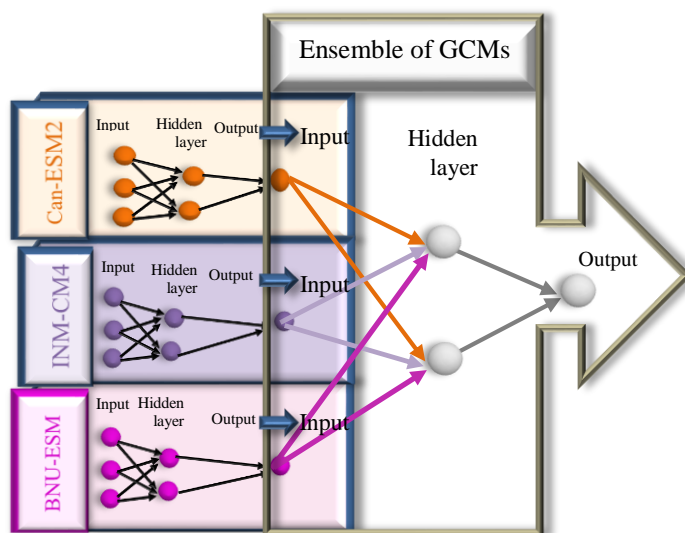


Fig. 4- Schematic of the GCMs ensemble model
شکل ۴- شماتیک ترکیب مدل های GCM

Table 4- Point prediction results for two stations
جدول ۴- نتایج پیش بینی نقطه ای در دو ایستگاه


| Parameter | Station | Model | NSE train | NSE verification | CC train | CC verification | RMSE* train | RMSE* verification | Epoch number | Hidden Neurons number | |
|---------------|---------|---------------|---------------|------------------|----------|-----------------|-------------|--------------------|--------------|-----------------------|---|
| precipitation | Tabriz | Can-ESM2 | 0.3 | 0.29 | 0.55 | 0.54 | 0.03 | 0.03 | 200 | 3 | |
| | | BNU-ESM | 0.36 | 0.33 | 0.55 | 0.6 | 0.1 | 0.08 | 140 | 6 | |
| | | INM-CM4 | 0.32 | 0.29 | 0.57 | 0.57 | 0.15 | 0.2 | 100 | 4 | |
| | Ardabil | Ensemble-GCMs | 0.49 | 0.47 | 0.7 | 0.71 | 0.11 | 0.09 | 130 | 4 | |
| | | Can-ESM2 | 0.26 | 0.2 | 0.42 | 0.62 | 0.5 | 0.64 | 140 | 2 | |
| | | BNU-ESM | 0.37 | 0.36 | 0.55 | 0.38 | 0.3 | 0.42 | 160 | 3 | |
| Temperature | Tabriz | Can-ESM2 | 0.3 | 0.29 | 0.55 | 0.54 | 0.45 | 0.41 | 150 | 8 | |
| | | Ensemble-GCMs | 0.36 | 0.33 | 0.55 | 0.6 | 0.1 | 0.08 | 240 | 3 | |
| | | Can-ESM2 | 0.77 | 0.69 | 0.88 | 0.83 | 0.11 | 0.12 | 280 | 9 | |
| | Ardabil | BNU-ESM | 0.78 | 0.73 | 0.88 | 0.86 | 0.07 | 0.07 | 240 | 5 | |
| | | INM-CM4 | 0.8 | 0.63 | 0.89 | 0.81 | 0.07 | 0.1 | 310 | 11 | |
| | | Ensemble-GCMs | 0.89 | 0.74 | 0.94 | 0.87 | 0.07 | 0.11 | 200 | 3 | |
| | | Can-ESM2 | 0.93 | 0.63 | 0.96 | 0.86 | 0.06 | 0.09 | 320 | 12 | |
| | | BNU-ESM | 0.84 | 0.81 | 0.91 | 0.91 | 0.12 | 0.13 | 160 | 4 | |
| | | INM-CM4 | 0.90 | 0.87 | 0.94 | 0.91 | 0.09 | 0.1 | 230 | 4 | |
| | | | Ensemble-GCMs | 0.97 | 0.82 | 0.97 | 0.82 | 0.04 | 0.08 | 140 | 4 |

*implies normalized RMSE values


برای داده‌های صحت‌سنجی برای پیش بینی نقطه‌ای و PI در شکل ۵ و ۶ نشان داده شده است.

همانطور که در شکل‌های ۵ و ۶ نشان داده شده است، دما در هر دو ایستگاه بیش برآورد شده است و هم چنین بارش در ایستگاه اردبیل کم برآورد شده است. وجود خطا در نتایج حاصل از مدل‌های CMIP5 و دقت کم آنها ممکن ناشی از منابع مختلف خطا باشد. خطا در فیزیک و دینامیک مدل، روش حل عددی، پارامتره کردن از جمله این خطاها می‌باشد. در این ارتباط، برخی محققان دریافته‌اند که مدل‌های CMIP5 تمایل به کم برآورد کردن پوشش ابر و بخار هوای استراتوسفریک دارند (Fyfe et al., 2013; Nam et al., 2012) که هر دو باعث می‌شود که نور خورشید بیشتری وارد زمین شده و زمین را در طول فرایند شبیه‌سازی گرم کند و اثر کربن دی اکسید کمتر در نظر گرفته شود. مقایسه بین نتایج دو ایستگاه حاکی از آن است که GCM‌های استفاده شده عملکرد بهتری در ایستگاه تبریز نسبت به اردبیل دارند بنابراین نتیجه گرفته می‌شود که GCM‌های یکسان می‌توانند عملکرد متفاوتی در ایستگاه‌های مختلف داشته باشند.

برتری ترکیب مدل‌ها به این دلیل است که ترکیب مدل‌ها شامل خواص هر یک از مدل‌ها می‌شود و بر محدودیت هر یک از مدل‌ها غلبه می‌کند، در نتیجه منجر به نتایج قابل اطمینان‌تر می‌شود (Duan and Philips, 2010). در بین مدل‌های تکی GCM برای ایستگاه تبریز، BNU-ESM عملکرد بهتری در ریزمقیاس‌نمایی بارش و دما داشت. پس می‌توان نتیجه گرفت برای این ایستگاه، GCM‌ها با وضوح بیشتر عملکرد بهتری دارند. اما برای ایستگاه اردبیل، INM-CM4 در بین مدل‌های تکی GCM، نتایج قابل اطمینانی برای دما نشان داد و برای بارش این ایستگاه، مدل Can-ESM2 نتایج بهتری داشت. این نتایج حاکی از آن است که برای این ایستگاه، GCM‌های با وضوح پایین (مثل INM-CM4) می‌توانند نتایج بهتری نسبت به GCM‌های با وضوح بالاتر، داشته باشند، که این نتایج با برخی مطالعات گذشته (مثل Miao et al., 2012) مطابقت دارد. برای هر دو ایستگاه ریزمقیاس‌نمایی GCM‌ها برای دما عملکرد بهتری نسبت به ریزمقیاس‌نمایی بارش داشت، به این دلیل که طبیعت پایدار و منظم دما، باعث سهولت پیش‌بینی آن می‌شود، در حالی که فرایند بارش دارای عدم قطعیت بالا است و که با برخی مطالعات (مانند Ahmadalipour et al., 2017) مطابقت دارد. سری زمانی




الف




ب

Fig. 5- Results for a) precipitation of Tabriz b) precipitation of Ardabil
 شکل ۵- نتایج برای الف) بارش تبریز ب) بارش اردبیل



الف



ب

Fig. 6- Results for a) temperature of Tabriz b) temperature of Ardabil
شکل ۶- نتایج برای الف) دما تبریز ب) دما اردبیل

برای ایستگاه اردبیل، استفاده از ترکیب داده‌های GCM، مقادیر PICP تا ۳۰٪ و ۲۰٪ بیشتر و مقادیر NMPIW تا ۲۰٪ و ۲۰٪ کمتر به ترتیب برای دما و بارش در مقایسه با GCM‌های تکی است. با توجه به این که PICP و NMPIW رابطه عکس دارند در نظر گرفتن همزمان هر دو معیار نشان می‌دهد که مدل Can-ESM2 نتایج بهتری برای ریزمقیاس‌نمایی بارش دارد و BNU-ESM به نتایج بهتری برای ریزمقیاس‌نمایی دما در ایستگاه تبریز منجر می‌شود. اما برای ایستگاه اردبیل Can-ESM2 و BNU-ESM به ترتیب نتایج بهتری برای پارامتر دما و بارش دارند. بنابراین برخلاف پیش‌بینی نقطه‌ای، GCM‌هایی با وضوح بالا شاید منجر به عملکرد بهتری برای ساخت PI در مقایسه با GCM‌هایی با وضوح پایین‌تر (مانند INM-CM4) باشند. برای ارزیابی مقادیر PI ساخته شده با روش LUBE، روش کلاسیک بوت استرپ برای ساخت PI استفاده شد و نتایج هر دو روش با هم مقایسه شدند. بنابراین، برای ANN هر پارامتر ۸۰ بار آموزش داده شد، هر بار مدل‌سازی با داده‌های انتخاب شده تصادفی، نمونه به تعداد ۴۰۰ و ۲۵۰ از بین ۶۵۹ و ۳۵۹ نمونه کلی به ترتیب برای داده‌های ایستگاه تبریز و اردبیل (برای مدل CAN-ESM2 نمونه‌های تصادفی انتخاب شده، ۶۵۰ و ۳۵۰ از بین ۷۴۳ و ۴۳۱ نمونه کلی به ترتیب برای داده‌های ایستگاه تبریز و اردبیل است).

۳-۲- ساخت PI با استفاده از روش LUBE و بوت استرپ

عملکرد کلی هر روش ساخت PI برای مدل‌سازی مبتنی بر ANN به طور کامل بستگی به ساختار شبکه و روند آموزش دارد. برای تولید نتایج PI در ریزمقیاس‌نمایی با روش LUBE، ANN برای هر پارامتر (بارش و دما در تبریز و اردبیل) ایجاد شده که شامل دو نرون خروجی به عنوان حد بالا و پایین پیش‌بینی برای هر نقطه نمونه است. مقادیر بهینه نرون‌های مخفی با استفاده از روش آزمون و خطا تعیین شدند که در محدوده ۱-۱۲ نرون مورد آزمایش قرار گرفت. سطح اطمینان مرتبط با تمام PI‌ها ۹۰٪ در نظر گرفته شده است. دو معیار PICP (معادله ۷) و NMPIW (معادله ۹) برای هر مجموعه از وزن‌های تولید شده (با تغییر وزن‌های اولیه) برای یافتن ساختار بهینه ANN (بیشترین PICP و کمترین NMPIW) محاسبه شد. مقادیر بهینه بدست آمده PICP و NMPIW در ساخت PI برای پارامترهای بارش و دما دو ایستگاه تبریز و اردبیل در جدول ۵ نشان داده شده است.

مقدار PICP برای ترکیب GCM‌ها تا ۲۰٪ و ۱۰٪ به ترتیب بیشتر و مقدار NMPIW تا ۱۰٪ و ۵۰٪ به ترتیب کمتر از GCM‌های تکی برای بارش و دما است. بنابراین ترکیب GCM‌ها، هم در پیش‌بینی نقطه‌ای و هم در PI عملکرد بهتری دارد. ترکیب مدل‌سازی تأثیر بیشتری در باریک کردن عرض نسبت به همگرایی PI داشت. به‌علاوه

Table 5- PIs results for both stations via Bootstrap and LUBE methods

جدول ۵- PI های هر دو ایستگاه با روش بوت استرپ و LUBE

| Parameter | Station | GCM | Bootstrap | | LUBE | |
|---------------|---------|---------------|-----------|-------|------|-------|
| | | | PICP | NMPIW | PICP | NMPIW |
| Temperature | Tabriz | Can-ESM2 | 0.92 | 0.57 | 0.77 | 0.65 |
| | | INM-CM4 | 0.88 | 0.49 | 0.92 | 0.67 |
| | | BNU-ESM | 0.86 | 0.46 | 0.96 | 0.67 |
| | | Ensemble-GCMs | 0.67 | 0.27 | 0.93 | 0.48 |
| | Ardabil | Can-ESM2 | 0.96 | 0.65 | 0.82 | 0.4 |
| | | INM-CM4 | 0.95 | 0.55 | 0.73 | 0.44 |
| | | BNU-ESM | 0.87 | 0.38 | 0.7 | 0.28 |
| | | Ensemble-GCMs | 0.86 | 0.38 | 0.93 | 0.43 |
| Precipitation | Tabriz | Can-ESM2 | 0.94 | 0.88 | 0.90 | 0.50 |
| | | INM-CM4 | 0.93 | 1.15 | 0.90 | 0.77 |
| | | BNU-ESM | 0.94 | 0.66 | 0.83 | 0.87 |
| | | Ensemble-GCMs | 0.64 | 0.3 | 0.93 | 0.35 |
| | Ardabil | Can-ESM2 | 0.95 | 1.2 | 0.77 | 0.36 |
| | | INM-CM4 | 0.88 | 0.61 | 0.78 | 0.39 |
| | | BNU-ESM | 0.94 | 0.58 | 0.56 | 0.29 |
| | | Ensemble-GCMs | 0.93 | 0.75 | 0.90 | 0.51 |

اولیه‌ای در مورد توزیع داده‌ها حاصل می‌شوند. اما در روش بوت استرپ فرض می‌شود که خطاها از توزیع نرمال تبعیت می‌کنند. همچنین، زمان لازم برای ساخت PI با روش LUBE خیلی کمتر از بوت استرپ است. به این دلیل که در روش بوت استرپ به اندازه B بار آموزش ANN باید انجام شود اما برای روش LUBE یک بار آموزش ANN کافی است (Khosravi et al., 2011). در نتیجه روش LUBE به عنوان روش قابل اطمینان برای ساخت PI از هر دو جنبه کمی و کیفی به شمار می‌رود.

۴- جمع بندی

اگر چه ریزمقیاس‌نمایی مبتنی بر ANN به طور گسترده در پیش‌بینی متغیرهای اقلیم بکار می‌رود، پیش‌بینی نقطه‌ای ANN هیچ اطلاعاتی درباره‌ی دقت پیش‌بینی نمی‌دهد. بنابراین، PI شاخص مهمی در کمیت‌سنجی قابلیت اطمینان ریزمقیاس‌نمایی مبتنی بر ANN برای پارامترهای اقلیم با استفاده از داده‌های GCM است.

در این مقاله، ریزمقیاس‌نمایی مبتنی بر ANN برای پارامترهای بارش و دما با استفاده از سه GCM مختلف و ترکیب GCM‌ها انجام شد و داده‌ها برای مدل Can-ESM2 از ۱۹۵۰ تا ۲۰۱۲ و از ۱۹۷۵ تا ۲۰۱۲ به ترتیب برای ایستگاه تبریز و اردبیل برای آموزش ANN استفاده شدند (داده‌های مربوط به مدل BNU-ESM2 و INM-CM4 تا سال ۲۰۰۵ می‌باشند). متغیرهای غالب از بین چندین پارامتر اتمسفر

وزن‌های آموزش یافته سپس برای شبیه‌سازی خروجی مدل ANN برای نمونه کلی استفاده شدند. سپس برای ساخت PI، میانگین و انحراف معیار خروجی با سطح اطمینان ۹۰٪ برای ساخت حد بالا و پایین (معادل ۱۱،۱۰، ۱۲) استفاده شدند و نتایج به دست آمده در جدول ۵ نشان داده شده‌اند. با توجه به جدول ۵، برای روش بوت استرپ هم، ترکیب GCM‌ها تقریباً نتایج بهتری در مقایسه با GCM‌های تکی داشت. برای GCM‌های تکی مدل Can-ESM2 نتایج بهتری برای بارش ایستگاه تبریز و اردبیل دارد. PI‌های ساخته شده با روش بوت استرپ عرض بیشتری نسبت به روش LUBE دارند، در نتیجه باعث می‌شود که داده‌های مشاهداتی بیشتری را در بر بگیرد و مقدار PICP بیشتری داشته باشد. اگرچه بوت استرپ در بیشتر حالت‌ها قادر به تخمین نقاط اوج است، همانطور که در شکل ۵ دیده می‌شود در برخی موارد قادر به تخمین نقاط اوج نبوده، به این دلیل که انتخاب تصادفی نمونه‌های ورودی و خروجی برای آموزش بدون در نظر گرفتن مشخصات آماری مشابه بین نمونه‌های بوت استرپ استفاده شده است و یا شاید الگوهای نمونه ورودی و خروجی شامل اطلاعات کافی نقاط اوج در آموزش زیرمجموعه داده‌ها نباشند. با توجه به رابطه ۱۳، حد بالا و پایین محدوده PI بدست آمده از روش بوت استرپ باید حول مقادیر میانگین متقارن باشند. همانطور که در شکل ۵ نشان داده شده است این مسأله برای دما صادق است اما در بارش، به دلیل این که برخی مقادیر حد پایین کمتر از صفر شده، مقدار آنها صفر در نظر گرفته شده در نتیجه الگوی کاملاً متقارنی ندارند. در مورد ساخت PI با روش LUBE، PI‌ها مستقیماً از خروجی ANN بدون هیچ فرض

- climate change impact analysis. *Theoretical and Applied Climatology* 128(1-2):71-87
- Beecham S, Rashid M, and Chowdhury RK (2014) Statistical downscaling of multi-site daily rainfall in a South Australian catchment using a Generalized Linear Model. *International Journal of Climatology*, Wiley Online Library 34(14):3654-3670
- Chryssolouris G, Lee M, and Ramsey A (1996) Confidence interval prediction for neural network models. *IEEE Transactions on Neural Networks* IEEE 7(1):229-232
- Danandeh Mehr A, Kahya E (2016) Grid-based performance evaluation of GCM-RCM combinations for rainfall reproduction. *Theoretical and Applied Climatology* 129(1-2):47-57
- Dhanesh Y and Sudheer KP (2010) Predictions in ungauged basins: can we use artificial neural networks. *American Geophysical Union Joint Assembly*, Foz do Iguassu, Brazil, August 8-13
- Duan Q and Phillips TJ (2010) Bayesian estimation of local signal and noise in multimodel simulations of climate change. *Journal of Geophysical Research: Atmospheres*, Wiley Online Library 115(D18)
- Efron B and Tibshirani RJ (1994) *An introduction to the bootstrap*. CRC press
- Farahani MA, Rasekhi A, Parmas B, and Keshvari A (2018) The effects of climate change on temperature, precipitation and drought in the future Shadegan basin. *Journal of Iran-Water Resource Research* 14(3):125-133 (In Persian)
- Feng J, Lee D-K, Fu C, Tang J, Sato Y, Kato H, Mcgregor JL, and Mabuchi K (2011) Comparison of four ensemble methods combining regional climate simulations over Asia. *Meteorology and Atmospheric Physics* Springer 111(1-2):41-53
- Fyfe JC, Gillett NP, and Zwiers FW (2013) Overestimated global warming over the past 20 years. *Nature Climate Change* Nature Publishing Group 3(9):767
- Gao Z, Gu B, and Lin J (2008) Monomodal image registration using mutual information based methods. *Image and Vision Computing* 26(2):164-173
- Grant El, Leavenworth RS (1972) *Statistical quality and control* Table A P643. New York: McGraw-Hill
- Hosseini Baghanam A, Nourani V, Keynejad M A, Taghipour H, & Alami M T (2018) Conjunction of wavelet-entropy and SOM clustering for multi-GCM statistical downscaling. *Hydrology Research* Online Published doi:10.2166/nh.2018.169
- MI در چهار نقطه شبکه در اطراف هر ایستگاه با استفاده از معیار انتخاب شد. ریزمقیاس‌نمایی مبتنی بر ANN با استفاده از مدل‌های ترکیبی GCM و ترکیب GCMها نشان می‌دهد که ترکیب GCMها به نتایج دقیق‌تری منجر می‌شود و در بین مدل‌های ترکیبی GCM، مدل Can-ESM2 به بهترین نتایج منجر می‌شود. ارزیابی‌های کمی با استفاده از معیارهای مرتبط با عرض و احتمال همگرایی PIها بکار گرفته شدند. نتایج همچنین با نتایج روش کلاسیک بوت استرپ مقایسه شد. بررسی‌ها نشان می‌دهد که ترکیب GCMها به نتایج قابل اطمینانی منجر می‌شود. بنابراین PICP تا ۲۰٪ بیشتر و NMPIW تا ۵۰٪ کمتر از GCMهای ترکیبی می‌باشد. همچنین نتایج بدست آمده حاکی از این است که روش LUBE قادر به ساخت فواصل باریک با درصد همگرایی بالا در مقایسه با روش بوت استرپ می‌باشد. کیفیت PIهای ساخته شده با روش LUBE بهتر از روش بوت استرپ می‌باشد و NMPIW برای روش LUBE ۱۰٪ تا ۶۰٪ کمتر از روش بوت استرپ می‌باشد. در روش پیشنهاد شده LUBE برای بهینه‌سازی ANN برای ساخت PI دو معیار PICP و NMPIW به عنوان تابع هدف در بهینه‌سازی در نظر گرفته شده اند. برای سرعت بخشیدن به بهینه‌سازی و رسیدن به نتایج دقیق‌تر، پیشنهاد می‌شود تا از ترکیب این دو معیار به عنوان تابع هزینه و استفاده از روش بهینه‌سازی مثل الگوریتم ژنتیک برای پیدا کردن شبکه بهینه استفاده شود.

پی‌نوشت‌ها

- 1- Artificial Neural Network (ANN)
- 2- Prediction Interval (PI)
- 3- Mutual Information (MI)
- 4- Nash Sutcliffe Efficiency (NSC)
- 5- Root Mean Square Errors (RMSE)
- 6- Correlation Coefficient (CC)
- 7- Prediction Interval Coverage Probability
- 8- Mean P Prediction Interval Width
- 9- Feed Forward
- 10- Back Propagation
- 11- Levenberg-Marquardt
- 12- Drought Inter-Arrival Time

۵- مراجع

- Afzali-Gorouh Z, Faridhosseini A and Bakhtiari B (2019) Investigation of climate change impact on 24-h probable maximum precipitation in a sub-humid climate. *Journal of Iran-Water Resource Research* 15(2) Available at: http://www.iwrr.ir/article_82591.html (In Persian)
- Ahmadalipour A, Rana A, Moradkhani H, and Sharma A (2017) Multi-criteria evaluation of CMIP5 GCMs for

- wavelet-ANN based rainfall-runoff modeling. *Journal of Environmental Informatics* 26(1)
- Osman YZ and Abdellatif ME (2016) Improving accuracy of downscaling rainfall by combining predictions of different statistical downscale models. *Water Science, Elsevier* 30(2):61-75
- Quan H, Srinivasan D and Khosravi A (2014) Particle swarm optimization for construction of neural network-based prediction intervals. *Neurocomputing, Elsevier* 127:172-180
- Sailor D J, Li X (1999) A semiempirical downscaling approach for predicting regional temperature impacts associated with climatic change. *Journal of Climate* 12(1):103-114
- Samadi S, Wilson C, and Moradkhani H (2013) Uncertainty analysis of statistical downscaling models using Hadley Centre Coupled Model. *Theoretical and Applied Climatology, Springer* 114(3-4):673-690
- Shannon CE (1948) A mathematical theory of communication. *Bell System Technical Journal, Wiley Online Library* 27(3):379-423
- Shiravand H and Dostkamiyan M (2019) Analysis of temperature fluctuations in the South West of Iran based on general circulation model and neural network (Case study: plain and mountainous stations). *Journal of Iran-Water Resource Research, Available at: http://www.iwrr.ir/article_90429.html (In Persian)*
- Srivastav RK, Sudheer KP, and Chaubey I (2007) A simplified approach to quantifying predictive and parametric uncertainty in artificial neural network hydrologic models. *Water Resources Research, Wiley Online Library* 43(10)
- Wilby RL and Wigley TML (1997) Downscaling general circulation model output: a review of methods and limitations. *Progress in physical geography, Sage Publications Sage CA: Thousand Oaks, CA* 21(4):530-548
- Yang HH, Van Vuuren S, Sharma S, and Hermansky H (2000) Relevance of time-frequency features for phonetic and speaker-channel classification. *Speech communication, Elsevier* 31(1):35-50
- Zio E (2006) A study of the bootstrap method for estimating the accuracy of artificial neural networks in predicting nuclear transient processes. *IEEE Transactions on Nuclear Science IEEE* 53(3):1460-1478
- Her Y, Yoo S-H, Cho J, Hwang S, Jeong J, and Seong C (2019) Uncertainty in hydrological analysis of climate change: multi-parameter vs. multi-GCM ensemble predictions. *Scientific Reports Nature Publishing Group* 9(1):4974
- Kaboosi K and Kordjazi M (2017) The effect of climate change on meteorological parameters and drought in Golestan province. *Journal of Iran-Water Resource Research* 13(3):205-213 (In Persian)
- Kasiviswanathan KS and Sudheer KP (2016) Comparison of methods used for quantifying prediction interval in artificial neural network hydrologic models. *Modeling Earth Systems and Environment Springer* 2(1):22
- Khosravi A, Nahavandi S, and Creighton D (2010) A prediction interval-based approach to determine optimal structures of neural network metamodels. *Expert Systems With Applications Elsevier* 37(3):2377-2387
- Khosravi A, Nahavandi S, Creighton D, and Atiya AF (2011) Lower upper bound estimation method for construction of neural network-based prediction intervals. *IEEE Transactions on Neural Networks United States* 22(3):337-346
- Lee J-K and Kim Y-O (2017) Selection of representative GCM scenarios preserving uncertainties. *Journal of Water and Climate Change, International Water Association* 8(4):641-651
- Liu Y, Feng J, Shao Y, and Li J (2019) Identify optimal predictors of statistical downscaling of summer daily precipitation in China from three-dimensional large-scale variables. *Atmospheric Research Elsevier*
- MacKay DJC (1992) A practical Bayesian framework for backpropagation networks. *Neural computation MIT Press* 4(3):448-472
- Miao C, Duan Q, Yang L, and Borthwick AGL (2012) On the applicability of temperature and precipitation data from CMIP3 for China. *PLoS One, Public Library of Science* 7(9):e44659
- Nam C, Bony S, Dufresne J, and Chepfer H (2012) The 'too few, too bright' tropical low-cloud problem in CMIP5 models. *Geophysical Research Letters, Wiley Online Library* 39(21)
- Nourani V, Baghanam AH, and Gokcekus H (2018) Data-driven ensemble model to statistically downscale rainfall using nonlinear predictor screening approach. *Journal of Hydrology, Elsevier* 565:538-551
- Nourani V, Khanghah TR, and Baghanam AH (2015) Application of entropy concept for input selection of