

اثرات تغییر اقلیم بر منابع آبی با روش الگوریتم شبکه عصبی مصنوعی (مطالعه موردی: زرینه رود)

هستی همتی^{۱*}، احمد ابریشمچی^۲، مسعود تجریشی^۳

۱- دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی شریف،
hasti_hemati@yahoo.com

۲- استاد، دانشکده مهندسی عمران، دانشگاه صنعتی شریف، ahmad.abrishamchi@gmail.com

۳- استاد، دانشکده مهندسی عمران، دانشگاه صنعتی شریف، tajrishy@sharif.edu

چکیده

هدف از این تحقیق، بررسی اثر تغییر اقلیم بر منابع حوضه آبریز زرینه رود در شرایط آبی با مقایسه‌ی آن با دوره‌های گذشته است. حوضه آبریز زرینه رود یکی از قطب‌های کشاورزی ایران و بزرگترین زیرحوضه دریاچه ارومیه است. این زیرحوضه، تامین نیازهای آبی هر سه استان آذربایجان شرقی، آذربایجان غربی و کردستان را به عهده دارد و به تنهایی ۴۰ درصد از ورودی به دریاچه ارومیه را تشکیل می‌دهد. تغییر شرایط اقلیمی و کاهش نزولات جوی، بهره‌برداری بیش از حد از رودخانه‌های جاری به دریاچه سبب کاهش شدید سطح آب و افزایش شوری دریاچه شده است. بدین منظور، اثر تغییر اقلیم بر حوضه تحت چهار سناریوی گزارش پنجم تغییر اقلیم ارزیابی می‌شود. از آنجا که خروجی این مدل‌ها بزرگ مقیاس هستند، آن‌ها را توسط الگوریتم ANN ریزمقیاس و خطاها با استفاده از QM تعدیل می‌شود. نتایج تغییر اقلیم نشان‌دهنده‌ی افزایش دما و کاهش بارندگی در منطقه بوده است. این تغییرات در سناریو RCP2.6 به کمترین و در RCP8.5 به بیشترین مقدار خود رسیده است. در ادامه، برای بررسی عملکرد روش ANN به-مقایسه آن با روش دلتا پرداخته می‌شود که نتایج حاکی از برتری این روش با مقایسه‌ی پارامترهای ارزیابی است.

واژه‌های کلیدی: تغییر اقلیم، CMIP5، ANN، QM، دلتا، زرینه رود

۱- مقدمه

اقلیم کره زمین در طول تاریخ همواره در حال تغییر بوده، با شروع انقلاب صنعتی نقش بشر در تغییرات اقلیمی افزایش پیدا کرد. این امر به طور عمده به علت افزایش مصرف سوخت‌های فسیلی، شهرنشینی، جنگل‌زدایی و بیابان‌زدایی است. تغییر جنگل‌ها و مراتع به اراضی کشاورزی امروزی به یکی از نگرانی‌های قابل توجه در سطح دنیا در زمینه تخریب محیط‌زیست و تغییر اقلیم جهانی تبدیل شده است. بنابر گزارش IPCC^۱ مدل‌های اقلیمی جهانی GCM^۲ افزایش شدت بارش‌های سنگین در اثر گرمایش جهانی ناشی از افزایش گازهای گلخانه‌ای را نشان می‌دهند. گرم شدن کره‌زمین منجر به تغییر بیلان تابش از سطح زمین، گردش اتمسفر، تغییر توزیع مکانی و زمانی و شدت بارش شده است و به چرخش بخار آب سرعت می‌بخشد، هم-چنین ویژگی‌های هیدرولوژیکی از قبیل تبخیر، رواناب و خاک را تحت تاثیر قرار می‌دهد.

مدل‌های اقلیمی بحث جدیدی است که بیشتر از ۳۰ سال از عمر آن نمی‌گذرد. هر مدل اقلیمی تلاش می‌کند تا فرآیندهایی که روی اقلیم تاثیر می‌گذارند را شبیه‌سازی کرده و براساس آن اقلیم را برای سال‌های آینده پیش‌بینی کند. چون پیش‌بینی وضعیت اقلیم آینده تحت تاثیر پدیده تغییر اقلیم به طور قطعی ممکن نمی‌باشد، راه‌حل جایگزین مشخص کردن امکان‌های رخداد گوناگون برای آن‌ها است که سناریوی اقلیمی نامیده می‌شود. در حال حاضر معتبرترین ابزار جهت تولید این سناریوها مدل‌های چرخش عمومی می‌باشد. این مدل‌ها برپایه قوانین فیزیکی بوده که به وسیله روابط ریاضی در یک شبکه سه‌بعدی در سطح کره زمین حل می‌شوند. در تمام این مدل‌ها هشت متغیر سطحی اقلیمی شامل میزان بارندگی، میانگین

فشار سطح دریا، تابع خورشیدی، دمای میانگین، دمای نقطه شبنم، دمای حداقل و حداکثر و سرعت باد در ارتفاع ۱۰ متری تا سال ۲۱۰۰ تحت سناریوهای مختلف انتشار و شبیه‌سازی شده‌اند. سناریوهای انتشار دربرگیرنده اطلاعاتی از وضعیت اقتصادی-اجتماعی و میزان انتشار گازهای گلخانه‌ای در اتمسفر کره زمین است. هیات بین‌الدول تغییر اقلیم سری اول سناریوهای انتشار را در سال ۱۹۹۲ با نام IS92، سری دوم سناریوهای انتشار در سال ۱۹۹۶ با نام SAR، سری سوم در ۲۰۰۱ سال و با نام SER، سری چهارم در سال ۲۰۰۷ و با نام SRES و سری جدید این سناریوها در سال ۲۰۱۴ تحت عنوان RCP به منظور به روزرسانی و جایگزینی سناریوهای قبلی ارائه کرد. در گزارش پنجم سعی شده به دور از مسائل سیاسی و با تاکید بر جنبه‌های علمی و فنی و استفاده از نظرات کارشناسان خبره به نگرش پرداخته شود و بیشتر بر جنبه‌های اقتصادی-اجتماعی تغییر اقلیم و نقش آن در تعدیل، مدیریت ریسک و توسعه پایدار تاکید دارد و چهارچوب کلی آن بر کاهش گازهای گلخانه‌ای و روش‌های سازگاری با تغییر اقلیم است. (IPCC, 2014)

هیلبرت و فلچر تاثیر تغییر اقلیم بر محیط زیست و کشاورزی استرالیا را بررسی کردند. بدین منظور سناریوهای A1B و A1FI از گزارش چهارم هیئت بین‌الدول را با استفاده از الگوریتم شبکه عصبی مصنوعی مدل‌سازی کردند. نتایج نشان داد که تغییر اقلیم بر روی توزیع و گستردگی بیومس استرالیا تاثیر مستقیم می‌گذارد که این به نوبه‌ی خود باعث تغییر در کشاورزی و پوشش گیاهی استرالیا می‌شود. آن‌ها هم چنین با استفاده از آنالیز قاره‌ای نشان دادند که روش ANN عملکرد مناسبی را در شبیه‌سازی و ریزمقیاس‌نمایی سناریو داشته است. (David W Hilbert and Cameron S Fletcher, 2012). دیوید مندز و همکارانش به بررسی پدیده تغییر اقلیم و بررسی ترند بارش‌های پیک بر منطقه‌ی آمازون پرداختند. بدین منظور آن‌ها از ۵ سناریو گزارش چهارم AOGCM و برای ریزمقیاس‌نمایی از روش الگوریتم شبکه عصبی مصنوعی استفاده کردند. نتایج نشان داد که الگوریتم ANN برای شهرهای بلم^۳ و ماناوس^۴ با کورلیشن به ترتیب ۸۸/۹ و ۹۱/۳ درصد و مقایسه‌ی توزیع فضایی همبستگی عملکرد بسیار مناسبی را داشته است و در میانگین شدت بارش، ماکسیمم بارش یک روزه سالانه و طول دوره خشک منطقه‌ای افزایش پیش‌بینی کردند. (Mendes David et al., 2014)

۲- روش تحقیق

۲-۱ تصحیح خطاها

نمودار چندک^۵ یا به اختصار QM دارای عملکردی مناسب در تعیین خطا و عدم قطعیت است پس در این پژوهش از این روش استفاده می‌شود.

روش QM متغیرهای نسبی مدل تصویر شده را در چندک‌ها حفظ می‌کند و همزمان خطاهای سیستماتیک موجود در سری زمانی مدل را با توجه به داده‌های موجود، تصحیح می‌کند، اینکار توسط روش توزیع چندک که توسط ویلمز و وراک در سال ۲۰۱۴ و روش فاکتور چندک که توسط اولسون و همکارانش در سال ۲۰۰۹ ارائه شدند، انجام می‌شود. در هر دوی این روش‌ها تغییرات نسبی بر چندک‌های سری زمانی دوره‌ی پایه مشاهداتی اعمال می‌شوند. این روش هم‌چنین الگوریتم تطابقی توزیع تجمع هم‌فاصله که در سال ۲۰۱۰ توسط لی و همکارانش ارائه شده را در نظر گرفته است. QM الگوریتمی استاتیک بر پایه این فرض است که عدم قطعیت‌های مدل ایستا هستند، بدین معنا که مشخصات دوره‌های پایه در آینده نیز برقرار است. (Maraun et al., 2012) نکته مهم و مثبت این روش این است که با همگام‌سازی توزیع تجمعی به تصحیح داده‌ها می‌پردازد در حالی که سایر روش‌ها تنها میانگین و انحراف معیار داده‌های مشاهداتی را برای تطابق در دوره‌های پایه استفاده می‌کنند.

روش QM تابع تجمعی^۶ $F_{o,h}$ و $F_{m,h}$ را که به ترتیب برای داده‌های مشاهداتی $X_{o,h}$ و داده‌های مدل $X_{m,h}$ هستند، را برای یک دوره پایه محاسبه می‌کند. رابطه ۱ نشان‌دهنده‌ی این بیان است:

$$\hat{x}_{m,p}(t) = F_{o,h}^{-1}\{F_{m,h}[x_{m,p}(t)]\} \quad (1)$$

که فرمول برای تصحیح خطای $x_{m,p}$ در یک دوره پیش‌بینی p برای زمان t در این بازه است. کار این الگوریتم به این صورت است که با تخمین CDF و معکوس داده‌های مشاهداتی (توابع quantile) با جست و جو و درون‌یابی بین مقادیر توابع quantile در داده‌های مشاهداتی پایه و داده‌های اقلیم پایه به یک تابع تبدیل می‌رسد. از آنجا که مقادیر ایستگاه‌های مشاهداتی محدود به سال ۱۹۸۶ به بعد هستند و داده‌های تاریخچه‌ای بازه زمانی بیشتری را پوشش می‌دهند، برای اطمینان از هم‌پوشانی توابع فیت شده یک راه حذف روند^۸ در داده‌هاست. بدین معنا که با حذف روند در میانگین طولانی مدت داده‌ها مقدم بر ایجاد نمودار quantile، و سپس توزیع آینده را دوباره بر داده‌ها وضع می‌کند. طی پروسه‌ی نمودار کردن quantile ها سعی بر این است که مقدار پیش‌بینی صفر روی صفر باقی بماند و هیچ داده از حداکثر داده‌های مشاهداتی بیشتر نشود. برای یک تابعی مانند بارندگی روندها توسط بزرگ و کوچک مقیاس کردن برداشته می‌شود:

$${}^{(Y)}\hat{x}_{m,p}(t) = F_{o,h}^{-1}\left\{F_{m,h}\left[\frac{x_{m,h}(t)}{\bar{x}_{m,p}(t)}\right]\right\}\bar{x}_{m,t}$$

که $\bar{x}_{m,p}$ و $\bar{x}_{m,h}$ به ترتیب میانگین طولانی مدت بر روی بازه‌ی تاریخچه‌ای و در زمان t در دوره‌ی پیش‌بینی شده هستند.

۲-۲ ریزمقیاس‌نمایی

در این پژوهش برای ریزمقیاس‌نمایی از روش الگوریتم شبکه عصبی مصنوعی یا ANN استفاده می‌شود که در ادامه به توضیح این روش و اجزای آن پرداخته می‌شود.

۲-۲-۱ شبکه‌های عصبی مصنوعی یا ANN

شبکه‌های عصبی مصنوعی^۹ با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند که به این عمل یادگیری^{۱۰} می‌گویند. شبکه عصبی مصنوعی به عنوان یک روش نوین در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرماندگار فرآیندهایی که برای شناخت و توصیف دقیق آن‌ها راه‌حل و رابطه‌ی صریحی وجود ندارد، عملکرد خوبی از خود نشان داده‌است. شبکه عصبی با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین داده‌های ورودی و خروجی برقرار می‌کند. شبکه‌های عصبی از یک سری لایه‌هایی شامل اجزای ساده‌ای به نام نرون^{۱۱} تشکیل شده است؛ که به صورت موازی با هم عمل می‌کنند در این شبکه‌ها به کمک دانش برنامه نویسی، ساختار داده‌ای طراحی می‌شود که می‌تواند همانند نرون عمل کند. که به این ساختار داده گره گفته می‌شود. بعد با ایجاد شبکه‌ای بین این گره‌ها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند. در این حافظه یا شبکه‌ی عصبی گره‌ها دارای دو حالت فعال (روشن یا ۱) و غیرفعال (خاموش یا ۰) اند و هر یال (سیناپس یا ارتباط بین گره‌ها) دارای یک وزن می‌باشد. یال‌های با وزن مثبت، موجب تحریک یا فعال کردن گره غیر فعال بعدی می‌شوند و یال‌های با وزن منفی، گره متصل بعدی را غیر فعال یا مهار (در صورتی که فعال بوده باشد) می‌کنند.

اکثر شبکه‌های عصبی دارای سه لایه یا بیشتر می‌باشند. لایه ورودی که برای ورود داده‌ها به شبکه استفاده می‌شود، لایه خروجی، برای تولید پاسخ‌های مناسب به ورودی‌های داده شده و یک یا تعداد بیشتری لایه میانی که از گره‌های پردازشگر تشکیل شده‌اند و محل پردازش داده‌ها به‌شمار می‌روند. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی، مشخص می‌شود. حال آنکه شمار لایه‌های مخفی و تعداد نرون در هر لایه مخفی معمولاً به وسیله‌ی روش آزمون و خطا در جهت کاهش خطا توسط طراح مشخص می‌شود. (مقدم نیا و همکاران، ۲۰۰۹)

با این حال توصیه شده است که تعداد لایه‌های پنهان تا حد امکان باید کم باشد (اسفندیاری در آباد و همکاران، ۱۳۸۹). به طوری که ابتدا شبکه با یک لایه پنهان آموزش داده شود و در صورت عملکرد نامناسب، تعداد لایه‌ها افزوده می‌شود. این موضوع در مورد تعداد نرون‌های لایه مخفی نیز صدق می‌کند. به گونه‌ای که در ابتدا تعداد نرون‌های کم مورد بررسی قرار می‌گیرد و در صورت همگرا نشدن به یک جواب مطلوب آن‌ها را افزایش می‌دهند. گره‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند (اصغری نیا و همکاران ۱۳۸۷). ورودی‌های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع محرک^{۱۲} است. ورودی‌ها به شکل یک بردار $X(X_1, X_2, X_3, \dots, X_n)$ هستند. هر ورودی توسط یک وزن به گره پردازشگر وصل می‌شود و در نهایت تسلسلی از وزن‌ها به شکل بردار وزن (W_1, W_2, \dots, W_n) به گره مورد نظر مرتبط می‌گردد. خروجی گره که Y نامیده می‌شود طبق رابطه ۳ محاسبه می‌شود:

$$(3) Y = f(X \cdot W - b)$$

که در رابطه ۳، X داده‌های ورودی، W بردار وزن و b مقدار آستانه یا بایاس است. با گذشت ۶۰ سال از مطرح شدن ایده اولیه شبکه عصبی نخستین کاربرد عملی آن با معرفی شبکه‌های پرسپترون^{۱۳} چند لایه انجام شد. در شبکه‌های فوق، هر نرون در هر لایه به تمام نرون‌های لایه قبل متصل است. این شبکه‌ها از نوع پیشرو بوده که یکی از پرکاربردترین مدل‌های شبکه عصبی مصنوعی در مدل‌سازی و پیش‌بینی عناصر اقلیمی است (حسینی، ۱۳۸۸). جهت آموزش شبکه‌های عصبی آموزش‌هایی مبنی بر ساختار پرسپترون چند لایه وجود دارد. معروف‌ترین این روش‌ها عبارتند از: انتشار خطا به عقب، گرادیان مزدوج و لونبرگ-مارکوات. لونبرگ-مارکوات^{۱۴} از سال ۱۹۹۳ میلادی تا امروز به عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است.

۲-۲-۲ تابع محرک

تابع محرک برای محدود کردن بزرگی خروجی یک نرون به کار می‌رود. تابع محرک هم‌چنین به تابع محدود کننده نیز اطلاق می‌گردد که دامنه‌ی مجاز بزرگی سیگنال خروجی به مقدار مشخص را محدود می‌کند. (Haykin, 1996) انواع مختلفی تابع محرک وجود دارد که سه تابع معروف فوق عبارت است از: تابع تانژانت سیگموئید، خطی و لگاریتم سیگموئید (دموث و بیله).

تابع سیگموئید^{۱۵} که نمودار آن به شکل حرف S است متداول‌ترین نوع تابع محرک در ساخت شبکه‌های عصبی است. این تابع به صورت یک تابع اکیدا صعودی تعریف می‌شود که موازنه‌ی مطلوبی بین رفتار خطی و غیر خطی ارائه می‌کند. مثالی از توابع سیگموئید تابع لجستیک^{۱۶} است که به صورت رابطه ۴ تعریف می‌شود:

$$(4) \varphi = \frac{1}{1 + \exp(-ax)}$$

که در آن a پارامتر شیب در تابع سیگموئید است، با تغییر پارامتر a تابع سیگموئید مختلف با شیب‌های متفاوت به دست می‌آید. در واقع شیب در مبدا برابر $a/4$ است. در نهایت زمانی که پارامتر شیب به این مقدار بینهایت نزدیک می‌شود تابع سیگموئید به تابع آستانه‌ای تبدیل می‌شود. در حالی که یک تابع آستانه‌ای مقدار صفر یا یک را به خود می‌گیرد در تابع سیگموئید این مقادیر به صورت پیوسته بازه‌ی صفر و یک را به خود می‌گیرد. (hayekin, 1996)

۲-۲-۳ لونبرگ - مارکوات

الگوریتم‌های یادگیری، روندهایی هستند که توسط آن‌ها وزن‌های شبکه تنظیم می‌گردد. هدف از آموزش شبکه این است که شبکه قانون کار را یاد بگیرد و پس از آموزش به ازای هر ورودی، خروجی مناسب را ارائه دهد. لونبرگ - مارکوات یکی از

مناسب‌ترین الگوریتم‌های آموزشی-تطبیقی مرتبه بالاتر شناخته شده برای به حداقل رساندن خطای حداقل مربعات (MSE) در شبکه‌های عصبی است. (Neuro solution, 2012)

روش منحنی برازش لونیبرگ - مارکوات در واقع ترکیبی از دو روش مینیمم کردن گرادیان نزولی و روش گاوس-نیوتون است. در روش گرادیان نزولی، مجموع خطای مربعات با جایگزینی پارامترها در جهت تندترین شیب کاهش می‌یابد. در روش گاوس نیوتن، مجموع خطاهای مربع برابر با در نظر گرفتن حداقل تابع مربع به صورت درجه دوم کاهش می‌یابد و حداقل می‌شود. روش لونیبرگ - مارکوات هنگامی که پارامترهای آن دور از مقادیر بهینه‌اش باشند، بیشتر شبیه یک روش گرادیان نزولی عمل می‌کند و هنگامی که پارامترهای آن نزدیک به مقدار بهینه‌اش باشند، بیشتر شبیه به روش گاوس-نیوتن عمل می‌کند. (Gavin, 2015)

داده‌های بدست آمده مربوط به بارش در محل ایستگاه و به صورت نقطه‌ای است و لازم است که این بارش‌ها به مساحت حوضه آبریز تعمیم داده شود برای این کار از روش چندضلعی‌های تیسن استفاده می‌شود. در روش چند ضلعی‌های تیسن^{۱۷} تمامی ایستگاه‌های داخل و خارج از حوضه آبریز مورد استفاده قرار می‌گیرند. ابتدا ایستگاه‌های هم‌جوار به هم وصل می‌شوند تا تعدادی مثلث ایجاد گردد، با رسم عمود منصف‌های اضلاع این مثلث‌ها پلی‌گون‌هایی ایجاد می‌شود که هر ایستگاه در داخل یکی از این پلی‌گون‌ها قرار می‌گیرد سپس متوسط بارندگی حوضه از رابطه ۵ محاسبه می‌شود:

$$\bar{P} = \frac{A_1 P_1 + A_2 P_2 + \dots + A_n P_n}{A_1 + A_2 + \dots + A_n} \quad (5)$$

که در آن A_1, A_2, \dots, A_n مساحت‌های مربوط به هر پلی‌گون است که در داخل حوضه قرار دارد و P_1, P_2, \dots, P_n مقدار بارندگی در ایستگاه‌های داخل چندضلعی است.

۳- نتایج و بحث

حوضه زربینه رود بزرگترین زیرحوضه درجه ۲ از حوضه دریاچه ارومیه است. این زیر حوضه تامین نیازهای هر سه استان آذربایجان شرقی، آذربایجان غربی و کردستان را دربرمی‌گیرد و ۴۰ درصد از ورودی به دریاچه ارومیه را تشکیل می‌دهد. در سال‌های اخیر ذخیره آب در دریاچه به شدت کاهش یافته به طوری که اکوسیستم آن به شدت تهدید شده است. عوامل مختلفی از جمله خشکسالی‌های دوره‌ای، ساخت و ساز سدها و طرح‌های آبیاری، افزایش نیازهای آبی و تغییر اقلیم در این باب نقش دارند.

ایستگاه‌های سینوپتیک مورد بررسی برای برآورد تغییر اقلیم دارای داده‌های معتبر و کمترین فاصله از حوضه مورد مطالعه هستند و پراکندگی آن‌ها به صورتی است که می‌توانند کل حوضه را پوشش دهند. در ابتدا داده‌های روزانه برای ایستگاه‌های سینوپتیک از سازمان هواشناسی دریافت و به فرمت مناسب تبدیل شده است. داده‌های تاریخچه‌ای و داده‌های گزارش پنجم نیز برای هر ۴ سناریو دانلود شده و برای محدوده حوضه مورد مطالعه جداسازی شده است. در قدم اول مدل الگوریتم شبکه عصبی مصنوعی (ANN) توسط داده‌های مشاهداتی و تاریخچه‌ای دوره‌ی ۲۰۰۵-۱۹۸۵ کالیبره شده و مدل بر داده‌های اقلیمی آینده برای سال‌های ۲۰۱۸-۲۰۵۰ اعمال شده سپس خروجی گرفته شده برای هر سه پارامتر و برای هر ۵ ایستگاه در الگوریتم QM تصحیح شده است. در مجموع برای ۵ ایستگاه و ۳ متغیر و ۴ سناریو، ۶۰ بار از مدل الگوریتم شبکه عصبی مصنوعی خروجی گرفته شد و برای این ۶۰ خروجی تصحیح انجام گرفت.


برای هر کدام از پارامترهای بارش، دمای حداقل و دمای حداکثر توسط داده‌های گرفته شده از سازمان هواشناسی و داده‌های تاریخی‌های گزارش پنجم برای ایستگاه‌های مورد نظر مدل الگوریتم شبکه عصبی مصنوعی آموزش داده شد. داده‌های تاریخی‌های گزارش پنجم از سال ۱۹۷۰ تا سال ۲۰۰۵ موجود است پس برای هماهنگی داده‌های تاریخی‌های با داده‌های مشاهداتی طول دوره‌ی پایه در این پژوهش از سال ۱۹۸۵-۲۰۰۵ در نظر گرفته شده است. داده‌های گرفته شده از گزارش پنجم شامل داده‌های تاریخی‌های و هر کدام از ۴ سناریوها توسط نرم‌افزار ArcGIS و با ورودی مختصات هر کدام از ایستگاه‌ها از فایل NetCDF جدا شده است. از شبکه عصبی نوع پرسپترون چند لایه استفاده شده است، برای آموزش شبکه عصبی از الگوریتم لونیبرگ-مارکوات استفاده شده و تابع محرک از نوع سیگموئید است. مدل به کار رفته دارای سه لایه است، لایه اول مربوط به ورودی و لایه آخر خروجی است و عملیات محاسبه و شبیه‌سازی در لایه میانی و بر روی نرون‌ها انجام می‌گیرد. تعداد نرون‌های لایه اول و سوم تابع تعداد ورودی‌ها و خروجی‌های مدل است و اما تعداد نرون‌های لایه میانی قاعده‌ی خاصی ندارد و با سعی و خطا مشخص می‌شود که در این پژوهش تعداد این نرون‌ها بین سه تا ده بسته به نوع داده‌ها با سعی و خطا استفاده شد.

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. پس مطابق با رابطه تمامی داده‌ها ابتدا استانداردسازی شده و سپس وارد شبکه می‌شوند. (قربانی و همکاران، ۱۳۸۸)

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (6)$$


در رابطه فوق X_n داده‌ی استاندارد شده، اندیس‌های i ، min و max به ترتیب مربوط به ردیف، حداقل و حداکثر آن داده در دیتاست خود است.

در تصحیح QM برای هر مجموعه تصحیح، تفاوت کوانتایل‌های داده‌های مشاهداتی و داده‌های شبیه‌سازی شده به صورت تابعی چند جمله‌ای فیت شده روی تفاوت کوانتایل‌ها، بر داده‌های مجموعه مدل شده اعمال شده است که خطای نتایج به حداقل خود رسیده است. نمونه‌ای از نمودار اینگونه تصحیح در ایستگاه مهاباد برای سناریوی RCP2.6 و متغیرهایش در شکل ۱ آورده شده است. همانطور که مشخص است درصد احتمال و وقوع برای هر کدام از مقادیر شبیه‌سازی شده به داده‌های مشاهداتی نزدیک شده است.




شکل ۱- تصحیح بارش، دمای حداقل و دمای حداکثر ایستگاه مهاباد

تغییرات پارامترها به صورت ماهانه برای بازه زمانی پیش‌بینی ۳۳ ساله بعد از اعمال ANN و تصحیح QM برای ایستگاه مهاباد به صورت نمودار میله‌ای، برای مقایسه‌ی بهتر سناریوها، در شکل‌های ۲ تا ۴ آورده شده است. (برای سایر ایستگاه‌ها نیز نمودارها بدین صورت بدست آورده می‌شود)



شکل ۲- میانگین ماهانه حداکثر دما در ایستگاه مهلباد

شکل ۳- میانگین ماهانه تغییرات بارش در ایستگاه مهلباد



شکل ۴- میانگین ماهانه حداقل دما در ایستگاه مهلباد

در نتایج مشاهده می‌شود که برای همه سناریوها دماهای حداقل و دماهای حداکثر نسبت به دماهای مشاهداتی افزایش یافته است و در هر سناریو به ترتیب از سناریو RCP2.6، RCP4.5، RCP6.0، RCP8.5 و RCP8.5 مقدار افزایش دماها نسبت به مشاهداتی بیشتر بوده است. بیشترین تغییرات دمایی نسبت به دمای مشاهداتی مربوط به RCP8.5 و در حدود ۳/۶ درجه است که پیش‌بینی رخ‌دادن این شدت تغییرات در طول ۳۳ سال نگران‌کننده است. در ماه‌های گرم سال بیشترین دما مربوط به ایستگاه مهلباد و خنک‌ترین ایستگاه زرینه است. در ماه‌های سرد سال سفز دارای کمترین دما و مراغه گرم‌ترین ایستگاه است. به طور کلی می‌توان گفت گرم‌ترین ماه‌های سال مرداد تا اوایل شهریور (اگست) و سردترین ماه‌های سال اواسط دی تا اواخر بهمن پیش‌بینی شده است که این روند تغییرات بنابر آنچه در سال‌های اخیر رخ داده است نشان از جابه‌جایی فصل‌ها ناشی از تغییر اقلیم دارد.

برای ایستگاه‌های تکاب، مراغه، زرینه و مهلباد پیک بارندگی سالانه در آپریل معادل اواسط فروردین تا اواسط اردیبهشت و برای ایستگاه سفز در مارچ معادل اواسط اسفند تا اواسط فروردین پیش‌بینی شده است. در مقایسه سناریوها به ترتیب از سناریو RCP2.6، RCP4.5، RCP6.0، RCP8.5 و RCP8.5 میزان بارندگی کاهش یافته است که این مورد به افزایش تغییرات دمایی مرتبط است. بیشترین بارش‌های سالانه در مقایسه‌ی تمامی سناریوها برای ایستگاه‌ها متعلق به ایستگاه سفز و کمترین بارش برای ایستگاه مراغه پیش‌بینی شده است. در سناریوها برای ماه‌های ژوئن، ژولای، اگست و سپتامبر می‌توان مشاهده کرد که در سناریو RCP8.5 مقدار بارندگی معمولاً بیشتر از سایر سناریوهاست که بر اساس اینکه در این سناریو بیشترین تغییرات دمایی پیش‌بینی شده پس انتقال فصلی ناشی از تغییرات دمایی دور از ذهن نیست. در سال‌های آخر بازه‌ی پیش‌بینی، در ۳ مورد از داده‌های خروجی ایستگاه مراغه در سناریو RCP8.5 بارش ماهانه با روند منفی رخ داده که متأسفانه براساس گزارش-

های سال‌های اخیر این مورد در چندین استان ایران نیز اتفاق افتاده است، که نگرانی‌ها در مورد کم‌آبی و خشکسالی را افزایش می‌دهد.

در مرحله بعد هدف بررسی عملکرد مدل بر دوره‌ای از داده‌های در دسترس و برآورد میزان عدم قطعیت مدل شبکه عصبی مصنوعی و تصحیح QM است. در این راستا از شاخص توافق^{۱۸} یا AI، جذر میانگین مربعات خطاها^{۱۹} یا RMSE و آزمون ضریب همبستگی گشتاوری پیرسون استفاده شده است، که روابط آن‌ها به صورت زیر است:

$$AI = 1 - \left[\frac{\sum_{i=1}^n (X_{i,m} - X_{i,o})^2}{\sum_{i=1}^n (X_{i,m} - \bar{X}_m)^2 + (X_{i,o} - \bar{X}_o)^2} \right] \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{i,m} - X_{i,o})^2}{n}} \quad (8)$$

$$r = \frac{\sum_{i=1}^n (X_{i,m} - \bar{X}_m)(X_{i,o} - \bar{X}_o)}{\sqrt{\sum_{i=1}^n (X_{i,m} - \bar{X}_m)^2} \sqrt{\sum_{i=1}^n (X_{i,o} - \bar{X}_o)^2}} \quad (9)$$

که در این روابط n تعداد داده‌ها، $X_{i,m}$ داده‌ی شبیه‌سازی شده نام، $X_{i,o}$ داده‌ی مشاهده شده نام، \bar{X}_m میانگین داده‌های شبیه‌سازی شده و \bar{X}_o میانگین داده‌های شبیه‌سازی شده است.

در جدول ۱ مقادیر این شاخص‌ها در هر ایستگاه برای پارامترها آورده شده است.

جدول ۱- شاخص‌های ارزیابی ANN

دمای حداکثر			دمای حداقل			بارش			ایستگاه
RMSE	r	AI	RMSE	r	AI	RMSE	r	AI	
۰/۰۰۱	۰/۷۸۸	۰/۹۱۶۳	۰/۰۰۱	۰/۷۴۵	۰/۹۱۳۰	۰/۰۰۳	۰/۷۵۵	۰/۹۴۲۵	تکاب
۰/۰۰۵	۰/۶۷۹	۰/۹۱۱۲	۰/۰۰۴	۰/۶۸۴	۰/۹۲۱۵	۰/۰۰۴	۰/۶۷۸	۰/۹۵۴۴	مهاباد
۰/۰۰۴	۰/۶۸۲	۰/۹۵۳۲	۰/۰۰۵	۰/۶۴۹	۰/۹۴۶۱	۰/۰۰۱	۰/۶۲۲	۰/۹۱۶۷	زرینه
۰/۰۰۴	۰/۷۸۰	۰/۹۰۷۴	۰/۰۰۳	۰/۷۵۳	۰/۹۷۱۳	۰/۰۰۳	۰/۷۹۸	۰/۹۵۳۸	مراغه
۰/۰۰۲	۰/۷۵۲	۰/۹۶۳۷	۰/۰۰۶	۰/۶۳۲	۰/۹۸۸۹	۰/۰۰۲	۰/۶۹۵	۰/۹۴۴۲	سقز

با توجه نتایج گرفته شده از آزمون‌های صحت سنجی میزان شاخص توافق در رده‌ی بالایی قرار دارد و ارتباط بین روندهای داده‌های مشاهداتی و داده‌های شبیه‌سازی را نشان می‌دهد. در مرتبه‌ی خطی کورلیشن بین داده‌های مشاهداتی و شبیه‌سازی در بازه ۰/۶ تا ۰/۸ قرار دارد و درصد باقی مانده از همبستگی به صورت غیر خطی توسط الگوریتم شبیه‌سازی شده است. میزان خطا در شبیه‌سازی پایین و در حد قابل قبول است. پس به طور کلی می‌توان نتیجه گرفت که عملکرد الگوریتم ANN و تصحیح QM در شبیه‌سازی قابل قبول است.


برای مقایسه‌ی عملکرد روش ANN و اطمینان از دقت آن این مدل‌سازی برای بارش توسط روش دیگری نیز کدنویسی شده و انجام گرفت. روش بسیار متداول و رایج در ریزمقیاس نمایی پارامترهای اقلیمی یعنی روش عامل تغییر^{۲۰} یا دلتا یکی از قدیمی‌ترین و پرکاربردترین روش‌ها در ریزمقیاس نمایی است. در جدول ۲ مقدار جذر میانگین مربعات خطاها^{۲۱} یا RMSE برای این روش به ازای هر کدام از ایستگاه‌ها آورده شده است.

جدول ۲- شاخص MRSE روش دلتا

ایستگاه	۲,۶	۴,۵	۶,۰	۸,۵
تکاب	۰/۰۵۲	۰/۰۷۵	۰/۰۴۸	۰/۰۵۳
مهاباد	۰/۰۰۷	۰/۰۵۷	۰/۰۵۵	۰/۰۷۴
زرینه	۰/۰۷۸	۰/۰۰۷	۰/۰۰۶	۰/۰۹۶
مراغه	۰/۰۳۷	۰/۰۹۱	۰/۰۸۵	۰/۰۶۶
سقز	۰/۰۰۵	۰/۰۸۵	۰/۰۶۸	۰/۰۶۸


همانطور که مشاهده می‌شود مقدار جذر میانگین مربعات خطاها برای این روش نسبت به همین مقدار در روش ANN از مرتبه بالاتری است. این بدین دلیل است که روش دلتا رابطه‌ای خطی بر مبنای داده‌های گذشته و داده‌های آینده برای مقادیر پیش‌بینی در نظر می‌گیرد اما الگوریتم ANN بر اساس چندین فاکتور تاثیرگذار مانند میانگین متحرک، روابط رگرسیونی از درجات بالا، واریانس و سایر پارامترهای استاتستیکی به شبیه‌سازی و سپس ریزمقیاس نمایی می‌پردازد. بنابراین نتایج روش ANN از دقت بالاتری برخوردار است و نسبت به اکثر روش‌های دیگر برتری دارد.

برای تعمیم تغییر پارامترها به کل حوضه زرینه‌رود از روش چندضلعی‌های تیسن که در فصل سوم شرح داده شد، استفاده می‌شود. بدین منظور با استفاده از نرم‌افزار ArcGIS لایه‌های حوضه و ایستگاه‌های درون و مجاور آن چندضلعی‌ها رسم شده و میزان مساحت موثر ناشی از هر یک از ایستگاه‌ها در حوضه مشخص شده است. مطابق با خروجی پلی‌گون‌های تیسن از نرم افزار تاثیر میزان بارش در بارش کل حوضه برای ایستگاه سقز بیشترین و در ایستگاه مهاباد کمترین است. برای بررسی میزان بارندگی در کل حوضه نمودارهای بارش حوضه برای هر چهار سناریو و با استفاده از میانگین بلندمدت ۳۳ ساله‌ی حوضه در شکل‌های ۵ تا ۸ رسم شده است.



شکل ۶- بارش حوضه زرینه رود در سناریو ۴/۵

شکل ۵- بارش حوضه زرینه رود در سناریو ۲/۶



شکل ۸- بارش حوضه زربینه رود در سناریو ۸/۵

شکل ۷- بارش حوضه زربینه رود در سناریو ۶/۰

مطابق با تعریف سناریو RCP2.6 میزان گازهای گلخانه‌ای با در نظر گرفتن تدابیر کنترلی اجتماعی، سیاسی و محیط زیستی به مرور کاهش می‌یابد به موازات کاهش گازهای گلخانه‌ای میزان تغییر در دمای هوا و پدیده گرمایش جهانی کاهش می‌یابد، در نتیجه مقدار بارندگی در سال‌های پیش‌بینی کاهش چشم‌گیری نخواهد داشت. در سناریوی RCP4.5 میزان کاهش گازهای گلخانه‌ای به مقدار سناریو RCP2.6 نیست اما هم‌چنان روند کاهشی دارد که در نتیجه میزان بارندگی در مقایسه با سناریو RCP2.6 کمتر است. در سناریو RCP6.0 نسبت به سناریو RCP2.6 و RCP4.5 میزان بارندگی کمتر است که این بر اثر این است که مطابق با تعریف سناریوی RCP6.0 میزان کاهش در گازهای گلخانه‌ای نسبت به دو سناریو پیشین کمتر است و روند گرمایشی زمین صعودی است. در سناریو RCP8.5 فرض بر این است که هیچ‌گونه اقدامات سیاسی، اجتماعی و محیط زیستی در رابطه با کاهش گازهای گلخانه‌ای صورت نگیرد پس گرمایش جهانی در بالاترین حد تغییرات خود رخ می‌دهد و میزان دی‌اکسید کربن افزایش می‌یابد در نتیجه میانگین بارندگی کاهش می‌یابد و از طرفی در بعضی ماه‌ها بارش‌های پیک و غیر قابل پیش‌بینی و در مقابل آن در ماه‌های دیگر بارش منفی صورت می‌گیرد، در مقایسه نمودارها مشاهده می‌شود که میزان بارش در ماه‌های گرم سال (یعنی جولای، اگست و سپتامبر) در سناریو RCP8.5 بیشتر از میزان بارندگی این ماه‌ها در سناریوهای دیگر است و در مقابل در ماه‌های آبی سال (فوریه، مارچ و آوریل) میزان بارش در سناریو RCP8.5 نسبت به سایر سناریوها در همین ماه‌ها کمتر است.

۴- نتیجه‌گیری

در این تحقیق به بررسی اثر تغییر اقلیم بر منابع حوضه آبریز زربینه رود در شرایط آبی با مقایسه‌ی آن با دوره‌های گذشته پرداخته شد. بر اساس مقادیر پیش‌بینی شده افزایش دما در ۳۳ سال آینده در مقیاس‌های متفاوت در همه‌ی سناریوها رخ می‌دهد. تغییر در الگوی بارش باعث جابه‌جایی فصل‌ها و تغییر ماه‌های آبی می‌شود. در بدترین سناریوی ممکن (RCP8.5) امکان رخ دادن بارش با روند منفی دور از انتظار نیست. بنابراین می‌توان گفت به علت افزایش انتشار گازهای گلخانه‌ای انتظار می‌رود پدیده تغییر اقلیم در سال‌های آینده رخ دهد. وقوع پدیده‌هایی از قبیل افزایش یا کاهش ناگهانی دما، بارندگی و غیره، طی یک یا چند سال اخیر این گمان را ایجاد می‌کند که وقوع چنین رفتاری را می‌توان بر اثر تغییر اقلیم منطقه تفسیر نمود.

۵- پی‌نوشت‌ها

1. Intergovernmental Panel on Climate Change

2. General Circulation Model
3. Belem
4. Manaus
5. Quantile Mapping
6. stationary
7. Cumulative Density Function
8. trend
9. Artificial Neural Network
10. train
11. neuron
12. Activation Function
13. Perceptron
14. Levenbreg-Marquard
15. Sigmoid
16. Logistic
17. Thiessen polygon
18. Agreement Index
19. Root Mean Square Error
20. Changing Factor
21. Root Mean Square Error

۶- مراجع

- Azaranfar.A., Abrishamchi A., and Tajrishi M., 2006. Effect of climate change on precipitation and temperature in zayand rood watershed by GCM model output. 2th Iranian conference on Water Resources Management, industrial Esfahan University, 8p.
- Cannon, A.J., S.R. Sobie, and T.Q. Murdock, 2015: Bias Correction of GCM Precipitation by Quantile Mapping: how well do methods preserve changes in quantiles and extremes?. *J. Climate*, **28**, 6938–6959.
- Hilbert David W., and Fletcher Cameron S., 2012. Using artificial neural networks to assess the impacts of future climate change on ecoregions and major vegetation groups in Australia. CSIRO Climate Adaptation Flagship working paper series; 13H.
- Fiseha, Melesse B.M., Romano A.M., Volpi E. and Fiori A. (2012). Statistical downscaling of precipitation and temperature for the upper tiber Basin in central Italy. *International Journal of Water Sciences*, Vol.1, 1-14
- Huggett, R. 1997. *Environmental change*, Routledge, London: Pp. 102-128.
- IPCC, 2014. *Climate change 2014, scientific basis*. Cambridge University Press, Cambridge, UK and NewYork, NY, USA.
- Mendes David, Antonio Marengo José, Rodrigues Sidney, and Oliveira Magaly, 2014. Downscaling statistical model techniques for climate change analysis applied to the amazon region, Volume 2014, Article ID 595462, 10 pages.
- Najafi M.R., Moradkhani H. and Jung I.W., 2011. Assessing the uncertainties of hydrologic model selection in climate change impact studies. *Hydrology. Process.* 25 (18), 2814–2826

Evaluation of climate change impacts on water resources using Artificial Neural Network (Case study: Zarinerood basin)

Hasti Hemati^{*1}, Ahmad Abrishamchi², Masoud Tajrishi³

**1- Grad. M.Sc. Student, Dept. of Civil Eng., Sharif University of Tech., Tehran
(Corresponding Author) hasti_hemati@yahoo.com**

**2- Prof., Dept. of Civil Eng. and UNESCO Chair in Water and Environment
Management for Sustainable Cities, Sharif University of Tech., Tehran,
ahmad.abrishamchi@gmail.com**

**3- Prof., Dept. of Civil Eng. and UNESCO Chair in Water and Environment
Management for Sustainable Cities, Sharif University of Tech., Tehran,
tajrishi@sharif.edu**

Abstract

The objective of this study is to study evaluate impact of climate change on water resources comparing with past data available. The drainage basin of Zarinerood is a valuable water resource that supply the water needs such as; drinking, industrial, agricultural and environmental, and makes 40 percent inflow to Urmia lake. Assessing climate change impact on Zarinerood river basin, scenarios of fifth IPCC reports e.g. RCP2.6, RCP4.5, RCP6.0 and RCP8.5, had been used. For downscaling outputs of GCMs an Artificial Neural Network (ANN) and for bias correction a Quantile Mapping (QM) method has been used. The results indicate an overall increase in temperature and decrease in precipitation in the basin which these changes will increase from RCP2.6 to RCP8.5. For evaluation of ANN method in downscaling a comparison with Delta method has been done that shows a better performance by ANN method.

Keywords: Climate Change, CMIP5, ANN, QM