

پیش‌بینی خشکسالی شهر خاش با استفاده از مدل شبکه عصبی

حسین نگارش*، دانشیار دانشکده جغرافیا و برنامه ریزی محیطی دانشگاه سیستان و بلوچستان، زاهدان، ایران
محسن آرمش، کارشناس ارشد اقلیم شناسی دانشگاه سیستان و بلوچستان، زاهدان، ایران

چکیده

در اثر تغییرات آب و هوایی رخ داده‌های ناگوار اقلیمی مانند خشکسالی در بسیاری از نقاط کره‌ی زمین تشدید شده است. در این پژوهش با استفاده از مدل شبکه‌ی عصبی خشکسالی‌های شهر خاش در سه بازه‌ی زمانی ماهانه، سه ماهه و دوازده ماهه پیش‌بینی شد. جهت این امر آمار اقلیمی شامل نم‌نسبی، دما و بارش ایستگاه هواشناسی شهر خاش و شاخص‌های اقلیمی از سال ۱۹۶۱ تا ۲۰۱۰ مورد استفاده قرار گرفت و شاخص خشکسالی *SPI* به عنوان خروجی مدل‌ها در نظر گرفته شد. ۷۰ درصد داده‌ها به عنوان داده‌های مرحله آموزش و ۳۰ درصد به عنوان داده‌های آزمایش در نظر گرفته شد. شبکه‌های مورد استفاده از نوع پس انتشار و تابع پایه‌ی شعاعی با الگوریتم پس انتشار خطا و روش یادگیری لونیبرگ - مارکواردت می‌باشند. پس از تشکیل مدل‌های فراوان با ساختار متفاوت از تعداد ورودی، تعداد لایه و نرون، پیش‌بینی سه ماهه خشکسالی به عنوان بهترین بازه زمانی جهت پیش‌بینی خشکسالی شناخته شد و پس از آن پیش‌بینی دوازده ماهه خشکسالی نتایج مناسبی ارائه داد. مقایسه دو نوع شبکه عصبی نشان داد که شبکه پس انتشار با دو لایه پنهان ۱۵ نرونی و با ورودی‌های بیشینه نم‌نسبی، میانگین نم‌نسبی با ۳ فصل تأخیر، شاخص بارش موسمی جنوب غربی آمریکا با ۴ فصل تأخیر، شاخص بارش موسمی جنوب غربی آمریکا با ۲ فصل تأخیر، میانگین نم‌نسبی و کمینه نم‌نسبی مناسب‌ترین مدل جهت پیش‌بینی سه ماهه خشکسالی در شهر خاش می‌باشد. مقایسه نتایج مدل شبکه‌ی عصبی و مدل رگرسیونی بر دقت و توانایی شبکه‌ی عصبی در پیش‌بینی خشکسالی شهر خاش صحت گذاشت.

واژگان کلیدی

خشکسالی، شبکه‌ی عصبی مصنوعی، شاخص‌های اقلیمی، خاش، پیش‌بینی

۱- مقدمه

خشک‌سالی^۱ وضعیتی از کمبود بارندگی و افزایش دماست که در هر وضعیت اقلیمی ممکن است رخ دهد (علیزاده، ۱۳۸۱: ۲۶۲). خشک‌سالی خطرات زیادی را برای یک منطقه ایجاد می‌کند زیرا کاهش رطوبت سیستم‌های حیاتی را که به آب وابسته‌اند مختل می‌کند و چه بسا این سیستم‌ها از بین بروند (کاوایانی و علیجانی، ۱۳۷۸: ۲۶۸). نوسانات شدید بارش در نواحی خشک و نیمه‌خشک سبب شده پیش‌بینی خشک‌سالی در این نواحی بسیار مشکل شود و استفاده از روشی که دقت کافی داشته باشد در این بین از اهمیت شایانی برخوردار است. تأثیر منفی خشک‌سالی بر زندگی بشر سبب شده تا انسان‌ها جهت مقابله با اثرات سوء آن به دنبال راهکار باشند. در این بین پیش‌بینی خشک‌سالی ذهن بسیاری از دانشمندان را به خود مشغول کرده است. بطوریکه تاکنون روش‌های گوناگونی جهت پیش‌بینی خشک‌سالی ارائه شده است. از آن جمله استفاده از آزمون دنباله‌ها، روش سری‌های زمانی و شاخص‌های مختلفی را که جهت پیش‌بینی خشک‌سالی به وجود آمده‌اند می‌توان نام برد. روش شبکه‌های عصبی مصنوعی رویکردی نوین در این مقوله می‌باشد و طی سالیان اخیر بسیاری از پژوهشگران جهت پیش‌بینی خشک‌سالی آن را بکار گرفته‌اند. سلاجقه و همکاران (۱۳۸۷) خشک‌سالی در استان خراسان رضوی را با دو روش سری زمانی و شبکه‌ی عصبی پرسپترون پیش‌بینی کردند که نتایج، برتری روش سری زمانی را تأیید کرد. صداقت کردار و فتاحی (۱۳۸۷) برای پیش‌بینی خشک‌سالی در ایران از سیگنال‌های بزرگ مقیاس اقلیمی و روش شبکه‌ی عصبی استفاده کردند. تحلیل نتایج خروجی شبکه‌ی عصبی با داده‌های مشاهده‌ای نشان داد که طی فاز گرم انسو و فاز منفی *NAO* شرایط ترسالی و در شرایط عکس آن خشک‌سالی در ایران به وقوع می‌پیوندد. اعلمی و همکاران (۱۳۸۸) برای پیش‌بینی خشک‌سالی در حوضه‌ی ليقوان چای از شاخص‌های پیش‌بینی خشک‌سالی و شبکه‌ی عصبی مصنوعی استفاده کردند که مشخص شد مدل شبکه عصبی کارایی بالاتری برای پیش‌بینی خشک‌سالی دارد. عیوضی و همکاران (۱۳۸۸) برای پیش‌بینی خشک‌سالی در ایستگاه نوده واقع در حوضه گرگان رود دو نوع شبکه عصبی پرسپترون و پایه شعاعی را بکار گرفتند. بررسی نتایج، دقت بیشتر شبکه‌ی پرسپترون را نسبت به شبکه‌ی پایه شعاعی تأیید کرد. افخمی و همکاران (۱۳۸۹) خشک‌سالی استان یزد را با استفاده از داده‌های اقلیمی و مدل شبکه‌ی عصبی پیش‌بینی کردند. خروجی این تحقیق انعطاف‌پذیری بالای شبکه نسبت به فقدان داده‌های ورودی را اثبات کرد. حسین پورنیکنام و همکاران (۱۳۸۹) با استفاده از شاخص‌های اقلیمی و روش فازی - عصبی^۲ خشک‌سالی‌های شهر زاهدان را پیش‌بینی کردند. نتایج به دست آمده نشان داد که پیش‌بینی فصلی خشک‌سالی، پاسخ‌های به مراتب مناسب‌تری را نسبت به پیش‌بینی پیوسته‌ی خشک‌سالی ارائه می‌دهد. خوشحال دستجردی و حسینی (۱۳۸۹) از داده‌های اقلیمی و هیدرولوژیکی و شبکه‌ی پرسپترون چند لایه برای پیش‌بینی خشک‌سالی در استان اصفهان استفاده کردند. نتایج نشان داد که با دقت بالای ۹۵ درصد، می‌توان سیکل خشک‌سالی استان را پیش‌بینی نمود. فرخ‌نیا و همکاران (۱۳۸۹) با شناسایی الگوهای پیوند از دور مؤثر بر خشک‌سالی استان تهران، خشک‌سالی‌های این استان را با شبکه‌ی عصبی مصنوعی و مدل فازی - عصبی با دقت بالایی پیش‌بینی کردند. نصیری (۱۳۸۹) با استفاده از عناصر اقلیمی و الگوهای پیوند از دور، خشک‌سالی‌های شهر شیراز را با مدل شبکه‌ی عصبی پیش‌بینی کرد. نتایج نشان داد که پیش‌بینی گسسته‌ی خشک‌سالی زمستانه به مراتب دقیق‌تر از پیش‌بینی پیوسته‌ی خشک‌سالی است. میشرای و دسائی^۳ (۲۰۰۶) از سه مدل سری زمانی، شبکه‌های عصبی *RMSNN* و *DMSNN* برای پیش‌بینی خشک‌سالی در

^۱ - Drought^۲ - ANFIS^۳ - Mishra and Desai

حوضه رودخانه‌ی کاناباتی در غرب بنگال هند بهره گرفتند. مرید^۱ و همکاران (۲۰۰۷) از شاخص‌های اقلیمی و روش شبکه‌ی عصبی برای پیش‌بینی دو شاخص خشک‌سالی *SPI* و *EDI* استفاده کردند. خروجی مدل‌ها نشان داد شاخص‌های *NAO* و *SOI* تأثیر کمی در بهبود نتایج مدل‌ها دارند. میشر و همکاران (۲۰۰۷) برای پیش‌بینی خشک‌سالی در حوضه‌ی رودخانه‌ی کاناباتی از مدل هیبریدی و یک شبکه غیرخطی عصبی مصنوعی استفاده کردند. نتایج نشان داد که مدل ترکیبی مورد نظر دقت بالایی برای پیش‌بینی خشک‌سالی دارد. کامیلو و ریور^۲ (۲۰۰۸) به وسیله‌ی شبکه‌های پرسپترون چند لایه خشک‌سالی سالانه را برآورد کردند. سانتوس^۳ و همکاران (۲۰۰۹) روش شبکه‌های عصبی پس انتشار را برای پیش‌بینی خشک‌سالی در سه منطقه از حوضه‌ی رودخانه سان فرانسیسکو در شمال شرق برزیل بکار گرفتند. نتایج، دقت بالای مدل شبکه عصبی را تأیید کرد. کاتوره^۴ و همکاران (۲۰۰۹) با استفاده از شاخص‌های اقلیمی و روش شبکه‌ی عصبی شاخص خشک‌سالی پالم در سیسیل ایتالیا را پیش‌بینی کردند. نتایج نشان داد همبستگی معناداری بین شاخص *NAO* و *EB* برای شاخص خشک‌سالی پالم پاییزه و زمستانه وجود دارد. باروا^۵ و همکاران (۲۰۱۰) برای پیش‌بینی خشک‌سالی روش *ADI* و دو نوع از شبکه‌های عصبی *RMSNN* و *DMSNN* را بکار گرفتند. نتایج نشان داد شبکه‌های *RMSNN* برای پیش‌بینی سه ماهه و شبکه‌های *DMSNN* برای بازه‌ی زمانی شش ماهه نتایج بهتری دارند. شهرستان خاش با داشتن زمین‌های زراعی و باغی گسترده همواره در معرض این مخاطره اقلیمی می‌باشد وقوع خشک‌سالی‌هایی متعدد سبب کاهش بازدهی محصولات می‌شود. هدف از این پژوهش پیش‌بینی خشک‌سالی شهر خاش طی سه‌بازه زمانی ماهانه، سه ماهه و دوازده ماهه است تا با ارائه مدل مناسب جهت پیش‌بینی خشک‌سالی در برنامه‌ریزی‌های آبی با استفاده‌ی از نتایج آن خسارات ناشی از خشک‌سالی را به کمینه رساند.

۲- منطقه‌ی مطالعاتی

شهر خاش با طول جغرافیایی ۶۱ درجه و ۱۲ دقیقه‌ی شرقی و عرض جغرافیایی ۲۸ درجه و ۱۳ دقیقه‌ی شمالی و ارتفاع ۱۳۹۴ متر از سطح آب‌های آزاد دنیا در جنوب شرق ایران واقع شده است. حدود ۲۴ هزار کیلومتر مربع وسعت دارد و از شمال به شهرستان زاهدان، از غرب و جنوب غرب به شهرستان ایرانشهر، از جنوب و جنوب شرق به شهرستان سراوان و از شرق به کشور پاکستان محدود شده است (شکل ۱). در شکل ۲ نمودار آمیروترمیک شهر خاش نمایش داده شده است، همان‌طور که مشاهده می‌شود دوره‌ی مرطوب سال به فصل زمستان محدود می‌شود و در سایر مواقع سال شرایط خشک حاکم است.

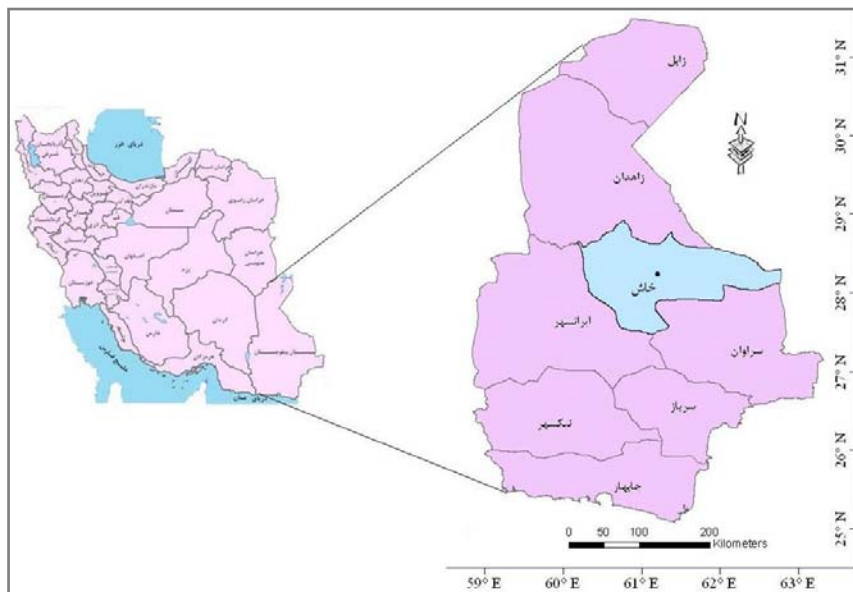
^۱. Morid

^۲. Camilo and Rivera


^۳. Santos

^۴. Cutore

^۵. Barua




شکل ۱- موقعیت جغرافیایی شهر خاش

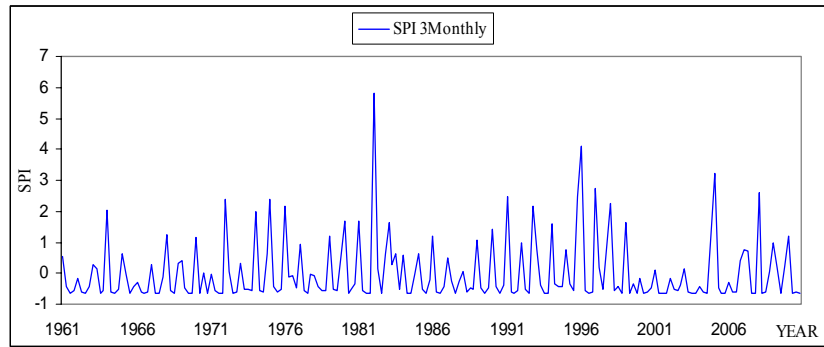


شکل ۲- نمودار آمبروترمیک شهر خاش


متوسط بارش سالانه شهر خاش حدود ۱۴۷ میلی‌متر است و از این حیث قطب بارش استان محسوب می‌شود. نمودار سری زمانی شاخص خشک‌سالی SPI در سه بازه‌ی زمانی ماهانه، ۳ ماهه و ۱۲ ماهه در شکل‌های ۳ تا ۵ نشان داده شده است. در این نمودارها دوره‌های مرطوب و خشک شهر خاش کاملاً قابل تشخیص است.



شکل ۳- سری زمانی مشاهداتی شاخص SPI در مقیاس زمانی



شکل ۴- سری زمانی مشاهداتی شاخص *SPI* در مقیاس زمانی ۳ ماهه (۱۹۶۱-۲۰۱۰)



شکل ۵- سری زمانی مشاهداتی شاخص *SPI* در مقیاس زمانی

۳- مواد و روش‌ها

این پژوهش آمار ماهانه، سه ماهه و دوازده ماهه عناصر اقلیمی مانند بارش، نهنسی، دما و شاخص‌های اقلیمی مؤثر بر خشک‌سالی از سال ۱۹۶۱ تا ۲۰۱۰ مورد استفاده قرار گرفته است. داده‌های مزبور استاندارد شده و سپس با ترکیب ۷۰ به ۳۰ (۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمایش مدل‌ها) به مدل شبکه عصبی اعمال شدند. علت استفاده از داده‌های نهنسی و دما این است که در زمان وقوع پدیده خشک‌سالی وضعیت نرمال این داده‌ها دچار تغییراتی شده به طوری که کمبود رطوبت به علت کاهش ورود توده‌های هوایی مرطوب بر روی رطوبت نسبی تأثیر گذاشته و سبب کاهش آن می‌شود، از طرفی بر نوسانات دمایی نیز اثر می‌گذارد و آن را بالا می‌برد. چون وجود رطوبت در منطقه ضامن خوبی برای کاهش دامنه‌ی تغییرات دمایی و کمبود آن سبب بالا رفتن دامنه نوسانات دمایی می‌شود. سازمان ملی مطالعات جوی و اقیانوسی ایالات متحده آمریکا (*NOAA*) با برآورد اختلاف فشار و دما، سطح اقیانوس‌ها شاخص‌هایی را ارائه کرده است که جهت تحلیل تحولات جوی می‌توان از آن‌ها کمک گرفت. در این تحقیق نوزده شاخص اقلیمی جهت پیش‌بینی خشک‌سالی بررسی شد از بین این شاخص‌ها سه الگوی شاخص بارندگی موسمی ناحیه‌ی جنوب غربی آمریکا (*SW Monsoon*)، شاخص *Nino1+2* و شاخص *Nino3* به کمک روش رگرسیونی گام به گام^۱ و همبستگی مؤثر بر خشک‌سالی شهر خاش تشخیص داده شدند که در مدل‌سازی از آن‌ها بهره گرفته شد. شاخص بارندگی موسمی ناحیه‌ی جنوب غربی آمریکا بیانگر میانگین بارندگی ناحیه ساحلی آریزونا و نیومکزیکو می‌باشد، شاخص *Nino1+2* مربوط به مقادیر حدی دمای سطح اقیانوس بوده و محدوده ۰ تا ۱۰ درجه‌ی جنوبی و ۸۰ تا ۹۰ درجه غربی

^۱. step wise

را در بر می‌گیرد. شاخص *Nino3* مربوط به دمای سطح اقیانوس آرام بوده و محدوده ۵ درجه شمالی تا ۵ درجه جنوبی و ۹۰ تا ۱۵۰ درجه غربی را در بر می‌گیرد.

شاخص خشک‌سالی بارش استاندارد (*SPI*) به عنوان خروجی مدل‌ها به کار گرفته شده است. خشک‌سالی زمانی شدید است که شاخص *SPI* ۱-، یا کمتر باشد و در صورتی که مثبت شود رخداد خشک‌سالی به پایان خواهد رسید. مدت دوره‌ی خشک‌سالی با شروع و خاتمه ارقام منفی *SPI* تعیین می‌شود و مقادیر تجمعی *SPI* نیز بزرگی و شدت دوره خشک‌سالی را نشان می‌دهد (انصافی مقدم، ۱۳۸۶: ۲۷۷). طبقه بندی شاخص *SPI* از ترسالی فرین تا خشک‌سالی فرین متغیر است (جدول ۱).


جدول ۱ - طبقه‌بندی *SPI*

وضعیت	<i>SPI</i>	وضعیت	<i>SPI</i>
ترسالی فرین	$SPI \geq 2$	نسبتاً خشک‌سالی	-۱/۴۹ تا -۱
ترسالی شدید	۱/۵ تا ۱/۹۹	خشک‌سالی شدید	-۱/۵ تا -۱/۹۹
نسبتاً ترسالی	۱ تا ۱/۴۹	خشک‌سالی فرین	$SPI \leq -2$
نزدیک نرمال	۰/۹۹ تا ۰/۹۹	-	-

منبع: (هایس و همکاران، ۱۹۹۹: ۴۳۱)

۳-۱- شبکه‌ی عصبی مصنوعی^۱

در سالیان اخیر علاقه فزاینده‌ای در توسعه تئوریک سیستم‌های دینامیکی هوشمند مدل - آزاد ایجاد شده است، شبکه‌های عصبی که جزء این سیستم‌های دینامیکی هستند با پردازش داده‌های تجربی، قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند این شبکه‌ها براساس محاسبات، روی داده‌های عددی، قوانین کلی را فرا می‌گیرند(منهاج، ۱۳۸۷: ۲۰). ساختار این شبکه‌ها از شبکه‌های عصبی زیستی تبعیت می‌کند که در آن با تنظیم وزن‌ها نحوه ارتباط بین اجزای آن تعیین می‌گردد. پس از آموزش شبکه اعمال یک ورودی خاص منجر به دریافت پاسخ خاص می‌شود(کیا، ۱۳۸۷: ۲۹). عناصر شبکه‌ی عصبی را بردار ورودی، وزن‌ها، توابع محرک و خروجی تشکیل می‌دهد. اساس شبکه‌های عصبی در واقع شبیه‌سازی تفکر و پردازش اعمال مغز انسان است که از طریق مدل سازی سلول‌های عصبی امکان پذیر می‌شود(فرج زاده، ۱۳۸۹: ۱۲۲). سیستم شبکه عصبی از اجتماع نرون‌ها تشکیل شده و هر نرون از سه بخش بدنه، دندریت و آکسون تشکیل شده است (شکل ۶).



شکل ۶ - ساختار نرون غیر خطی (Barua, 2010: 33)

^۱ Artificial Neural Network

خروجی نرون به صورت زیر محاسبه می‌شود:

$$a = f(wp + b) \quad \text{رابطه‌ی (۱)}$$


در رابطه‌ی فوق a خروجی نرون، f تابع محرک، w بردار وزن‌ها، p ورودی نرون و b مقدار بایاس می‌باشد. توابع محرک مورد استفاده در این پژوهش شامل توابع غیرخطی تانژانت هیپربولیک و Radial Basis در لایه‌ی میانی و تابع محرک خطی در لایه‌ی خروجی می‌باشند. این توابع به ترتیب با روابط کلی زیر تعریف می‌شوند:

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad \text{رابطه‌ی (۲) (Barua, 2010: 34)}$$

$$\text{radbas}(n) = e^{-n^2} \quad \text{رابطه‌ی (۳) (کیا، ۱۳۸۷: ۱۴۰)}$$

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases} \quad \text{رابطه‌ی (۴) (Barua, 2010: 34)}$$

در شکل ۷ توابع محرک مورد استفاده در تحقیق نشان داده شده است.



شکل ۷ - توابع محرک مورد استفاده در پژوهش

جهت آموزش شبکه از الگوریتم مارکوارت - لونیبرگ که از قاعده پس انتشار خطا^۱ تبعیت می‌کند استفاده شده است. این الگوریتم جزء تکنیک‌های استاندارد بهینه سازی عددی محسوب شده که سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس *Hessian* دارد. ماتریس *Hessian* به صورت زیر قابل تخمین است.

$$H = J^T J \quad \text{رابطه (۵)}$$

هم‌چنین شیب نیز به صورت زیر محاسبه می‌شود:

$$g = J_e^T \quad \text{رابطه‌ی (۶)}$$

^۱ . Back Propagation

که J ماتریس ژاکوبیان است و شامل مشتقات اول از خطاهای شبکه، نسبت به وزن‌ها و بایاس‌ها است و e بردار خطای شبکه است، ماتریس ژاکوبیان از طریق تکنیک‌های استاندارد BP قابل محاسبه است و پیچیدگی کم‌تری نسبت به ماتریس Hessian دارد (کیا ۱۳۸۷: ۹۱). الگوریتم مارکوارت - لوبنرگ از تقریب زیر برای محاسبه‌ی ماتریس Hessian استفاده می‌کند:

$$X_{k+1} = X_k - [J^T J + \alpha I]^{-1} J^T e + e \quad \text{رابطه‌ی (۷)}$$

X وزن‌های شبکه‌ی عصبی، J ژاکوبیان ماتریس معیار اجرای شبکه که باید کمینه شود، α عددی است که فرایند آموزش را کنترل می‌کند و e بردار خطای باقیمانده است. محاسبات شبکه‌های عصبی در حالت پیشرو^۱ به صورت زیر است:

$$Net_{pi} = \sum W_{ij} a_j + b_i \quad \text{رابطه‌ی (۸)}$$

(خوشحال دستجردی و حسینی، ۱۳۸۹: ۱۱۱)

در این رابطه، apj مقدار خروجی لایه‌ی قبل، Wij وزن‌های لایه‌ی مربوطه و bi میزان بایاس است. این رابطه خطی است که بعد از آن مقدار $F(Net_{pi})$ محاسبه می‌شود، در واقع F همان تابع محرک است که در لایه‌های پنهان غیرخطی و در لایه خروجی از نوع خطی می‌باشد. طی فرایند آموزش که همان یافتن وزن‌ها و بایاس‌های مناسب جهت پیش‌بینی است، باید یک الگوریتم برگشتی برای آموزش داشته باشیم که در این‌جا همان روش پس انتشار خطا (BP) است که محاسبات آن به صورت زیر است:

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} \quad \text{رابطه‌ی (۹)}$$


(خوشحال دستجردی و حسینی، ۱۳۸۹: ۱۱۲)

$$E = \sum_i (obs_i - pre_i)^2 \quad \text{رابطه‌ی (۱۰)}$$

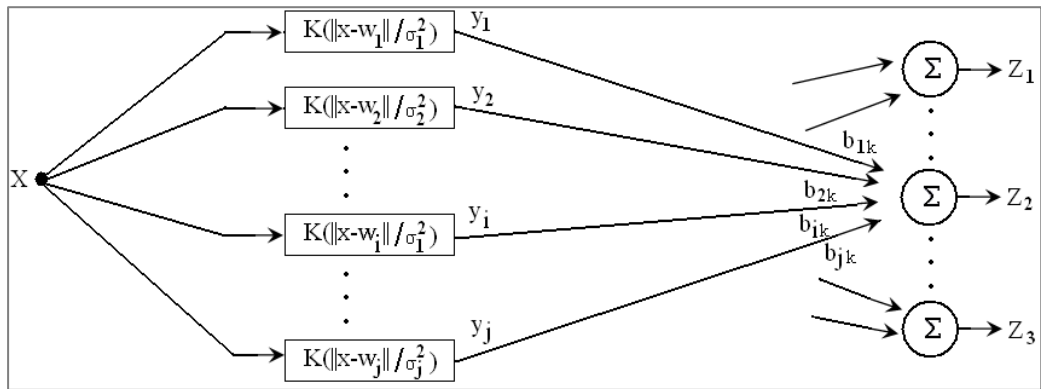
(خوشحال دستجردی و حسینی، ۱۳۸۹: ۱۱۲)

که در آن ΔW_{ij} به مقدار W_{ij} برای آموزش اضافه می‌شود و η نرخ آموزش و ثابت است. برای پیش‌بینی خشک‌سالی در این پژوهش از دو نوع شبکه‌ی عصبی پس انتشار و $Radial Basis$ استفاده شده است. شبکه‌ی پس انتشار یک شبکه‌ی چندلایه با تابع محرک غیرخطی و قاعده‌ی یادگیری $Hoff-Widrow$ می‌باشد و برای تقریب توابع، یافتن ارتباط بین ورودی و خروجی و دسته‌بندی ورودی‌ها براساس روش‌های تعیین شده توسط طراح استفاده می‌شوند (شکل ۸). شبکه‌های $Radial Basis$ نیاز به نرون‌های بیشتری نسبت به شبکه‌های پس انتشار دارند، ولی نیاز به زمان کمتری جهت طراحی نسبت به شبکه‌های پس انتشار دارند. وقتی که ورودی شبکه‌ها زیاد باشد بهترین کارایی را دارند (شکل ۹). در این تحقیق برای شبکه‌ی پس انتشار از تابع محرک تانژانت‌هایپربولیک و خطی و در شبکه‌ی $Radial Basis$ از تابع محرک $radbas$ و خطی استفاده شده است.

^۱ - Feed Forward



شکل ۸ - نمونه شبکه‌ی سه لایه پیش خور با الگوریتم آموزش پس انتشار خطا (Barua, 2010: 119)



شکل ۹ - شبکه‌ی عصبی مصنوعی تابع پایه‌ای شعاعی (عیوضی و همکاران، ۱۳۸۸: ۱۵۲)

برای برازش مدل‌ها در این تحقیق از ضریب تعیین (R^2)، ریشه‌ی میانگین مربعات خطا ($RMSE$) و میانگین قدر مطلق خطا (MAE) استفاده شده است (روابط ۱۱ تا ۱۳).

$$R^2 = \frac{\sum_{i=1}^n (obs - \overline{obs})(pre - \overline{pre})}{\sqrt{\sum_{i=1}^n (pre - \overline{pre})^2 \sum_{i=1}^n (obs - \overline{obs})^2}} \quad (۱۱) \text{ رابطه‌ی}$$

(خوشحال دستجردی و حسینی، ۱۳۸۹)

$$RMSE = \sqrt{\frac{\sum_i P_{obs} - P_{sim}}{n}} \quad (۱۲) \text{ رابطه‌ی}$$

(فرج زاده، ۱۳۸۹: ۱۲۷)

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z^*(x_i) - Z(x_i)| \quad (۱۳) \text{ رابطه‌ی}$$

(اختری و همکاران، ۱۳۸۵: ۳۱)

در روابط فوق obs , P_{obs} و $Z(x_i)$ مقادیر مشاهده شده، pre , P_{sim} و $Z^*(x_i)$ مقادیر برآورد شده و n تعداد داده‌ها می‌باشند.

۴- یافته‌های پژوهش و تحلیل خروجی‌ها

۴-۱- پیش‌بینی ماهانه خشک‌سالی

متغیرهای مؤثر در خشک‌سالی ماهانه به ترتیب اعمال در شبکه‌ها شامل کمینه نم، بیشینه‌ی دما، کمینه‌ی دما، کمینه‌ی نم با ۱ ماه تأخیر، میانگین نم، بیشینه‌ی نم، بیشینه‌ی نم با ۱ ماه تأخیر، میانگین نم با ۱ ماه تأخیر، بیشینه‌ی دما با ۵ ماه تأخیر، میانگین دما با ۶ ماه تأخیر می‌باشند. همبستگی این متغیرها با شاخص SPI در جدول ۲ نشان داده شده است. نکته این‌که هیچ کدام از الگوهای پیوند از دور و تأخیر زمانیشان تأثیر مثبتی در مدل‌ها نداشتند و متغیرهای نم‌نسبی و دما اساس مدل‌سازی پیش‌بینی ماهانه خشک‌سالی را تشکیل داده‌اند. چهار ورودی نخست توسط مدل رگرسیونی با روش گام به گام انتخاب شده‌اند و سایر ورودی‌ها بر اساس ارزش همبستگی که با شاخص SPI داشته‌اند به شبکه اعمال شده‌اند.

جدول ۲- همبستگی متغیرهای مورد استفاده در مدل‌های ماهانه با شاخص SPI


متغیر شاخص	کمینه نم‌نسبی	بیشینه دما	کمینه دما	کمینه نم با ۱ ماه تأخیر	متوسط نم‌نسبی
SPI	۰/۶۴۴	-۰/۵۲	-۰/۳۷	۰/۳۹۶	۰/۶۵۴
متغیر شاخص	بیشینه نم‌نسبی	بیشینه نم با ۱ ماه تأخیر	متوسط نم با ۱ ماه تأخیر	بیشینه دما با ۵ ماه تأخیر	متوسط دما با ۶ ماه تأخیر
SPI	۰/۶۴۱	۰/۴۲۹	۰/۴۱۸	۰/۲۷۵	۰/۴۰۱

پس از تشکیل انبوه مدل‌ها، ۸ مدل از شبکه‌ی $Radial Basis$ و ۱۰ مدل از شبکه‌ی پس انتشار به عنوان مدل‌های مناسب انتخاب شدند (جدول ۳). در بین مدل‌های منتخب $Radial Basis$ ، مدل $RBF6$ با ۵ ورودی و یک لایه پنهان ۱۰ نرونی به عنوان مدل بهینه انتخاب شد. مدل مزبور بالاترین ضریب تعیین ($R2$) ۰/۶۸۱۶ و کمترین خطا را در مرحله‌ی آزمایش ایجاد کرد، البته نتایج مرحله آموزش در غالب مدل‌ها نزدیک به هم بود. در بین مدل‌های برگزیده شبکه‌ی پس انتشار، مدل $BP9$ به عنوان مدل برگزیده انتخاب شد. این مدل ضریب تعیین ۰/۶۹۸۷ را در مرحله آزمایش با خطای کمتر ایجاد کرد البته نتایج مدل $BP8$ در این مرحله اندکی بهتر بود، ولی نتایج مدل $BP9$ در مرحله‌ی آموزش بسیار مناسب‌تر از مدل $BP8$ می‌باشد. نمودار پیش‌بینی مدل‌های برگزیده همراه با نتایج پیش‌بینی مدل رگرسیون جهت مقایسه در شکل ۱۰ نشان داده شده است. داده‌های پیش‌بینی مدل رگرسیون با استفاده از روش $Enter$ برآورد شده است. ضریب تعیین مدل رگرسیون ۰/۶۶۸۸، $RMSE$ ۰/۶۲۱۸ و مقدار MAE ۰/۰۴۶۳ برآورد شد.

جدول ۳- مشخصات مدل‌های برگزیده در مدل شبکه‌ی عصبی در بازه‌ی زمانی یک ماهه

مرحله آزمایش			مرحله آموزش			مشخصات مدل‌های برگزیده			
MAE	RMSE	R2	MAE	RMSE	R2	تعداد نرون	تعداد لایه پنهان	تعداد ورودی	مدل
۰/۰۴۶۲	۰/۶۲۰۳	۰/۶۶۰۸	۰/۰۱۵۴	۰/۳۱۶۲	۰/۸۸۵۱	۱۰	۱	۴	RBF1
۰/۰۵۰۱	۰/۶۷۲	۰/۶۴۳۸	۰/۰۱۴۲	۰/۲۹۱۱	۰/۹۰۳۶	۱۰	۲	۴	RBF2
۰/۰۴۸	۰/۶۴۴۱	۰/۶۴۷۲	۰/۰۱۳۸	۰/۲۸۲۸	۰/۹۰۸۴	۱۵	۲	۴	RBF3

مرحله آزمایش			مرحله آموزش			مشخصات مدل‌های برگزیده			
MAE	RMSE	R2	MAE	RMSE	R2	تعداد نرون	تعداد لایه پنهان	تعداد ورودی	مدل
۰/۰۴۶۴	۰/۱۶۲۲۱	۰/۱۶۵۶۲	۰/۰۱۳۶	۰/۲۷۹۷	۰/۹۱۰۶	۲۰	۲	۴	RBF4
۰/۰۴۸۲	۰/۱۶۴۷۳	۰/۱۶۳۰۴	۰/۰۱۳۸	۰/۲۸۲۶	۰/۹۰۸۴	۲۵	۱	۴	RBF5
۰/۰۴۵۴	۰/۱۶۰۹۴	۰/۱۶۸۱۶	۰/۰۱۵۴	۰/۳۱۵۶	۰/۸۸۵۴	۱۰	۱	۵	RBF6
۰/۰۴۶	۰/۱۶۱۶۸	۰/۱۶۶۰۶	۰/۰۱۵۳	۰/۳۱۲۶	۰/۸۹۰۴	۱۰	۲	۵	RBF7
۰/۰۴۷۴	۰/۱۶۳۶۲	۰/۱۶۵۳۵	۰/۰۱۴۲	۰/۲۹۰۹	۰/۹۰۳	۱۰	۲	۱۰	RBF8
۰/۰۴۳۹	۰/۱۵۸۸۶	۰/۱۶۸۹۴	۰/۰۱۳۲	۰/۲۷۰۸	۰/۹۱۶	۱۰	۳	۴	BP1
۰/۰۴۵۵	۰/۱۶۱۰۵	۰/۱۶۷۱۷	۰/۰۱۳۸	۰/۲۸۲۶	۰/۹۰۸	۱۵	۱	۴	BP2
۰/۰۴۶۵	۰/۱۶۲۳۳	۰/۱۶۵۷۷	۰/۰۱۳۲	۰/۲۷۱۲	۰/۹۱۵۶	۲۰	۲	۴	BP3
۰/۰۴۴۹	۰/۱۶۰۲۴	۰/۱۶۸۹۷	۰/۰۱۴۷	۰/۳۰۱۳	۰/۸۹۶	۱۰	۲	۱۰	BP4
۰/۰۴۵۶	۰/۱۶۱۲۵	۰/۱۶۷۴۸	۰/۰۱۴۹	۰/۳۰۴۷	۰/۸۹۶۲	۱۰	۳	۱۰	BP5
۰/۰۴۵	۰/۱۶۰۳۹	۰/۱۶۷۹۸	۰/۰۱۵۱	۰/۳۱۰۴	۰/۸۸۹۴	۱۰	۴	۱۰	BP6
۰/۰۴۵۹	۰/۱۶۱۶۳	۰/۱۷۰۵۷	۰/۰۱۴	۰/۲۸۶	۰/۹۰۷۸	۱۰	۵	۱۰	BP7
۰/۰۴۳۴	۰/۱۵۸۲۶	۰/۱۷۲۳۳	۰/۰۱۵	۰/۳۰۸۳	۰/۸۹۵۶	۱۰	۶	۱۰	BP8
۰/۰۴۳۴	۰/۱۵۸۲۸	۰/۱۶۹۸۷	۰/۰۰۸۳	۰/۱۷۰۲	۰/۹۶۸	۱۵	۲	۱۰	BP9
۰/۰۴۶	۰/۱۶۱۷	۰/۱۶۶۳۵	۰/۰۱۲۷	۰/۲۵۹۴	۰/۹۲۲۷	۱۵	۳	۱۰	BP10



شکل ۱۰ - مقایسه‌ی مدل‌های ماهانه برگزیده شبکه‌ی عصبی با داده‌های واقعی و مدل رگرسیون

۴-۲- پیش‌بینی سه ماهه خشک‌سالی

در بازه‌ی زمانی سه ماهه داده‌های مؤثر در مدلسازی شامل بیشینه‌ی نم‌نسبی سه ماهه، میانگین نم‌نسبی سه ماهه با ۳ فصل تأخیر، شاخص بارش موسمی جنوب غربی با ۴ فصل تأخیر، شاخص بارش موسمی جنوب غربی با ۲ فصل تأخیر، میانگین نم‌نسبی سه ماهه، کمینه‌ی نم‌نسبی سه ماهه، بیشینه‌ی نم‌نسبی سه ماهه با ۴ فصل تأخیر، میانگین نم‌نسبی سه ماهه با ۴ فصل تأخیر می‌باشند. همبستگی این ورودی‌ها با شاخص *SPI* در جدول ۴ نشان داده شده است.

جدول ۴ - همبستگی متغیرهای مورد استفاده در مدل‌های سه ماهه با شاخص *SPI*

شاخص	متغیر	بیشینه‌ی نم‌نسبی	متوسط نم با ۳ فصل تأخیر	SW Monsoon با ۴ فصل تأخیر	SW Monsoon با ۲ فصل تأخیر
SPI		۰/۷۳۱	-۰/۱۸	-۰/۱۷۶	۰/۵۳۹
شاخص	متغیر	متوسط نم‌نسبی	کمینه‌ی نم‌نسبی	بیشینه‌ی نم با ۴ فصل تأخیر	متوسط نم با ۴ فصل تأخیر
SPI		۰/۷۰۹	۰/۶۶۵	۰/۵۸۸	۰/۵۵


چهار ورودی نخست توسط مدل رگرسیونی با روش گام به گام انتخاب شده‌اند و سایر ورودی‌ها بر اساس بیش‌ترین ارزش همبستگی با شاخص *SPI* به شبکه اعمال شده‌اند. پس از تشکیل مدل‌های فراوان، ۸ مدل شبکه‌ی *Radial Basis* و ۱۰ مدل در شبکه‌ی پس انتشار مدل‌های مناسب شناخته شدند (جدول ۵).

جدول ۵ - مشخصات مدل‌های برگزیده‌ی در مدل شبکه‌ی عصبی در بازه‌ی زمانی سه ماهه

مرحله آزمایش			مرحله آموزش			مشخصات مدل‌های برگزیده			
MAE	RMSE	R2	MAE	RMSE	R2	تعداد نرون	تعداد لایه پنهان	تعداد ورودی	مدل
۰/۰۷۸	۰/۶۰۴	۰/۶۹۱	۰/۰۲۱۴	۰/۲۵۲۸	۰/۹۳۲۳	۱۰	۱	۵	RBF1
۰/۰۸۶۳	۰/۶۶۸۳	۰/۷۱۲۳	۰/۰۲۲۳	۰/۲۶۳۶	۰/۹۲۶	۱۵	۱	۵	RBF2
۰/۰۷۷۵	۰/۶۰۰۱	۰/۷۲۶۴	۰/۰۲۲۱	۰/۲۶۱	۰/۹۲۶۸	۲۵	۱	۵	RBF3
۰/۰۸۸۱	۰/۶۸۲۵	۰/۶۹۷۵	۰/۰۲۰۹	۰/۲۴۷۵	۰/۹۳۴۳	۳۰	۱	۵	RBF4
۰/۰۷۶۲	۰/۵۹۰۵	۰/۷۰۳۹	۰/۰۲۲۲	۰/۲۶۲۵	۰/۹۲۵۸	۱۵	۱	۶	RBF5
۰/۰۷۶۶	۰/۵۹۳۳	۰/۷۲۱۳	۰/۰۲۱۷	۰/۲۵۷۳	۰/۹۲۹۶	۲۰	۱	۶	RBF6
۰/۰۸۱۸	۰/۶۳۳۸	۰/۶۹۲۲	۰/۰۲۲	۰/۲۶۰۵	۰/۹۲۸۹	۳۰	۱	۶	RBF7
۰/۰۸۲۷	۰/۶۴۰۷	۰/۶۹۱۲	۰/۰۲۱۷	۰/۲۵۶۸	۰/۹۳۲۴	۱۵	۱	۸	RBF8
۰/۰۷۱۲	۰/۵۵۱۷	۰/۷۸۸۷	۰/۰۲۱۱	۰/۲۴۹۵	۰/۹۳۳۳	۱۵	۳	۴	BP1
۰/۰۶۲۳	۰/۴۸۲۴	۰/۸۱۰۲	۰/۰۲۰۹	۰/۲۴۷۸	۰/۹۳۴۵	۱۰	۲	۶	BP2
۰/۰۵۹۹	۰/۴۶۳۸	۰/۸۲۰۵	۰/۰۲۱۴	۰/۲۵۳۳	۰/۹۳۱۶	۱۰	۳	۶	BP3
۰/۰۶۰۵	۰/۴۶۸۸	۰/۸۲۲۳	۰/۰۱۷۵	۰/۲۰۶۷	۰/۹۵۴۳	۱۰	۴	۶	BP4
۰/۰۶۱۵	۰/۴۷۶۲	۰/۸۰۹۳	۰/۰۲۲۱	۰/۲۶۱۵	۰/۹۲۶۶	۱۰	۵	۶	BP5
۰/۰۵۸۲	۰/۴۵۳۳	۰/۸۳۰۶	۰/۰۱۹	۰/۲۲۴۸	۰/۹۴۶۳	۱۵	۲	۶	BP6

مرحله آزمایش			مرحله آموزش			مشخصات مدل‌های برگزیده			
MAE	RMSE	R2	MAE	RMSE	R2	تعداد نرون	تعداد لایه پنهان	تعداد ورودی	مدل
۰/۰۶۲۲	۰/۴۸۱۶	۰/۸۰۲۴	۰/۰۲۲۳	۰/۲۶۳۴	۰/۹۲۵۴	۱۵	۳	۶	BP7
۰/۰۶۲۵	۰/۴۸۵۱	۰/۸۱۶۳	۰/۰۲۰۸	۰/۲۴۶۳	۰/۹۴۲۲	۲۰	۲	۶	BP8
۰/۰۶۶۵	۰/۵۱۵	۰/۷۹۱۴	۰/۰۲۲	۰/۲۶۰۷	۰/۹۲۷۵	۱۰	۲	۸	BP9
۰/۰۷۴۲	۰/۵۷۵۱	۰/۷۹۰۳	۰/۰۱۷۹	۰/۲۱۱۸	۰/۹۵۳۳	۱۵	۲	۸	BP10

از میان مدل‌های برگزیده *Radial Basis* مدل *RBF6* با ۶ ورودی و یک لایه پنهان ۲۰ نرونی مناسب‌ترین مدل شناخته شد. نتایج مدل *RBF3* بسیار نزدیک به مدل برگزیده می‌باشد، ولی در مجموع مدل *RBF6* نتایج مناسب‌تری ارائه داد. در بین مدل‌های شبکه‌ی پس انتشار، مدل *BP6* با ۶ ورودی و دو لایه پنهان ۱۵ نرونی مناسب‌ترین مدل شناخته شد. این مدل با ضریب تعیین $0/8306$ و کمترین خطا در مرحله‌ی آزمایش به عنوان مدل بهینه انتخاب شد. نمودار پیش‌بینی مدل‌های برگزیده همراه با نتایج پیش‌بینی مدل رگرسیون جهت مقایسه در شکل ۱۱ نشان داده شده است. داده پیش‌بینی مدل رگرسیون با استفاده از روش Enter برآورد شده است. ضریب تعیین مدل رگرسیون $0/743$ ، *RMSE* $0/8661$ و مقدار *MAE* $0/1118$ برآورد شد.



شکل ۱۱ - مقایسه مدل‌های سه ماهه برگزیده شبکه عصبی با داده‌های واقعی و مدل رگرسیون

۴-۲- پیش‌بینی دوازده ماهه‌ی خشکسالی

جهت پیش‌بینی سالانه‌ی خشکسالی از داده‌های بیشینه‌نم‌نسبی سالانه، شاخص *Nino3* سالانه، بیشینه‌ی دمای سالانه، میانگین دمای سالانه با ۱ سال تأخیر، بارش سالانه با ۱ سال تأخیر و شاخص *Nino1+2* استفاده شد، همبستگی این ورودی‌ها با شاخص *SPI* در جدول ۶ نشان داده شده است.


جدول ۶ - همبستگی متغیرهای مورد استفاده در مدل‌های سالانه با شاخص SPI

متغیر شاخص	بیشینه‌نم‌نسبی سالانه	<i>Nino3</i>	بیشینه دمای سالانه
<i>SPI</i>	۰/۴۷۹	۰/۴۱۲	-۰/۴۲۹
متغیر شاخص	متوسط دمای سال قبل	بارش سال قبل	<i>Nino1+2</i>
<i>SPI</i>	-۰/۰۵۹	۰/۳۲۸	۰/۴۱۹

از میان انبوه مدل‌ها در بازه زمانی ۱۲ ماهه، ۷ مدل در شبکه‌ی *Radial Basis* و ۷ مدل در شبکه‌ی پس انتشار به عنوان مدل‌های برگزیده انتخاب شدند (جدول ۷). از بین مدل‌های منتخب *Radial Basis* مدل *RBF5* با ۶ ورودی و یک لایه پنهان ۳۰ نرونی، مدل بهینه شناخته شد، ضریب تعیین ۰/۷۹۲۶ و خطای کم در مرحله‌ی تست و ضریب تعیین بسیار بالا و خطای بسیار کم در مرحله‌ی آموزش از دلایل انتخاب این مدل به عنوان مناسب‌ترین مدل است. در بین انواع مدل‌های شبکه‌ی پس انتشار، مدل *BP5* با ۶ ورودی و چهار لایه پنهان ۱۵ نرونی، مدل بهینه شناخته شد، پیش‌بینی مدل رگرسیونی نیز ضریب تعیین ۰/۶۴، *RMSE* ۰/۶۳۴۲ و *MAE* ۰/۱۶۳۸ تولید کرد. در شکل ۱۲ نتایج مدل‌های برگزیده و مدل رگرسیونی مقایسه شده است.

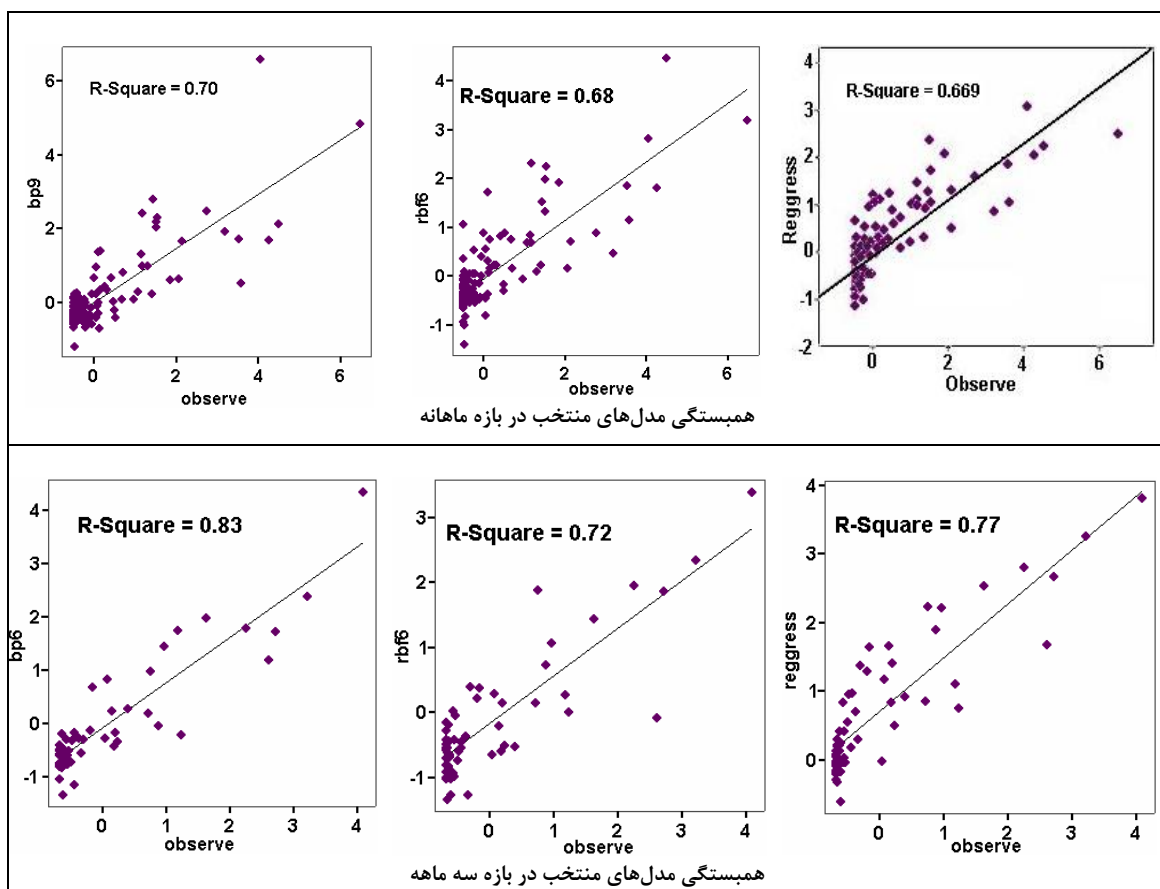
جدول ۷ - مشخصات مدل‌های برگزیده در مدل شبکه عصبی در بازه زمانی دوازده ماهه (سالانه)

مرحله آزمایش			مرحله آموزش			مشخصات مدل‌های برگزیده			مدل
MAE	RMSE	R2	MAE	RMSE	R2	تعداد نرون	تعداد لایه پنهان	تعداد ورودی	
۰/۲۶	۱/۰۰۶۹	۰/۶۹۷	۰/۰۱۶۴	۰/۰۹۶۹	۰/۹۹۰۸	۲۵	۱	۵	RBF1
۰/۳۰۴۴	۱/۱۷۸۸	۰/۷۰۷۸	۰/۰۱۳۴	۰/۰۷۹۲	۰/۹۹۴۸	۱۰	۱	۶	RBF2
۰/۱۲۴	۰/۴۸۰۱	۰/۷۷۳	۰/۰۱۲۱	۰/۰۷۱۹	۰/۹۹۶۲	۱۵	۱	۶	RBF3
۰/۱۴۰۲	۰/۵۴۲۹	۰/۷۸۹۸	۰/۰۳۱۶	۰/۱۸۷	۰/۹۶۵۹	۲۰	۱	۶	RBF4
۰/۲۲۹۸	۰/۸۹۰۱	۰/۷۹۲۶	۰/۰۰۳۱	۰/۰۱۸۱	۰/۹۹۹۸	۳۰	۱	۶	RBF5
۰/۳۱۰۸	۱/۲۰۲۷	۰/۷۴۹۶	۰/۰۰۳۱	۰/۰۱۸۶	۰/۹۹۹۶	۳۵	۱	۶	RBF6
۰/۱۵۸۷	۰/۶۱۴۸	۰/۷۰۸۶	۰/۰۳۷۴	۰/۲۲۱۴	۰/۹۵۷۴	۴۰	۱	۶	RBF7
۰/۱۷۷۱	۰/۶۸۶	۰/۶۷۹۳	۰/۰۲۱۲	۰/۱۲۵۲	۰/۹۸۶	۱۵	۲	۵	BP1
۰/۲۳۹۳	۰/۹۲۶۹	۰/۷۳۹۴	۰/۰۲۶۴	۰/۱۵۶۵	۰/۹۷۹۳	۱۵	۴	۵	BP2
۰/۲۱۸۳	۰/۸۴۵۳	۰/۷۰۸۴	۰/۰۲۷۵	۰/۱۶۲۵	۰/۹۷۷۹	۲۰	۲	۵	BP3
۰/۱۶۲۵	۰/۶۲۹۵	۰/۷۱۳	۰/۰۳۷۷	۰/۲۲۲۸	۰/۹۷۳۷	۱۰	۲	۶	BP4
۰/۱۱۹۴	۰/۴۶۲۴	۰/۷۸۹۲	۰/۰۲۳۹	۰/۱۴۱۴	۰/۹۸۱۷	۱۵	۴	۶	BP5
۰/۲۴۰۳	۰/۹۳۰۵	۰/۷۵۱۳	۰/۰۳۷۸	۰/۲۲۳۴	۰/۹۵۰۶	۱۵	۵	۶	BP6
۰/۲۲۸۷	۰/۸۸۵۶	۰/۶۹۷۷	۰/۰۲۴۳	۰/۱۴۳۸	۰/۹۸۱۷	۲۰	۳	۶	BP7




شکل ۱۲ - مقایسه‌ی مدل‌های دوازده ماهه برگزیده شبکه‌ی عصبی با داده‌های واقعی و مدل رگرسیون

در شکل ۱۳ نیز همبستگی مدل‌های برگزیده شبکه‌ی عصبی و مدل رگرسیونی در بازه‌های زمانی سه‌گانه نشان داده شده است.



همبستگی مدل‌های منتخب در بازه ماهانه

همبستگی مدل‌های منتخب در بازه سه ماهه



شکل ۱۳ - مقایسه‌ی همبستگی مدل‌های منتخب ANN و مدل رگرسیون (از راست مدل رگرسیون، *RBF* و *BP*)

۵ - نتیجه گیری

خشک‌سالی از جمله حوادث طبیعی است که نواحی مختلف همواره در معرض خطر آن قرار دارند. با توجه به توانایی *ANN*‌ها در پیش‌بینی رخداد‌های طبیعی استفاده از این روش جهت پیش‌بینی و شبیه‌سازی به طور گسترده‌ای شیوع پیدا کرده است. در این تحقیق خشک‌سالی شهر خاش در سه بازه زمانی ماهانه، سه ماهه و دوازده ماهه توسط شبکه‌ی *Radial Basis* و پس انتشار پیش‌بینی شد و نتایج مدل رگرسیونی نیز جهت نشان دادن عملکرد شبکه و مقایسه ذکر شده است.

نتایج مدلسازی‌ها نشان داد که پیش‌بینی خشک‌سالی در بازه‌ی زمانی سه ماهه و دوازده ماهه به مراتب بهتر از پیش‌بینی ماهانه خشک‌سالی است. در پیش‌بینی ماهانه و سه ماهه خشک‌سالی شبکه‌های پس انتشار نتایج بهتری ارائه دادند. در پیش‌بینی سه ماهه خشک‌سالی شبکه‌های پس انتشار عملکرد خیلی خوبی داشت. به طوری که مدل *BP6* ضریب تعیین (R^2) با داده‌های واقعی ایجاد کرد (جدول ۵). نتایج مدل رگرسیونی در این بازه زمانی اندکی بهتر از شبکه‌ی *RBF* بود، ولی نسبت به شبکه پس انتشار نتایج مدل رگرسیونی ضعیف‌تر بود. نتایج شبکه‌ی *RBF* برای پیش‌بینی دوازده ماهه‌ی خشک‌سالی اندکی بهتر از شبکه‌ی پس انتشار بود (جدول ۷). ولی در مجموع پیش‌بینی سه ماهه خشک‌سالی با شبکه پس انتشار با دو لایه پنهان ۱۵ نرونی و با ورودی‌های بیشینه‌نم‌نسبی سه ماهه، میانگین نم‌نسبی سه ماهه با ۳ فصل تأخیر، شاخص بارش موسمی جنوب غربی با ۴ فصل تأخیر، شاخص بارش موسمی جنوب غربی با ۲ فصل تأخیر، میانگین نم‌نسبی سه ماهه، کمینه‌نم‌نسبی سه ماهه مناسب‌ترین مدل جهت پیش‌بینی خشک‌سالی در شهر خاش شناخته شد. نقش شاخص‌های اقلیمی در پیش‌بینی سه ماهه و دوازده ماهه خشک‌سالی کاملاً مشخص است. شاید علت اینکه شاخص‌های اقلیمی در بازه‌ی زمانی ماهانه مطرح نیستند به خاطر تأثیر دیر هنگام آن‌ها بر منطقه باشد. از دیگر نکاتی که منتج از تحلیل خروجی‌ها بود اینکه ورودی‌هایی که همبستگی بالایی داشتند در بهبود نتایج مدل‌های شبکه‌ی عصبی بسیار مؤثر بودند. در حالی که در مدل رگرسیونی فقط یک تا دو ورودی که بالاترین همبستگی را داشتند بسیار مؤثر بودند و ورودی‌های دیگر علی‌رغم داشتن همبستگی بالا تأثیر زیادی در بهبود مدل رگرسیونی نداشتند.

۶- فهرست منابع

- (۱) اختری، روح انگیز، محمدحسین مهدیان و سعید مرید (۱۳۸۵)، تحلیل مکانی شاخص‌های خشک‌سالی *SPI* و *EDI* در استان تهران، مجله‌ی تحقیقات منابع آب ایران، سال دوم، شماره ۳، صص ۳۸ - ۲۷.
- (۲) اعلمی، محمدتقی، یوسف حسین‌زاده و مهدی کماسی (۱۳۸۸)، ارزیابی و مقایسه نمایه‌های خشک‌سالی و پیش‌بینی آن با شاخص *SPI* به روش مدل‌سازی دو متغیره با شبکه‌ی عصبی - مصنوعی، هشتمین سمینار بین‌المللی مهندسی رودخانه.
- (۳) افخمی، حمیده، محمدتقی دستورانی، حسین ملکی نژاد و حسین مبین (۱۳۸۹)، بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه‌ی عصبی مصنوعی در پیش‌بینی خشک‌سالی منطقه‌ی یزد، مجله‌ی علوم و فنون کشاورزی و منابع طبیعی، جلد ۱۴، شماره ۵۱، صص ۱۷۰-۱۵۷.
- (۴) خوشحال دستجردی، جواد و سیدمحمد حسینی (۱۳۸۹)، کاربرد شبکه‌ی عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشک‌سالی (مطالعه‌ی موردی: استان اصفهان)، مجله‌ی جغرافیا و برنامه‌ریزی محیطی، سال ۲۱، پیاپی ۳۹، شماره ۳، صص ۱۲۰-۱۰۷.
- (۵) سلاجقه، علی، ابوالحسن فتح‌آبادی و منصور نجفی حاجی‌ور (۱۳۸۷)، مقایسه‌ی شبکه‌ی عصبی و سری‌های زمانی در پیش‌بینی خشک‌سالی (مطالعه‌ی موردی: استان خراسان رضوی)، مجله‌ی علوم و مهندسی آب‌خیزداری ایران، سال دوم، شماره ۴، صص ۷۷-۷۴.
- (۶) صداقت‌کردار، عبدالم... و ابراهیم فتاحی (۱۳۸۷)، شاخص‌های پیش‌آگاهی خشک‌سالی در ایران، مجله‌ی جغرافیا و توسعه، شماره ۱۱، صص ۷۶-۵۹، زاهدان.
- (۷) عزیززاده، امین (۱۳۸۱)، اصول هیدرولوژی کاربردی، چاپ چهاردهم، مشهد: انتشارات آستان قدس رضوی.
- (۸) عیوضی، معصومه، ابوالفضل مساعدی و امیراحمد دهقانی (۱۳۸۸)، مقایسه‌ی روش‌های مختلف پیش‌بینی شاخص خشک‌سالی *SPI*، مجله‌ی پژوهش‌های حفاظت آب و خاک، جلد ۱۶، شماره دوم، صص ۱۶۷-۱۴۵.
- (۹) فرج‌زاده، منوچهر (۱۳۸۹)، تکنیک‌های اقلیم‌شناسی، چاپ سوم، انتشارات سمت، تهران.
- (۱۰) فرخ‌نیا، اشکان، سعید مرید و هوشنگ قائمی (۱۳۸۹)، داده‌کاوی روی سیگنال‌های بزرگ مقیاس اقلیمی برای پیش‌بینی بلندمدت خشک‌سالی، سومین کنفرانس مدیریت منابع آب.
- (۱۱) کاویانی، محمدرضا و بهلول علیجانی (۱۳۷۸)، مبانی آب و هواشناسی، چاپ ششم، تهران: انتشارات سمت.
- (۱۲) کیا، مصطفی (۱۳۸۷)، شبکه‌های عصبی در *MATLAB*، تهران: انتشارات کیان رایانه.
- (۱۳) منهج، محمدباقر (۱۳۸۷)، مبانی شبکه‌های عصبی - هوش محاسباتی، جلد اول، چاپ پنجم، تهران: انتشارات دانشگاه صنعتی امیرکبیر.
- (۱۴) نصیری، مریم (۱۳۸۹)، پیش‌بینی خشک‌سالی با استفاده از شبکه‌های عصبی مصنوعی مطالعه موردی ایستگاه سینوپتیک شیراز، پایان‌نامه‌ی کارشناسی ارشد اقلیم‌شناسی، دانشگاه سیستان و بلوچستان.
- (۱۵) نیک‌نام، حسین، اژدری مقدم، مهدی و محمود خسروی (۱۳۸۹)، استفاده از مدل فازی - عصبی و الگوهای ارتباط از دور جهت پیش‌بینی خشک‌سالی مطالعه‌ی موردی زاهدان، چهارمین کنگره بین‌المللی جغرافیدانان جهان اسلام، زاهدان.
- (16) Barua Shishutosh (2010), *Drought Assessment and Forecasting Using a Nonlinear Aggregated Drought Index*, M.Sc. (Water), Engineering and Science Victoria University, Australia.

- (17) Barua, Shishutosh and Perera, B. J. C, A. W. M. Ng and Tran, D. H (2010), **Drought forecasting using an aggregated drought index and artificial neural networks**, *Journal of water and climate change*, 1 (3), pp.193-206.
- (18) Cutore P, Di Mauro G, Cancelliere A (2009), **Forecasting Palmer Index Using Neural Network and Climatic Indexes**, *Journal of Hydrologic Engineering/ vol 14/ Issue 6*, pp. 588-595.
- (19) Hayes, Michael J.; Svoboda, Mark. D.; Wilhite, Donald A.; Vanyarkho, Olga V. (1999), **Monitoring the 1996 Drought Using the Standardized Precipitation Index**, *National Drought Mitigation Center, Vol. 80, No. 3*, pp. 429-438.
- (20) <http://www.cdc.noaa.gov/ClimateIndices/List/>, (2011).
- (21) Juan Camilo, Ochoa-Rivera (2008), **Prospecting droughts with stochastic artificial neural networks**, *Journal of Hydrology, Vol 352, Issues 1-2*, pp. 174-180.
- (22) Mishra A.K, Desai V.R (2006), **Drought forecasting using feed-forward recursive neural network**, *ecological modeling, vol.198*, pp.127-138.
- (23) Mishra A.K, Desai V.R, Singh P(2007), **Drought Forecasting Using a Hybrid Stochastic and Neural Network Model**, *Journal of Hydrologic Engineering, Vol. 12, No. 6*, pp. 626-638.
- (24) Morid S, Smakhtin V, Bagherzadeh K(2007), **Drought forecasting using artificial neural networks and time series of drought indices**, *International Journal of Climatology, Vol. 27*, pp. 2103-2111.
- (25) Santos, Celso Augusto G; Morais, Bruno S; Silva, Gustavo B L(2009), **Drought forecast using an artificial neural network for three hydrological zones in San Francisco River basin, Brazil**, *Proceedings of Symposium HS.2 at the Joint Convention of The International Association of Hydrological Sciences (IAHS) and The International Association of Hydrogeologists (IAH), No.333, Hyderabad, India*, pp. 302-312.