

تحلیل و پیش‌بینی روزهای خشک با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه تهران)

حسین عساکره^۱
فریبا صیادی^۲

چکیده

شبکه‌های عصبی مصنوعی به‌عنوان یکی از تکنیک‌های غیرخطی در مطالعات اقلیمی و هیدرولوژی اهمیت فراوانی به‌خود اختصاص داده‌اند. تغییر اقلیم و به‌دنبال آن گرمایش جهانی از پدیده‌های اقلیمی به‌شمار می‌رود. شمار روزهای خشک و تداوم آن خشکسالی را به‌دنبال دارد. در این پژوهش از داده‌های بارش روزانه طی سال‌های (۱۹۷۶-۲۰۰۸) و شبکه عصبی مصنوعی در نرم‌افزار MATLAB به‌منظور پیش‌بینی شمار روزهای خشک ایستگاه تهران استفاده شده است. شبکه به‌کار رفته از نوع Feed-forward با الگوریتم کاهش شیب و مارکوارت لوبزگ در مرحله آموزش و یادگیری می‌باشد. ساختارهای گوناگونی در لایه ورودی و پنهان در مرحله آموزش مورد آزمایش قرار گرفت. در نهایت شبکه با ۴ ورودی و ۵ نرون در لایه پنهان و ۱ نرون در لایه خروجی به مطلوب‌ترین ساختار (۱-۵-۴) جهت پیش‌بینی بهینه با بیش‌ترین همبستگی پاسخ داد. نتایج نشان داد که در ایستگاه مذکور، روزهای خشک پیش‌بینی شده توسط شبکه در مقایسه با طول دوره آماری مورد بررسی دارای روند افزایشی بوده است که با محاسبه احتمال وقوع روزهای خشک، طی سال‌های (۲۰۰۹-۲۰۱۸) با استفاده از زنجیره مارکوف، موارد فوق تأیید گردیده است. ضریب همبستگی مقادیر پیش‌بینی روزهای خشک بدون ترکیب با الگوریتم ژنتیک ۸۶ درصد است. بعد از آموزش شبکه با ترکیب الگوریتم ژنتیک با لایه‌های مختلف این مقدار به ۸۸ درصد رسید که می‌توان گفت در صورت ترکیب شبکه با الگوریتم مذکور نتایج قابل قبول ارائه می‌دهد.

واژگای کلیدی: شبکه عصبی مصنوعی، شبکه پیش‌خور، الگوریتم ژنتیک، پیش‌بینی روزهای خشک، تهران.

مقدمه

اخیراً با توجه به پیامدهای حاصل از تغییر اقلیم، متخصصان علوم زمین با استفاده از روش‌های مختلف درصدد مطالعه تغییری اقلیمی، آشکارسازی و کشف پیامدهای حاصل از آن هستند. از جمله روش‌هایی که به تازگی در مطالعه تغییرات سیستم زمین نقش مهمی بازی می‌کند، اهمیت کاربرد روش‌های غیرخطی زمانی آشکار می‌شود که بدانیم سامانه اقلیم یک سیستم غیرخطی بوده و فرایندهای اقلیمی ناشی از آن عناصر اقلیمی را در ردیف سری‌های زمانی آشوب‌مند و تصادفی قرار داده‌اند (خوشحال دستجردی و قویدل رحیمی، ۱۳۸۶: ۵). مطالعات گسترده‌ای از دهه ۲۰۰۰ در زمینه استفاده از شبکه‌های عصبی در پژوهش‌های اقلیمی و هیدرولوژی صورت گرفته که به مواردی اشاره شده است. راجورکار^۱ و همکاران (۲۰۰۴) به مدل‌سازی رابطه بارش و رواناب با استفاده از شبکه عصبی برای ۵ ایستگاه در حوضه هند پرداختند. افی موف و پوسوشکوف^۲ (۲۰۰۶) به پیش‌بینی بارش در دریای سیاه با استفاده از مدل شبکه عصبی در ماه‌های زمستان پرداختند که یافته‌های آن از بهره‌وری بالای روش A.N.N نسبت به روش بازکاوی برای شبیه‌سازی بارش حکایت می‌کند. ستاری^۳ و همکاران (۲۰۱۱) به منظور بررسی رابطه بارش و رواناب در رودخانه سوهو^۴ از مدل شبکه عصبی با الگوریتم پس‌انتشار^۵ استفاده کردند. مطالعاتی در زمینه استفاده از شبکه‌های عصبی توسط پژوهشگران ایرانی صورت گرفته است. پیره و فاتحی مرج (۱۳۹۰) به بررسی میزان توان تاثیرگذاری سیگنال‌های بزرگ مقیاس اقلیمی بر بارش نواحی مختلف ایران با استفاده از شبکه‌های عصبی مصنوعی پرداختند. خورشیددوست و همکاران (۱۳۹۱) به بازسازی سری زمانی دمای حداکثر و حداقل روزانه با استفاده از شبکه عصبی و روش نزدیک‌ترین همسایه غرب استان تهران پرداختند که نتایج نشان داد برای ۱۵ ایستگاه انتخابی روش شبکه متوسط خطای مطلق کمتری نسبت به نزدیک‌ترین همسایه

1- Rajurkar

2- Efimov and Pososhkov

3- Sattari


6- Sohu

7- back-Propagation

در تخمین دماهای مذکور دارد. نگارش و همکاران (۱۳۹۲) با استفاده از شبکه عصبی مصنوعی به پیش‌بینی سیلاب در حوضه آبریز سرپاز پرداختند که نتایج نشان داد که مدل شبکه عصبی توانایی بالاتری نسبت به مدل رگرسیون خطی در برآورد و پیش‌بینی سیلاب در حوضه مذکور دارد. در پژوهش مذکور، ضمن بهره‌گیری از شبکه عصبی مصنوعی Feed-Forward با ترکیب الگوریتم ژنتیک ۱- در شبکه‌های پیش‌خور، شبکه‌ها همانند مغز انسان جهت اتصالات به سمت جلو دارند و در شبکه مسیر بسته وجود ندارد، ۲- در پیش‌بینی عناصر جوی و اقلیمی با استفاده از شبکه، به دلیل قدرت تفکیک و نگهداری اطلاعات دیده‌بانی گذشته، معمولاً از این شبکه‌ها استفاده زیادی می‌گردد، ۳- با ترکیب این دو مدل میزان سرعت تحلیل داده‌ها بالاتر رفته و نهایتاً میزان خطا کمتر می‌شود، به پیش‌بینی تعداد روزهای خشک ایستگاه همدید تهران طی ده سال آینده (۲۰۱۸-۲۰۰۹) پرداخته شد.

تئوری ریاضی شبکه عصبی

در واقع شبکه عصبی مصنوعی یک مدل ریاضی-محاسباتی می‌باشد که بر اساس شبکه عصبی بیولوژیکی شبیه‌سازی شده است (Gao et al, 2010: 690). شکل (۱) ساختار شبکه عصبی طبیعی و مصنوعی را نشان می‌دهد.




شکل (۱) تصویری از یک نرون طبیعی (الف) و نرون مصنوعی (ب)

بنابراین هر شبکه عصبی دارای سه لایه ورودی^۸، مخفی^۹ و خروجی^{۱۰} می‌باشد که لایه ورودی می‌تواند شامل چند نرون باشد. لایه ورودی در واقع لایه است برای تهیه داده‌هایی که به عنوان ورودی به شبکه داده می‌شود. لایه خروجی شامل مقادیری است که توسط شبکه پیش‌بینی شده ولی لایه میانی (مخفی) محل تجزیه و تحلیل داده می‌باشد که معمولاً تعداد نرون‌های انتخابی این لایه با روش آزمایش و خطا به دست می‌آید.

شبکه‌های پس انتشار (پیش‌خور)^{۱۱}

شبکه پس انتشار یک شبکه چندلایه با تابع محرک غیرخطی و قاعده یادگیری ویدرو-هووف^{۱۲} می‌باشد و برای تقریب توابع، یافتن ارتباط بین ورودی و خروجی و دسته‌بندی ورودی‌ها بر اساس روش‌های تعیین شده توسط طراح استفاده می‌شوند. یک شبکه پس انتشار دارای بایاس^{۱۳}، یک لایه سیگموئید و یک لایه خروجی خطی توانایی تخمین زدن هر تابعی با نقاط ناپیوستگی محدود را داراست. بنابراین در شکل (۲) ساختار یک شبکه عصبی پس انتشار را نشان می‌دهد که نحوه قرارگیری و ترکیب عناصر تشکیل دهنده شبکه را می‌توان در آن دید.



شکل (۲) ساختار کلی شبکه عصبی پس انتشار

- 6- Input Layer
- 7- Hidden Layer
- 8- Output Layer
- 9- Feed Forward
- 10- Widrow-Hoff
- 11- Bias

توابع انتقال

معمولاً در نرون‌ها می‌توان از توابع مختلفی برای طراحی شبکه استفاده نمود ولی عموماً با توجه به تحقیقات اقلیم‌شناسی صورت گرفته در زمینه شبکه عصبی مصنوعی چند لایه از توابع سیگموئید، تانژانت-سیگموئید و خطی بیش‌تر استفاده می‌گردد.

تعداد تکرار^{۱۴}

یک دور (تکرار) معادل یک بار ارائه کل بردارهای آموزش است که معمولاً در شبکه‌های عصبی پس‌انتشار دوره‌های زیادی لازم است (ویسی و همکاران، ۱۳۸۸: ۵۰). در پژوهش حاضر به‌منظور دستیابی به همگرایی تا ۳۰۰۰ تکرار الگوریتم صورت گرفته است.

آموزش شبکه عصبی چندلایه

برای آموزش شبکه روش‌های گوناگونی از جمله: گرادینان مزدوج، شبه نیوتن، مارکوارت-لونبرگ و پس‌انتشار خطای استاندارد وجود دارد. از آن‌جا که هدف آموزش شبکه‌های عصبی پیش‌خور حداقل‌سازی مربعات خطا در حل یک مسئله بوده، بنابراین نیاز به یک الگوریتم بوده تا شبکه را سریع‌تر آموزش دهد.

الگوریتم مارکوارت-لونبرگ

این الگوریتم جزء تکنیک‌های استاندارد بهینه‌سازی عددی محسوب می‌شود که سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس هسیان^{۱۵} دارد. (کیا، ۱۳۸۷: ۹۱)

ترکیب شبکه عصبی پس‌انتشار با ژنتیک پروگرامینگ^{۱۶}

با توجه به این‌که در سال‌های اخیر از روش شبکه عصبی استفاده‌های گوناگونی در زمینه تحقیقات اقلیمی صورت گرفته در این تحقیق سعی شد با ترکیب شبکه با این

12- Epoch

15- Hessian

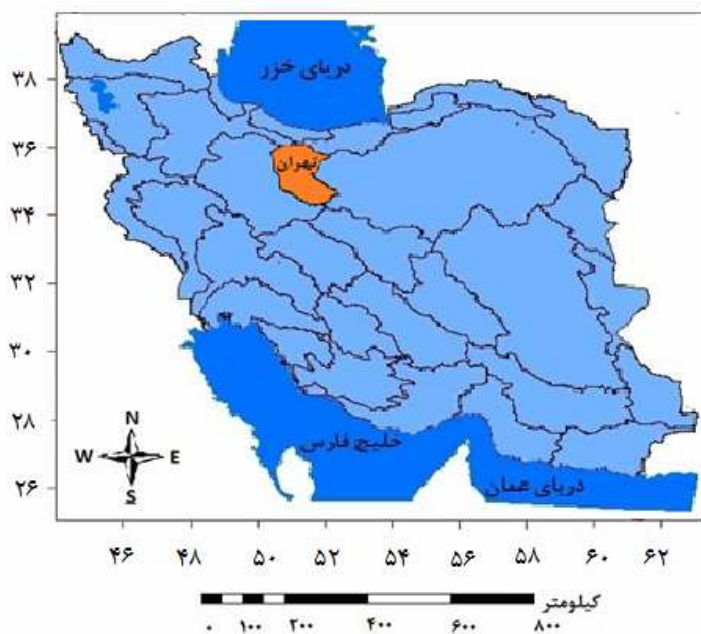
14- Genetic Programming

الگوریتم نتایج ملموس‌تری ارائه شود. الگوریتم ژنتیک تکنیک جستجویی در علم رایانه برای یافتن راه‌حل تقریبی برای بهینه‌سازی و مسائل جستجو است. الگوریتم ژنتیک نوع خاصی از الگوریتم‌های تکامل است که از تکنیک‌های زیست‌شناسی مانند وراثت و جهش استفاده می‌کند. در واقع الگوریتم‌های ژنتیک از اصول انتخاب طبیعی داروین برای یافتن فرمول بهینه جهت پیش‌بینی یا تطبیق الگو استفاده می‌کنند. در هوش مصنوعی الگوریتم ژنتیک یک تکنیک برنامه‌نویسی است که از تکامل ژنتیکی به‌عنوان یک الگوی حل مسئله استفاده می‌کند. مسئله‌ای که باید حل شود دارای ورودی‌هایی می‌باشد که طی یک فرآیند الگوبرداری شده از تکامل ژنتیکی به راه‌حل‌ها تبدیل می‌شود سپس راه‌حل‌ها به‌عنوان کاندیداها توسط تابع ارزیاب مورد ارزیابی قرار می‌گیرند و چنانچه شرط خروج مسئله فراهم شده باشد الگوریتم خاتمه می‌یابد. الگوریتم ژنتیک به‌طور کلی یک الگوریتم مبتنی بر تکرار است که اغلب بخش‌های آن به‌صورت فرآیندهای تصادفی انتخاب می‌شوند. الگوریتم ژنتیک که به‌عنوان یکی از روش‌های تصادفی بهینه‌یابی شناخته شده، توسط جان هالند در سال ۱۹۶۷ ابداع شده است. ژنتیک پروگرامینگ تکنیکی است که کامپیوترها را قادر می‌سازد تا به حل مسائل بپردازند بدون آنکه بطور صریح برای آن برنامه‌ریزی شده باشند. برای استفاده از الگوی ژنتیک در یک زمینه خاص، می‌بایست توابع پایه‌ای که در آن زمینه مورد نیاز هستند نظیر سینوس، کوسینوس و مربعات خطا و... به‌کار برده شوند که توسط کاربر تعریف می‌شود. آنگاه این الگوریتم در فضای بسیار بزرگ برنامه‌هایی که توسط این مقادیر اولیه قابل بیان هستند یک عمل جستجوی تکاملی را انجام خواهد داد.

مواد و روش‌ها

معرفی و شناسایی ویژگی‌های بارشی منطقه مورد مطالعه

شکل (۳) موقعیت منطقه مورد مطالعه در ایران را نشان می‌دهد. طول دوره آماری مورد بررسی شامل داده‌های بارش روزانه ایستگاه همدید تهران (فرودگاه مهرآباد) ۲۰۰۸-۱۹۷۶ می‌باشد.



شکل (۳) نقشه موقعیت تهران در ایران

در جدول (۱) برخی مشخصات بارشی ایستگاه تهران آورده شده است.

جدول (۱) برخی مشخصات آماری ایستگاه همدید تهران طی دوره آماری (۱۹۷۶-۲۰۰۸)

ایستگاه	میانگین بارش (میلی‌متر)	تعداد روزهای برفی	میانگین تعداد روزهای بدون بارش	تعداد روزهای بارش بیش از ۵ و بیش از ۱۰ میلی‌متر	ضریب تغییرات (درصد)	انحراف معیار
فرودگاه مهرآباد (تهران)	۲۵۲	۴۲۱	۱۱۵۰۷	۶۰۸	۲۹/۴	۷۴

معماری شبکه عصبی

با توجه به این‌که الگوریتم آموزش در شبکه‌های چندلایه از نوع پس‌انتشار خطا می‌باشد بنابراین محاسبات شبکه عصبی در وضعیت محاسبه پیش‌رو انجام گرفته است. برای آموزش

شبکه از الگوریتم پس‌انتشار استفاده گردیده است. معادله ریاضی محاسبه پیش‌رو به صورت زیر قابل بررسی است (خوشحال دستجردی و قویدل رحیمی، ۱۳۸۶: ۹).

$$\text{Net}_{pi} = \sum w_{ij} a_{pi} + b_i \quad (\text{رابطه ۱-۲})$$

که در این رابطه، α_{pi} مقدار خروجی لایه قبلی، W_{ij} وزن‌های لایه مربوطه و b_i میزان بایاس می‌باشد. (اندیس i ز برای نشان دادن هر نرون در شبکه استفاده می‌شوند. اندیس j برای نشان دادن لایه‌ای که نرون در آن قرار دارد و اندیس i نشان‌دهنده شماره نرون در یک لایه است. p متغیر مورد نظر است). سپس مقدار $f(\text{net}_{pi})$ محاسبه می‌شود که در آن f یک تابع محرک می‌باشد (خوشحال دستجردی و قویدل رحیمی، ۱۳۸۶: ۹).

$$f(\text{net}_{pi}) = (1 + \exp(-\text{net}_{pi})) \quad (\text{رابطه ۱-۳})$$

بنابراین برای پیش‌بینی باید مقادیر b_i و W_{ij} را با آزمایش و خطا طوری آموزش داد تا شبکه پیش‌بینی بهتری داشته باشد که در چنین حالتی باید محاسبات پس‌رو برای آموزش وزن‌ها و بایاس‌ها در نظر گرفت. اگر فرض کنیم که DD_{obc} روز خشک واقعی و DD_{pre} روزهای خشک پیش‌بینی شده باشد در این صورت محاسبات پیش‌رو به شکل زیر می‌باشد: (خوشحال دستجردی و قویدل رحیمی، ۱۳۸۶: ۱۰)

$$E = \sum_q (DD_{obc} - DD_{pre})^2 \quad (\text{رابطه ۱-۴})$$

در این رابطه ΔW_{ij} به مقدار W_{ij} برای آموزش اضافه می‌شود که در آن η نرخ یادگیری و عددی ثابت و مثبت است.

مراحل تحلیل شبکه

انتخاب داده‌های مورد استفاده در شبکه

در این پژوهش از داده‌های بارش روزانه ایستگاه همدید تهران طی دوره آماری (۲۰۰۸-۱۹۷۶) که از سازمان هواشناسی کشور تهیه گردیده استفاده شده است. در ادامه با توجه به طول دوره آماری زیاد برای انتخاب داده‌های ورودی به شبکه، با به‌کارگیری تکنیک تحلیل

طیفی چرخه‌های معنادار برای ایستگاه مذکور برآورد گردید. سپس ۴ چرخه معنادار مورد تشخیص قرار گرفت. این تحلیل به منظور تعیین تعداد ورودی‌ها به مدل شبکه عصبی انجام گرفت به این صورت که با استفاده از این تکنیک می‌توان نوسانات و چرخه‌هایی را در یک سری زمانی تشخیص داد. در این پژوهش ابتدا با استفاده از این تکنیک چرخه‌های ۴ ساله در داده‌های بارش به دست آمد. در نهایت، مجموع داده‌های مورد استفاده در شبکه برای ایستگاه مذکور با تأخیر ۴ ساله شامل: الف) در مرحله آموزش ۶۱۳۷ روز ب) مرحله اعتبارسنجی با ۲۰۵۴ روز پ) مرحله آزمون با ۲۰۵۴ روز در نظر گرفته شد. معمولاً تعداد لایه‌های پنهان در یک شبکه چند لایه، یک تا سه لایه می‌باشد و تعداد نرون‌های آن با آزمایش و خطا تا زمانی ادامه می‌دهیم که شبکه به یک جواب همگرا برسد در این صورت تعداد نرون‌های مخفی را کاهش داده در غیر این صورت تعداد نرون‌ها را می‌توان افزایش داد (منهاج، ۱۳۸۶: ۳۰). که در این پژوهش با ۵ نرون پنهان با آزمون و خطا، شبکه به همگرایی پاسخ مثبتی داد. در نهایت شبکه پس انتشار یک بار با ترکیب الگوریتم ژنتیک مورد آزمایش قرار گرفت.

یافته‌ها و بحث

مجموع داده‌های مورد استفاده در شبکه برای ایستگاه تهران شامل: در مرحله، الف) آموزش ۶۱۳۷ روز ب) اعتبارسنجی با ۲۰۵۴ روز پ) آزمون با ۲۰۵۴ روز

شبکه عصبی پس انتشار

برای ایجاد یک شبکه پس انتشار، در لایه پنهان تابع انتقال تانژانت سیگموئید و در لایه خروجی تابع انتقال خطی به کار گرفته شد. الگوریتم به کار گرفته در مرحله آموزش و یادگیری کاهش شیب و مارکوارت - لونیبرگ می‌باشد. با توجه به جدول ۲، نوع داده بر اساس روزهای خشک و تر تعریف شد. برای روزهای خشک عدد ۱ و روزهای تر عدد صفر انتخاب گردید. نسبت در واقع، تعداد داده ورودی به شبکه در مرحله آموزش و یادگیری

می‌باشد. ساختار لایه، تعداد لایه ورودی، تعداد نرون پنهان در هر لایه و تعداد لایه خروجی را نشان می‌دهد. تعداد تکرار، میزان کل دور در بردارهای آموزش می‌باشد.

جدول (۲) مشخصه مدل بهینه برای ایستگاه منتخب در شبکه پس انتشار

روشن آموزش و یادگیری	تابع محرک	تعداد تکرار	تعداد نرون	ساختار لایه ورودی	نسبت	نوع داده	ورودی
الگوریتم کاهش شیب و مارکوارت-لونبرگ	تانژانت سیگموئید-خطی	۷	۵	۴-۵-۱	۴۰-۶۰	(۰،۱)	تهران

سپس با استفاده از تابع شبیه‌سازی و نیز تابع کارایی در مدل منتخب، مجذور میانگین مربعات خطا (RMSE) بررسی شد. نتیجه در جدول (۳) ارائه شده است. شبیه‌سازی در واقع میزان همبستگی بین داده ورودی و میزان عملکرد شبکه جهت پیش‌بینی را نشان می‌دهد. که در مرحله آموزش شبکه با ترکیب الگوریتم با میزان ۸۷/۴ درصد پاسخ مناسبی جهت مدل مذکور به دست داد.

جدول (۳) نتایج ورودی‌های بهینه به شبکه جهت پیش‌بینی و میزان شبیه‌سازی حاصل از مدل شبکه و ترکیب با الگوریتم (داخل پرانتز مقادیر ترکیب شبکه با الگوریتم می‌باشد)

ورودی‌ها	معیار انتخاب ورودی مدل	مجذور میانگین مربعات خطا (درصد)			شبیه‌سازی حاصل از مدل با داده‌های مشاهده شده (درصد) و ترکیب با الگوریتم ژنتیک
		آموزش	اعتبارسنجی	آزمایش	
تهران		۰/۰۸۱۳	۰/۰۸۱۲	۰/۰۸۱۳	(۸۷/۴)۸۵/۴
اصفهان (نمونه)		۲/۳۳	۰/۰۹۷	۰/۰۹۷	-
حوضه سرپاز، ایرانشهر و پیردان (نمونه)		۰/۰۰۵۴	۰/۰۰۵۴	۰/۰۵۱۴	-

در مرحله بعد با توجه به انتخاب نسبت، متوسط مجذورات خطا توسط شبکه برای مراحل آموزش، اعتبارسنجی و آزمایش تعریف شده که هرچه این مقدار به صفر نزدیک‌تر باشد عملکرد شبکه جهت پیش‌بینی مناسب خواهد بود. یکی از کاربردهای مهم شبکه‌های عصبی خصوصاً با الگوریتم پس‌انتشار، پیش‌بینی سری‌های زمانی می‌باشد. برای پیش‌بینی


معمولاً لازم است مقدار w و b را طوری تنظیم کرد تا شبکه بتواند پیش‌بینی بهینه داشته باشد. معمولاً مقدار وزن‌دهی و بایاس بسته به هدف طراح شبکه، نوع الگوریتم و تابع محرک فرق می‌کند. بنابراین برای ایستگاه تهران به پیش‌بینی ۱۰ ساله (۲۰۰۹-۲۰۱۸) پرداخته شد. برای ایستگاه تهران با تأخیر ۴ ساله، ۴ سال آخر با تقدم یک ساله جهت پیش‌بینی در نظر گرفته شد. به این صورت که ۳ سال آخر به شبکه داده تا برای سال بعد پیش‌بینی انجام دهد. البته این مرحله برای کل دوره آماری مورد بررسی قرار گرفت.

پیش‌بینی شمار روزهای خشک

برای ایستگاه مذکور با آزمایش و خطا با ۴ لایه ورودی و ۵ نرون پنهان و یک لایه خروجی به پیش‌بینی بهینه روزهای خشک پرداخته شد. وزن و بایاس هر کدام از لایه‌های ورودی در جدول (۴) و نتایج پیش‌بینی در جدول (۵) ارائه شده است.

جدول (۴) ماتریس ضرایب و بایاس لایه‌های ورودی و خروجی ایستگاه تهران

i	j				k
w_i	-۰/۳	-۹	-۳/۷	-۲/۹	۵
	۰/۳	-۳/۳	-۲/۲	-۱/۵	-۰/۴
	۳/۳	۵/۶	۳/۴	-۳/۲	۰/۱
	۴/۸	۲/۶	-۲/۱	۶/۴	۰/۱
	۱/۷	-۲/۶	-۰/۷	-۳	-۵
b_i	۴				-۰/۶
	۴				
	۷/۹				
	۱/۷				
	-۵				




شکل (۴) مدل شبکه عصبی برای پیش‌بینی روزهای خشک ایستگاه تهران

انتخاب وزن و بایاس‌های اولیه می‌تواند بر روی یادگیری شبکه و رسیدن به حداقل خطا تاثیر داشته باشد. بنابراین بازه انتخابی برای این مقادیر به صورت تصادفی مثبت یا منفی می‌باشد زیرا وزن‌های نهایی بعد آموزش می‌تواند هر علامتی داشته باشند. بر اساس شکل ۵ لایه‌های ورودی به شبکه با تأخیر ۴ ساله انتخاب گردید. برای ایستگاه تهران با انتخاب ۴ سال آخر دوره آماری برای پیش‌بینی سال بعد با تقدم یک‌ساله و تأخیرهای دیگر با ۵ نرون در لایه پنهان و یک لایه خروجی پیش‌بینی صورت گرفت. لازم به یادآوری است که مراحل تقدم و تأخر برای کل دوره آماری ۳۳ ساله مورد آموزش قرار گرفته است. بنابراین مدل پیش‌بینی روزهای خشک ایستگاه تهران به صورت زیر می‌توان نوشت:

$$\text{Forecast Tehran} = \text{pureline}(w_2(\text{tansig}(w_1 \times \text{lagtime4}) + b_1) + b_2)$$

pureline: تابع خطی در لایه خروجی، w_{12} : وزن‌های مربوط به لایه‌های ورودی، tansig : تابع سیگموئید در لایه ورودی، b_{12} : بایاس وزن‌ها در لایه‌ها). نتایج پیش‌بینی شبکه بدون ترکیب با الگوریتم (جدول ۵) نشان داد که طی سال‌های ۲۰۱۵ تا ۲۰۱۸ در مقایسه با سال‌های قبل پیش‌بینی روزهای خشک روند افزایشی داشته است به طوری که این سیر افزایشی را می‌توان در ماه ژانویه به وضوح مشاهده کرد (مثلاً، در ماه ژانویه سال ۲۰۱۷ روند افزایشی مشاهده می‌شود). در مقایسه ماه‌های مختلف طی دوره (۲۰۰۹-۲۰۱۸) که پیش‌بینی صورت گرفته، تقریباً در همه ماه‌ها تعداد وقوع روزهای خشک دارای سیر صعودی بوده که با توجه به معادله شکل (۵)، روزهای خشک پیش‌بینی شده توسط مدل روند افزایشی داشته است.



شکل (۵) نمودار روند سری زمانی روزهای خشک پیش‌بینی شده ایستگاه تهران (در اینجا تعداد ماه‌ها طی ده سال مورد نظر است)

بنابراین می‌توان انتظار داشت که به طور متوسط طی هر ۲۰ سال یک روز خشک جایگزین یک روز تر در طول دوره آماری مورد پیش‌بینی شود. جدول ۵ احتمال وقوع روزهای خشک پیش‌بینی شده توسط شبکه با به‌کارگیری زنجیره مارکوف ارائه شده است (برای تحلیل مارکوفی روزهای خشک، داده‌های بارش روزانه بر اساس آستانه صفر (روزهای فاقدبارش) و یک (روزهای توأم با بارش) برای زنجیره مارکوف مرتب گردید. سپس فراوانی وقوع هر یک از حالت‌ها بر اساس وقوع و عدم وقوع برای هر یک از آستانه‌ها محاسبه گردید. در مرحله بعد ماتریس احتمال تغییرحالت برای هر یک از وضعیت‌ها در نظر گرفته شد). کمینه احتمال وقوع روز خشک پیش‌بینی شده با استفاده از مدل شبکه مربوط به ماه فوریه با ۵۹/۸ درصد می‌باشد که در مقایسه با احتمال وقوع حاصل از زنجیره مارکوف که تقریباً ۶۵ درصد است قرابت زیادی دارد ولی بیشینه احتمال سالانه در هر دو مدل تقریباً نزدیک به (۸۳/۴ درصد) بوده است. بنابراین تغییرات زمانی احتمال رخداد روز خشک با بارندگی منطقه دارای رابطه بوده به طوری که حداکثر احتمال رخداد تعداد روزهای خشکی مقارن با فصول خشک در منطقه بوده است. در ادامه با مقایسه ترکیب شبکه با الگوریتم (جدول ۶) نتایج نشان داد که پیش‌بینی شبکه بعد آموزش با ترکیب الگوریتم نتایج واقعی‌تری را نشان می‌دهد که این مورد در سال‌های (۲۰۰۹-۲۰۱۲) به‌وضوح قابل مشاهده است که ضریب همبستگی (۸۷/۴ درصد) نیز موارد فوق را تایید می‌کند.

جدول (۵) پیش‌بینی ده ساله و احتمال وقوع شمار روزهای خشک ایستگاه تهران

سال	سال	سال	سال	سال	سال	سال	سال	سال	سال	سال	سال	ماه
۲۰۱۸	۲۰۱۷	۲۰۱۶	۲۰۱۵	۲۰۱۴	۲۰۱۳	۲۰۱۲	۲۰۱۱	۲۰۱۰	۲۰۰۹	احتمال وقوع روزهای خشک		
۷۲/۱	۲۵	۲۸	۲۴	۲۳	۲۳	۲۲	۱۸	۲۲	۲۱	۱۸	ژانویه	
۵۹/۸	۲۰	۲۰	۱۹	۱۹	۱۹	۱۸	۱۳	۱۸	۱۷	۱۱	فوریه	
۷۶	۲۵	۲۵	۲۵	۲۵	۲۴	۲۵	۲۰	۲۳	۲۴	۲۰	مارس	
۶۹/۸	۲۳	۲۳	۲۲	۲۲	۲۱	۲۲	۲۰	۱۸	۱۹	۲۰	آوریل	
۸۴/۸	۲۹	۲۹	۲۸	۲۷	۲۸	۲۸	۲۱	۲۷	۲۶	۲۰	می	
۹۵/۳	۲۹	۲۹	۲۹	۲۹	۲۸	۲۹	۲۹	۲۷	۲۸	۲۹	ژوئن	
۹۹/۳	۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۳۰	۳۰	۳۱	جولای	
۹۸/۳	۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۲۹	۳۱	۳۱	۲۸	آگوست	
۱۰۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	سپتامبر	
۸۹	۳۱	۳۱	۲۸	۲۷	۳۱	۲۷	۲۷	۲۵	۲۲	۲۷	اکتبر	
۸۲/۶	۲۶	۲۷	۲۶	۲۶	۲۵	۲۶	۲۲	۲۴	۲۵	۲۱	نوامبر	
۷۲/۶	۲۶	۲۶	۲۴	۲۲	۲۴	۲۱	۱۸	۲۱	۱۸	۱۸	دسامبر	

(تن تبره و روشن، بیشینه و کمینه روزهای خشک پیش‌بینی شده و احتمال وقوع در هر ماه از سال را نشان می‌دهد)

جدول (۶) پیش‌بینی ده ساله شبکه عصبی با ترکیب الگوریتم بعد از آموزش شبکه شمار روزهای خشک

ایستگاه تهران

سال	سال	سال	سال	سال	سال	سال	سال	سال	سال	سال	ماه
۲۰۱۸	۲۰۱۷	۲۰۱۶	۲۰۱۵	۲۰۱۴	۲۰۱۳	۲۰۱۲	۲۰۱۱	۲۰۱۰	۲۰۰۹	احتمال وقوع روزهای خشک	
۲۶	۲۸	۲۴	۲۳	۲۳	۲۲	۱۸	۱۹	۲۸	۲۶	۲۶	ژانویه
۲۰	۲۰	۱۹	۱۹	۱۶	۱۷	۱۴	۱۷	۱۷	۱۶	۱۶	فوریه
۲۷	۲۵	۲۵	۲۴	۲۴	۲۲	۲۰	۲۰	۲۴	۲۲	۲۲	مارس
۲۳	۲۳	۲۲	۲۲	۲۰	۲۲	۲۱	۲۰	۱۹	۱۸	۱۸	آوریل
۲۹	۲۵	۲۸	۲۳	۲۷	۲۵	۲۱	۲۲	۲۳	۲۰	۲۰	می
۳۰	۲۹	۲۹	۲۷	۲۸	۲۹	۲۹	۲۹	۲۶	۲۳	۲۳	ژوئن
۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۳۰	۳۰	۳۱	۳۱	جولای
۳۱	۳۱	۳۱	۳۱	۳۱	۳۱	۲۹	۳۱	۳۱	۲۸	۲۸	آگوست
۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۳۰	۲۹	۲۵	۲۵	سپتامبر
۳۱	۳۱	۲۸	۲۶	۳۱	۲۷	۲۶	۲۴	۲۸	۲۷	۲۷	اکتبر
۲۵	۲۵	۲۶	۲۶	۲۱	۲۵	۲۲	۲۴	۲۵	۲۱	۲۱	نوامبر
۲۶	۲۷	۲۴	۲۲	۲۳	۲۱	۱۸	۲۱	۲۸	۲۱	۲۱	دسامبر

نتیجه‌گیری

بارش از جمله مهم‌ترین متغیرهای ورودی به سیستم‌های هیدرولوژیکی محسوب می‌شود. با توجه به اهمیت بارش و کمبود آن در کشور ایران، مطالعات صورت گرفته در زمینه پیش‌بینی بارش اندک بوده است. در این پژوهش سعی شده است با به‌کارگیری شبکه عصبی مصنوعی و الگوریتم ژنتیک به پیش‌بینی شمار روزهای خشک ایستگاه تهران پرداخته شود. با ترکیب شبکه عصبی با الگوریتم ژنتیک سرعت تحلیل داده‌ها افزایش و در نهایت میزان خطا تقلیل می‌یابد. شبکه به‌کار گرفته شده در این پژوهش از نوع feed-forward با ساختار ۱-۵-۴ و ۵ نرون پنهان در لایه میانی است. در ادامه با استفاده از الگوریتم مارکوارت لونبرگ و کاهش شیب در مرحله آموزش و یادگیری به پیش‌بینی روزهای خشک پرداخته شد. پیش‌بینی با تأخیرهای ۴ ساله و تقدم‌های ۳، ۲ و ۱ ساله برای ۱۰ سال آینده (۲۰۰۹-۲۰۱۸) به شبکه صورت گرفت. نتایج نشان داد که در ایستگاه مذکور تعداد روزهای خشک و به‌دنبال آن کمبود بارش طی سال‌های پیش‌بینی شده با ترکیب الگوریتم روند افزایشی اندکی برای آینده به‌دنبال خواهد داشت. که این مورد با مقایسه داده‌های واقعی با مقادیر پیش‌بینی طی سال‌های (۲۰۰۹-۲۰۱۲) کاملاً گویا می‌باشد. با توجه به مقادیر پیش‌بینی شمار روزهای خشک می‌توان گفت که دارای روند افزایشی طی ده سال بوده است که مقدار افزایش خیلی کم بوده است. ولی به طور کلی می‌توان گفت که دارای روند محسوسی نبوده است که در مطالعات گذشته در مورد بارش این ایستگاه ثابت شده است. نتایج پیش‌بینی شبکه با ترکیب الگوریتم نشان داد میزان همبستگی بین داده‌های ورودی به شبکه و عملکرد آن نزدیک به ۸۸ درصد می‌باشد. این در حالی است که رقم ضریب همبستگی حاصل از شبکه بدون ترکیب با الگوریتم حدود ۸۶ درصد می‌باشد. بنابراین می‌توان اذعان داشت که مدل شبکه عصبی با ترکیب الگوریتم ژنتیک به عنوان یک مدل غیرخطی، ابزار مناسبی برای پیش‌بینی مسایل مهم هیدرولوژیکی و اقلیمی می‌توان به‌شمار آورد (قلی‌زاده و دارند، ۱۳۸۸؛ نگارش و همکاران، ۱۳۹۲: ...).

منابع

- پیره، علیرضا و احمد فاتحی مرچ (۱۳۹۰)، «بررسی میزان توان تأثیرگذاری سیگنال‌های بزرگ مقیاس اقلیمی بر بارش نواحی مختلف ایران با استفاده از شبکه عصبی مصنوعی»، کنفرانس ملی خشکسالی و تغییر اقلیم، مرکز تحقیقات کم‌آبی و خشکسالی در کشاورزی و منابع طبیعی.
- خورشیددوست، علی‌محمد؛ نساجی زواره، مجتبی و باقر قرمزچشمه (۱۳۹۱)، «بازسازی سری‌های زمانی دمای حداکثر و حداقل روزانه با استفاده از روش نزدیک‌ترین همسایه و شبکه عصبی مصنوعی (مطالعه موردی غرب استان تهران)»، *فضای جغرافیایی*، شماره ۳۸، صص ۲۱۴-۱۹۷.
- خوشحال دستجردی، جواد و یوسف قویدل رحیمی (۱۳۸۶) «بررسی رابطه تغییرات بارش سالیانه تبریز با ناهنجاری‌های دمایی کره زمین و شبیه‌سازی عددی آن با استفاده از شبکه عصبی مصنوعی، *فصلنامه مدرس علوم انسانی*، شماره ۲، صص ۱۵-۱.
- صدرموسوی، میرستار (رحیمی)، اکبر، «مقایسه نتایج شبکه‌های عصبی پرسپترون چندلایه با رگرسیون چندگانه در پیش‌بینی غلظت آزون در شهر تبریز، *پژوهش‌های جغرافیای طبیعی*، شماره ۷۱، (۱۳۸۸)، صص ۷۲-۶۵.
- فلاح قالهری، غلامعباس؛ موسوی‌بایگی، محمد و مجید حبیبی نوخندان (۱۳۸۷)، «پیش‌بینی بارش فصلی بر اساس الگوهای سینوپتیکی با استفاده از سیستم فازی-عصبی تطبیقی (ANFIS)، *پژوهش‌های جغرافیای طبیعی*، شماره ۶۶، صص ۱۳۹-۱۲۱.
- قلی‌زاده، محمدحسین و محمد دارند (۱۳۸۸)، «پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد: تهران)»، *پژوهش‌های جغرافیای طبیعی*، شماره ۷۱، صص ۶۳-۵۱.
- کیا، مصطفی (۱۳۸۷)، «*شبکه‌های عصبی در MATLAB*»، تهران، انتشارات کیان رایانه.
- منهای، محمدباقر (۱۳۸۶)، «*مبانی شبکه‌های عصبی*»، چاپ چهارم، انتشارات دانشگاه صنعتی امیرکبیر.
- نگارش، حسین؛ اژدری‌مقدم، مهدی و محسن آرامش (۱۳۹۲)، «کاربرد شبکه عصبی مصنوعی در شبیه‌سازی و پیش‌بینی سیلاب در حوضه آبریز سرباز، *جغرافیا و توسعه*، شماره ۳۱، صص ۲۸-۱۵.

- ویسی، هادی؛ مفاخری، کبری، و سعید باقری شورکی (۱۳۸۸)، «مبانی شبکه‌های عصبی (ساختارها، الگوریتم‌ها و کاربردها)»، نشر تهران: نص.
- Azadi, Samira & Sepaskhah, Ali Reza (2011), "Annual precip-itation forecast for west, southwest, and south provinces of Iran using artificial neural network, *Theor Appl Climatol*, PP. 220-232.
- Efimov, V.V & Pososhkov, V.L, (2006), "Analysis of observations and methods for calculating hydrophysical fields in the ocean application of the method of artificial neural networks to The downscaling of precipitation forecasting in the coastal region of the Black Sea", *Physical Oceanography*, No.3, Vol.16.
- Gao, Chao & Gemmer, Marco & Zeng, Xiaofan & Liu, Bo & Su, Buda & Yuhua, Wen, (2010), "Projected streamflow in the huaihe River basin (2010–2100) using artificial neural network", *Stoch Environ Res Risk Assess*, PP.685–697.
- John Cheng, Fi & Chiu Chang, Li & Lung Huang, Hau, (2002), "Real-Time recurrent learning neural network for stream-flow forecasting", *Hydrological Processes*, 16, PP. 2577-2588.
- Khalili, Najmeh & Khodashenas, Saeed Reza & Davary, Kam-ran & Karimaldini, Fatemeh, (2011), "Daily Rainfall Forecasting for Mashhad synoptic station using artificial neural Networks, *International Conference on Enviromental and Computer Science*, Vol.19.
- Rajurkar, M.P & Kothyari, U.C & Chaube, U.C, (2004), "Model-ing of The daily rainfall-runoff relationship with artificial neural Network, *Journal of Hydrology*, 285, PP.96-113.
- Sattari, M. Taghi & Apaydin, Halit & Ozturk, Fazli (2001), Flow Estimations For The Sohu Stream Using Artificial Neural Networks, *Environment Earth Sci*. PP.100-118.