

کاربرد الگوهای شبکه عصبی مصنوعی در شبیه‌سازی شدت خشکسالی (مطالعه موردی: ایستگاه ترشکلی استان گلستان)

سمانه شاه‌حسین دستجردی^۱، ناصر شاهنوشی^۲، علی دریجانی^۳ و کامران داوری^۴

shahhosseini64@yahoo.com

naser.shahnoushi@gmail.com

ali.darijani@gmail.com

kamdav@um.ac.ir

۱. کارشناس ارشد گروه اقتصاد کشاورزی دانشگاه فردوسی مشهد،

۲. دانشیار گروه اقتصاد کشاورزی دانشگاه فردوسی مشهد،

۳. استادیار گروه اقتصاد کشاورزی دانشگاه علوم کشاورزی و منابع طبیعی گرگان،

۴. دانشیار گروه مهندسی آب دانشگاه فردوسی مشهد،

چکیده

پیش‌بینی خشکسالی ابزار مناسبی برای مدیران و سیاست‌گذاران حوزه‌های مختلف است تا با در نظر گرفتن این پیش‌بینی، سیاست‌های آینده را در جهت بهینه‌نمودن هزینه‌ها طرح‌ریزی نموده و با اتخاذ راهکارهای پیشگیرانه خسارات ناشی از خشکسالی‌های آتی بر بخش‌های آسیب‌پذیر جامعه را به حداقل ممکن برسانند. در این مطالعه، از شاخص استاندارد شده بارش (SPI) و روش شبکه عصبی مصنوعی برای شبیه‌سازی خشکسالی‌ها بهره گرفته شد. همچنین، از آمار باریک‌دست‌گی ایستگاه تبخیر-سنگی ترشکلی واقع در شهرستان گنبدکاووس استان گلستان طی سال‌های ۱۳۵۴-۸۷ استفاده گردید. بر اساس معیارهای ضریب همبستگی (r)، کمترین میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE) مشخص گردید، شبکه عصبی با ۷ نرون در لایه ورودی، ۲۸ نرون با تابع فعالیت تانژانت هایپربولیک در لایه پنهان، یک نرون در لایه خروجی با تابع فعالیت خطی و همچنین، قانون یادگیری مومنتم در مقایسه با سایر شبکه‌های عصبی اجرا شده، ارتباط بین اطلاعات ورودی و خروجی را با دقت بالایی شبیه‌سازی نموده و از عملکرد بهتری در توصیف رفتار تصادفی پدیده خشکسالی ایستگاه ترشکلی برخوردار است. شبکه منتخب برای پیش‌بینی خشکسالی در دوره ۹۳-۱۳۸۸ مورد استفاده قرار گرفت؛ به‌گونه‌ای که مقادیر پیش‌بینی شده، وقوع خشکسالی‌های ملایم در این دوره را نشان دادند. در مجموع، نتایج شبیه‌سازی الگوهای شبکه عصبی مصنوعی نشان می‌دهند، این روش از دقت بالایی در دوره‌های اولیه پیش‌بینی برخوردار است.

واژه‌های کلیدی: پیش‌بینی، خشکسالی، شاخص استاندارد شده بارش، شبکه عصبی مصنوعی، گلستان

مقدمه

خشکسالی، ویژگی طبیعی و برگشت‌پذیر اقلیمی می‌باشد و تقریباً در کلیه اقلیم‌ها رخ می‌دهد. این پدیده علاوه بر مناطق با بارندگی کم، در مناطق با حجم بارندگی زیاد نیز اتفاق می‌افتد (ویلهاپت، ۲۰۰۳). در دهه‌های اخیر، تعداد وقوع پدیده خشکسالی از نظر شدت، طول مدت، مجموع فضای تحت پوشش، تلفات جانی، خسارات اقتصادی و اثرات اجتماعی بلندمدت بر جامعه، بیشتر از سایر بلاای طبیعی بوده است. همچنین، تمایز این پدیده با سایر بلاای طبیعی در این است که برخلاف سایر بلایا، این پدیده به تدریج و در یک دوره زمانی نسبتاً طولانی عمل کرده و اثرات آن ممکن است پس از چند سال و با تأخیر بیشتری نسبت به سایر حوادث طبیعی ظاهر شود (بداق جمالی و همکاران، ۱۳۸۴).

مطالعات مختلف نشان می‌دهد، خشکسالی و به‌خصوص خشکسالی اقلیمی و کشاورزی، نتیجه یک عامل منفرد و مشخصی نیست که بتوان آن را از قبل و به‌طور دقیق پیش‌بینی نمود. با وجود این، امکان پذیر است که در مقیاس زمانی ماهانه یا فصلی، نشانه‌هایی از رخداد خشکسالی و نیز خاتمه آن ارائه شود و از طریق روند حوادث رخ داده در دوره‌های قبل، وقایع آتی خشکسالی را پیش‌بینی نمود (علیزاده، ۱۳۸۱). بر این اساس، پیش‌بینی خشکسالی ابزار مناسبی را در اختیار مدیران و سیاست‌گذاران حوزه‌های مختلف قرار می‌دهد تا با در نظر گرفتن این پیش‌بینی، سیاست‌های آینده را در جهت بهینه‌نمودن هزینه‌ها طرح‌ریزی

نموده و با اتخاذ راهکارهای پیشگیرانه و تنظیم استراتژی‌های مدیریت خشکسالی، خسارات ناشی از خشکسالی‌های آتی بر بخش‌های آسیب‌پذیر جامعه را به حداقل ممکن برسانند.

برای پیش‌بینی فرآیندهای هیدرولوژیکی همچون بارش، دبی ماهانه و سالانه رودخانه‌ها، سیلاب‌ها و خشکسالی‌ها معمولاً از الگوهای تصادفی خودتوضیح میانگین متحرک^۱ (ARMA) و خودتوضیح جمعی میانگین متحرک^۲ (ARIMA) استفاده شده است. این الگوهای تصادفی، فرآیندهای پایا را به صورت خطی الگوسازی نموده و در توصیف ویژگی‌های ناپایا و غیرخطی سری‌های زمانی غالباً ناتوان می‌باشند. با توجه به اهمیت ویژگی‌های غیرخطی و ناپایای سری‌های زمانی فرآیندهای هیدرولوژیکی در پیش‌بینی‌ها، استفاده از روش‌هایی که ویژگی‌های مذکور را در نظر بگیرند، امری ضروری است. در سال‌های اخیر، شبکه‌های عصبی مصنوعی، توانایی خود را در الگوسازی و پیش‌بینی سری‌های زمانی غیرخطی و ناپایای فرآیندهای هواشناسی و هیدرولوژیکی با توجه به ماهیت غیرخطی و انعطاف‌پذیری خود به اثبات رسانده‌اند (انجمن مهندسين عمران امریکا، ۲۰۰۰).

مطالعات مختلفی در خصوص پیش‌بینی فرایندهای جوی از جمله خشکسالی با استفاده از شبکه‌های عصبی مصنوعی در ایران و سایر کشورها صورت گرفته است که می‌توان به مطالعه میسرا و دیزای (۲۰۰۶) اشاره نمود. آن‌ها برای پیش‌بینی خشکسالی‌ها در حوضه آبریز کانسباتی در غرب بنگال هند، با استفاده از شاخص استاندارد شده بارش^۳ (SPI) به مقایسه قدرت پیش‌بینی الگوهای تصادفی خطی (ARMA, SARIMA)، شبکه عصبی مصنوعی چندمرحله‌ای برگشتی و شبکه عصبی مصنوعی چندمرحله‌ای مستقیم پرداختند. نتایج نشان داد که روش چندمرحله‌ای برگشتی برای پیش‌بینی SPI با گام زمانی یک‌ماهه عملکرد بهتری نسبت به سایر روش‌ها دارد. بر اساس مطالعه سیریکالرا و تانپراسرت (۲۰۰۶)، شبکه‌های عصبی با الگوریتم آموزشی پس‌انتشار خطا از دقت قابل‌قبولی در پیش‌بینی بارندگی‌های روزانه در رودخانه چائو فرایا تایلند برخوردارند. حیاتی و محبی (۲۰۰۷) به منظور طراحی سیستم پیش‌بینی کوتاه‌مدت دما در کرمانشاه از شبکه عصبی پرسپترون چندلایه^۴ (MLP) در طی دوره ۲۰۰۶-۱۹۹۶ استفاده نمودند. نتایج حاکی از این است که شبکه عصبی MLP با حداقل خطای پیش‌بینی روش مناسبی برای الگوسازی سیستم‌های پیش‌بینی کوتاه‌مدت دما می‌باشد. رامیرز و همکاران (۲۰۰۵) از شبکه عصبی پرسپترون پیش‌خور با الگوریتم آموزش پس‌انتشار خطا برای پیش‌بینی بارش ماهیانه در منطقه سائوپائولو برزیل استفاده کردند. نتایج حاصله، برتری روش شبکه‌های عصبی مصنوعی را نسبت به روش‌های رگرسیونی نشان می‌دهد. در تحقیقی دیگر، مرید و همکاران (۲۰۰۷) با بهره‌گیری از شبکه‌های عصبی مصنوعی و دو شاخص استاندارد شده بارش (SPI) و شاخص خشکسالی مؤثر^۵ (EDI) به پیش‌بینی خشکسالی‌ها در ایستگاه‌های بارندگی استان تهران پرداختند. نتایج نشان داد که شاخص خشکسالی EDI به عنوان متغیر ورودی بهتر از شاخص خشکسالی SPI عمل می‌کند.

با توجه به آن‌چه که بیان گردید، الگوهای شبکه عصبی پرسپترون، توانایی خود را در پیش‌بینی فرایندهای جوی نشان داده‌اند. از این‌رو مطالعه حاضر از روش مذکور برای پیش‌بینی وقوع خشکسالی‌ها در دوره‌های آتی استفاده نموده است.

مواد و روش‌ها

۱- تعیین شاخص خشکسالی

در ارزیابی خشکسالی، تعیین مجموعه‌ای از شاخص‌های مناسب و دقیق از اهمیت ویژه‌ای برخوردار است. با استفاده از شاخص‌های خشکسالی می‌توان شدت، مدت و وسعت خشکسالی را کمی کرده و به صورت دوره‌ای ارزیابی نمود. شاخص‌های متعددی برای ارزیابی خشکسالی به کار برده می‌شوند (بداق‌جمالی و همکاران، ۱۳۸۴) که در بین آن‌ها، شاخص استاندارد شده بارش (SPI) در تحلیل منطقه‌ای خشکسالی و مطالعات تطبیقی و مقایسه‌ای میان مناطق مختلف متداول تر بوده و قابلیت بالای آن در بسیاری از مطالعات نشان داده شده است (کیانتاش و دراکوپ، ۲۰۰۲). شدت خشکسالی و ترسالی بر اساس مقادیر SPI به صورت جدول ۱ طبقه‌بندی

^۱ Auto-Regressive Moving Average Models

^۲ Auto-Regressive Integrated Moving Average Models

^۳ Standardized Precipitation Index

^۴ Multilayer Perceptron

^۵ Effective Drought Index

می‌شود؛ به گونه‌ای که مقادیر مثبت SPI نمایانگر بارش بیش از میانگین و مقادیر منفی آن نشان‌دهنده بارش کمتر از میانگین می‌باشد. زمانی که مقدار SPI منفی باشد، نشانه شروع خشکسالی است و هنگامی که مقدار این شاخص مثبت باشد، پایان خشکسالی و آغاز ترسالی را نوید می‌دهد (بداق جمالی و همکاران، ۱۳۸۴).

جدول (۱): طبقه‌بندی شدت خشکسالی و ترسالی بر اساس شاخص SPI


مقادیر SPI	طبقه خشکسالی
۲ و بیشتر	ترسالی بسیار شدید
۱/۵ تا ۱/۹۹	خیلی مرطوب
۱ تا ۱/۴۹	ترسالی متوسط
۰ تا ۰/۹۹	ترسالی ملایم
۰ تا -۰/۹۹	خشکسالی ملایم
-۱ تا -۱/۴۹	خشکسالی متوسط
-۱/۵ تا -۱/۹۹	خشکسالی شدید
-۲ و کمتر	خشکسالی بسیار شدید

در مطالعه حاضر، برای پیش‌بینی خشکسالی کشاورزی از شاخص SPI سه‌ماهه و همچنین به‌منظور پیش‌بینی خشکسالی‌های سالانه (هیدرولوژیکی) از شاخص SPI دوازده‌ماهه استفاده می‌شود.

۲- روش شبکه عصبی مصنوعی

الف) شبکه‌های عصبی پیش‌خور

شبکه‌های عصبی مصنوعی شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشند که به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. این شبکه‌ها از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده‌اند. نحوه و شکل اتصال نرون‌ها در لایه‌های مختلف، باعث ایجاد ساختارهای مختلفی در شبکه‌های عصبی مصنوعی شده است. چنانچه در یک شبکه عصبی، خروجی هر نرون تنها به نرون‌های لایه بعد وصل شود، به آن شبکه عصبی پیش‌خور گفته می‌شود. شکل ۱، نمای کلی شبکه عصبی پیش‌خور چندلایه را نشان می‌دهد.



شکل (۱): نمای کلی شبکه عصبی مصنوعی پیش‌خور چند لایه: کیم (۲۰۰۸)

از نظر ریاضی، مقدار خروجی یک شبکه پیش خور می‌تواند به صورت زیر بیان گردد (کیم و والدس، ۲۰۰۳):

$$\hat{Y}_k = \varphi_{output} \left[\sum_{j=1}^m w_{kj} \cdot \varphi_{hidden} \left(\sum_{i=1}^n w_{ji} x_i + w_{jhidden} \right) + w_{koutput} \right] \quad (5)$$

در معادله ۵، w_{ji} وزن اتصال دهنده i امین نرون در لایه ورودی به j امین نرون در لایه پنهان؛ $w_{jhidden}$ بایاس مربوط به j امین نرون پنهان؛ φ_h تابع فعالیت نرون پنهان؛ w_{kj} وزن اتصال دهنده j امین نرون در لایه پنهان و k امین نرون در لایه خروجی؛ $w_{koutput}$ بایاس مربوط به k امین نرون خروجی می‌باشد.


تعداد نرون‌های ورودی، متناظر با تعداد مشاهدات باوقه برای کشف الگوی اصلی در یک سری زمانی به کار می‌روند تا مقادیر آینده را پیش‌بینی نمایند. لایه پنهان و نرون‌های آن، نقش مهمی را در موفقیت شبکه عصبی ایفا می‌کنند. نرون‌های پنهان، داده‌های ورودی را دریافت کرده و نگاشت غیرخطی و پیچیده‌ای را بین متغیرهای ورودی و خروجی اجرا می‌کنند. محققین اثبات نموده‌اند که تنها یک لایه پنهان برای شبکه‌های عصبی کافی است تا تابع غیرخطی را با هر دقت دلخواهی تقریب بزند (سبینکو، ۱۹۸۹؛ هورنیک و همکاران، ۱۹۸۹). برای انتخاب تعداد نرون‌های پنهان قاعده مشخصی وجود ندارد، لذا پیشنهاد می‌گردد از روش آزمون و خطا برای تعیین تعداد آن‌ها استفاده شود (جوراچی و همکاران، ۲۰۰۷).

ب) توابع فعالیت

مجموع ورودی‌های وزن دار شده (ورودی خالص) از طریق یک تابع فعالیت به مقدار خروجی تبدیل می‌شوند. در لایه خروجی می‌توان از یک تابع خطی استفاده نمود، اما کاربرد این تابع در لایه پنهان پیشنهاد نمی‌شود، به این دلیل که کارایی شبکه کاهش یافته و قادر به حل مسائل غیرخطی نخواهد بود. از آنجا که اکثر مسائل در دنیای واقعی غیرخطی می‌باشند، لازم است در لایه‌های پنهان از توابع غیرخطی استفاده گردد. توابع خطی، سیگموئید و تانژانت هایپربولیک از رایج‌ترین توابع فعالیت به‌شمار می‌روند (کامروزامن و همکاران، ۲۰۰۶).

ج) الگوریتم آموزشی پس‌انتشار خطا

یکی از متداول‌ترین شبکه‌های عصبی پیش‌خور، پرسپترون چند لایه (MLP) همراه با الگوریتم یادگیری (آموزشی) پس‌انتشار خطا می‌باشد که در الگوسازی و نگاشت فرایندهای غیرخطی بسیار مورد استفاده قرار گرفته است. شکل ۲، الگوریتم یادگیری پس‌انتشار در یک شبکه عصبی پرسپترون سه لایه را نمایش می‌دهد.



شکل (۲): نمای کلی الگوریتم یادگیری پس انتشار در شبکه عصبی پرسپترون سه لایه: کیم و والدس

(د) آزمون شبکه

پس از کامل شدن مرحله آموزش که مناسب‌ترین وزن‌ها، حاصل و تثبیت شده‌اند، داده‌های ورودی جدیدی تحت عنوان داده‌های آزمون یا اعتبارسنجی که در آموزش وارد نشده‌اند، جهت ارزیابی کارایی و توانایی شبکه اعمال می‌گردند. اگر خروجی الگو با داده‌های واقعی مطابقت داشته باشد، آن‌گاه می‌توان بیان نمود که شبکه به‌درستی آموزش دیده است (زیجیان، ۲۰۰۵). آزمون قطعی و مشخصی جهت ارزیابی قدرت پیش‌بینی الگوهای مختلف شبکه عصبی وجود ندارد. از این‌رو، معیارهای آماری مختلفی به کار می‌روند (سبری و همکاران، ۲۰۰۲) که می‌توان به معیارهای ضریب همبستگی^۱ (r)، میانگین مربعات خطا^۲ (MSE) و میانگین خطای مطلق^۳ (MAE) اشاره نمود. معیارهای مذکور را می‌توان به‌صورت روابط زیر نشان داد:

- ضریب همبستگی (r):

$$r = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n ((y_{act} - \bar{y}_{act})^2) \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}} \quad (1)$$

- میانگین مربعات خطا (MSE)

$$MSE = \frac{\sum_{i=1}^n (y_{est} - y_{act})^2}{n} \quad (2)$$

- میانگین خطای مطلق (MAE)

$$MAE = \frac{\sum_{i=1}^n |y_{est} - y_{act}|}{n} \quad (3)$$

در معادلات فوق، y_{act} مقادیر مشاهده شده (واقعی)؛ \bar{y}_{act} میانگین مقادیر مشاهده شده؛ y_{est} مقادیر پیش‌بینی شده؛ \bar{y}_{est} میانگین مقادیر پیش‌بینی شده و n تعداد مشاهدات می‌باشد. هر چه مقدار ضریب همبستگی (r) به یک نزدیک باشد، نشان‌دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی خواهد بود. همچنین، مقدار کوچک هر یک از معیارهای خطا در روابط ۲ و ۳ بیانگر دقت بالای پیش‌بینی می‌باشد.

۴- اطلاعات و آمار

برای پیش‌بینی خشکسالی از داده‌های ایستگاه تبخیرسنجی ترشکلی (با طول $48^{\circ} 54'$ ، عرض $40^{\circ} 37'$ و ارتفاع ۲۵ متر از سطح دریا) واقع در بخش داشلی‌برون گنبدکاووس مربوط به سال‌های آبی ۸۷-۱۳۵۴ استفاده گردید که از شرکت آب منطقه‌ای استان گلستان جمع‌آوری شده است. همچنین، برای انجام محاسبات و تحلیل داده‌ها نیز از برنامه SPI نسخه DOS و بسته‌های نرم‌افزاری Excel و NeuroSolution 5.0 استفاده شده است.

نتایج

در این تحقیق برای پیش‌بینی شاخص خشکسالی SPI سه‌ماهه برای ایستگاه ترشکلی از داده‌های ماهانه سال‌های ۸۷-۱۳۵۴، یعنی ۴۰۸ داده استفاده شده است. برای آموزش شبکه عصبی از داده‌های ماهانه سال‌های ۸۲-۱۳۵۴ استفاده شد و سایر داده‌ها نیز برای آزمون شبکه به کار رفت. لازم به ذکر است که این تعداد داده‌های آموزش و آزمون برای ایستگاه مذکور، بر اساس مطالعات ارائه شده و به ترتیب حدود ۸۰ و ۲۰ درصد داده‌های کل انتخاب شده‌اند. در مطالعه حاضر از شبکه عصبی پرسپترون سه لایه با الگوریتم آموزشی پس انتشار خطا استفاده گردید. در فرایند آموزش، برای مقایسه برتری قوانین یادگیری، علاوه بر قانون یادگیری مومنتم از قوانین یادگیری دیگری همچون LevenbergMorguan, DeltaBarDelta و ConjugatedGradient نیز

¹ Correlation coefficient

² Mean Square Error

³ Mean Absolute Error

استفاده شد. مقدار بهینه این قوانین توسط نرم افزار NeuroSolution 5.0 انتخاب و در آموزش شبکه به کار رفت. همچنین، مقدار بایاس (نرون اریب) و نرخ یادگیری بهینه توسط نرم افزار انتخاب، شد و تعداد تکرار و شروع مجدد با توجه به مقدار بهینه نرم افزار، ۱۰۰۰ و ۳ در نظر گرفته شد. با توجه به این که انتخاب نرون ها در لایه ورودی از اهمیت خاصی برخوردار است، تعداد وقفه های مختلفی از شاخص خشکسالی مورد بررسی قرار گرفت. همچنین، بر اساس اینکه تنها یک لایه پنهان برای شبکه عصبی کافی است تا تابع غیرخطی را با هر دقت دلخواهی تقریب نماید، از یک لایه پنهان در ایجاد شبکه عصبی استفاده گردید. به منظور انتخاب تعداد نرون های بهینه در این لایه نیز، تعداد نرون ها از ۱ تا ۳۰ نرون مورد آزمون قرار گرفت. لایه خروجی نیز یک نرون خروجی که شاخص خشکسالی SPI سه ماهه با تقدّم زمانی یک ماهه (SPI_{t+1}) است را شامل شد. لازم به ذکر است که برای لایه پنهان، توابع فعالیت غیرخطی سیگموئید و تانژانت هایپربولیک مورد مقایسه قرار گرفتند و در لایه خروجی نیز از تابع فعالیت خطی استفاده شد. همان طور که ذکر شد، برای انتخاب تعداد وقفه بهینه در لایه ورودی از الگوهای ورودی مختلفی استفاده شده است. جدول ۲، الگوهای ورودی مذکور را نشان می دهد.

جدول (۲): الگوهای ورودی بکار رفته در انتخاب تعداد وقفه بهینه لایه ورودی

نام الگو	تعریف*
۱	$S_{t+1} = f(S_t, S_{t-1})$
۲	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2})$
۳	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3})$
۴	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4})$
۵	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5})$
۶	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5}, S_{t-6})$
۷	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5}, S_{t-6}, S_{t-7})$
۸	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5}, S_{t-6}, S_{t-7}, S_{t-8})$
۹	$S_{t+1} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5}, S_{t-6}, S_{t-7}, S_{t-8}, S_{t-9})$

* لازم به ذکر است، حرف f نشان دهنده تابع و حرف S، بیانگر شاخص خشکسالی SPI است.

مأخذ: یافته های تحقیق

در جدول ۳، نتایج بررسی ساختارهای مختلف شبکه عصبی مصنوعی در پیش بینی شاخص خشکسالی SPI سه ماهه ایستگاه ترشکلی بر اساس معیارهای ضریب همبستگی (r)، میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE) گزارش شده است. همان طور که ارقام جدول نشان می دهد، از بین ساختارهای مختلف شبکه های عصبی مصنوعی، شبکه عصبی مصنوعی با ۷ نرون در لایه ورودی، ۲۸ نرون در لایه پنهان با تابع فعالیت تانژانت هایپربولیک و قانون یادگیری مومنتم، با بالاترین ضریب همبستگی (r)، کمترین میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE)، به عنوان شبکه عصبی بهینه انتخاب می شود. بنابراین، در پیش بینی شاخص خشکسالی SPI سه ماهه با تقدّم زمانی یک ماهه (SPI_{t+1}) از بین الگوهای مختلف در جدول ۲، الگوی ۸ با متغیرهای شاخص خشکسالی SPI در زمان t (SPI_t)، شاخص SPI در زمان t-۱ بین SPI_{t-1} ، شاخص SPI در زمان t-۲ (SPI_{t-2})، شاخص SPI در زمان t-۳ (SPI_{t-3})، شاخص SPI در زمان t-۴ تا SPI_{t-4} ، شاخص SPI در زمان t-۵ (SPI_{t-5}) و شاخص SPI در زمان t-۱۲ (SPI_{t-12}) به عنوان الگوی ورودی بهینه انتخاب شد.

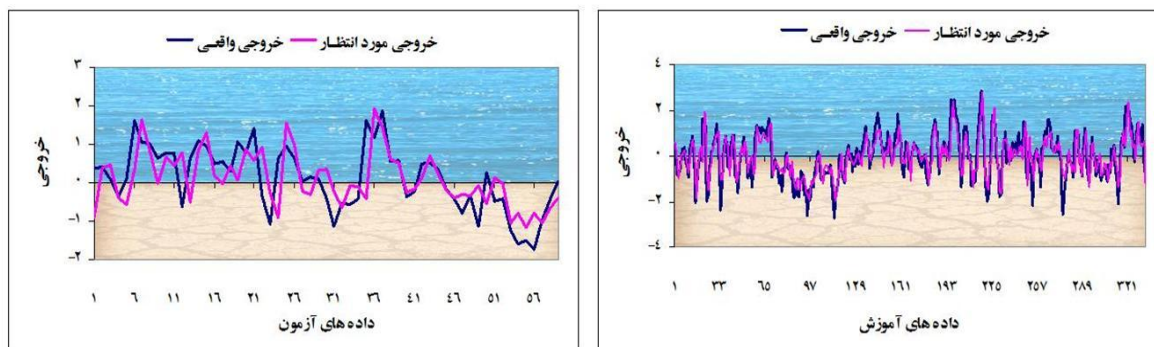
جدول (۳): نتایج ساختارهای مختلف شبکه پرسپترون سه لایه در برآورد شاخص SPI سه ماهه با تقدّم زمانی یک ماهه در ایستگاه ترشکلی

MAE		MSE		r		قانون یادگیری	توابع فعالیت	ساختار شبکه*	الگوی ورودی
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش				
۰/۵۳	۰/۵۴	۰/۴۹	۰/۴۹	۰/۵۸	۰/۷۳	Momentum	Tan-Lin	(۲-۲۷-۱)	۱
۰/۵۴	۰/۵۳	۰/۴۷	۰/۴۷	۰/۶۱	۰/۷۴	Momentum	Tan-Lin	(۳-۲۲-۱)	۲
۰/۵۳	۰/۵۰	۰/۴۷	۰/۴۳	۰/۶۱	۰/۷۷	Momentum	Tan-Lin	(۴-۳۰-۱)	۳
۰/۵۳	۰/۴۹	۰/۴۷	۰/۴۱	۰/۶۱	۰/۷۸	Momentum	Tan-Lin	(۵-۳۰-۱)	۴
۰/۵۲	۰/۴۷	۰/۴۷	۰/۴۷	۰/۶۱	۰/۷۹	Momentum	Tan-Lin	(۶-۳۰-۱)	۵
۰/۵۳	۰/۴۸	۰/۴۹	۰/۴۰	۰/۶۰	۰/۷۹	Momentum	Tan-Lin	(۵-۲۷-۱)	۶
۰/۵۲	۰/۴۷	۰/۴۷	۰/۳۷	۰/۶۱	۰/۸۰	Momentum	Tan-Lin	(۶-۳۰-۱)	۷
۰/۵۱	۰/۴۵	۰/۴۶	۰/۳۴	۰/۶۲	۰/۸۲	Momentum	Tan-Lin	(۷-۲۸-۱)	۸
۰/۵۲	۰/۵۱	۰/۴۷	۰/۴۴	۰/۶۰	۰/۷۶	Momentum	Sig-Lin	(۷-۳-۱)	۸
۰/۵۶	۰/۴۶	۰/۵۶	۰/۳۶	۰/۵۴	۰/۸۱	DeltaBarDelta	Tan-Lin	(۷-۴-۱)	۸
۰/۵۲	۰/۴۵	۰/۴۷	۰/۳۵	۰/۶۱	۰/۸۲	Conjugated Gradient	Tan-Lin	(۷-۳۰-۱)	۸
۱/۰۸	۰/۴۸	۲/۰۶	۰/۳۶	۰/۵۱	۰/۹۲	Levenberg Morguan	Tan-Lin	(۷-۲۷-۱)	۸
۰/۵۵	۰/۴۴	۰/۴۹	۰/۳۳	۰/۶۰	۰/۸۳	Momentum	Tan-Lin	(۸-۲۸-۱)	۹

* لازم به ذکر است که ساختار شبکه از چپ به راست خوانده می‌شود.

مأخذ: یافته‌های تحقیق

همچنین در شکل ۳، مقادیر خروجی واقعی و مورد انتظار (پیش‌بینی‌شده) داده‌های آزمون و آموزش در شبکه عصبی بهینه (ANN(۷-۲۸-۱)tan-lin-momentum) نشان داده شده است. با توجه به معیارهای آزمون در جدول و شکل ۳ مشاهده می‌شود که شبکه عصبی مصنوعی بهینه در مقایسه با سایر شبکه‌های عصبی، ارتباط بین اطلاعات ورودی و خروجی را با دقت بالایی شبیه‌سازی نموده است و از عملکرد بهتری در توصیف رفتار تصادفی پدیده خشکسالی ایستگاه ترشکلی برخوردار است.



شکل (۳): مقادیر واقعی و مورد انتظار داده‌های آموزش و آزمون شبکه عصبی بهینه برای ایستگاه ترشکلی

بر اساس شبکه عصبی منتخب می‌توان مقادیر آینده شاخص خشکسالی SPI سه‌ماهه برای ایستگاه ترشکلی را پیش‌بینی نمود. جدول ۴، مقادیر پیش‌بینی‌شده شاخص خشکسالی SPI سه‌ماهه را در سال زراعی ۱۳۸۸ نشان می‌دهد. بر اساس اطلاعات جدول ۴-۲۹، در سال ۱۳۸۸، برای کلیه ماه‌ها، خشکسالی ملایم پیش‌بینی می‌شود. در ماه‌های خرداد، تیر و مرداد، شدت خشکسالی بیش از سایر ماه‌ها خواهد بود.

جدول (۴): مقادیر پیش‌بینی شده شاخص خشکسالی SPI سه‌ماهه در سال زراعی ۱۳۸۸ برای ایستگاه ترشکلی

ماه	مهر	آبان	آذر	دی	بهمن	اسفند	فروردین	اردیبهشت	خرداد	تیر	مرداد	شهریور
شاخص SPI سه‌ماهه	-۰/۱۴	-۰/۲۵	-۰/۴۳	-۰/۴۱	-۰/۳۹	-۰/۲۵	-۰/۲۹	-۰/۳۴	-۰/۵۰	-۰/۵۴	-۰/۵۷	-۰/۴۶

مأخذ: یافته‌های تحقیق

مقدار شاخص SPI سه‌ماهه ایستگاه ترشکلی برای سال‌های ۱۳۸۹-۹۳ تنها برای سه‌ماهه پایان آذر، اسفند، خرداد و شهریور (SPIهای فصلی) در جدول ۵ نشان داده شده است. بر اساس اطلاعات مندرج در جدول مذکور، وقوع خشکسالی ملایم در این سال‌ها محتمل است. همچنین، انتظار می‌رود در سال‌های بالاتر، شدت خشکسالی افزایش یابد.

جدول (۵): مقادیر پیش‌بینی شده شاخص SPI سه‌ماهه (فصلی) ایستگاه ترشکلی طی سال‌های ۱۳۸۹-۹۳

سال	۱۳۸۹	۱۳۹۰	۱۳۹۱	۱۳۹۲	۱۳۹۳
فصل پاییز	-۰/۳۴	-۰/۴۳	-۰/۵۳	-۰/۵۱	-۰/۵۶
زمستان	-۰/۵۰	-۰/۴۵	-۰/۴۸	-۰/۵۵	-۰/۵۶
بهار	-۰/۳۵	-۰/۵۰	-۰/۵۱	-۰/۵۳	-۰/۶۰
تابستان	-۰/۵۱	-۰/۴۴	-۰/۵۳	-۰/۵۶	-۰/۵۸

مأخذ: یافته‌های تحقیق

بر اساس نتایج حاصله، شبکه عصبی مصنوعی در ایستگاه ترشکلی، وقوع خشکسالی‌ها را بیش از ترسالی‌ها پیش‌بینی نمود و از دقت بالایی در دوره‌های اولیه پیش‌بینی برخوردار است. با توجه به نتایج تحقیق می‌توان اظهار داشت که کاربرد شبکه‌های عصبی مصنوعی در شبیه‌سازی خشکسالی‌ها می‌تواند برای مدیران منطقه‌ای و برنامه‌ریزان منابع آبی بسیار مفید باشد تا با آگاهی از میزان شدت خشکسالی مشخص‌شده، اقدامات پیشگیرانه‌ای را برای مبارزه با آن اتخاذ نمایند. نظر به این‌که روش شبکه عصبی مصنوعی از دقت بالایی در دوره‌های اولیه پیش‌بینی برخوردار است، پیشنهاد می‌شود از طریق اطلاعات جدید، وضعیت‌های مختلف آب و هوایی در هر دوره به‌روز و بازنگری شود. بدیهی است با گذشت زمان در سال‌های آتی و افزایش اطلاعات در دسترس، دقت روش مذکور افزایش یافته و برای پیش‌بینی‌های ماهانه، فصلی و سالانه نیز کاربری بیشتری خواهد داشت. همان‌طور که پیشتر بیان گردید، توانایی شاخص خشکسالی SPI در ارزیابی و پیش‌بینی خشکسالی‌ها و ترسالی‌ها در بسیاری از مطالعات مرتبط با خشکسالی به اثبات رسیده است. با این حال به‌نظر می‌رسد، می‌توان در مطالعات آینده از شاخص‌های دیگر خشکسالی همچون شاخص شدت خشکسالی پالم (PDSI) در بررسی و پیش‌بینی خشکسالی‌ها استفاده شود و نتایج آن با نتایج حاصل از شاخص SPI مقایسه و تحلیل گردد.

استقرار نظام پایش و پیش‌آگاهی خشکسالی در سطح ملی یا منطقه‌ای نقش بسزایی در مدیریت ریسک خشکسالی ایفا می‌نماید. در این نظام با استفاده از سیستم‌های پیش‌هشدار معتبر و الگوهای شبیه‌سازی دوره‌های خشکسالی می‌توان کشاورزان را از کم‌آبی و خشکسالی دوره‌های آینده آگاه نموده و از طریق برگزاری کلاس‌های آموزشی، بروشورها، اطلاعیه‌ها و مشاوره‌های حضوری آن‌ها را در خصوص روش‌های مقابله با خشکسالی آموزش داده و خسارت ناشی از آن‌را کاهش داد. از این‌رو، به‌کارگیری گروه‌های علمی متخصص، سرمایه‌گذاری در سیستم‌های پیش‌هشدار، بهبود اطلاعات هواشناسی، پیش‌بینی

خشکسالی با استفاده از الگوهای شبکه عصبی مصنوعی کمک قابل توجهی در جهت کارآمدسازی و اثربخشی این نظام خواهد داشت.

منابع

۱. بداق جمالی، ج.، آسیایی، م.، صمدی نقاب، س.، جوانمرد، س. و بهنیا، ا. ۱۳۸۴. مدیریت ریسک خشکسالی (شناخت و راهکارها). چاپ اول. انتشارات سخن گستر، مشهد.
۲. علیزاده، ا. ۱۳۸۱. آیا می توان خشکسالی را پیش بینی و یا با آن مقابله کرد؟ فصلنامه خشکی و خشکسالی کشاورزی. وزارت جهاد کشاورزی. شماره ۶
3. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology. I. Preliminary concepts. *Journal of Hydrologic*. 5 (2), pp 124–137.
4. Cybenko, G. 1989. Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals, and Systems*. 2(4), pp 303–314.
5. Hayati, M., and Mohebi, Z. 2007. Application of Artificial Neural Networks for Temperature Forecasting. *Proceedings of World Academy of Science, Engineering and Technology*. 22, pp 275-279.
6. Hornik, K., Stinchcombe, M. and White, H. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*. 2, pp 359–366.
7. Joorabchi, A., Zhang, H., and Blumenstein, M. 2007. Application of artificial neural networks in flow discharge prediction for the Fitzroy River. *Australian Journal of Coastal Research*. SI 50, pp 287-291.
8. Kamruzzaman, J., Begg, R., and Sarker, R. 2006. *Artificial Neural Networks in Finance and Manufacturing*. Idea Group Publishing, USA.
9. Keyantash, J., and Dracup, J.A. 2002. The quantification of drought: A evaluation of drought indices. *Bulletin of the American Meteorological Society*. 38(8), pp 1167-1180.
10. Kim, H.K. 2008. Multi-Scale Nonlinear Constitutive Models using Artificial Neural Networks. Msc thesis of Civil & Environmental Engineering. Georgia Institute of Technology.
11. Kim, T.W., and Valdes, J.B. 2003. A nonlinear Model for Drought Forecasting based on Conjunction of Wavelet Transforms and Neural Networks. *Journal of Hydrologic Engineering*. 8(6), pp 319-328.
12. Liu, X., Ren, L., Yuan, F., and Yang, B. 2009. Meteorological Drought Forecasting Using Markov Chain Model. *International Conference on Environmental Science and Information Application Technology*. Wuhan China. Vol 2, pp 23-26.
13. Mishra, A.K and Desai, V.R. 2006. Drought Forecasting using feed-forward recursive neural network. *Ecological Modelling*. 198, pp 127- 138.
14. Morid, S., Smakhtin, V., and Bagherzadeh, K. 2007. Drought Forecasting using Artificial Neural Networks and Time Series of Drought Indices. *International Journal of Climatology*. 27(15), pp 2103-2111.
15. Muhammad, F., and Nabi, G. 1991. A Markov Chain Model for Rainfall Occurrence in Pakistan. 1991. *Journal of Islamic Academy of Sciences* 4(2), pp 173-178.
16. Ramirez, M.C.V., Velho, H.F., and Ferreira, N.J. 2005. Artificial neural network technique for rainfall forecasting applied to the Saõ Paulo region. *Journal of Hydrology*. 301, pp 146–162.
17. Sobri, H., Nor Irwan, A.N., and Amir Hashim, M.K. 2002. Artificial Neural Network Model for Rainfall-Runoff Relationship. *Jurnal Teknologi*, 37(B), pp 1–12.
18. Srikalra, N., and Tanprasert, C. 2006. Rainfall Prediction for Chao Phraya River using Neural Networks with Online Data Collection. *Proceedings of the 2nd IMT-GT Regional Conference Mathematics, Statistics and Applications Universiti Sains Malaysia, Penang, June 13-15, 8 p.*
19. Wilhite, D.A. 2003. Moving toward risk management: The need for global strategy. 18 p. <http://www.nahrim.gov.my>.
20. Zijian, Z. 2005. Researches on Function-Link Artificial Neural Network based Load Cell Compensation. 7 p. <http://www.imeko.org>.

Application of Artificial Neural Network Models in Simulation of Drought Severity (A Case of Torshakli Station in Golestan Province)

Shahhossein Dastjerdi, S

Postgraduate of Department of Agricultural Economics, Ferdowsi University of Mashhad, Iran

Shahnoushi, N

Associate Professor of Department of Agricultural Economics, Ferdowsi University of Mashhad, Iran

Darjani, A

Assistant Professor of Department of Agricultural Economics, Gorgan University of Agricultural Sciences and Natural Resources, Iran

Davari, K

Associate Professor of Department of Water Engineering, Ferdowsi University of Mashhad, Iran

Abstract

Drought prediction gets suitable means for managers and policymakers in various parts to outline future policies for optimizing costs through this prediction and mitigate losses due to future droughts on vulnerable sectors with pursuing preventive measures and arranging drought management strategies. In this study, the Standardized Precipitation Index (SPI) and Artificial Neural Network method were utilized to predict the droughts. Also, a record of Torshakli evaporation gauge station in Gonbad-e-Kavous County during 1975-2008 was used to predict the drought. Through Correlation coefficient (r), Mean Square Error (MSE) and Mean Absolute Error (MAE) measures, neural network with 7 neurons in input layer, 28 neurons and tangent hyperbolic activation function in hidden layer, a neuron with linear function in output layer, and momentum learning rule compared to implemented neural networks simulated correlation between input and output data with a high accuracy. Optimal neural network was used to predict droughts during 2009-2014 periods. The predicted values showed the occurrence of mild droughts in these periods. Generally, the results showed that Artificial Neural Network models have high accuracy in the early years of the prediction period.

Keywords: Prediction, Drought, Standardized Precipitation Index, Artificial Neural Network, Golestan