

کاربرد شبکه عصبی مصنوعی در شبیه‌سازی عناصر اقلیمی و پیش‌بینی سیکل خشکسالی (مطالعه موردی: استان اصفهان)

جواد خوشحال دستجردی: دانشیار اقلیم‌شناسی، دانشگاه اصفهان، ایران*
سیدمحمد حسینی: دانشجوی کارشناسی ارشد اقلیم‌شناسی، دانشگاه اصفهان، ایران

چکیده

در این پژوهش، از شبکه‌های عصبی مصنوعی (Artificial Neural Networks) به عنوان ابزاری توانمند در مدل‌سازی فرآیندهای غیرخطی و نامعین، به منظور پیش‌بینی سیکل خشکسالی در ۲۰ ایستگاه سینوپتیک، کلیماتولوژی و هیدرومتری استان اصفهان که حداقل ۲۰ سال آمار روزانه داشتند، استفاده شد. از نرم‌افزار MATLAB-7 و در شاخه Neural Network، برای پیش‌بینی و تجزیه و تحلیل عناصر اقلیمی کمک گرفته شد. ورودی مدل‌های ANN، داده‌های میانگین ماهانه بارش، دبی حداقل و دمای بیشینه است که این داده‌ها، بازه زمانی سال‌های ۱۳۶۰ تا ۱۳۸۳ را در بر می‌گیرند. اطلاعات ۲۰ ساله برای آموزش مدل‌ها و ۴ سال باقی مانده برای آزمایش آن‌ها به کاررفته است. شبکه مورد استفاده از نوع پرسپترون چندلایه (Multi-layer Perceptron) با الگوریتم پس‌انتشار خطا (Back Propagation) و تکنیک یادگیری مارکوارت-لونبرگ (Train LM: Levenberg-Marquardt) است. ساختارهای گوناگونی از شبکه عصبی با تغییر در لایه‌های ورودی (۶ مدل)، تعداد گره‌ها در لایه‌های پنهان و خروجی (۲ الی ۲۰ گره) ایجاد گردید. نتایج حاصل از تحقیق حاضر، نشان می‌دهد که در میان الگوهای مورد بررسی، دمای بیشینه، دبی و بارش، نقش مثبتی در پیش‌بینی خشکسالی‌های استان اصفهان داشته، با کاربرد شبکه عصبی مصنوعی می‌توان با دقت بالای ۹۵ درصد، سیکل خشکسالی استان را پیش‌بینی نمود.

واژه‌های کلیدی: شبکه عصبی مصنوعی، پیش‌بینی خشکسالی، پرسپترون چندلایه، مارکوارت-لونبرگ، استان اصفهان

مقدمه

(منهاج، ۱۳۸۴: ۷۱۵؛ رضایی، ۱۳۸۳: ۱۴۱؛ کارآموز و عراقی‌نژاد، ۱۳۸۴: ۲۹۳). این مدل‌ها، در حقیقت پارامترها را به شکل خطی وارد فرآیندهای تصمیم‌گیری نموده که در اغلب موارد نمی‌تواند به خوبی مسایل پیچیده اقلیمی-هیدرولیکی را تحلیل نمایند و ضروری است، مدل‌هایی با کارایی بیشتر به منظور پیش‌بینی پدیده‌ای غیرخطی و پیچیده معرفی

در چند دهه اخیر، اغلب محققان برای پیش‌بینی و مدل‌سازی فرآیندهای هواشناختی و هیدرولوژیک و تعیین خصوصیات سیلاب‌ها و خشکسالی‌ها از رگرسیون چندمتغیره و مدل‌های زمین‌آمار Auto Regressive و Regressive Moving Average و Integrated Moving Average استفاده کرده‌اند

پیشینه تحقیق

امروزه، تحقیقات بسیار زیادی در زمینه پیش‌بینی جریان رودخانه‌ها، شبیه‌سازی بارش-رواناب و تخمین پارامترهای هیدرولوژی با استفاده از شبکه-عصبی انجام شده است و می‌توان بیان داشت که در اغلب موارد، شبکه‌عصبی مصنوعی قادر به پیش‌بینی و شبیه‌سازی قابل‌قبول پارامترهای هیدرولوژیک است. توکا و مارکز^۴ (۲۰۰۰)، کیسی^۵ (۲۰۰۴)، سیگیزوگلا^۶ (۲۰۰۵)، رامیرز^۷ و همکاران (۲۰۰۵)، آنکتیل و رات^۸ (۲۰۰۵)، جی^۹ و همکاران (۲۰۰۵)، سینگ^{۱۰} (۲۰۰۶)، چن و آدامز^{۱۱} (۲۰۰۶)، ونگ^{۱۲} و همکاران (۲۰۰۶)، صفارپور (۱۳۸۱)، عراقی‌نژاد و کارآموز (۱۳۸۳)، دستورانی (۱۳۸۶)، درواری (۱۳۸۶)، شادمان مطلق و همکاران (۱۳۸۶)، نیسی و خلیلی (۲۰۰۶)، حسینی و برهانی (۲۰۰۹).

در زمینه پیش‌بینی سیکل خشکسالی و شبیه‌سازی عناصر اقلیمی با استفاده از ساختارهای دینامیکی و مدل‌های ارایه شده، توسط شبکه عصبی مصنوعی نیز تحقیقات گسترده‌ای توسط پژوهشگرانی، مانند؛ کریسبو و مورا^{۱۳} (۲۰۰۳)، در اسپانیا، کیم و والدس^{۱۴} (۲۰۰۳)، در حوضه رودخانه کانچوس در مکزیکو، میشر و دیزای^{۱۵} (۲۰۰۶)، در حوضه رودخانه

شوند (کیم و والدس^۱، ۲۰۰۳:۳۲۲). بدین خاطر متخصصان و دانشمندان علم هیدرولوژی و سایر رشته‌های مرتبط در پی ایجاد مدل‌هایی مناسب، به منظور پیش‌بینی بهنگام این حوادث شده‌اند. ظهور تئوری‌های توانمندی، همچون: الگوریتم‌های فازی^۲، شبکه‌عصبی و فیلترآلمن، تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک در علوم مختلف مربوط به آب ایجاد کرده است.

امروزه از جمله روش‌های کارآمد که استفاده فراوانی در علوم مربوط به هوا و آب دارد، شبکه عصبی مصنوعی (ANN) است که به عقیده محققان امر، علت اصلی مقبولیت و استفاده روزافزون آن، قدرت و سرعت بالا در شبیه‌سازی فرآیندهایی است که درک و شناخت درستی از آن وجود نداشته و یا بررسی آن‌ها با دیگر روش‌های موجود، بسیار دشوار و وقت‌گیر است. به طور کلی، می‌توان اظهار داشت، مدل شبکه‌عصبی مصنوعی، مدلی قوی با توانمندی بالا است که می‌توان با دیدگاهی مثبت در پیش‌بینی مسایل اقلیمی - هیدرولوژیک به آن نگرینست؛ بخصوص آنجا که این شبکه، قادر است قانون حاکم بر داده‌ها، حتی داده‌های مغشوش را استخراج نماید (دهقانی و احمدی، ۱۳۸۷:۱۷۹) و در ضمن نیازی به توضیح صریح طبیعت فرآیندها به صورت ریاضی ندارد (باشر^۳ و همکاران، ۲۰۰۰:۱۰).

4 - Toka & Markus.

5 - Kisi.

6 - Cigizoglu.

7 - Ramirez.

8 - Anctil & Rat.

9 - Jy.

10 - Singh.

11 - Chen & Adamz.

12 - Wang.

13 - Crespo & Mora.

14 - Kim & Valdes

15 - Mishear & Desai.

1 - Kim & Valdes

2 - Fuzzy Algorithms

3 - Basheer

کرده، نشان دادند که مدل تأخیر زمانی شبکه عصبی، تطابق بیشتری با مقادیر Z مشاهده‌ای دارد و روشی مطلوب در پیش‌بینی خشکسالی‌ها در آینده است. هدف این مقاله، شبیه‌سازی عناصر اقلیمی و هیدرومتری مؤثر در پدیده خشکسالی، مانند: دمای بیشینه، دبی حداقل و بارش جهت پیش‌بینی سیکل خشکسالی استان اصفهان است. در این راستا، از شبکه‌های عصبی مصنوعی و سری زمانی^۷ پارامترهای مربوطه استفاده گردید.

مواد و روش‌ها

منطقه مطالعاتی

منطقه مطالعاتی در این پژوهش، استان اصفهان است که بین ۴۲° تا ۳۰° ۳۰' عرض شمالی و ۴۰° تا ۴۹° ۳۰' طول شرقی با وسعت ۱۰۷۰۲۷ کیلومترمربع در مرکز ایران واقع شده است (اطلس جامع گیئاشناسی، ۱۳۸۲: ۳۱). ایستگاه‌های مورد مطالعه در این استان، شامل هجده ایستگاه سینوپتیک و کلیماتولوژی و دو ایستگاه هیدرومتری (چهلگرد و دامنه فریدن) با دوره آماری ۲۰ سال و بالاتر است که آمار مورد نیاز آن‌ها از سازمان هواشناسی و سازمان آب منطقه‌ای استان دریافت و تجزیه و تحلیل گردید. در نهایت ۲۴ سال دوره آماری مشترک از سال ۱۳۶۰ تا ۱۳۸۳ برای مطالعه انتخاب گردید. دلیل انتخاب دوره آماری ۲۴ ساله، این است که اولاً داده‌های موجود در سال‌های اخیر با توجه به افزایش اطلاعات دیده‌بان‌ها و گسترش تکنولوژی ثبت داده‌ها، از دقت و اعتبار بیشتری برخوردارند و ثانیاً به دلیل خلأ کمتر

کانابتی در شرق هند و کامیلو^۱ (۲۰۰۸)، در حوضه رودخانه آلتوتاجو در اسپانیا انجام شده است.

در ایران، کارآموز و همکاران (۱۳۸۳)، برای پیش‌بینی سری‌های زمانی هیدرولوژیک، بخصوص سری زمانی بارش ماهانه از شبکه‌های عصبی زمانمند، مانند: شبکه آدلین تطبیقی^۲، شبکه عصبی با ورودی تأخیر یافته^۳ (IDNN)، شبکه عصبی بازگشتی تأخیر زمانی^۴ (TDRNN) و مدل آماری آریمما استفاده کرده، نشان دادند که مدل TDRNN، بهترین پیش‌بینی یک-ماه جلوتر و TDNN، بهترین مدل برای پیش‌بینی شش‌ماه جلوتر بارش را در مقایسه با دیگر مدل‌ها انجام می‌دهند. صداقت کردار و فتاحی (۱۳۸۷)، با استفاده از شبکه عصبی مصنوعی و سیگنال‌های بزرگ مقیاس اقلیمی به مطالعه خشکسالی‌های ایران پرداختند. نتایج حاصل از خروجی مدل عصبی نشان داد که طی فاز گرم ENSO و فاز منفی NAO، شرایط ترسالی و طی فاز سرد ENSO و مثبت NAO، شرایط خشکسالی در ایران به وقوع می‌پیوندد. افخمی و همکاران (۱۳۸۸)، به پیش‌بینی خشکسالی در ایستگاه سینوپتیک یزد با استفاده از دو مدل برگشتی RN^۵ و TLRN^۶ از ساختارهای دینامیک شبکه عصبی مصنوعی پرداختند. نتایج مطالعات آن‌ها نشان داد، مدل TLRN کارایی بیشتری برای شبیه‌سازی پدیده خشکسالی نسبت به سایر مدل‌ها دارد. یزدانی و بانژاد (۱۳۸۸)، خشکسالی‌های هیدرولوژیک در استان همدان را با استفاده از شبکه عصبی مصنوعی پیش‌بینی

- 1 - Camilo.
- 2 - Adaptive Adeline
- 3 - Input Delayed Neural Network
- 4 - Time Delay Recurrent Neural Network
- 5 - Recurrent network
- 6 - Time Lag Recurrent Network

7 - Time series.

(Training stage) و ۱۰ درصد در مرحله تست (Test stage) استفاده قرار گردید.

اطلاعات و آمار هواشناسی در این بازه زمانی، میزان داده‌های بازسازی شده کمتر است. به طور کلی، از مجموعه این داده‌ها، ۹۰ درصد در مرحله آموزش



شکل ۱). موقعیت استان اصفهان و توزیع فضایی ایستگاه‌های مورد مطالعه. منبع: نویسندگان.


جدول ۱). مشخصات ریاضی ایستگاه‌های مورد مطالعه در استان اصفهان. منبع: نویسندگان

ارتفاع از سطح دریا (متر)	طول جغرافیایی (درجه و دقیقه)		عرض جغرافیایی (درجه و دقیقه)		نام ایستگاه	ارتفاع از سطح دریا (متر)	طول جغرافیایی (درجه و دقیقه)		عرض جغرافیایی (درجه و دقیقه)		نام ایستگاه
۲۳۰۰	۵۰	۲۰	۳۳	۰۵	بادبجان	۲۲۳۴	۵۱	۳۵	۳۳	۳۴	ایبانه
۱۰۵۶	۵۲	۰۰	۳۳	۴۲	جنگلبانی بادرود	۱۷۶۸	۵۱	۱۸	۳۲	۲۴	ذوب آهن
۱۷۰۰	۵۱	۵۱	۳۲	۰۱	قمشه	۲۱۰۰	۵۰	۲۶	۳۲	۴۷	سینگرد
۲۳۰۰	۵۰	۱۹	۳۳	۱۴	خونسار	۱۳۰۰	۵۱	۲۹	۳۱	۰۰	خفر
۹۸۲	۵۱	۲۷	۳۳	۵۹	کاشان	۱۵۴۳	۵۱	۵۲	۳۲	۴۰	شرق اصفهان
۱۲۵۰	۵۲	۳۷	۳۲	۲۴	ورزنه	۱۴۱۶	۵۳	۴۰	۳۳	۲۰	نثارک
۲۳۰۰	۵۰	۲۹	۳۳	۰۱	دلغنه فریدون	۲۲۷۴	۵۱	۴۲	۳۱	۱۲	حنا
۲۱۵۰	۵۱	۲۷	۳۱	۵۵	همگین	۱۶۰۰	۵۳	۰۵	۳۲	۵۲	نابین
۱۵۵۰	۵۱	۴۰	۳۲	۳۳	اصفهان	۲۱۰۰	۵۰	۳۸	۳۲	۴۶	چادگان
۱۸۰۰	۵۱	۱۴	۳۲	۲۳	پل کله	۲۴۹۰	۵۰	۰۶	۳۲	۵۶	فریدون شهر

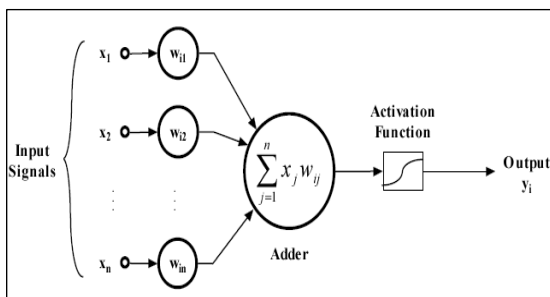
تئوری ریاضی شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی در واقع، مدل ساده‌شده‌ای از مغز انسان است که توانایی رخ دادن فرآیندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی - های هر سیستمی را داراست؛ ضمناً این شبکه با داده -

های موجود طی فرآیند یادگیری، آموزش داده می‌شود و به منظور پیش‌بینی در آینده استفاده می‌گردد. نرون - های شبکه عصبی در حقیقت، شکل بسیار ساده از نرون‌های بیولوژیک هستند، ولی از توانایی کمتری نسبت به آن‌ها برخوردارند (شکل ۲ و ۳).



شکل ۳: ساختار یک نرون طبیعی (بیولوژیک)



شکل ۲: ساختار یک نرون مصنوعی

در سال‌های اخیر، چندین تقریب‌گر عمومی تابع^۶ پیشنهاد شده است که از آن جمله می‌توان پرسپترون چند لایه (MLP) را نام برد. یک نقطه قدرت عملی این سیستم‌ها، این است که می‌توانند توابع غیرخطی را با تعداد زیادی متغیر، تقریب بزنند و از اطلاعات موجود در مجموعه‌های بسیار بزرگ عددی استفاده کنند (تشنه‌لب و منشی، ۱۳۸۲: ۴۳۵). به دلیل آن که الگوریتم آموزش در شبکه‌های MLP معمولاً پس انتشار (BP) است و ما نیز در پژوهش حاضر از آن استفاده کردیم، ذیلاً به محاسبات شبکه‌های عصبی در حالت پیشرو^۷ می‌پردازیم:

$$Net_{pi} = \sum W_{ij} a_{pi} + b_i$$

در این رابطه، مقدار خروجی لایه قبلی و W_{ij} وزن‌های لایه مربوطه و b_i میزان بایاس است. در واقع، این رابطه رابطه ای خطی است. سپس مقدار $F(Net_{pi})$

عموماً هر شبکه عصبی از سه لایه تشکیل شده که عبارتند از: ۱- لایه ورودی^۱، شامل چند نرون است که در این پژوهش، دمای بیشینه، متوسط بارش ماهانه و دبی حداقل را دریافت می‌کند؛ ۲- لایه پنهان^۲، شامل تعدادی نرون متغیر است که تعداد بهینه آن‌ها برای حداقل شدن خطا (RMSE, R, MAE) از طریق آزمایش و تکرار تعیین می‌گردد؛ ۳- لایه خروجی^۳، که برای افزایش سرعت شبکه در این لایه، از تابع فعالساز^۴ استفاده می‌شود تا با استفاده از آن هم سرعت سرعت یادگیری افزایش یابد و هم مقادیر خروجی بدون تغییر به شبکه ارائه شده، در نهایت خروجی مطلوب را بسازد.

معماری شبکه‌های عصبی چند لایه^۵

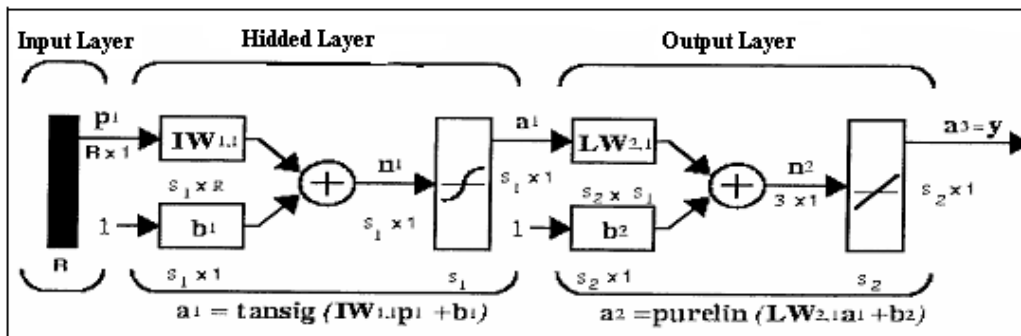
- 1 - Input layer
- 2 - Hidden layer
- 3 - Output layer
- 4 - Activation function
- 5 - MLP Network Architecture

^۶ - Universal Approximator Function

^۷ - Feed-Forward

محاسبه می‌شود که F ، یک تابع محرک است که در این مقاله، تابع فعال ساز لایه پنهان، از نوع تانژانت سیگموئید (Tan-Sigmoid Function) با رابطه

محاسبه می‌شود که F ، یک تابع محرک است که در این مقاله، تابع فعال ساز لایه پنهان، از نوع تانژانت سیگموئید (Tan-Sigmoid Function) با رابطه



شکل ۴: معماری شبکه های عصبی چند لایه

- ۱- جمع‌آوری و پیش پردازش داده‌های مورد نیاز برای شبکه عصبی مورد نظر؛
- ۲- تعیین نوع و ساختار مناسب برای شبکه عصبی و ایجاد شبکه کارآمد؛
- ۳- آموزش دادن شبکه با قسمتی از داده‌های جمع‌آوری شده (مرحله آموزش)؛
- ۴- آزمایش شبکه آموزش داده شده با باقیمانده داده‌ها (مرحله آزمون)؛
- ۵- در صورت قابل قبول بودن نتیجه آزمون، ذخیره شبکه و در غیر این صورت، تکرار مرحله ۲ تا ۴.

برای پیش‌بینی، بایستی مقادیر b_i و W_{ij} آموزش ببینند، یعنی مقادیر آن‌ها طوری طراحی شود که سیستم بتواند پیش‌بینی را صورت دهد. در چنین حالتی، بایستی ما یک الگوریتم برگشتی (محاسبات پسرو) برای آموزش وزن‌ها و بایاس‌ها^۱ داشته باشیم. فرض- کنید، obc مقادیر مشاهده شده (واقعی) و pre مقادیر پیش‌بینی شده (محاسبه شده) باشند، الگوریتم آموزش در اینجا روش BP است، که محاسبات آن به صورت پس‌انتشارخطا بوده و به شکل زیر است:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial W_{ij}}$$

$$E = \sum_i (obc_i - pre_i)^2$$

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

مراحل طراحی و پیاده سازی شبکه عصبی

مشخصات کلی شبکه عصبی مورد استفاده در پیش‌بینی خشکسالی برای ساخت مدل و پیش‌بینی خشکسالی‌ها در استان اصفهان، باید شبکه را آموزش دهیم و چون قوانین خاصی برای آموزش و طراحی شبکه‌های عصبی موجود نیست، بنابراین مجبوریم چندین

^۱ - Biases and Weights

است. با توجه به این موضوع که نرم افزار MATLAB مقادیری را به عنوان پیش فرض برای این ضرایب در نظر می‌گیرد، با انجام تکرارهای متعدد، اثر تغییر این پارامترها بر روی عملکرد شبکه‌ها، بررسی و در نهایت ضرایبی که نتایج مناسبتری داشت، برای آموزش شبکه به مدل معرفی شدند. آمار بارش، دبی و دمای بیشینه در مقیاس زمانی ماهانه و در دوره آماری ۲۴ ساله استفاده شد. داده‌های ورودی و خروجی به دو دسته تقسیم شدند؛ اطلاعات ۲۰ سال برای آموزش مدل‌ها و ۴ سال باقیمانده برای آزمون آن‌ها به کار رفته است. در ضمن، به علت ورود پارامترهای مورد نظر به مدل، لازم است چندین مدل طراحی شود. در این پژوهش، از شش مدل ورودی به شرح زیر استفاده شد:

ساختار را مورد آزمایش کنیم. لازم است به مسأله مهمی اشاره شود و آن رویکردی است که برای جلوگیری از بیش‌آموزی انتخاب می‌شود. با انتخاب داده‌های جداگانه به منظور انجام واسنجی (همزمان با عمل آموزش و یادگیری در شبکه مصنوعی) می‌توان با اطمینان بیشتری نسبت به عدم بیش‌آموزی بودن مدل‌های ایجادشده گام برداشت (چالکف (Schalkoff.) ۱۹۹۷ و مانیزو (Maniezzo) ۱۹۹۴: ۴۳). در این راستا، از شبکه پرسپترون چندلایه (MLP) با الگوریتم پس‌انتشارخطا (BP) و تکنیک یادگیری مارکواریت-لونیبرگ (LM) و برای آموزش شبکه، از قانون دلتا بار دلتا (Delta Bare-Delta) استفاده شد. در قانون یادگیری دلتا، ضریب نرخ آموزش (α) و ضریب مومنتم (η) به عنوان پارامتری یادگیری استفاده شده

شماره مدل	نام مدل	شماره مدل	نام مدل
۱	$Q_i = f(P_{ave}, T_{max}, q_{min_{chehl}}, q_{min_{damaneh}})$	۴	$Q_i = f(P_{ave}, T_{max}, q_{min_{chehl}})$
۲	$Q_i = f(T_{max}, q_{min_{chehl}}, q_{min_{damaneh}})$	۵	$Q_i = f(P_{ave}, T_{max}, q_{min_{damaneh}})$
۳	$Q_i = f(P_{ave}, q_{min_{chehl}}, q_{min_{damaneh}})$	۶	$Q_i = f(P_{ave}, T_{max})$

شاخص‌های آماری مانند جذر میانگین مربعات خطا^۱، ضریب همبستگی^۲ و متوسط قدر مطلق خطا^۳ استفاده شده است. روابط این معیارها به شکل زیر است:

$q_{min_{chehl}}$ ، $q_{min_{damaneh}}$: دبی حداقل در ایستگاه-های هیدرومتری دامنه فریدن و چهلگرد، T_{max} : دمای بیشینه در ایستگاه‌های مورد مطالعه و P_{ave} : متوسط بارندگی ماهانه در ایستگاه‌های مورد مطالعه.

معیارهای ارزیابی عملکرد شبکه

به منظور ارزیابی و مقایسه نتایج حاصل از روش‌ها و مدل‌های به کار برده شده در این پژوهش، از

1 - Root Mean Square Error (RMSE)
 2 - Random Error (R^2)
 3 - Mean Absolute Error (MAE)

$$RMSE = \sqrt{\sum_{i=1}^n \left(\frac{obs - pre}{n} \right)^2}$$

(۱). جذر میانگین مربعات خطا (RMSE)

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

(۲). ضریب همبستگی (R^2)

$$MAE = \frac{\sum_{i=1}^n |obs - pre|}{N}$$

(۳). متوسط قدرمطلق خطا (MAE)

یافته های تحقیق

تغییر تعداد نرون‌ها در الگوریتم‌های سه‌گانه یادگیری در هر یک از سه الگوریتم طراحی شده، تعداد نرون‌ها از ۲ تا ۲۰ نرون در لایه مخفی تغییر داده شد؛ به طوری که از تعداد نرون‌های کم شروع و تا ۱۲ نرون ادامه می‌یابد. تغییرات میزان خطای RMSE در شش مدل پیش‌بینی شده در شکل ۵ نشان داده شده است. بر اساس آزمون‌های مورد بررسی، بهترین تکنیک یادگیری از میان سه الگوریتم یادگیری LM، GDX، CGF^۳، تکنیک LM شناخته شد، زیرا سرعت بالا، دقت بالا و خطای کمتری نسبت به مدل‌های دیگر دارد و در مسایل تخمین تابع پارامترهای کمتر از ۱۰۰ الگوریتم، کارایی بالاتری از خود نشان می‌دهد. البته، شایان ذکر است که این تکنیک در


در روابط فوق، obs مقادیر مشاهده‌ای^۱، \overline{obs} میانگین مقادیر مشاهده‌ای و pre مقادیر پیش‌بینی شده^۲، \overline{pre} میانگین مقادیر پیش‌بینی توسط شبکه-مدل و N ، تعداد کل داده‌ها در هر مرحله از آزمون‌های آموزش و آزمایش است. هرچه مقدار RMSE و MAE به صفر و مقدار R به یک نزدیکتر باشد، نشان‌دهنده نزدیکتر بودن مقادیر مشاهده شده و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است. ضریب همبستگی، مربعات خطا و قدرمطلق خطا در نرم افزار MATLAB در شاخه Neural Network بررسی گردیده است.

³ - Fletcher-Powell Conjugate Gradient

¹ - Observed

² - Predicted

موقعی که با کمبود داده رو به رو هستیم، چندان کارایی ندارد، اما این ضعف، از اهمیت آن در بسیاری از پیش‌بینی‌ها نمی‌کاهد.



شکل ۵) تغییرات RMSE در سه الگوریتم یادگیری (LM,CGF,GDX)

نمایانگر تأثیر دمای بیشینه، میزان دبی و متوسط بارش در تخمین خشکسالی‌های ایستگاه‌های مورد مطالعه است. معماری شبکه پس از آموزش و خطاهای مکرر به صورت (۱-۲۰-۴) بهینه شد؛ یعنی ۴ نرون در لایه ورودی، ۲۰ نرون در لایه پنهان و یک نرون در لایه خروجی (جدول ۲).

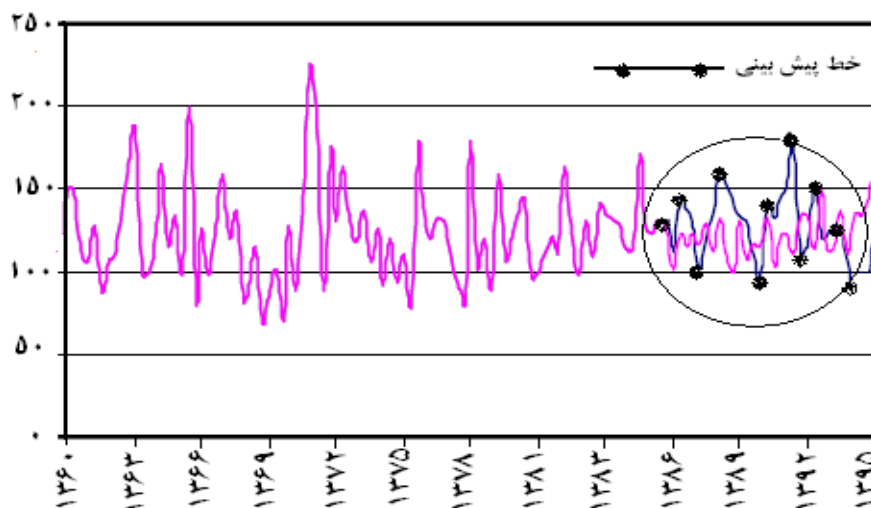
تعیین مهمترین الگو در مرحله آموزش و تست به منظور بررسی عملکرد ANN در شبیه‌سازی عناصر اقلیمی، شش مدل طراحی را با استفاده از تکنیک یادگیری LM و تعداد ۲۰-۲ نرون بررسی نمودیم. میزان خطای MAE، RMSE و R^2 محاسبه شد و الگوی ۱، به عنوان بهترین الگو از میان شش مدل، مورد بررسی انتخاب گردید که این خود

جدول ۲: آماره‌های مربوط به انواع الگوها و مدل‌ها

انواع مدل‌ها	نوع الگوریتم	ساختار لایه‌ها	RMSE		R^2		MAE	
			آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
مدل ۱	LM	۴-۲۰-۱	۲/۲۳	۰/۹۷	۰/۹۰	۹۴	۰/۸۲	۰/۹۰
مدل ۲	LM	۲-۸-۱	۶/۲۱	۱/۲۷	۰/۳۲	۰/۸۹	۱/۳۲	۲/۴۰
مدل ۳	LM	۳-۱۲-۱	۳/۹۰	۲/۱۹	۰/۴۳	۰/۶۴	۲/۰۶	۲/۸۷
مدل ۴	LM	۴-۸-۱	۵/۷	۱/۹	۰/۳۳	۰/۷۷	۰/۹۰	۱
مدل ۵	LM	۵-۱۰-۱	۴/۳۲	۲/۲۴	۰/۶۸	۰/۸۳	۲/۰۹	۲/۵۶
مدل ۶	LM	۶-۶-۱	۶/۳۱	۲/۳۴	۰/۷۳	۰/۹۳	۱/۴۴	۲/۰۰

مشخص گردید که روند بارش این ایستگاه در سال‌های اخیر کاهش چشمگیری داشته که ادامه همین روند در سال‌های پیش بینی شده توسط مدل تأیید شده است (شکل ۶).


به منظور پیش بینی روند بارش به عنوان بارزترین و مهمترین عنصر اقلیمی در تعریف خشکسالی‌ها، از شبکه عصبی مصنوعی طی یک دوره ۱۲ ساله (۱۳۹۵-۱۳۸۳) در ایستگاه سینوپتیک اصفهان استفاده شد و



شکل ۶) پیش بینی بارش سالانه اصفهان با شبکه عصبی طی دوره آماری ۱۳۸۳-۱۳۹۵


الگوهای مختلف در دو ایستگاه هیدرومتری چهلگرد و دامنه فریدن را نشان داده، دقت بالای مدل و شبکه را به نمایش می‌گذارد (۸۳ و ۸۹ درصد).

- شکل‌های ۷ و ۱۰، نتایج حاصل از مدل شبکه عصبی مصنوعی در شبیه‌سازی مقدار دبی و مقایسه آن با مقادیر مشاهده شده (واقعی) برای




شکل ۸) مقایسه نتایج شبیه سازی شده و مشاهده شده دبی در

ایستگاه هیدرومتری چهلگرد




شکل ۷) رابطه دبی اوج برآوردی و مشاهده‌ای

براساس دسته داده‌های آزمون



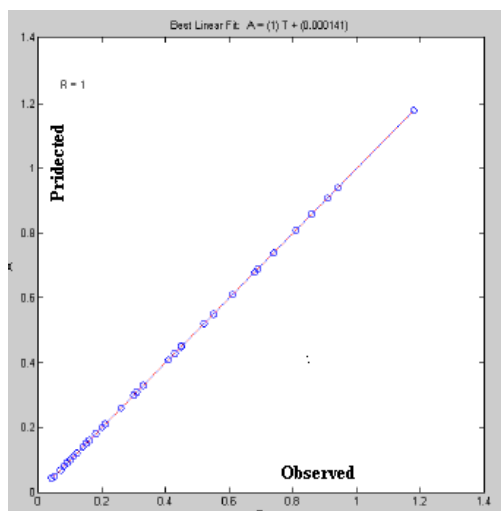
شکل ۱۰) مقایسه نتایج شبیه سازی شده و مشاهده شده دبی در ایستگاه هیدرومتری دامنه فریدن



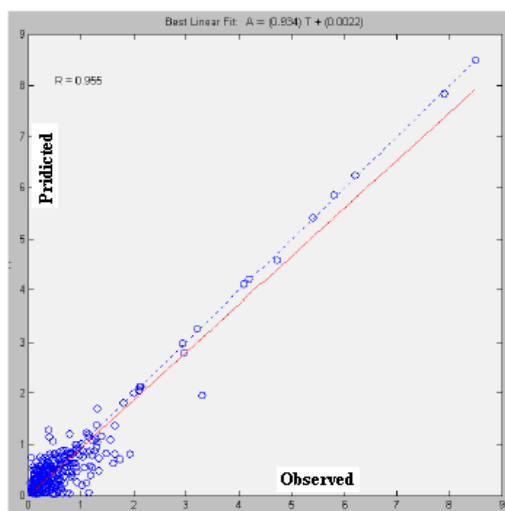
شکل ۹) رابطه دبی اوج برآوردی و مشاهده‌ای براساس دسته داده‌های آزمون

گذاشته شده است و دقت بالای مدل ANN را نشان می‌دهد.

هیدروگراف‌های مربوط به پیش‌بینی شبکه در الگوریتم LM و مدل ۱، به ترتیب در مرحله آموزش (شکل ۱۱) و مرحله آزمون (شکل ۱۲) به نمایش



شکل ۱۲) نمودار بهترین الگو در مرحله تست



شکل ۱۱) نمودار بهترین الگو در مرحله آموزش

مسئله‌ای که به دنبال حل آن هستیم، متفاوت است. با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز کالیبره کردن مناسب آن می‌توان گفت، این تکنیک ابزاری بسیار کارآ و قدرتمند برای مدل کردن خشکسالی‌های استان اصفهان است.

بحث و نتیجه گیری

با توجه به کارایی شبکه های عصبی مصنوعی در مدل سازی عناصر اقلیمی و پیش‌بینی سیکل خشکسالی‌ها، واضح است که توانایی‌های این تکنیک با توجه به ساختارهای مختلف آن و نیز طبیعت

برجسته‌ترین ویژگی این مدل در مقایسه با سایر مدل‌هاست.

منابع

. افخمی، حمیده؛ دستورانی، محمدتقی و ملکی-نژاد، حسین. (۱۳۸۸). «بررسی کاربرد مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی و پیش‌بینی خشکسالی»، دومین همایش ملی اثرات خشکسالی و راهکارهای مدیریتی آن، ۳۱-۳۰ اردیبهشت ۱۳۸۸، اصفهان.

. تشنه لب، محمد و مهدی منشی. (۱۳۸۲). «پیش‌بینی اقلیمی پارامترهای هواشناسی با استفاده از شبکه‌های عصبی - فازی بر اساس آموزش پارامترهای بخش تالی»، سومین کنفرانس منطقه‌ای تغییر اقلیم، ۲۹ مهر الی ۱ آبان ۱۳۸۲، اصفهان.

. درواری، زهرا. (۱۳۸۶). شبیه‌سازی جریان رودخانه‌ها با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: حوضه معرف کسلیان)، پایان‌نامه کارشناسی ارشد مهندسی آبخیزداری، دانشگاه مازندران، دانشکده منابع طبیعی.

. دستورانی، محمدتقی. (۱۳۸۶). «کاربرد مدل‌های هوش مصنوعی در شبیه‌سازی و پیش‌بینی بهنگام جریان‌های سیلابی»، مجله علوم و فنون کشاورزی و منابع طبیعی، سال یازدهم، ش ۴۰، تابستان ۱۳۸۶، صص ۲۷-۳۶.

. دهقانی، امیراحمد و رضا احمدی. (۱۳۸۷). «تخمین آبدهی حوزه‌های آبخیز فاقد آمار با استفاده از شبکه عصبی مصنوعی»، اولین کنفرانس بین‌المللی بحران آب، ۲۲-۲۰ اسفندماه ۱۳۸۷، دانشگاه زابل.

- مناسبترین ساختار برای پیش‌بینی سیکل خشکسالی در استان اصفهان به کمک شبیه‌سازی عناصر اقلیمی، با ۴ نرون در لایه ورودی، ۲۰ نرون در لایه پنهان و یک نرون خروجی؛ یعنی آرایش (۱-۲۰-۴) است که میزان جذر میانگین مربعات خطا، ضریب همبستگی و متوسط قدر مطلق خطا به ترتیب برای مرحله آموزش ۲/۲۳، ۰/۹۰ و ۰/۸۲ و برای مرحله آزمایش ۰/۹۷، ۰/۹۴، ۰/۹۰ برآورد شده است.

- خشکسالی هیدرولوژیک در استان اصفهان بین سال‌های ۱۳۸۳-۱۳۷۵، بیشترین شدت را داشته و این روند توسط داده‌های شبیه‌سازی شده در نرم‌افزار شبکه عصبی در ایستگاه‌های چهلگرد و دامنه فریدن کاملاً مشهود است.

- این تکنیک (LM) در مواقعی که با کمبود داده روبرو هستیم، چندان کارایی ندارد، اما این ضعف از اهمیت آن در بسیاری از پیش‌بینی‌ها بخصوص سرعت یادگیری و دقت بالای آن نمی‌کاهد.

- شبکه‌های عصبی به علت داشتن خاصیت غیر خطی و نامعین نسبت به روش‌های کلاسیک از اهمیت بیشتری برخوردارند. البته، شایان ذکر است که شبکه‌های عصبی در درون خود مدل‌های خطی را نیز شامل می‌شوند؛ یعنی به تناسب با روش‌های کلاسیک، بسیار جامع‌تر هستند.

- به طور کلی، می‌توان اظهار داشت که مدل شبکه عصبی مصنوعی، مدلی قدرتمندی با توانمندی بالا است که می‌توان با دیدگاهی مثبت در پیش‌بینی مسایل هیدرولوژیکی به آن نگریست؛ بخصوص آنجا که این شبکه قادر است قانون حاکم بر داده‌ها، حتی داده‌های مغشوش را استخراج نماید و این خصوصیت،

- رضایی، علی. (۱۳۸۳). مدل‌سازی منطقه‌ای دبی - های اوج زیرحوزه‌های آبخیز سدسفیدرود با استفاده از شبکه عصبی مصنوعی، پایان‌نامه دکتری در علوم و مهندسی آبخیز، دانشکده منابع طبیعی، دانشگاه تهران.
- شادمان مطلق، عادل؛ ابراهیمی، حسین؛ رهنما، محمدباقر. (۱۳۸۶). پیش‌بینی جریان رودخانه سفیدرود با استفاده از شبکه عصبی مصنوعی، ششمین کنفرانس هیدرولیک ایران، ۱۵-۱۳ شهریورماه ۱۳۸۶، دانشگاه شهرکرد.
- صداقت‌کردار، عبدل. و ابراهیم فتاحی (۱۳۸۷)، شاخص‌های پیش‌آگاهی خشکسالی در ایران، مجله جغرافیا و توسعه، ش ۱۱، بهار ۱۳۸۷، صص ۵۹-۷۶.
- صفارپور، شبنم. (۱۳۸۱). تخمین آستانه شروع رواناب با استفاده از شبیه‌سازی داده‌ای بارش و رواناب، پایان‌نامه کارشناسی ارشد مهندسی آبخیزداری، دانشگاه تربیت مدرس: دانشکده منابع طبیعی.
- عراقی‌نژاد، شهاب و محمد کارآموز. (۱۳۸۴). «پیش‌بینی بلندمدت رواناب با استفاده از شبکه‌عصبی- مصنوعی و سیستم استنتاج فازی»، مجله تحقیقات منابع آب ایران، ش ۲، صص ۲۹-۴۱.
- کارآموز، محمد و شهاب عراقی‌نژاد. (۱۳۸۴). هیدرولوژی پیشرفته، انتشارات دانشگاه صنعتی امیرکبیر، صص ۲۹۳-۲۹۵.
- کارآموز، محمد، رضوی، سیدسامان، عراقی‌نژاد، شهاب. (۱۳۸۳). «پیش‌بینی بلند مدت بارش با استفاده از شبکه‌های عصبی زمانمند»، اولین کنفرانس سالانه مدیریت منابع آب ایران، ۲۶-۲۷ آبان ۱۳۸۳، دانشکده فنی دانشگاه تهران.
- منهاج، محمد باقر. (۱۳۸۴). مبانی شبکه‌های- عصبی هوش محاسباتی، ج ۱، مرکز نشر پروفیسور حسابی.
- یزدانی، وحید و حسین بانژاد. (۱۳۸۸). «پیش- بینی خشکسالی هیدرولوژیکی با استفاده از شبکه عصبی مصنوعی، دومین همایش ملی اثرات خشکسالی و راهکارهای مدیریت آن، ۳۱-۳۰ اردیبهشت ۱۳۸۸، اصفهان.
15. Anctil, F., and Rat,A.(2005).Evaluation of neural network stream flow forecasting on 47 Watershed.J. Hydrologic Engrg.,ASCE,10(1),85-88.
16. Camilo,J.,(2008). Prospecting Drought with Stochastic Artificial Neural Networks. Journal of hydrology, Vol.352, pp. 174-180.
17. Basheer, I. A, Hajmeer, M, (2000). Artificial neural networks: fundamentals, computing, design, and applivation, Journal of Microbiological Methods,Volume 43, PP: 3-31.
18. Chen,J.,Adams,B.J.,(2006). Integration of Artificial Neural Networks with Conceptual Models in Rainfall – Runoff Modeling, Journal of Hydrology, Vol 318. pp, 232- 249.
19. Cigizoglu,H.K.,(2005).Application of Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation.Journal of Hydrologic Engineering, ASCE,10(4), pp. 336-340.
20. Crespo,J.L. and Mora,E.,(2003). Drought Estimation with Neural Networks. Advances in Engineering Software. Vol. 18, pp. 167-170.
21. Hosseini,S,M., and Borhani,R.,(2009). The Application of Artificial Neural Network in Estimating The River Yield by Minimum Temperature and Discharge. (Case Study: Basin Hamoon). The

32. Wang, W., Pitter, H., A.J.M. van, Gellde r., J.K. Vrijling., Jun, Ma. (2006). Forecastin Daily Stream flow Using Hybrid ANN Model. Journal of Hydrology, Vol. 324, pp. 383-399.
- First International Conference of Water Crisis. 10-12 March 2009. Zabol University.
22. Jy, p.E., J.Han, S. Annambhotla and S. Bryant. (2005). Artificial neural network for forecasting watershed runoff and stream flows. J. Hydrologic Engrg. ASCE, 10(3), 216-222.
23. Kim, T, Valdes, J.B. (2003). Nonlinear model for drought forecasting based on conjunction of wavelet transforms and neural networks, Journal of Hydro. Eng. ASCE, Volume 8(6), PP: 319-328.
24. Kisi. O., (2004). River Flow Modeling Using Artificial Neural Networks. Journal of Hydrologic Engineering. ASCE 9(1), pp. 60-63.
25. Maniezzo, V., (1994). Genetic Evaluation of the Topology and Weight Distribution of Neural Network, IEEE T transaction of Neural Network. Vol. 5, No. 1, pp. 39-53.
26. Mishra, A.k. and Desai, V.R., (2006). Drought Forecasting Using Feed-Forward Recursive Neural Networks. Ecological Modeling, Vol. 198, pp. 127-138.
27. Nayebi. M and Khalili. D. (2006). Daily stream Flow Predication Capability of Artificial Neural Networks as influenced by Minimum Air Temperature Data. biosystems Engineering
28. Ramirez, M., Veloh, H. Ferreira, N., (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. J of hydrology 301, 146-162
29. Schalkoff, R. j., (1997). Artificial Neural Networks, McGraw-Hill.
30. Singh, P., (2006). Suitability of Different Neural Networks in Daily Flow Suitability of Different Neural Networks in Daily Flow Forcasting. ASOC-269; no of page 11.
31. Toka, A.S. and Markus, M., (2000). Precipitation-Runoff Modeling Using Artificial Neural Networks and Conceptual Models. Journal of Hydrology Engineering, Vol. 45, pp. 156-161.