

واکاوی ارتباط دما و الگوهای پیوند از دور در حوضه آبی ایرانی دریای مازندران با استفاده از شبکه عصبی

ایرج حیدری

مرکز تحقیقات گردشگری، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

امیر گندمکار^۱

مرکز تحقیقات گردشگری، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

محسن باقری

مرکز تحقیقات گردشگری، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

تاریخ دریافت: ۱۳۹۶/۰۷/۲۵ تاریخ پذیرش: ۱۳۹۷/۰۶/۱۰

چکیده

دما یکی از پارامترهای بسیار مهم آب و هوایی است که در تعیین نقش و پراکندگی دیگر عناصر اقلیمی مؤثر می باشد. هدف از پژوهش حاضر بررسی ارتباط بین دمای ماهانه و سالانه حوضه آبی دریای مازندران و الگوهای پیوند از دور می باشد. در این راستا از داده های میانگین دمای ماهانه و سالانه ۹۷ ایستگاه همدیدی و آب و هواشناسی درون حوضه و بیرون حوضه و همچنین ۳۳ الگوی پیوند از دور طی دوره آماری (۱۹۷۰-۲۰۱۴) استفاده شد. بدین منظور مدل پرسپترون چندلایه مورد استفاده قرار گرفت. ابتدا داده ها در نرم افزار مت لب نرمال و در نرم افزار SPSS استاندارد شدند. سپس شبکه براساس الگوریتم گرادیان نزولی (SCG)، تابع متحرک هیپربولیک برای لایه های پنهان و تابع متحرک همانی برای داده های خروجی طراحی شد. در تمام ساختار شبکه ۱ تا ۲ لایه پنهان در نظر گرفته شد و بیش از ۶۰۰ شبکه ایجاد شد. طی این فرایند ۷۰ درصد از داده ها برای آموزش و ۳۰ درصد برای آزمون در نظر گرفته شد. سپس به ارزیابی عملکرد مدل، از طریق معیارهای آماری از جمله مجموع مربع خطاها و خطای نسبی پرداخته شد. نتایج نشان داد در رابطه با داده های ماهانه، دمای یک ماه پیش و الگوهای ONI و NINO3 دارای اهمیت بیشتر می باشد و ارتباط بیشتری را با دمای ماهانه حوضه مورد مطالعه نشان می دهد. در داده های سالانه نیز الگوهای NAO، AO، NCP، AMO و دمای یک سال قبل اهمیت بالای ۶۰ درصد نشان دادند. لذا می توان بیان نمود که رابطه الگوهای نامبرده با دمای سالانه بیش از سایر الگوها بوده است.

واژگان کلیدی: پیوند از دور، حوضه آبی دریای مازندران، دما، شبکه عصبی مصنوعی، مدل پرسپترون چندلایه (MLP)

مقدمه


طی سال‌های اخیر، دانشمندان به منظور تجزیه و تحلیل الگوهای اقلیمی توجه ویژه‌ای به سری‌های دمایی معطوف می‌دارند. دما در کنار بارش از مهمترین عناصر اقلیمی محسوب می‌گردد که در تعیین نقش و پراکندگی دیگر عناصر اقلیمی نیز مؤثر است (اسفندیاری و همکاران، ۱۳۸۹). پیش‌بینی عناصر اقلیمی و ارتباط سنجی آنها با سایر عناصر و عوامل اقلیمی قطعاً فرصت بیشتری را جهت برنامه‌ریزی و ارائه تمهیدات لازم در اختیار برنامه‌ریزان قرار می‌دهد. از جمله مدل‌هایی که در گذشته و در اکثر مطالعات از آنها استفاده می‌شد، مدل‌های رگرسیونی هستند. با پیشرفت علوم یکی از روش‌های هوشمند و جدید که امروزه در علوم مختلف از آنها استفاده می‌شود، شبکه‌های عصبی مصنوعی هستند که توانایی زیادی در مدلسازی و پیش‌بینی و ارتباط سنجی بین عناصر جوی و اقلیمی دارند. این شبکه‌ها با استفاده از مجموعه ورودی و خروجی، روابط بین آنها را تخمین زده و اصطلاحاً آموزش می‌بینند، به نحوی که پس از آن به ازای یک عضو جدید از مجموعه ورودی، خروجی متناظر آن را تقریب می‌زنند (کارآموز و همکاران، ۱۳۸۵). مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (گلابی و همکاران، ۱۳۹۲). یکی از شبکه‌های عصبی پر کاربرد شبکه عصبی پیش‌خور با الگوریتم پس انتشارخطا (شبکه چند لایه پرسپترون (MLP)) است که در این پژوهش جهت بررسی ارتباط بین دما و الگوهای پیوند از دور در حوضه دریای مازندران از آن استفاده شده است. در این زمینه تاکنون مطالعاتی صورت گرفته از جمله: راجو و کومار (۲۰۰۷) طبقه‌بندی ایستگاه‌های هواشناسی هند را با استفاده از روش‌های خوشه‌بندی به روش وارد، خوشه‌ای فازی و شبکه عصبی مقایسه و دریافتند روش خوشه‌ای فازی نتایج بهتری نشان داده است. ماروهازی و آبوت (۲۰۱۵) کیفیت ۸ سری دمای حداکثر کپ اوتو استرالیا را برای پیش‌بینی بارش ماهانه با استفاده از شبکه عصبی مصنوعی بررسی و دریافتند روند متوسط گرم شدن این سری‌ها در دوره ۱۸۸۷ تا ۲۰۱۳ در هر قرن برابر با ۰/۸ درجه سانتیگراد است که با افزایش دمای سطح زمین از سال ۱۸۸۰ سازگار است. همچنین تمام سری‌های دمای حداکثر از ۱۹۲۱ تا ۱۹۵۰ خنک شده‌اند. جان و همکاران (۲۰۱۵) شبیه‌سازی و پیش‌بینی تغییرات سطح آب زیرزمینی را با استفاده از مدل شبکه عصبی انجام و دریافتند نسبت تغییر و دامنه سطح آب زیرزمینی فرایخندان پایین‌تر از آنهایی است که در شیب بالا تحت گرم شدن آب و هوا هستند. پاپانتوریوس و کولوکوتسا (۲۰۱۶) پیش‌بینی دمای هوای ۴ شهر اروپا را با استفاده از شبکه عصبی انجام و مقایسه دمای هوای فصلی اندازه‌گیری شده و پیش‌بینی شده، آموزش دقیق شبکه عصبی برای هر چهار شهر اروپایی را تایید کرد. شمشیربند و همکاران (۲۰۱۶) تشعشع دریافتی ایستگاه بندرعباس را با استفاده از شبکه عصبی مصنوعی پیش‌بینی و دریافتند تشعشع پیش‌بینی شده بر مبنای داده‌های ساعات آفتابی و مجموع ساعات آفتابی از دقت بیشتری برخوردار می‌باشد. لی و همکاران (۲۰۱۷) پیش‌بینی زمان تأخیر دمای داخلی را با استفاده از شبکه عصبی المن بررسی کردند. نتایج نشان داد روش کنترل پیش‌بینی دمای محیط پیشنهاد شده بر پایه وابستگی فشار وابسته به ولتاژ VAV می‌تواند حالت تنظیم متعارف سیستم تهویه هوا VAV را تغییر دهد که برای بهبود پایداری کنترل دمای حلقه کنترل دمای داخلی و دیگر

حلقه های کنترل مربوطه مفید خواهد بود. اسفندیاری و همکاران (۱۳۸۹) دمای ماهانه ایستگاه سنندج را با استفاده از شبکه عصبی پیش بینی و نتایج نشان دهنده کارایی مناسب و دقت قابل قبول شبکه عصبی در پیش بینی دما می باشد. قلی زاده و دارند (۱۳۸۹) بارش ماهانه تهران را با مدل شبکه عصبی مصنوعی پیش بینی و نتایج نشان داد که استفاده از شبکه عصبی با یک پرسپترون ۲ لایه پنهان با ضریب یادگیری ۰/۱ و مومتم ۰/۷ مدل نسبتاً بهتری را ارائه می کند. صلاحی و همکاران (۱۳۸۹) دماهای حداکثر اردبیل را با استفاده از شبکه عصبی مصنوعی پیش بینی و پس از بررسی شاخص های عملکرد شبکه، مشاهده شد که پیش بینی دمای حداکثر با دقت قابل قبولی انجام شده است؛ به گونه ای که میزان ضریب همبستگی آن ۰/۹۹ و بیشترین اختلاف آن با داده های واقعی برابر ۰/۸۳ درجه سانتیگراد بوده است. گلابی و همکاران (۱۳۹۲) در مدلسازی ایستگاه های استان خوزستان الگوریتم های مختلف شبکه عصبی را مقایسه و دریافتند در هر سه ایستگاه الگوریتم لونبرگ - مارکواریت بهترین الگوریتم آزمایش می باشد. عزیزی و منتظری (۱۳۹۴) دماهای ماهانه ایستگاه های منتخب استان اصفهان را با استفاده از شبکه عصبی پیش بینی و نتایج نشان داد که مدل شبکه عصبی مصنوعی با دقت بالایی قادر به پیش بینی دمای ماهانه است. نجفی و همکاران (۱۳۹۴) دبی های حداکثر لحظه ای ایستگاههای هیدرومتری هفتحوض، سولقان، قلاک و مقصودییک تهران را با مدل شبکه عصبی مصنوعی شبیه سازی و نتایج نشان داد در همه ایستگاههای مورد بررسی، استفاده از شبکه عصبی مصنوعی در شبیه سازی دبی های حداکثر لحظه ای با استفاده از داده های دبی حداکثر روزانه و ماهانه از کارایی بالایی برخوردار است. لکزاییان پور و همکاران (۱۳۹۵) آثار تغییر اقلیم بر رواناب حوضه نازلوچای دریاچه ارومیه را بررسی و نتایج حاکی از افزایش رواناب رودخانه در دوره آتی تحت سناریوهای انتشار به میزان ۴۸ و ۴۹ درصد بوده است. قربانی و همکاران (۱۳۹۵) طبق بندی دمایی ایستگاه های هواشناسی کشور را با استفاده از شبکه عصبی و خوشخ بندی فازی انجام و نتایج حاکی از دقت قابل قبول هر دو روش می باشد. لیکن خوشه بندی فازی تا حدودی نسبت به شبکه عصبی انطباق بهتری را با پهنه های حاصل از روش دمارتن نشان می دهد. شیداییان و همکاران (۱۳۹۶) مدل های شبکه عصبی و SDSM را در کوچک مقیاس سازی دما مقایسه و نتایج به دست آمده نشان دهنده کارایی مناسب مدل SDSM برای کوچک مقیاس سازی دما نسبت به مدل شبکه عصبی مصنوعی است. رضائی و ذونعمت کرمانی (۱۳۹۶) روش رگرسیون و شبکه عصبی را در پیش بینی تراز آب زیرزمینی دشت شهرکرد را مقایسه و نتایج نشان داد در ۵۶ درصد مدل MLP و در ۴۴ درصد مدل SVR عملکرد بهتری نسبت به سایر مدل ها داشته است. با توجه به اهمیت دما و تأثیر آن بر سایر عناصر اقلیمی هدف از پژوهش حاضر بررسی ارتباط بین دمای ماهانه و سالانه حوضه آبی دریای مازندران با الگوهای پیوند از دور می باشد.

مواد و روشها

حوضه آبریز مازندران با مساحت حدود ۱۷۳،۳۰۰ کیلومتر مربع بین مدار ۳۵ درجه تا ۳۹ درجه و ۴۵ دقیقه عرض شمالی از استوا و ۴۴ درجه و ۵ دقیقه تا ۵۹ درجه طول شرقی از نصف النهار مبدأ قرار گرفته است. در این پژوهش به منظور بررسی ارتباط بین دمای ماهانه و سالانه حوضه آبی دریای مازندران با الگوهای پیوند از دور از آمار میانگین دمای ماهانه و سالانه ۹۷ ایستگاه های همدیدی و آب و هواشناسی درون حوضه و اطراف آن واقع در محدوده استان های گیلان، مازندران و گلستان، زنجان، اردبیل، آذربایجان شرقی و غربی، قزوین، خراسان شمالی،

خراسان رضوی، سمنان، تهران، کردستان، همدان، کرمانشاه و البرز طی دوره آماری (۲۰۱۴-۱۹۷۰) از پایگاه داده سازمان هواشناسی کشور استفاده شده است. همچنین داده‌های مربوط به الگوهای پیوند از دور از سایت <http://www.cdc.noaa.gov/Climate Indices> اخذ و مورد استفاده قرار گرفت. در شکل (۱) پراکنندگی ایستگاه‌های مورد مطالعه و در جدول (۱) مشخصات الگوهای پیوند از دور مورد استفاده قابل مشاهده می‌باشد.



شکل ۱- پراکنش ایستگاه‌های هواشناسی درون و بیرون حوضه آبی دریای مازندران

جدول ۱- مشخصات الگوهای پیوند از دور مورد مطالعه

مخفف الگو	معادل فارسی الگو	مخفف الگو	معادل فارسی الگو
PNA	اقیانوس آرام آمریکای شمالی	AO	مخفف الگو
WP	شاخص اقیانوس آرام غربی	AMO	نوسانات چنددهه‌ای اقیانوس اطلس
NAO	نوسانات اقیانوس اطلس شمالی	AMM	حالت نصف‌النهاری اقیانوس اطلس
SOI	شاخص نوسانات جنوبی	NTA	دمای سطح آب حاره‌ای اطلس شمالی
ONI	شاخص نینوی اقیانوسی	CAR	دمای سطح آب دریای کاریب
TNA	حاره‌ای اقیانوس اطلس شمالی	QBO	نوسانات شبه‌دوساله
TSA	حاره‌ای اقیانوس اطلس جنوبی	Monsoon	بارش ناحیه جنوب غربی مانسون
WHWP	استخرگرم نیمکره غربی	Flux	شارخورشیدی
NINO 3	دمای سطح آب در ناحیه نینو ۳	EA	الگوی اطلس شرقی
NINO 1.2	دمای سطح آب در ناحیه نینو ۱/۲	EA/WR	الگوی اطلس شرقی/غرب روسیه
NINO 4	دمای سطح آب در ناحیه نینو ۴	SCA	الگوی اسکاندیناوی
NINO 3.4	دمای سطح آب در ناحیه نینو ۳/۴	POL	الگوی قطبی/اروپا و آسیا (اوراسیا)
PDO	نوسان دهه‌ای اقیانوس آرام	PMM	حالت نصف‌النهاری اقیانوس آرام
NOI	شاخص نوسانات شمالی	MEI	شاخص چندمتغیره انسو
NP	الگوی آرام شمالی	EPNP	الگوی شرق آرام شمال آرام
TNI	شاخص انتقالی نینو	ENSO	انسو
NCP	الگوی دریای شمال - مازندران		

منبع: یافته‌های پژوهش

در این تحقیق پارامترهای پیوند از دور و دمای سالها و یا ماههای قبل به عنوان داده‌های ورودی و دمای سالانه و ماهانه به عنوان داده‌های خروجی در نظر گرفته شدند. برای دستیابی به هدف مورد نظر، ابتدا داده‌های مورد مطالعه در نرم افزار مت لب نرمال سازی و در نرم افزار SPSS 23.0 استاندارد شدند تا نوع و ساختار داده‌ها متناسب با شبکه عصبی گردد. سپس از نرم افزار SPSS 23.0 جهت انجام شبکه عصبی استفاده و پس از تعیین مقادیری بهینه نرون‌ها و لایه‌های پنهان، شبکه براساس الگوریتم گرادیان نزولی (SCG)، تابع متحرک هیبرولیک^۲ برای لایه

1- Scaled Conjugate Gradient

2 - Hyperbolic tangent


های پنهان و تابع متحرک همانی ابرای داده های خروجی طراحی شد. بدین ترتیب که ۷۰ درصد داده ها برای آموزش و ۳۰ درصد آنها برای آزمون در نظر گرفته شد. در نهایت جهت انتخاب مدل مناسب و بهینه از شاخص های خطای نسبی و ریشه میانگین مربع خطا استفاده گردید.

شبکه های عصبی مصنوعی

رایانه ها دارای سرعت قابل توجهی نسبت به انسان می باشند ولی قدرت تفکر ندارند و در هنگام کمبود اطلاعات و یا وجود داده های پرت، عملکرد آنها به شدت کاسته می شود و رضایت بخش نمی باشد. چون داده هایی که در دسترس پژوهش گران هستند، معمولاً محدود و گاه پرت می باشند؛ از این رو، ایده ی شبکه های عصبی مصنوعی که یک سامانه ی محاسباتی هوشمند و دارای قدرت یادگیری است، مطرح گردید. شبکه های عصبی مصنوعی (ANNs) شبکه های محاسباتی انعطاف پذیری هستند که می توانند روابط غیرخطی پیچیده ی بین متغیرهای مربوط را شرح دهند (ریپلی، ۱۹۹۶). هم چنین، ANN بیان گر گروهی از توابع برای برازش الگوریتم ها است که نیازمند فرضیات توزیع خطاها نمی باشد (گاهگان، ۲۰۰۰ و ۲۰۰۳). بنابراین، ANN، فن آوری نیرومندی است و مزایای زیادی برای خلاصه سازی و استخراج اطلاعات در سطوح وسیع و پهنای را دارا می باشد.

عصب های مصنوعی، در واقع، چهار عمل اصلی عصب های زیستی را شبیه سازی می کنند. به عبارت دیگر، اطلاعات را دریافت، جمع آوری و پردازش می کنند و به دیگر عصب ها انتقال می دهند. شکل (۲) ساختار ریاضی این فرآیند را نشان می دهد.

ورودی های شبکه عصبی مصنوعی با P_j ($j = 1, \dots, N$) نمایش داده می شوند که N ، نشان گر تعداد وزن ها است. هر ورودی (P_j) در وزن مربوط به آن (W_j) ضرب می شود و با جمله ی اُریب (Bias) عصبی (b) جمع می گردد و مجموع آن ها (a) در تابع تبدیل (تابع فعالیت $f(a)$) قرار می گیرد و نتیجه (خروجی x) به دیگر عصب ها منتقل می شود (شکل ۲). فرآیند محاسبه ی صحیح وزن های یک شبکه عصبی را برای حل یک مسأله، در اصطلاح، آموزش یا یادگیری شبکه می نامند. هدف از آموزش یک شبکه، کمینه کردن خطای بین خروجی شبکه و مقدار مطلوب آن (هدف) است.



شکل ۲- نمایش ساختار ریاضی یک عصب مصنوعی منبع: یافته های پژوهش

لازم به ذکر است که شبکه های عصبی، نیازمند ورودی عددی می باشند و خروجی عددی نیز تولید می کنند. از آن جا که ورودی شبکه باید عددی باشد، داده های غیر عددی را نیز بایستی به گونه ای به ماهیت عددی تبدیل کرد (مانند کُد کردن به صورت صفر و یک). از طرفی، چون خروجی شبکه، دامنه ی محدودی دارد؛ گاه داده های عددی هم ممکن


است قبل از سپردن به شبکه، مقیاس‌بندی شوند. در هر حال، موفقیت شبکه‌های عصبی را می‌توان ناشی از دو عامل اصلی زیر دانست:

(۱) قدرت: شبکه‌های عصبی قادر به مدل‌سازی توابع بسیار پیچیده هستند. این قدرت، به‌ویژه، مدیون غیرخطی بودن شبکه‌های عصبی است. روش‌های خطی که به‌طور سنتی به‌کار می‌روند نمی‌توانند پدیده‌های غیرخطی را مدل‌سازی کنند. این در حالی است که روابط بسیاری از پدیده‌های طبیعی و تغییرات آن‌ها غیرخطی هستند.

(۲) سهولت استفاده: در مقایسه با روش‌های خطی و غیرخطی رگرسیونی، در شبکه‌های عصبی نیازی به تعیین شکل مدل نیست و تنها از طریق یادگیری، ساختار داده‌ها و رابطه‌ی متغیرهای ورودی و خروجی کشف می‌شود (اسکاپ و همکاران، ۱۹۹۸).

توانایی پردازش اطلاعات عصب‌های مصنوعی، شبیه عصب‌های زیستی در شبکه‌ای از عصب‌ها بهتر نمایان می‌گردد. شبکه‌های عصبی مصنوعی، دارای ساختار لایه‌ای می‌باشند که در هر لایه، پردازش اطلاعات به‌صورت موازی و انتقال آن به لایه‌های دیگر، به‌صورت متوالی یا سری انجام می‌شود (شکل ۳).

در بیشتر مطالعات انجام‌شده، از مدل پرسپترون چندلایه^۱ (MLP) که مترادف باشکله‌ی پیش‌رونده^۲ می‌باشد، استفاده شده است. چون MLP برای آموزش، نیازمند داده‌های خروجی شناخته‌شده است، این نوع ANN به‌عنوان شبکه‌ی نظارت‌شده نیز شناخته می‌شود. MLP با استفاده از داده‌های آموزشی، یک مدل بین داده‌های ورودی و خروجی می‌سازد. این مدل می‌تواند با استفاده از داده‌های ورودی معلوم، داده‌های خروجی نامعلوم را برآورد کند. شکل (۳) ساختار MLP را برای پژوهش حاضر نشان می‌دهد. برای نام‌گذاری شبکه، پس از MLP، به‌ترتیب، تعداد ورودی، لایه‌ی پنهان و خروجی آورده می‌شوند. برای نمونه، 2-3-4 MLP، به معنی یک شبکه‌ی پرسپترون چندلایه با چهار داده‌ی ورودی، سه لایه‌ی پنهان و دو خروجی است. (پاپانتونیو^۳ و همکاران، ۲۰۱۶)



شکل ۳- ساختار لایه‌ای شبکه‌های عصبی مصنوعی (علایم HN_۱ تا HN_n. نشان‌گر گره‌های لایه‌ی پنهان می‌باشند).

منبع: یافته‌های پژوهش

1- Multi-Layer Perceptron
2 - Feed-Forward Network
3- Papantoniou

انتخاب پارامترهای ANN (مانند تعداد لایه‌ها و یا گره‌ها) به شدت روی دقت و صحت برآوردها تأثیرگذار است. برای نمونه، معمولاً اگر تعداد گره در لایه‌ای کم انتخاب شود، مشکل کم‌برازشی (Under-fitting) و اگر تعداد گره زیاد انتخاب شود، مشکل بیش‌برازشی بروز خواهد کرد. در کم‌برازشی، انعطاف‌پذیری مدل در تعیین رابطه‌ی متغیر ورودی و خروجی کم می‌باشد و مانند آن است که از یک مجموعه نقاط پراکنده، یک خط راست عبور داده شود. اگر داده‌ها روی یک خط راست قرار بگیرند مشکلی پیش نمی‌آید، ولی اگر روند پراکندگی نقاط، غیرخطی باشد، برازش یک خط راست واقعیت غیرخطی بودن داده‌ها را نشان نمی‌دهد و از واقعیت دور می‌شود. در کم‌برازشی، خطای آموزشی، بزرگ (به عبارتی، Rtrain کوچک) است. حال اگر تعداد گره‌ها زیاد باشد؛ رابطه‌ی برازش شده بسیار انعطاف‌پذیر می‌شود و همانند برازش مدل‌های رگرسیون چندجمله‌ای با توان بزرگ، منحنی از تمام نقطه‌ها عبور خواهد کرد. در این صورت، به جای آن‌که داده‌ها مدل‌سازی شوند، خطای تصادفی مدل‌سازی می‌شود و مشکل بیش‌برازشی پیش می‌آید. به عبارت دیگر، در بیش‌برازشی، ورودی‌ها و خروجی‌ها توسط شبکه حفظ می‌شوند و فرآیند یادگیری رخ نخواهد داد. در این حالت، خطای آموزش بسیار کم (گاه صفر) خواهد بود. به عبارتی، R2train مقدار بزرگی را به خود اختصاص خواهد داد؛ ولی مقدار R2test، کوچک می‌باشد. (چاپ‌و همکاران، ۱۹۹۸)

مدلسازی با شبکه عصبی مصنوعی

بسط و توسعه یک مدل شبکه عصبی مصنوعی مستلزم طراحی اجزاء فنی تشکیل دهنده آنست. جهت دستیابی به اهداف مورد نظر از شبکه‌های عصبی با ساختارهای مختلف همانند پرسپترون سعی گردید تا بهترین و کاراترین شبکه با تعیین مقدار خطای آن انتخاب و مورد استفاده قرارگیرد. در نهایت جهت انتخاب مدل مناسب و بهینه از شاخص‌های R2 و RMSE استفاده گردید.

استاندارد سازی و تصادفی نمودن داده‌ها

اصولاً وارد کرن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌گردد و در عین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زود هنگام نرون‌ها جلوگیری نمود. (پاپانتونیو و همکاران، ۲۰۱۶)

تقسیم بندی داده‌ها

شبکه‌های عصبی مصنوعی جهت طراحی و آموزش نیازمند یک سری داده‌های ورودی و خروجی می‌باشند تا با تجزیه و تحلیل منطقی که بین این داده‌ها به عنوان نمونه صورت می‌گیرد، بتواند روابط غیر خطی آنها را استخراج نموده و کار شبیه سازی را برای موارد احتمالی مشابه انجام دهند. مدل‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، اعتبارسنجی و آزمون می‌باشند. از داده‌های آموزشی به منظور پیدا کردن رابطه بین

ورودی‌ها و خروجی‌های مشاهده‌ای، استفاده می‌گردد. از داده‌های اعتبارسنجی به منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود و از داده‌های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده می‌گردد. لازم به ذکر است که گاه جهت طراحی شبکه‌های عصبی مصنوعی تنها دو دسته داده آموزشی و آزمون استفاده می‌شوند. در این تحقیق نیز به همین صورت تقسیم بندی داده‌ها انجام شد و سپس مورد مطالعه و مقایسه قرار گرفتند. برای این منظور ۷۰ و ۳۰ درصد کل داده‌ها، به ترتیب برای آموزش و آزمون مدل اختصاص یافت.

طراحی شبکه

از آنجا که رابطه‌سنجی‌ها نشان داده است که بالاترین روابط معنی‌دار بین تغییرات دما با دمای ماه قبل و شاخص‌های ONI و NINO3 است، لذا مهمترین خصوصیات مؤثر بر دمای ماهانه شامل دمای یک ماه پیش، ONI و NINO3 به عنوان پارامترهای ورودی و دمای ماهانه به عنوان خروجی شبکه در نظر گرفته شدند. این ویژگی‌ها پس از انجام آزمایش روی تمام الگوهای پیوند از دور و بررسی تأثیر اهمیت هریک از آنها روی دما بدست آمدند. این متغیرها دارای اهمیت نرمال شده بیش از ۶۰ درصد می‌باشند. به منظور آموزش شبکه‌ی عصبی، شبکه MLP مورد استفاده قرار گرفت. فرایند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام گردید تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به حداقل برسد. تعداد عناصر پردازش لایه مرکزی نیز از ۱ تا $2N+1$ (تعداد نرون‌های ورودی می‌باشد) و تعداد لایه‌های مخفی نیز از ۱ تا ۲ بار در فرایند آموزش و آزمون مدل تکرار گردیدند و در نهایت بیش از ۶۰۰ شبکه مختلف تهیه گردید. در هر الگوریتم آموزشی هدف، کاهش میزان ریشه میانگین مربع خطا (RMSE) و افزایش ضریب تعیین است.

بحث

بسط و توسعه یک مدل شبکه عصبی مصنوعی مستلزم طراحی اجزاء فنی تشکیل دهنده آن است. جهت دستیابی به هدف پژوهش از شبکه‌های عصبی با ساختارهای مختلف همانند پرسپترون استفاده و سعی گردید تا بهترین و کاراترین شبکه با تعیین مقدار خطای آن انتخاب و مورد استفاده قرارگیرد. در نهایت جهت انتخاب مدل مناسب و بهینه از ضریب تعیین و ریشه میانگین مربع خطاها استفاده گردید. در این پژوهش پارامترهای پیوند از دور و دمای سالها و یا ماههای قبل به عنوان داده‌های ورودی و دمای سالانه و ماهانه به عنوان داده‌های خروجی در نظر گرفته شدند.

جدول (۲) مقادیر مربوط به آموزش و آزمون را برای حالتی که تمام داده‌های ماهانه به عنوان ورودی به مدل وارد شده‌اند را نشان می‌دهد. در این جدول مجموع مربعات خطاها از آنجایی که لایه خروجی دارای متغیرهای وابسته به مقیاس بوده، نشان داده شده است. این همان تابع خطایی است که شبکه تلاش دارد طی عملیات آموزش آن را به کمترین میزان خود برساند. این مقادیر هر چه به صفر نزدیکتر باشد نشانه عملکرد بهتر شبکه می‌باشد. با توجه به اینکه معیارهای ارزیابی شبکه در حد قابل قبول می‌باشند؛ می‌توان اظهار داشت که شبکه طراحی شده دارای عملکرد خوبی بوده و آموزش و آزمون شبکه تا حد بسیار زیادی قابل قبول است.


¹ - Root Mean Square Error (RMSE)

جدول ۲- مقادیر مربوط به آموزش و آزمون برای تمام داده های ماهانه ورودی

آموزش	مجموع مربع خطاها	۲/۰۷۸
	خطای نسبی	۰/۰۱۶
آزمون	مجموع مربع خطاها	۱/۹۰۴
	خطای نسبی	۰/۰۴۰


منبع: یافته های پژوهش

شکل (۴) مقادیر برآورد را برای حالتی که تمام داده های ماهانه به عنوان ورودی به مدل وارد شده اند در برابر داده های واقعی نشان می دهد. بهترین خط برازش یافته داده ها و قرارگیری داده ها بر روی آن حدود خط ۴۵ درجه می باشد. هر چه پراکنش نقاط در اطراف این خط باشد، بیانگر برازش عالی و برآورد دقیق خروجی های شبکه خواهد بود. در مرحله بعد تنها داده هایی که اهمیت نرمال شده بیش از ۶۰ درصد داشتند، یعنی دمای یک ماه قبل، ONI و NINO3، وارد مدل شدند. شکل (۵) ساختار این شبکه را نشان می دهد.



شکل ۴- نمودار برازش تمام داده ها در شبکه

منبع: یافته های پژوهش



Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

شکل ۵- ساختار شبکه


منبع: یافته های پژوهش

جدول (۳) مقادیر مربوط به آموزش و آزمون را برای حالتی که تنها داده های دمای یک ماه پیش، ONI و NINO3، به عنوان ورودی به مدل وارد شده اند نشان می دهد. شکل (۶) مقادیر برآورد را برای حالتی که داده های دمای یک ماه پیش، ONI و NINO3، به عنوان ورودی به مدل وارد شده اند در برابر داده های واقعی نشان می دهد. همان گونه که مشاهده می شود به دلیل قرارگیری موقعیت نقاط و قرار گرفتن در خط ۴۵ درجه شبکه عملکرد خوبی داشته است.

جدول ۳- مقادیر مربوط به آموزش و آزمون برای داده های دمای یک ماه پیش، ONI و NINO3.

آموزش	مجموع مربع خطاها	۱۸/۴۹۷
	خطای نسبی	۰/۱۰۰
آزمون	مجموع مربع خطاها	۷/۰۶۰
	خطای نسبی	۰/۰۸۰

منبع: یافته های پژوهش



شکل ۶- مقادیر برآورد با دمای یک ماه پیش، ONI و NINO3

منبع: یافته های پژوهش


مهمترین خصوصیات مؤثر بر دمای سالانه شامل NAO، AO، NCP، AMO و دمای یک سال پیش به عنوان پارامترهای ورودی و دمای ماهانه به عنوان خروجی شبکه در نظر گرفته شدند. این ویژگی ها پس از انجام آزمایش روی تمام الگوهای پیوند از دور و بررسی تأثیر اهمیت هریک از آنها روی دما بدست آمدند. این متغیرها دارای اهمیت نرمال شده بیش از ۶۰ درصد می باشند. برای دمای سالانه بیش از ۳۰۰ شبکه مختلف تهیه گردید. در هر الگوریتم آموزشی هدف، کاهش میزان ریشه میانگین مربع خطا و افزایش ضریب تعیین است. جدول (۴) مقادیر مربوط به آموزش و آزمون را برای حالتی که تمام داده های سالانه به عنوان ورودی به مدل وارد شده اند را نشان می دهد. با توجه به ضرایب به دست آمده می توان بیان کرد که شبکه طراحی شده دارای عملکرد خوبی بوده است. شکل (۷) مقادیر برآورد را برای حالتی که تمام داده های سالانه به عنوان ورودی به مدل وارد شده اند در برابر داده های واقعی نشان می دهد. با توجه به این شکل شبکه از عملکرد مناسبی برخوردار بوده است. در مرحله بعد تنها داده هایی که اهمیت نرمال شده بیش از ۶۰ درصد داشتند یعنی NAO، AO، NCP، AMO و دمای یک سال پیش

وارد مدل شدند. شکل (۸) مقادیر برآورد را برای حالتی که این داده ها وارد مدل شده اند در برابر داده های واقعی نشان می دهد. جدول (۵) مقادیر مربوط به آموزش و آزمون را برای این حالت نشان می دهد. با توجه به اینکه ضرایب حاصل شده در حد قابل قبول می باشند می توان بیان کرد شبکه طراحی شده دارای عملکرد خوبی بوده است.


جدول ۴- مقادیر مربوط به آموزش و آزمون برای تمام داده های سالانه

مجموع مربع خطاها آموزش	۱/۰۴۶
خطای نسبی	۰/۱۱۶
مجموع مربع خطاها آزمون	۰/۲۴۴
خطای نسبی	۰/۰۸۱

منبع: یافته های پژوهش



شکل ۷- مقادیر برآورد تمام داده ها برابر داده های واقعی



شکل شماره ۸- مقادیر برآورد داده های AMO, NCP, AO و دمای یک سال پیش در برابر داده های واقعی

منبع: یافته های پژوهش

جدول ۵- مقادیر مربوط به آموزش و آزمون برای داده های دمای یک ماه پیش، NAO, AO, NCP

آموزش	مجموع مربع خطاها	۷/۸۰۳
	خطای نسبی	۰/۵۳۸
آزمون	مجموع مربع خطاها	۱/۳۴۵
	خطای نسبی	۰/۴۲۴

منبع: یافته های پژوهش

نتیجه گیری

در پژوهش حاضر به منظور بررسی ارتباط بین دمای ماهانه و سالانه حوضه آبی دریای مازندران با الگوهای پیوند از دور از شبکه عصبی پرسپترون با الگوریتم گرادیان نزولی (SCG) و تابع متحرک هیپربولیک برای لایه های پنهان و تابع متحرک همانی برای داده های خروجی استفاده شد. بدین منظور ۷۰ درصد از داده ها برای آموزش و ۳۰ درصد از آنها برای آزمون در نظر گرفته شد. در تمام ساختار شبکه ۱ تا ۲ لایه پنهان در فرایند آموزش و آزمون تکرار و در نهایت بیش از ۶۰۰ شبکه ایجاد شد. نتایج حاصل از بررسی و ارزیابی شبکه حاکی از آن است که در حالتی که تمام داده های ماهانه به عنوان ورودی به مدل وارد شده اند، شبکه از عملکرد مناسبی برخوردار می باشد ولی دمای یک ماه پیش و الگوهای ONI و NINO3 از بین سایر داده ها دارای اهمیت بیش از ۶۰ درصد می باشند و نشان دهنده ارتباط بیشتر این شاخص ها با دمای ماهانه حوضه مورد مطالعه می باشد. ضرایب بدست آمده از مدل زمانی که تمام داده های سالانه به عنوان ورودی به شبکه وارد شوند نیز نشان می دهد که شبکه طراحی شده دارای عملکرد خوبی بوده است. با این وجود الگوهای های NAO, AO, NCP, AMO و دمای یک سال پیش از اهمیت بالای ۶۰ درصد برخوردار بوده اند و می توان بیان نمود که بیش از سایر الگوها با دمای سالانه حوضه مطالعاتی رابطه داشته اند.

در مجموع می توان بیان نمود که الگوهای پیوند از دور هم با دمای ماهانه و هم با دمای سالانه حوضه رابطه نشان می دهد، البته برای دما ماهانه برخی شاخص ها اثرگذاری دارد و برای دمای سالانه برخی شاخص های دیگر.

منابع

- اسفندیاری درآباد، فریبا، حسینی، سیداسعد، آزادی مبارکی، محمد، حجازی زاده، زهرا، ۱۳۸۹، پیش بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج با استفاده از مدل شبکه ی عصبی مصنوعی پرسپترون چندلایه (MLP)، جغرافیا (فصلنامه علمی پژوهشی انجمن جغرافیای ایران)، سال هشتم، شماره ۲۷، صص ۶۴-۴۵.
- امامی فر، سعید، رحیمی خوب، علی، نوروزی، علی اکبر، ۱۳۹۳، ارزیابی مدل درختی M5 و شبکه عصبی مصنوعی برای برآورد متوسط روزانه دمای هوا بر اساس داده های دمای سطح زمین سنجنده مودیس، تحقیقات آب و خاک ایران، دوره ۴۵، شماره ۴، صص ۴۳۳-۴۲۳.
- خوشحال دستجردی، جواد، حسینی، سیدمحمد، ۱۳۸۹، کاربرد شبکه عصبی مصنوعی در شبیه سازی عناصر اقلیمی و پیش بینی سیکل خشکسالی (مطالعه موردی: استان اصفهان)، مجله جغرافیا و برنامه ریزی محیطی، سال ۲۱، شماره پیاپی ۳۹، شماره ۳، ۱۲۰-۱۰۷.
- رضائی چرمهینه، عبدالله، ذونعمت کرمانیف ذونعمت، ۱۳۹۶، بررسی کارایی روش های رگرسیون بردار پشتیبان، شبکه عصبی پرسپترون چندلایه و رگرسیون خطی چندمتغیره به منظور پیش بینی تراز سطح آب زیرزمینی (مطالعه موردی: دشت شهرکرد)، پژوهشنامه مدیریت حوزه آبخیز، سال هشتم، شماره ۱۵، صص ۱۲-۱.
- شیداییان، مجید، ضیاتبارا احمدی، میرخالق، فضل اولی، رامین، ۱۳۹۶، مقایسه مدل شبکه عصبی مصنوعی (ANN) و SDSM در کوچک مقیاس سازی دما، علوم و مهندسی آبیاری، جلد ۴۰، شماره ۲، صص ۷۳-۵۹.

- صلاحی، برومند، حسینی، سیداسعد، شایقی، حسین، سبحانی، بهروز، ۱۳۸۹، پیش بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی مطالعه موردی: شهرستان اردبیل، فصلنامه تحقیقات جغرافیایی، شماره ۹۸، صص ۷۸-۵۷.
- عزیزی، حمیدرضا، منتظری، مجید، ۱۳۹۴، پیش بینی دماهای ماهانه ایستگاه های همدید منتخب استان اصفهان، با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه، فصلنامه تحقیقات جغرافیایی، سال ۳۰، شماره ۳، صص ۲۵۸-۲۴۱.
- قربانی، محمدعلی، پوریابک، سرور، جباری خامنه، حسین، اسدی، اسماعیل، فاضلی فرد، محمدحسن، ۱۳۹۵، طبقه بندی دمایی ایستگاه های هواشناسی کشور با استفاده از خوشه بندی فازی و شبکه عصبی مصنوعی کوهونن، نشریه علمی پژوهشی جغرافیا و برنامه ریزی، سال ۲۰، شماره ۵۵، صص ۶۳-۴۵.
- قلی زاده، محمدحسین، دارند، محمد، ۱۳۸۹، پیش بینی بارش ماهانه با استفاده از شبکه عصبی مصنوعی (مورد: تهران)، پژوهش های جغرافیای طبیعی، شماره ۷۱، صص ۶۳-۵۱.
- کارآموز، محمد؛ رضانی، فرید؛ رضوی، سامان. ۱۳۸۵، پیش بینی بلند مدت بارش با استفاده از سیگنال های هواشناسی: کاربرد شبکه های عصبی مصنوعی، هفتمین کنگره بین المللی مهندسی عمران، دانشگاه تربیت مدرس تهران.
- گلآبی، محمدرضا، آخوندعلی، علیمحمد، رادمنش، فریدون، ۱۳۹۵، مقایسه عملکرد الگوریتم های مختلف شبکه عصبی مصنوعی در مدل سازی بارندگی فصلی مطالعه موردی؛ ایستگاههای منتخب استان خوزستان، نشریه تحقیقات کاربردی علوم جغرافیایی سال سیزدهم، شماره ۳۰، صص ۱۶۹-۱۵۱.
- لکزاییان پور، غلامحسین، محمدرضاپور، ام البنی، مال میر، مهسا، ۱۳۹۵، ارزیابی آثار تغییر اقلیم بر میزان رواناب رودخانه نازلوچای در حوضه آبریز دریاچه ارومیه، جغرافیا و توسعه، شماره ۴۲، صص ۱۹۸-۱۸۳.
- نجفی، اسماعیل، صفاری، امیر، قنواتی، عزت الله، کرم، امیر، ۱۳۹۴، شبیه سازی و تحلیل دبی های حداکثر لحظه ای با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه های هیدرومتری هفت حوض، سولقان، قلاک و مقصدبیک در کلان شهر تهران)، پژوهش های ژئومورفولوژی کمی، سال چهارم، شماره ۱، صص ۱۰۳-۹۰.
- Gahegan, M., 2000. On the application of inductive machine learning tools to geographical analysis. *Geographical Analysis*, 32:113– 139.
- Gahegan, M., 2003. Is inductive machine learning just another wild goose chase (or might it lay the golden egg)? *International Journal of Geographic Information Science*, 17: 69–92.
- Juan, Chang, Genxu, Wang, Tianxu, Mao, 2015, Simulation and prediction of suprapapermafrost groundwater level variation in response to climate change using a neural network model, *Journal of Hydrology*, Volume 529, Part 3, Pages 1211-1220
- Li, Xiuming, Zhao, Tianyi, Zhang, Jili, Chen, Tingting, 2017, Predication control for indoor temperature time-delay using Elman neural network in variable air volume system, *Energy and Buildings*, Volume 154, Pages 545-552
- Marohasy, Jennifer, Abbot, John, 2015, Assessing the quality of eight different maximum temperature time series as inputs when using artificial neural networks to forecast monthly rainfall at Cape Otway, Australia, *Atmospheric Research*, Volume 166, Pages 141-149.
- Papantoniou, Sotiris, Kolokotsa, Dionysia-Denia, 2016, Prediction of outdoor air temperature using neural networks: Application in 4 European cities, *Energy and Buildings*, Volume 114, Pages 72-79.
- Raju, K. Srinivasa, Kumar, D. Nagesh 2007, Classification of Indian meteorological stations using cluster and fuzzy cluster analysis, and Kohonen artificial neural networks, *Hydrology Research* , 38 (3) 303-314.
- Ripley, B.D., 1996. *Pattern recognition and neural networks*. Cambridge University Press, Cambridge, N.Y
- Shamshirband, Shahaboddin, Mohammadi, Kasra, Piri, Jamshid, Petković, Dalibor, Karim, Ahmad, 2016, Hybrid auto-regressive neural network model for estimating global solar radiation in Bandar Abbas, Iran, *Environmental Earth Sciences*, 75:172.

Schaap, Marcel, Feike, J. Leij, Martinus. Th. Genuchten, van. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. Soil Sci. Soc. Am.J., 62:847-855.