

پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنتدج با استفاده از مدل شبکه‌ی عصبی مصنوعی پرسپترون چندلایه (MLP)

فریبا اسفندیاری درآباد^۱، سید اسعد حسینی^۲، محمد آزادی مبارکی^۳، زهرا حجازی‌زاده^۴

چکیده

پیش‌بینی دما به عنوان یکی از مهمترین پارامترهای اقلیمی در حوزه‌های مختلف مدیریت منابع آبی و طبیعی، خشکسالی‌ها، مطالعات زیست محیطی، خطر سیلاب، کمبود مواد غذایی، گسترش آفات و بیماری‌ها، حمل و نقل و غیره از اهمیت ویژه‌ای در تعیین سیاست‌های آینده جهت بهینه‌سازی این منابع و صرف هزینه‌ها، کنترل و جلوگیری از بحران و استفاده از منابع برخوردار است. مدل پرسپترون چندلایه (MLP) یکی از پرکاربردترین مدل‌های شبکه‌های عصبی مصنوعی از مؤلفه‌های هوش مصنوعی در زمینه پیش‌بینی عناصر جوی و اقلیمی است که می‌تواند بدون در نظر گرفتن معادلات پیچیده غیرخطی، دینامیک حاکم بر سیستم را استخراج نموده و خروجی مدل را پیش‌بینی کند. در این پژوهش، با استفاده از اطلاعات میانگین دمای ماهانه ایستگاه سینوپتیک سنتدج در طول دوره آماری ۳۸ ساله (۱۹۶۴-۲۰۰۱)، به عنوان ورودی‌های شبکه پرسپترون چندلایه، میانگین دمای ماهانه در طی سال‌های (۲۰۰۵-۲۰۰۲) به منظور تعیین میزان خطای مدل، پیش‌بینی شد. بدین منظور از امکانات و توابع موجود در محیط برنامه نویسی

۱. استادیار گروه جغرافیای طبیعی، دانشگاه محقق اردبیلی

۲. کارشناس ارشد اقلیم شناسی، دانشگاه محقق اردبیلی

۳. کارشناس ارشد اقلیم شناسی، دانشگاه محقق اردبیلی

۴. استاد گروه جغرافیای طبیعی، دانشگاه تربیت معلم

نرم افزار MATLAB، بهره گرفته شد. سپس به ارزیابی عملکرد مدل، از طریق معیارهای آماری از جمله روابط رگرسیونی و ضریب همبستگی بین مقادیر مشاهداتی و پیش‌بینی شده‌ی دما و همچنین میانگین درصد خطای نسبی پرداخته شد. نتایج بدست آمده نشان دهنده‌ی کارآیی مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی در پیش‌بینی دما می‌باشد. به طوری که ضریب همبستگی برابر با 0.99 و میانگین درصد خطای مدل برابر با 1.97 درصد است. یعنی شبکه، دما را با اختلاف کمتر از یک درجه سلسیوس با دمای واقعی پیش‌بینی کرده است از این‌رو با استفاده از این روش می‌توان وضعیت‌های دمایی را از قبل تعریف نمود و در مدیریت منابع آبی و طبیعی دخالت داد.

کلیدواژگان: پیش‌بینی دما، سنتدج، 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، همچنین دما از عوامل اصلی و اساسی در پهنه‌بندی و طبقه‌بندی اقلیمی محسوب می‌گردد و بر این اساس نوسانات و تغییرپذیری دما دارای اهمیت زیادی است که عوامل اقلیمی و جغرافیای زیادی از قبیل رطوبت، ابرناکی، سرعت باد، ارتفاع، دوری و نزدیکی به دریا و غیره در تغییرات آن نقش دارند. تغییرات معنی‌دار دمای کره‌ی زمین یا گرمایش جهانی به عنوان مهمترین نمودهای تغییر اقلیم در قرن حاضر مورد توجه قرار گرفته است. بسیاری از معضلات محیطی عصر ما از جمله سیل، طوفان، خشکسالی، تکثیر بیش از حد حشرات موذی و مصونیت آنها در برابر سموم و مسایلی از این دست، جملگی ریشه در تغییر اقلیم کره‌ی زمین خصوصاً افزایش دما دارند (خورشیددوست، ۱۳۸۳). لذا پیش‌بینی عناصر اقلیمی، قطعاً فرصت بیشتری را جهت برنامه‌ریزی و ارائه تمهیدات لازم در اختیار برنامه‌ریزان قرار می‌دهد مدل‌های قدیمی در زمینه پیش‌بینی، مدل‌های رگرسیونی هستند. امروز با پیشرفت علوم و ابداع روش‌های هوشمند در علوم مختلف، ضرورت جانشینی آن مطرح می‌شود یکی از این روش‌های هوشمند، شبکه‌های عصبی مصنوعی هستند که توانایی زیادی در مدل‌سازی و پیش‌بینی 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). یکی از پرکاربردترین مدل شبکه‌های عصبی مصنوعی، مدل پرسپترون چندلایه است که در این پژوهش جهت پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنتدج از ژانویه سال ۲۰۰۲ تا دسامبر ۲۰۰۵ میلادی جهت محاسبه خطای شبکه و مقایسه داده‌های مشاهده شده و محاسباتی استفاده می‌گردد. جین^۱

1.Jain

(۲۰۰۳) با هدف توسعه یک سیستم برای هشدار درباره ینبندان، جهت کاهش خسارات تولیدات کشاورزی، دمای هوا را در منطقه جنوب جورجیا با استفاده از شبکه‌های عصبی مصنوعی برای یک تا دوازده ساعت آینده پیش‌بینی کرد. رحمان و همکاران^۱ (۲۰۰۸) از شبکه‌های عصبی جهت برآورد تابش خورشیدی در شهر آبهای^۲ عربستان سعودی استفاده کردند نتایج به دست آمده نشان داد که شبکه‌های عصبی قادرند تابش خورشیدی را از دما و رطوبت نسبی برآورد کنند. سنکال و همکاران^۳ (۲۰۰۹) با استفاده شبکه‌های عصبی مصنوعی و داده‌های ماهواره‌ای، تابش خورشید را در کشور ترکیه برآورد کردند آنها از الگوریتم‌های یادگیری انتشار بهبودپذیر (RP)، شیب توأم (SCG) وتابع انتقال تانزانیت سیگموئیدی در شبکه عصبی استفاده کردند و این مدل را برای برآورد تابش خورشیدی در ترکیه معرفی کردند. سگوندی (۱۳۷۶) با استفاده از شبکه عصبی پرسپترون چندلایه به پیش‌بینی عناصر مختلف جوی ایستگاه اهواز در طول دوره آماری ۳۰ ساله (۱۹۸۷-۱۹۵۷) پرداخت و ضرایب همبستگی بین داده‌های پیش‌بینی و واقعی برای عناصر مختلف را با ۰/۹۶ الی ۰/۹۱ بدست آورد. جهانبخش و باباپور (۱۳۸۲) با استفاده از مدل آریما، میانگین دمای ماهانه ایستگاه تبریز را با سطح اطمینان ۹۵٪ تا سال ۲۰۱۰ پیش‌بینی کردند. علیجانی و قویدل‌رحمی (۱۳۸۴) با استفاده از روش‌های رگرسیون خطی و شبکه‌های عصبی مصنوعی به مقایسه و پیش‌بینی تغییرات دمای سالانه تبریز با ناهنجاری‌های دمایی کره‌ی زمین در طول دوره‌ی آماری ۵۴ ساله (۱۹۵۱-۲۰۰۳) پرداختند و نشان دادند که مدل‌های غیرخطی (ANNs) بسیار قوی‌تر از مدل‌های خطی و نیمه خطی عمل می‌کنند. رحیمی (۱۳۸۵) به تحلیل آلودگی‌های هوایی ناشی از مکانیابی نامناسب مراکز صنعتی در شهر تبریز با استفاده از شبکه‌های عصبی مصنوعی پرداخت و نشان داد که شبکه‌های عصبی مصنوعی پرسپترون نسبت به سایر روش‌ها نتایج بهتری به دست می‌دهد.

1.Rehman et al

2 .Abha City


3 .Senkal et al

چوبدار (۱۳۸۶) ورودی ماهانه‌ی دریاچه‌ی سد شهید مدنی تبریز را بر اساس تأثیر عناصر اقلیمی با استفاده از شبکه‌های عصبی پیش‌بینی کرد نتایج حاکی از موفقیت این روش بود. اصغری مقدم و همکاران (۱۳۸۷) از شبکه‌های عصبی مصنوعی و فرمول تجربی ارائه شده برای تعیین تعداد گره‌های میانی جهت تهیه مدل پیش‌بینی بارش دشت تبریز استفاده کردند بر اساس نتایج بدست آمده، بهترین مدل از یک شبکه پیشرو با شش گره ورودی، یک گره خروجی، یک لایه میانی و الگوریتم لونبرگ-مارکوارت تشکیل شده است.

منطقه مورد مطالعه و ویژگیهای دمائی آن

شهرستان سنتدج با مساحت ۲۹۰۶ کیلومتر مربع در ۳۵ درجه و ۲۰ دقیقه عرض شمالی و ۴۷ درجه طول شرق در ارتفاع ۱۵۳۸ متری از سطح دریا قرار گرفته که جزو مناطق کوهستانی با خصوصیات اقلیمی تابستان‌های معتدل و زمستان‌های سرد به شمار می‌آید. قسمت‌های کم ارتفاع این منطقه جزء نقاط گرمسیری و قسمت‌های مرتفع آن جزء نقاط نسبتاً سرد است. این شهرستان جزو مناطق کوهستانی غرب و جنوب غربی زاگرس است که موقعیت آن در شکل (۱) آورده شده است جهت انجام پژوهش از ایستگاه سینوپتیک سنتدج استفاده شد که مشخصات آن در جدول (۱) آورده شده است. میانگین دمای سالانه در این ایستگاه $13\frac{3}{4}$ درجه سانتیگراد است که ضریب تغییرپذیری آن با حداقل $11\frac{3}{3}$ و حداکثر 15 درجه سانتیگراد در سال به میزان $3\frac{7}{7}$ درجه سانتیگراد در دوره آماری $1964-2005$ بوده است. میانگین دمای ماهانه ایستگاه در شکل (۲) آورده شده است حداقل و حداکثر میانگین دمای ماهانه به ترتیب مربوط به ماه ژوئن با صفر و ماه جولای با $27\frac{1}{1}$ درجه سانتیگراد بوده است. روند تغییرات میانگین دمای سالانه در دوره آماری مورد نظر نیز با استفاده از رگرسیون خطی و پولی‌نومیال مرتبه ششم در شکل (۳) آورده شده است که روند آن با استفاده از رگرسیون خطی و پولی‌نومیال به ترتیب برابر با 17 و 38 درصد که روند افزایشی تقریباً تندی است. (نتایج مربوط به رگرسیون خطی و پولی-نومیال نیز در داخل شکل (۳) آورده شده است).


شکل ۱: موقعیت شهرستان سنندج در استان کردستان




جدول ۱: مشخصات جغرافیایی ایستگاه سینوپتیک سنندج

نوع ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع به متر	دوره آماری
سینوپتیک	۴۷° ۰۰"	۳۵° ۲۰"	۱۳۷۳/۴	۱۹۶۴-۲۰۰۵

شکل ۲: میانگین دمای ماهانه ایستگاه سینوپتیک سنندج در دوره آماری (۱۹۶۴-۲۰۰۵)



شکل ۳: روند تغییرات میانگین دمای سالانه ایستگاه سینوپتیک سنتدج در دوره آماری (۱۹۶۴-۲۰۰۵)




شبکه‌های عصبی مصنوعی^۱

شبکه‌های عصبی از یک سری لایه‌هایی شامل اجزای ساده‌ای به نام نرون تشکیل شده‌اند که به صورت موازی باهم عمل می‌کنند در شکل(۴) یک نرون ساده با R ورودی نشان داده شده است هر بردار ورودی با انتخاب مناسب وزن W ، وزن‌دار شده و جمع ورودی-های وزن‌دار با بایاس^۲، ورودی تابع محرک F را تشکیل می‌دهند (دموث و همکاران^۳، ۲۰۰۰). ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی^۴، لایه‌های میانی یا مخفی^۵، و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده بوسیله شبکه می‌باشد و بنابراین خروجی مدل را معرفی می‌کند. لایه میانی یا مخفی


-
1. Artificial Neural Networks(ANNs)
 - 2 . Bias
 - 3 . Demuth et al
 - 4 . Input Layer
 - 5 . Hidden Layer

که از نرون‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌هاست. شمار لایه‌ها و شمار نرون‌ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطا مشخص می‌شود نرون‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. به طور کلی شبکه‌های عصبی به دو نوع شبکه‌های پیشخور (FFN)^۱ و پسخور (RNN) تقسیم می‌شوند تفاوت آنها در این است که در شبکه‌های پسخور، حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون‌های همان لایه و یا لایه قبل وجود دارد. در بیشتر موارد، شبکه‌های عصبی پسخور می‌توانند بسیار مفید واقع شوند ولی با این حال، در ۸۰ درصد کاربردها از شبکه‌های عصبی پیشخور (شکل ۵) استفاده می‌شود (منهاج، ۱۳۸۴).

شکل ۴: مدل نرون (دموث و بیل، ۲۰۰۰)



شکل ۵: شبکه پیشخور دو لایه (دموث و بیل، ۲۰۰۰)




1 . Feed Forward Network

شبکه‌های پرسپترون چند لایه (MLP)^۱

شبکه‌های پرسپترون چند لایه از نوع شبکه‌های عصبی پیشخور هستند که یکی از پرکاربردترین مدل‌های شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی عناصر اقلیمی است (حسینی، ۱۳۸۸). در شبکه‌های پرسپترون چند لایه هر نرون در هر لایه به تمام نرون‌های لایه قبل متصل می‌باشد. به چنین شبکه‌هایی، شبکه‌های کاملاً مرتبط گویند (منهاج، ۱۳۸۴) در مورد مسئله‌ی برآورد عناصر جوی، شبکه عصبی باید قادر به نگهداری اطلاعات و دیده‌بانی‌های گذشته باشد به همین دلیل و با توجه به توانایی‌های شبکه پرسپترون و قابلیت آموزش و یادگیری زیاد این نوع شبکه عصبی، استفاده از آن به منظور برآورد عناصر جوی در تحقیقات گذشته توصیه شده است (حسینی، ۱۳۸۸). در این بررسی نیز با توجه به کاربرد شبکه‌های پرسپترون چند لایه پیشخور در مسائل پیش‌بینی و قابلیت بالای آنها در تعمیم نتایج، از این شبکه‌ها برای پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سندج استفاده شده است.

شکل (۶) یک شبکه پرسپترون با دو لایه مخفی و چهار نرون در هر لایه مخفی و ۲ نرون در لایه ورودی و یک نرون در لایه خروجی را نشان می‌دهد.

شکل ۶: شبکه پرسپترون چند لایه (حسینی، ۱۳۸۸)



1. Multi Layer Perceptron

جهت اجرای دقیق شبکه پرسپترون چندلایه در محیط برنامه نویسی Matlab موارد زیر بعنوان اصول کلی اجرا در نظر گرفته شد:

داده‌های ورودی و خروجی شبکه

در مرحله اول داده‌های مربوط به میانگین دمای ماهانه از وب سایت سازمان هواشناسی تهیه و سپس اقدام به داده‌پردازی، محاسبه و ماتریس‌بندی داده‌ها گردید. لایه ورودی شبکه را ۵ نرون شامل اطلاعات میانگین دمای ۵ ماه قبل و خروجی شبکه را نیز یک نرون شامل میانگین دمای ماه ششم تشکیل می‌دهد. از ۵۰۴ داده موجود (۱۹۶۴-۲۰۰۵)، ۴۵۶ داده برای آموزش شبکه و مابقی در مرحله آزمون شبکه به کار رفته‌ند شبکه به گونه‌ای طراحی گردید که می‌توان با ورود میانگین دمای ماهانه در پنج ماه از سال، میانگین دمای ماه بعد همان سال را با خطای کمتر از ۵ درصد برآورد کرد چرا که شبکه بر اساس ۴۵۶ داده (۱۹۶۴-۲۰۰۱) آموزش دیده است. در مجموع ۱۲ شبکه (هر ماه یک شبکه) برای پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنتدج در طی دوره آماری (۲۰۰۵-۲۰۰۲) یا ۴۸ داده باقیمانده برای آزمون شبکه، طراحی گردید.

نرم‌الیزه نمودن داده‌ها

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود از این رو داده‌های ورودی به شبکه بایستی نرمال شود. در این بررسی برای نرم‌الیزه کردن داده‌ها از رابطه (۱) استفاده شده است که ورودی‌ها را بین ۰/۱ و ۰/۹ استاندارد می‌نماید (ساجیکومار و همکاران^۱، ۱۹۹۹). در نهایت می‌توان خروجی‌های شبکه را با معکوس نمودن الگوریتم استانداردسازی، به حالت اولیه برگرداند.

تعداد لایه‌های پنهان

تعداد لایه‌های پنهان تا حد امکان باید کم باشد ثابت شده است که هر تابع می‌تواند حداقلبا سه لایه پنهان تقریب زده شود. ابتدا شبکه با یک لایه پنهان آموزش داده می‌شود که در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش خواهد یافت.


تعداد نرون‌های لایه پنهان

اندازه یک لایه مخفی عموماً به طور تجربی بدست می‌آید برای یک شبکه عصبی با اندازه معقول تعداد نرون‌های مخفی با یک نسبت بالنسه کوچکی از تعداد ورودی‌ها انتخاب می‌گردد. اگر شبکه MLP به جواب مطلوب همگرا نگردد تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نرون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند (منهاج، ۱۳۸۴).

توابع محرک

نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند. که از رایج‌ترین آنها می‌توان به توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع محرک خطی اشاره کرد (دموث و همکاران، ۲۰۰۰). با توجه به مسئله مورد بررسی و تحقیقات گذشته که در زمینه اقلیم‌شناسی صورت گرفته، مشخص می‌گردد که این توابع کاربرد فراوانی در زمینه مورد بررسی داشته و دارند (شکل ۷).

شکل ۷: توابع محرک رایج در شبکه‌های پرسپترون چند لایه (MLP)



روش‌های آموزش در شبکه‌های پرسپترون چند لایه

جهت آموزش شبکه‌های عصبی چهار الگوریتم آموزشی مرسوم که بر اساس ساختار معروف پرسپترون چند لایه می‌باشد وجود دارد این روش‌ها عبارتند از: پس انتشار خطای بیشترین شبیب (پس انتشار خطای استاندارد)، گرادیان مزدوج، شبیه نیوتون و مارکوارت-لونبرگ. الگوریتم مارکوارت-لونبرگ از سال ۱۹۹۳ تا به امروز به عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است (اصلاح، ۱۳۸۳) در این بررسی نیز در این پژوهش از این الگوریتم استفاده خواهد شد.

تعداد تکرار یا سیکل^۱

زمانی که پارامترهای شبکه پس از یک دوره کامل ارائه الگوها به دست آمدند در اصطلاح به این نوع تکرار، اپوک (Epoch) یا یک سیکل می‌گویند تعداد تکرارهای شبکه برابر تعداد داده‌های یادگیری می‌باشد (منهاج، ۱۳۸۴). که در این بررسی برای هر شبکه ۲۴۰ دور در نظر گرفته شد.

ارزیابی عملکرد شبکه

در پایان جهت بررسی و آزمون اعتبار شبکه‌ها، به ارزیابی عملکرد آنها پرداخته شد. برای ارزیابی عملکرد شبکه، از سه روش زیر استفاده گردید:

۱- ضریب تبیین: معیاری بدون بعد و بهترین مقدار آن برابر یک می‌باشد رابطه (۲) نحوه محاسبه آن را نشان می‌دهد (صدقت‌کردار و همکاران، ۱۳۸۷):

1.Epoch

(۲)

$$R^2 = \frac{\sum_{K=1}^K X_K Y_K}{\sqrt{\sum_{K=1}^K X_K^2 \sum Y_K^2}}$$

در این رابطه X_K مقادیر مشاهداتی، Y_K مقادیر برآورده شده و K تعداد داده‌ها می‌باشد.

در صد خطای نسبی: که می‌تواند از صفر در عملکرد عالی تا بینهایت تغییر کند:

(۳)

$$Error_i = \frac{Obs_i - For_i}{Obs_i} \times 100$$

در رابطه فوق $Error_i$ خطای مدل، Obs_i و For_i به ترتیب مقادیر مشاهداتی و پیش‌بینی شده و n تعداد کل داده‌های مشاهداتی می‌باشد.

ضریب همبستگی: بیان کننده میزان همبستگی بین نتایج پیش‌بینی شده مدل و داده‌های واقعی می‌باشد که بر اساس رابطه (۴) محاسبه می‌شود بدیهی است که هر چه مقدار آن به یک نزدیک‌تر باشد، نشان دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی است (خلیلی و همکاران، ۱۳۸۵):


(۴)

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

که در آن، y_{act} : مقادیر واقعی، \bar{y}_{act} : میانگین مقادیر واقعی، y_{est} : مقادیر برآورده شده، \bar{y}_{est} : میانگین مقادیر برآورده شده می‌باشد.

مراحل انجام پژوهش به طور خلاصه در شکل (۷) آورده شده است.

شکل ۸: فلوچارت مراحل انجام پژوهش برای تعیین بهترین ساختار شبکه عصبی



نتایج و بحث


به منظور پیش‌بینی میانگین دمای ماهانه شهرستان سنتدج، پس از تعیین موقعیت و ویژگی‌های دمایی منطقه مورد مطالعه، ایستگاه سینوپتیک سنتدج بعنوان مرجع قرار گرفت. جهت تعیین بهترین ورودی‌های شبکه پس از سعی و خطای فراوان، در نهایت ساختاری با استفاده از میانگین دمای ۵ ماه قبل جهت پیش‌بینی دمای ماه بعد انتخاب گردید که در این حالت بهترین همبستگی را بین داده‌های مشاهداتی و پیش‌بینی شده نشان داد. این کار در محیط برنامه نویسی نرم افزار MATLAB صورت گرفت سپس نمودارهای مربوطه در محیط Excel ترسیم گردید. خلاصه نتایج پارامترهای بهینه جهت پیش‌بینی میانگین دمای ماهانه با استفاده از شبکه پرسپترون در جدول (۲) آورده شده است. همانطور که ملاحظه می‌شود تمامی شبکه‌ها با ۲ تا ۴ نرون در لایه پنهان به هدف مورد نظر یعنی خطای زیر پنج درصد رسیده‌اند لازم به ذکر است که در این پژوهش جهت دقت بالای شبکه، برای هر ماه یک شبکه با خطای زیر ۵ درصد یعنی در مجموع ۱۲ شبکه، طراحی گردید. کمترین تعداد نرون‌ها مربوط به ماههای مارس و جولای و بیشترین تعداد نرون‌ها مربوط به ماههای سپتامبر و دسامبر است بقیه ماه‌ها هر کدام با ۳ نرون در لایه پنهان به هدف مورد نظر رسیده‌اند. تمامی شبکه‌ها با یک لایه پنهان به جواب رسیدند و نیاز به افزایش تعداد لایه‌های پنهان نگردید همچنین به غیر ماه مارس (لگاریتم سیگموئیدی) بقیه شبکه‌ها با تابع محرک تانزانست سیگموئیدی به جواب مطلوب همگرا گردیده‌اند. کمترین و بیشترین میزان همبستگی بین داده‌های مشاهده شده و پیش‌بینی شده در مرحله آموزش شبکه‌ها، به ترتیب مربوط به ماههای اکتبر با ۰/۸۱۱ و زانویه با ۰/۹۶۷ و بیشترین و کمترین خطای در مرحله آزمون نیز مربوط به ماههای فوریه و زوئن با ۳/۸۴ و ۰/۵۹ درصد است (جدول ۲).

جدول ۲: پارامترهای آموزشی بهینه برای شبکه‌های پرسپترون چند لایه جهت برآورد میانگین دما


پارامتر آموزشی ماه	تاریخ آغاز	تاریخ پایان	تعداد نمونه (R)	تعداد عکس	تعداد نمونه تعلیم	تعداد نمونه تest	تعداد نمونه تعلیم	تعداد نمونه test	نام شبکه	نام مدل
زانویه	۱/۵۹	۰/۹۶۷	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
فوریه	۳/۸۴	۰/۸۹۳	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
مارس	۲/۶۴	۰/۸۷	+۰/۰۰۵	۲۱۰	pureline	logsig	۴	۰	Lm	
آوریل	۲/۳۹	۰/۸۹۶	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
می	۱/۹۱	۰/۸۰۵	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
ژوئن	+۰/۵۹	۰/۸۴	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
جولای	۱/۴۶	۰/۸۹۱	+۰/۰۰۵	۲۴۰	pureline	tansig	۴	۰	Lm	
آگوست	۱/۰۴	۰/۸۸۴	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
سپتامبر	۳/۱۷	۰/۹۲۸	+۰/۰۰۵	۲۴۰	pureline	tansig	۴	۰	Lm	
اکتبر	۲/۸۱	+۰/۸۱۱	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
نوامبر	۱/۰۵	۰/۸۶	+۰/۰۰۵	۲۴۰	pureline	tansig	۳	۰	Lm	
دسامبر	۱/۱	۰/۸۶۵	+۰/۰۰۵	۲۴۰	pureline	tansig	۴	۰	Lm	

پس از پیش‌بینی میانگین دمای ماهانه برای ۴۸ ماه (۲۰۰۵-۲۰۰۲) جهت تعیین میزان خطای مدل‌ها، داده‌های مشاهداتی و پیش‌بینی شده به وسیله مدل شبکه پرسپترون چند لایه، در شکل (۹) با هم‌دیگر مقایسه شدند همانطور که ملاحظه می‌گردد به دلیل دقت شبکه در پیش‌بینی، منحنی‌های داده‌های مشاهداتی و پیش‌بینی شده کاملاً همپوشانی دارند که این نشان‌دهنده کارایی مناسب این شبکه‌ها در پیش‌بینی میانگین دمای ماهانه در این پژوهش بوده است. همچنین ضریب تبیین بین داده‌های مشاهداتی و پیش‌بینی شده برابر با ۰/۹۹ است که در شکل (۱۰) نمودار و معادله رگرسیونی مربوط به آن آورده شده است.

شکل ۹: نمودار مقادیر میانگین دمای مشاهده شده و پیش‌بینی شده در ماه‌های مختلف



شکل ۱۰: نمودار معادله رگرسیونی بین مقادیر میانگین دمای مشاهده شده و پیش‌بینی شده



میانگین کل خطای شبکه‌ها برابر با $1/97$ درصد است. کمترین و بیشترین میزان خطا به ترتیب مربوط به جولای ۲۰۰۴ با $0/۰۲$ درصد (قریباً بدون خطا) و فوریه ۲۰۰۵ با 5 درصد خطا است همچنین سال‌های ۲۰۰۳ و ۲۰۰۴ با $2/۴۴$ و $1/۶۴$ درصد، به ترتیب دارای بیشترین و کمترین خطا بودند (جدول ۳). در واقع حداکثر اختلاف بین داده‌های مشاهده شده و پیش‌بینی شده 1 درجه سانتیگراد است که مربوط به سپتامبر ۲۰۰۴ است و بقیه شبکه‌ها توانستند دمای ماهانه را با اختلاف کمتر از 1 درجه سانتیگراد پیش‌بینی کنند که نمایانگر دقیق بالای شبکه‌های طراحی شده است.

جدول ۳: میانگین خطای شبکه‌ها بر حسب ماه و سال

Month \ Year	2002	2003	2004	2005	Mean Error
Jan	0.18	1.69	2.62	1.88	1.59
Feb	4.84	4.19	1.32	5.00	3.84
Mar	0.85	3.88	2.34	3.47	2.64
Apr	0.22	4.89	3.07	1.39	2.39
May	0.94	2.23	1.76	2.70	1.91
Jun	0.65	1.07	0.20	0.43	0.59
July	1.27	2.26	0.02	2.27	1.46
Aug	0.70	2.30	0.45	0.71	1.04
Sep	4.46	1.21	4.47	2.54	3.17
Oct	4.12	3.71	1.30	2.11	2.81
Nov	2.31	0.75	0.58	0.57	1.05
Dec	1.32	1.04	1.58	0.47	1.10
Mean Error	1.82	2.44	1.64	1.96	1.97

نتایج ارزیابی عملکرد شبکه نیز در جدول (۴) آورده شده است همان طور که مشاهده می‌شود همبستگی بین داده‌های مشاهده شده و پیش‌بینی شده برابر با ۰/۹۹ و ضریب تبیین مشابه که ضریب همبستگی در سطح یک درصد معنی‌دار گشته است و با توجه به اینکه میانگین خطای شبکه ۱/۹۷ است و میانگین دمای ماهانه پیش‌بینی شده به مقادیر واقعی نزدیک است (شکل ۹) می‌توان اظهار داشت که شبکه طراحی شده دارای عملکرد مناسبی است.

جدول ۴: ارزیابی عملکرد شبکه پرسپترون چندلایه

R	R ²	Error	پارامترهای عملکرد شبکه
۰/۹۹۹	۰/۹۹۸	۱/۹۷	مدل شبکه پرسپترون چندلایه

در نهایت با توجه به نتایج تحقیق و ارزیابی مدل می‌توان اظهار داشت که استفاده از روش شبکه عصبی مصنوعی پرسپترون چندلایه به عنوان روشی غیرخطی در پیش‌بینی میانگین

دمای ماهانه با توجه به تعیین خطای آموزشی می‌تواند به عنوان گزینه‌ای سودمند مورد توجه و بررسی قرار گیرد که طبیعتاً با گذشت زمان در سال‌های آتی و افزایش اطلاعات در دسترس، دقیق‌ترین روش نیز افزایش یافته و برای پیش‌بینی‌های فصلی، سالانه و بلند مدت نیز کاربرد خواهد داشت. که از نتایج آن می‌توان در بهره‌برداری از منابع آب، مطالعات زیست محیطی، تغییر اقلیم‌ها، خشکسالی‌ها، حمل و نقل و غیره استفاده نمود.

منابع

۱. اصغری مقدم، الف. نورانی، و. ندیری، ع. ۱۳۸۷. مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی. مجله دانش کشاورزی دانشگاه تبریز، ج ۱۸، ش ۱، ص ۱۵-۱.
۲. اصلاح، پ. ۱۳۸۳. آنالیز برگشتی در آزمایش SASW با استفاده از شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد عمران، دانشکده فنی، دانشگاه ارومیه.
۳. جهانبخش اصل، س.، باباپور، ع. ۱۳۸۲. بررسی و پیش‌بینی متوسط دمای ماهانه تبریز با استفاده از مدل آریما (ARIMA). فصلنامه تحقیقات جغرافیایی دانشگاه اصفهان، ج ۱۸، ش ۳، ص ۴۶-۳۴.
۴. چوبدار، الف. ۱۳۸۶. پیش‌بینی ورودی ماهانه دریاچه سد شهید مدنی تبریز (ونیار) براساس تأثیر عناصر اقلیمی با استفاده از شبکه‌های عصبی مصنوعی. پایان‌نامه دکترای - تخصصی (PH.D) جغرافیای طبیعی (کلیماتولوژی)، دانشگاه تبریز.
۵. حجازی‌زاده، ز.، جویزاده، س. ۱۳۸۷. پایش خشکسالی در استان فارس، سومین همایش مقابله با سوانح طبیعی، دانشگاه تهران.
۶. حجازی‌زاده، ز.، فتاحی، الف. ۱۳۸۲. علل کمی شدت و تداوم خشکسالی‌های روزانه در شهر کرد، نشریه علوم جغرافیایی، دانشگاه تربیت معلم تهران، ج ۱، ش ۱، ص ۱۰.
۷. حسینی، س، الف. ۱۳۸۸. برآورد و تحلیل دمای حداکثر شهرستان اردبیل با استفاده از مدل تئوری شبکه‌های عصبی مصنوعی، پایان‌نامه کارشناسی ارشد جغرافیای طبیعی (اقلیم شناسی)، دانشگاه محقق اردبیلی.
۸. خلیلی، ن.، خداشناس، س.، داوری، ک. ۱۳۸۵. پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی. دومین کنفرانس مدیریت منابع آب.
۹. رحیمی، الف. ۱۳۸۵. تحلیل آلودگی‌های هوایی ناشی از مکانیابی نامناسب مراکز صنعتی در شهر تبریز با استفاده از شبکه‌های عصبی. پایان‌نامه کارشناسی ارشد جغرافیا و برنامه‌ریزی شهری، دانشگاه تبریز.
۱۰. سکوندی، ف. ۱۳۷۶. پیش‌بینی عناصر اقلیمی با استفاده از تئوری شبکه‌های عصبی (ایستگاه نمونه اهواز). پایان‌نامه کارشناسی ارشد جغرافیای طبیعی (اقلیم شناسی)، دانشگاه تبریز.

۱۱. صداقت کردار، ع.، فتاحی، الف. ۱۳۸۷. شاخص‌های پیش آگاهی خشکسالی در ایران. مجله جغرافیا و توسعه دانشگاه سیستان و بلوچستان، ج ۶، ش ۱۱، ص ۵۹-۷۶
۱۲. علیجانی، ب.، قویدل‌رحمی، ی. ۱۳۸۴. مقایسه و پیش‌بینی تغییرات دمای سالانه تبریز با ناهنجاری‌های دمایی کره زمین با استفاده از روش رگرسیون خطی و شبکه عصبی مصنوعی. مجله جغرافیا و توسعه دانشگاه سیستان و بلوچستان، ج ۳، ش ۶، ص ۲۱-۳۸.
۱۳. کارآموز، م.، رمضانی، ف.، رضوی، س. ۱۳۸۵. پیش‌بینی بلندمدت بارش با استفاده از سیگنال‌های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی. هفتمین کنگره بین‌المللی مهندسی عمران.
۱۴. منهاج، محمد، باقر. ۱۳۸۴. مبانی شبکه‌های عصبی (هوش محاسباتی)، مرکز نشردانشگاه صنعتی امیر کبیر، چاپ سوم، ج ۱، ۷۱۲ ص.

- 15. Demuth, H., Beale, M. 2000. Neural Network Toolbox User,s Guide, Copyright 1992-2002, By The Math Works, Inc, Version 4, 840pp.**
- 16. Jain, A. 2003. Predicting Air Temperature For Frost Warning Using Artificial Neural Network, A Thesis Submitted to the Graduate Faculty of The University of Georgia in Partial Fulfillment of the Requirements for the Degree MASTER OF SCIENCE, ATHENS, GEORGIA, 92 P.**
- 17. Rehman, S., Mohandes, M. 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity, Energy Policy 36: 571-576.**
- 18. Sajikumar, N., Thandaveswara, B.S. 1999. Non Liner rainfall runoff Model using artificial neural network. Journal of Haydrology, 216: 32-35.**
- 19. Senkal, O., Kuleli, T. 2009. Estimation of solar radiation over Turkey using artificial neural network and satellite data, Applied Energy 86: 1222-1228.**