

B. Salahi
S. A. Hosaini
H. Shayeghi
B. Sobhani

Email: Bromand416@yahoo.com

بروند صلاحی: استادیار گروه جغرافیای طبیعی، دانشگاه محقق اردبیلی
سید اسعد حسینی: دانشجوی کارشناسی ارشد اقلیم‌شناسی، دانشگاه محقق اردبیلی
حسین شایقی: استادیار گروه مهندسی برق، دانشگاه محقق اردبیلی
بهروز سبحانی: استادیار گروه جغرافیای طبیعی، دانشگاه محقق اردبیلی
شماره مقاله: ۷۹۴
شماره صفحه پایابی ۱۶۵۱۸-۱۶۴۹۶

پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی

مطالعه موردی: شهرستان اردبیل

چکیده

با توجه به تغییرات اقلیمی، گرمایش جهانی و خشکسالی‌های اخیر، پیش‌بینی دماهای حداکثر به عنوان یکی از مهمترین پارامترهای اقلیمی فرصت مناسبی را برای برنامه‌ریزی و ارائه تمهیدات لازم در اختیار برنامه‌ریزان قرار می‌دهد. بررسی و تحلیل دماهای حداکثر به عنوان یکی از پارامترهای اقلیمی در مدیریت منابع آبی و طبیعی، کشاورزی، گسترش آفات و بیماری‌ها، ذوب برف و سیلاب، تبخیر و تعرق، خشکسالی و غیره اهمیت زیادی دارد. امروزه با گسترش مدل‌های هوشمند و تجربی در علوم مختلف، از جمله اقلیم‌شناسی و لزوم پیش‌بینی‌های دقیقتر، جایگزینی آنها به جای مدل‌های قدیمی اهمیت پیدا می‌کند. یکی از این روش‌ها، شبکه‌های عصبی مصنوعی از مؤلفه‌های هوش مصنوعی است که یکی از مهمترین کاربردهای آن در زمینه علوم جوی، پیش‌بینی و محاسبه پارامترهای اقلیم‌شناسی است. در این تحقیق با استفاده از متغیرهای میانگین رطوبت نسبی، میانگین سرعت باد، مجموع ساعات آفتابی، میانگین حداقل و حداکثر دمای ماهانه به عنوان ورودی شبکه پرسپترون چندلایه (MLP)، میانگین حداکثر دمای ماهانه ایستگاه سینوپتیک اردبیل پیش‌بینی شد. پارامترهای مذکور سال‌های آماری ۱۹۸۵ تا ۲۰۰۵ را در

بر می‌گیرند. از ۲۱ سال دوره آماری موجود، حدود ۸۵ درصد آن یعنی ۱۸ سال (۲۱۶ ماه) برای آموزش شبکه و ۳ سال (۳۶ ماه) باقیمانده در مرحله آزمون شبکه به کار برده شده است. بدین منظور از امکانات و توابع موجود در نرم‌افزار MATLAB بهره‌گرفته شد و برای هر ماه یک شبکه با خطای کمتر از ۵ درصد طراحی گردید. پس از بررسی شاخص‌های عملکرد شبکه، از جمله ضریب تعیین، مجدول میانگین مربعات خطأ، میانگین مربعات خطأ، میانگین مطلق خطأ، میانگین درصد خطأ و ضریب همبستگی مشاهده شد که پیش‌بینی دمای حداکثر با دقت قابل قبولی انجام شده است؛ به گونه‌ای که میزان ضریب همبستگی آن ۰/۹۹ و بیشترین اختلاف آن با داده‌های واقعی برابر ۰/۸۳ درجه سانتیگراد بوده است.

واژه‌های کلیدی: پیش‌بینی، دمای حداکثر، شبکه‌های عصبی مصنوعی، شهرستان اردبیل.

مقدمه

از آن جایی که آب و هوا تاثیر شگرفی بر روی حیات اجتماعی و فردی انسان‌ها دارد، لذا مراکز علمی زیادی در سطح جهان، پژوهش بر روی مسائل مختلف آب و هوايی را شروع کرده‌اند. پیش‌بینی اقلیمی وضع هوا (بررسی و پیش‌بینی چگونگی تغییرات روزانه وضعیت جو در لایه پایین) از مهمترین کارهایی است که در این مراکز انجام می‌گیرد. پیش‌بینی اقلیمی وضع هوا، بر اساس مقادیر کنونی و پیش‌بینی شده پارامترهای جوی صورت می‌پذیرد (تشنه لب و منشی، ۱۳۸۲: ۴۴۶). نقش دماهای حداکثر در افزایش تبخیر و تعرق، کاهش آب‌های سطحی و زیر زمینی، گسترش انواع بیماری‌ها، آتش سوزی جنگل‌ها، فرایند ذوب یخچال‌ها و بروز خشکسالی و کم آبی در مناطقی دیگر بر کسی پوشیده نیست (حسینی، ۱۳۸۸: ۳). دما و بارش از مهمترین و اساسی‌ترین عناصر اقلیمی هستند که در تعیین نقش و پراکنش سایر عناصر اقلیمی نقش برجسته‌ای دارند. از آن جایی که دما نقش اساسی را در پهنه‌بندی‌ها و طبقه‌بندی‌های اقلیمی ایفا می‌کند، لذا نوسان‌ها و تغییرات آن نیز از اهمیت زیادی برخوردار است.

پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۵۹

تغییرات معنی‌دار دمای کره‌ی زمین یا گرمایش جهانی به عنوان مهمترین نمودهای تغییر اقلیم در قرن حاضر مورد توجه قرار گرفته، بسیاری از مسائل و مشکلات محیطی مانند سیل، طوفان، خشکسالی، تکثیر بیش از حد حشرات موذی و همگی در تغییر اقلیم کره‌ی زمین به ویژه افزایش دما ریشه دارند (علیجانی و قویدل‌رحمی، ۱۳۸۴: ۲۲).

در این میان، استفاده از روش‌های تخمین و پیش‌بینی در صورتی که از دقت کافی برخوردار باشند، می‌تواند در برنامه‌ریزی‌ها و مدیریت صحیح مفید واقع شوند (کارآموز و همکاران، ۱۳۸۵، ۲). روش‌های متداول در پیش‌بینی عناصر اقلیمی، بر مبنای بحث و بررسی بر روی نقشه‌های پیش‌بینی به دست آمده بر مبنای داده‌های ایستگاه‌های زمینی، ماهواره‌ای و مانند آنها استوار است. داده‌های مذکور پس از پردازش، به صدور پیش‌بینی منجر می‌شوند. این روش، به دلیل انسان محور بودن، احتمالاً خالی از اشکال نخواهد بود. در ضمن، خطای پیش‌بینی نیز به همین دلیل می‌تواند دامنه بالایی داشته باشد (علیاری شوره دلی و همکاران، ۱۳۸۳: ۱۳۹). درجه حرارت‌های بالا در زمینه حمل و نقل جاده‌ای نیز می‌تواند به خطرات و حوادث منجر گردد؛ از جمله تأثیر مستقیم بر روی وسیله نقلیه از طریق تبخیر شدید بنزین و آب موجود در خودرو (کای و سیموندا^۱، ۲۰۰۵: ۱۰۹) و همچنین ایجاد خستگی در راننده (اریکسون و لیندکویست^۲، ۲۰۰۳: ۴۰۵).

پیش‌بینی هوا از سیستم‌های غیرخطی و پیچیده و فاقد مدل ریاضی است که به دلیل تغییر پذیر بودن سیستم با زمان، روش‌های معمول پیش‌بینی، امکان پیش‌بینی را غیر ممکن می‌سازد. از طرف دیگر، اهمیت پیش‌بینی هوا در زمینه‌های مختلف، از جمله امور اقتصادی، نظامی، کشاورزی و آشکار است (تشنه‌لب و همکاران، ۱۳۷۷: ۹). امروزه، پژوهشگران با ابداع علمی همانند روش‌های هوشمند که ابزاری توانمند و انعطاف‌پذیر هستند، به دنبال راه‌هایی فراتر از روش‌های معمول برای شناخت و پیش‌بینی پارامترهای مهم هواشناسی هستند. شبکه‌های عصبی مصنوعی یکی از این روش‌هاست که قادر به

1-Keay; Simmonda
2-Eriksoon; Lindqvist

محاسبه توابع حسابی و منطقی هستند (خلیلی و همکاران، ۱۳۸۵: ۲). شبکه‌های عصبی مصنوعی که زیر مجموعه سیستم‌های هوشمند هستند قادرند با تکنیک‌های قوی آموزشی، خصوصیات سیستم را از داده‌های وسیع موجود به دست آورند. این روش در نیل به اهداف علمی چون هواشناسی که دارای سیستم‌های غیرخطی و پیچیده‌ای هستند کاربردهای زیادی دارد. هدف این تحقیق، پیش‌بینی دماهای حداکثر با توجه به اهمیت‌های ذکر شده در مورد دماست. دماهای حداکثر در منطقه مورد مطالعه چندان بالا نیست، ولی تغییرات جزئی آن می‌تواند با بروز مسائل و مضلات اقلیمی و زیست محیطی همانند سیلاب، خشکسالی، گسترش آفات و بیماری‌ها، از بین رفتن پوشش گیاهی و به ویژه کاهش آب‌های سطحی و زیر زمینی همراه باشد. از طرف دیگر، منطقه مورد بررسی و حتی ساکنان آن با دماهای پایین سازگاری پیدا کرده‌اند. امروزه از شبکه‌های عصبی در شبیه‌سازی تغییرات عناصر اقلیمی در مقیاس منطقه‌ای استفاده زیادی می‌شود. برقراری ارتباط منطقی بین داده‌های ورودی و خروجی بدون لحاظ نمودن رابطه‌ی فیزیکی بین آن‌ها از ویژگی‌های اصلی این شبکه‌ها محسوب می‌شود (کولیبالی^۳ و همکاران، ۲۰۰۵: ۴۸۶).

در این تحقیق سعی خواهد شد ضمن معرفی مختصر و شناخت شبکه‌های عصبی مصنوعی، دماهای حداکثر شهرستان اردبیل از ژانویه سال ۲۰۰۴ تا دسامبر سال ۲۰۰۶ میلادی برای ارزیابی عملکرد این مدل‌ها با داده‌های واقعی، برآورد و تحلیل و مدل مناسب ارائه گردد.

پیشینه تحقیق

جین^۴ (۲۰۰۳) با استفاده از شبکه‌های عصبی مصنوعی، دمای هوا را در منطقه جنوب جورجیا برای یک تا دوازده ساعت آینده پیش‌بینی کرد. رحمان و موهاندنس^۵ (۲۰۰۸)

3-Coulibaly

4 -Jain

نشان دادند که شبکه‌های عصبی قادرند تابش خورشیدی شهر آبهای^۵ عربستان سعودی را از طریق دما و رطوبت نسبی دوره آماری ۱۹۹۸ تا ۲۰۰۲ برآورد نمایند. کادناس و ریورا^۶ (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی، سرعت باد را در مناطق لاوتا، اوزاکا و مکزیکو برای کوتاه مدت با دقت خوبی پیش‌بینی نمودند. سنکال و کوللی^۷ (۲۰۰۹) با استفاده از الگوریتم‌های یادگیری انتشار برگشتی بهبودپذیر(RP)^۸، گرادیان مزدوج مقیاس شده (SCG)^۹ و تابع محرك تائزانت سیگموئیدی در شبکه‌های عصبی مصنوعی و نیز با بهره‌گیری از داده‌های ماهواره‌ای، تابش خورشید را در سطح ترکیه پیش‌بینی کردند. احمدی (۱۳۸۲) با استفاده از مدل شبکه‌های عصبی مصنوعی مبتنی بر مدل خود سازمانده کوهنن (SOM)، تغییرات بارش شهر بوشهر را طبقه‌بندی نمود. سهیلی‌خواه و تشنه‌لب (۱۳۸۳) با استفاده از یک ساختار نوین پویای شبکه عصبی- فازی به پیش‌بینی حداکثر دمای روزانه پرداختند و با الگوریتم پیشنهادی خود، دقت پیش‌بینی را بالاتر بردنده. رحمانی و تشنه‌لب (۱۳۸۴) ساختار جدیدی را بر اساس شبکه‌های عصبی مصنوعی با عنوان TD-CMAC^{۱۰} که بسط یافته مدل مخچه یا CMAC^{۱۱} است، مطرح و از آن برای پیش‌بینی مقادیر حداقل و حداکثر دمای روزانه استفاده نمودند. علیجانی و قویدل رحیمی (۱۳۸۴) با استفاده از روش‌های رگرسیون خطی و شبکه‌های عصبی مصنوعی، به مقایسه و پیش‌بینی تغییرات سالانه دمای تبریز با ناهنجاری‌های دمایی کره زمین پرداختند. کارآموز و همکاران (۱۳۸۵) با استفاده از شبکه‌های عصبی به پیش‌بینی بلند مدت بارش حوضه‌های غربی ایران پرداخته، کارایی خوب و دقت قابل قبول شبکه‌های عصبی را اثبات کردند. رحیمی‌خوب و همکاران (۱۳۸۶) با بهره‌گیری از مدل

5-Rehman;Mohandes

6-Abha City

7-Cadenas; Rivera

8-Senkal; Kuleli

9- Resilient Back Propagation

10- Scaled Conjugate Gradient

11- Time Delay Cerebella Model Arithmetic Computer

12- Cerebella Model Arithmetic Computer

شبکه‌های عصبی مصنوعی، دقت پیش‌بینی دمای حداکثر هوای استان خوزستان را مطالعه کردند و به این نتیجه رسیدند که مدل شبکه عصبی با ساختار ۶ نرون در لایه ورودی (شامل ۴ باند ماهواره نوا، روز شمار سال و ارتفاع زمین) و ۱۹ نرون در لایه پنهان، بهترین مدل است و $91/4$ درصد نتایج را با دقت ۳ درجه سانتیگراد پیش‌بینی کردند. خوشحال دستجردی و قویل رحیمی (۱۳۸۷) رابطه تغییرات بارش سالانه تبریز با ناهنجاری‌های کره زمین را بررسی و اعداد آن را با شبکه‌های عصبی مصنوعی شبیه سازی نمودند. اصغری مقدم و همکاران (۱۳۸۷) از شبکه‌های عصبی مصنوعی برای پیش‌بینی بارش دشت تبریز استفاده کردند و نشان دادند که بهترین مدل، از یک شبکه پیشرو با شش گره ورودی، یک گره خروجی، یک لایه میانی و الگوریتم مارکوارت-لونبرگ تشکیل شده است. نتایج حاصل از بررسی پیشینه تحقیق نشان می‌دهد که شبکه‌های عصبی مصنوعی در بیشتر مسایل از دقت بسیار خوبی برخوردارند و در مسایل مربوط به آب و هوا، مدل پرسپترون چندلایه با الگوریتم مارکوارت-لونبرگ و توابع محرک سیگموئیدی کاربرد بیشتری دارند. لذا با توجه به دقت این مدل‌ها و گسترش روزافزون آن‌ها در مسایل مربوط به پیش‌بینی و برآورد پارامترها و همچنین تغییرات اقلیمی و گرمایش جهانی در دهه‌های اخیر، در این مقاله نیز سعی خواهد شد دماهای حداکثر شهرستان اردبیل با استفاده از شبکه‌های عصبی مصنوعی برآورد و تحلیل گردد.

ویژگی‌های منطقه مورد مطالعه

ایستگاه سینوپتیک اردبیل از لحاظ مختصات جغرافیایی در ۴۸ درجه و ۱۷ دقیقه طول جغرافیایی و ۳۸ درجه و ۱۸ دقیقه عرض جغرافیایی قرار دارد. شهرستان اردبیل نیز با مساحت ۲۳۹۸ کیلومتر مربع در ارتفاع ۱۳۳۲ متری از سطح دریا واقع شده است (معاونت برنامه‌ریزی و نظارت راهبردی مرکز آمار ایران، ۱۳۸۵: ۲۴۹). برای بررسی و ضعیت‌های دمایی شهرستان اردبیل، از دوره آماری در دسترس (۱۹۸۵-۲۰۰۵) ایستگاه سینوپتیک اردبیل به عنوان نماینده شهرستان اردبیل استفاده شده است. متوسط دمای سالانه شهرستان

پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۶۳

اردبیل ۹ درجه سانتی‌گراد و دامنه تغییرات سالانه آن با حداکثر ۱۱/۱ درجه سانتی‌گراد در سال ۱۹۸۱ و حداقل ۶/۶ درجه سانتی‌گراد در سال ۱۹۹۳ به میزان ۴/۵ درجه سانتی‌گراد است. میانگین حداقل و حداکثر دمای دوره آماری نیز به ترتیب مربوط به ماههای دی و تیر با ۷/۹ و ۲۵ درجه سانتی‌گراد است. حداقل دمای مطلق ثبت شده نیز مربوط به سوم فوریه سال ۱۹۸۹ میلادی با دمای ۳۳/۸ درجه سانتی‌گراد و حداکثر آن مربوط به ۱۲ آگوست سال ۲۰۰۳ میلادی با ۳۹/۸ درجه سانتی‌گراد است (جدول ۱).

جدول ۱ : مشخصات آماری دمای ایستگاه سینوپتیک اردبیل (درجه سانتی‌گراد)

دوره آماری	میانگین دمای سالانه	حداکثر دمای سالانه	میانگین حداقل دمای سالانه	میانگین حداقل دمای سالانه	میانگین دمای مطلق دما	حداقل دمای مطلق دما	دامنه تغییرات دمای میانگین دما
-۲۰۰۵ ۱۹۷۷	۹	۱۵/۳	۴/۸	۳۹/۸	-۳۳/۸	۴/۵	

(ماخذ: نگارنده‌گان)

مواد و روش‌ها

در پژوهش حاضر، از آمار هواشناسی ایستگاه سینوپتیک اردبیل استفاده شده است. آمار مذکور برای پیش‌بینی، پارامترهای مختلف ماهانه مربوط به سال‌های آماری ۱۹۸۵ تا ۲۰۰۵ را در بر می‌گیرد. به دلیل در دسترس نبودن دیده‌بانی‌های پیوسته قبل از سال ۱۹۸۵ (نبود آمار مجموع ساعت‌آفتابی) و به دلیل کنترل کیفی نشدن میانگین سرعت باد ماهانه بعد از سال ۲۰۰۵، از متوسط ماهانه داده‌های موجود در این بازه زمانی (۲۰۰۵-۱۹۸۵) استفاده شده است. داده‌های مربوطه پس از تهیه از اداره کل هواشناسی اردبیل و کنترل کیفی آن‌ها، بررسی شد؛ بدین صورت که ابتدا عناصر تأثیرگذار بر دما مشخص و سپس جهت ورود به شبکه پرسپترون چندلایه اقدام به تشکیل ماتریس مربوطه گردید. ورودی‌های شبکه، متغیرهای میانگین رطوبت نسبی، میانگین سرعت باد، مجموع ساعت

آفتایی، میانگین حداقل و حداکثر دمای ماهانه در زمان‌های قبل و خروجی شبکه نیز میانگین حداکثر دمای ماهانه هستند. پس از انتخاب داده‌های ورودی و خروجی شبکه و تعیین ساختار شبکه از لحاظ تابع محرک، تعداد نمونه‌های لایه پنهان، تعداد لایه‌های پنهان، تعداد تکرار (اپوک)^{۱۳}، مقادیر پارامترهای آموزشی و تابع عملکرد، آموزش شبکه با استفاده از هر یک از الگوریتم‌های آموزشی موجود در برنامه MATLAB، ابتدا با یک نمون پنهان و ۱۰ تکرار شروع شده و با افزایش آن تا حداکثر تعداد نمون و تکرار ادامه یافت. همچنین در تمام مراحل فوق، پس از هر بار آموزش، شبکه آزمون گردید که برای ارزیابی بهتر عملکرد و انتخاب شبکه بهینه اقدام به آنالیز رگرسیونی و تعیین ضریب همبستگی بین داده‌های ورودی و خروجی در مرحله آموزش و درصد خطا در مرحله آزمون گردید. تعداد بهینه نمون پنهان و تکرار در الگوریتم‌های آموزشی بر اساس بالاترین ضریب همبستگی و خطای کمتر از ۵ درصد مشخص گردید. با داشتن تعداد بهینه نمون پنهان و تکرار، می‌توان با استفاده از روش سعی و خطای نسبت به نوع تابع محرک، مقادیر پارامترهای آموزشی و تعداد لایه‌های پنهان تجدید نظر نمود که در صورت عملکرد بهتر شبکه، آن شبکه به عنوان شبکه بهینه انتخاب و برنامه ذخیره و جهت استفاده در مراحل بعدی Load می‌گردید، در غیر این صورت الگوریتم آموزشی دیگری استفاده و همه مراحل باز تکرار می‌گردید تا شبکه به جواب مطلوب همگرا گردد و اگر شبکه در هر الگوریتم آموزشی و با هر تعداد لایه و نمون پنهان و تکرار به جواب مورد نظر می‌رسید، آن شبکه به عنوان شبکه بهینه انتخاب می‌شد. برای ارزیابی عملکرد شبکه‌های عصبی نیز از شاخص‌های، ضریب تعیین (R^2)^{۱۴}، محدود میانگین مربعات خطای

13 -Epoch

14 -Determination Coefficient


پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۶۵

میانگین مربعات خطأ (MSE)^{۱۶}، میانگین مطلق خطأ (MAE)^{۱۷}، میانگین (RMSE) درصد خطأ (Error)^{۱۸} و ضریب همبستگی (R) استفاده شده است.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANNs)^{۱۹} ابزار ریاضی‌ای هستند که با تقلید از سیستم عصبی بیولوژیک ساخته شده‌اند (فولاپ و همکاران^{۲۰}، ۱۹۹۸؛ ۷۵۴)، قدرت انعطاف و تصحیح‌پذیری بالایی در انطباق خود با داده‌های موجود را دارند (رنجیتان و همکاران^{۲۱}، ۱۹۹۵)؛ به گونه‌ای که قادرند به سازماندهی مجهر شده، نظم و هماهنگی موجود در داخل این داده‌ها را پیدا کنند (منهاج، ۲۱: ۱۳۸۴) و بر اساس بردارهای ورودی، رخداد و بزرگی یک پدیده را پیش‌بینی نمایند (کنراد و روهل^{۲۲}، ۱۹۹۹: ۳). در شکل (۱) یک نرون ساده با R ورودی نشان داده شده است. هر بردار ورودی با انتخاب مناسب وزن W، وزن‌دار شده و جمع ورودی‌های وزن‌دار با بایاس^{۲۳}، ورودی تابع حرک F را تشکیل می‌دهند. نرون‌ها قادرند از توابع حرک مختلفی برای تولید خروجی بهره ببرند. توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع حرک خطی متداول‌ترین آن‌ها محسوب می‌شوند (دموثر و بیل^{۲۴}، ۲۰۰۰: ۱۳۹).

-
- 15 -Root Mean Square Error
 - 16 - Mean Square Error
 - 17 -Mean Absolute Error
 - 18 -Correlation Coefficient
 - 19-Artificial Neural Network
 - 20-Fulop et al
 - 21-Ranjithan et al
 - 22-Conrads;Roehle
 - 23-Bias
 - 24-Demuth; Beale



شکل ۱ : مدل نرون در یک شبکه عصبی مصنوعی (مأخذ: دموث و بیل، ۲۰۰۰: ۱۳۹).

ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی یا پنهان و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه است و لایه پنهان محل پردازش داده‌هاست. شمار لایه‌ها و شمار نرون‌ها در هر لایه پنهان، به طور معمول به وسیله روش آزمون و خطأ مشخص می‌شود (اصغری مقدم و همکاران، ۱۳۸۷: ۳).

شبکه‌های پرسپترون چند لایه (MLP)^{۲۵}

در سال‌های اخیر، انواع زیادی از شبکه‌های عصبی مصنوعی در زمینه‌ها و اهداف گوناگون علوم به ویژه برای تخمین و پیش‌بینی پدیده‌ها طراحی و به کار گرفته شده‌اند. برای استفاده از شبکه‌های عصبی جهت حل مسائل، نیاز به انتخاب شبکه عصبی مناسب نیاز است. نوع یک شبکه عصبی توسط ساختار و آموزش آن مشخص می‌شود. انتخاب این شبکه به ماهیت مسئله مورد بررسی و نوع داده‌های آن وابسته است. در برآورد عناصر جوی، شبکه عصبی باید قادر به نگهداری اطلاعات و دیده‌بانی‌های گذشته باشد. به

25 -Multi Layer Perceptron

پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۶۷

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: ۲۸). در این بررسی نیز از شبکه‌های پرسپترون چند لایه پیشخور در پیش‌بینی داده‌ها (با توجه به کاربرد و قابلیت زیاد آن‌ها در تعمیم نتایج) استفاده می‌شود. متغیرهای میانگین رطوبت نسبی، میانگین سرعت باد، مجموع ساعت - آفتابی، میانگین حداقل و حداکثر دمای ماهانه در زمان‌های قبل به عنوان ورودی‌های شبکه و میانگین حداکثر دمای ماهانه به عنوان خروجی شبکه در نظر گرفته شده است. پارامترهای مذکور سال‌های آماری ۱۹۸۵ تا ۲۰۰۵ را در بر می‌گیرد. از ۲۱ سال دوره آماری موجود، حدود ۸۵ درصد آن، یعنی ۱۸ سال (۲۱۶ ماه) برای آموزش شبکه و ۳ سال (۳۶ ماه) باقیمانده در مرحله آزمون شبکه به کار گرفته می‌شود. طبق نظر نیرومند و بزرگ‌نیا (۱۳۷۲)، تعداد پیش‌بینی‌ها نباید بیشتر از یک چهارم داده‌ها ($N/4$) باشد؛ لذا شبکه طوری طراحی گردید که بتوان با ورود متغیرهای ذکر شده در یک ماه از سال، دمای حداکثر همان ماه در سال بعد را با خطای کمتر از ۵ درصد برآورد کرد، چرا که شبکه بر اساس یک دوره آماری بلند مدت (۱۸ ساله) آموزش دیده است. ساختارهای مختلف شبکه پرسپترون از نظر پارامترهای آموزشی در محیط برنامه‌نویسی نرم‌افزار MATLAB با استفاده از ۱۲ الگوریتم طراحی شدند و شبکه بهینه انتخاب و بارگذاری گردید. ورود داده‌ها به صورت خام، سرعت و دقت شبکه را کاهش می‌دهد، لذا لازم است داده‌های ورودی به شبکه استاندارد گردد. در پژوهش حاضر، برای نرمال کردن داده‌ها بین ۰/۰ و ۰/۹ از رابطه (۱) استفاده شده است (ساجیکومار و تانداورسوارا^{۲۶}، ۱۹۹۹: ۳۴). با معکوس نمودن الگوریتم استاندارد سازی، خروجی‌های شبکه به حالت اولیه بر می‌گردند:

26- Sajikumar; Thandaveswara

$$N_i = 0.8 \left[\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right] + 0.1 \quad (1)$$

در معادله فوق، N_i : مقدار نرمال شده، x_i : مقادیر واقعی، x_{\min} و x_{\max} حداقل و حداکثر مقادیر واقعی هستند.

نتایج و بحث

انتخاب مناسب‌ترین متغیرهای ورودی و الگوریتم


برای انتخاب مناسب‌ترین ورودی‌های مدل، ضرایب همبستگی و رگرسیونی بین دمای حداکثر واقعی و برآورد شده تمامی شبکه‌ها (ماه‌ها) به کار گرفته شده و نتایج آن‌ها در جدول (۲) ارائه شده است. در تمامی ماه‌ها، دمای حداکثر ماه i از سال n دارای همبستگی مناسبی با متغیرهای میانگین رطوبت نسبی ماهانه، میانگین سرعت باد ماهانه، مجموع ساعت‌آفتابی ماهانه، میانگین حداقل و حداکثر دمای ماهانه‌ی ماه i از سال n به $i-1$ بودند. البته، این حالت با سعی و خطأ و بررسی فراوان به دست آمده است؛ بدین صورت که همه حالات ممکن از جمله برآورد دمای حداکثر یک ماه با استفاده از پنج متغیر ذکر شده در ۵ ماه قبل و یا برآورد دمای حداکثر یک ماه از سال با استفاده از پنج متغیر ذکر شده و یا فقط دمای حداکثر ۱۲ ماه قبل و یا با یک متغیر و افزایش آن تا ۵ متغیر امتحان گردید که در نهایت، برآورد دمای حداکثر یک ماه با استفاده از پنج متغیر ذکر شده در ۵ ماه قبل انتخاب گردید. این مساله نشان داد که افزایش دقت شبکه با افزایش متغیرهای ورودی در ارتباط است. پس از هر بار آموزش شبکه، نموداری که نشان دهنده روند تغییرات خطای داده‌های آموزشی و تست شبکه است در نرم افزار MATLAB ترسیم شد که نمونه آن در شکل (۲) آورده شده است. در این نمودار، خط ممتد، مربوط به بهترین خط برآذش یافته از بین نقاط داده‌ها و خط نقطه چین، نیمساز ربع اول دو محور عمودی و افقی است. هر قدر این خط به بهترین خط

پیش‌بینی دماهی حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۶۹

برازش یافته (خط ممتد) نزدیکتر باشد، بیانگر برآورد عالی و برآورده دقيق خروجی‌های شبکه خواهد بود (داده‌های موجود در نسودار نرمال شده است). کمترین ضریب همبستگی در مرحله آموزش مربوط به ماه زوئن با ۰/۷۵۴ و بیشترین آن مربوط به ماه‌های فوریه و اکتبر با ۰/۹۷۱ با سطح خطای ۰/۰۰۵ است (جدول ۲). در انتخاب مناسبترین الگوریتم نیز با بررسی‌های به عمل آمده، الگوریتم مارکوآرت-لونبرگ در میان سایر الگوریتم‌ها، در مرحله آموزش، بالاترین همبستگی و در مرحله آزمون، کمترین خطا را داشت، لذا بهتر از دیگر الگوریتم‌ها شناخته شد. دارا بودن بهترین عملکرد، بالاترین ضریب همبستگی و کمترین تعداد نرون در لایه پنهان از دلایل انتخاب این الگوریتم بود.

جدول ۲ : پارامترهای آموزشی بهینه برای شبکه‌های پرسپترون چندلایه برای برآورد دماهی حداکثر

پارامتر آموزشی	قیمتیوند پنهان	قیمتیوند لایه مidden	قیمتیوند لایه خروجی	تعداد نرون	پارامتر آموزشی					
Lm	۴/۶۴	۰/۹۲۴	۰/۰۰۵	۳۰	pureline	tansig	۵-۳	ژانویه		
Lm	۱/۳۸	۰/۹۷۱	۰/۰۰۵	۱۰	pureline	tansig	۱۱	فوریه		
Lm	۱/۸۱	۰/۹۶۷	۰/۰۰۵	۱۲۰	pureline	tansig	۶	مارس		
Lm	۱/۴۸	۰/۸۲۵	۰/۰۰۵	۱۱۰	pureline	tansig	۴	آوریل		
Lm	۱/۸۶	۰/۸۹۱	۰/۰۰۵	۵۰	pureline	tansig	۸	می		
Lm	۰/۸۱	۰/۷۵۴	۰/۰۰۵	۷۰	pureline	tansig	۸	ژوئن		
Lm	۱/۳۱	۰/۸۱۳	۰/۰۰۵	۴۰	pureline	tansig	۹	ژوئیه		
Lm	۰/۶۳	۰/۸۳۹	۰/۰۰۵	۷۰	pureline	tansig	۷	اوت		
Lm	۱/۳	۰/۸۱۱	۰/۰۰۵	۱۰	pureline	tansig	۵	سپتامبر		
Lm	۰/۵	۰/۹۷۱	۰/۰۰۵	۸۰	pureline	tansig	۳	اکتبر		
Lm	۳/۰۸	۰/۹۵۶	۰/۰۰۵	۵۰	pureline	tansig	۷	نوامبر		
Lm	۱/۳۲	۰/۸۲۷	۰/۰۰۵	۵۰	pureline	tansig	۳-۳	دسامبر		



شکل ۲: ضریب همبستگی در مرحله آموزش با الگوریتم LM در ماه فوریه (ماخذ: نگارندگان)

انتخاب مناسبترین تعداد نرون‌ها و لایه‌های پنهان


در انتخاب مناسبترین تعداد نرون، معمولاً تعداد نرون‌های پنهان با یک نرون در لایه پنهان شروع شده و تا حد اکثر تعداد نرون (۱۲ نرون) ادامه می‌یابد. الگوریتم مارکوارت-لونبرگ به دلیل سرعت بالای همگرایی، نسبت به دیگر الگوریتم‌ها به تعداد نرون‌های کمتری نیاز دارد. تعداد نرون‌های مورد نیاز با افزایش اطلاعات ورودی به شبکه و یادگیری روابط ورودی و خروجی به صورت ساختار ساده‌تر، کاهش می‌یابد. در شبکه‌های مورد بررسی در این مطالعه، بیشترین تعداد نرون متعلق به ماه فوریه (با ۱۱ نرون در لایه پنهان) و کمترین آن (با ۳ نرون) متعلق به ماه اکتبر است (جدول ۲). در صورت وجود شبکه ساده‌تر با عملکرد مناسب، به کارگیری شبکه‌های بزرگ‌تر ضرورتی ندارد. در نیاز به لایه پنهان، اغلب شبکه‌ها (به غیر از ماه‌های ژانویه و دسامبر)، با یک لایه پنهان عملکرد مناسبی از خود نشان دادند، لذا لایه پنهان را افزایش ندادیم، ولی در ماه‌های ژانویه و دسامبر، به دلیل نوسان‌ها زیاد دمای حد اکثر، عملکرد شبکه با یک لایه پنهان و با حد اکثر تعداد نرون، مناسب نبود، لذا لایه پنهان تا دو لایه افزایش یافت.

انتخاب مناسبترین تعداد تکرار، خطای هدف و نوع تابع محرک

تعداد اولیه تکرارهای آموزشی شبکه برای هر ماه برای الگوریتم مارکوارت-لونبرگ با مقدار اولیه خطای هدف برابر با 0.005° ابتدا از ۱۰ تکرار برای هر نرون در لایه پنهان شروع شد و تا حداکثر تعداد تکرار (۱۳۰ تکرار) ادامه یافت. مقادیر مختلف تکرار با ثابت نگه داشتن مقدار خطای هدف، بررسی و کنترل گردید. به منظور مشخص شدن تعداد تکرار بهینه و نیز برای اینکه الگوریتم‌ها زمان بیشتری برای آموزش در اختیار داشته باشند و کاملاً آموزش بیینند، تعداد تکرارهای بالاتر از ۱۳۰ نیز بعض‌انتخاب گردید. در صورتی که شبکه‌ای در هر تکرار (حداکثر تا ۱۳۰) به بالاترین ضرایب همبستگی در مرحله آموزش و خطای زیر ۵ درصد دست می‌یافتد، به عنوان تکرار بهینه برای آن شبکه انتخاب می‌گردید. ماههای فوریه و مارس با ۱۰ و ۱۲۰ تکرار به ترتیب کمترین و بیشترین تکرار را داشتند. به عبارت دیگر، در این تعداد تکرار، شبکه به هدف مورد نظر دست یافته است (جدول ۲). پس از تعیین نوع الگوریتم، تعداد نرون‌پنهان و تعداد تکرار بهینه، شبکه با مقدار خطای 0.0001° (دقیق اندازه‌گیری داهها) آزمون گردید. از آنجایی که اغلب شبکه‌ها با الگوریتم مارکوارت-لونبرگ و با خطای 0.005° عملکرد مناسب‌تری داشتند، این مقدار به عنوان مقدار بهینه خطای هدف انتخاب شد. عدد 0.005° به عنوان مقدار خطای هدف در صورتی انتخاب شد که شبکه با مقادیر 0.009° و 0.008° در تکرارهای مختلف، قبلاً به عنوان مقادیر خطای هدف مورد کنترل قرار گرفته بود، ولی مقدار 0.005° عملکرد بهتری نسبت به دو خطای دیگر داشت.

پس از تعیین مقادیر بهینه نرون‌ها و لایه‌های پنهان، تعداد تکرار و خطای هدف، شبکه با تابع لگاریتم سیگموئیدی سنجیده شد و تانژانت سیگموئیدی نسبت به آن عملکرد بهتری نشان داد؛ لذا در برآورد دمای حداکثر در لایه پنهان و لایه خروجی، تابع محرک تانژانت سیگموئید و تابع محرک خطی بهتر از سایر توابع ارزیابی شدند. در جدول شماره ۲، تعداد نرون در لایه پنهان، تابع محرک لایه پنهان، تابع محرک لایه خروجی، تعداد تکرار، هدف عملکرد، ضریب همبستگی (R)، میانگین خطاب بر حسب درصد و الگوریتم

یادگیری برای ۱۲ پارامتر آموزشی (۱۲ شبکه یا ماه) ارائه شده است. با نگاهی اجمالی به جدول مذکور می‌توان دریافت که آموزش و آزمون شبکه‌ها تا حد بسیار زیادی قابل قبول است. شکل شماره ۳ ساختار بهترین شبکه پرسپترون چندلایه ماه اکتبر در منطقه مورد مطالعه را نشان می‌دهد. بهترین ساختار شبکه‌های طراحی شده مربوط به این ماه با یک لایه پنهان، کمترین تعداد نرون در لایه مخفی (۳ نرون) و پایین‌ترین خطای (۰/۵) در مرحله آزمون است.



شکل ۳: ساختار بهترین شبکه پرسپترون چندلایه (ماه اکتبر) (ماخذ: نگارنده‌گان)

در جدول شماره ۳، میزان خطای (%) در ۱۲ شبکه عصبی مصنوعی (۱۲ ماه) آمده است. حداقل و حداکثر خطای به ترتیب مربوط به ماه آوریل با ۲۰۰۴ با ۰/۱ درصد تقریباً بدون خطای ماه ژانویه ۲۰۰۶ با ۵/۶۹ درصد است. بهترین و ضعیف‌ترین شبکه‌ها، مربوط به ماه اکتبر با میانگین ۰/۵ درصد و ماه ژانویه با ۴/۶۴ درصد و کمترین میانگین سالانه خطای مربوط به سال ۲۰۰۴ با ۱/۴۸ درصد خطای میانگین کل خطای شبکه‌ها برابر با


پیش‌بینی دماهای حداکثر با استفاده از مدل شبکه عصبی مصنوعی ۷۳

۱/۶۸ درصد است. بر این اساس، شبکه‌های طراحی شده قادر بودند دما را با حداکثر اختلاف ۰/۸۳ درجه سانتیگراد با داده واقعی پیش‌بینی کنند، به عبارت دیگر، شبکه‌های طراحی شده می‌توانند دمای واقعی را حتی با کمتر از ۱ درجه سانتیگراد اختلاف برآورد کنند (اختلاف بین دمای حداکثر واقعی و برآورده شده)؛ به طوری که میزان همبستگی دماهای حداکثر برآورده شده و واقعی به ۰/۹۹ رسیده که با دماهای حداکثر برآورده شده به وسیله مدل شبکه‌های عصبی مصنوعی در سطح یک درصد معنی‌دار شدند (اشکال ۴ و ۵). همان‌طور که مشاهده می‌شود، دمای حداکثر برآورده شده به وسیله مدل به حدی به دمای حداکثر واقعی نزدیک است که دمای واقعی و برآورده شده در بیشتر موارد بر هم منطبق‌اند.


جدول ۳ : میزان خطأ بر حسب درصد در شبکه‌های عصبی مصنوعی

سال	ماه	میانگین خطای هر شبکه		
		۲۰۰۶	۲۰۰۵	۲۰۰۴
۰/۶۸	ژانویه	۵/۶۹	۴/۱۶	۴/۰۸
۱/۳۸	فوریه	۰/۳۹	۲/۱۲	۱/۶۳
۱/۸۱	مارس	۲/۹۲	۱/۰۷	۱/۴۳
۱/۴۸	آوریل	۴/۲۷	۰/۱۸	۰/۰۱
۱/۸۶	می	۱/۰۸	۲/۷۸	۱/۷۲
۰/۸۱	ژوئن	۰/۱۵	۱/۱۲	۱/۱۶
۱/۳۱	ژوئیه	۰/۴	۳/۱۵	۰/۴
۰/۶۳	اوت	۰/۱۸	۰/۱۶	۱/۵۴
۱/۳	سپتامبر	۲/۴۳	۱/۲۸	۰/۱۹
۰/۵	اکتبر	۰/۹۷	۰/۳۹	۰/۱۳
۳/۰۸	نوامبر	۲/۹۹	۳/۲۲	۳/۰۲
۱/۳۲	دسامبر	۰/۵۱	۱/۰۴	۲/۴۱
۱/۶۸	میانگین خطأ	۱/۸۳	۱/۷۲	۱/۴۸

(مأخذ: نگارنده‌گان)



شکل ۴: نتایج مرحله آزمون در مدل شبکه عصبی (ماخذ: نگارنده گان)



شکل ۵: معادله رگرسیونی بین دماهی حداقل واقعی و برآورده شده با مدل شبکه عصبی مصنوعی
(ماخذ: نگارنده گان)

ارزیابی عملکرد شبکه (جدول ۴) نیز نشان داد که مجدد میانگین مربعات خطأ، میانگین مربعات خطأ، میانگین مطلق خطأ و میانگین درصد خطای به ترتیب برابر با 0.05 ، 0.09 و 0.22 و 0.68 است. این مقادیر هرچه به صفر نزدیکتر باشند، نشان‌دهنده عملکرد بهتر شبکه است. ضریب تعیین و همبستگی شبکه نیز برابر با 0.99 و 0.99 است که ضریب همبستگی در سطح یک درصد معنی‌دار شده است و با توجه به اینکه دیگر معیارهای ارزیابی شبکه نیز در حد قابل قبول بودند و دمای حداکثر برآورده شده به مقادیر واقعی نزدیک است (شکل ۴)، می‌توان اظهار داشت که شبکه طراحی شده دارای عملکرد بسیار خوبی است.

جدول ۴ : ارزیابی عملکرد شبکه عصبی مصنوعی

R	R ²	Error	MAE	MSE	RMSE	مدل
						شبکه عصبی مصنوعی
0.99	0.99	0.68	0.22	0.09	0.05	(مأخذ: نگارنده‌گان)

نتیجه‌گیری

برآورد دما به عنوان یکی از عناصر مهم اقلیمی که پدیده‌ای غیر خطی و متغیر با زمان و مکان است و عوامل اقلیمی و جغرافیایی زیادی در آن مؤثرند دارای اهمیت فراوان است. در پژوهش حاضر، برای پیش‌بینی دماهای حداکثر شهرستان اردبیل، یک مدل شبکه عصبی مصنوعی ارزیابی و بررسی گردید. بررسی تأثیر استفاده از متغیرهای اقلیمی به ورودی مدل نشان داد که مدلی با ۵ متغیر شامل میانگین رطوبت نسبی، میانگین سرعت باد، مجموع ساعات آفتابی، میانگین حداقل و حداکثر دمای ماهانه، دقیق‌ترین مدل است، چرا که با خطای کمتر از ۵ درصد و همبستگی بالا، دمای حداکثر را برآورد کردند. آزمون تعداد نمونه‌ای مختلف در لایه پنهان نیز نشان داد که مدل با سه نمون و

تابع محرك تانزانت سیگموئیدی در لایه پنهان و ۸۰ تکرار بیشترین دقت را دارد. بنابراین بهترین مدل شبکه عصبی مصنوعی در این بررسی یک مدل پرسپترون^۳ لایه با ۵ نرون در لایه ورودی، ۳ نرون در لایه پنهان، یک نرون در لایه خروجی و الگوریتم آموزشی مارکوارت-لونبرگ است (شکل ۳) و این مدل برای پیش‌بینی دماهای حداکثر شهرستان اردبیل پیشنهاد می‌گردد. نتایج تحقیق و ارزیابی مدل نشان می‌دهند که در پیش‌بینی دماهای حداکثر، استفاده از روش شبکه‌های عصبی مصنوعی با توجه به تعیین خطای آموزشی می‌تواند مورد توجه و استفاده قرار گیرد. در آینده، با افزایش داده‌های اقلیمی در دسترس، دقت این روش نیز افزایش خواهد یافت و امکان پیش‌بینی‌ها در بازه‌های زمانی دیگر نیز فراهم خواهد گردید. از نتایج پیش‌بینی دماهای حداکثر می‌توان در برنامه‌ریزی‌های محیطی نظیر کنترل بیماری‌ها و آفات، مدیریت بهینه منابع آب، مطالعات زیست محیطی و غیره استفاده نمود.

پیشنهادها

از آنجا که در این پژوهش با استفاده از ۵ متغیر ورودی، هدف مورد نظر (خطای کمتر از ۵ درصد) حاصل شد، با توجه به نقش مهم داده‌های ورودی در مدل شبکه‌های عصبی پیشنهاد می‌گردد برای دستیابی به دقت و عملکرد بهتر شبکه، تأثیر پارامترهایی مثل میانگین دما، بارش، ابرناکی آسمان، ارتفاع از سطح دریا و دیگر پارامترهای مؤثر بر دما را در نظر گرفت و دقت مدل را بالاتر برد و این مدل را با دیگر مدل‌های رگرسیونی و سری زمانی نیز مقایسه کرد. همچنین پیشنهاد می‌شود دیگر پارامترهای اقلیمی نیز برای اثبات توانایی این مدل‌ها در پیش‌بینی‌های اقلیمی با استفاده از این مدل بررسی شوند. نیز با توجه به گسترش مدل‌های جدیدی همچون تئوری موجک و یا شبکه‌های عصبی-موجکی، ترکیب سری‌های زمانی و شبکه عصبی به عنوان ابتکاری جدید در زمینه اقلیم شناسی، می‌تواند بررسی شود.

منابع

- ۱- احمدی، اسماعیل. (۱۳۸۲). «طبقه‌بندی تغییرات بارش بوشهر با استفاده از شبکه‌های عصبی مصنوعی مبتنی بر مدل خودسازمانده کوهون». استاد راهنمای، علیجانی، بهلوان. دانشگاه تربیت معلم تهران، گروه جغرافیای طبیعی.
- ۲- اصغری مقدم، اصغر؛ نورانی، وحید؛ ندیری، عطالله. (۱۳۸۷). «مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی»، مجله دانش کشاورزی، جلد ۱۸، شماره ۱، دانشگاه تبریز، صص ۱۵-۱.
- ۳- تشنه‌لب، محمد؛ اخوان‌ذکری، مجید؛ ثانی، بهرام. (۱۳۷۷). «کاربرد شبکه‌های عصبی در پیش‌بینی هوا، ششمین کنفرانس مهندسی برق ایران، دانشگاه خواجه نصیرالدین طوسی»، صص ۹-۱۴.
- ۴- تشنه‌لب، محمد؛ منشی، مهدی. (۱۳۸۲). «پیش‌بینی پارامترهای هواشناسی با استفاده از شبکه عصبی- فازی براساس آموزش پارامترهای بخش تعالی، سومین کنفرانس منطقه‌ای و اولین کنفرانس تغییر اقلیم، دانشگاه اصفهان، ص ۸۰.
- ۵- حسینی، سید اسد. (۱۳۸۸). «برآورد و تحلیل دماهای حداکثر شهرستان اردبیل با استفاده از مدل تغوری شبکه‌های عصبی مصنوعی»، استاد راهنمای، صلاحی، برومند، دانشگاه محقق اردبیلی، گروه جغرافیای طبیعی.
- ۶- خلیلی، نجمه؛ خداشناس، سعیدرضا؛ داوری، کامران. (۱۳۸۵). «پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی»، مجموعه مقالات دومین کنفرانس مدیریت منابع آب، دانشگاه صنعتی اصفهان.
- ۷- خوشحال دستجردی، جواد؛ قویدل‌رجیمی، یوسف. (۱۳۸۷). «بررسی رابطه تغییرات بارش سالیانه تبریز با ناهنجاری- های دمایی کره زمین و شبیه سازی عددی آن با استفاده از شبکه عصبی مصنوعی»، فصلنامه مدرس علوم انسانی، شماره ۲، صص ۵۱-۲۹.
- ۸- رحمانی، امیر مسعود؛ تشنه‌لب، محمد. (۱۳۸۴). «پیش‌بینی دمای روزانه هوا با استفاده از شبکه عصبی». مجله بین‌المللی علوم مهندسی (انگلیسی)، جلد ۱۶، شماره ۳، دانشگاه علم و صنعت ایران، صص ۱-۸.
- ۹- رحیمی خوب، علی؛ بهبهانی، محمدرضا؛ نظری فر، محمد‌هادی. (۱۳۸۶). «پیش‌بینی دمای هوای استان خوزستان بر اساس داده‌های ماهواره نوا و مدل شبکه عصبی»، مجله علوم و فنون کشاورزی و منابع طبیعی، جلد ۱۱، شماره ۴۲(ب)، دانشگاه صنعتی اصفهان، صص ۳۶۴-۳۵۷.
- ۱۰- سهیلی‌خواه، سعید؛ تشنه‌لب، محمد. (۱۳۸۳). «پیش‌بینی حداکثر دمای روزانه با استفاده از یک ساختار نوین پویای شبکه عصبی - فازی»، مجموعه مقالات ششمین کنفرانس سیستم‌های هوشمند، دانشگاه شهید باهنر کرمان، صص ۱۵۳-۱۴۷.
- ۱۱- علیجانی، بهلوان؛ قویدل‌رجیمی، یوسف. (۱۳۸۴). «مقایسه و پیش‌بینی تغییرات دمای سالانه تبریز با ناهنجاری‌های دمایی کره زمین با استفاده از روش‌های رگرسیون خطی و شبکه‌های عصبی مصنوعی»، مجله جغرافیا و توسعه، شماره ۶، صص ۳۸-۲۱.
- ۱۲- علیاری‌شوره‌دلی، مهدی؛ تشنه‌لب، محمد؛ خاکی‌صدیق، علی. (۱۳۸۳). «پیش‌بینی کوتاه مدت آلودگی هوا با کمک شبکه‌های عصبی پرسپترون چندلایه و خط حافظه‌دار تأخیر»، مجموعه مقالات ششمین کنفرانس سیستم‌های هوشمند، دانشگاه شهید باهنر کرمان، صص ۱۴۶-۱۳۹.

۱۳- کارآموز، محمد؛ رمضانی، فرید؛ رضوی، سامان. (۱۳۸۵). «پیش‌بینی بلند مدت بارش با استفاده از سیگنال‌های هواشناسی: کاربرد شبکه‌های عصبی مصنوعی»، هفتمین کنگره بین‌المللی مهندسی عمران، دانشگاه تربیت مدرس تهران.

۱۴- معاونت برنامه‌ریزی و نظارت راهبردی مرکز آمار ایران. (۱۳۸۵). نتایج کلی سرشماری عمومی نفوس و مسکن، ص ۲۴۹.

۱۵- منهاج، محمد باقر. (۱۳۸۴). مبانی شبکه‌های عصبی (هوش محاسباتی)، جلد ۱، چاپ سوم، مرکز نشر دانشگاه صنعتی امیرکبیر، ص ۷۱۲.

۱۶- نیرومند، حسینعلی؛ بزرگنیا، ابولقasm. (۱۳۷۲). ترجمه مقدمه‌ای بر تحلیل سری‌های زمانی، چاپ اول، انتشارات دانشگاه فردوسی مشهد، ص ۲۸۳.

- 17- Cadenas, E., Rivera, V. 2009. Short term wind speed forecasting in La Venta, Oaxaca, Me'xico, using artificial neural networks. *Renewable Energy* 34:pp 274–278.
- 18- Conrads, P.A., Roehle, E. A., 1999. Comparing Physics- Based and Neural Network Mo Simulating Salinity, Temperature and Dissolved in a Complex, Tidally Affected River Basin, Proceeding of the South Carolina Environmental Conference, pp 1-15.
- 19- Coulibaly, P., Yoans, D., Francois, A. 2005. Downscaling precipitation and temperature with temporal neural networks. *Journal of hydrometeorology*, 6: pp483-496.
- 20- Demuth, H., Beale, M., 2000. *Neural Network Toolbox User's Guide*, Copyright 1992-2002, BT The Math Works, Inc, Version 4, 840P.
- 21- Eriksoon, M; Lindqvist, S; 2003. Regional influence on road slipperiness during winter precipitation events, *Physical geography, department of earth science, box 460, se 405*.
- 22- Fulop, I. A., Jozsa, J., Karamer, T., 1998. A neural network application in estimating wind induced shallow lake motion, *Hydro informatics* 98, 2, pp 753-757.
- 23- 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.
- 24- Keay, K; Simonda, I; 2005. The association of rain fall and other weather variables with road traffic volume in Melbourne, Australia, *Accident analysis and prevention*, 37, pp109-127
- 25- Ranjithan, J., Eheart, J., Garrett, J. H., 1995. Application of neural network in groundwater remediation under condition of uncertainty. *New Uncertainty concepts Hydrology and Water Resources*, pp133-140.
- 26-Rehman, S., Mohandes, M., 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity, *Energy Policy* 36, pp 571–576.
- 27-Sajikumar, N., Thandaveswara, B. S., 1999. Non Liner rainfall runoff Model using artificial neural network, *Journal of Hydrology*, 216, pp 32-35.
- 28- Senkal, O., Kuleli, T., 2009. Estimation of solar radiation over Turkey using artificial neural network and satellite data, *Applied Energy* 86, PP 1222–1228.