



بررسی تأثیر تعدیل دامنه تغییرات داده‌ها بر کارایی مدل شبکه عصبی مصنوعی و درخت تصمیم رگرسیونی در پیش‌بینی خشکسالی

۱. حبیبی پور^۱، م. ت. دستورانی^۲، م. ر. اختصاصی^۲ و ح. افخمی^۳

۱- کارشناس ارشد آبخیزداری دانشگاه یزد، نویسنده مسؤل: habibipoor_azam@yahoo.com

۲- دانشیار دانشکده منابع طبیعی دانشگاه یزد

۳- کارشناس ارشد آبخیزداری دانشگاه یزد

چکیده

خشکسالی یکی از اثرات تغییر سامانه اقلیمی است. پیش‌بینی خشکسالی نقش مهمی در اعمال روش‌های مؤثر مدیریت منابع آب ایفا می‌کند. روش‌های مختلفی برای مطالعه خشکسالی وجود دارد. روش تحلیل داده‌های بارندگی، جزء عمومی روش‌های تحلیل خشکسالی به شمار می‌رود. لذا پیش‌بینی دقیق و پیش از وقوع بارش می‌تواند شرایط را برای ارزیابی وضعیت خشکسالی فراهم نماید. هدف از این پژوهش، بررسی تأثیر پیش‌پردازش داده‌ها بر عملکرد دو مدل داده‌کاوی در پیش‌بینی خشکسالی در ایستگاه سینوپتیک یزد می‌باشد. در این رابطه از دو روش شبکه عصبی مصنوعی و درخت تصمیم رگرسیونی که از انواع روش‌های داده‌کاوی محسوب می‌شود استفاده شد و شبیه‌سازی‌ها در دو حالت کلی صورت گرفت. در حالت اول، از مقادیر اصلی برخی پارامترهای اقلیمی استفاده و میزان بارش ۱۲ ماه پیش از وقوع پیش‌بینی گردید. در حالت دوم میانگین متحرک سه ساله همان داده‌ها به مدل معرفی و پیش‌بینی بر همین اساس انجام شد. در پایان برای ارزیابی دقت و درستی دو روش مورد استفاده، معیارهای آماری R ، $RMSE$ مورد استفاده قرار گرفت. یافته‌ها نشان داد که اعمال میانگین لغزان روی داده‌های اصلی به نحو چشمگیری در بهبود کارایی هر دو مدل مؤثر می‌باشد و در این شرایط هر دو روش درخت تصمیم رگرسیونی و شبکه عصبی مصنوعی در ایستگاه یزد قادرند با ضریب اطمینان بالایی میزان بارش را ۱۲ ماه پیش از وقوع برآورد نمایند.

واژه‌های کلیدی: پیش‌بینی، خشکسالی، شبکه عصبی مصنوعی، درخت تصمیم رگرسیونی، داده‌کاوی

مقدمه

تغییر اقلیم در سال ۲۰۰۱ گزارش داد که اقلیم در حال تغییر و گرمایش جهانی در حال وقوع است. توجه به تغییرات اقلیمی در سال‌های اخیر به علت نتایج اقتصادی، اجتماعی و

در دهه‌های اخیر تغییر سیستم اقلیمی زمین به ویژه گرمایش سیاره‌ای ناشی از مصرف سوخت‌های فسیلی به طور گسترده‌ای مورد توجه قرار گرفته است. هیئت بین‌الدول

آسیب‌های مالی مربوط به رویدادهای جوی اهمیت زیادی پیدا کرده است. یکی از اثرات تغییر سیستم اقلیمی کره زمین بروز خشکسالی در بسیاری از نقاط کره زمین و یا تشدید سیل و سیل‌گیری در نقاط دیگر است که برخلاف سایر بلایای طبیعی همانند طوفان، آتشفشان، زمین‌لرزه، سونامی و غیره به آرامی آغاز و به طور خزنده‌ای گسترش می‌یابد و تقریباً در همه رژیم‌های اقلیمی دیده می‌شود (۱۴).

خشکسالی در زمینه‌های مختلف، هم به طور مستقیم و هم به طور غیر مستقیم اثرهای زیان‌آوری وارد می‌کند. با کم شدن بارندگی یا نبود آن برای یک مدت طولانی در سال (خشکسالی)، مراتع، جنگل‌ها، مزارع و باغ‌هایی که منبع آبی آن‌ها وابسته به ریزش‌های جوی است و نیز خاک و دیگر منابع طبیعی به طور مستقیم زیان می‌بینند. علاوه بر آن منابع آب‌های سطحی و زیرزمینی نیز از ریزش‌های جوی متأثر می‌گردند. به این ترتیب با وقوع خشکسالی، فعالیت‌ها و تأسیسات وابسته به آب، چه شهری و روستایی، چه صنعتی و غیره تحت تأثیر قرار گرفته و خسارت خواهند دید (۱۰).

از این رو پیش‌بینی خشکسالی می‌تواند در اعمال روش‌های مؤثر مدیریت منابع آب و تعدیل خسارات ناشی از خشکسالی مؤثر واقع شود. روش‌های مختلفی برای مطالعه خشکسالی وجود دارد. روش تحلیل داده‌های بارندگی، جزء عمومی روش‌های تحلیل خشکسالی به شمار می‌رود. علت این امر دسترسی

راحت‌تر و آسان‌تر به انواع داده‌های بارندگی در بخش‌های مختلف کره زمین است. از طرفی مقادیر بارندگی جزء بی‌ثبات‌ترین متغیرهای آب و هوایی مخصوصاً در مناطق خشک محسوب می‌شود و از این رو نمایه خوبی برای مطالعه خشکسالی می‌باشد (۴). این در حالی است که در سال‌های اخیر شاهد حرکتی مستمر، از تحقیقات صرفاً تئوری به پژوهش‌های کاربردی به خصوص در زمینه پردازش اطلاعات، برای مسائلی که برای آن‌ها راه‌حلی موجود نیست و یا به راحتی قابل حل نیستند، بوده ایم (۱). این موضوع تحت عنوان کشف دانش و داده کاوی تعبیر شده است. داده کاوی یک حوزه میان‌رشته‌ای و با رشد سریع است که حوزه‌های مختلفی همچون پایگاه داده، آمار، یادگیری ماشین و سایر زمینه‌های مرتبط را تلفیق کرده است تا اطلاعات و دانش ارزشمند نهفته در حجم بزرگی از داده‌ها را استخراج نماید (۱۱).

امروزه حجم زیادی از داده‌ها توسط سازمان‌ها و ارگان‌های متولی امر در مقیاس‌های زمانی مختلف ثبت می‌گردد. نظر به گسترش سیستم پایگاه داده و ایجاد ابزارهای متعدد برای ذخیره حجم بالایی از داده‌ها، داده کاوی به عنوان یکی از شاخه‌های علوم بین رشته‌ای توسعه روزافزونی یافته است. داده کاوی به جستجو و کشف مدل‌های گوناگون، چکیده‌سازی و اخذ مقادیر از مجموعه‌ای از داده‌های معلوم اطلاق می‌گردد

(۹). دسته بندی و پیش بینی دو نوع عملیات داده کاوی برای تحلیل داده ها و استخراج مدل به منظور توصیف دسته های مهم داده ها، فهم و پیش بینی رفتار آن ها در آینده است. مدل های دسته ای در تحلیل داده های گسسته و طبقه ای به کار رفته و مدل های پیش بینی یا رگرسیون بیشتر روی داده های پیوسته کار می کنند (۱۱). تحقیقات متعددی روی کارایی روش های داده کاوی در مطالعات مربوط به منابع آب صورت گرفته، که به تعدادی از آنها اشاره می شود.

میشرا و دسای (۱۲) با استفاده از مدل های آماری به پیش بینی خشکسالی در حوزه کانسباتی هند پرداختند و سپس در سال ۲۰۰۶ کارایی روش های آماری و شبکه های عصبی مصنوعی در پیش بینی خشکسالی را با هم مقایسه نمودند که نتایج نشان دهنده برتری شبکه های عصبی مصنوعی نسبت به روش های آماری بود. در تحقیق دیگری که در همین سال توسط نامبردگان انجام گرفت پیش بینی خشکسالی با استفاده از سه روش آماری، شبکه عصبی مصنوعی و مدل های درآمیخته (هیبریدی) با هم مقایسه شد که مدل های هیبرید نتایج برتری نسبت به دو روش دیگر داشت. مرید و همکاران (۱۳) با به کارگیری شبکه های عصبی و استفاده از برخی شاخص های خشکسالی به پیش بینی خشکسالی در استان تهران پرداختند که در نهایت نمایه خشکسالی

مؤثر در پیش بینی خشکسالی نسبت به سایر روش ها مؤثرتر واقع شد.

فاتحی مرج و همکاران (۶) با به کارگیری مدل شبکه عصبی مصنوعی و استفاده از شاخص های SOI و ۴، ۳ NINO به پیش بینی خشکسالی پاییزه یک فصل زودتر از وقوع پرداختند. آنها داده های نام برده را از ایستگاه ارومیه واقع در حوزه دریاچه ارومیه مورد استفاده قرار دادند و سپس نتایج حاصل از آن را با مدل رگرسیون چند متغیره، مقایسه کردند. آنها بدینوسیله موفق به بررسی روند تغییرات بارش شدند (۶).

سلسو آگستو و همکاران (۴) پیش بینی خشکسالی را با استفاده از شبکه های عصبی مصنوعی پیش تغذیه برای سه ناحیه همگن بارش در رودخانه سانفرانسیسکو برزیل انجام داد. در این مطالعه از داده های ۲۴۸ ایستگاه بارندگی استفاده شد. نتایج بدست آمده نشان داد که شبکه های عصبی مصنوعی روشی مناسب برای انواع پیش بینی هاست و زمانی که از شاخص بارش استاندارد جهت پیش بینی ها انجام می شود نتایج بهبود بخشیده می شود و در نهایت نتایج نهایی تحت تأثیر زون های مختلف هیدرولوژیکی نمی باشد.

افخمی و همکاران (۲) در تحقیقی با عنوان «بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه عصبی مصنوعی در پیش بینی خشکسالی منطقه یزد» نقش تعداد و نوع

مدل ها بارش نرمال ماهیانه به عنوان ورودی به شبکه معرفی شد و بارش ماهیانه یک سال آینده پیش بینی شد. لازم به ذکر است در این تحقیق از الگوریتم آموزشی موسوم به قانون یادگیری ممنتم استفاده شد. بعد از بررسی مدل های نامبرده، دو شبکه TLRN و RN مورد استفاده قرار گرفت که در نهایت شبکه TLRN بهترین کارایی را در پیش بینی خشکسالی از خود نشان داد. بهترین تابع فعال تابع تانژانت هایپربولیک تشخیص داده شد. از بین عناصر دینامیک در شبکه ها نوع لاگور (Laguarre) و تأخیر زمانی (TDNN) سازگاری بهتری را از خود نشان دادند.

لازم به ذکر است هدف از این تحقیق بررسی کارایی دو روش داده کاوی (شبکه عصبی مصنوعی و درخت تصمیم) در پیش بینی بارش در حالت استفاده از داده های اصلی و مقایسه آن با کارکرد مدل در شرایط استفاده از میانگین متحرک سه ساله می باشد. در این حالت میتوان به بررسی تأثیر عملیات پردازشی بر کارایی مدل درخت تصمیم و شبکه عصبی مصنوعی در پیش بینی میزان بارش و در نهایت رخداد خشکسالی پرداخت.

مواد و روش ها

معرفی روش مورد استفاده

در این تحقیق از دو روش شبکه عصبی مصنوعی و درخت تصمیم رگرسیونی استفاده شد، که در زیر به تشریح کلی آنها پرداخته می شود:

عوامل اقلیمی را در دقت پیش بینی خشکسالی با شبکه های عصبی مصنوعی مورد ارزیابی قرار دادند. حبیبی پور (۷) با استفاده از آمار ایستگاه سینوپتیک یزد (در دوره آماری ۱۳۸۴ - ۱۳۳۲) به بررسی کارایی درخت تصمیم در پیش بینی خشکسالی پرداخت. سپس برای بررسی کارایی الگوریتم درخت تصمیم در پیش بینی خشکسالی، مدل در چهار حالت استفاده از داده های خام، استفاده از داده های نرمال، استفاده از میانگین متحرک سه ساله و استفاده از میانگین متحرک پنج ساله اجراگردید. نتایج این تحقیق نشان داد که درخت تصمیم رگرسیونی با دقت قابل قبولی قادر به پیش بینی میانگین متحرک بارش (سه ساله و پنج ساله) می باشد (۷).

جی لون چیانگ و چیانگ وی (۵) پیش بینی خشکسالی مخزن را با استفاده از شبکه های عصبی مصنوعی انجام داد. در این مطالعه متغیر های مربوط به خشکسالی مخزن از جمله مخزن ذخیره و جریانات زیرقشری استفاده شد. جهت آنالیز و مقایسه نتایج خشکسالی مخزن از احتمال ماکزیمم و روش بیضی به کار گرفته شد. نتایج خروجی، عملکرد بهتر شبکه عصبی را نسبت به روش های دیگر نشان داد. به طوری که استفاده از شبکه عصبی مصنوعی اطلاعات مفیدی را جهت مدیریت و اداره مخازن فراهم می آورد. جهت انجام این تحقیق ۷ مدل از شبکه های عصبی شامل ^۱MLP، ^۲GFF، ^۳MNN، ^۴PCA، ^۵RN، ^۶TLRN مورد استفاده قرار گرفت در تمام

1- Multi Layer Perspetron

2- Generalized Feed Forward

3- Modular Neural Network

4- Principal Component Analysis

5- Recurrent Network


6- Time Lag Recurrent Network

شبکه عصبی مصنوعی

ایده شبکه عصبی مصنوعی را می توان به صورت ذیل تشریح نمود:

- مجموعه ای از گره ها (واحدها یا نرون ها یا عناصر محاسباتی).
- هر گره ورودی و خروجی دارد.
- هر گره براساس تابعی خاص محاسبه ساده ای انجام می دهد.
- بین گره ها، اتصالات موزون وجود دارد.
- اتصالات براساس معماری شبکه مشخص می شوند.
- نتیجه یک شبکه تابعی بسیار پیچیده از ارتباطات موزون می باشد.
- روش شبکه عصبی یک روش نوین در

حل مسائل پیچیده ای می باشد که یا الگوریتم مشخص برای حل آنها وجود ندارد و یا از روش های متعارف دارای راه حلی بسیار طولانی و زمان بر هستند. این روش در سال های اخیر در مسائل مختلف منابع آب مورد استفاده قرار گرفته است و بیشترین کاربرد آن در مورد مسائلی بوده است که یک ارتباط غیرخطی میان پارامترهای معلوم و مجهول آن مسائل وجود دارد، زیرا یکی از قابلیت های مهم شبکه عصبی مصنوعی، درک رفتار غیرخطی یک سیستم می باشد (۸). شکل ۱ مدل مفهومی شبکه های عصبی مصنوعی را نشان می دهد.



شکل ۱- مدل مفهومی شبکه های عصبی مصنوعی.


ساختارهای مختلفی برای شبکه عصبی مصنوعی وجود دارد، که در این تحقیق دو ساختار از آنها شامل شبکه های عصبی مصنوعی برگشتی و شبکه های عصبی مصنوعی برگشتی با تأخیر زمانی مورد استفاده قرار گرفته است. این شبکه ها از نوع دینامیک هستند که دارای لایه هایی با اتصال برگشتی

محلی می باشند. از ویژگی های مهم این شبکه ها وجود یک حافظه^۱ بی نهایت عمیق است که بین لایه ورودی و میانی یا بین لایه میانی و خروجی و یا بین عوامل موجود در لایه میانی قرار گرفته است و قادر است روابط بین ورودی و خروجی ها را به صورت لحظه ای و آنی تخمین بزند. میزان نرون های لایه مخفی متناسب با $2n$

عصبی به تولید قانون می‌پردازد. یعنی درخت تصمیم‌گیری پیش‌بینی خود را در قالب یکسری قوانین توضیح می‌دهد (شکل ۲). در حالی که در شبکه‌های عصبی تنها پیش‌بینی بیان می‌شود و چگونگی آن در خود شبکه پنهان باقی می‌ماند. علاوه بر آن در درخت تصمیم‌گیری بر خلاف شبکه‌های عصبی، می‌توان از داده‌های غیر عددی نیز استفاده نمود.

طراحی شد که n متناسب با تعداد عوامل ورودی به مدل می‌باشد. همچنین از توابع تانژانت هایپربولیک و سیگموئید به عنوان توابع فعال در لایه میانی و خروجی استفاده شد. **درخت تصمیم^۱**

درخت تصمیم‌گیری یکی از روشهای داده‌کاوی و از ابزارهای قوی و متداول برای دسته‌بندی و پیش‌بینی می‌باشد که برخلاف شبکه‌های



شکل ۲- نمونه‌ای از یک درخت تصمیم ساده.

$SS(t)$: مجموع مربعات خطا
 N_t : تعداد سنج‌ها (داده‌ها) در گره برگ t .
 $y_i(t)$: مقدار خروجی (متغیر هدف در هر گره برگ).
 $\bar{y}(t)$: میانگین مقادیر متغیر هدف برای همه گره‌ها.

حال متغیر ورودی S زمانی بهترین متغیر برای ایجاد شاخه در گره t می‌باشد که مقدار $Q(s,t)$ را بیشینه نماید.
 رابطه (۲) $Q(s,t) = SS(t) - SS(t_R) - SS(t_L)$ که در آن $SS(t_R)$ و $SS(t_L)$ به ترتیب میزان $SS(t)$ در شاخه سمت راست و سمت چپ گره t می‌باشد.

آماده سازی داده‌ها

ساختار این درخت بر سه اصل استوار است:
 ۱- تعیین مجموعه‌ای از پرسش‌ها به شکل $x \leq d$? که در آن x یک متغیر مستقل و d یک مقدار ثابت است و جواب هر پرسش آری/نه است.

۲- بهترین معیار شکاف برای انتخاب بهترین متغیر مستقل برای شکاف.

۳- ایجاد آمار خلاصه برای گره پایانی (۳).
 معیار مورد استفاده در درختان تصمیم رگرسیونی، کمترین انحراف مربعات (LSD)^۲ نام دارد. این معیار براساس کمیت خطا که به صورت زیر محاسبه می‌شود، مورد ارزیابی قرار می‌گیرد:

$$\text{رابطه (۱)} \quad SS(t) = \sum_{i=1}^{N_t} (y_i(t) - \bar{y}(t))^2$$

در این تحقیق از آمار ایستگاه همدیدی یزد برای بازه زمانی ۱۳۸۴-۱۳۳۲ استفاده شد. این ایستگاه در شهرستان یزد واقع است و از سال ۱۳۴۰ شروع به کار نموده و در ارتفاع ۱۲۳۰ متری از سطح دریا و طول جغرافیایی ۵۴° ۱۷' و عرض جغرافیایی ۵۳° ۳۱' قرار دارد. این ایستگاه با بالغ بر ۵۰ سال آمار، دارای بلندترین طول دوره آماری در بین ایستگاه‌های استان یزد می‌باشد.

در ابتدا آمار و اطلاعات مربوط به ایستگاه اخذ و از طریق آزمون توالی، همگنی داده‌ها بررسی شد. سپس ۱۲ ایستگاه هواشناسی استان که ضریب همبستگی پارامتر بارش آن‌ها با ایستگاه یزد در سطح ۱ درصد معنی دار بود شناسایی گردید. این ایستگاه‌ها عبارتند از: ابرکوه، اردکان، خرانق، مزرعه‌نو عقدا، ساغند، حاج‌آباد زرین، قطروم، باجگان، پاچنار تفت، نصرآباد، یزد و خوی‌دک. با استفاده از روش

نسبت نرمال و از طریق آمار و اطلاعات این ایستگاه‌ها، بازسازی کمبودهای آماری ایستگاه یزد انجام گردید. پس از آن، داده‌ها به نسبت ۷۰ به ۳۰ به دو دسته آموزش و آزمون تقسیم شدند. انتخاب داده‌های آموزش و آزمون به صورت سیستماتیک انجام شد ضمن اینکه هیچ یک از داده‌های آزمون در مرحله آموزش مورد استفاده قرار نگرفتند.

در دو مدل درخت تصمیم و شبکه عصبی مصنوعی، از پارامترهای بارش، میانگین دما، دمای بیشینه، رطوبت نسبی، سرعت باد و جهت باد به عنوان ورودی مدل استفاده و شبیه‌سازی‌ها برای پیش‌بینی بارش ۱۲ ماه قبل از وقوع صورت گرفت. متغیرهای مستقل مورد استفاده در این تحقیق و علائم اختصاری هر یک از این متغیرها در جدول ۱ نمایش داده شده است.

جدول ۱- معرفی پارامترهای ورودی مدل (ایستگاه یزد- دوره آماری ۱۳۳۲ لغایت ۱۳۸۴)

میانگین	حداقل	حداکثر	پارامتر ورودی	علامت اختصاری
۴/۴۷	۰	۷۰	بارش (میلیمتر)	P
۲۰/۱۸	-۰/۸	۳۵/۵	دمای متوسط (درجه سانتیگراد)	T _{mean}
۲۷/۲۵	۵/۸	۴۲/۶	دمای ماکزیمم (درجه سانتیگراد)	T _{max}
۲۲/۸۴	۸	۷۴	رطوبت نسبی (درصد)	H
۵/۷	۱/۶	۱۱/۱	سرعت شدید ترین باد (متر بر ثانیه)	W _s
۲۵۶/۶	۱۰	۳۶۰	جهت باد غالب (درجه)	W _d

اجرای مدل

در مجموع مدل شبکه عصبی مصنوعی و مدل درخت تصمیم در دو حالت کلی اجرا شد. در حالت اول از اصل داده‌ها استفاده شد، به عبارت دیگر روی داده‌ها هیچ گونه عملیات

پردازشی انجام نشد و ورودی‌ها و خروجی همان داده‌های خام بودند که به مدل معرفی شدند. در حالت دوم از میانگین لغزان سه ساله داده‌ها برای اجرای مدل استفاده گردید. استان یزد یک استان خشک می‌باشد که از

نتایج مدل درخت تصمیم در شرایط استفاده از اصل داده ها

در این حالت، مدل با ۶ متغیر مستقل شامل بارش، میانگین دما، دمای بیشینه، رطوبت نسبی، سرعت باد و جهت باد و ۶۲۰ سطر داده اجرا شد. لازم به ذکر است که از این تعداد ۴۳۴ سطر داده در مرحله آموزش و ۱۸۶ سطر داده در مرحله آزمون استفاده گردید. قوانین ایجاد شده در این حالت عبارتند از:

IF $T_{\max} \leq 26.2$ then $P\text{-lead12}=9.38$
 IF $T_{\max} > 26.2$ and $T_{\max} \leq 33.2$ and $W_d \leq 245$ then $p\text{-lead12}=10.06$
 IF $T_{\max} > 26.2$ and $T_{\max} \leq 33.2$ and $W_d > 245$ and $T_{\text{mean}} \leq 24.05$ and $p \leq 1.8$ then $p\text{-lead12}=0.523$
 IF $T_{\max} > 26.2$ and $T_{\max} \leq 33.2$ and $W_d > 245$ and $T_{\text{mean}} \leq 24.05$ and $p > 1.8$ then $p\text{-lead12}=3.29$
 IF $T_{\max} > 26.2$ and $T_{\max} \leq 33.2$ and $W_d > 245$ and $T_{\text{mean}} > 24.05$ then $p\text{-lead12}=4.59$
 IF $T_{\max} > 26.2$ and $T_{\max} > 33.2$ then $p\text{-lead12}=0.27$

قوانین ایجاد شده توسط مدل درخت تصمیم نشان می دهد که مدل درخت تصمیم در شرایط استفاده از اصل داده ها، از بین شش پارامتری که در اختیار داشته، تنها از پارامتر بارش، میانگین دما، دمای بیشینه و جهت باد برای پیش بینی استفاده کرده است. مقادیر خطا برای مدل درختی در این حالت محاسبه و نتایج آن در جدول ۲ ارائه شده است.

خصوصیات بارز آن نوسانات شدید بارش از یک سال به سال دیگر می باشد به گونه ای که داده های بارش از هیچ گونه روند منظمی برخوردار نمی باشند. از این رو پس از انجام چندین شبیه سازی برای بالا بردن ضریب کارایی در پیش بینی بارش، به جای اصل داده های ماهیانه از میانگین متحرک سه ساله آنها استفاده شد. به این ترتیب میانگین متحرک سه ساله برای کل پارامترهای ورودی مدل محاسبه شد و میانگین متحرک سه ساله بارش برای یک سال بعد پیش بینی گردید.

ارزیابی کارایی مدل

برای ارزیابی کارایی مدل های استفاده شده در این تحقیق از دو پارامتر آماری به شرح ذیل استفاده گردید:

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}} \quad \text{رابطه (۳)}$$

$$RMSE = \left(\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right)^{1/2} \quad \text{رابطه (۴)}$$


در این روابط O و P به ترتیب مقادیر مشاهده شده و شبیه سازی شده، $\bar{O}$ و $\bar{P}$ میانگین مقادیر مشاهده شده و شبیه سازی شده و n تعداد نمونه ها می باشد.

نتایج و بحث

جدول ۲- نتایج مدل درخت تصمیم رگرسیونی در حالت استفاده از اصل داده ها

رَدیف	متغیر مستقل	متغیر هدف	R	RMSE
حالت اول	$P-T_{\text{mean}}-T_{\max}-W_d$	P_1	۰/۵۳	۸/۲

نمودار نقطه ای و نمودار خطی مربوط به نتایج مدل درخت تصمیم و مقادیر واقعی



شکل ۳- نمودار تغییرات مقادیر پیش بینی شده بارش در مقابل مقادیر واقعی در شرایط استفاده از اصل داده ها- مدل درخت تصمیم رگرسیونی.

۱۷۹ سطر در مرحله آزمون استفاده گردید. قوانین درخت ایجاد شده در این حالت عبارتست از:

IF $p \leq 8.15$ and $p \leq 3.9$ and $T_{max} \leq 32.6$ and then P- lead12=2.6

IF $p \leq 8.15$ and $p \leq 3.9$ and $T_{max} > 32.6$ and $p \leq 1.3$ and $p \leq 0.3$ then P- lead12=0.06

IF $p \leq 8.15$ and $p \leq 3.9$ and $T_{max} > 32.6$ and $p \leq 1.3$ and $p > 0.3$ then P- lead12=0.06

IF $p \leq 8.15$ and $p \leq 3.9$ and $T_{max} > 32.6$ and $p > 1.3$ then P- lead12=1.6

IF $p \leq 8.15$ and $p > 3.9$ and $W_d \leq 261.7$ then P- lead12=7.4

IF $p \leq 8.15$ and $p > 3.9$ and $W_d > 261.7$ then P- lead12=5.1

IF $p > 8.15$ and $p \leq 2.19$ and $p \leq 15.07$ then P- lead12=10.5

IF $p > 8.15$ and $p \leq 2.19$ and $p > 15.07$ then P- lead12=15.4

IF $p > 8.15$ and $p > 2.19$ then P- lead12=23.9

در این حالت درخت سه پارامتر بارش، دمای ماکزیمم و جهت باد را در شبیه سازی

هر چند مدل درخت تصمیم از نظر آماری در حالت استفاده از اصل داده ها معنی دار بوده، ولی مشاهده می شود که مدل در این حالت در غالب دوره های زمانی ۱۲ ماهه پیش بینی های خود را در قالب دو مقدار عددی حداقل و حداکثر انجام داده است. به عبارتی درخت ایجاد شده با استفاده از اصل داده ها روند پیش بینی نسبتاً ثابتی داشته و نتوانسته تغییرات را به خوبی شبیه سازی نماید.

نتایج مدل درخت تصمیم در حالت استفاده

از میانگین متحرک سه ساله داده ها

در این حالت برای اجرای مدل، ۶ متغیر مستقل شامل میانگین متحرک سه ساله داده های بارش، دمای متوسط، دمای بیشینه، رطوبت نسبی، سرعت باد و جهت باد با ۵۹۶ سطر داده در اختیار سیستم قرار گرفت که از این تعداد ۴۱۷ سطر داده در مرحله آموزش و


لحاظ نموده است. علاوه بر آن قوانین ایجاد شده توسط درخت در حالت اول (استفاده از داده های اصلی) با حالت دوم (استفاده از میانگین متحرک سه ساله داده ها) متفاوت می باشد، که این موضوع حاکی از تأثیر تعدیل دامنه تغییرات داده های ورودی بر کارایی

مدل درخت تصمیم گیری می باشد. کارایی درخت تصمیم ایجاد شده در این حالت نیز با استفاده از دو پارامتر آماری R ، $RMSE$ بررسی شد که مقادیر مربوط به این پارامتر ها در جدول ۳ درج شده است.

جدول ۳- نتایج مدل درخت تصمیم رگرسیونی با استفاده از میانگین متحرک سه ساله داده ها

متغیر هدف (میانگین متحرک سه ساله)	متغیر مستقل (میانگین متحرک سه ساله)	ردیف	R	RMSE
P_3	$P - T_{max} - W_d$	حالت دوم	۰/۸۳	۳/۴۴

نمودار نقطه ای و نمودار خطی مربوط به نتایج مدل درختان تصمیم و مقادیر واقعی مربوط به حالت استفاده از میانگین متحرک سه ساله داده ها در شکل ۴ نمایش داده شده است.




شکل ۴- نمودار تغییرات مقادیر پیش بینی شده بارش در مقابل مقادیر واقعی با استفاده از میانگین متحرک سه ساله- مدل درخت تصمیم رگرسیونی.

در این تحقیق از دو ساختار شبکه عصبی شامل شبکه های عصبی مصنوعی برگشتی و شبکه های عصبی مصنوعی برگشتی با تأخیر زمانی استفاده شد. نتایج بهترین شبیه سازی های صورت گرفته با استفاده از شبکه عصبی مصنوعی در حالت استفاده از اصل داده ها در جدول ۴ آمده است.

بررسی ها نشان داد مدل درخت تصمیم در حالت استفاده از میانگین لغزان داده ها هم معنی دار می باشد. علاوه بر آن توانایی مدل در پیش بینی خشکسالی به میزان قابل توجهی افزایش یافته است (جداول ۲ و ۳). نتایج مدل شبکه عصبی مصنوعی در شرایط استفاده از اصل سنجها (داده ها)

جدول ۴- نتایج مدل شبکه عصبی مصنوعی در حالت استفاده از اصل داده ها

ردیف	نوع مدل	ترکیب ورودی	تابع لایه میانی	تابع لایه خروجی	Epoch	نوع خروجی (بارش ۱۲ ماه قبل از وقوع)	R	RMSE
۱	RN	P-T _{mean}	sigxon	tanhaxon	۲۵۰۰	P ₁	۰/۴۲	۸/۰۱
۲	RN	P-T _{mean} -H	sigxon	Tanhaxon	۲۵۰۰	P ₁	۰/۳۶	۱۱/۹۶
۳	RN	P-T _{mean} -W _s -W _d	sigxon	Tanhaxon	۱۰۰۰	P ₁	۰/۴۲	۸/۷۷
۴	RN	P-H-W _s -W _d	sigxon	Tanhaxon	۱۰۰۰	P ₁	۰/۴۴	۸/۷۷
۵	RN	P-T _{mean} -H-W _s -W _d	sigxon	Tanhaxon	۱۰۰۰	P ₁	۰/۴۰	۸/۱۱
۶	TLRN	P-T _{mean}	tanhaxon	Tanhaxon	۱۰۰۰	P ₁	۰/۶۴	۵/۴
۷	TLRN	P-T _{mean} -H	tanhaxon	Tanhaxon	۱۰۰۰	P ₁	۰/۴۵	۶/۳
۸	TLRN	P-T _{mean} -W _s -W _d	tanhaxon	Tanhaxon	۱۰۰۰	P ₁	۰/۵۸	۷/۵
۹	TLRN	P-H-W _s -W _d	tanhaxon	Tanhaxon	۱۰۰۰	P ₁	۰/۴۵	۷/۰۲
۱۰	TLRN	P-T _{mean} -H-W _s -W _d	tanhaxon	tanhaxon	۱۰۰۰	P ₁	۰/۵۱	۶/۴



شکل ۵- نمودار تغییرات پیش بینی شده بارش در مقابل مقادیر واقعی در شرایط استفاده از اصل داده ها، ترکیب بارش- دمای متوسط (مدل شبکه عصبی مصنوعی).


معنی داری مدل در این حالت از نظر آماری بررسی و نتایج حاکی از معنی دار بودن مدل می باشد. با توجه به نمودارهای ترسیم شده (اشکال ۳، ۴، ۵ و ۶)، می توان گفت در شبیه سازی های صورت گرفته، مدل در پیش بینی مقادیر کمینه از توانایی بیشتری برخوردار است. لذا با توجه به اینکه هدف، ارزیابی هر چه بهتر وضعیت خشکسالی در آینده از طریق مؤلفه بارندگی است، توانایی بیشتر دو مدل مورد استفاده در پیش بینی مقادیر کم بارش به نسبت مقادیر زیاد آن قابل تأمل، مورد نظر و مطلوب می باشد. بهترین

بررسی ها نشان داد که از نظر آماری مدل شبکه عصبی مصنوعی هم در شرایط استفاده از اصل داده ها معنی دار می باشد و بهترین نتیجه در شرایط استفاده از میانگین دما و بارش به عنوان ورودی مدل به دست آمد. نتایج مدل شبکه عصبی مصنوعی در شرایط استفاده از میانگین متحرک سه ساله داده ها نتایج بهترین شبیه سازی های صورت گرفته در این حالت در جدول ۵ آمده است. بهترین نتیجه در شرایطی حاصل شده که از بارش و دمای بیشینه به عنوان ورودی مدل استفاده شد.

نتایج حاصل از دو مدل مورد استفاده در جدول ۶ آمده است.

جدول ۵- نتایج مدل شبکه عصبی مصنوعی با استفاده از میانگین متحرک سه ساله داده ها

ردیف	نوع مدل	ترکیب ورودی (میانگین متحرک سه ساله)	تابع لایه میانی	تابع لایه خروجی	Epoch	نوع خروجی (میانگین متحرک سه ساله)	R	RMSE
۱	TLRN	$P-T_{mean}-H-W_s-W_d$	tanhaxon	tanhaxon	۲۳۰۰	P_3	۰/۸۴	۴/۹
۲	TLRN	P-H	tanhaxon	tanhaxon	۱۰۰۰۰	P_3	۰/۸۶	۵/۶
۳	TLRN	$P-T_{mean}-H-W_s$	tanhaxon	tanhaxon	۷۰۰۰	P_3	۰/۸۷	۵/۶
۴	TLRN	$P-H-W_s-W_d$	tanhaxon	tanhaxon	۳۰۰۰	P_3	۰/۸۸	۴/۹
۵	TLRN	$P-T_{max}-H-W_s$	tanhaxon	tanhaxon	۸۶۰	P_3	۰/۸۸	۵/۶
۶	TLRN	$P-T_{mean}-W_s-W_d$	tanhaxon	tanhaxon	۳۰۰۰	P_3	۰/۹	۴/۹
۷	TLRN	$P-T_{mean}-H$	tanhaxon	tanhaxon	۲۳۰۰	P_3	۰/۹	۴/۹
۸	TLRN	$P-W_s$	tanhaxon	tanhaxon	۱۰۰۰۰	P_3	۰/۹۲	۴/۲
۹	TLRN	$P-T_{mean}-H$	tanhaxon	tanhaxon	۱۰۰۰۰	P_3	۰/۹۳	۴/۲
۱۰	TLRN	$P-T_{mean}$	tanhaxon	tanhaxon	۱۸۰۰۰	P_3	۰/۹۵	۴/۹
۱۱	TLRN	$P-T_{max}$	tanhaxon	tanhaxon	۲۲۰۰۰	P_3	۰/۹۵	۳/۵



شکل ۶- نمودار تغییرات پیش بینی شده بارش در مقابل مقادیر واقعی با استفاده از میانگین متحرک سه ساله، ترکیب بارش- دمای بیشینه (مدل شبکه عصبی مصنوعی).

جدول ۶- بهترین نتایج حاصل از دو مدل درخت تصمیم و شبکه عصبی مصنوعی

مدل مورد استفاده	متغیر ورودی (میانگین متحرک سه ساله)	متغیر هدف (میانگین متحرک سه ساله)	میزان تغییر نتایج نسبت به حالت استفاده از اصل داده ها (درصد)	
			R	RMSE
بهترین نتیجه در مدل درخت تصمیم	$P-T_{max}-W_d$	P	۷۳/۹	-۱۳۸/۴
بهترین نتیجه در مدل شبکه عصبی مصنوعی	$P-T_{max}$	P	۵۵/۵	-۵۴/۳

می‌رسد دامنه تغییرات این داده‌ها برای استفاده در مدل های داده کاوی زیاد می‌باشد و همین موضوع منجر به کاهش کارایی مدل در پیش‌بینی می‌گردد. بهتر شدن کارایی هر دو

در مجموع در ایستگاه یزد، دو مدل داده کاوی درختان تصمیم و شبکه عصبی مصنوعی در پیش‌بینی خشکسالی در شرایط استفاده از اصل داده‌ها ناموفق بود. به نظر

صورت گرفته توسط هر دو مدل، پارامترهای بارش و دمای ماکزیمم دخیل بوده است که این موضوع نشان دهنده اهمیت این پارامترها در پیش بینی فرآیند خشکسالی می باشد.

در چهار شبیه سازی صورت گرفته در این تحقیق، زمانی که از میانگین متحرک سه ساله داده ها برای اجرای مدل شبکه عصبی مصنوعی استفاده گردید، ترکیب "بارش، دمای بیشینه" به عنوان ورودی های مدل، منجر به کسب دقیقترین نتایج شد (جدول ۷).

مدل در پیش بینی به هنگام استفاده از داده های میانگین متحرک مؤید این موضوع می باشد. به عبارتی هر دو مدل درخت تصمیم و شبکه عصبی مصنوعی در شرایط استفاده از میانگین متحرک داده ها نتایج قابل قبولی داشته اند. ضمن اینکه اعمال فرآیند میانگین متحرک روی داده های ورودی به نحو چشمگیری بر کارایی هر دو مدل و به ویژه مدل درخت تصمیم رگرسیونی تأثیرگذار بوده است.

لازم به ذکر است در بهترین شبیه سازی

جدول ۷- بهترین نتایج حاصل از دو مدل درخت تصمیم و شبکه عصبی مصنوعی

مدل مورد استفاده	متغیر ورودی (میانگین متحرک سه ساله)	متغیر هدف (میانگین متحرک سه ساله)	R	RMSE
درخت تصمیم	$P - T_{max} - W_d$	P	۰/۸۳	۳/۴۴
شبکه عصبی مصنوعی	$P - T_{max}$	P	۰/۹۵	۳/۵

داده است. علیرغم اینکه منطقه تحقیق وی منطقه ای مرطوب با دامنه تغییرات کم داده ها بوده، بهترین نتیجه در شرایط استفاده از SPI ۲۴ ماهه و تأخیر زمانی یک ماهه ($R^2 = ۰/۹۲ - ۰/۹۳$) به دست آمده است. با افزایش تأخیر زمانی میزان R^2 کاهش یافته، به طوری که میزان R^2 با تأخیر زمانی ۶ ماهه به $۰/۵۹ - ۰/۶۳$ تقلیل یافته است.

مرید (۱۳) در منطقه تهران با استفاده از دو شاخص SPI و EDI و چندین مدل شبکه عصبی خشکسالی را برای ۱۲-۱ ماه آینده پیش بینی کرد. در تحقیق وی بهترین نتایج در تأخیر زمانی شش ماهه ($R^2 = ۰/۶۶ - ۰/۹۸$) حاصل شد که این ضریب با افزایش زمان تأخیر

هرچند دقت مدل شبکه عصبی مصنوعی اندکی بیشتر از مدل درخت تصمیم می باشد. لیکن شبکه های عصبی مصنوعی به مثابه مدل های جعبه سیاه عمل کرده و نحوه عملکرد مدل در آن ها مشخص نیست، ولی مدل درخت تصمیم با تولید قوانین در زمره مدل های جعبه سفید تلقی می گردد.

نتایج بدست آمده از این تحقیق با نتایج تحقیقات مشیرا و مرید (۱۲ و ۱۳) که به ترتیب خشکسالی را با استفاده از شبکه عصبی مصنوعی در حوزه کنسباتی هند و تهران انجام دادند مقایسه شد. مشیرا پیش بینی خشکسالی را با استفاده از شاخص SPI ۳، ۶، ۱۲ و ۲۴ ماهه و در تأخیرهای زمانی ۱ تا ۶ ماهه انجام

کاهش یافت و در تأخیر زمانی ۱۲ ماهه برای شاخص SPI به $R^2 = 0.54 - 0.62$ و برای شاخص EDI به $R^2 = 0.55 - 0.72$ کاهش یافت.

لازم به ذکر است در رابطه با پیش بینی بارش و به تبع آن ارزیابی خشکسالی قبل از وقوع، تا کنون موفقیت قابل توجهی در سطح جهان حاصل نشده است. این مسئله هنگامی که فاصله زمانی بین پیش بینی و وقوع خشکسالی افزایش می یابد شدیدتر می شود. علاوه بر آن در مناطق خشک و نیمه خشک (که پراکنش داده های اقلیمی به ویژه بارش نسبت به میانگین دراز مدت آن زیاد می باشد) مدل های پیش بینی از ناتوانی بیشتری برخوردار می گردند. نتیجه این تحقیق نشان داد که پیش پردازش مناسب داده های مرتبط با خشکسالی همراه با به کارگیری مدل های مناسب داده کاوی می تواند افق جدیدی در فرایند پیش بینی پدیده خشکسالی ایجاد کرده و دقت پیش بینی ها را به مقدار قابل توجه ای ارتقاء بخشد. البته لازم است تحقیقات بیشتر در این زمینه در مناطق مختلف با شرایط اقلیمی و داده ای متفاوت صورت پذیرد، تا بتوان نسبت به انعطاف پذیری و سازگاری مدل های استفاده شده در شرایط مختلف اطمینان حاصل کرد. بدیهی است اصلی ترین عامل در مدیریت پدیده های خشکسالی و کاهش خسارات مربوطه، امکان پیش بینی مناسب آن می باشد و هرگونه پیشرفتی در این زمینه حائز اهمیت ویژه است.

مقادیر بارندگی جزء بی ثبات ترین متغیرهای آب و هوایی مخصوصاً در مناطق

خشک محسوب می شود و به لحاظ تأثیرات مستقیم بر خشکی، شاخص خوبی برای مطالعه خشکسالی می باشد. به همین علت هم غالباً اصلی ترین عامل جهت محاسبه شاخص های خشکسالی (SPI، RDI و ...) میزان بارش است. لذا هر مدلی که بتواند میزان بارش را با دقت کافی قبل از وقوع آن پیش بینی نماید، می تواند جهت ارزیابی شدت خشکسالی در آینده مورد استفاده قرار گیرد. بدیهی است اطلاع از شدت و وضعیت خشکسالی می تواند تصمیم گیران و جوامع تحت تأثیر را جهت آمادگی و مقابله با خسارات آن به شکل قابل توجهی یاری نماید. علاوه بر آن پارامترهای هواشناسی و به ویژه پارامتر بارش از پایگاه داده مناسبی در سازمان های مسئول زیربط برخوردار می باشد، لذا می توان از طریق داده کاوی به پردازش، شبیه سازی و تجزیه و تحلیل داده های مذکور و کشف روابط حاکم بر داده های اقلیمی موثر بر رخداد خشکسالی پرداخت. این در حالی است که نوسانات شدید بارش به خصوص در مناطق خشک، توانایی مدل های داده کاوی را در یادگیری فرایند حاکم بر وقوع خشکسالی تحت الشعاع قرار می دهد. از این رو پردازش داده ها به منظور افزایش کارایی این مدل ها می تواند در تحقق اهداف تحقیق مثمر ثمر قرار گیرد. نتایج این تحقیق نشان داد که اعمال فرآیند میانگین متحرک به عنوان یکی از عملیات موثر در تعدیل دامنه تغییرات داده ها، به نحو چشمگیری بر افزایش کارایی هر دو مدل مورد استفاده و به ویژه مدل درخت تصمیم

رگرسیون تأثیرگذار بوده است. نتایج به دست آمده نشان می دهد که هر دو روش درخت تصمیم رگرسیونی و روش شبکه عصبی مصنوعی در ایستگاه یزد، مدل هایی کارا در پیش بینی خشکسالی با استفاده از داده های پردازش شده می باشند، که در صورت تعدیل دامنه تغییرات داده های ورودی قادرند با ضریب اطمینان بالایی میزان بارش را ۱۲ ماه قبل از وقوع برآورد نمایند. به طور مشخص، استفاده از

میانگین متحرک سه ساله نسبت به حالت استفاده از اصل داده ها منجر به افزایش چشمگیر کارایی مدل های درخت تصمیم رگرسیونی و شبکه عصبی مصنوعی می شود. ضمن اینکه اعمال فرآیند میانگین متحرک در مدل های هوشمند نظیر درخت تصمیم منجر به تغییر ترکیب پارامترهای ورودی و قوانین ایجاد شده توسط مدل را تغییر داد.

منابع:

1. Afkhami, H. 2008. Evaluation and prediction of drought in Yazd area using artificial neural network. Thesis of M.Sc. Yazd university. 236 pp.
2. Afkhami, H., M.T. Dastorani, H. Malekinezhad and M.H. Mobin. 2010. Evaluation of the effects of climatic factors on ANN based drought prediction in Yazd area. Journal of sciences and Technology of Agriculture and Natural Resources. 51: 157-169.
3. Breiman, L., J. Friedman, R. Olshen and C. Stone. 1984. Classification and Regression Trees, Monterey, CA:Wadsworth and Brooks/cole Advanced Books and Software. 105 pp.
4. Celso Augusto, G., S. Santon Bruno Morais and B.L. Gustavo. 2009. Drought forecast using an artificial neural network for three hydrological zones in san Francisco river basin. Brazil. New Approaches to Hydrological Prediction in Data-Sparse Regions. IAHS. 333: 302-312.
5. Chiang, J.L. and W. Chiang. 2011. Drought prediction using artificial neural network. Geophysical Research Abstracts. Vol. 13, EGU 2011-2224.
6. Fatehi, A., M.H. Davoudi and N. Arman. 2008. Evaluation of drought using SOI and NINO3, 4 Index and Artificial Neural Network. The 5th National Conference on Watershed Management Engineering. 173 pp.
7. Habibipour, A. 2010. Prediction of drought in synoptic station of Yazd using decision trees. Thesis of M.Sc. Yazd university. 130 pp.
8. Ghazanfari, M., S. Alizadeh and T. Pour babak. 2008. Data mining and Discovering Knowledge. Press center of Ferdowsi university. 335 pp.
9. Kantardzic, M. 1998. Data Mining. 208 pp.
10. Kardvani, P. 2001. Drought and The methods to prevent it. Tehran university Press 335 pp.
11. Meshgani, A. and A. Nazemi. 2009. An introduction to data mining. Mashhad university Press 185 pp.
12. Mishra, A.K. and V.R. Desai. 2006. Drought forecasting using feed-forward recursive neural network. Ecological Modelling 198: 127-138.

13. Morid, S., V. Smakhtin and K. Bagherzadeh. 2007. Drought forecasting using artificial neural networks and time series of drought indices. *Int. Journal of Climatology*. 27: 2103-2111.
14. Wilhite, D.A. 1993. The enigma of drought, chapter 1, In: D.A. Wilhite(ed), *Drought Assessment Management, and planning: Theory and case studies*, Kluwer Academic publishers, Boston, MA, pp: 3-17.

Evaluation of the Effects of Data range Modification on Efficiency of Regression Decision Tree and Artificial Neural Networks for Drought Prediction

A. Habibipoor¹, M.T. Dastorani², M.R. Ekhtesasi² and H. Afkhami³

1- M.Sc. Faculty of Natural Resources, Yazd University, (Corresponding author: habibipoor_azam@yahoo.com)

2- Associate Professor, Faculty of Natural Resources, Yazd University

3- M.Sc. Faculty of Natural Resources, Yazd University

Abstract

One of the effects of climate system change is the occurrence and intensification of drought phenomenon. Prediction of drought condition can play an important role in mitigation of its effects as well as effective management of the available water during the drought periods. Different approaches have been presented for evaluation of drought. Analysis of precipitation data is the general method for drought evaluation, as acceptable prediction of precipitation before its occurrence, would be necessary and effective for analysis of drought. The purpose of this research is the evaluation of the effect of data processing on applicability of two data mining models on drought prediction in Yazd station. In addition, during the recent decades some new computer based models have been developed for drought prediction and in most of the cases they have presented quite satisfactory results. In this research, prediction of precipitation, which is the main component on drought occurrence, has been carried out in Yazd synoptic meteorological station. Therefore, two data mining methods including Regression Decision Tree (RDT) and Artificial Neural Networks (ANN) have been used, and simulations were carried out in two different conditions. In the first condition, the measured values of some meteorological variables were used as inputs and the amount of precipitation was predicted 12 months in advance. However, In the second condition, 3-year moving average of data were the inputs of the models for prediction of precipitation amount 12 months before its occurrence. Finally for evaluation of the model performance in different conditions, statistical criterion including R and RMSE were employed. Results indicated that using moving average of data as inputs of the models has considerably improved the performance of the models. Both RDT and ANN methods are able to predict the amount of precipitation in Yazd station 12 months before its occurrence.

Keywords: Prediction, Drought, Artificial Neural Networks, Regression Decision Tree, Data mining