

هیدروژئومورفولوژی، شماره ۱۴، بهار ۱۳۹۷، صص ۱۹۷-۱۷۹

وصول مقاله: ۱۳۹۶/۱۰/۰۲ تأیید نهایی مقاله: ۱۳۹۶/۱۱/۱۷

## تخمین خشکسالی با استفاده از شبکه‌های هوشمند

حسن ترابی پوده<sup>۱\*</sup>

بابک شاهی نژاد<sup>۲</sup>

رضا دهقانی<sup>۳</sup>

### چکیده

خشکسالی یکی از پدیده‌های آب و هوایی است که در همه‌ی شرایط اقلیمی و در همه‌ی مناطق کره‌ی زمین به وقوع می‌پیوندد. پیش‌بینی خشک‌سالی نقش مهمی در طراحی و مدیریت منابع طبیعی، سیستم‌های منابع آب، تعیین نیاز آبی گیاه ایفا می‌نماید. در این پژوهش جهت تخمین شاخص بارش استاندارد ۱۲ ماهه‌ی چهار ایستگاه باران‌سنجی دلفان، سلسله، دورود و بروجرد واقع در استان لرستان از مدل شبکه‌ی عصبی موجک استفاده شد و نتایج آن با سایر روش‌های هوشمند از جمله شبکه‌ی عصبی مصنوعی مقایسه گردید. برای این منظور از پارامتر بارش در مقیاس زمانی ماهانه در طی دوره‌ی آماری (۱۳۷۲-۱۳۹۲) به عنوان ورودی و شاخص بارش استاندارد به عنوان پارامتر خروجی مدل‌ها انتخاب گردید. معیارهای ضریب همبستگی، ریشه‌ی میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج نشان داد هر دو مدل قابلیت خوبی در تخمین شاخص بارش استاندارد دارند، لیکن از لحاظ دقت، مدل شبکه‌ی عصبی موجک عملکرد بهتری نسبت به شبکه‌ی عصبی مصنوعی از خود نشان

۱- دانشیار گروه مهندسی آب، دانشگاه لرستان، لرستان، ایران (نویسنده‌ی مسئول). E-mail: torabi1976@gmail.com

۲- استادیار گروه مهندسی آب دانشگاه لرستان، لرستان، ایران.

۳- دانشجوی دکتری سازه‌های آبی، دانشگاه لرستان، لرستان، ایران.

داده است. در مجموع نتایج نشان داد استفاده از مدل شبکه‌ی عصبی موجک می‌تواند در زمینه تخمین خشکسالی موثر باشد.

**کلمات کلیدی:** بارش، خشکسالی، شاخص بارش استاندارد، شبکه‌ی عصبی موجک.

### مقدمه

خشکی و خشکسالی یکی از ویژگی‌های اجتناب‌ناپذیر و زیان بار اقلیمی کشور ایران به شمار می‌رود، بنابراین پژوهش و مطالعه در این زمینه بسیار ضروری است. خشکسالی غالباً یک پدیده‌ی خزنده توصیف می‌شود و توصیف زمانی و مکانی آن بسیار مشکل است. یکی از گام‌های مهم و اساسی در مطالعات خشکسالی و ترسالی برای بیان کمی خشکسالی و همچنین ارزیابی آن در مقیاس‌های مختلف زمانی و مکانی در هر منطقه، تعیین شاخص‌هایی است که میتوان براساس آنها میزان شدت و تداوم خشکسالی و ترسالی را ارزیابی کرد. شاخص بارش استاندارد که یکی از جامع‌ترین شاخص مطالعه‌ی خشکسالی و ترسالی به شمار می‌آید. تغییرپذیری آن باعث می‌شود که در مقیاس‌های کوتاه‌مدت برای اهداف کشاورزی و در مقیاس‌های بلندمدت برای اهداف هیدرولوژی مورد استفاده قرار گیرد. پیش‌بینی خشکسالی در برنامه‌ریزی‌های کشاورزی منابع آب با اهمیت بوده و در یک نظام هدفمند و جامع مدیریتی منجر به برنامه‌ریزی در ذخیره‌ی آبی سدها، پیش‌بینی میزان واردات مواد غذایی، تغییر الگوی کشت، اطلاع‌رسانی برای پیش‌آگاهی مبارزه با خشکسالی و غیره خواهد شد. امروزه سیستم‌های هوشمند به طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، که شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی از جمله این روش‌ها است. شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی، که توانایی آن در تقریب الگوهای

یک مساله سبب افزایش دامنه‌ی کاربرد این شبکه‌ها شده است. طی سال‌های اخیر استفاده از روش‌های هوشمند در مطالعات شاخص بارش استاندارد حوضه‌های آبریز مورد توجه محققان قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود اسدزاده و همکاران (۱۳۹۵) در پژوهشی با استفاده از مدل عصبی فازی تطبیقی به پیش‌بینی خشکسالی در ایستگاه‌های دریاچه‌ی ارومیه پرداختند و نشان دادند مدل سیستم استنتاج عصبی- فازی تطبیقی در تخمین خشکسالی در مقیاس زمانی طولانی‌مدت از عملکرد مطلوبی برخوردار است. نتایج پژوهش جلال کمالی و همکاران (۲۰۱۵) که جهت تخمین شاخص بارش استاندارد از مدل‌های هوشمند استفاده کردند نشان داد مدل ARIMAX نسبت به مدل‌های هوشمند از عملکرد بهتری برخوردار است. گای و همکاران<sup>۱</sup> (۲۰۱۵) در پژوهشی به تجزیه و تحلیل شاخص بارش استاندارد با استفاده از شبکه‌ی عصبی مصنوعی پرداختند در این پژوهش از داده‌های بارش حوضه‌ی سیواس در آناتولی مرکزی جهت بررسی شاخص بارش بهره گرفتند و نشان دادند شبکه‌ی عصبی مصنوعی دقت بالایی در پیش‌بینی شاخص بارش استاندارد دارد. بوای و گمانه<sup>۲</sup> (۲۰۱۶) کاربرد شبکه‌ی عصبی موجک را جهت تجزیه و تحلیل شاخص خشکسالی حوضه‌ی الجزایر بررسی نمودند و به این نتیجه دست یافتند که شبکه‌ی عصبی موجک دقت بالاتری نسبت به شبکه‌ی عصبی مصنوعی دارد. نتایج حاصل از پژوهش ماکا و پچ<sup>۳</sup> (۲۰۱۶) که جهت پیش‌بینی شاخص خشکسالی SPI از شبکه عصبی مصنوعی در حوضه‌ی دریای ایالات متحده طی سالیان ۱۹۴۸-۲۰۰۲ استفاده نمود نشان داد شبکه‌ی عصبی مصنوعی عملکرد قابل قبولی در پیش‌بینی SPI دارد. ذوالفقار و همکاران (۲۰۱۷) در پژوهشی با استفاده از شبکه‌ی عصبی مصنوعی شاخص خشکسالی را در ۱۷ ایستگاه

---

1- Gaye et al.,

2- Djerbouai and Gaman

3- Maca and Pech

هواشناسی با استفاده از پارامتر تبخیر مورد بررسی قرار دادند و به این نتیجه رسیدند شبکه‌ی عصبی مصنوعی قابلیت بالایی در تخمین شاخص خشکسالی دارد. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت دشت‌های دلفان، سلسله، بروجرد و دورود واقع در استان لرستان از لحاظ شرب و کشاورزی تغییرات شاخص بارش استاندارد به منظور پیش‌بینی و اقدامات مدیریتی جهت جلوگیری از خشکسالی بیش از پیش ضروری است. لذا هدف از این تحقیق تخمین شاخص بارش استاندارد این ایستگاه‌ها با استفاده از مدل شبکه‌ی عصبی موجک و شبکه‌های عصبی مصنوعی بر اساس پارامتر بارش به عنوان پارامترهای ورودی و شاخص بارش استاندارد به عنوان خروجی مدل در مقیاس زمانی ماهانه می باشد.

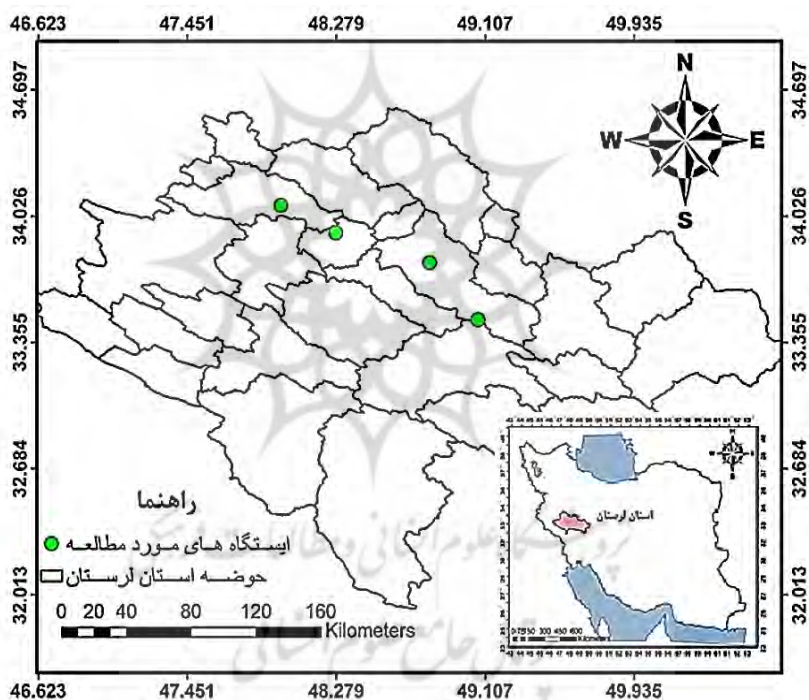
## مواد و روش‌ها

### منطقه‌ی مورد مطالعه

جغرافیای لرستان به دلیل قرار گرفتن این استان در رشته کوه‌های زاگرس، جغرافیایی کوهستانی و چهارفصل است. این استان یکی از استان‌های کوهستانی غرب ایران بوده که بیشتر مناطق این استان را کوه‌های زاگرس پوشانده است. آب و هوای استان لرستان متنوع و تنوع آب و هوا در آن از شمال شرق به جنوب غرب کاملاً مشهود است. استان لرستان سومین استان پر آب کشور و ۱۲ درصد آب‌های کشور را در اختیار دارد. دشت‌های دلفان، سلسله، بروجرد و دورود در این استان در ناحیه‌های شمال و شمال شرق با آب و هوای معتدل مرکزی قرار دارند که در شکل (۱) موقعیت ایستگاه‌های باران‌سنجی مورد مطالعه در استان لرستان نشان داده شده است. همچنین در جدول (۱) موقعیت جغرافیایی این ایستگاه‌ها قابل مشاهده است.

جدول (۱) مشخصات جغرافیایی ایستگاه‌های مورد بررسی

ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا (m)	میانگین بارش (m)
دورود	۴۸/۰۶۵	۳۳/۴۷۶	۱۸۰۰	۵۷/۶۸۹
بروجرد	۴۸/۷۱۹	۳۳/۹۰۰	۱۵۳۰	۴۲/۲۷۵
سلسله	۴۸/۲۰۷	۳۳/۷۸۶	۱۵۶۰	۴۸/۰۵۴
دلفان	۴۸/۹۷۰	۳۴/۰۸۲	۱۴۵۰	۴۲/۵۶۱



شکل (۱) منطقه‌ی مورد مطالعه و ایستگاه‌های مورد بررسی

### - شاخص بارش استاندارد (SPI)

شاخص SPI به منظور پایش خشکسالی اقلیمی ایالت کلرادوی آمریکا توسط مک کی و همکاران در سال ۱۹۹۳ ابداع گردید. در واقع SPI عبارت است از متغیری از تابع توزیع احتمال استاندارد که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر مورد نظر از توزیع گامای به دست آمده، یکسان باشد. برای تعیین سال‌های شاخص خشکسالی و ترسالی در دوره‌ی آماری ۱۳۷۲-۱۳۹۲، از شاخص بارش استاندارد شده SPI استفاده شد. بسیاری از محققان انعطاف‌پذیری شاخص SPI و قابلیت آن برای مقیاس‌های مختلف زمانی را تأیید نمودند (ادوارد، ۱۹۹۷). این شاخص برای هر منطقه براساس ثبت بارش‌های طولانی مدت آن محاسبه می‌شود. ابتدا توزیع آماری مناسب برای آمار بلند مدت بارندگی‌ها برآزش داده و سپس تابع تجمعی توزیع با استفاده از احتمالات مساوی به توزیع نرمال تبدیل می‌شود، به طوری که استاندارد شده و متوسط آن برای هر منطقه و دوره‌ی مدنظر صفر شود (ادوارد، ۱۹۹۷). مقادیر مثبت SPI نشان‌دهنده‌ی بارش بیش از میزان متوسط و مقادیر منفی آن معنای عکس دارد. طبق این روش دوره خشکسالی رخ می‌دهد که شاخص SPI به طور مستمر منفی و به مقدار ۱- و کمتر برسد و زمانی پایان می‌یابد که SPI مثبت شود که در جدول (۲) نشان داده شده است. شاخص بارش استاندارد SPI طبق رابطه زیر قابل محاسبه است.

$$\text{SPI}_n = \frac{P_0 + \sum_{i=1}^n P_i - H_n}{\delta_n} \quad \text{رابطه‌ی (۱)}$$

که در آن،  $n$  تعداد ماه‌هایی که بارش تجمعی‌شان محاسبه شده است؛  $P_0$  مقدار نرمال شده بارش ماه فعلی؛  $P_i$  مقدار نرمال شده بارش ماه قبل؛ میانگین بارش تجمعی  $n$  ماه و انحراف معیار بارش تجمعی  $n$  ماه می‌باشد.

جدول (۲) طبقه بندی مقادیر شاخص SPI

مقادیر	طبقات
$2 >$	ترسالی بسیار شدید
$1.5 < SPI < 1.99$	ترسالی شدید
$1 < SPI < 1.49$	ترسالی
$-0.99 < SPI < 0.99$	نرمال
$-1.49 < SPI < -1$	خشکسالی
$-1.99 < SPI < -1.5$	خشکسالی شدید
$2 <$	خشکسالی بسیار شدید

### - شبکه‌ی عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویولت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی بوجود آمده‌اند (واپنیک<sup>۱</sup>، ۱۹۹۸). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چندمقیاسی را دارا هستند. در ویولت‌ها از دو دسته توابع ویولت و توابع مقیاس (scaling functions) استفاده می‌شود. یک خانواده از توابع مقیاس  $\iota(x)$  به صورت زیر معرفی می‌شوند:

$$\text{رابطه‌ی (۲)} \quad \iota_{m,k}(x) \cong 2^{0m/2} \iota(2^{0m} x - k) \quad m, k \in \mathbb{Z}$$

اگر  $\iota(x)$  را یک تابع مقیاس مادر در نظر بگیریم، مقادیر  $2^{0m}$  و  $k$  به ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس رزولوشن  $m$ ،  $\iota_{m,k}(x)$ ، در اصل پایه‌های متعامد فضای برداری  $V_m$  در رزولوشن  $m$  می‌باشند. به عبارتی فضای برداری  $V_m$  حاوی کلیه‌ی تقریب‌های تابع  $f(x)$  با رزولوشن  $m$  و توسط توابع

1- Vapnik

$l_{m,k}(x)$  می‌باشد. بنابراین فضاهای برداری  $v_m$  حاوی تقریب‌های مختلف تابع  $f(x)$  در رزولوشن‌های مختلف می‌باشند. حال اگر  $w_m$  را فضای برداری متعامد با  $v_m$  در رزولوشن  $m$  فرض کنیم آنگاه می‌توان دسته‌ای دیگر از پایه‌های متعامد فضای  $w_m$  که ویولت  $(x)$  / نامیده می‌شوند را نیز به صورت زیر بیان نمود (وانگ و همکاران، ۲۰۰۰):

$$\text{رابطه‌ی (۳)} \quad m, k \in \mathbb{Z} \quad l_{m,k}(x) \equiv 2^{0m/2} / (2^{0m} x 0 k)$$

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به صورت زیر بیان نمود:

$$\text{رابطه‌ی (۴)} \quad f(x) \equiv f_0(x) \cdot \prod_{m=0}^{\infty} \prod_{k=0}^{\infty} d_{m,k} / l_{m,k}(x)$$

$$\text{رابطه‌ی (۵)} \quad f_0(x) \equiv \prod_k a_{0,k} l_{0,k}(x)$$

روابط فوق بیان می‌دارند که هر تابع فیزیکی را می‌توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن‌های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد.

شبکه‌ی عصبی ویولت بر مبنای روابط (۴) و (۵) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش شین و همکاران (۲۰۰۵) به صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است در حالت کلی خانواده‌ی ویولت‌های پیوسته نیز به صورت زیر بیان می‌شود:

$$\text{رابطه‌ی (۶)} \quad l_{a,b}(t) \equiv \frac{1}{\sqrt{a}} / \left( \frac{t 0 b}{a} \right) \quad a, b \in \mathbb{R}$$



و تبدیل ویولت برای توابع پیوسته به وسیله‌ی رابطه‌ی زیر محاسبه می‌شود:

$$W_{a,b}(f) \cong \tilde{f}_{(a,b)} \cong \mathcal{P}_{a,b}(t, f(t)) \cong \frac{1}{\sqrt{a}} \int_{0^*}^* f(t) \exp\left(-\frac{t0b}{a}\right) dt \quad (7)$$

در اینجا پارامتر  $a$  به عنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (به عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر  $b$  به عنوان پارامتر انتقال و متناسب با زمان می‌باشد (شین و همکاران<sup>۱</sup>، ۲۰۰۵).

#### - شبکه‌ی عصبی مصنوعی

امروزه شبکه‌ی عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (نورانی و همکاران، ۲۰۱۱). ساختار شبکه عصبی معمولاً از لایه‌ی ورودی، لایه‌ی میانی و لایه خروجی تشکیل شده است. لایه‌ی ورودی یک لایه‌ی انتقال‌دهنده‌ی و وسیله‌ای برای تهیه کردن داده‌ها، لایه‌ی خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه‌ی میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چند لایه<sup>۲</sup> انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا<sup>۳</sup> با ساختار شبکه پیش‌خور<sup>۴</sup> و تعداد سه لایه به طور رضایت‌بخشی در حل مسائل پیچیده‌ی مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (نورانی و همکاران، ۲۰۰۹). از رایج‌ترین توابع محرک استفاده شده در

1- Shin et al.,

2- Multi-Layer Perceptron

3- Back Propagation (BP)

4- Feed Forward

شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (توکار و جانسون<sup>۱</sup>، ۱۹۹۹).

#### - معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر می‌باشد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad \text{رابطه‌ی (۸)}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad \text{رابطه‌ی (۹)}$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad \text{رابطه‌ی (۱۰)}$$

در روابط بالا،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $i$ ام،  $N$  تعداد گام‌های زمانی،  $\bar{x}$  و  $\bar{y}$  نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است.

#### بحث و نتایج

در این تحقیق به منظور بررسی نتایج مدل‌ها جهت پیش‌بینی شاخص بارش

استاندارد از داده‌های ماهانه‌ی ۴ ایستگاه بارانسنجی در طی دوره‌ی آماری (۱۳۹۲-۱۳۷۲) استفاده گردید. ابتدا مقادیر شاخص بارش استاندارد ۱۲ ماهه محاسبه و تحلیل شد و سپس به عنوان خروجی در مدل‌ها با توجه به پارامتر ورودی بارش در هر ایستگاه مورد بررسی، منظور گردید. یک نکته‌ی مهم در آموزش شبکه‌های عصبی نرمال سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه‌ی تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (ژو و همکاران، ۲۰۰۷). برای نرمال‌سازی داده‌های تحقیق از رابطه‌ی زیر استفاده شده است:

$$X_n \cong 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه‌ی (۱۰)}$$

که در آن  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{\max}$  و  $X_{\min}$  به ترتیب حداکثر و حداقل داده‌ها می‌باشد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آنها در طبیعت کاری دشوار با عدم قطعیت بالا است. شاخص بارش استاندارد از پارامترهای مهم خشکسالی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر شاخص بارش استاندارد با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکر شده مورد استفاده قرار گرفت که در مقایسه با روش‌های تقریبی به مراتب عملکرد بهتری را ارائه خواهد داد. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هواشناسی و ارائه مدل جهت پیش‌بینی در آینده است و از آنجایی که بارش از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد. بنابراین این پارامتر به عنوان متغیر هدف انتخاب شد. تفکیک داده‌ها به صورت تصادفی صورت گرفته است لازم به ذکر است جهت مدل‌سازی ۸۰ درصد

داده‌ها برای آموزش و ۲۰ درصد باقی مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (ناگای و همکاران<sup>۱</sup>، ۲۰۰۲؛ کیسی و همکاران<sup>۲</sup>، ۲۰۰۶). به منظور مدل‌سازی شاخص بارش استاندارد در ایستگاه‌های باران‌سنجی دورود، بروجرد، سلسله و دلفان واقع در استان لرستان از مدل شبکه‌ی عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل رویداده‌ها، ضرایب تقریب و جزئیات آنها استخراج گردید و داده‌ها به وسیله تابع موجک کلاه مکزیکی به عنوان توابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادیان نزولی که در یادگیری شبکه‌های عصبی و حداقل‌سازی مقدار خطای و تنظیم پارامترهای شبکه استفاده می‌شود، بکار گرفته شد. همچنین جهت مقایسه‌ی نتایج شبکه‌ی عصبی موجک از مدل شبکه‌ی عصبی مصنوعی استفاده شد که در این شبکه تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه‌ی خروجی شبکه‌های عصبی مصنوعی استفاده گردید. همانطور که در جدول (۳) مشاهده می‌شود شبکه‌ی عصبی موجک از دقت و خطای کمتری نسبت به شبکه‌ی عصبی مصنوعی برخوردار است به‌گونه‌ای که در ایستگاه دورود ضریب همبستگی ۰/۸۱۱ و کمترین ریشه‌ی میانگین مربعات خطا ۰/۰۶۸ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۵۱ میلی‌متر، در ایستگاه بروجرد ضریب همبستگی ۰/۸۸۵ و کمترین ریشه‌ی میانگین مربعات خطا ۰/۰۵۶ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۸ میلی‌متر، ایستگاه سلسله ضریب همبستگی ۰/۸۲۷ و کمترین ریشه‌ی میانگین مربعات خطا ۰/۰۴۵ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۳۹ میلی‌متر و در نهایت در ایستگاه دلفان

1- Nagy et al.,

2- Kisi et al.,

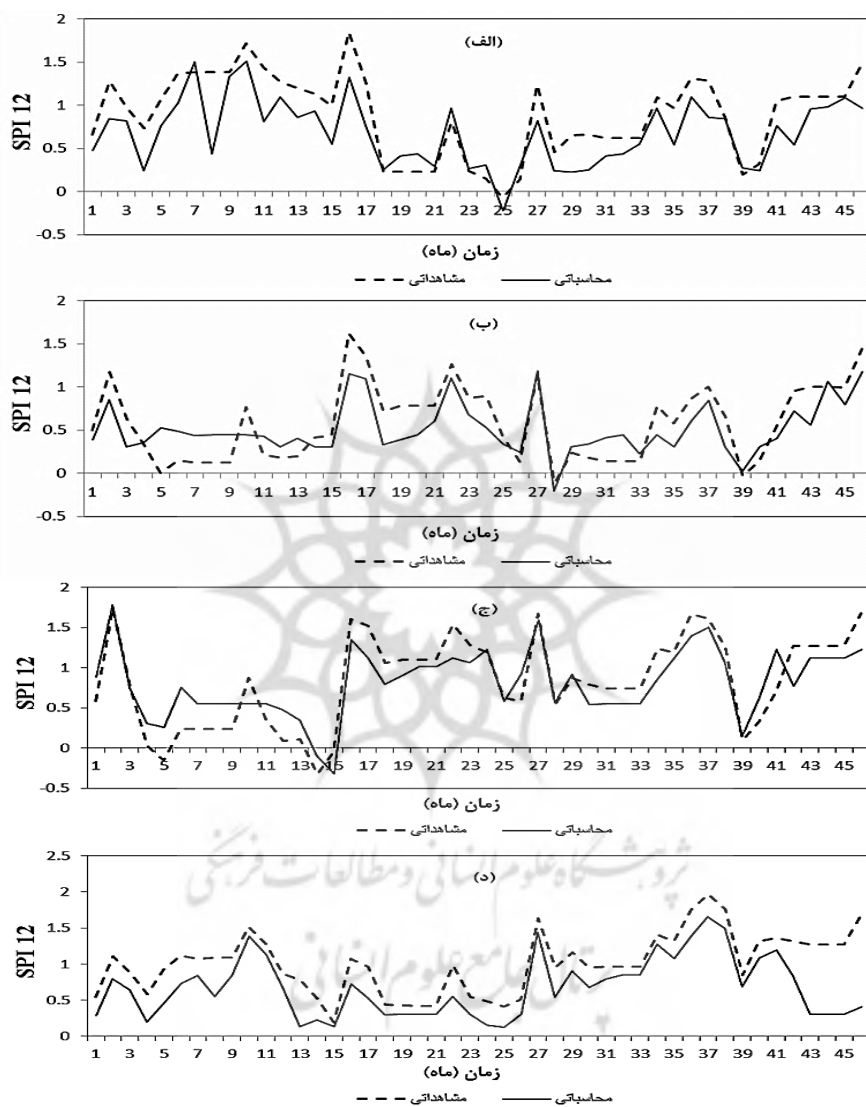
با ضریب همبستگی  $0/849$  و کمترین ریشه میانگین مربعات خطا  $0/050$  میلی‌متر و کمترین میانگین قدر مطلق خطا  $0/046$  میلی‌متر در مرحله‌ی صحت‌سنجی نسبت به سایر ساختارها جهت مدل‌سازی شاخص بارش استاندارد در مقیاس زمانی ماهانه مناسب‌تر خواهد بود.

جدول (۳) ساختار و توابع محرک بهینه در مدل‌های شبکه‌های عصبی موجک و شبکه‌ی عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

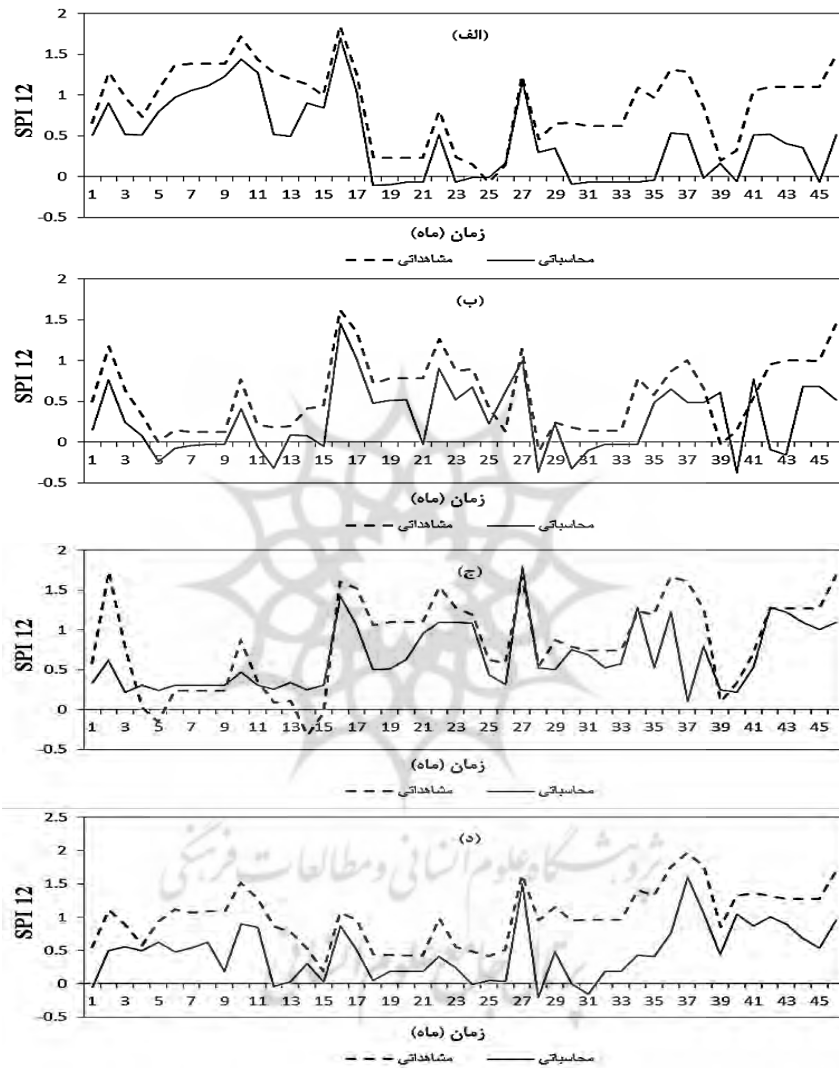
مدل	ایستگاه ساختار	تابع محرک	آموزش			صحت سنجی		
			MAE	RMSE	R	MAE	RMSE	R
دورود	۱-۷-۱	کلاه مکزیکی	$0/820$	$0/057$	$0/050$	$0/811$	$0/068$	$0/051$
شبکه‌ی بروجرد عصبی	۱-۵-۱	کلاه مکزیکی	$0/890$	$0/480$	$0/041$	$0/885$	$0/056$	$0/048$
موجک سلسله	۱-۸-۱	کلاه مکزیکی	$0/838$	$0/057$	$0/045$	$0/827$	$0/045$	$0/039$
دلفان	۱-۱۰-۱	کلاه مکزیکی	$0/857$	$0/040$	$0/030$	$0/849$	$0/050$	$0/046$
دورود	۱-۶-۱	تانژانت هیپربولیک	$0/792$	$0/093$	$0/076$	$0/784$	$0/102$	$0/089$
شبکه‌ی بروجرد عصبی	۱-۷-۱	تانژانت هیپربولیک	$0/760$	$0/075$	$0/057$	$0/752$	$0/089$	$0/067$
مصنوعی سلسله	۱-۹-۱	تانژانت هیپربولیک	$0/750$	$0/061$	$0/053$	$0/726$	$0/075$	$0/059$
دلفان	۱-۸-۱	تانژانت هیپربولیک	$0/800$	$0/074$	$0/063$	$0/791$	$0/097$	$0/079$

در شکل (۲) نمودار بهترین مدل حاصل‌شده برای داده‌های بخش صحت‌سنجی مدل شبکه‌ی عصبی موجک نشان داده‌شده است. همانطور که در این شکل

تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده است، مدل شبکه‌ی عصبی موجکی در تخمین اکثر مقادیر در هر چهار ایستگاه مورد بررسی عملکرد قابل قبولی داشته است. به گونه‌ای که در ایستگاه‌های سلسله و دلفان در تخمین مقادیر بیشینه توانایی مدل مشهود است. اما در ایستگاه‌های دورود و بروجرد در تخمین مقادیر کمینه نتایج خوبی از خود نشان داده است به طوری که این مقادیر را نزدیک به مقدار واقعی‌شان تخمین زده است. در شکل (۳) نمودار مدل شبکه‌ی عصبی مصنوعی برای ایستگاه‌های دورود، بروجرد، سلسله و دلفان نشان داده شده است در این شکل در ایستگاه‌های دورود و بروجرد عملکرد بهتری مدل شبکه‌ی عصبی مصنوعی از خود نشان داده است. در مجموع همانطور که در اشکال ۲ و ۳ قابل مشاهده است نتایج حاکی از برتری کامل مدل شبکه‌ی عصبی-موجکی نسبت به مدل شبکه‌ی عصبی در پیش‌بینی شاخص بارش استاندارد است. در نهایت نتایج پژوهش فوق با نتایج پژوهش‌های ذوالفقار و همکاران (۲۰۱۷)، بوای و گمانه (۲۰۱۶)، ماکا و پیچ (۲۰۱۶)، بلانیه و همکاران (۲۰۱۴)، جلال کمالی و همکاران (۲۰۱۵) همخوانی دارد. در تبیین این نتایج می‌توان بیان نمود شبکه‌ی عصبی موجک که با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برآزش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود (وانگ و همکاران، ۲۰۰۰).



شکل (۲) نمودار مقادیر بهینه‌ی مشاهداتی و محاسباتی مدل شبکه‌ی عصبی موجک برای داده‌های مرحله‌ی صحت‌سنجی، الف) دورود ب) بروجرد ج) سلسله د) دلفان



شکل (۳) نمودار مقادیر بهینه‌ی مشاهداتی و محاسباتی مدل شبکه‌ی عصبی مصنوعی برای داده‌های مرحله‌ی صحت‌سنجی، الف) دورود ب) بروجرد ج) سلسله د) دلفان



## نتیجه‌گیری

شناخت ویژگی‌های خشکسالی لازم‌ه‌ی مدیریت منابع آب است. تحلیل پایش خشکسالی از نیازهای اساسی برنامه‌ریزی‌های مدیریتی کشاورزی و منابع آبی محسوب می‌شود. بدین منظور باید از شاخص‌های خشکسالی استفاده گردد. شاخص استاندارد شده بارش (SPI) یکی از شاخص‌های مهمی است که هدف آن اختصاص ارزش عددی به مهم‌ترین فاکتور اقلیمی (بارندگی) است. این شاخص برای تعیین کمبود بارش در مقیاس‌های زمانی مختلف به کار می‌رود. مقیاس‌های زمانی، تأثیرات خشکسالی را در توانایی منابع آب نشان می‌دهند. در پژوهش حاضر عملکرد مدل‌های شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی را جهت شبیه‌سازی شاخص بارش استاندارد در ۴ ایستگاه باران‌سنجی در طی دوره‌ی آماری (۱۳۷۲-۱۳۹۲) مورد ارزیابی قرار گرفت. مقادیر شاخص بارش استاندارد مشاهداتی با شاخص تخمین زده شده این مدل‌ها با استفاده معیارهای ارزیابی بررسی گردید. نتایج تحقیق نشان داد مدل شبکه‌ی عصبی موجک خطای کمتری نسبت به شبکه‌ی عصبی مصنوعی دارد و همچنین این مدل (شبکه‌ی عصبی موجک) در تخمین اکثر مقادیر دقت قابل قبولی از خود نشان داده است. در تبیین این نتایج می‌توان بیان نمود شبکه‌ی عصبی موجک قادر به پیش‌بینی شاخص خشکسالی در حجم بالا، که احتیاج به اندازه‌گیری و کارهای آزمایشگاهی آنها پرهزینه و زمان‌بر هستند، می‌باشد. همچنین دقت بالای شبکه‌ی عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه‌ی عصبی مصنوعی است. در مجموع این تحقیق نشان می‌دهد استفاده از مدل شبکه‌ی عصبی موجک می‌تواند در زمینه‌ی تخمین شاخص بارش استاندارد موثر باشد. همچنین این مدل می‌تواند در نوبه‌ی خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریتی جهت جلوگیری از ایجاد خشکسالی مفید باشد و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود منابع آب می‌باشد.

## منابع

- اسدزاده، فرخ؛ بایزیدی، مطلب و مهري کاکي (۱۳۹۵)، پایش و تخمین خشکسالی ایستگاه‌های شرق دریاچه‌ی ارومیه با استفاده از مدل عصبی - فازی تطبیقی، اکوهیدرولوژی، شماره ۲، صص ۲۰۵-۲۱۸.
- کاوه، علی و عباس ایران‌منش (۱۳۸۴)، شبکه‌ی عصبی مصنوعی در بهینه‌سازی سازه‌ها، چاپ سوم، انتشارات مرکز تحقیقات ساختمان و مسکن.
- Djrbouai, M., Gamane, D., (2016), **Drought Forecasting Using Neural Networks, Wavelet Neural Networks, and Stochastic Models: Case of the Algerois Basin in North Algeria**. Water Resources Management: An International Journal, Published for the European Water Resources Association (EWRA), Vol.30, No.7: PP,2445-2464.
- Edwards, DC. (1997), **Characteristics of 20th century drought in the United States at multiple time scales**, Climatology Report Number 97-2, Colorado State University, Fort Collins, Colorado.
- Gaye, O., Yildiz, O., Duvan, A., (2015), **A Drought Analysis Of Sivas Using The Standardized Precipitation Index (SPI) Method And Drought Estimation With The Artificial Neural Networks**, International Journal of Advances in Mechanical and Civil Engineering, Vol. 2, No. 5: PP,1-7.
- Jalalkamali, A., Moradi, M., Moradi, M., (2015), **Application of several artificial intelligence models and ARIMAX model for forecasting drought using the Standardized Precipitation Index**, International Journal of Environmental Science and Technology, Vol. 4, No. 12: PP,1201-1210.
- Kisi, O., Karahan, M., Sen, Z. (2006), **River suspended sediment modeling using fuzzy logic approach**, Hydrol Process, Vol.20, No.2: PP,4351-4362.
- Maca, P., Pech, P. (2016), **Forecasting SPEI and SPI Drought Indices Using the Integrated Artificial Neural Networks**, Computational Intelligence and Neuroscience, Vol. 24, No. 3: PP,40-57.

- McKee, TB., Doesken, NJ., Kleist, J., (1993), **The Relationship of Drought Frequency and Duration to Time Scales**. Eighth Conference on Applied Climatology, January 17e22, Anaheim, California: PP,179-184.
- Nagy, H., Watanabe, K., Hirano, M. (2002), **Prediction of sediment load concentration in rivers using artificial neural network model**, Journal of Hydraulics Engineering, Vol.128, No.4: PP,558-559.
- Nourani, V., Alami, MT., Aminfar, MH. (2009), **A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation**, Engineering Applications of Artificial Intelligence, Vol. 22, No. 2: PP,466–472.
- Nourani, V., Kisi,O., Komasi, M., (2011), **Two hybrid artificial intelligence approaches for modeling rainfall–runoff process**, Journal of Hydrology, Vol.402, No. 1–2: PP,41–59.
- Shin, S., Kyung, D., Lee, S., Taik & Kim, J., Hyun, J., (2005), **An application of support vector machines in bankruptcy prediction model**. Expert Systems with Applications, Vol. 28, No.1: PP,127-135.
- Tokar, A., Johnson,P., (1999), **Rainfall-Runoff Modeling Using Artificial Neural Networks**, J Hydrol., Eng, Vol.4, No.3: PP,232-239.
- Wang, D., Safavi, AA., Romagnoli, JA., (2000), **Wavelet-based adaptive robust M-estimator for non-linear system identification**, AIChE Journal, Vol. 46, No.8: PP,1607-1615.
- Zhu, YM., Lu, XX., Zhou,Y., (2007), **Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment**, Geomorphology, Vol.84, No.1: PP,111-125.
- Zulifqar, A., Hussain, I., Faisal,M., Mamona Nazir, H., Hussain, T., Yosafshad,M., Shoukry, AM., Gani, S., (2017), **Forecasting Drought Using Multilayer Perceptron Artificial Neural Network Model**, Advances in Meteorology, Vol.25, No.1: PP,1-10.