

## استفاده از روش های شبکه عصبی موجکی و سیستم استنتاج فازی عصبی تطبیقی در

### پیش بینی بارش ماهانه

اباذر سلگی<sup>۱\*</sup>، حیدر زارعی<sup>۲</sup> و بهداد فلامرزی<sup>۳</sup>

(۱) دانشجوی کارشناسی ارشد، گروه مهندسی منابع آب، دانشگاه شهید چمران اهواز، اهواز، ایران.

(۲) استادیار، گروه هیدرولوژی، دانشگاه شهید چمران اهواز، اهواز، ایران.

(۳) دانشجوی کارشناسی ارشد، گروه مهندسی منابع آب، دانشکده علوم آب، دانشگاه شهید چمران اهواز، اهواز، ایران.

\* نویسنده مسئول: A-solgi@mcsctu.scu.ac.ir

تاریخ پذیرش: ۹۶/۰۲/۲۵

تاریخ دریافت: ۹۵/۰۹/۲۳

### چکیده

پیش بینی بارش به دلیل ماهیت تصادفی آن در مکان و زمان همواره با مشکلات بسیاری مواجه بوده است و این عدم قطعیت از اعتبار بسیاری از مدل های پیش بینی می کاهد. امروزه شبکه های غیرخطی به عنوان یکی از سیستم های هوشمند در پیش بینی یک چنین پدیده های پیچیده ای بسیار مورد استفاده قرار می گیرند. یکی از روش هایی که در سال های اخیر در زمینه هیدرولوژی مورد توجه قرار گرفته است، استفاده از تبدیل موجک به عنوان روشی نوین و مؤثر در زمینه آنالیز سیگنال ها و سری های زمانی است. در پژوهش حاضر، تجزیه و تحلیل موجک به صورت ترکیب با شبکه عصبی مصنوعی و مقایسه با سیستم استنتاج فازی- عصبی تطبیقی برای پیش بینی بارش ایستگاه وراینه در شهرستان نهاوند انجام شد. برای این منظور، سری زمانی اصلی با استفاده از تئوری موجک به چندین زیرسیگنال زمانی تجزیه شد، پس از آن این زیرسیگنال ها به عنوان داده های ورودی به شبکه عصبی مصنوعی برای پیش بینی بارش ماهانه استفاده شد. نتایج به دست آمده نشان داد که مدل ترکیبی موجک- شبکه عصبی عملکرد بهتری نسبت به مدل سیستم استنتاج فازی- عصبی تطبیقی دارد و می تواند برای پیش بینی بارش کوتاه مدت و بلند مدت استفاده شود. همچنین نتایج نشان داد که مدل ترکیبی موجک- شبکه عصبی در برآورد نقاط حدی به خوبی عمل می کند.

واژه های کلیدی: مدل های هوشمند، مدل ترکیبی موجک، عصبی، سیستم استنتاج فازی- عصبی تطبیقی و پیش بینی بارش ماهانه.

## مقدمه

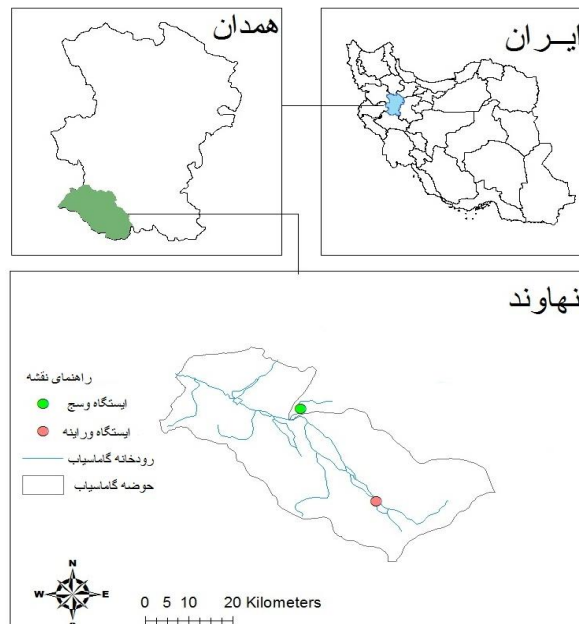
یکی از روش‌های دستیابی به توسعه پایدار و رفع مشکلات مدیریت و برنامه‌ریزی منابع آب، استفاده و گسترش مدل‌های ریاضی هیدرولوژی حوضه آبریز است. کارهای زیادی در زمینه فهم و مدل‌سازی فرآیندهای مرتبط با چرخه هیدرولوژیکی انجام شده است که منجر به ساخت مدل‌های زیادی برای برخورد با گستره وسیعی از مشکلات منابع آب و محیط زیست شده است. با توجه به غیرخطی بودن فرآیندهای بارش رواناب و تصادفی بودن این پدیده‌ها از نظر زمانی و مکانی تشریح آن‌ها با مدل‌های ساده به راحتی امکان پذیر نیست. به همین دلیل امروزه شبکه‌های غیرخطی به عنوان یکی از سامانه‌های هوشمند در پیش‌بینی پدیده‌های پیچیده و غیرخطی بسیار مورد استفاده قرار می‌گیرند. یکی از روش‌هایی که در سال‌های اخیر در زمینه هیدرولوژی مورد توجه قرار گرفته است، استفاده از تبدیل موجک به عنوان روشی نوین و مؤثر در زمینه آنالیز سیگنال‌ها و سری‌های زمانی است. از مهم‌ترین روش‌های مبتنی بر هوش مصنوعی هم می‌توان به سیستم استنتاج فازی عصبی تطبیقی اشاره نمود. در سال‌های اخیر استفاده از این روش‌ها در فرآیندهای هیدرولوژیکی و از جمله مدل‌سازی بارش، بارش- رواناب مورد توجه محققان بوده است. مدل‌سازی و پیش‌بینی جریان ماهانه رودخانه با استفاده از روش موجک شبکه عصبی با استفاده از داده‌های جریان ماهانه دو رودخانه در منطقه شرقی دریای سیاه در ترکیه مورد بررسی قرار گرفت. نتایج این مقایسه نشان داد که مدل بدست آمده می‌تواند دقت پیش‌بینی را افزایش دهد و از مدل‌های پرسپترون چندلایه (MLP)، رگرسیون چند خطی (MLR) و خود همبسته (AR) بهتر انجام می‌شود (Kisi, 2009). یک مدل ترکیبی عصبی- موجک برای پیش‌بینی بارش حوضه ليقوان چای تبریز ارائه شده است. برای این منظور سری زمانی اصلی توسط تبدیل موجک به چندین زیر سری تبدیل شده که این سری‌های تبدیل شده به عنوان ورودی به شبکه عصبی برای پیش‌بینی بارش یک ماهه اعمال شد. نتایج این تحقیق نشان داد که مدل پیشنهادی می‌تواند بارش را در هر دو سطح کوتاه مدت و بلند مدت پیش‌بینی کند (Nourani et al., 2009). دو روش ترکیبی هوش مصنوعی برای مدل‌سازی فرایند بارش- رواناب برای دو حوضه در آذربایجان ایران ارائه شد. مدل اول SARIMAX-ANN (مدل شبکه عصبی مصنوعی- ARIMA فصلی ضربی با ورودی خارجی)، و مدل دوم، مدل موجک- سیستم استنتاج فازی- عصبی تطبیقی (WANFIS) بود. نتایج نشان داد که اگر چه مدل‌های پیشنهادی می‌تواند هر دو شرایط کوتاه مدت و بلند مدت تخلیه رواناب را با توجه به اثرات فصلی پیش‌بینی کنند، ولی مدل دوم نسبتاً مناسب‌تر است (Nourani et al., 2011). یک ترکیب جدید شبکه عصبی برای مدل‌سازی بارش- رواناب در حوضه آق‌چای ایران ارائه شد. این مدل پیشنهادی ترکیبی از روش‌های پردازش داده‌ها، الگوریتم ژنتیک و الگوریتم لونبرگ مارکوارت برای آموزش ورودی‌های شبکه‌های عصبی بود. نتایج نشان داد که این روش قادر به پیش‌بینی دقیق‌تر رواناب نسبت به شبکه‌های عصبی مصنوعی و مدل

سیستم استنتاج فازی عصبی تطبیقی است (Asadi et al., 2013). روش استخراجی مبتنی بر ویژگی نقشه خودسازماندهی شده (SOM) و روش ترکیبی موجک شبکه عصبی مصنوعی برای مدل‌سازی بارش رواناب ارائه شده است. در این کار یک روش دو مرحله‌ای برای مدل‌سازی فرایند بارش-رواناب در دو حوضه دلانی کریک و پایین کریک، فلوریدا، ایالات متحده آمریکا انجام شد. روش دو مرحله‌ای شامل اطلاعات قبل از پردازش و مراحل مدل‌سازی است. نتایج نشان داد که مدل پیشنهادی منجر به نتیجه بهتر به خصوص در مورد ضریب تعیین برای تشخیص نقاط اوج شده است (Nourani and Parhizkar, 2013). پیش‌بینی بلند مدت رواناب رودخانه زاینده‌رود با استفاده از سیستم استنتاج فازی و شبکه عصبی مصنوعی انجام شد. نتایج حاکی از این بود که استفاده ترکیبی از دو مدل مذکور برای پیش‌بینی نقطه‌ای و بلند مدت جریان دارای دقت قابل قبولی می‌باشد (عراقی نژاد و کارآموز، ۱۳۸۴). مدل‌سازی بارش-رواناب با استفاده از مدل ترکیبی موجک- شبکه عصبی مصنوعی برای حوضه ليقوان چای تبریز مورد بررسی قرار گرفته است. نتایج نشان داد که مدل ترکیبی موجک شبکه عصبی نسبت به مدل شبکه عصبی و روش رگرسیونی کارایی بالاتری دارد (کماسی، ۱۳۸۶). استفاده از سیستم فازی عصبی تطبیقی در مدل‌سازی بارش-رواناب روزانه و ماهانه در حوضه آبریز ليقوان چای واقع در آذربایجان شرقی ارائه شده است. در نهایت نتایج با نتایج بدست آمده از روش‌های رگرسیون خطی و مدل سری‌زمانی خطی غیرفصلی (ARIMA) مقایسه شد. عمده‌ترین مزیت مدل‌سازی فازی، سادگی و قابل فهم بودن آن است. از طرفی چون پارامترهای بارش و رواناب به کار رفته در مدل‌سازی، مفروض به خطا و دارای عدم قطعیت می‌باشند، بنابراین منطق فازی ابزار مناسبی جهت مدل‌سازی این سیستم‌ها می‌باشد (نورانی و همکاران، ۱۳۸۸). با استفاده از تبدیل موجک پیش‌بینی بارندگی ماهانه در ایستگاه زرینگل استان گلستان انجام شده و نتایج حاصل از آن با مدل سری‌زمانی خطی فصلی (SARIMA) مقایسه شد. نتایج نشان داد که تجزیه سیگنال با موجک همبستگی میان داده‌های مشاهده‌ای و محاسبه‌ای را نسبت به روش‌های سری‌زمانی به طور قابل ملاحظه‌ای افزایش می‌دهد و پیش‌بینی سیگنال بارش با دقت بیشتری صورت می‌گیرد (طوفانی و همکاران، ۱۳۹۰).

با توجه به کاربرد وسیع شبکه عصبی مصنوعی و تبدیل‌های موجک در علوم مختلف به خصوص علوم مربوط به آب در این تحقیق پیش‌بینی بارش با مدل ترکیبی شبکه عصبی موجک انجام و با مدل سیستم استنتاج فازی عصبی تطبیقی مورد مقایسه قرار گرفت. همچنین در تحقیقات محدود گذشته فقط از پارامتر بارش جهت پیش‌بینی بارش استفاده شده است در این تحقیق علاوه بر پارامتر بارش از پارامترهای دما و رطوبت نسبی نیز استفاده شده است تا اثر آن‌ها بر پیش‌بینی بارش مورد بررسی قرار گیرد.

## مواد و روش‌ها

ایستگاه ورائنه شامل سه ایستگاه باران‌سنجی، تبخیرسنجی و هیدرومتری به نام ورائنه می‌باشد. که در شهرستان نهاوند در موقعیت جغرافیایی ۴۸ درجه و ۲۴ دقیقه و ۱۵ ثانیه طول شرقی و ۳۴ درجه و ۰۴ دقیقه و ۳۲ ثانیه عرض شمالی قرار دارند. این ایستگاه در سال ۱۳۴۸ تأسیس شده است و دارای ارتفاع ۱۷۹۵ متر از سطح دریا با میانگین بارش سالانه دراز مدت ۵۲۱ میلی‌متر می‌باشد. در این بررسی داده‌های بارش، دما و رطوبت‌نسبی در یک دوره ۳۲ ساله (۱۳۹۰-۱۳۵۹) از ایستگاه ورائنه در شهرستان نهاوند دریافت شد (جدول ۱). برای بررسی همگنی داده‌ها از ایستگاه وسج به عنوان ایستگاه کمکی و از نمودار جرم مضاعف استفاده شد که نتایج حاکی از همگنی داده‌ها بود.



شکل ۱: موقعیت ایستگاه ورائنه در شهرستان نهاوند، استان همدان و ایران

جدول ۱: برخی از متغیرهای اقلیمی ایستگاه ورائنه

متغیر اقلیمی	میانگین	حداکثر	حداقل	انحراف معیار	واریانس	ضریب تغییرات
بارش ماهانه (میلی‌متر)	۴۴	۲۵۱	۰/۰	۴۸/۳	۲۳۲۶/۴	۱/۱
دمای ماهانه (سلسیوس)	۱۰	۲۶	-۹	۹/۰	۸۱/۰	۰/۹
رطوبت نسبی ماهانه (درصد)	۶۸	۸۷	۲۰	۱۱/۱	۱۳۳/۹	۰/۲

به علت اینکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود، از روش نرمال‌سازی داده‌ها استفاده شده است که این کار مانع کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌شود با روش نرمال‌سازی هر عدد تبدیل به عددی بین صفر تا یک می‌شود، تا بتوان آن‌ها را در تابع شبکه عصبی به کاربرد (Riad et al., 2004). برای این کار از رابطه ۱ استفاده شد.

$$y = 0/5 + (0/5 \times \frac{x - \bar{x}}{x_{\max} - x_{\min}})$$

رابطه ۱:

در این رابطه  $X$  داده مورد نظر،  $\bar{X}$  میانگین داده‌ها،  $X_{\max}$  حداکثر داده‌ها،  $X_{\min}$  حداقل داده‌ها و  $y$  داده استاندارد شده می‌باشد. ۷۵ درصد از داده‌ها به عنوان داده‌های آموزش و ۲۵ درصد به عنوان داده‌های شبیه‌سازی در نظر گرفته شد. بعد از استفاده از تبدیل موجک، زیر سری‌های بدست آمده به عنوان ورودی شبکه عصبی مورد استفاده قرار گرفتند. با استفاده از شبکه عصبی مصنوعی و ساخت مدل‌های مختلف به طوری که در هر مدل نوع ورودی‌ها متفاوت باشد با مقایسه قانون‌های مختلف آموزش و روشهای مختلف موجود مثل پرسپترون چند لایه، GFF و غیره، بهترین قانون آموزش، تعداد نرون و لایه‌های مخفی و تعداد اجرای برنامه، تعداد تکرار هر مرحله مشخص شد. در نهایت بهترین مدل با استفاده از روش الگوریتم ژنتیک تعیین شد. برای سیستم استنتاج فازی عصبی تطبیقی پنج مدل مورد بررسی قرار گرفت (جدول ۲). در این جدول  $T(t)$ ,  $P(t)$ ,  $N(t)$  به ترتیب رطوبت نسبی، بارش و دمای ماهانه،  $T(t-1)$ ,  $P(t-1)$ ,  $N(t-1)$  به ترتیب رطوبت نسبی، بارش و دمای ماهانه با یک تأخیر زمانی و  $P(t+1)$  بارش ماه آینده می‌باشد. ۷۵ درصد از داده‌ها به عنوان داده‌های آموزش، و ۲۵ درصد باقیمانده به عنوان داده‌های شبیه‌سازی به مدل سیستم عصبی تطبیقی فازی معرفی شد.

جدول ۲: جدول توصیف مراحل کار در سیستم استنتاج فازی عصبی تطبیقی

خروجی	ورودی	ساختار
$P(t+1)$	$P(t), P(t-1)$	۱
$P(t+1)$	$T(t), T(t-1), N(t), N(t-1)$	۲
$P(t+1)$	$N(t), N(t-1), P(t-1), P(t)$	۳
$P(t+1)$	$P(t-1), P(t), T(t), T(t-1)$	۴
$P(t+1)$	$T(t), T(t-1), N(t), N(t-1), P(t-1), P(t)$	۵

### تبدیل موجک

تئوری موجکی یکی از روش‌های علم ریاضی است که ایده اصلی آن برگرفته از تبدیل فوریه است که در قرن نوزدهم مطرح شده است ولی استفاده از آن قدمتی ۱۰ ساله دارد. مفهوم کلی موجک‌ها به صورت تئوری کنونی توسط مورلت و تیمی در مرکز تحقیقات فیزیک نظری مارسل زیر نظر آلکس گراسمن در فرانسه ارائه شد. روش‌های آنالیز موجکی توسط مایر و همکارانش ارائه شد که این روش‌ها را گسترش دادند. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس-زمان از سری‌های زمانی و روابط آن‌ها جهت آنالیز سری‌های زمانی که شامل متغیرها و غیرثابت‌ها می‌باشد را ارائه می‌دهد. تحلیل موجکی استفاده از فاصله‌های زمانی طولانی مدت را برای اطلاعات دارای فرکانس پائین و تناوب‌های کوتاه‌تر را برای اطلاعات دارای فرکانس بالا ارائه می‌دهد.

تحلیل موجکی قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌ها می‌باشد که ممکن است دیگر روش‌های آنالیز سیگنال آن‌ها را نشان ندهند. تابع موجک، تابعی است که دو ویژگی مهم نوسانی بودن و کوتاه مدت بودن را دارا می‌باشد  $\psi(x)$  تابع موجک است اگر و فقط اگر تبدیل فوریه آن  $\psi(\omega)$ ، (رابطه ۲) را ارضا کند (Mallat, 1998).

$$\int_{-\infty}^{+\infty} \frac{|\varphi(x)|}{|\omega|} d\omega < +\infty \quad \text{رابطه ۲:}$$

این شرط به عنوان شرط پذیرفتگی برای موجک  $\psi(x)$  شناخته می‌شود. رابطه فوق را می‌توان معادل با (رابطه ۳) دانست:

$$\varphi(0) = \int_{-\infty}^{+\infty} \varphi(x) dx = 0 \quad \text{رابطه ۳:}$$

این ویژگی تابع با میانگین صفر، چنان محدود کننده نبوده و توابع بسیاری را می‌توان بر اساس آن تابع موجک نامید.  $\psi(x)$  تابع موجک مادر است که توابع مورد استفاده در تحلیل، با دو عمل ریاضی انتقال و مقیاس در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند.


$$\varphi_{a,b}(x) = \frac{1}{\sqrt{a}} \varphi\left(\frac{x-b}{a}\right) \quad \text{رابطه ۴:}$$

در نهایت ضرایب موجک در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با (رابطه ۵) قابل محاسبه می‌باشد (Mallat, 1998).

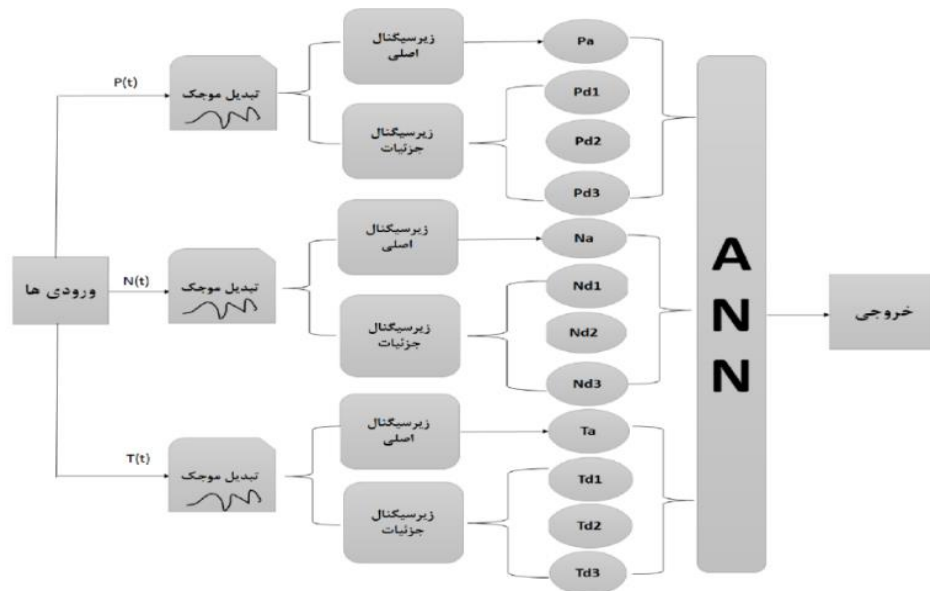
$$T(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \varphi\left(\frac{t-b}{a}\right) f(t) dt \quad \text{رابطه ۵:}$$

که در (رابطه ۵)، a کار مقیاس و b کار انتقال تابع را انجام می‌دهند. به ازای مقادیر مختلف a و b مقدار T بدست می‌آید هر موقع T بیش‌ترین مقدار مثبت را داشته باشد بیش‌ترین انطباق را دارد. به ازای T برابر صفر انطباقی وجود ندارد و به ازای Tهای منفی انطباق عکس یا بیش‌ترین تفاوت وجود دارد. توابع موجک مادرها دارای انواع بسیاری هستند که در شکل دو موجک‌های مادر استفاده شده در این تحقیق نشان داده شده‌اند (Nourani et al., 2009). شرط‌های انتخاب موجک مادر شامل سه شرط که مساحت زیر منحنی آن صفر باشد، مقدار میانگین آن از هر دو سمت به صفر میل کند و ممان‌های آن هم صفر باشد است. شرط آخر اگر وجود نداشته باشد اشکالی ندارد؛ همچنین ویژگی‌های تبدیل موجک شامل تفکیک کردن و تجزیه و تحلیل فرکانس‌های مختلف و در نظر گرفتن نقاط مختلف و حذف نویزها می‌باشد

(Fofola-Georgiou and Kumar, 1995). تبدیل موجک به عنوان یک ابزار ریاضی در شاخه‌های مختلف مهندسی کاربردهای متفاوتی دارد و این به دلیل قابلیت‌های منحصر به فرد این ابزار است که توانایی تعقیب تغییرات یک سیگنال را در طیف زمانی-مقیاسی (زمانی- فرکانسی) وسیع به طور همزمان دارد. برخی کاربردهای آن یافتن نقاط ناپیوسته در سیگنال، نویز برداری از سیگنال، فشرده سازی سیگنال و شناسایی سیستم می‌باشد. اگر داده ها با استفاده از تبدیل موجک تجزیه و تحلیل شود و خروجی آن به عنوان ورودی در شبکه عصبی مورد استفاده قرار بگیرد مدل ترکیبی حاصل می‌شود. پارامترهای بارش، دما و رطوبت نسبی توسط تبدیل موجک تجزیه شده و بسته به سطح بررسی و موجک مادر آن‌ها به چندین زیرسری زمانی تبدیل می‌شوند که این زیرسری‌ها به عنوان ورودی به شبکه عصبی داده می‌شوند (شکل ۳). همچنین در این شکل که نمای شماتیکی از مدل موجک شبکه عصبی است. زیرسری  $P_a(t)$ ،  $N_a(t)$  و  $T_a(t)$  مربوط به مقیاس کلی در سطح پایانی و زیرسری‌های دیگر مربوط به مقیاس کوچک در سطح یک تا سطح پایانی می‌باشند.



شکل ۲: موجک sym3 (الف)، موجک db4 (ب)، موجک Haar (ج)



شکل ۳: نمای شماتیکی از مدل موجک- شبکه عصبی

### سیستم استنتاج فازی عصبی تطبیقی

از آنجا که نظریه مجموعه فازی توسط لطفی‌عسگرزاده مشهور به زاده در سال ۱۹۶۵ پیشنهاد شده است به طور گسترده در بسیاری از زمینه‌ها استفاده می‌شود (Ross, 1995). مشکل اصلی منطق فازی این است که روند سینماتیکی

برای طراحی یک کنترل کننده فازی وجود ندارد. به عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند (جفت‌های ورودی و خروجی)، ساختارش را خود مرتب کند و با شیوه‌ای تعامل خود را تطبیق دهد. بدین منظور پروفیسور جنگ در سال ۱۹۹۳ مدل سیستم شبکه عصبی- فازی تطبیقی را ارائه کرد که قابلیت ترکیب توانایی دو روش مذکور را داشت (نورانی و همکاران، ۱۳۸۸). این روش به طور عملی در زمینه مهندسی توسعه یافته است. بر اساس نظریه بهینه فازی، شبکه‌های عصبی فازی جدید برای پیش‌بینی رواناب معرفی شده است (Ross, 1995).

### ساختار و الگوریتم

سیستم استنتاج فازی-عصبی تطبیقی قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به طور تطبیقی یک قاعده- بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سیستم‌های فازی را تنظیم کند. مشکل اصلی مدل پیش‌بینی سیستم شبکه عصبی- فازی تطبیقی احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین پارامترها می‌باشد. به منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی مورد نظر دو ورودی  $x$  و  $y$  و یک خروجی  $z$  دارد. برای یک مدل فازی تاکاگی سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر-آنگاه فازی به صورت زیر بیان کرد:

$$\text{قانون اول: } p_1x + q_1y + r_1z_1 = \text{باشد آنگاه } B_1 \text{ برابر } y \text{ و } A_1 \text{ برابر } x \text{ اگر: قانون اول}$$

$$\text{قانون دوم: } p_2x + q_2y + r_2z_2 = \text{باشد آنگاه } B_2 \text{ برابر } y \text{ و } A_2 \text{ برابر } x \text{ اگر: قانون دوم}$$

که  $p_1, q_1, r_1$  (i=1,2) پارامترهای خطی در بخش تالی مدل فازی تاکاگی- سوگنو درجه اول هستند (نورانی و همکاران، ۱۳۸۸).

ساختار سیستم استنتاج فازی-عصبی تطبیقی شامل پنج لایه می‌شود (Nourani and Komasi, 2013). لایه اول، گره‌های ورودی، هر گره از این لایه، مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کنند.

$$\text{رابطه ۶: } i=1,2 \quad o_{i1} = u_{A_i}(x) \quad i=3,4 \quad o_{i2} = u_{B_{i-2}}(x)$$

که  $x$  و  $y$  ورودی‌های غیرفازی به گره  $i$ ،  $A_1$  و  $B_1$  برچسب‌های زبانی هستند که به ترتیب با توابع عضویت مناسب  $\mu_{A_i}$  و  $\mu_{B_i}$  مشخص می‌شوند. باید پارامترهای این توابع عضویت که به عنوان پارامترهای مقدماتی در این لایه شناخته می‌شوند، مشخص شوند. لایه دوم، گره‌های قاعده، در لایه دوم، عملگر "و" (And) به کار برده می‌شود تا خروجی (قوه اشتغال) که نمایانگر بخش مقدم آن قانون است بدست آید. قوه اشتغال به مقدار درجه‌ای که بخش مقدم یک قانون فازی برآورده شده، گفته می‌شود و به تابع خروجی آن قانون، شکل می‌دهد. از این رو، خروجی‌های  $O_{2,k}$  این لایه، حاصل ضرب درجات مربوط به لایه اول هستند.



$$o_{2,k} = u_{Ai}(x) \times u_{Bi}(y) \quad \text{رابطه ۷:}$$

لایه سوم، گره‌های متوسط، هدف اصلی در لایه سوم، تعیین نسبت هر قوه اشتعال به عنوان  $i$  امین قانون به مجموع همه قوه اشتعال قوانین می‌باشد در نتیجه  $W_i$  قوه اشتعال نرمال شده به دست می‌آید.

$$o_{3,e} = \bar{w} = \frac{w_1}{\sum_{k=1}^4 w_k} \quad \text{رابطه ۸:}$$

لایه چهارم، گره‌های نتیجه، تابع گره چهارمین لایه توزیع  $i$  امین قانون را به کل خروجی محاسبه می‌کند و به صورت زیر تعریف می‌شود:

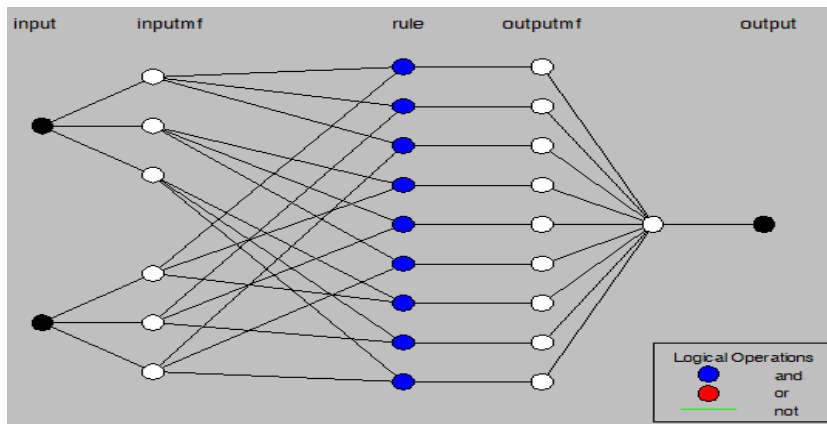
$$o_{4,i} = \bar{w}_i f_i = w_i(p_i x + q_i y + r_i) \quad \text{رابطه ۹:}$$

که  $\bar{w}_1$  خروجی  $i$  امین گره از لایه قبلی است.  $(p_i, q_i, r_i)$  ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی- سوگنو نیز می‌باشند. لایه پنجم، گره‌های خروجی، این تک گره، خروجی کلی را با جمع کردن همه سیگنال‌های ورودی محاسبه می‌کند. بنابراین، در این لایه فرآیند غیرفازی سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می‌دهد.

$$o_{s,i} = \bar{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad \text{رابطه ۱۰:}$$

سیستم استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، در مدل‌سازی فرآیندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق بسیار قدرتمند می‌باشد (Nayak et al., 2004; Kişi, 2009). مدل فازی عصبی تطبیقی بر اساس تغییر در میزان مقادیر و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. در مدل سیستم استنتاج عصبی فازی تطبیقی از روش استنتاجی تاکاگی سوگنو استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین شوند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیش‌ترین مقدار را داشته باشند. تعداد و نوع ورودی‌ها، شکل توابع عضویت از عوامل مؤثر بر مدل نروفازی می‌باشد (Jang et al., 1997).

در شکل شماره چهار ساختاری از عملکرد و ارتباط بین لایه‌ها در مدل استنتاج عصبی فازی تطبیقی آورده شده است.



شکل ۴: نمای شماتیکی از مدل سیستم استنتاج عصبی فازی تطبیقی

#### معیارهای ارزیابی مدل

منظور از ارزیابی مدل به دست آوردن میزان خطای مدل با توجه به داده‌های ورودی داده شده به مدل جهت آموزش و بر اساس معیارهای مختلف محاسبه خطا می‌باشد. در این پژوهش برای ارزیابی مدل از معیارهای زیر استفاده شد:

$$CE = 1 - \frac{\sum (p_{obs} - p_{pre})^2}{\sum (p_{obs} - \bar{p})^2} \quad \text{رابطه ۱۱}$$

$$RMSE = \sqrt{\frac{\sum (P_{obs} - p_{pre})^2}{n}} \quad \text{رابطه ۱۲}$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (p_{obs} - p_{pre})^2}{\sum_{i=1}^N (p_{pre} - \bar{p})^2} \quad \text{رابطه ۱۳}$$

RMSE جذر میانگین مربعات خطاست، CE ضریب بهره‌وری است که ضریب نش- ساتکلیف<sup>۱</sup> نیز نامیده می‌شود. R<sup>2</sup> ضریب تعیین می‌باشد که در این شاخص‌ها P<sub>obs</sub> بارش مشاهده‌ای، p<sub>pre</sub> بارش پیش‌بینی شده و  $\bar{p}$  میانگین بارش مشاهده‌ای است (Talei et al., 2010) شاخص دیگری که در این تحقیق استفاده شده است شاخص آکائیک است که بر اساس این شاخص هر مدلی که شاخص آکائیک کمتری داشته باشد مناسب است.

$$AIC = m \times \ln(RMSE) + 2(Npar) \quad \text{رابطه ۱۴}$$

در (رابطه ۱۴)، m تعداد داده‌های ورودی، Npar تعداد پارامترهای آموزش دیده می‌باشد (Nourani and Komasi,

2013).

<sup>1</sup> Nash-Sutcliffe

## نتایج و بحث

ساختارهای مختلف در مدل سیستم استنتاج فازی عصبی تطبیقی با مقایسه توابع عضویت مختلف و تعداد تکرارهای مختلف مورد بررسی قرار گرفت. برای پیدا کردن بهترین مدل شاخص‌های مختلف مطابق (جدول ۳) بررسی شد و بهترین مدل مربوط به ساختار D<sub>5</sub> بود، که در آن تابع عضویت مثلثی (Trimf) با تعداد تکرار ۱۰ بدست آمد.

جدول ۳: ساختار و نتایج مدل سیستم استنتاج فازی عصبی تطبیقی

بهرترین ساختار	تابع عضویت	تعداد تکرار	ضریب تعیین داده‌های آموزش	ضریب تعیین داده‌های شبیه‌سازی	جذر میانگین مربعات خطای آموزش	جذر میانگین مربعات خطای شبیه‌سازی
D <sub>1</sub>	Pimf	۲۰	۰/۷۴	۰/۶۳	۰/۰۴۸۲	۰/۰۶۸۰
D <sub>۲</sub>	Trimf	۱۰	۰/۴۷	۰/۲۹	۰/۰۶۴۳	۰/۱۰۲۷
D <sub>۳</sub>	Trimf	۱۵	۰/۴۹	۰/۱۸	۰/۰۶۵۲	۰/۱۲۸۰
D <sub>۴</sub>	Trapmf	۲۰	۰/۶۱	۰/۴۱	۰/۰۵۷۱	۰/۰۸۹۳
D <sub>۵</sub>	Trimf	۱۰	۰/۷۶	۰/۶۵	۰/۰۴۵۳	۰/۰۶۳۲

در مدل ترکیبی با بررسی مدل‌های مختلف بدین صورت که ابتدا با استفاده از تبدیل‌های موجک زیر سری‌های مختلف با درجه‌های تجزیه مختلف به ازای موجک مادرهای متفاوت مورد بررسی قرار گرفت. برای تعیین سطوح مختلف از رابطه (۱۵) استفاده شد (Nourani et al., 2009).


$$L = \text{Int}[\log(N)] \quad \text{رابطه ۱۵:}$$

در این رابطه L درجه تجزیه پیشنهادی و N تعداد سری زمانی اعداد می‌باشد. در این پژوهش با  $N=384$ ،  $L=2$  می‌باشد که برای دقت بیشتر، درجات تجزیه یک تا چهار مورد بررسی قرار گرفت. تعداد نرون‌های لایه اول وابسته به درجه تجزیه موجک می‌باشد و همان‌طوری که در (شکل ۳) دیده می‌شود تعداد نرون‌های ورودی برای شبکه برابر با  $m(j+1)$  است که j درجه تجزیه موجک و m تعداد پارامترهای ورودی می‌باشد. لایه خروجی نیز دارای یک نرون می‌باشد. تعداد نرون‌های لایه میانی متغیر بوده و با سعی و خطا بدست می‌آید که در این پژوهش تعداد نرون‌های لایه میانی از سه تا ۲۰ مورد تجزیه و تحلیل قرار گرفت. ساختارهای مختلف در (جدول ۴) نشان داده شده است. یکی از نکات مهم و اساسی در مورد انتخاب موجک‌های مادر، طبیعت رخداد پدیده و نوع سری زمانی آن می‌باشد. لذا الگویی‌هایی از توابع موجک مادر که بتواند به لحاظ شکل هندسی به خوبی بر منحنی سری زمانی منطبق شوند بهتر می‌توانند عمل نگاشت را انجام دهند و نتایج حاصل نیز بهتر خواهد بود. در این پژوهش با توجه به آزمایش موجک‌های مادر مختلف و توجه به نکته گفته شده در بالا موجک‌های مادر Haar، Sym3 و Db4 انتخاب شدند. یکی دیگر از نکات اساسی در آموزش شبکه تعداد تکرارها (Epoch) می‌باشد. تعیین تعداد صحیح این تکرارها در آموزش بسیار مهم است. در حالت کلی هر چه


تعداد تکرار در آموزش شبکه افزایش یابد خطای پیش‌بینی در شبکه کمتر می‌شود اما هنگامی که تعداد تکرارها از یک مقدار خاص تجاوز کند، خطای دسته آزمایشی نیز افزایش می‌یابد. بنابراین بایستی مقدار بهینه‌ای برای تعداد تکرارها مدنظر گرفته شود تا کیفیت مدل برای هر دو مرحله آموزش و تست قابل قبول باشد. در این پژوهش با توجه به تغییرات خطای شبکه در حالت آموزش و تست تعداد تکرار بهینه ۴۰۰ تکرار بدست آمد (شکل ۵) سیگنال اصلی بارش را به عنوان نمونه‌ای از ورودی‌های تحقیق نشان می‌دهد. این سیگنال با استفاده از تبدیل موجک به زیر سیگنال‌هایی تجزیه شده است (شکل ۶). این زیر سیگنال‌ها توسط کدنویسی در نرم افزار متلب به عدد تبدیل شده و به عنوان ورودی شبکه عصبی مورد استفاده قرار گرفت. با توجه به معیارهای ارزیابی مدل‌ها در این تحقیق، بهترین مدل موجک- شبکه عصبی در ساختار ۱۵ D با موجک مادر Sym3 با درجه تجزیه دو بدست آمد (جدول ۴). (شکل ۷) بارش محاسبه‌ای در مقابل مشاهده‌ای را برای دو مدل به کار رفته در تحقیق نشان می‌دهد.

جدول ۴: نتایج و ساختارهای مدل ترکیبی موجک- شبکه عصبی


ساختار	سطح تجزیه	موجک مادر	ساختار شبکه	ضریب تبیین داده‌های آموزش	ضریب تبیین داده‌های شبیه‌سازی	جذر میانگین مربعات خطای آموزش	جذر میانگین مربعات خطای شبیه‌سازی
D6	۱	Haar	۶-۱۰-۱	۰/۷۵	۰/۳۰	۰/۴۷۱	۰/۱۲۳۳
D7	۲	Haar	۹-۸-۱	۰/۷۶	۰/۳۵	۰/۴۵۴	۰/۱۱۹۲
D8	۳	Haar	۱۲-۹-۱	۰/۸۰	۰/۴۷	۰/۴۱۲	۰/۱۰۲۹
D9	۴	Haar	۱۵-۸-۱	۰/۸۴	۰/۴۴	۰/۳۶۴	۰/۱۰۳۶
D10	۱	۴Db	۶-۶-۱	۰/۸۶	۰/۷۰	۰/۳۵۳	۰/۰۶۰۹
D11	۲	۴Db	۹-۸-۱	۰/۵۱	۰/۳۹	۰/۰۶۴۰	۰/۱۱۷۱
D12	۳	۴Db	۱۲-۵-۱	۰/۶۵	۰/۳۴	۰/۰۶۲۴	۰/۱۱۸۳
D13	۴	۴Db	۱۵-۸-۱	۰/۷۸	۰/۳۶	۰/۰۴۳۶	۰/۱۱۸۵
D14	۱	Sym3	۶-۸-۱	۰/۵۱	۰/۳۸	۰/۰۸۱۰	۰/۱۱۴۰
D15	۲	Sym3	۹-۳-۱	۰/۸۵	۰/۸۰	۰/۰۳۵۹	۰/۰۴۹۲
D16	۳	Sym3	۱۲-۷-۱	۰/۷۰	۰/۴۰	۰/۰۵۰۲	۰/۱۱۲۰
D17	۴	Sym3	۱۵-۶-۱	۰/۷۳	۰/۴۲	۰/۰۴۸۰	۰/۱۰۶۹



شکل ۵: سیگنال اصلی بارش



شکل ۶: زیر سیگنال‌های سری زمانی بارش با موجک مادر Sym3 با درجه تجزیه ۲




شکل ۷: بارش محاسبه‌ای در مقابل مشاهده‌ای، الف: مدل سیستم استنتاج فازی- عصبی تطبیقی و ب: مدل ترکیبی موجک- شبکه عصبی

با توجه به مقادیر پیش‌بینی شده و از شکل ۷ این نتیجه بدست می‌آید که مدل ترکیبی در برآورد مقادیر حداقل موفق‌تر از مدل استنتاج فازی بوده است. با مقایسه مقادیر حداکثر نیز این نتیجه به دست می‌آید که مدل ترکیبی موفق بوده است. به‌طور کلی مدل ترکیبی موجک شبکه عصبی موفق‌تر از مدل استنتاج فازی بوده و قابلیت خوبی در برآورد مقادیر حدی دارد. در پایان بهترین ساختار از مدل شبکه عصبی با بهترین ساختار از مدل ترکیبی مورد مقایسه قرار گرفت که نتایج آن در جدول ۵ ارائه شده است همچنین مقادیر بارش مشاهده‌ای با بارش‌های پیش‌بینی شده توسط هر دو مدل در شکل ۸ نشان داده است.

جدول ۵: مقایسه مدل‌های مورد استفاده

مدل	مرحله آموزش				مرحله شبیه‌سازی			
	RMSE	R <sup>2</sup>	CE	AIC	RMSE	R <sup>2</sup>	CE	AIC
موجک- شبکه عصبی	۰/۳۵۹	۰/۸۵	۰/۸۵	۱۶۲/۹	۰/۴۹۱	۰/۸۰	۰/۸۳	۱۶۲/۹
استنتاج فازی	۰/۴۵۳	۰/۷۶	۰/۶۳	۱۸۱/۷۲	۰/۶۳۲	۰/۶۵	۰/۶۲	۱۸۱/۷۲

از آنجا که هر چه شاخص ضریب بهره‌وری یا ضریب نش ساتکلیم بیشتر باشد آن مدل بهتر می‌باشد برای ضریب تعیین نیز همین مطلب صادق است. با توجه به نتایج جدول ۵ این نتیجه حاصل می‌شود که مدل ترکیبی عملکرد بهتری داشته است. از آنجا هر چه شاخص با آکائیک و جذر میانگین مربعات خطا کمتر باشند مدل مناسب‌تر است این نتیجه حاصل می‌شود که مدل ترکیبی بهتر بوده چون شاخص آکائیک و جذر میانگین مربعات خطای کمتری دارد.



شکل ۸: مقایسه نتایج مدل‌های مورد استفاده

نتایج این تحقیق با نتایج Nourani و همکاران (۲۰۰۹) در پیش‌بینی فرآیندهای هیدرولوژیکی، که قابلیت آنالیز موجکی را بررسی کردند کاملاً منطبق می‌باشد. عبقری (۱۳۸۷) نیز نشان داد که تجزیه سیگنال‌ها با استفاده از تحلیل

گسسته موجکی الگوهای بارش رواناب، موجب افزایش دقت بیشتری نسبت به سایر روش‌های به کار گرفته شده می‌شود که با نتایج این تحقیق مبنی بر تجزیه مستقیم امواج بارندگی ماهانه همخوانی دارد.

### نتیجه‌گیری

در این تحقیق از مدل ترکیبی موجک- شبکه عصبی و مدل سیستم استنتاج فازی عصبی تطبیقی برای پیش‌بینی بارش ایستگاه وراینه استفاده شد. نتایج حاصل نشان داد که تجزیه سیگنال با موجک همبستگی میان داده‌های مشاهده‌ای و محاسبه‌ای را نسبت به مدل سیستم استنتاجی فازی به طور قابل ملاحظه‌ای افزایش می‌دهد و پیش‌بینی سیگنال بارش با دقت بیشتری صورت می‌گیرد. همان طوری که از بررسی ساختارهای مختلف در این تحقیق برداشت شد می‌توان نتیجه گرفت که مدل ترکیبی موجک- شبکه عصبی نسبت به مدل سیستم استنتاج فازی عصبی تطبیقی دارای دقت بیشتری است. این به دلیل این است که روی میزان اثر داده‌های سری زمانی قبل از ورود به شبکه تفکیک‌پذیری صورت می‌گیرد. در مدل ترکیبی از سه موجک مادر استفاده شد که موجک مادر Sym3 در مقایسه با دیگر موجک‌های مادر (یعنی Haar و Db4) عملکرد بهتری داشت. با بررسی ساختارهای مختلف، این نتیجه حاصل شد که افزایش تعداد نرون‌های لایه میانی دلیلی برای بهتر شدن نتیجه مدل نیست به طوری که در این تحقیق در تمامی ساختارهای برتر تعداد نرون‌های لایه میانی کم‌تر از ۱۰ بوده است یعنی با تعداد نرون‌های کمتر هم می‌توان انتظار داشتن نتایج مطلوب را داشت. به طور کلی از این تحقیق این نتیجه حاصل شد که مدل ترکیبی در برآورد نقاط حدی به خوبی عمل می‌کند در حالی که مدل سیستم استنتاج فازی در برآورد نقاط حدی عملکرد خوبی نداشت. در این تحقیق از داده‌های رطوبت نسبی و دما نیز علاوه بر بارش استفاده شد که در ساختارهای برتر هر دو مدل مشاهده شد که پارامترهای رطوبت نسبی و دما باعث بهتر شدن نتایج مدل‌سازی شده است پس پیشنهاد می‌شود در مطالعات پیش‌بینی بارش علاوه بر پارامتر بارش از دو پارامتر دما و رطوبت نسبی نیز استفاده شود. همچنین پیشنهاد می‌شود در بررسی عملکرد مدل ترکیبی این مدل با مدل ترکیبی موجک- سیستم استنتاج فازی عصبی تطبیقی نیز مورد مقایسه قرار گیرد.

### منابع

- طوفانی، پ.، مساعدی، ا. و فاخری فرد، ا. (۱۳۹۰). پیش‌بینی بارش با استفاده از نظریه موجک. نشریه آب و خاک (علوم و صنایع کشاورزی). (۵)۲۵:ص: ۱۲۲۶-۱۲۱۷.
- کماسی، م. (۱۳۸۶). مدلسازی بارش- رواناب با استفاده از مدل ترکیبی موجک- شبکه‌عصبی مصنوعی. پایان نامه کارشناسی ارشد. دانشگاه تبریز. ص: ۷۸-۸۷.

عبقری، ه. (۱۳۸۷). بررسی روش‌های پیش‌بینی هوشمند مبتنی بر شبکه‌های عصبی موجکی و مدل‌های خود همبستگی

دبی ماهانه رودخانه. پایانه نامه دکتری آبخیزداری- منابع آب. دانشگاه تهران. ص. ۵۶.

عراقی نژاد، ش. و کارآموز، م. (۱۳۸۴). پیش‌بینی بلند مدت رواناب با استفاده از شبکه‌های عصبی مصنوعی و سیستم -

استنتاج فازی. تحقیقات منابع آب ایران. سال یکم شماره ۲. ص ۴۱-۲۹.

نورانی، و. کی‌نژاد، م. و ملکانی، ل. (۱۳۸۸). استفاده از سیستم فازی- عصبی تطبیقی در مدل‌سازی بارش- رواناب.

نشریه مهندسی عمران و محیط زیست. (۴) ۳۹. ص: ۷۵-۸۱.

**Asadi, S., Shahrabi, J., Abbaszadeh, P. and Tabanmehr, S. (2013).** A New Hybrid Artificial Neural Networks for Rainfall-Runoff Process Modeling. *Neurocomputing*: pp: 05-23.

**Fofola-Georgiou. and Kumar, E. (1995).** Wavelet in geophysics. Academic New York.

**Jang, J. S. R., Sun, C. T. and Mizutani, E. (1997).** Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice-Hall International. New Jersey.

**Kisi, Ö. (2009).** Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology* 372(1-4), pp: 68-79.

**Mallat, S. G. (1998).** A wavelet tour of signal processing, San Diego.

**Nayak, P. C., Sudheer, K. P., Rangan, D. M. and Ramasastri, K. S. (2004).** A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology* 291(1-2): pp: 52-66.

**Nourani, V., Alami, M. T. and Aminfar, M. H. (2009).** A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence* 22, 3, pp: 466-472.

**Nourani, V., Komasi, M. and Mano, A. (2009).** A Multivariate ANN-Wavelet Approach for Rainfall-Runoff Modeling. *Water Resour Manage* 23, pp: 2877-2894.

**Nourani, V., Kisi, Ö. and Komasi, M. (2011).** Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology* 402, pp: 41-59.

**Nourani, V and Komasi, M. (2013).** A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology* 490, pp: 41-55.

**Nourani, V and Parhizkar, M. (2013).** Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for rainfall-runoff modeling. *Journal of Hydroinformatics* 15, 3, pp: 829-848.

**Riad, S., J. Mania., L. Bouchaou and Najjar, Y. (2004).** Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling* 40(7-8), pp: 839-846.



**Ross, T. J. (1995).** Fuzzy logic with engineering application. McGraw Hill Inc., USA.

**Talei, A., Chua, L. H. C. and Wong, T. S. W. (2010).** Evaluation of rainfall and discharge inputs used by Adaptive Network-based Fuzzy Inference Systems (ANFIS) in rainfall-runoff modeling. *Journal of Hydrology* 391(3-4), pp: 248-262.