

## پیش‌بینی تراز سطح آب با استفاده از مدل ترکیبی پویایی سیستم و شبکه عصبی فازی موجکی

مهدی کماسی\*<sup>۱</sup>، ندا قشلاقی<sup>۲</sup>، سروش شرقی<sup>۳</sup>

<sup>۱</sup> دانشیار گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی، دانشگاه آیت‌اله العظمی بروجردی<sup>(د)</sup>، بروجرد

<sup>۲</sup> دانش‌آموخته کارشناسی ارشد سازه‌های آبی، دانشگاه بوعلی سینا، همدان

<sup>۳</sup> دانشجوی کارشناسی ارشد گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی، دانشگاه آیت‌اله العظمی بروجردی<sup>(د)</sup>، بروجرد

دریافت: ۱۳۹۶/۱/۲۷، پذیرش: ۱۳۹۶/۹/۱۹، نشر آنلاین: ۱۳۹۶/۹/۱۹

### چکیده

چالش منابع آب امروزه مشکل بسیاری از کشورهای خاورمیانه است و این واقعیت در مورد دریاچه ارومیه که تراز سطح آب آن، با توجه به تغییرات بارش، خشک‌سالی و سدسازی دچار تغییرات و نوسانات زیادی شده است، دارای اهمیت بیشتری می‌باشد. هدف اصلی این مقاله بررسی قابلیت روش پویایی سیستم، SD (System Dynamic)، برای پیش‌بینی نوسانات سطح آب با استفاده از شبکه عصبی فازی تطبیقی موجکی، WANFIS (Wavelet Adaptive Neuro-Fuzzy Inference Systems)، می‌باشد. به همین دلیل، یک مدل شبیه‌سازی بر پایه پویایی سیستم برای حوضه آبریز دریاچه ارومیه توسعه داده شد. سپس، برای پیش‌بینی سطح آب، عوامل مؤثر بر آن مانند بارش، دبی و تبخیر با استفاده از مدل WANFIS پیش‌بینی شده و نتایج حاصل از پیش‌بینی وارد مدل پویایی سیستم می‌گردد و سپس سطح آب محاسبه می‌شود. نتایج مدل‌سازی نشان داد که مدل ترکیبی پویایی سیستم و شبکه عصبی فازی تطبیقی موجکی (SD-WANFIS) دارای عملکرد مناسبی می‌باشد. مقادیر شاخص‌های آماری مانند جذر میانگین مربعات خطا و ضریب تبیین برای مدل ترکیبی پویایی سیستم و شبکه عصبی فازی موجکی در مرحله صحت‌سنجی به ترتیب ۰/۳۱ متر و ۰/۸۴ می‌باشد. درحالی‌که این شاخص‌ها برای مدل جعبه سیاه خطی خود همبسته میانگین متحرک تلفیق شده، ARIMA (Auto Regressive Integrated Moving Average) برابر ۰/۶۱ متر و ۰/۵۳ می‌باشند. این نتایج نشان داد که ترکیب این دو مدل SD و مدل فازی WANFIS جهت پیش‌بینی با دقت مناسب، مفید می‌باشد.

**کلیدواژه‌ها:** پویایی سیستم، موجک، شبکه عصبی فازی تطبیقی، پیش‌بینی تراز سطح آب، دریاچه ارومیه.

### ۱- مقدمه

در سیستم‌های تأمین آب، رابطه بیلان جرم در شبیه‌سازی جریان ورودی و خروجی منابع آب توسط کاربران استفاده می‌شود. واضح است که اگر بنا باشد که یک مدل شبیه‌سازی، سطح آب را پیش‌بینی نماید، به شبیه‌سازی و پیش‌بینی متغیرهای هیدرولوژیکی مؤثر بر سطح آب نیاز دارد. به همین دلیل، اگرچه روش پویایی سیستم دارای قابلیت مدل‌سازی سیستم با دقت بالا می‌باشد، اما به پیش‌بینی مقادیر متغیرهای ورودی به مدل و خروجی از مدل نیاز دارد. پیش‌بینی متغیرهای هیدرولوژیکی همواره مورد توجه محققان بوده است و در این زمینه مدل‌های زیادی برای پیش‌بینی سری‌های زمانی و بهبود پیش‌بینی‌های هیدرولوژیکی ارائه شده است (Wang، ۲۰۰۹).

یکی از روش‌هایی که امروزه به‌طور گسترده در پیش‌بینی سری‌های زمانی استفاده می‌شود، مدل‌های جعبه سیاه است.

چالش منابع آب در جهان دارای اهمیت بسیاری است و به تصمیم‌گیری جامع و یکپارچه جهت طرح‌های توسعه منابع آب و برنامه‌ریزی‌های آینده نیاز دارد. یکی از ابزارهای مدیریتی رویکرد پویایی سیستم (SD) می‌باشد. این تکنیک روشی شیء‌گرا است که سیستم‌هایی دارای بازخوردهای پیچیده را مطالعه و مدیریت می‌کند و در بسیاری از مطالعات زیست‌محیطی و منابع آب استفاده شده است (Winz و همکاران، ۲۰۰۹؛ Gastelum و همکاران، ۲۰۱۰؛ Hassanzadeh و همکاران، ۲۰۱۲؛ Nozari و همکاران، ۲۰۱۴). همچنین از این روش برای نشان دادن رابطه بین بیش از دو متغیر در سیستم، استفاده می‌شود (Simonovic و Ahmad، ۲۰۰۲؛ Serman، ۲۰۰۰).

فرایند ریاضی برای تجزیه یک سیگنال به چند سطح از جزئیات و سپس تحلیل آن‌ها می‌باشد. از طرفی با توجه به توانایی ANFIS در مدل‌سازی فرآیندهای هیدرولوژیکی که معمولاً درجه‌ای از عدم قطعیت را دربر دارد، روش ترکیبی جدیدی مبتنی بر آنالیز موجک و شبکه عصبی- فازی تطبیقی (WANFIS) برای مدل‌سازی هیدرولوژیکی چند متغیره پیشنهاد شده است (Nourani و همکاران، ۲۰۱۱). این مدل در مطالعات اخیر مانند پیش‌بینی بارش - رواناب (Nourani و همکاران، ۲۰۱۱)، بارش (Partal و Kisi، ۲۰۰۷) و رسوب در مخزن سد (Alizadeh و همکاران، ۲۰۱۵) مورد استفاده و ارزیابی قرار گرفته است.

هدف از این پژوهش پیش‌بینی سطح آب دریاچه ارومیه با استفاده از ترکیب روش‌های SD و WANFIS می‌باشد که در آن، روش پویایی سیستم جهت شبیه‌سازی حوضه آبریز دریاچه ارومیه استفاده شده است. سپس متغیرهای هیدرولوژیکی مؤثر بر تراز آب دریاچه مثل بارش و دبی و تبخیر با استفاده از روش WANFIS برای پیش‌بینی دقیق‌تر تراز در آینده، پیش‌بینی شدند. پس از آن، نتایج به‌دست‌آمده از مدل WANFIS وارد مدل شبیه‌سازی SD شد و تراز آب دریاچه ارومیه محاسبه گردید.

در ادامه، نخست روش مطالعه و مدل‌سازی بیان گردیده و پس از آن، منطقه مورد مطالعه معرفی شده است. نتایج حاصل از مدل‌سازی و نتیجه‌گیری تحقیق در بخش‌هایی ارائه گردیده است.

## ۲- روش تحقیق

### ۲-۱- روش پویایی سیستم (SD)

روش پویایی سیستم ابتدا توسط Forrester (۱۹۶۱) به منظور درک بهتر مسائل استراتژیک در سیستم‌های پویای پیچیده ابداع گردید. با استفاده از این روش می‌توان رفتار سیستم را از طریق توجه به مکانیسم‌های اولیه، قسمت‌های اصلی و روابط مهم بین بخش‌های مختلف سیستم شناسایی نمود (Ghashghaei، ۲۰۱۳). با توجه به ضرورت تجزیه و تحلیل سیستم‌ها و مشکلات متعدد منابع آب، در این مطالعه، از محیط برنامه‌نویسی Vensim که یک ابزار برای مدل‌سازی سیستم به‌روش پویا است، استفاده شد. پس از فرموله کردن فرضیه‌های دینامیکی و تشخیص متغیرهای کلیدی و روابط آن‌ها، سیستم‌های متغیر برون‌زا و درون‌زا مشخص شده است تا بتواند ورودی‌ها و خروجی‌های سیستم را محاسبه کند.

مدل‌های جعبه سیاه مانند مدل خود همبسته میانگین متحرک تلفیق شده (ARIMA) و یا مدل خود همبسته میانگین متحرک تلفیق شده فصلی (SARIMA)<sup>۱</sup> به‌طور گسترده‌ای برای پیش‌بینی سری‌های زمانی هیدرولوژیکی استفاده می‌شود (Salas و همکاران، ۱۹۸۰؛ Nourani و همکاران، ۲۰۱۱).

این مدل‌ها اساساً خطی هستند و در آن‌ها فرض بر ایستا بودن داده‌ها می‌باشد و توانایی آن‌ها در مدل‌سازی داده‌های ناپایستا و غیرخطی هیدرولوژیکی محدود است. اخیراً روش‌های هوش مصنوعی (AI)<sup>۲</sup> توانایی زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی غیرخطی نشان داده‌اند. تکنیک‌های هوش مصنوعی روش مؤثری برای بررسی داده‌های پویا، غیرخطی و پراشوب، به‌ویژه هنگامی که روابط فیزیکی به‌طور کامل مشخص نشده است، می‌باشد (Nourani و همکاران، ۲۰۱۱).

استفاده از مدل‌های شبکه عصبی مصنوعی (ANN)<sup>۳</sup> با یک هسته غیرخطی برای بازسازی سیگنال، رفتار غیرخطی پدیده‌ها را نسبت به مدل‌های خطی مانند آریمای<sup>۴</sup> فصلی بهتر شبیه‌سازی می‌کند (Nourani و همکاران، ۲۰۱۴). روش قدرتمند دیگر هوش مصنوعی برای مدل‌سازی سیستم‌های غیرخطی، ترکیب منطق فازی و شبکه‌های عصبی می‌باشد که شبکه عصبی- فازی نامیده می‌شود. در رویکرد عصبی- فازی، قابلیت بررسی عدم قطعیت سیستم‌های فازی و قابلیت یادگیری شبکه‌های عصبی برای پیش‌بینی بهتر ترکیب شده‌اند.

شکل خاصی از سیستم‌های عصبی- فازی، سیستم عصبی فازی تطبیقی (ANFIS)<sup>۵</sup> است که برای پیش‌بینی سطح آب در مخزن استفاده شد (Chang و Chang، ۲۰۰۶). زمانی که تغییرات سیگنال بسیار ناپایستا و فیزیکی هستند، عملکرد فرآیندهای هیدرولوژیکی تحت طیف وسیعی از مقیاس قرار دارد و اگر پیش- پردازشی بر روی داده‌های ورودی یا خروجی صورت نگیرد، مدل‌های ANN و ANFIS، ممکن است نتوانند الگوی حاکم بر داده‌ها را به‌خوبی تشخیص دهند. در این وضعیت، تبدیل موجک به‌عنوان یک رویکرد پیش‌پردازش داده ممکن است مشکل را حل کند (Nourani و همکاران، ۲۰۱۱).

آنالیز موجک<sup>۶</sup> ابزار مؤثری برای برخورد با داده‌های ناپایستا است و اخیراً در پیش‌بینی‌های هیدرولوژیکی استفاده شده است (Adamowski و Belayneh، ۲۰۱۲). تجزیه سری‌های زمانی ناپایستا به مقیاس‌های مختلف، بر اساس تئوری موجک، امکان تفسیر ساختار سری‌ها و اطلاعات مهم مربوط به تاریخچه آن‌ها در دو حوزه زمان و فرکانس را با استفاده از ضرایبی، فراهم می‌کند (Nourani و همکاران، ۲۰۱۲). مزیت روش موجک ایجاد یک

4. Arima  
 5. Adaptive Neuro-Fuzzy Inference Systems  
 6. Wavelet Analysis

1. Seasonal Auto Regressive Integrated Moving Average  
 2. Artificial Intelligence  
 3. Artificial Neural Network

۲-۲- شبکه عصبی فازی تطبیقی (ANFIS)

شبکه عصبی فازی تطبیقی (ANFIS) یک شبکه پیشرو پنج لایه است که قوانین تصمیم‌گیری فازی و عملکرد خوب در هر زمینه را بررسی می‌کند. چند سیستم استنتاج فازی از جمله سوگنو<sup>۷</sup> و ممدانی<sup>۸</sup> می‌تواند برای این هدف به کار گرفته شود. هر سیستم فازی شامل سه بخش اصلی فازی‌سازی داده‌ها، پایگاه داده‌های فازی و برگرداندن داده‌ها به حالت اولیه است. پایگاه داده‌های فازی شامل دو بخش اصلی است: پایگاه قوانین و سیستم استنتاج فازی. در پایگاه قوانین فازی، قواعد مربوط به گزاره‌های فازی و توصیف آن‌ها وجود دارد (Jang و همکاران، ۱۹۹۷). هدف یادگیری استفاده از داده‌های آموزشی ورودی و خروجی است. فازی‌سازی داده‌های ورودی با استفاده از توابع عضویت (MFS) انجام می‌شود، که با استفاده از یک رابطه غیرخطی داده‌های ورودی در بازه [۰ و ۱] قرار می‌گیرند. ANFIS پارامترهای یک سیستم فازی را با استفاده از ترکیب روش حداقل مربعات و الگوریتم پس انتشار خطا برای آموزش سیستم استنتاج فازی تنظیم می‌کند.

پایه و اساس معماری ANFIS که دارای دو ورودی  $x$  و  $y$  و یک خروجی  $F$  است، در شکل (۱) نشان داده شده است. فرض پایه شامل دو قانون اگر-آنگاه، تاکاجی<sup>۹</sup>- سوگنو است که به شرح زیر می‌باشد:

- Rule 1: If  $x$  is  $A_1$  and  $y$  is  $B_1$  Then  $f_1 = p_1 x + q_1 y + r_1$   
Rule 2: If  $x$  is  $A_2$  and  $y$  is  $B_2$  Then  $f_2 = p_2 x + q_2 y + r_2$

که در آن  $A_1, A_2$  و  $B_1, B_2$  توابع عضویت برای ورودی‌های  $x$  و  $y$  هستند و  $p_1, q_1, r_1$  و  $p_2, q_2, r_2$  پارامترهای تابع خروجی می‌باشد. عملکرد ANFIS به شرح زیر است (شکل (۱)).

لایه (۱) هر گره در این لایه درجه عضویت متغیر را تعیین می‌کند:

$$\begin{aligned} Q_i^1 &= \mu_{A_i}(x) & i &= 1, 2 \\ Q_i^1 &= \mu_{B_{i-2}}(y) & i &= 3, 4 \end{aligned} \quad (1)$$

که در آن  $X$  ورودی به گره  $i$  است، و  $A_i$  متغیر زبانی (بزرگ، کوچک، و ...) است. خروجی از گره  $i$ -ام در لایه  $K$ -ام به صورت  $Q^k$  نشان داده می‌شود. با فرض یک تابع زنگوله‌ای به عنوان تابع عضویت، خروجی  $Q_i^1$  می‌تواند محاسبه شود:

$$Q_i^1 = \mu_{A_i}(x) = \exp\left(-\frac{(x-c)^2}{\sigma}\right) \quad (2)$$

که در آن  $\{c, \sigma\}$  متغیرهای تطبیقی هستند و به عنوان پارامترهای فرض شناخته می‌شوند.

لایه (۲) هر گره در این لایه به سیگنال‌های ورودی تکثیر می‌شود:

$$Q_i^2 = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1, 2 \quad (3)$$

لایه (۳) گره  $i$ -ام از این لایه ضریب نرمال شده را محاسبه می‌کند (Sun و Jang، ۱۹۹۵):

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (4)$$

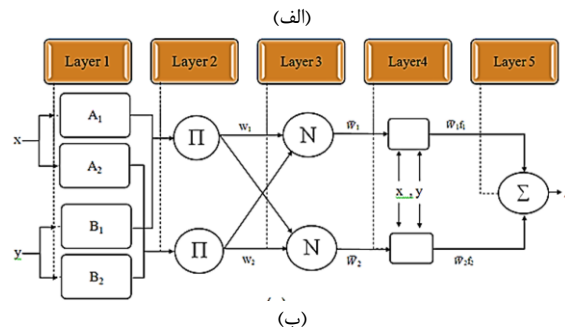

لایه (۴) گره  $i$ -ام چگونگی مشارکت قانون  $i$ -ام را در خروجی مدل، محاسبه می‌کند:

$$Q_i^4 = \bar{w}_i f_i = (p_i x + q_i y + r_i) \quad (5)$$

که در آن  $\bar{w}_i$  خروجی لایه سوم و  $\{r_i, q_i, p_i\}$  پارامترهای تنظیمی هستند.

لایه (۵) در لایه آخر خروجی نهایی و کلی ANFIS به صورت زیر محاسبه می‌گردد (Sun و Jang، ۱۹۹۵):

$$Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$



شکل ۲- مکانیزم قوانین سیستم فازی تاکاجی- سوگنو و ساختار معادل ANFIS (Nourani و همکاران، ۲۰۱۲)

الگوریتم یادگیری مدل ANFIS ترکیبی از روش گرادیان نزولی و روش حداقل مربعات است. پارامترهایی که باید در روند مدل ANFIS بهینه‌سازی شوند پارامترهای مقدم  $\{c_i, b_i, a_i\}$  و پارامترهای تالی  $\{r_i, q_i, p_i\}$  می‌باشند. در رویکرد ترکیبی یادگیری انتقال رو به جلو، خروجی‌های گره تا لایه (۴) می‌رود و

10. Premise  
11. Consequent

7. Sugeno  
8. Mamdani  
9. Takagi

ممکن است در آینده قابل قبول یا غیرقابل قبول باشند (Nourani و همکاران، ۲۰۱۲؛ Addison و همکاران، ۲۰۰۱).

تبدیل موجک پیوسته (CWT)<sup>۱۲</sup> زنجیره‌ای از تمام مقیاس‌ها به‌عنوان خروجی تولید می‌کند. هر مقیاس مربوط به پهنای موجک است؛ از این رو، مقیاس بزرگ‌تر بدان معنی است که از سری‌های زمانی بیشتری در محاسبه ضریب، نسبت به مقیاس کوچک‌تر استفاده شده است. با این حال، با توجه به پیچیدگی و زمان موردنیاز برای محاسبه، معمولاً برای پیش‌بینی استفاده نمی‌شود. به‌جای آن، موجک‌های گسسته اغلب به‌طور مجزا در پیش‌بینی برنامه‌های کاربردی محاسبات عددی استفاده می‌شود. تبدیل موجک گسسته (DWT)<sup>۱۳</sup> به زمان کم‌تری برای محاسبات نیاز دارد و در پیاده‌سازی ساده‌تر است. مقیاس‌ها و موقعیت‌های DWT معمولاً بر اساس دو ویژگی است (مقیاس‌ها و موقعیت‌های دوتایی) و با اصلاح نمایش موجک به‌دست می‌آید (Cannas و همکاران، ۲۰۰۶).

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (9)$$

که در آن  $m$  و  $n$  اعداد صحیحی هستند که مقیاس و انتقال را کنترل می‌کنند.  $a_0$  حدود مقیاس را که بیشتر از ۱ است و  $b_0$  پارامتر مکان که باید بزرگ‌تر از صفر باشد مشخص می‌کنند. معمولی‌ترین و ساده‌ترین انتخاب برای پارامترها  $a_0 = 2$  و  $b_0 = 1$  می‌باشد.

تبدیل موجک گسسته دو مجموعه از توابع را اجرا می‌کند: فیلترهای بالاگذر و پایین‌گذر. سری زمانی اصلی از میان فیلترهای بالاگذر و پایین‌گذر عبور می‌کند و ضرایب دقیق و تقریبی به‌دست می‌آیند. یکی از چالش‌های اصلی در استفاده از DWT برای پیش‌بینی متغیر بودن ضرایب است (به‌عنوان مثال اگر مقادیر ابتدایی سری‌های زمانی تغییر کنند، همه ضرایب موجک تغییر خواهند کرد). برای غلبه بر این مشکل، یک الگوریتم اضافی، که به‌عنوان الگوریتم تروس<sup>۱۴</sup> شناخته شده، می‌تواند مورد استفاده قرار گیرد (Mallat، ۱۹۹۸):

$$c_{i+1}(k) = \sum_{l=-\infty}^{+\infty} h(l)c_i(k + 2^i l) \quad (10)$$

که در آن  $h$  فیلتر پایین‌گذر است و بهترین مقیاس سری زمانی اصلی است. برای استخراج جزئیات  $w_i(k)$  که در رابطه (۱۰) حذف شدند، نسخه هموار شده سیگنال که از سیگنال بزرگ اولیه، حذف شده، توسط مالات ارائه شده است (Mallat، ۱۹۹۸):

متعاقباً پارامترها با روش حداقل مربعات شناخته می‌شوند. در انتقال رو به عقب، سیگنال‌های خطا به عقب منتشر می‌شوند و پارامترهای فرض توسط گرادپان نزولی محاسبه می‌شوند.

### ۲-۳- تبدیل موجک (Wavelet Transform)

تبدیلات موجک توابع ریاضی کارآمدی در زمینه تجزیه و تحلیل سری‌های زمانی ناپایستا هستند و استفاده از فواصل زمانی طولانی مدت را برای اطلاعات فرکانس پایین و فواصل زمانی کوتاه‌تر را برای اطلاعات فرکانس بالا ارائه می‌دهد. تبدیل موجک قادر به نمایش جنبه‌های مختلف داده مانند روند، نقاط شکست، و ناپیوستگی هستند که ممکن است دیگر تکنیک‌های تجزیه و تحلیل سیگنال‌ها قادر به تشخیص آن‌ها نباشند. مزیت دیگر تحلیل موجک توانایی انتخاب موجک مادر با توجه به بررسی ویژگی‌های سری زمانی است (Adamowski و Belayneh، ۲۰۱۲). اولین گام در آنالیز موجک انتخاب موجک مادر است. تابع موجک  $\psi(t)$  موجک مادر نامیده می‌شود، که دارای خاصیت نوسانی است و می‌تواند به سرعت به صفر کاهش پیدا کند و می‌توان آن را به‌عنوان تابع ریاضی  $\int_{-\infty}^{+\infty} \psi(t) dt = 0$  تعریف نمود.  $\psi_{a,b}(t)$  را می‌توان از طریق فشرده و کشیده شدن (نوسانی) به‌دست آورد (Wang و Ding، ۲۰۰۳):

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad b \in R, a \in R, a \neq 0 \quad (7)$$

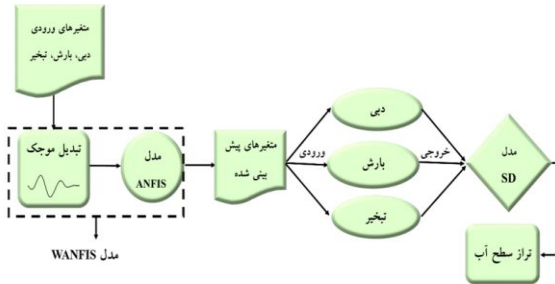
تبدیل موجک پیوسته سری‌های زمانی در رابطه (۸) تعریف شده است:

$$x(b, a) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (8)$$

که در آن  $X(b, a)$  طیف موجک،  $\psi(t)$  یک تابع موجک و "\*" نشان‌دهنده مزدوج مختلط است، پارامتر  $a$  به‌عنوان عامل مقیاس، و  $b$  مربوط به انتقال می‌باشد، زمانی  $\psi(t)$  که امکان بررسی سیگنال را در اطراف  $b$  می‌دهد (Kwon و همکاران، ۲۰۰۷).

تبدیل موجک همبستگی بین سیگنال و تابع موجک را بررسی می‌کند. این محاسبه در مقیاس‌های مختلفی از  $a$  و به‌صورت مکانی در سراسر زمان  $b$  انجام می‌شود. در واقع، تجزیه موجک شامل محاسبه "شاخص شباهت" بین سیگنال و موجک واقع در موقعیت  $b$  و مقیاس  $a$  می‌شود. اگر شاخص بزرگ باشد، شباهت زیاد است در غیر این صورت اندک است. رابطه گسسته رابطه (۸) بر اساس قانون دوزنقه‌ای است که ساده‌ترین روش گسسته‌سازی است. این تبدیل ضریب  $N^2$  را از مجموعه داده‌ها به طول  $N$  تولید می‌کند. بنابراین، اطلاعات اضافی در ضرایب نگهداری می‌شوند که

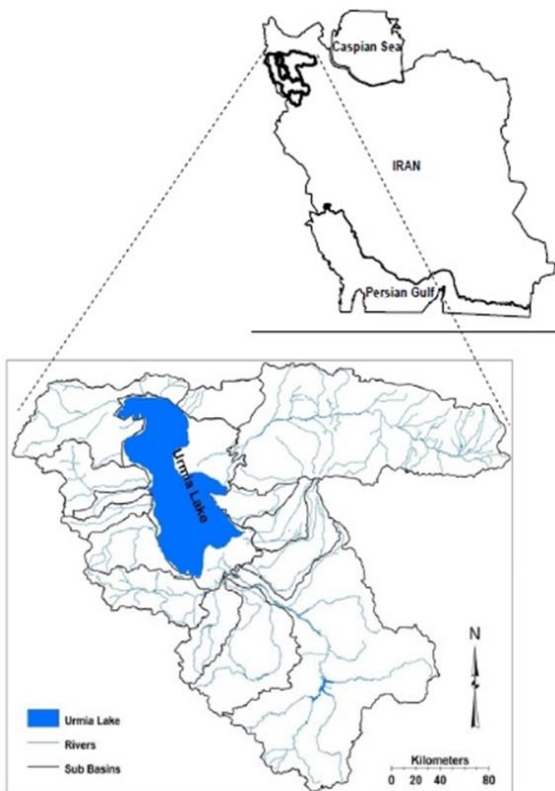
پیش‌بینی مورد استفاده قرار گرفتند. پس از آن، نتایج پیش‌بینی متغیرهای هیدرولوژیکی وارد مدل SD شده و تراز سطح آب محاسبه می‌گردد (شکل (۴)).



شکل ۴- نمودار مدل SD-WANFIS

### ۲-۶- مطالعه موردی

دریاچه ارومیه در شمال ایران واقع شده است (شکل (۵)). مساحت حوضه دریاچه حدود ۵۱/۸۷۶ کیلومترمربع است که ۳/۱۵ درصد کل مساحت کشور است و ۷ درصد از آب سطحی کشور را شامل می‌شود (Mohebbi و Eimanifar، ۲۰۰۷). دریاچه ارومیه بیستمین دریاچه بزرگ و دومین دریاچه شور جهان است. همه رودخانه‌های حوضه به دریاچه ارومیه می‌ریزند. مهم‌ترین رودخانه‌ها زرینه‌رود، سیمینه‌رود و آجی‌چای هستند.



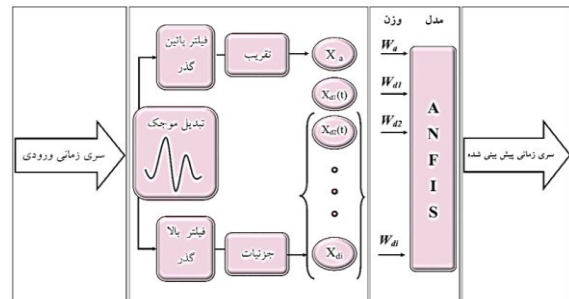
شکل ۵- موقعیت دریاچه ارومیه در ایران

$$w_i(k) = c_{i-1}(k) - c_i(k) \quad (11)$$

که تقریبی از سیگنال و سیگنال بزرگ است. در هر بار استفاده از معادلات (۱۰) و (۱۱) یک تقریب هموار و یک سطح بالاتری از جزئیات ایجاد می‌شود.

### ۲-۴- سیستم شبکه عصبی- فازی- موجکی (WANFIS)

ترکیب موجک و سیستم عصبی فازی تطبیقی بر پایه مؤلفه‌های زیر سری‌هایی است که از استفاده از تبدیل موجک حاصل شده است. در واقع، جزئیات (D) و تقریب‌های زیرسری‌ها (A) می‌توانند به‌عنوان ورودی به ساختار ANFIS که در شکل (۳) نشان داده شده، وارد شوند. در این مدل‌سازی، داده‌های پیش‌پردازش شده (توسط تبدیل موجک) به مدل ANFIS وارد می‌شوند. برای این منظور، تبدیل موجک گسسته استفاده شده است. در نتیجه فرایند تحلیل موجکی داده‌ها در مقیاس‌های زمانی مختلف (سطح) ویژگی‌های دراز مدت ( $X_n$ ) و کوتاه‌مدت سیگنال ( $X_{di}$ ) از هم جدا شوند. مدل WANFIS ارائه‌شده شامل ۵ لایه که بر اساس قانون سوگنو است، می‌باشد. در لایه اول زیر سری‌های فازی بارش، رواناب و تبخیر با استفاده از تبدیل موجک به دست آمد. برای به‌دست آوردن وزن‌های آموزش WANFIS می‌توان محاسبات غیرخطی پس انتشار خطا را به کار گرفت.



شکل ۳- معماری شماتیک سیستم شبکه عصبی- فازی- موجکی

### ۲-۵- مدل ترکیبی پویایی سیستم و شبکه عصبی فازی موجکی (SD-WANFIS)

ساختار این مدل ترکیبی دو بخش دارد. در بخش نخست مدل شبیه‌سازی تراز سطح آب دریاچه بر اساس روش پویایی سیستم در محیط نرم‌افزار Vensim توسعه داده شد. برای اجرای مدل و پیش‌بینی تراز سطح آب، پیش‌بینی متغیرهای ورودی و خروجی دریاچه از قبیل: دبی، بارش و تبخیر نیاز است. به‌همین دلیل این متغیرها با استفاده از تبدیل موجک به زیرسری‌هایی تبدیل شده و سپس به‌عنوان ورودی مدل ANFIS جهت

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (h_{obs_i} - h_{com_i})^2}{N}} \quad (12)$$

$$DC = 1 - \frac{\sum_{i=1}^N (h_{obs_i} - h_{com_i})^2}{\sum_{i=1}^N (h_{obs_i} - \bar{h}_{obs})^2} \quad (13)$$

پیش‌بینی‌شده، میانگین داده‌های مشاهداتی و تعداد ماه‌ها می‌باشند.  $N$  به ترتیب داده‌های مشاهداتی،  $h_{obs_i}$ ،  $h_{com_i}$  و  $\bar{h}_{obs}$

### ۳- نتایج و بحث

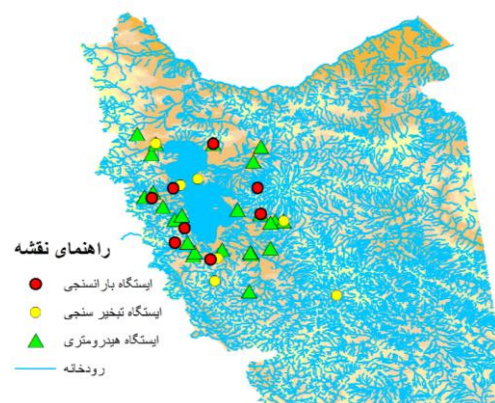
#### ۳-۱- فرایند مدل‌سازی به روش پویایی سیستم

فرایند مدل‌سازی شامل دو مرحله است. مرحله اول مدل مفهومی یا رسم نمودارهای علت- معلولی (GLD)<sup>۱۵</sup> می‌باشد. تعریف مشکل، توضیح سیستم و رسم نمودارهای علت- معلولی در این مرحله از روش پویایی سیستم انجام می‌شود. ذخیره، جریان‌ها، اتصالات و مبدل‌ها مؤلفه‌های اصلی در روش SD هستند. نمودارهای علت معلولی، علت و تأثیر آن را نشان می‌دهند. روابط علت- معلولی با دو علامت مثبت و منفی نشان داده می‌شوند. اگر علت و معلول در یک جهت تغییر پیدا کنند، رابطه علت و معلولی مثبت یا تقویت‌کننده خواهد بود و اگر عکس جهت همدیگر تغییر پیدا کنند، رابطه علت و معلولی منفی یا متعادل‌کننده خواهد بود. مرحله دوم رسم نمودار ذخیره- جریان (SFD)<sup>۱۶</sup> بر اساس نمودار مفهومی CLD است. پس از مدل‌سازی فرمول نویسی فرضیه‌های دینامیکی انجام و مدل شبیه‌سازی کامل می‌شود. سپس برای اطمینان از نتایج حاصله، مدل مورد ارزیابی قرار می‌گیرد. در این تحقیق محیط برنامه‌نویسی Vensim برای پیاده‌سازی مدل استفاده شد.

#### ۳-۲- نمودار علت- معلولی (CLD)

همان‌طور که در مدل‌سازی به روش SD اشاره شد، حلقه‌های علت- معلولی مکانیزم بازخورد را نشان می‌دهند. نمودار CLD دریاچه ارومیه طراحی و در شکل (۷) نشان داده شده است. در حلقه شماره یک با افزایش حجم دریاچه، تراز دریاچه نیز افزایش می‌یابد و با افزایش تراز دریاچه مساحت آن و متعاقباً حجم بارش نیز افزایش یافته و تشکیل حلقه مثبت می‌دهند. از طرفی در حلقه شماره دو اگر سطح دریاچه افزایش یابد مساحت بین حوضه آخرین ایستگاه‌های هیدرومتری و دریاچه ارومیه کاهش می‌یابد و با کاهش آن، حجم آب سطحی و در پی آن حجم دریاچه کاهش می‌یابد و تشکیل حلقه منفی می‌دهد. در حلقه شماره سه با افزایش حجم و سپس تراز و در پی آن افزایش مساحت، حجم

با توجه به جنبه‌های مختلف اقتصادی، اجتماعی و زیست- محیطی، دریاچه ارومیه نقش مهمی را در شمال غرب کشور بازی می‌کند که متأسفانه در دهه‌های اخیر با مشکلات زیادی مواجه شده است. خشک‌سالی‌ها، استفاده بیش از حد از آب‌های سطحی و سدسازی باعث کاهش تراز سطح آب شده‌اند. در این پژوهش، اطلاعات موردنیاز مانند: مشخصات ایستگاه‌های جغرافیایی، هواشناسی و هیدرومتری، متوسط بارش، تبخیر و دبی ماهانه به مدت ۳۴ سال (۱۳۸۸-۱۳۵۵) از سازمان مدیریت منابع آب ایران تهیه شد. ایستگاه‌های هواشناسی و هیدرومتری متعددی در حوضه دریاچه ارومیه واقع شده است که از میان آن‌ها ۲۴ ایستگاه هیدرومتری، ۸ ایستگاه باران‌سنجی و ۷ ایستگاه تبخیرسنجی برای ایجاد مدل شبیه‌سازی انتخاب شدند (شکل (۶)).



شکل ۶- ایستگاه‌های هواشناسی و هیدرومتری انتخابی حوضه دریاچه ارومیه

#### ۲-۷- معیار ارزیابی مدل‌ها

عملکرد مدل‌های گوناگون در طول دوره‌های واسنجی و صحت‌سنجی با استفاده از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE) و ضریب تبیین (DC) موردبررسی قرار گرفته شد. RMSE برای اندازه‌گیری دقت پیش‌بینی استفاده می‌شود، که یک مقدار مثبت را به‌عنوان مربع خطا تولید می‌کند. RMSE صفر برای پیش‌بینی‌های کامل و بی‌نقص است. DC میزان ارتباط بین مقادیر مشاهده‌شده و پیش‌بینی‌شده را اندازه‌گیری می‌کند. بازه مقادیر DC از صفر تا یک می‌باشد. مقدار یک رابطه مناسب و کاملی را بین داده‌های مشاهداتی و داده‌های پیش‌بینی‌شده نشان می‌دهد و صفر نشان‌دهنده عدم وجود ارتباط آماری بین آن‌ها است. بدیهی است که مقدار بالا برای DC (تا یک) و مقدار کوچک برای RMSE بازدهی بالای مدل را نشان می‌دهد (Nourani و همکاران، ۲۰۱۱).

همچنین رابطه بین سطح و تراز آب دریاچه ارومیه در رابطه (۱۶) نشان داده شده است (Tajrishy و Sima، ۲۰۱۳).

$$A = 4.67 \times 10^9 - 11.02 \times 10^6 L + 8.68 \times 10^3 L^2 - 2.28 L^3 \quad (16)$$

که در آن  $L$  تراز آب دریاچه ارومیه برحسب متر و  $A$  مساحت سطح دریاچه برحسب کیلومتر مربع است. رابطه (۱۷) ارتباط بین تراز آب دریاچه ارومیه و حجم آن را نشان می‌دهد (Tajrishy، ۲۰۱۳).

$$V = -1.48 \times 10^9 + 4.67 \times 10^6 L - 5.51 \times 10^3 L^2 + 2.98 L^3 - 5.70 \times 10^{-4} L^4 \quad (17)$$


که در آن  $L$  تراز آب دریاچه ارومیه برحسب متر و  $V$  حجم دریاچه برحسب کیلومتر مکعب است. رابطه بارش- رواناب در رابطه (۱۸) نشان داده شده است.

$$\text{runoff} = \text{MAX}(0.21 \times (\text{"Pr."} - 0.005) \times A_m, 0) \quad (18)$$

$Pr.$  بارش ماهانه برحسب متر،  $A_m$  مساحت بین دریاچه ارومیه و آخرین ایستگاه هیدرومتری نزدیک به آن می‌باشد.

### ۳-۴- نمودار ذخیره و جریان (SFD)

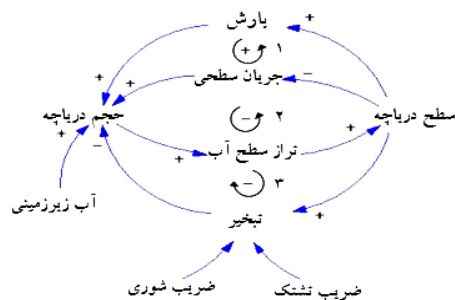
بعد از رسم نمودار CLD با استفاده از آن، نمودار ذخیره- جریان طراحی گردیده است (شکل ۸). متغیرهای تبخیر و بارش (متر بر ماه)، جریان آب سطحی و زیرزمینی (میلیون مترمکعب بر ماه) در محاسبه بیلان آب دریاچه در نظر گرفته شد.



شکل ۸- نمودار ذخیره- جریان دریاچه ارومیه

بعد از این که مدل شبیه‌سازی دریاچه ارومیه ایجاد شد، برای یک دوره ۲۵ ساله (۱۳۸۰-۱۳۵۵) به صورت ماهانه واسنجی شد. نتایج شبیه‌سازی با توجه به ضریب تبیین و جذر میانگین مربعات خطا که به ترتیب برابر ۰/۸۷ و ۰/۳۲ متر می‌باشند، نشان می‌دهد که مدل به خوبی توانسته تراز سطح آب را شبیه‌سازی کند. بعد از

تبخیر از سطح دریاچه نیز افزایش می‌یابد و همین امر باعث کاهش حجم دریاچه و تشکیل حلقه منفی می‌گردد.



شکل ۷- نمودار علت- معلولی دریاچه ارومیه

### ۳-۳- تعریف مدل

متغیرهای ذخیره حالت سیستم و متغیرهای جریان چگونگی تغییر متغیرهای ذخیره را نشان می‌دهند. برای مثال مقدار آب در یک مخزن (متغیر ذخیره) با جریان‌های ورودی و خروجی (متغیرهای جریان) تغییر پیدا می‌کند (Hassanzadeh و همکاران، ۲۰۱۲). رابطه ذخیره به شکل زیر است:

$$\text{Stock}(t) = \int_{t_0}^{t_n} [\text{Inflow}(t) - \text{Outflow}(t)] dt + \text{Stock}(t_0) \quad (14)$$

در این رابطه  $\text{Stock}(t)$  ذخیره در زمان  $t$ ،  $\text{Inflow}(t)$  جریان ورودی در زمان  $t$ ،  $\text{Outflow}(t)$  جریان خروجی در زمان  $t$  و  $\text{Stock}(t_0)$  ذخیره در زمان  $t_0$  می‌باشد. حجم دریاچه ارومیه با استفاده از رابطه (۱۵) محاسبه شده است:

$$V(t) = \int_{t_0}^{t_n} [SW(t) + R(t) + GW(t) + P(t) - E(t)] dt + V(t_0) \quad (15)$$

در این رابطه  $V(t)$  حجم دریاچه،  $SW(t)$  دبی رودخانه‌ها،  $R(t)$  رواناب،  $GW(t)$  آب زیرزمینی،  $P(t)$  بارش،  $E(t)$  تبخیر و  $V(t_0)$  حجم اولیه دریاچه است (که در آن مقادیر رواناب، بارش و تبخیر در مساحت دریاچه ضرب و به حجم تبدیل می‌شوند). متغیرهای مدل در جدول (۱) معرفی شده‌اند.

### جدول ۱- متغیرهای مدل شبیه‌سازی دریاچه ارومیه

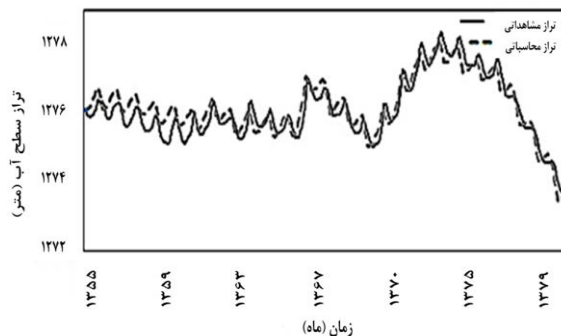
متغیر	توضیحات	واحد
دبی	جریان ورودی به دریاچه توسط رودخانه‌ها	میلیون مترمکعب بر ماه
بارش	بارش بر روی دریاچه	متر بر ماه
تبخیر	تبخیر از سطح دریاچه	متر بر ماه
آب زیرزمینی	حجم آب زیرزمینی	میلیون مترمکعب بر ماه
رواناب	رواناب ورودی به دریاچه	متر بر ماه
آلفا	ضریب تشنگ × ضریب شوری	بدون بعد

MATLAB نوشته شده، تعریف شده است. از قبیل و Meyer, Mexican hat, Morle, Symlet, Daubechies, Haar و Coiflet سپس زیرسری‌ها برای بهبود دقت پیش‌بینی ماهانه متغیرها به‌عنوان ورودی مدل ANFIS استفاده شدند.

مدل WAFIS، که شامل دو مدل مفهومی Wavelet و ANFIS می‌باشد دارای پارامترهای متعددی برای کالیبراسیون از جمله تعداد تابع عضویت (MF)، نوع تابع عضویت، تعداد سطوح تجزیه و نوع موجک مادر است. در مدل‌سازی ANFIS، دو نکته دارای اهمیت هستند و باید توجه خاص به آن‌ها شود نخست معماری ANFIS (به‌عنوان مثال، نوع و تعداد MF) و در مرحله دوم تعداد تکرار آموزش و انتخاب مناسب مدلی که بتواند بازدهی مدل را در هر دو مرحله واسنجی (آموزش) و صحت‌سنجی (آزمایش) تخمین نماید. به‌بیان‌دیگر مدل ANFIS قابلیت انتخاب بهترین و بهینه‌ترین پارامترهایی که می‌بایست توسط کاربر تعیین گردند همچون درجه تجزیه، تابع موجک و ... را دارا است. نتایج در جدول (۲) و نمودارها در شکل‌های (۱۰)، (۱۱) و (۱۲) نشان داده شده‌اند.

دقت بالای پیش‌بینی مدل WAFIS را به‌وضوح از انطباق نمودارها می‌توان مشاهده نمود. به‌خصوص در نقاط اوج سری زمانی دوره صحت‌سنجی نتایج رضایت‌بخش بوده است. پس از شبیه‌سازی بارش، دبی و رواناب برای سال‌های ۱۳۸۰-۱۳۵۵ این متغیرها برای سال‌های ۱۳۸۸-۱۳۸۰ پیش‌بینی شدند سپس نتایج پیش‌بینی وارد مدل SD شد، مدل اجرا و نتایج در شکل (۱۳) نشان داده شده است.

واسنجی مدل SD متغیر خروجی از دریاچه (تبخیر) و متغیرهای ورودی به دریاچه (دبی و بارش) با استفاده از روش WAFIS پیش‌بینی می‌شوند. سپس نتایج آن‌ها وارد مدل SD و تراز سطح آب محاسبه می‌گردد (شکل ۹).



شکل ۹- تراز سطح آب مشاهداتی و محاسباتی در مرحله واسنجی مدل SD


### ۳-۵- مدل‌سازی به روش SD-WAFIS

در این مرحله سری‌های زمانی بارش، دبی و تبخیر با استفاده از روش WAFIS به‌طور مستقل شبیه‌سازی و پیش‌بینی شدند. در فرایند مدل‌سازی داده‌ها به دو قسمت برای واسنجی و صحت‌سنجی تقسیم شدند. ۷۵٪ از داده‌ها برای واسنجی و ۲۵٪ آن‌ها برای صحت‌سنجی در نظر گرفته شد. داده‌های سری زمانی قبل از این‌که وارد شبکه شوند معمولاً در بازه (۱ و ۰) نرمال می‌شوند. موجک مادر متفاوتی برای برنامه‌ای که در محیط نرم‌افزار


جدول ۲- شاخص‌های آماری متغیرهای مورد مطالعه در مدل‌سازی به روش WAFIS

متغیر	بهترین نوع موجک مادر	بهترین تابع عضویت (MF)	بهترین درجه تجزیه	مرحله واسنجی	مرحله صحت‌سنجی
بارش	Dmey	gausmf-2	۲	DC	RMSE
دبی	Haar	gbellmf-2	۳	DC	RMSE
تبخیر	Coif1	gbellmf-3	۲	DC	RMSE


با توجه به نرمال بودن داده‌ها RMSE بدون بعد است.



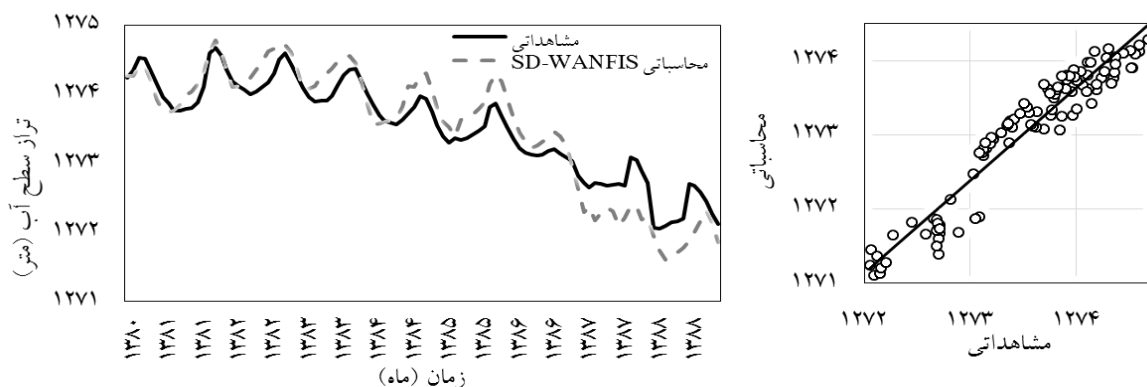
شکل ۱۰- نتایج مدل WAFIS در پیش‌بینی بارش: الف) بارش مشاهداتی و محاسباتی، ب) نمودار پراکندگی در مرحله صحت‌سنجی



شکل ۱۱- نتایج مدل WANFIS در پیش‌بینی دبی: الف) دبی مشاهده‌ای و محاسباتی، ب) نمودار پراکندگی در مرحله صحت‌سنجی



شکل ۱۲- نتایج مدل WANFIS در پیش‌بینی تبخیر: الف) تبخیر مشاهده‌ای و محاسباتی، ب) نمودار پراکندگی در مرحله صحت‌سنجی



شکل ۱۳- تراز سطح آب مشاهده‌ای و محاسباتی توسط SD-WANFIS در مرحله صحت‌سنجی

مقدار آن در ماه‌های قبل با استفاده از روش مارکوف پیش‌بینی شد. مدل ARIMA یک مدل جعبه سیاه خطی است. مدل مناسب در این روش ARIMA (4, 1, 5) است. در این روش جهت تشخیص نوع و مرتبه مدل، ضرایب خودهمبستگی ( $p$ ) و خودهمبستگی جزئی ( $q$ ) مورد بررسی قرار می‌گیرند و برای کنترل صحت مدل انتخابی، آزمون نرمال بودن و استقلال باقی‌مانده‌ها در زمان، استفاده می‌شود. شاخص‌های آماری ضریب تبیین و جذر میانگین مربعات خطا بین تراز آب مشاهده‌ای و پیش‌بینی‌شده در مدل ARIMA در جدول (۳) نشان داده شده است. نتایج مدل‌های SD-WANFIS و ARIMA در شکل (۱۴) نشان داده شده است. نتایج

شاخص‌های آماری ضریب تبیین و جذر میانگین مربعات خطا بین تراز آب مشاهده‌ای و پیش‌بینی‌شده به ترتیب ۰/۸۴ و ۰/۳۱ متر به دست آمد. قدرت تجزیه و تحلیل موجک در استخراج فرکانس غالب، و تجزیه و تحلیل فازی در بررسی عدم قطعیت پدیده‌ها توانایی مدل WANFIS را بالا می‌برد. در واقع، با استفاده از مفاهیم فازی و موجک عدم قطعیت و فصلی بودن پدیده‌ها بهتر می‌تواند بررسی شود. در مرحله بعد، جهت ارزیابی کارایی مدل SD-WANFIS، تراز سطح آب به‌طور مستقیم و بدون در نظر گرفتن عوامل مؤثر بر آن مثل: بارش، دبی و تبخیر و با استفاده از مدل ARIMA (p,d,q) پیش‌بینی شد. در این روش سطح آب با توجه به

#### ۴- نتیجه گیری و جمع بندی

با توجه به کاهش قابل توجه تراز آب دریاچه ارومیه، مدل سازی و پیش بینی دقیق سری زمانی تراز سطح آب و سایر فرایندهای هیدرولوژیکی دریاچه ارومیه، گامی مؤثر در راستای مدیریت منابع آب پایدار این حوضه محسوب می گردد. برای این منظور، پژوهش حاضر به بررسی دقت پیش بینی تراز سطح آب با روش های مدل سازی مختلف می پردازد. برای رسیدن به این هدف، ابتدا مدل WAFIS به دلیل قابلیت بررسی تغییرات درازمدت توسط تبدیل موجک و فازی سازی داده ها و بررسی عدم قطعیت آن ها توسط مدل ANFIS، برای پیش بینی عوامل مؤثر بر سطح آب مانند بارش، تبخیر و تخلیه مورد استفاده قرار گرفت سپس مقادیر تراز آب دریاچه ارومیه با بهره گیری از مدل SD که توانایی بالایی را در بررسی و مدل سازی بیلان حوضه دارد شبیه سازی و پیش بینی شد. برای اطمینان بیشتر در مورد پیش بینی تراز سطح آب با استفاده از مدل SD که با WAFIS ترکیب شده، نتایج با مدل ARIMA مقایسه شد. نتایج نشان داد که شاخص های آماری RMSE و DC، در مرحله صحت سنجی به ترتیب در روش SD-WAFIS برابر ۰/۳۱ و ۰/۸۴ و در روش ARIMA برابر ۰/۶۱ متر و ۰/۵۳ می باشند. بنابراین روش جدید ارائه شده در این مطالعه با دقت بیشتری می تواند سطح آب را پیش بینی کند. به عنوان مطالعه بیشتر می توان در آینده از ترکیب سایر مدل های قدرتمند هوش مصنوعی همچون روش ماشین بردار پشتیبان (SVM) با مدل پویایی سیستم (SD-SVM) استفاده نمود.

#### ۵- مراجع

- Addison PS, Murrary KB, Watson JN, "Wavelet transform analysis of open channel wake flows", Journal of Engineering Mechanics, 2001, 127 (1), 58-70.
- Alizadeh MJ, Mohammadnia Joneyd P, Motahhari M, "A Wavelet-ANFIS model to estimate Sedimentation in dam reservoir", International Journal of Computer Applications, 2015, 114 (9), 19-25.
- Belayneh A, Adamowski J, "Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression", Applied Computational Intelligence and Soft Computing, 6, 2012.
- Cannas B, Fanni A, Sias G, Tronei S, Zedda MK, "River flow forecasting using neural networks and wavelet analysis", Proceedings of the European Geosciences Union 2006, 234-243.
- Chang FJ, Chang YT, "Adaptive neuro-fuzzy inference system for prediction of water level in reservoir", Advances in Water Resources, 2006, 29 (1), 1-10.
- Eimanifar A, Mohebbi F, "Urmia Lake (northwest Iran): A brief review", Saline Systems, 2007, 3 (5), 1-8.
- Forrester JW, "Industrial dynamics. MIT Press", Cambridge, 1961.
- Gastelum RJ, Valdés JB, Stewart S, "A system dynamics model to evaluate temporary water transfers in the Mexican Conchos Basin", Water Resources Management, 2010, 24 (11), 1285-1311.
- Ghashghaei M, Bagheri A, Morid A, "Rainfall-runoff modeling in a watershed scale using an object


بیانگر این است که مدل SD-WAFIS سطح آب را با دقت بالاتری نسبت به مدل ARIMA پیش بینی کرده است. مقادیر شاخص های آماری مانند RMSE و DC، در مرحله صحت سنجی برای مدل ARIMA، ۰/۶۱ متر و ۰/۵۳ و برای مدل SD-WAFIS به ترتیب ۰/۳۱ و ۰/۸۴ به دست آمد (جدول (۴)). در واقع، SD-WAFIS مدل ترکیبی از روش پویایی سیستم و شبکه های عصبی فازی موجکی است که تراز سطح آب را با دقت بیشتری پیش بینی می کند. در مدل WAFIS تبدیل موجک با گرفتن اطلاعات مفید داده ها در سطح های مختلف، توانایی پیش بینی مدل را بهبود می بخشد. الگوی پیش بینی می تواند به طور هم زمان از طریق تجزیه و تحلیل موجک گرفته شود، این در حالی است که ANFIS تنها می تواند الگوی خودهمبستگی سری های زمانی را تشخیص دهد. مدل های پس رو که فقط از گام های اخیر و یا چند گام عقب تر به عنوان ورودی استفاده می کنند نمی توانند پرش های لحظه ای سری های زمانی را تشخیص دهند. مدل های ARIMA قادر به تشخیص روند نیستند و همچنین برای پیش بینی طولانی مدت نیز استفاده نمی شوند، همچنین این مدل عوامل مؤثر بر تراز آب (مثل: بارش، تبخیر و دبی) را در پیش بینی در نظر نمی گیرد در حالی که مدل SD-WAFIS همه این عوامل را در نظر می گیرد.

#### جدول ۳- مقایسه آماری مدل های مختلف آریمای جهت پیش بینی

تراز آب دریاچه ارومیه در مرحله صحت سنجی		
نوع مدل	RMSE (m)	DC
ARIMA (4,1,5)	۰/۶۱	۰/۵۳
ARIMA (5,1,4)	۰/۶۰	۰/۲۷
ARIMA (4,1,4)	۰/۶۲	۰/۳۸
ARIMA (3,1,5)	۰/۶۷	۰/۲۸

#### جدول ۴- مقایسه شاخص های آماری روش های پیش بینی در

مرحله صحت سنجی		
روش پیش بینی	RMSE	DC
پیش بینی مستقیم با استفاده از روش آریمای مدل ARIMA (4,1,5)	۰/۶۱	۰/۵۳
پیش بینی غیرمستقیم با استفاده از روش SD-WAFIS	۰/۳۱	۰/۸۴



شکل ۱۴- ارزیابی تراز سطح آب پیش بینی شده با استفاده از

روش های ARIMA و SD-WAFIS

- oriented approach based on the concepts of system dynamics", *Water Resour Manage*, 2013, 27 (15), 5119-5141.
- Hassanzadeh E, Zarghami M, Hassanzadeh Y, "Determining the main factors in declining the Urmia Lake level by using system dynamics modeling", *Water Resources Management*, 2012, 26 (1), 129-145.
- Jang JSR, Sun CT, "Neuro-fuzzy modeling and control", *Proc IEEE*, 1995, 83 (3), 378-406.
- Jang JSR, Sun CT, Mizutani E, "Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence", Prentice-Hall, Eaglewood Cliffs, 1997, 665-685.
- Kwon HH, Lall U, Khalil AF, "Stochastic simulation model for nonstationary time series using an autoregressive wavelet decomposition: Applications to rainfall and temperature", *Water Resources research*, 2007, 43 (5), 1-15.
- Mallat S, "A wavelet tour of signal processing, 2nd Ed", Academic Press, San Diego, CA, 1998.
- Nourani V, Baghanam AH, Adamowski J, Kisi O, "Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review", *Journal of Hydrology*, 2014, 514, 358-377.
- Nourani V, Kisi O, Komasi M, "Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process", *Journal of Hydrology*, 2011, 402 (1), 41-59.
- Nourani V, Komasi M, Alami MT, "Hybrid Wavelet-Genetic programming approach to optimize ANN modeling of Rainfall-Runoff process", *Journal of Hydrologic Engineering*, 2012, 17 (6), 724-741.
- Nozari H, Heydari M, Azadi S, "Simulation of a right abshar irrigation network and its cropping pattern using a system dynamics approach", *Journal of Irrigation and Drainage Engineering*, 2014, 140 (12), 05014008.
- Partal T, Kisi O, "Wavelet and neuro-fuzzy conjunction model for precipitation forecasting", *Journal of Hydrology*, 2007, 342 (1), 199-212.
- Salas JD, Delleur JW, Yevjevich V, Lane WL, "Applied Modeling of Hydrological Time Series, first ed", Water Resources Publications, Littleton, 1980.
- Sima S, Tajrishy M, "Using satellite data to extract volume-area-elevation relationships for Urmia Lake, Iran", *Journal of Great Lakes Research*, 2013, 39 (1), 90-99.
- Simonovic SP, Ahmad S, "System dynamics modeling of reservoir operation for flood management", *Journal of Computing in Civil Engineering*, 2002, 14 (3), 190-198.
- Sterman JD, "Business dynamics, systems thinking and modeling for a complex world", McGraw Hill, Boston, 2000.
- Wang W, Ding J, "Wavelet network model and Its application to the prediction of hydrology", *Nature and Science*, 2003, 1 (1), 67-71.
- Wang WC, Chau KW, Cheng CT, Qiu L, "A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series", *Journal of Hydrology*, 2009, 374 (3), 294-306.
- Winz I, Brierley G, Trowsdale S, "The use of system dynamics simulation in water resources management", *Water Resources Management*, 2009, 23 (11), 1301-1323.

## EXTENDED ABSTRACT

# Lake Water Level Forecasting using Wavelet-ANFIS and System Dynamic Model

Mehdi Komasi<sup>a,\*</sup>, Neda Gheshlaghi<sup>b</sup>, Soroush Sharghi<sup>a</sup>

<sup>a</sup> Faculty of Engineering, Water Engineering and Hydraulic Structures, University of Ayatollah Ozma Borujerdi, Borujerd, Iran

<sup>b</sup> Hydraulic Structures, Bu Ali Sina University, Hamedan, Iran

**Received:** 17 April 2017; **Accepted:** 11 December 2017

### Keywords:

Adaptive neuro-fuzzy inference system; System dynamic; Urmia lake; Wavelet.

## 1. Introduction

Nowadays challenge of water resource is a problem of many countries in the Middle East. This fact about Urmia Lake in Iran has more importance in the recent decade. Urmia Lake water level has involved many changes and fluctuations due to rainfall changes, droughts and dam constructions. The main purpose of this article is an investigation of System Dynamic (SD) methods for forecasting water level fluctuations using Wavelet Adaptive Neuro-Fuzzy Inference System (WANFIS).

## 2. Methodology

### 2.1. System Dynamic method (SD)

System dynamics (SD) is an approach to understand the nonlinear behavior of complex systems over time using stocks, flows, internal feedback loops, table functions and time delays. DC method was firstly initiated by Forrester (1961) in order to better understand the strategic issues in complex dynamic systems.

### 2.2. Adaptive Neuro-Fuzzy Inference Systems (ANFIS)

ANFIS architecture is an adaptive network that uses supervised learning on learning algorithm, which has a function similar to the model of Takagi-Sugeno fuzzy inference system (Suparta and Alhasa, 2013). In ANFIS model, the parameters of the fuzzy functions are well determined by Neural Network (NN).

### 2.3. Wavelet Transform

The wavelet transform is a mathematical tool that provides a time-frequency representation of a signal in the time domain. In addition, wavelet analysis can often compress or de-noise a signal and thus, it is introduced as an efficient approach for dealing with local discontinuities in a given time series (Mallat, 1998).

\* Corresponding Author

E-mail addresses: komasi@abru.ac.ir (Mehdi Komasi), n.qeshlaqi@yahoo.com (Neda Gheshlaghi), s.sharghi@abru.ac.ir (Soroush Sharghi). [www.SID.ir](http://www.SID.ir)

### 2.4. Wavelet-ANFIS (WANFIS)

In WANFIS model firstly, the original time series are decomposed into subseries by wavelet transform. Then, these sub-time series are imposed as input of ANFIS model to forecast proposed time series.

### 2.5. Urmia Lake Case Study

Urmia Lake is a salt lake in Northwestern Iran and is reportedly the largest lake in the Middle East (between 45°03'00" and 37°40'00" east longitude and north latitude respectively). It covers an area varying from 5200 to 6000 km<sup>2</sup>. The lake is about 140km long and 40 to 55km wide with a maximum depth of 16 m.

## 3. Results and discussion

A simulation model based on SD method is developed for the Urmia Lake basin. Then, for forecasting water level, effective variables upon it such as precipitation, discharge and evaporation were forecasted with the WANFIS model. For instance, the forecasted discharge time series was illustrated in Fig.1. These forecasted variables (time series) were entered into the SD model and the water level can be accounted. DC and RMSE efficiency criteria are calculated for ARIMA and SD-WANFIS to be 0.53, 0.61 and 0.31, 0.84 respectively (Table 1). As it is illustrated in Fig. 2, SD-WANFIS indirect forecasting model has more efficiency than ARIMA model due to the usage of data pre-processing wavelet transform and the application of SD method in forecasting Urmia Lake water level.




Fig.1. Computed and observed discharge time series of Urmia watershed obtained by WANFIS model

Table 1. The forecasting results measured by efficiency criteria of ARIMA and SD-ANFIS models in verification step

DC	RMSE	Model
0.53	0.61	Direct forecasting using ARIMA (4,1,5)
0.84	0.31	Indirect forecasting using SD-WANFIS




Fig. 2. Evaluation of water level forecasting ARIMA and SD-WANFIS methods

#### 4. Conclusions

The results of this research indicate that the accuracy of new conjunction SD-WANFIS model is satisfactory. The values of statistical indexes such as RMSE and DC for SD WANFIS model were 0.31m and 0.84 in verification step respectively. Whereas, these values for black-box Auto Regressive Integrated Moving Average (ARIMA) model are calculated to be 0.61m and 0.53. As a result, results of this research reveal that coupling of two SD and WANFIS models is useful for forecasting with suitable accuracy.

#### 5. References

- Forrester JW, "Industrial dynamics. MIT Press", Cambridge, 1961.
- Suparta W, Alhasa KM, "A comparison of ANFIS and MLP models for the prediction of precipitable water vapor", IEEE International Conference On Space Science and Communication (IconSpace), 2013, 243-248.
- Mallat S, "A wavelet tour of signal processing, 2nd Ed", Academic Press, San Diego, CA, 1998.