

پیش‌بینی تراز آب دریاچه ارومیه با استفاده از روش‌های سری زمانی، شبکه عصبی مصنوعی و شبکه عصبی- موجکی

مهدی کماسی^۱، حامد نودری^۲، ندا قشلاقی^۳

تاریخ دریافت: ۱۳۹۳/۱۰/۱۰

تاریخ پذیرش: ۱۳۹۵/۰۴/۲۳

چکیده

دریاچه ارومیه دومین دریاچه شور جهان است و با توجه به معیارهای اجتماعی- اقتصادی و زیست محیطی نقش مهمی در منطقه شمال غرب ایران دارد که در سالهای اخیر با مشکلاتی مواجه شده است و به دلیل خشکسالی، استفاده بیش از حد آب‌های سطحی و ساخت سدها تراز سطح آب آن کاهش یافته است. یکی از فاکتورهای مهم که در مدیریت صحیح در هر زمینه‌ای، تأثیر دارد، داشتن یک دید و نگرش مناسب از اتفاقات آینده در آن زمینه است به همین دلیل شبیه‌سازی و سپس پیش‌بینی متغیرهای هیدرولوژیکی از اهمیت ویژه‌ای برخوردار است. بنابراین در پژوهش حاضر به مقایسه سه روش پیش‌بینی سری زمانی آریمای، شبکه عصبی مصنوعی و شبکه عصبی- موجکی جهت ارائه بهترین روش پیش‌بینی تراز سطح آب دریاچه ارومیه در مقیاس ماهانه پرداخته شده است. نتایج حاصل با توجه به معیار ضریب تبیین و جذر میانگین مربعات خطا مقایسه شد که نشان‌دهنده عملکرد بهتر شبکه عصبی- موجکی در مقایسه با دو روش سری زمانی آریمای و شبکه عصبی مصنوعی، به دلیل لحاظ نمودن تغییرات ماهانه، فصلی و سالانه در قالب تجزیه سری‌های زمانی می‌باشد.

واژه‌های کلیدی: تراز سطح آب دریاچه ارومیه، سری زمانی، شبکه عصبی مصنوعی، شبکه عصبی- موجکی.

۱ استادیار گروه عمران دانشگاه آیت الله العظمی بروجردی (ره)، ۰۹۱۶۶۶۲۴۱۸۰، komasi@abru.ac.ir (مسئول مکاتبه)

۲ استادیار گروه علوم و مهندسی آب دانشگاه بوعلی سینا همدان، ۰۹۳۷۰۹۳۷۷۳۶، hanozari@yahoo.com

۳ دانشجوی کارشناسی ارشد مهندسی منابع آب دانشگاه بوعلی سینا همدان- لرستان، بروجرد، خیابان طالقانی، ۰۹۱۶۳۶۲۸۱۰۹، n.qeshlaqi@yahoo.com

مقدمه

در دهه‌های اخیر با توجه به مشکل کمبود منابع آبی، مسئله استفاده و مدیریت بهینه از این منابع اهمیت خاصی پیدا کرده است. یکی از مواردی که در این زمینه مورد توجه قرار گرفته است تهیه مدل پیش‌بینی‌کننده عوامل هیدرولوژیکی می‌باشد. وجود چنین مدل‌هایی باعث می‌گردد که مدیریت و تصمیم‌گیری‌های مربوط به منابع آبی با دقت بیشتری انجام گیرد. به همین دلیل شبیه‌سازی و سپس پیش‌بینی متغیرهای هیدرولوژیکی می‌تواند اهمیت به‌سزایی داشته باشد. در این زمینه می‌توان از پیش‌بینی با استفاده از روش‌های خطی مانند مدل‌های آریمای و روش‌های شبکه عصبی و شبکه عصبی-موجکی نام برد. در این میان تحلیل سری زمانی تراز دریاچه‌ها می‌تواند اطلاعات کاملی را به منظور پیش‌بینی تغییرات متغیرهای اقلیمی و تغییرات منابع آبی موجود در منطقه در اختیار کارشناسان قرار دهد (Ghil et al. 2002). به همین دلیل پژوهش‌های زیادی روی روش‌های شبیه‌سازی و پیش‌بینی تراز دریاچه‌ها صورت گرفته است تا بتوان تغییرات اقلیمی را به درستی پیش‌بینی نمود. به عنوان نمونه رسولی و عباسیان (۱۳۸۸) نشان دادند سری‌های زمانی تراز دریاچه ارومیه در مقیاس سالانه و فصلی دارای نوسانات و تغییرات بسیار چشم‌گیری هستند که شاید به نوعی نشان‌دهنده حاکمیت متناوب اقلیم‌های نیمه‌خشک تا نیمه مرطوب با ماهیت‌های مختلف در طول زمان در منطقه است. مقایسه روش‌های شبکه عصبی، سیستم استنتاج تطبیقی فازی عصبی^۱ (ANFIS) و روش استوکستیک در پیش‌بینی سطح آب دریاچه اجیردیر ترکیه نیز نشان داد که دقت مدل‌های ANN و ANFIS بیشتر از مدل‌های AR و ARMA بوده است اما مدل‌های استوکستیک نیز همچنان می‌توانند برای سیاست‌های مدیریت دریاچه با ریسک مجاز و قابل قبولی استفاده شوند

(Güldal and Tongal, 2010). در این راستا خطی و همکاران (۲۰۱۴) پنج روش مدل‌سازی تراز آب شش دریاچه از ایالات متحده آمریکا و ترکیه با ویژگی‌های متفاوت فیزیکی را مورد استفاده قرار دادند. این پنج مدل عبارت‌اند از: تئوری هرج و مرج (Chaos)، مدل خودهمبسته میانگین متحرک تلفیق‌شده^۲ (ARIMA)، مدل خودهمبسته میانگین متحرک تلفیق‌شده فصلی^۳ (SARIMA)، شبکه عصبی مصنوعی^۴ (ANN)، برنامه‌نویسی ژنتیک^۵ (GEP) و رگرسیون خطی چندگانه^۶ (MLR). هر کدام از این روش‌ها با فرضیات متفاوتی فرموله شده‌اند. عملکرد این پنج مدل از خوب تا ضعیف دسته‌بندی شد. آنها نشان دادند که حتی ضعیف‌ترین این مدل‌ها از نظر عملکرد، می‌تواند برای درک نسبی رفتار طبیعت مورد استفاده قرار گیرد (Khatibi et al. 2014).

اما یکی از روش‌هایی که امروزه استفاده از آن در تحلیل و پیش‌بینی سری زمانی در حال گسترش است، روش تبدیل موجک می‌باشد (نوری و رهنما، ۱۳۸۵). با استفاده از این تبدیل می‌توان یک سری زمانی ناپیوسته را به چندین سری زمانی ایستا تجزیه و با وارد نمودن آن‌ها به عنوان ورودی شبکه عصبی قدرت این شبکه را در پیش‌بینی بالا برد. این مدل ترکیبی جدید به نام شبکه عصبی-موجکی^۷ (WNN) بوجود می‌آورد که از مزیت‌های شبکه عصبی و تبدیل موجک باهم استفاده می‌کند (نخعی و صابری، ۱۳۹۱). همچنین از ترکیب آنالیز موجک و برنامه‌نویسی ژنتیک برای ساخت یک مدل ترکیبی جهت یافتن الگوی فصلی بارش رواناب استفاده شد، نتایج به دست آمده نشان داد که مدل می‌تواند هر دو الگوی بلندمدت و کوتاه مدت را با توجه به استفاده از سری‌های زمانی چند مقیاسه بارش و رواناب به عنوان ورودی استفاده کند. (Nourani et al. 2012).

^۲ Auto Regressive Integrated Moving Average

^۳ Seasonal Auto Regressive Integrated Moving Average

^۴ Artificial Neural Networks

^۵ Gene Expression Programming

^۶ Multiple Linear Regression

^۷ Wavelet Neureal Network

^۱ Adaptive Network-based Fuzzy Inference System (ANFIS)

تفاضل سری و مدلسازی آن با ARMA (p,q) منجر به پیدایش سری جدیدی از مدل‌های آماری موسوم به مدل‌های آریمای غیرفصلی ARIMA (p,d,q) گردیده است. مدل ساده آریما برای سری زمانی x_t از برازش مدل ARMA بر روی سری تفاضلات آن u_t بدست می‌آید. در این حالت مدل آریما به شکل رابطه (۱) خواهد بود

$$u_t = \sum_{i=1}^p \phi_i u_{t-i} + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1)$$

که در آن u سری حاصل از تفاضل d ام سری اصلی می‌باشد. P مرتبه جزء خودهمبسته، d مرتبه تفاضل و q مرتبه جزء میانگین متحرک می‌باشد. در صورت استفاده از عملگر تفاضل فصلی با تأخیر ω و برازش آن‌ها با مدل‌های ARMA (p,q) مدل‌های فصلی آریما $ARIMA(P, D, Q)$ به وجود می‌آید. ترکیبی از مدل‌های فصلی و غیر فصلی مدل‌های موسوم به آریمای مکرر^۱ را تشکیل می‌دهند. جهت مدلسازی سری‌های زمانی فصلی در کنار سری‌های غیرفصلی مدل $ARIMA(p, d, q)(P, D, Q)$ به صورت رابطه (۲) تعریف می‌گردد.

$$\Phi(B^\omega)\Theta(B)(1-B^\omega)^D(1-B)^d Z_t = \theta(B^\omega)\theta(B)\varepsilon_t \quad (2)$$

که در آن ε_t متغیر تصادفی، B عملگر تفاضل به صورت $B(Z_t) = Z_{t-1}$ ، $(1-B^\omega)^D$ D امین تفاضل فصلی به اندازه ω ، $(1-B)^d$ d امین تفاضل غیر فصلی، p مرتبه مدل خودهمبسته غیر فصلی، q مرتبه مدل میانگین متحرک غیر فصلی، P مرتبه مدل خودهمبسته فصلی، Q مرتبه مدل میانگین متحرک فصلی، Θ پارامتر مدل خودهمبسته غیر فصلی، θ پارامتر مدل میانگین متحرک غیر فصلی، Φ پارامتر مدل خودهمبسته فصلی، Θ پارامتر مدل میانگین متحرک فصلی می‌باشد (کارآموز و عراقی‌نژاد، ۱۳۸۹).

در پژوهش حاضر، با استفاده از آنالیز چند مقیاسه موجک، تغییرات دراز مدت سری زمانی تراز سطح آب دریاچه ارومیه مورد بررسی قرار می‌گیرد و به منظور ارزیابی این روش، نتایج حاصل از آن با دو روش شبکه عصبی (مدل خود همبسته غیرخطی) و سری زمانی آریما (خود همبسته خطی) مقایسه می‌شود.

مواد و روش‌ها

مدل سری زمانی

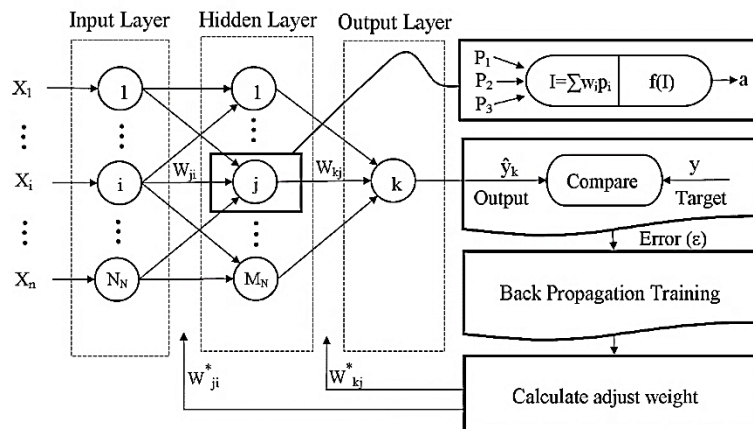
سری‌های زمانی به دو دسته ایستا و غیر ایستا تقسیم می‌شوند. از آنجا که نظریه احتمال سری‌های زمانی بیشتر با سری‌های زمانی ایستا سروکار دارد بنابراین لازم است در صورت نایستا بودن سری، ابتدا به یک سری زمانی ایستا تبدیل شود. راه حل مناسب برای ایستا سازی یک سری زمانی که در میانگین نایستا است، تفاضلی کردن آن سری و در مورد سری زمانی که در واریانس نایستا است استفاده از تبدیلات باکس-کاکس می‌باشد (Box and Jenkins, 1976). یک سری زمانی شامل مدل‌های غیر فصلی همانند خودهمبسته، میانگین متحرک، خودهمبسته میانگین متحرک، آریمای غیرفصلی و فصلی می‌باشد (کارآموز و عراقی‌نژاد، ۱۳۸۹). یکی از مشکلاتی که در مدل‌های خودهمبسته برای مدلسازی سری‌های زمانی هیدرولوژیکی وجود دارد، تغییرات سری در شرایط خاص است. به عنوان مثال جریان رودخانه در شرایط کم آبی و پربابی از رفتار خاصی تبعیت می‌کند که در صورت استفاده از مدل‌های خودهمبسته به تنهایی، این تغییرات به خوبی مدل نخواهند شد. جهت رهایی از این مشکل بخش دیگری تحت عنوان میانگین متحرک به رابطه ارائه شده برای مدل‌های خودهمبسته، اضافه شده و مدل ترکیبی تحت عنوان مدل خودهمبسته میانگین متحرک ارائه شده است. در بخش‌های قبل ذکر شد که اگر یک سری زمانی دارای میانگین ثابت نبوده اما تفاضل تغییرات این پارامتر ایستا باشد، با استفاده از عملگر تفاضل آن سری زمانی ایستا می‌شود. استفاده از اولین، دومین یا d امین

¹ Multiplicative ARIMA

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی برای اولین بار در سال ۱۹۴۳ توسط مک کولاک و بیتس معرفی شد.

با توسعه رایانه و همچنین ظهور الگوریتم پسانتشار خطا توسط راملهارت و همکاران در سال ۱۹۸۶، استفاده از شبکه عصبی وارد مرحله جدیدی گردید (محتشم و همکاران، ۱۳۸۹). شکل (۱) ساختار شماتیک شبکه عصبی مصنوعی را نشان می‌دهد.



شکل (۱): ساختار شبکه عصبی مصنوعی

آید. w_{kj} مقدار وزنی است که به نرون k ام لایه میانی اختصاص داده می‌شود تا بر اساس آن نرون k ام لایه خروجی به دست آید (حسن‌زاده و همکاران، ۱۳۹۱). هر شبکه عصبی با دریافت مثال‌هایی آموزش می‌بیند. یادگیری شبکه زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر مشاهده‌شده و پیش‌بینی‌شده در حد قابل قبولی باشد. ویژگی عمده شبکه عصبی مصنوعی سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم دانش پس از یادگیری و عدم وجود اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است (غفاری و وفاخواه، ۱۳۹۲).

تئوری نگاهت موجک

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

در هر لایه تعدادی پردازشگر به نام نرون وجود دارد. لایه یا لایه‌های مخفی اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهد. تابع انتقال بیان‌کننده پاسخ هر نرون به سیگنال ورودی آن نرون است. مدل ریاضی مورد استفاده برای بیان مقدار یک خروجی از شبکه عصبی توسط رابطه (۳) بیان می‌شود.

$$\hat{y}_k = f_0 \left[\sum_{j=1}^m w_{kj} - f_h \left(\sum_{i=1}^n w_{ij} x_i + w_{j0} \right) + w_{k0} \right] \quad (3)$$

که در آن n تعداد کل نرون‌های لایه ورودی، m تعداد کل نرون‌های لایه میانی، k تعداد کل نرون‌های لایه خروجی، f_0 تابع محرک مورد استفاده در لایه خروجی، f_h تابع محرک مورد استفاده در لایه میانی، w_{j0} مقدار وزن اریب نرون j ام لایه میانی، w_{k0} مقدار وزن اریب نرون k ام لایه خروجی، w_{ij} مقدار وزنی است که به نرون i ام لایه ورودی اختصاص داده می‌شود تا بر اساس آن، نرون j ام لایه میانی به دست

در نهایت ضرایب موجک در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با رابطه (۷) قابل محاسبه‌اند:

$$\begin{aligned} CWT(a,b) &= Wf(a,b) = \\ &= \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{x-b}{a}\right) dx = \\ &= \int_{-\infty}^{+\infty} f(x) \psi_{a,b}(x) dx \quad (1) \end{aligned}$$

انتقال در تبدیل موجکی نشان‌دهنده موقعیت پنجره است. در این روش نیز یک تابع پنجره در نظر گرفته شده و در موج مورد نظر ضرب می‌شود. بر خلاف تبدیل قطعه‌ای، در تبدیل پیوسته موجکی پهنای تابع پنجره متغیر می‌باشد، بطوری‌که برای هر مؤلفه موج می‌توان عرض مناسبی را انتخاب نمود. این موضوع مهم‌ترین خصوصیت تبدیل موجکی است. مقیاس به طور ساده به معنای کشیده شدن یا فشرده شدن موج می‌باشد. همچنین انتقال موجک به طور ساده به مفهوم به تأخیر انداختن یا جلو انداختن موجک و بیان‌کننده موقعیت موجک بر روی محور زمان است. توابع موجک‌ها دارای انواع بسیاری هستند که در شکل (۲) نمودار تابع نمونه‌هایی از آن‌ها نشان داده شده‌اند (نیک منش و طالب بیدختی، ۱۳۹۱).

همان‌طور که قبلاً بیان شد شبیه سازی و پیش بینی با استفاده از روش سری زمانی به دلیل خاصیت خود همبسته بودن این روش و عدم تشخیص روند موجود در اطلاعات، مستلزم حذف نایستایی موجود در داده‌ها می‌باشد. همچنین در شبیه سازی و پیش بینی با استفاده از شبکه عصبی داده‌ها باید به صورت نرمال مورد استفاده قرار بگیرند اما در روش موجک به دلیل اینکه این روش خود قادر به شناسایی و تشخیص روند موجود در داده‌ها و آنالیز چند مقیاسه می‌باشد نیازی به رفع نایستایی و نرمال نمودن داده‌ها نیست.

شد که این روش‌ها را گسترش دادند (Nourani and Komasi, 2013). 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 پایین و تناوب‌های کوتاه‌تر را برای اطلاعات دارای فرکانس بالا ارائه می‌دهد و قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌ها می‌باشد. 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 $\Psi(\omega)$ ، شرط زیر را ارضا کند (Nourani et al., 2009).

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|}{|\omega|^2} < +\infty \quad (4)$$

این شرط با عنوان شرط پذیرفتگی^۱ برای موجک $\psi(x)$ شناخته می‌شود. رابطه فوق را می‌توان معادل با فرمول زیر دانست:

$$\Psi(0) = \int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (5)$$


این ویژگی تابع با میانگین صفر، چنان محدودکننده 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^۲ و مقیاس^۳ در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (6)$$

¹ Admissibility

² Translation

³ Dilation

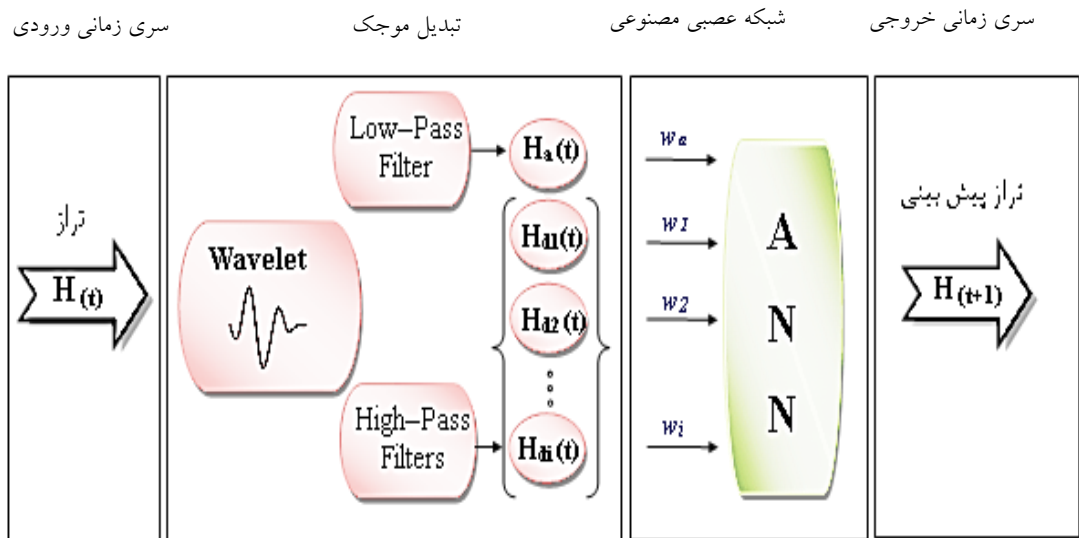


شکل (۲): نمودار (الف) تابع موجک bior (ب) تابع موجک sym2 (ج) تابع موجک coif1 (د) تابع موجک db2 (ه) تابع موجک Haar

مدل شبکه عصبی - موجکی

ترکیب دو قابلیت شبکه عصبی و تئوری موجک باعث ایجاد مدل ترکیبی با کارایی بهتری در شبیه‌سازی فرایندهای هیدرولوژیکی می‌شود. بنابراین اگر پیش‌پردازی بر روی داده‌ها صورت نگیرد شبکه

قادر به پیش‌بینی نخواهد بود (Cannas et al., 2006). به همین دلیل با ترکیب این دو مدل ابتدا داده‌ها با تبدیل موجکی تجزیه و سپس به عنوان ورودی وارد شبکه عصبی مصنوعی می‌گردند. شکل (۳) ساختار شماتیک شبکه عصبی - موجکی را نشان می‌دهد.

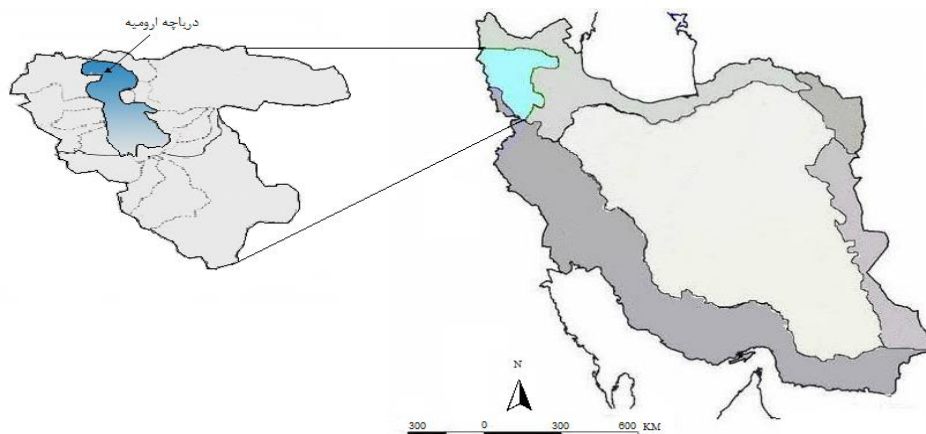


شکل (۳): ساختار شماتیک شبکه عصبی - موجکی

جهت ارزیابی مدل‌های مورد استفاده از شاخص‌های جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (DC) و همچنین معیار آکائیک (AIC) در مورد سری‌های زمانی، استفاده شد.

مطالعه موردی (دریاچه ارومیه)

دریاچه ارومیه در شمال غربی ایران با طول حدود ۱۴۶ کیلومتر و عرض حداکثر برابر با ۵۸ کیلومتر قرار دارد. عمق دریاچه چندان زیاد نبوده و به طور متوسط ۵ تا ۶ متر می‌باشد. عمیق‌ترین نقطه آن در شمال غربی به عمق ۱۴ متر در مواقع کم آبی و ۲۰ متر در مواقع پرآبی قرار دارد. شکل (۴) نمایی از حوضه آبریز دریاچه ارومیه می‌باشد.



شکل (۴): حوضه آبریز دریاچه ارومیه

موجکی به شبیه‌سازی و پیش‌بینی تراز سطح آب دریاچه ارومیه پرداخته شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (h_{obs} - h_{com})^2}{n}} \quad (۸)$$

$$DC = 1 - \frac{\sum_{i=1}^n (h_{obs} - h_{com})^2}{\sum_{i=1}^n (h_{obs} - \bar{h}_{obs})^2} \quad (۹)$$

$$AIC = N \ln(\sigma_{\varepsilon}^2) + 2(p + q) \quad (۱۰)$$

در مدل عصبی-موجکی جهت انجام محاسبات از شبکه عصبی برای یافتن ضرایب وزن تراز در ساختار شبکه استفاده می‌گردد. در این مدل نخست سری تراز به زیرسری‌هایی با مقیاس‌های متفاوت تجزیه می‌شوند. به عنوان نمونه می‌توان سری زمانی را به یک مقیاس بلند مدت و چند مقیاس کوتاه مدت (برای رهگیری خواص گذرا و نوسانات کوتاه مدت سری) تجزیه نمود. در این صورت زیرسری زمانی که تحت عنوان $a(t)$ (همانند $H_a(t)$) نام‌گذاری می‌شوند، معرف زیرسری تقریبی (مقیاس بلند مدت)، و برای زیرسری زمانی که تحت عنوان $d_i(t)$ با اندیس i (همانند $H_{di}(t)$) نام‌گذاری می‌شوند، معرف زیرسری جزئی (مقیاس کوتاه مدت) هستند. پارامتر i نیز مرتبه تجزیه سری تراز ($H(t)$) می‌باشد.

نتایج و بحث

برای انجام این تحقیق ابتدا داده‌های ماهانه تراز سطح آب دریاچه ارومیه از سازمان مدیریت منابع آب ایران تهیه گردید. پس از آن تراز سطح آب دریاچه به سه روش شبیه‌سازی و پیش‌بینی گردید. در روش اول تراز سطح آب دریاچه به کمک مدل‌های استوکاستیک و با استفاده از سری زمانی تراز سطح آب پیش‌بینی شد. در روش دوم با استفاده از شبکه عصبی مصنوعی و در روش سوم با استفاده از روش ترکیبی شبکه عصبی

محیط نرم افزار مینی تب، از بین برده شد و سپس نالیستایی در میانگین نیز با یک مرتبه تفاضل گیری از سری، حذف شد. پس از حذف روند برای تشخیص بهترین مدل استوکاستیکی باید بر اساس نمودارهای خودهمبستگی و خودهمبستگی جزئی داده ها مدلی را پیشنهاد نمود و با توجه به آزمون های موجود بهترین گزینه را انتخاب کرد. مشخصات تعدادی از مدل های برازش داده شده که دارای کمترین معیار آکائیک هستند در جدول (۱) نمایش داده شده است.


در این روابط، h_{com} تراز آب محاسباتی، \bar{h}_{obs} میانگین تراز آب مشاهداتی، h_{obs} تراز آب مشاهداتی، n تعداد ماه های بررسی شده در بازه زمانی ۱۳۵۵ تا ۱۳۹۰. p و q پارامترهای مدل آریما و σ_{ε} انحراف معیار باقیمانده های حاصل از برازش مدل می باشند. برای شبیه سازی و پیش بینی تراز سطح آب به کمک سری زمانی آن، سری زمانی داده ها ترسیم و روند آن ها مورد بررسی قرار می گیرد. ابتدا نالیستایی داده ها در واریانس با انجام تبدیل باکس-کاکس در

جدول (۱): نتایج مدل های سری زمانی ARIMA

صحت سنجی مدل		واسنجی مدل		تعداد پارامتر	نوع مدل
DC	RMSE(m)	DC	RMSE(m)	AIC	
۰/۳۰	۰/۶۴۸	۰/۸۹	۰/۰۷۹	-۱۶۷۵/۹۱	۶ ARIMA(۲,۱,۴)(۰,۱,۰)
۰/۷۸	۰/۳۶۰	۰/۹۱	۰/۰۷۸	-۱۶۸۰/۲۴	۵ ARIMA(۲,۱,۳)(۰,۱,۰)
۰/۷۹	۰/۳۵۱	۰/۹۵	۰/۰۷۹	-۱۶۸۱/۱۹	۴ ARIMA(۲,۱,۲)(۰,۱,۰)
۰/۷۵	۰/۳۸۵	۰/۹۳	۰/۰۷۷	-۱۶۸۱/۸۶	۳ ARIMA(۲,۱,۱)(۰,۱,۰)
۰/۹۴	۰/۱۹۲	۰/۹۸	۰/۰۷۲	-۱۷۳۵/۰۹	۵ ARIMA(۲,۱,۲)(۱,۱,۰)

انجام شد. شکل (۵) نشان دهنده مقایسه نتایج حاصل از شبیه سازی با سری زمانی و مقادیر واقعی در بخش صحت سنجی می باشد.

پس از انتخاب مناسب ترین مدل با استفاده از تراز سطح آب از سال ۱۳۵۵ تا سال ۱۳۸۳، پیش بینی تراز آب با استفاده از مدل $ARIMA(2,1,2)(1,1,0)$ برای ماه های مختلف در طی سال های ۱۳۸۳ تا ۱۳۹۰



شکل (۵): مقایسه نتایج حاصل از شبیه سازی با سری زمانی و مقادیر واقعی در بخش صحت سنجی

شدند و ۸۰ درصد داده ها جهت آموزش شبکه و ۲۰ درصد برای شبیه سازی در نظر گرفته شد. سپس با

در مرحله بعد جهت شبیه سازی و پیش بینی تراز با استفاده از شبکه عصبی مصنوعی ابتدا داده ها نرمال

۲۰ نرون متغیر و همچنین تعداد مجاز تکرار تا ۱۰۰ دور در نظر گرفته شد. نتایج حاصل از اجرای برنامه با تعداد لایه های پنهان و تعداد تکرار متفاوت در جدول (۲) نشان داده شده است.


توجه به برنامه نوشته شده در محیط برنامه نویسی متلب جهت ساخت شبکه عصبی، یک شبکه سه لایه با تابع فعال سازی تانژانت سیگموئید در لایه مخفی و لایه خروجی با تعداد نرون لایه های پنهان بین ۳ تا

جدول (۲): نتایج حاصل از اجرای برنامه شبکه عصبی با تعداد نرون لایه های پنهان متفاوت

صحت سنجی مدل		واسنجی مدل		Epoch	تعداد نرون لایه پنهان
RMSE(m)	DC	RMSE(m)	DC		
۰/۰۴۶	۰/۸۰	۰/۰۲۶	۰/۹۴	۱۰۰	۱۰
۰/۰۳۷	۰/۸۷	۰/۰۱۹	۰/۹۷	۹۰	۱۱
۰/۰۳۲	۰/۹۰	۰/۰۱۹	۰/۹۷	۸۰	۱۰
۰/۰۴۷	۰/۷۹	۰/۰۲۷	۰/۹۴	۱۰۰	۷
۰/۰۴۱	۰/۸۴	۰/۰۲۰	۰/۹۶	۹۰	۸
۰/۰۵۱	۰/۷۵	۰/۰۲۹	۰/۹۰	۷۰	۹

دست آمد. شکل (۶) شبیه سازی تراز دریاچه ارومیه را با استفاده از شبکه عصبی مصنوعی نشان می دهد.

نتایج نشان داد که با تعداد متفاوت نرون ها در لایه پنهان از ۳ تا ۱۰ و ۸۰ دور تکرار حلقه آموزشی بهترین نتیجه برای شبیه سازی تراز با جذر میانگین مربعات خطای ۰/۰۳۲ متر وضرب تبیین ۰/۹۰ به



شکل (۶): مقایسه نتایج حاصل از شبیه سازی با شبکه عصبی مصنوعی و مقادیر واقعی در بخش صحت سنجی

برنامه ابتدا نوع موجک مادر توسط کاربر انتخاب می‌شود و سپس حداقل و حداکثر درجه تجزیه سیگنال تراز سطح آب و همچنین حداقل و حداکثر تعداد نرون لایه‌های پنهان از کاربر درخواست می‌شود. برنامه برای تجزیه سیگنال تراز آب ماهانه دریاچه با توجه به موجک‌های مادر مختلف و تعداد نرون‌های متفاوت اجرا شد، نتایج در جدول (۳) نمایش داده شده است.


در مرحله آخر تراز سطح آب دریاچه ارومیه با استفاده از مدل ترکیبی شبکه عصبی- موجکی شبیه‌سازی شد. بدین صورت که ابتدا بر اساس برنامه نوشته شده به زبان متلب، موجک‌های مادر مختلف برای برنامه تعریف شد. موجک‌های haar، db2، sim1، bior1.1، dmey، rbio1.1، coif1 به عنوان موجک‌های مادر به برنامه معرفی شدند. جهت اجرای

جدول (۳): عملکرد شبکه عصبی موجکی در شبیه‌سازی تراز آب ماهانه دریاچه ارومیه

صحت سنجی مدل		واسنجی مدل		درجه تجزیه	تعداد نرون لایه پنهان	نوع موجک مادر
RMSE(m)	DC	RMSE(m)	DC			
۰/۰۱۹	۰/۹۷	۰/۰۱۰	۰/۹۸	۲	۴	Haar
۰/۰۴۳	۰/۸۶	۰/۰۱۳	۰/۹۴	۴	۴	Db2
۰/۰۴۸	۰/۷۸	۰/۰۱۰	۰/۹۸	۵	۶	Sym1
۰/۰۴۰	۰/۸۴	۰/۰۱۳	۰/۹۶	۳	۹	Coif1
۰/۰۴۳	۰/۸۱	۰/۰۱۵	۰/۹۵	۲	۵	Bior1.1
۰/۰۶۷	۰/۶۷	۰/۰۱۶	۰/۹۴	۵	۸	Dmey
۰/۰۵۰	۰/۷۵	۰/۰۱۳	۰/۹۸	۴	۷	Rbio1.1

داشته است. شکل (۷) نشان‌دهنده شبیه‌سازی تراز سطح آب دریاچه ارومیه با استفاده از شبکه عصبی- موجکی می‌باشد.

همان طور که در جدول (۳) ملاحظه می‌گردد شبیه‌سازی و پیش‌بینی با موج Haar با تعداد نرون ۴ و درجه تجزیه ۲ بهترین عملکرد را با ضریب تبیین ۰/۹۷ و جذر میانگین مربعات خطا ۰/۰۱۹ متر، در پی



شکل (۷): مقایسه نتایج حاصل از شبیه‌سازی با شبکه عصبی- موجکی و مقادیر واقعی در بخش صحت‌سنجی


سال ششم • شماره بیست و چهارم • تابستان ۱۳۹۵

روش را نشان می دهد. ملاحظه می شود که در هر سه روش همبستگی بین داده های مشاهداتی و محاسباتی مناسب است اما با توجه به ساختار غیرخطی و چند مقیاسه بودن شبکه عصبی- موجکی این مدل بهتر توانسته است نقاط اوج را شبیه سازی نماید و دارای دقت بیشتری است.

نتایج نشان می دهد که پیش بینی تراز سطح آب دریاچه ارومیه با استفاده از روش ترکیبی عصبی- موجکی نتایج بهتری را در مقایسه با روش های سری زمانی و شبکه عصبی مصنوعی در پی دارد. جدول (۴) مقایسه آماری روش های شبیه سازی تراز سطح آب دریاچه ارومیه و شکل (۸) نتایج حاصل از هر سه

جدول (۴): مقایسه آماری روش های شبیه سازی تراز آب دریاچه ارومیه

صحت سنجی مدل		واسنجی مدل		روش شبیه سازی
DC	RMSE(m)	DC	RMSE(m)	
۰/۹۴	۰/۱۹۲	۰/۹۸	۰/۰۷۲	آریما
۰/۹۰	۰/۰۳۲	۰/۹۷	۰/۰۱۹	شبکه عصبی مصنوعی
۰/۹۷	۰/۰۱۹	۰/۹۸	۰/۰۱۰	شبکه عصبی- موجکی



شکل (۸): ارزیابی توانایی روش های مختلف مدل سازی تراز آب دریاچه ارومیه

توسط دو معیار ضریب تبیین و جذر میانگین مربعات خطا که به ترتیب برابر ۰/۹۴ و ۰/۱۹۲ متر می باشند مورد ارزیابی قرار گرفت. سپس شبیه سازی و پیش بینی با استفاده از روش شبکه عصبی مصنوعی انجام شد که در آن ضریب تبیین و جذر میانگین مربعات خطا به ترتیب برابر ۰/۹۰ و ۰/۰۳۲ متر می باشد و در مرحله آخر شبیه سازی و پیش بینی با استفاده از روش عصبی موجکی با ضریب تبیین ۰/۹۷

نتیجه گیری و جمع بندی

در پژوهش حاضر شبیه سازی و پیش بینی تراز سطح آب دریاچه ارومیه به سه روش: سری زمانی، شبکه عصبی مصنوعی و شبکه عصبی موجکی انجام شد. در روش سری زمانی مدل های متعددی بر داده های موجود برازش داده شد که از بین آنها با توجه به معیار آکائیک مدل $(1,1,0)$ $ARIMA(2,1,2)$ جهت پیش بینی انتخاب شد، نتایج حاصل از این روش

پیش‌پردازش صورت گرفته بر روی داده‌ها، در مقایسه با دو روش سری زمانی و شبکه عصبی مصنوعی می‌باشد، نتایج قدم پور و شقاقیان (۱۳۹۰) و همچنین ملکی نژاد و پورشرعیانی (۱۳۹۲) در پیش‌بینی تراز آب زیرزمینی نیز تایید کننده دقت بیشتر روش‌های هوشمند در مقابل روش‌های کلاسیک سری زمانی می‌باشد. در نهایت پژوهش حاضر هیچ یک از روش‌های فوق را برای تولید و پیش‌بینی داده رد نمی‌کند.

و جذر میانگین مربعات خطا $0/019$ متر انجام شد. با توجه به ویژگی خودهمبسته و خطی بودن روش‌های استوکستیکی مانند روش سری‌های زمانی این روش قادر به تشخیص روند داده‌ها و گاه‌ها نقاط بیشینه سری زمانی نمی‌باشد. همچنین با توجه به منعطف بودن شبکه‌های عصبی، گاهی این روش نیز در پیش‌بینی سری‌های زمانی به شدت ناپایستا، با مشکل مواجه می‌شوند. در این تحقیق نیز نتایج نشان‌دهنده عملکرد بهتر شبکه عصبی- موجکی، با توجه به

منابع

- حسن‌زاده، ی.، ا. عبدی کردانی و ا. فاخری فرد. ۱۳۹۱. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی. فصلنامه علمی- پژوهشی آب و فاضلاب، شماره ۸۳، ص ۴۸-۵۹.
- رسولی، ع. ا و ش. عباسیان. ۱۳۸۸. تحلیل مقدماتی سری‌های زمانی تراز سطح آب دریاچه ارومیه. نشریه جغرافیا و برنامه ریزی، سال ۱۴، شماره ۲۸، ص ۱۶۵-۱۳۷.
- غفاری، غ و م. وفاخواه. ۱۳۹۲. شبیه‌سازی فرایند بارش- رواناب با استفاده از شبکه عصبی مصنوعی و سیستم فازی- عصبی تطبیقی (مطالعه موردی: حوزه آبخیز حاجی قوشان). پژوهشنامه مدیریت حوزه آبخیز، شماره ۸، ص ۱۳۶-۱۲۰.
- قدم پور، ز و م. شقاقیان. ۱۳۹۰. مقایسه مدل‌های کلاسیک سری زمانی و هوش مصنوعی در تعیین سطح تراز آب زیرزمینی. ششمین کنگره ملی مهندسی عمران. سمنان، دانشگاه سمنان.
- کارآموز، م و ش. عراقی نژاد. ۱۳۸۹. هیدرولوژی پیشرفته. چاپ دوم. انتشارات دانشگاه صنعتی امیرکبیر.
- محتشم، م.، ا. دهقانی، ا. اکبرپور، م. مفتاح هلقی و ب. اعتباری. ۱۳۸۹. پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرجند). مجله آبیاری و زهکشی ایران، شماره ۱، ص ۱۰-۱.
- ملکی نژاد، ح و ر. پورشرعیانی. ۱۳۹۲. کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه موردی: دشت مروست). مجله علوم و مهندسی آبیاری، دوره ۳۶، شماره ۳، ص ۹۲-۸۱.
- نخعی، م و ا. صابری نصر. ۱۳۹۱. پیش‌بینی نوسانات سطح آب زیرزمینی دشت قره با استفاده از شبکه عصبی موجکی و مقایسه آن با مدل عددی MODFLOW. مجله زمین‌شناسی کاربردی پیشرفته. شماره ۴، ص ۴۷-۵۸.
- نوری، م. و م. ب. رهنما. ۱۳۸۵. مدل بارندگی- رواناب با استفاده از تئوری موجک و شبکه‌های عصبی مصنوعی (مطالعه موردی هلیل رود). هفتمین کنگره بین‌المللی مهندسی عمران. تهران، دانشگاه تربیت مدرس، دانشکده عمران.
- نیک منش، م. ر. و ن. طالب بیدختی. ۱۳۹۱. مقایسه توانایی تئوری موجک و سری‌های زمانی در مدل‌سازی بارندگی ماهانه مناطق سعادت شهر و ارسنجان در استان فارس. فصلنامه جغرافیای طبیعی، سال پنجم، شماره ۱۶، ص ۱-۱۰.

Box G. E. P. and G. M. Jenkins. 1976. Time Series Analysis: Forecasting and Control. Holden Day Press. San Francisco.

Cannas, B., A. Fanni, L. See and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks: wavelet transforms and partitioning. *Physics and Chemistry of the Earth*, Vol: 31 (18): 1164-1171.

Ghil, M., M. R. Allen, M. D. Dettinger, K. Ide, D. Kondrashov, M. E. Mann, A. W. Robertson, A. Saunders, Y. Tian, F. Varadi and P. Yiou. 2002. Advanced Spectral Methods For Climatic Time Series. *Reviews of Geophysics*, 1-1:1-41.

Güldal, V. and H. Tongal 2010. Comparison of Recurrent Neural Network, Adaptive Neuro-Fuzzy Inference System and Stochastic Models in Eğirdir Lake Level Forecasting. *Water Resources Management* 24(1): 105-128.

Khatibi, R., M. A. Ghorbani, L. Naghipour, V. Jothiprakash, T. A. Fathima, M. H. Fazelifard. 2014. Inter-comparison of time series models of lake levels predicted by several modeling strategies. *Journal of Hydrology*. 530-545.

Nourani, V., M. Komasi and A. Mano. 2009. A multivariate ANN-wavelet approach for rainfall-runoff modeling. *Water Resource Management*. 23(14): 2877-2894.

Nourani, V., M. Komasi, M. T. Alami. 2012. Hybrid Wavelet-Genetic Programming Approach to Optimize ANN Modeling of Rainfall-Runoff Process. [Journal of Hydrologic Engineering](#). 17(6): 724-741.

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

Forecasting of water level in Urmia Lake using Time series, Artificial Neural Network and Neural Network-Wavelet.

Mehdi Komasi¹, Hamed Nozari², Neda Gheshlaghi³

Abstract

Urmia Lake in Iran is the second largest saline lake in the world. Due to various socio-economical and ecological criteria, Urmia Lake has important role in the Northwestern part of the country but it has faced many problems in recent years. Because of droughts, overuse of surface water resources and dam constructions water level is reduced. One of the important factors that has influence in correct management, is having a suitable point of view for future events in that field. So simulation and forecasting of hydrological variables has many importance. In this research, time series, Artificial Neural Network and Neural Network-Wavelet methods for presentation the best method in monthly scale for simulation and forecasting Urmia Lake water level is compared. Comparing these three methods indicates that forecasting with Neural Network-Wavelet due to considering monthly, seasonal and annual changes in the time series analysis, has the best Performance.

Keywords: Artificial Neural Network, Neural Network-Wavelet, time series, Urmia Lake water level.

¹ Assistant Professor Faculty of Civil Engineering. University of Ayatollah Boroujerdi. email:Komasi@abru.ac.ir

² Assistant Professor Faculty of water Engineering. University of Bu-Ali Sina.

³ MSc Student, Faculty of water Engineering. University of Bu-Ali Sina.