

فازی-عصبی تطبیقی عملکرد بهتری دارند. همچنین در این تحقیق مشاهده گردید که مدل‌های ماشین یادگیری افراطی خیلی سریع‌تر از مدل‌های دیگر، یادگیری در مرحله آموزش را سپری می‌کنند حال آنکه مدل‌های فازی-عصبی تطبیقی زمان بیشتری را برای مرحله آموزش صرف کردند.

کلید واژه‌ها: دریاچه ارومیه، سطح آب، ماشین یادگیری افراطی، مدل‌سازی

مقدمه

مدل‌سازی نوسانات سطح آب دریاچه در برنامه‌ریزی، طراحی، ساخت و راه‌اندازی سازه‌های هیدرولیکی واقع در امتداد دریاچه‌ها، مدیریت آب شیرین برای اهداف تأمین آب، آبیاری، نوسانات جزر و مدی و همچنین عملیات کانال زهکشی ضروری است [۲۵]. نوسانات سطح آب دریاچه حاصل تأثیر عوامل متعددی از جمله عوامل زیست‌محیطی می‌باشند. به عنوان مثال می‌توان از تخلیه‌های ورودی و خروجی، بارش بیش از سطح دریاچه یا حوضه آبریز دریاچه، تبادل آب‌های زیرزمینی، تبخیر در سطح دریاچه، سرعت باد، رطوبت، درجه حرارت نام برد [۲۷، ۲۰]. مدل‌های پیشرفته پیش‌بینی سطح آب دریاچه می‌تواند با استفاده از متغیرهای هیدرولوژیکی و آب و هواشناسی مانند بارش، رواناب، درجه حرارت و تبخیر توسعه یابد. با این وجود، زمانی که کاربر به عنوان یک تصمیم‌گیرنده می‌باشد، توسعه مدلی که نوسانات آینده سطح آب دریاچه را بر پایه اطلاعات سطح آب گذشته پیش‌بینی کند، مقرون به صرفه‌تر است [۲۵، ۲۶].

بسیاری از فرآیندهای مربوط به سیستم‌های طبیعی نسبت به زمان غیرخطی هستند، اگرچه جنبه‌های خاصی از این سیستم‌ها ممکن است نسبت به جنبه‌های دیگر به فرایند خطی نزدیک‌تر باشند. به هر حال ماهیت غیرخطی بودن برای ما کاملاً آشکار نیست [۲۸]. شبکه‌های عصبی مصنوعی (ANN)^۴ و سامانه استنتاج فازی-عصبی تطبیقی (ANFIS)^۵ از جمله روش‌هایی است که در الگوبندی پدیده‌های غیرخطی کاربرد فراوانی دارد. مدل شبکه عصبی مصنوعی، مدلی قوی با توانمندی بالاست که می‌توان با دیدگاهی مثبت در پیش‌بینی مسایل اقلیمی-هیدرولوژیکی به آن نگرست؛ به خصوص

مدل‌سازی نوسانات روزانه سطح آب دریاچه ارومیه با استفاده از مدل ماشین یادگیری افراطی

رحیم برزگر^۱، اصغر اصغری مقدم^۲ و شهلا سلطانی^۳
تاریخ دریافت: ۱۳۹۵/۰۵/۳۰ تاریخ پذیرش: ۱۳۹۵/۰۷/۱۹

چکیده

در دهه‌های اخیر به دلیل افزایش بی‌رویه برداشت از منابع آب سطحی و زیرزمینی، جلوگیری از ورود منابع آب سطحی به دریاچه ارومیه و همچنین تغییرات اقلیمی، سطح آب دریاچه ارومیه کاهش یافته و سبب ایجاد بحران آبی و زیست محیطی در منطقه گردیده است. بنابراین، مدل‌سازی نوسانات سطح آب دریاچه ارومیه برای برنامه‌ریزی و مدیریت منابع آب آن ضروری می‌باشد. هدف از این تحقیق پیش‌بینی نوسانات سطح آب دریاچه ارومیه برای یک، سه و هفت روز آینده با استفاده از مدل ماشین یادگیری افراطی است. برای مقایسه کارایی این مدل از مدل‌های شبکه عصبی مصنوعی و سامانه استنتاج فازی-عصبی تطبیقی استفاده گردید. برای این منظور، از داده‌های روزانه سطح آب دریاچه (آذر ماه ۱۳۴۴- آذر ماه ۱۳۹۱) استفاده گردید. برای توسعه مدل‌ها، از داده‌های سطح آب روز جاری و شش روز گذشته دریاچه ارومیه به عنوان ورودی مدل‌ها به منظور پیش‌بینی سطح آب یک $[h(t+1)]$ ، سه $[h(t+3)]$ و هفت $[h(t+7)]$ روز آینده استفاده گردید. داده‌ها به دو دسته آموزش/اعتبارسنجی (۸۵ درصد) و آزمایش (۱۵ درصد) تقسیم گردید و پس از مدل‌سازی عملکرد مدل‌ها بر اساس پارامترهای ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و ضریب نش-سانکلیف (NSC) ارزیابی گردید. نتایج نشان داد که مدل ماشین یادگیری افراطی با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۹۵، ۰/۰۱۵۱ و ۰/۹۹۹۵ برای مدل‌سازی یک روز آینده سطح آب دریاچه در مقایسه با مدل‌های شبکه عصبی مصنوعی و سامانه استنتاج

۱- دانشجوی دکتری هیدروژئولوژی، گروه علوم زمین، دانشگاه تبریز، تبریز، ایران، پست الکترونیک: rm.barzegar@yahoo.com

۲- نویسنده مسئول و استاد گروه علوم زمین، دانشگاه تبریز، تبریز، ایران، پست الکترونیک: moghaddam@tabrizu.ac.ir

۳- دانشجوی کارشناسی ارشد هیدروژئولوژی، گروه علوم زمین، دانشگاه تبریز، تبریز، ایران، پست الکترونیک: sh.soltani.d@gmail.com

4. Artificial neural network

5. Adaptive nero fuzzy inference nystem

آنجا که این شبکه، قادر است قانون حاکم بر داده‌ها، حتی داده‌های مغشوش را استخراج نماید [۱۸] و در ضمن نیازی به توضیح صریح طبیعت فرآیندها به صورت ریاضی ندارد [۸].

مدل‌های هوش مصنوعی که در مدل‌سازی پدیده‌های غیرخطی پیچیده در سیستم‌های هیدرولوژی و منابع آب استفاده می‌شوند، به تازگی گسترش در دامنه کاربرد آنها دیده می‌شود. اخیراً تعدادی از این مدل‌های هوش مصنوعی شامل شبکه‌های عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی، برنامه‌ریزی بیان ژن (GEP)^۱ و ماشین بردار پشتیبان (SVM)^۲ برای مدل‌سازی و پیش‌بینی نوسانات سطح آب دریاچه‌ها به کار برده شده‌اند. برای مثال، یارار و همکاران [۲۹] برای پیش‌بینی تغییرات در سطح آب دریاچه بهسهر^۳ از مدل‌های ANFIS و خودهمبسته میانگین متحرک فصلی انباشته (SARIMA)^۴ استفاده کردند. آنان دریافتند که عملکرد مدل ANFIS بهتر از SARIMA است. آلتونکایاناک [۳] از مدل ANN برای پیش‌بینی سطح آب یک ماه آینده دریاچه وان در ترکیه بهره گرفت و به این نتیجه رسید که مدل ANN عملکرد بهتری نسبت به مدل الگوی خودرگرسیون میانگین متحرک همراه با متغیر برونزا (ARMAX)^۵ دارد. ثانی‌خانی [۲۵] قابلیت مدل‌های ANFIS، GEP و ANFIS-GEP را برای پیش‌بینی سطح آب یک، دو و سه ماه آینده دریاچه‌های مانیاس^۶ و توز^۷ در ترکیه مورد بررسی قرار دادند و دریافتند که تمامی این مدل‌ها برای پیش‌بینی سطح آب این دریاچه‌ها مناسب هستند. کیشی و همکاران [۲۰] از مدل‌های ANN، ANFIS و GEP برای پیش‌بینی سطح آب سه روز آینده دریاچه به کار گرفتند و به این نتیجه رسیدند که مدل GEP عملکرد بهتری نسبت به مدل‌های ANN و ANFIS دارد.

در سال‌های اخیر تحقیقات متعددی برای مدل‌سازی و پیش‌بینی سطح آب دریاچه ارومیه صورت گرفته است. طالبی‌زاده و مریدنژاد [۲۷] دریافتند که مدل ANFIS در مقایسه با مدل ANN کارایی بهتری در پیش‌بینی سطح آب دریاچه ارومیه دارد. کریمی و همکاران [۱۷] دریافتند که مدل‌های هوش مصنوعی همچون GEP و ANFIS عملکرد بهتری نسبت به مدل‌های مرسوم همچون ARMA^۸ دارد. کاکاحاجی و همکاران [۱۶] به این نتیجه رسیدند که مدل‌های هوش مصنوعی مانند شبکه پرسپترون چند لایه (MLP)^۹ و نروفازی خطی محلی (LLNF)^{۱۰} در مدل‌سازی سطح آب دریاچه ارومیه نتایج بهتری نسبت به مدل‌های آماری خطی همچون خودرگرسیون با متغیر

برونزا (ARX)^{۱۱} و باکس-جنکینس (BJ)^{۱۲} اراده می‌دهند. کیشی و همکاران [۱۹] از مدل کرم شب تاب-ماشین بردار پشتیبان (SVM)^{۱۳} (FA) برای پیش‌بینی سطح آب یک روز آینده دریاچه ارومیه استفاده کردند. آنها نشان دادند که این مدل در مقایسه با مدل‌های GEP و ANN از نظر تعمیم و دقت پیش‌بینی نتایج بهتری دارد.

مدل ماشین یادگیری افراطی (ELM)^{۱۴} یک تکنیک یادگیری سریع با عملکرد تعمیم بالا است که اساساً شبکه‌های عصبی پیشرو لایه پنهان منفرد (SLFN)^{۱۵} را به کار می‌گیرد [۱۵، ۱۴]. کاربرد مدل ماشین یادگیری افراطی آسان است و هیچ پارامتری به جز معماری شبکه از پیش تعریف شده نیاز ندارد. بنابراین این مدل از عوارضی همچون نرخ یادگیری، دوره یادگیری و کمینه محلی که الگوریتم‌های بر اساس شیب با آنها مواجه هستند، به دور هستند [۱۱]. در سال‌های اخیر این مدل به طور موفقیت آمیزی در مسائل هیدرولوژی و منابع آب به کار گرفته شده است [۱۱، ۱۲].

در سالیان اخیر افزایش بی‌رویه برداشت از منابع آب سطحی و زیرزمینی، جلوگیری از ورود منابع آب سطحی به دریاچه و عوامل تشدیدکننده دیگر همچون تغییرات اقلیمی سبب کاهش سطح آب دریاچه ارومیه و ایجاد بحران آبی و زیست محیطی در منطقه گردیده است. بنابراین ضروری است که مدیریت و برنامه‌ریزی صحیح و قابل اعتماد در این زمینه صورت گیرد که لازمه آن مدل‌سازی سطح آب دریاچه برای آینده می‌باشد. هدف از این تحقیق پیش‌بینی نوسانات سطح آب دریاچه ارومیه برای یک، سه و هفت روز آینده با استفاده از مدل یادگیری ماشین افراطی است که برای مقایسه کارایی این مدل از مدل‌های شبکه عصبی مصنوعی و فازی-عصبی تطبیقی نیز استفاده گردید.

مواد و روش‌ها

داده‌ها و منطقه مطالعاتی

دریاچه ارومیه در شمال غرب ایران بین استان‌های آذربایجان شرقی و آذربایجان غربی قرار گرفته است. این دریاچه با موقعیت جغرافیایی ۳۵ درجه و ۴۰ دقیقه تا ۳۸ درجه و ۲۹ دقیقه عرض شمالی و نصف النهار ۴۴ درجه و ۱۳ دقیقه تا ۴۷ درجه و ۵۳ دقیقه طول شرقی، بزرگ‌ترین دریاچه داخلی ایران و دومین دریاچه بزرگ آب شور دنیا می‌باشد. شکل ۱ موقعیت دریاچه ارومیه و حوضه آبریز آن را نشان می‌دهد. طول دریاچه از ۱۳۰ تا ۱۴۶ کیلومتر متغیر بوده و عرض آن در پهن‌ترین قسمت ۵۸ کیلومتر و در کم عرض‌ترین قسمت ۱۵ کیلومتر می‌باشد. وسعت حوضه آبریز دریاچه ارومیه در حدود ۵۲۳۵۵ کیلومتر مربع می‌باشد که از این مقدار حدود ۵۸۲۲ کیلومتر مربع وسعت خود دریاچه است که مستقیماً با ارتفاع آب دریاچه ارتباط داشته و با

1. Genetic expression programming
2. Support vector machine
3. Behsehir
4. Seasonal auto regressive integrated moving average
5. Autoregressive moving average with exogenous inputs
6. Manyas
7. Tuz
8. Autoregressive moving average
9. Multi-layer perceptron
10. Locally linear neuro-fuzzy

11. Autoregressive with exogenous input
12. Box-Jenkins
13. Support vector machine- firefly algorithm
14. Extreme learning machine
15. Single-layer feed-forward neural network

افزایش یا کاهش حجم آب آن تغییر پیدا می‌کند. دمای متوسط سالیانه منطقه از ۱۱ درجه سانتی‌گراد در نواحی نزدیک به دریاچه تا ۲/۵ درجه سانتی‌گراد در نواحی کوهستانی تغییر می‌کند [۲۷].

در این تحقیق از اطلاعات سطح آب روزانه دریاچه ارومیه برای یک دوره زمانی ۴۷ ساله (آذر ماه سال ۱۳۴۴ تا آذر ماه سال ۱۳۹۱) استفاده گردید. جدول ۱ خصوصیات آماری داده‌های روزانه سطح آب دریاچه ارومیه برای این دوره زمانی را نشان می‌دهد. بیشینه و کمینه سطح آب دریاچه در این دوره زمانی به ترتیب ۱۲۷۸/۴۱ و ۱۲۷۰/۶ متر (با میانگین ۱۲۷۵/۱۲ متر) می‌باشند. یکی از مراحل مهم در توسعه مدل‌های هوش مصنوعی، تعیین متغیرهای ورودی مهم می‌باشد. در این مطالعه از اطلاعات سطح آب روز جاری و شش روز گذشته دریاچه ارومیه به عنوان ورودی مدل‌ها، $h(t)$, $h(t-1)$, $h(t-2)$, $h(t-3)$, $h(t-4)$, $h(t-5)$, $h(t-6)$ برای پیش‌بینی سطح آب یک $h(t+1)$ ، سه $h(t+3)$ و هفت $h(t+7)$ روز آینده استفاده گردید. در پیش‌بینی سری‌های زمانی به صورت چند گام زمانی دو روش قابل اجراست: الف) روش پیش‌بینی تکرار و ب) روش پیش‌بینی مستقیم. در روش پیش‌بینی تکرار، پیش‌بینی یک گام زمانی برای ایجاد پیش‌بینی‌های بعدی (برای مثال تا n گام زمانی) صورت می‌گیرد. در مقابل، در روش


پیش‌بینی مستقیم، مدل‌های پیش‌بینی جداگانه (مستقیم) برای هر افق پیش‌بینی انجام می‌گیرد. مزایای هر کدام از این روش‌ها به‌طور جامع بحث شده است [۲۲]. در این مطالعه از روش پیش‌بینی مستقیم استفاده گردید. مزیت اصلی این روش در آسان بودن آن و عدم وجود خطاهای پیش‌بینی تجمعی است [۱۹].

برای مدل‌سازی، اطلاعات سطح آب روزانه به کار گرفته شده به دو دسته داده‌های آموزش / اعتبارسنجی (۸۵ درصد کل داده‌ها) در بازه زمانی آذر ماه سال ۱۳۴۴ تا شهریور ماه سال ۱۳۸۵ و داده‌های آزمایش (۱۵ درصد کل داده‌ها) در بازه زمانی مهر ماه سال ۱۳۸۵ تا آذر ماه سال ۱۳۹۱ تقسیم‌بندی گردید. برای مدل‌سازی هوش مصنوعی، داده‌های ورودی و خروجی مدل‌ها با استفاده از رابطه (۱) بین صفر و یک نرمالیزه شد. سپس پس از اتمام مدل‌سازی این داده‌ها با استفاده از رابطه (۲) به مقادیر واقعی خود برگردانده شدند.

$$X_N = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

$$X = [X_N (X_{\max} - X_{\min})] + X_{\min} \quad (2)$$

در این روابط، X_N مقدار نرمالیزه شده متغیر X ، $X_{\max}$ و $X_{\min}$ مقادیر بیشینه و کمینه متغیر X قبل از نرمالیزه کردن می‌باشند.




شکل ۱- موقعیت دریاچه ارومیه و حوضه آبریز آن

Figure 1. Location of the Urmia Lake and its catchment

جدول ۱- خصوصیات آماری داده‌های روزانه سطح آب دریاچه ارومیه

Table 1. Statistics of the daily water level of Urmia Lake

	کمینه Minimum	میانگین Mean	بیشینه Maximum	انحراف معیار Standard deviation	چولگی Skewness	کشیدگی Kurtosis
سطح آب (متر) Water level (m)	1270.6	1275.12	1278.41	1.78	-0.7	-0.31



شکل ۲- ساختار مدل شبکه عصبی مصنوعی

Figure 2. The structure of the ANN model

در این مدل هفت متغیر $[h(t), h(t-1), h(t-2), h(t-3), h(t-4), h(t-5), h(t-6)]$ به عنوان ورودی در لایه اول و سطح آب دریاچه در یک، سه و هفت روز آینده به عنوان خروجی در لایه سوم به کار برده شدند.

سامانه استنتاج فازی-عصبی تطبیقی
سامانه استنتاج فازی-عصبی تطبیقی یک روش ترکیبی از محاسبات نرم و شبکه‌های عصبی است که اولین بار توسط جانگ [۴] معرفی گردید. در مدل‌های فازی، ورودی‌ها به صورت متغیرهای بیان فازی مطرح شده و با قواعد فازی (اگر-آنگاه) به خروجی‌هایی که به صورت متغیرهای بیان فازی تعریف شده، متصل می‌شوند. مطابق شکل (۳) ساختار سیستم فازی-عصبی از پنج لایه به شرح زیر تشکیل می‌گردد.

لایه اول: این لایه به عنوان لایه ورودی شناخته می‌شود. در این لایه هر گره i مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تعریف شده برای آن تولید می‌نماید. به عنوان مثال برای دو ورودی و دو تابع عضویت می‌توان نوشت [۴]:

$$O_{1,i} = \mu_{A_i}(x) \quad \text{for } i = 1, 2, \text{ or } \quad (4)$$

$$O_{1,i} = \mu_{B_{i-2}}(y) \quad \text{for } i = 3, 4 \quad (5)$$

که در آن x و y ورودی‌های اول و دوم، μ_{A_i} و $\mu_{B_{i-2}}$ توابع عضویت مجموعه‌های فازی A_i و B_i هستند.

توابع عضویت انواع متفاوتی دارد که از جمله آن می‌توان به توابع دوزنقه‌ای، مثلثی، سیگموئید، گوسی و تابع زنگوله‌ای شکل که حالت کلی‌تری از آنها را شامل می‌شود، اشاره کرد. تابع گوسی دارای مزایای هموار و غیر صفر بودن است و همچنین پارامترهای کمتری دارد به همین دلیل در این تحقیق از تابع عضویت گوسی استفاده گردید.

لایه دوم: در این لایه مقادیر ورودی به هر گره در هم ضرب و وزن قانون‌ها به دست می‌آید. برای گره اول داریم:

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1, 2 \quad (6)$$

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی در واقع، مدل ساده‌شده‌ای از مغز انسان است که توانایی رخ دادن فرآیندها و ترکیبات دلخواه غیرخطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را داراست [۱۸]. هر شبکه عصبی از سه لایه ورودی، مخفی و خروجی تشکیل شده است. در هر لایه تعدادی پردازشگر به نام نرون وجود دارد که پاسخ آنها به سیگنال ورودی توسط توابع انتقال منتقل می‌شوند. توابع انتقال معمول مورد استفاده در شبکه‌های عصبی مصنوعی تابع سیگموئید^۱ و تانژانت هایپربولیک^۲ می‌باشند.

شبکه پرسپترون چند لایه از شبکه‌های عصبی مصنوعی است که بر مبنای یک واحد محاسباتی به نام پرسپترون ساخته می‌شود. یک پرسپترون برداری از ورودی‌ها با مقادیر حقیقی را گرفته و یک ترکیب خطی از این ورودی‌ها را محاسبه می‌کند. اگر مقدار حاصل از یک مقدار آستانه بیشتر بود خروجی پرسپترون برابر با یک و در غیر این صورت معادل منفی یک خواهد بود. در طی آموزش شبکه MLP به کمک الگوریتم یادگیری پس انتشار خطا (BP^۳)، ابتدا محاسبات از ورودی شبکه به سوی خروجی شبکه انجام می‌شود و سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد. در ابتدا، محاسبه خروجی به صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود [۵].

مدل‌های شبکه عصبی به کار گرفته شده در این مطالعه از نوع شبکه چند لایه پیش‌خور^۴ (FF) با الگوریتم پس انتشار خطا و تکنیک یادگیری مارکوارت - لونبرگ^۵ می‌باشند که ساختار آن در شکل (۲) نشان داده شده است. این الگوریتم نوعی از روش نیوتن است که بدون نیاز به محاسبه ماتریس هسین^۶ برای آموزش سریع با مرتبه درجه دو طراحی می‌شود [۱]. بنابراین، با استفاده از معادله (۳) خواهیم داشت [۲۴، ۶]:

$$\hat{y}_k = f \left[\sum_{i=1}^{M_N} w_{kj} \cdot f_h \left(\sum_{i=1}^{N_N} w_{ji} x_i + w_{j0} \right) + w_{k0} \right] \quad (3)$$

در این رابطه x_i متغیرهای ورودی لایه ورودی، $\hat{y}_k$ متغیرهای خروجی محاسباتی، f_h تابع انتقال لایه پنهان، f تابع انتقال برای نرون خروجی، N_N تعداد نرون‌های لایه ورودی، M_N تعداد نرون‌های لایه پنهان، w_{ji} وزن لایه پنهان که i^{th} نرون در لایه ورودی را به j^{th} نرون در لایه پنهان وصل می‌کند، w_{j0} بایاس j^{th} لایه پنهان، w_{kj} وزن لایه خروجی که j^{th} نرون در لایه پنهان را به k^{th} نرون در لایه خروجی وصل می‌کند و w_{k0} بایاس k^{th} نرون خروجی می‌باشند.

1. Sigmoid function
2. Hyperbolic tangent function
3. Back propagation
4. Feed forward
5. Levenberg-Marquardt
6. Hessian matrix

که در آن $a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ بردار وزن ورودی متصل به گره لایه پنهان، مقدار بایاس گره‌های لایه پنهان، $b_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ بردار وزن خروجی متصل به گره لایه پنهان می‌باشند.

معادله (۱۰) را می‌توان به صورت زیر نوشت:

$$\sum_{i=1}^L \beta_i f_i(x_j) = H\beta \quad (11)$$

$$H = \begin{bmatrix} f(a_1, x_1, b_1) & \dots & f(a_L, x_1, b_L) \\ \vdots & \dots & \vdots \\ f(a_1, x_N, b_1) & \dots & f(a_L, x_N, b_L) \end{bmatrix}_{N \times L} \quad (12)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad T = \begin{bmatrix} y_1^T \\ \vdots \\ y_L^T \end{bmatrix}_{N \times m} \quad (13)$$

در این معادلات H ماتریس خروجی لایه پنهان، β ماتریس خروجی وزن و T ماتریس برچسب می‌باشد.

در این مدل اولین مرحله تعیین مقادیر تصادفی وزن‌های ورودی a و بایاس گره لایه پنهان b در مرحله آموزش است. پس از تعیین این وزن‌ها و بایاس‌ها، ماتریس خروجی لایه پنهان می‌تواند از نمونه‌های ورودی به دست آید. بنابراین، آموزش SFLN به حل حداقل مربعات تبدیل می‌شود. پس از تعیین وزن‌های ورودی و بایاس‌های لایه پنهان، ماتریس خروجی لایه پنهان می‌تواند از نمونه‌های آموزش به دست آید. بنابراین آموزش SFLN به حل حداقل مربعات^۲ تبدیل می‌شود. با معرفی تئوری ساماندهی^۳ برای مدل ELM تابع هدف به صورت زیر بیان می‌شود.

$$\min L_{ELM} = \frac{1}{2} \|\beta\|^2 + \frac{c}{2} \|T - H\beta\|^2 \quad (14)$$

حل حداقل مربعات معادله (۱۴) می‌شود:

$$V - CH^T(T - H\beta) = 0 \quad (15)$$

وقتی که تعداد نمونه‌های مرحله آموزش بیشتر از تعداد گره‌های

$$\beta = \left(\frac{1}{c} + H^T H\right)^{-1} H^T T \quad \text{لایه پنهان باشد داریم:} \quad (16)$$

وقتی که تعداد نمونه‌های مرحله آموزش کمتر از تعداد گره‌های

$$\beta = H^T \left(\frac{1}{c} + HH^T\right)^{-1} T \quad \text{لایه پنهان باشد داریم:} \quad (17)$$

زمانی که تعداد واحدهای گره پنهان به حد کافی بزرگ باشد، دقت رگرسیون این الگوریتم همیشه ثابت خواهد بود. شکل (۴) ساختار مدل ماشین یادگیری افراطی را نشان می‌دهد.

در این مطالعه از تابع انتقال پایه شعاعی^۵ f_{radbas} استفاده گردید که به صورت معادله (۱۸) بیان می‌شود.

$$f_{radbas}(a, b, x) = \exp(-(ax + b)^2) \quad (18)$$

لایه سوم: هر گره در این لایه، عمل محاسبه وزن نسبی قوانین را با استفاده از معادله زیر انجام می‌دهد.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (7)$$


لایه چهارم: این لایه به لایه قوانین معروف بوده و از جمع عملیات‌ها بر روی سیگنال‌های ورودی به این لایه بدست می‌آید. در این لایه مقادیر پارامترهای p, q و r بهینه می‌شوند. برای این لایه می‌توان نوشت:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i) \quad (8)$$

که p_i, q_i, r_i مجموع پارامترها و $\bar{w}$ خروجی این لایه است. لایه پنجم: تنها گره این لایه، یک گره ثابت می‌باشد که خروجی اصلی شبکه را با جمع‌آوری ورودی‌ها به گره به صورت i محاسبه می‌نماید.

$$O_{5,i} = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum_{i=1}^2 w_i f_i}{\sum_{i=1}^2 w_i} \quad (9)$$

در این تحقیق برای آموزش مدل فازی-عصبی تطبیقی از دو الگوریتم پس‌انتشار خطا و الگوریتم ترکیبی که ترکیبی از دو روش کاهش گرادینان و کمینه مربعات است، استفاده گردید [۵،۷].



شکل ۳- ساختار مدل استنتاج فازی-عصبی تطبیقی

Figure 3. The structure of the ANFIS model

ماشین یادگیری افراطی


اخیراً یک الگوریتم یادگیری جدید برای شبکه‌های کنترل‌کننده با لایه پنهان منفرد (SLFN) پیشنهاد شده است که ماشین یادگیری افراطی (ELM) نامیده می‌شود [۱۴]. در این مدل پارامترهای گره پنهان (وزن‌های ورودی، تمایلات پنهان یا مراکز توابع و عوامل موثر بر گره پنهان) به شکل تصادفی انتخاب شده و وزن‌های خروجی به صورت تحلیلی با استفاده از مور-پنورس (MP)^۱ معکوس عمومی تعیین می‌شوند [۳۱]. ماشین یادگیری افراطی از مشکلات بسیاری همچون معیار توقف، نرخ یادگیری و دوره‌های یادگیری می‌باشد که مبتنی بر روش‌های یادگیری هستند و به وسیله شیب ایجاد می‌گردند، جلوگیری می‌کند.

فرض کنید که N نمونه دلخواه در مرحله آموزش به صورت $(x_i, y_i) \in R^n \times R^m$ ($i = 1, 2, 3, \dots, n$) با تعداد L گره پنهان وجود دارد. بنابراین، مدل SFLN با تابع انتقال $f(x)$ می‌تواند به صورت زیر بیان شود [۲۱، ۱۳، ۲]:

$$\sum_{i=1}^L \beta_i f_i(x_j) = \sum_{i=1}^L \beta_i f(a_i, b_i, x), \quad j = 1, \dots, N \quad (10)$$

1. Moore-Penrose

2. Label matrix
3. Least square solution
4. regularization theory
5. Radial basis function



شکل ۴- ساختار مدل ماشین یادگیری افراطی
Figure 4. The structure of the ELM model

چهار و پانزده می‌شود. بر این اساس، تعداد نرون‌های پنهان برای پیش‌بینی‌های یک، سه و هفت روز گام زمانی به ترتیب هفت، شش و دوازده تعیین شدند. برای تمامی مدل‌های شبکه عصبی مصنوعی تابع انتقال از لایه اول به دوم تابع تانزانست هیپربولیک (TANSIG) و از لایه دوم به سوم تابع تبدیل خطی (PURELIN) در نظر گرفته شدند که اغلب بهترین نتایج را ارائه می‌دهند [۴،۵،۶،۷]. تعداد گام‌ها^۴ برای تمامی مدل‌ها ۱۰۰۰ در نظر گرفته شد. جدول (۲) پارامترهای حاصل از مدل‌های شبکه عصبی مصنوعی در مرحله آموزش را نشان می‌دهد. بر اساس مقادیر خطای میانگین مربعات^۵ (MSE) برابر با^۶ ۲/۴۲×۱۰^{-۶}، ۷/۶۴×۱۰^{-۶} و ۲/۴۱×۱۰^{-۵} برای گام‌های زمانی یک، سه و هفت روز آینده، بهترین عملکرد مدل‌ها به ترتیب در گام‌های ۷۳، ۷۲ و ۱۲۲ بدست آمدند. مقدار شیب برای گام‌های زمانی یک، سه و هفت روز آینده در دوره تکرار ۷۹، ۷۸ و ۱۲۸ به ترتیب برابر با ۱/۲۸×۱۰^{-۵}، ۶/۴۳×۱۰^{-۵} و ۷/۸۷×۱۰^{-۶} به دست آمدند که سبب توقف مرحله آموزش شدند. عملکرد مدل‌های شبکه عصبی مصنوعی برای مرحله آموزش در شکل ۵ نشان داده شده‌اند. پس از پایان مراحل آموزش و اعتبارسنجی مدل‌ها، داده‌های مربوط به مرحله آزمایش برای مدل‌ها تعریف شد تا مقادیر پیش‌بینی شده محاسبه گردد. نتایج حاصل از مدل‌سازی شبکه عصبی مصنوعی در مرحله آموزش و آزمایش به ترتیب در جدول‌های ۵ و ۶ نشان داده شده است. نتایج مدل‌های شبکه عصبی مصنوعی نشان می‌دهند که مدل‌سازی سه روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۸۷، ۰/۴۹۷ و ۰/۹۹۴۷ و مدل‌سازی هفت روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۸۲۲، ۰/۲۳۷ و ۰/۸۸۰۴ در مرحله آموزش، به ترتیب بهترین و بدترین عملکرد را در پیش‌بینی سطح آب دریاچه دارند.

معیارهای ارزیابی عملکرد مدل‌ها

به منظور ارزیابی و مقایسه نتایج حاصل از مدل‌های به کار برده شده در این تحقیق، از شاخص‌های آماری مانند ضریب تعیین^۱ (R^2)، جذر میانگین مربعات خطا^۲ (RMSE) و ضریب ناش- ساتکلیف^۳ (NSC) استفاده گردید. روابط این معیارها به شکل زیر هستند.

$$R^2 = \frac{[\sum_{i=1}^N (P_i - \bar{P})(O_i - \bar{O})]^2}{\sum_{i=1}^N (P_i - \bar{P})^2 \sum_{i=1}^N (O_i - \bar{O})^2} \quad (19)$$

$$RMSE = [N^{-1} \sum_{i=1}^N (P_i - O_i)^2]^{0.5} \quad (20)$$

$$NSC = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \quad (21)$$

در روابط فوق، O_i مقادیر مشاهداتی، $\bar{O}$ میانگین مقادیر مشاهداتی، P_i مقادیر پیش‌بینی شده، $\bar{P}$ میانگین مقادیر پیش‌بینی شده و N تعداد کل داده‌ها می‌باشند. هر چه مقدار RMSE به صفر و مقادیر R^2 و NSC به یک نزدیک باشند نشان‌دهنده نزدیک‌تر بودن مقادیر مشاهداتی و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.

نتایج و بحث

برای ایجاد مدل شبکه عصبی مصنوعی، از شبکه‌های سه لایه MLP با الگوریتم آموزش لونیگ-مارکوارت استفاده گردید. در این تحقیق، تعداد نرون‌های پنهان بین $\log N$ و $2n+1$ محدود شدند (N تعداد داده‌های مرحله آزمایش و n تعداد نرون‌های ورودی) [۲۳، ۲۹]. سپس با روش آزمون و خطا براساس رسیدن به بهترین عملکرد شبکه (کمترین خطا)، تعداد نرون‌های پنهان تعیین گردیدند. برای مثال در مطالعه حاضر اگر $\log N = 14917$ و $n = 7$ باشد، تعداد نرون‌های پنهان بین

4. Epoch
5. Mean square error

1. Coefficient of determination
2. Root mean square errors
3. Nash-Sutcliffe efficiency coefficient

جدول ۲- تعداد گام‌ها، خطای میانگین مربعات و زمان آموزش در مدل‌های شبکه عصبی مصنوعی

Table 2. Epoch, mean square error and training time of the ANN models

Model مدل	Epoch تعداد گام	Mean square error خطای میانگین مربعات	Training time(s) زمان آموزش (ثانیه)
h(t+1) سطح آب یک روز آینده	73	$10^{-6} \times 2.42$	1.14
h(t+3) سطح آب سه روز آینده	72	$10^{-6} \times 7.64$	1.35
h(t+7) سطح آب هفت روز آینده	122	$10^{-6} \times 2.41$	2.32

جدول ۳- شعاع دسته‌بندی، تعداد قوانین «اگر-آنگاه» به‌وجود آمده و زمان آموزش در مدل‌های فازی-عصبی

Table 3. Clustering radius, number of generated fuzzy 'if-then' rules of the ANFIS models


Model مدل	No. of "if-then" rules تعداد قوانین «اگر-آنگاه»	Clustering radius بندی شعاع دسته	Training time(s) زمان آموزش (ثانیه)
h(t+1) سطح آب یک روز آینده	5	0.55	21.13
h(t+3) سطح آب سه روز آینده	3	0.7	25.83
h(t+7) سطح آب هفت روز آینده	4	0.6	24.21

شده محاسبه گردد. نتایج حاصل از مدل‌سازی استنتاج فازی-عصبی تطبیقی در مرحله آموزش و آزمایش در جدول‌های ۲ و ۳ نشان داده شده است. با توجه به معیارهای ارزیابی عملکرد مدل‌های فازی-عصبی می‌توان گفت که مدل‌سازی یک روز آینده سطح آب دریاچه با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۹۵، ۰/۱۵۵ و ۰/۹۹۹۵ متر و در مرحله آموزش، بهترین عملکرد را دارد. حال آنکه، مدل‌سازی هفت روز آینده سطح آب دریاچه با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۷۶، ۰/۳۴۱ و ۰/۹۹۷۵ متر و در مرحله آموزش، بدترین عملکرد را دارد.


برای توسعه مدل‌های ماشین یادگیری افراطی از سه لایه برای ایجاد معماری شبکه استفاده گردید. در لایه اول و سوم مدل، ورودی‌ها و خروجی همانند مدل‌های عصبی و فازی-عصبی بودند. در لایه دوم نرون‌های پنهان قرار دارند که تعداد این نرون‌ها برای هر مدل از طریق آزمون و خطا تعیین گردید. تعداد نرون‌های لایه پنهان با افزایش تدریجی از مقدار یک تا پنجاه بر اساس کمترین خطا به ترتیب برابر با ۱۴، ۲۱ و ۱۸ برای مدل‌های پیش‌بینی سطح آب یک، سه و هفت روز آینده تعیین گردیدند (جدول ۴). در این مدل‌ها از تابع انتقال پایه شعاعی (radbas) استفاده گردید. پس از پایان مرحله آموزش مدل‌ها، داده‌های مربوط به مرحله آزمایش برای مدل‌ها تعریف شد تا مقادیر پیش‌بینی گرفته شد تا مقادیر پیش‌بینی شده محاسبه گردد.

مدل‌های فازی-عصبی تطبیقی نیز با همان داده‌های مربوط به مدل شبکه عصبی مصنوعی، آموزش و آزمایش گردیدند. در مدل‌های فازی-عصبی از الگوریتم ترکیبی که از روش‌های آموزش پس‌انتشار خطا و کمینه مربعات خطا بهره‌گیری می‌کند، برای بهینه‌سازی پارامترهای تابع عضویت گوسین و ضرایب معادلات خطی خروجی استفاده گردید. شکل (۱۳) توابع عضویت گوسی^۱ به‌کار گرفته شده در مدل‌سازی‌ها را نشان می‌دهد. در این مدل‌ها تعداد گام و میزان خطا به ترتیب برابر با ۵۰۰ و صفر تنظیم گردید. در این مدل از روش‌های مختلفی از جمله روش افراز شبکه^۲ و دسته‌بندی تفریقی^۳ برای طبقه‌بندی داده‌ای استفاده می‌شود [۹] که در این مطالعه از روش دسته‌بندی تفریقی استفاده شد. مهم‌ترین پارامتر در این روش تعیین شعاع دسته‌بندی می‌باشد که کنترل‌کننده تعداد دسته‌ها و قوانین فازی است. شعاع دسته‌بندی مدل‌ها با افزایش تدریجی از مقدار صفر تا یک بر اساس کمترین خطا به ترتیب برابر با ۰/۵۵، ۰/۷ و ۰/۶ برای مدل‌های پیش‌بینی سطح آب یک، سه و هفت روز آینده تعیین گردید (جدول ۳). پس از پایان مرحله آموزش مدل‌ها، داده‌های مربوط به مرحله آزمایش برای مدل‌ها تعریف شد تا مقادیر پیش‌بینی

1. Gaussian membership functions
2. Grid partitioning
3. Subtractive clustering (Sub-Clustering)



شکل ۵- عملکرد مدل‌های شبکه عصبی برای مرحله آموزش در مدل‌سازی سطح آب دریاچه برای الف) یک ب) سه و ج) هفت روز آینده
Figure 5. The performance of the ANN models for training stage in Urmia Lake water level modeling for a) one b) three and c) seven days ahead



شکل ۶- توابع عضویت متغیرهای ورودی مدل فازی- عصبی در پیش‌بینی سطح آب دریاچه برای الف) یک ب) سه و ج) هفت روز آینده
Figure 6. Membership functions of the ANFIS model of the input variables in forecasting of the lake water level for a) one b) three and c) seven days ahead

جدول ۴- تعداد نرون‌های لایه پنهان و زمان آموزش در مدل‌های ماشین یادگیری افراطی

Table 3. Number of hidden neurons and training time of the ELM models

Model	No. of hidden neurons	Training time(s)
مدل	های لایه پنهان تعداد نرون	زمان آموزش (ثانیه)
h (t+1) سطح آب یک روز آینده	14	0.59
h (t+3) سطح آب سه روز آینده	21	0.35
h (t+7) سطح آب هفت روز آینده	18	0.11

جدول ۵- نتایج حاصل از مدل‌سازی نوسانات سطح آب دریاچه ارومیه در مرحله آموزش

Table 3. Results of the Urmia Lake water level fluctuations modeling in the training stage

Model مدل	h (t+1) سطح آب یک روز آینده			h (t+3) سطح آب سه روز آینده			h (t+7) سطح آب هفت روز آینده		
	R ²	RMSE (m)	NSC	R ²	RMSE (m)	NSC	R ²	RMSE (m)	NSC
ANN شبکه عصبی	0.9999	0.0135	0.9999	0.9996	0.0232	0.9996	0.9990	0.0283	0.9990
ANFIS فازی-عصبی	0.9999	0.0132	0.9999	0.9996	0.0230	0.9996	0.9990	0.0284	0.9990
ELM ماشین یادگیری افراطی	0.9999	0.0135	0.9999	0.9996	0.0232	0.9996	0.9990	0.0280	0.9990


که مدل ماشین یادگیری افراطی در مقایسه با مدل‌های شبکه عصبی مصنوعی و فازی-عصبی عملکرد بهتری دارند. همچنین این مدل از لحاظ زمان آموزش نیز مزیت‌هایی را نسبت به مدل‌های دیگر نشان داد. جدول‌های ۲، ۳ و ۴ زمان سپری شده برای آموزش مدل‌های مختلف به کار گرفته شده را نشان می‌دهد. در این تحقیق مشاهده گردید که مدل‌های ELM خیلی سریع‌تر از مدل‌های دیگر، یادگیری در مرحله آموزش را سپری می‌کنند حال آنکه مدل‌های فازی عصبی تطبیقی زمان بیشتری را برای مرحله آموزش صرف کردند. به طور کلی، لازم نیست که پارامترهای لایه پنهان مدل ELM تنظیم شود و می‌تواند از داده‌های آموزش مجزا باشد. بنابراین، مدل ELM فقط وزن‌های خروجی را به طور تحلیلی محاسبه می‌کند و سرعت یادگیری به مراتب بیشتر و پیچیدگی محاسباتی کمتری را نسبت به مدل‌های ANN و ANFIS دارد.

نتایج حاصل از مدل‌سازی ماشین یادگیری افراطی در مرحله آموزش و آزمایش در جدول‌های ۵ و ۶ نشان داده شده است. ارزیابی معیارهای عملکرد مدل‌های ماشین یادگیری افراطی نشان می‌دهند که مدل‌سازی یک روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۹۵، ۰/۰۱۵۱ متر و ۰/۹۹۹۵ و مدل‌سازی هفت روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۷۶، ۰/۰۳۴۱ متر و ۰/۹۹۷۵ در مرحله آموزش، به ترتیب بهترین و بدترین عملکرد را در پیش‌بینی سطح آب دریاچه دارند. شکل ۷ به طور نمونه مقایسه بین مقادیر سطح آب اندازه‌گیری شده و مدل‌سازی شده یک روز آینده برای مدل‌های شبکه عصبی مصنوعی، فازی-عصبی و یادگیری ماشین افراطی در مرحله آزمایش را نشان می‌دهد. در این مطالعه به دلیل همبستگی بالای پارامترهای ورودی و خروجی مدل‌های توسعه یافته، عملکرد مدل‌ها تقریباً به هم نزدیک می‌باشند. با این وجود نتایج نشان می‌دهد

جدول ۶- نتایج حاصل از مدل‌سازی نوسانات سطح آب دریاچه ارومیه در مرحله آزمایش

Table 4. Results of the Urmia Lake water level fluctuations modeling in the testing stage

Model مدل	h (t+1) سطح آب یک روز آینده			h (t+3) سطح آب سه روز آینده			h (t+7) سطح آب هفت روز آینده		
	R ²	RMSE (m)	NSC	R ²	RMSE (m)	NSC	R ²	RMSE (m)	NSC
ANN شبکه عصبی	0.9887	0.1979	0.9165	0.9987	0.0497	0.9947	0.9822	0.2370	0.8804
ANFIS فازی-عصبی	0.9995	0.0155	0.9995	0.9987	0.0245	0.9987	0.9971	0.0370	0.9971
ELM ماشین یادگیری افراطی	0.9995	0.0151	0.9995	0.9991	0.0208	0.9991	0.9976	0.0341	0.9975



شکل ۷- مقایسه مقادیر اندازه‌گیری‌شده و پیش‌بینی‌شده یک روز آینده سطح آب دریاچه ارومیه در مرحله آزمایش

Figure 7. Comparison of the measured and forecasted one step ahead water level of the Urmia Lake in the testing stage

نتیجه گیری

در این تحقیق از داده‌های سطح آب شش روز گذشته دریاچه ارومیه برای پیش‌بینی سطح آب یک، سه و هفت روز آینده با به‌کارگیری مدل‌های شبکه عصبی مصنوعی، فازی-عصبی تطبیقی و ماشین یادگیری افراطی استفاده گردید و از معیارهای ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و ضریب نش-ساتکلیف (NSC) برای ارزیابی عملکرد مدل‌ها بهره گرفته شد. ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی نشان دادند که مدل‌سازی سه روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۸۷، ۰/۰۴۹۷ و ۰/۹۹۴۷ و مدل‌سازی هفت روز آینده سطح آب با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۸۲۲، ۰/۲۳۷ و ۰/۸۸۰۴ در مرحله آموزش، به ترتیب بهترین و بدترین عملکرد را در پیش‌بینی سطح آب دریاچه دارند. نتایج مدل‌های فازی-عصبی نشان دادند که مدل‌سازی یک روز آینده سطح آب دریاچه با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۹۵، ۰/۰۱۵۵ و ۰/۹۹۹۵ در مرحله آموزش، بهترین عملکرد را دارد. حال آنکه، مدل‌سازی هفت روز آینده سطح آب دریاچه با مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۷۶، ۰/۰۳۴۱ و ۰/۹۹۷۵ در مرحله آموزش، بدترین عملکرد را دارد. همچنین با بهره‌گیری از مدل‌های ماشین یادگیری افراطی برای مدل‌سازی یک روز آینده سطح آب، مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۹۵، ۰/۰۱۵۱ و ۰/۹۹۹۵ و برای مدل‌سازی هفت روز آینده سطح آب، مقادیر R^2 ، RMSE و NSC به ترتیب برابر با ۰/۹۹۷۶، ۰/۰۳۴۱ و ۰/۹۹۷۵ در مرحله آموزش به دست آمدند که به ترتیب بهترین و بدترین عملکرد را در پیش‌بینی سطح آب دریاچه داشتند. به طور کلی یافته‌ها نشان دادند که مدل ماشین یادگیری افراطی در مقایسه با مدل‌های شبکه عصبی و فازی-عصبی عملکرد بهتری دارند. در این تحقیق مشاهده گردید که مدل‌های ماشین یادگیری افراطی خیلی سریع‌تر از مدل‌های دیگر، یادگیری در مرحله آموزش را سپری می‌کنند حال آنکه مدل‌های فازی-عصبی زمان بیشتری را برای مرحله آموزش صرف کردند. مدل‌های حاصل می‌توانند بر اساس دقت طرح در برنامه‌ریزی و مدیریت هر چه بهتر برنامه‌های نجات دریاچه ارومیه مورد استفاده قرار گیرند.

منابع

algorithm) to predict exergetic performance of a DI diesel engine running on diesel/biodiesel blends containing polymer waste. Energy. 94:443-456.

3) Altunkaynak, A. 2007. Forecasting surface water level fluctuations of Lake Van by artificial neural networks. Water Resources Management. 21(2):399-408.

4) Barzegar, R. Adamowski, J. and Asghari Moghaddam, A. 2016. Application of wavelet-artificial intelligence hybrid models for water quality prediction: a case study in Aji-Chay River, Iran. Stochastic Environmental Research and Risk Assessment.

5) Barzegar, R. and Asghari Moghaddam, A. 2016. Combining the advantages of neural networks using the concept of committee machine in the groundwater salinity prediction. Modeling Earth Systems and Environment. 2:26.

6) Barzegar, R., Asghari Moghaddam, A., and Baghban, H., 2016b. A supervised committee machine artificial intelligent for improving DRASTIC method to assess groundwater contamination risk: a case study from Tabriz plain aquifer, Iran. Stochastic Environmental Research and Risk Assessment. 30(3):883-899.

7) Barzegar, R. Sattarpour M. Nikudel, MR. and Asghari Moghaddam, A. 2016. Comparative evaluation of artificial intelligence models for prediction of uniaxial compressive strength of travertine rocks, Case study: Azarshahr area, NW Iran. Modeling Earth Systems and Environment. 2:76.

8) Basheer, IA. and Hajmeer, M. 2000. Artificial neural networks: fundamentals, computing, design, and application. Journal of Microbiological Methods. 43:3-31.

9) Chiu, SL. 1994. Fuzzy model identification based on cluster estimation. Journal of Intelligent and Fuzzy Systems. 2(3):267-278.

10) Deo, R. Şahin, M. 2015. Application of the extreme learning machine algorithm for the prediction of monthly Effective Drought Index in eastern Australia. Atmospheric Research. 153:512-525.

11) Deo, RC. and Şahin, M. 2016. An extreme learning machine model for the simulation of monthly

1) Adamowski, JF. and Sun, K. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. Journal of Hydrology. 390(1-2):85-91.

2) Aghbashlo, M. Shamshirband, S. Tabatabaei, M. Yee, PL. and Larimi, YN. 2016. The use of ELM-WT (extreme learning machine with wavelet transform

- Cai, Z. and Lin, J. 2016. Applying a new localized generalization error model to design neural networks trained with extreme learning machine. *Neural Computing and Applications*. 27:59–66
- 22) Marcellino, M. Stock, J. and Watson, MW. 2006. A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. *Journal of Econometrics*. 135:499–526.
- 23) Mishra, AK. and Desai, VR. 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modelling*. 198(1–2):127–138.
- 24) Nourani, V. Baghanam, AH. Adamowski, J. and Gebremichael, M. 2013. Using self-organizing maps and wavelet transforms for space–time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling. *Journal of Hydrology*. 476:228–243
- 25) Sanikhani, H. Kisi, O. Kiafar, H. and Ghavidel, SZZ. 2015. Comparison of different data-driven approaches for modeling lake level fluctuations: The case of Manyas and Tuz Lakes (Turkey). *Water Resources Management*. 29(5):1557–1574.
- 26) Şen, Z. Kadioğlu, M. and Batur, E. 2000. Stochastic modelling of the Van Lake monthly level fluctuations in Turkey. *Theoretical and Applied Climatology*. 65(1-2):99–110.
- 27) Talebizadeh, M. and Moridnejad, A. 2011. Uncertainty analysis for the forecast of lake level fluctuations using ensembles of ANN and ANFIS models. *Expert Systems with Applications*. 38(4):4126–4135.
- 28) Tsonis, AA. 2001. Probing the linearity and nonlinearity in the transitions of the atmospheric circulation. *Nonlinear Processes Geophysics*. 8:341–345.
- 29) Wanas, N. Auda, G. Kamel, MS. and Karray, F. 1998. On the optimal number of hidden nodes in a neural network. *Proceedings of the IEEE Canadian Conference on Electrical and Computer Engineering*. 2:918–921.
- 30) Yarar, A. Onüçyıldız, M. and Coptý, NK. 2009. Modelling level changes in lakes using neuro-fuzzy and artificial neural networks. *Journal of Hydrology*. mean streamflow water level in eastern Queensland. *Environmental Monitoring and Assessment*. 188:90
- 12) Deo, RC. Samui, P. and Kim, D. 2016. Estimation of monthly evaporative loss using relevance vector machine, extreme learning machine and multivariate adaptive regression spline models. *Stochastic Environmental Research and Risk Assessment*. 30:1769.
- 13) Ding, S. Zhang, J. Xu, X. and Zhang, Y. 2015. A wavelet extreme learning machine. *Neural Computing and Applications*. 27(4):1033–1040.
- 14) Huang, GB. Zhu, QY. and Siew, CK. 2004. Extreme learning Machine: a new learning scheme of feedforward neural networks. *International Joint Conference on Neural Networks*. 2:985–90.
- 15) Huang, GB. Zhu, Q.Y. and Siew, CK. 2006. Extreme learning machine: Theory and applications. *Neurocomputing*. 70(1):489–501.
- 16) Kakahaji, H. Dehghan Banadaki, H. Kakahaji, A. and Kakahaji, A. 2013. Prediction of Urmia Lake water-level fluctuations by using analytical, linear statistic and intelligent methods. *Water Resources Management*. 27(13):4469–4492.
- 17) Karimi, S. Shiri, J. Kisi, O. and Makarynsky, O. 2012. Forecasting water level fluctuations of Urmieh Lake using gene expression programming and adaptive neuro-fuzzy inference system. *International Journal of Ocean and Climate Systems*. 3(2):109–125.
- 18) Khoshhal Dastjerdi, J. and Hosseini, SM. 2010. Application of the ANN in simulation of the climate elements and prediction of drought cycle (case study: Isfahan province). *Geography and environmental planning*. 39(3):107–120.
- 19) Kisi, O. Shiri, J. Karimi, S. Shamshirband, S. Motamedi, S. Petković, D. and Hashim, R. 2015. A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm. *Applied Mathematics and Computation*. 270:731–743.
- 20) Kisi, O. Shiri, J. and Nikoofar, B. 2012. Forecasting daily lake levels using artificial intelligence approaches. *Computers & Geosciences*. 41:169–180.
- 21) Liu, Q. Yin, J. Leung, VCM. Zhai, JH.

365(3-4):329–334.

31) Yua, L. Danninga, Z. and Hongbinga, C. 2015. Prediction of length-of-day using extreme learning machine. *Geodesy and Geodynamics*. 16(2):151–159.

*Abstract***Modeling of Daily Water Level Fluctuations of the Urmia Lake Using Extreme Learning Machine Model**R. Barzegar¹, A. Asghari Moghaddam² and S. Soltani³

Received: 2016/08/20 Accepted: 2016/10/10

In recent decades, the water level of the Urmia Lake has decreased due to over utilization of surface and groundwater resources, prevention of surface water resources discharges to the Urmia Lake and also climate changes, which caused water and environmental crisis in the region. Therefore, modeling Lake level fluctuations is essential for its water resources planning and management. The aim of the study is to forecast the Urmia Lake water level fluctuations for one, three and seven days ahead using extreme learning machine (ELM). Also, the artificial neural network (ANN) and adaptive neuro fuzzy inference system (ANFIS) models used to compare the ability of ELM. For this purpose, the daily water level (Dec 1965-Nov 2012) of the lake was used. To develop the models, the current day and six days water level lags as the inputs used for forecasting the one $[h(t+1)]$, three $[h(t+3)]$ and seven $[h(t+7)]$ days ahead water levels. The data sets were divided into two subsets training/validation (85%) and testing (15%) and after modeling, the performance of the models were evaluated based on coefficient of determination (R^2), root mean square errors (RMSE) and Nash-Sutcliffe coefficient (NSC). The results showed that the ELM model for one-step-ahead water level modeling with $R^2 = 0.9995$, $RMSE = 0.0151$ m and $NSC = 0.9995$ respectively, outperformed in comparison with ANN and ANFIS models. Also, it was observed that ELM models learned faster than the other models during model development trials whereas the ANFIS models had the highest computation time.

Keywords: *Urmia Lake, Water level, Extreme learning machine, Modeling*

1. Ph.D. student of Hydrogeology, Dept. of Earth Sciences, Fac. of Natural Sciences, Univ. of Tabriz, Iran. Email: rm.barzegar@yahoo.com
2. Prof., Dept. of Earth Science, Fac. of Natural Sciences, Univ. of Tabriz, Iran. Corresponding Author. Email: moghaddam@tabrizu.ac.ir
3. MSc. Student of Hydrogeology, Dept. of Earth Sciences, Fac. of Natural Sciences, Univ. of Tabriz, Iran. Email: sh.soltani.d@gmail.com