

Assessment of thermal stratification of Chahnimeh reservoirs exposed to adverse weather conditions

Mahmoud Reza Mollaeinia^{1*}, Jamshid Piri^{2*}

¹Associate Professor, Department of Civil Engineering, Faculty of Technology and Engineering, University of Zabol, Zabol, Iran

²Assistant Professor, Department of Water Science Engineering, Faculty of Water and Soil, University of Zabol, Zabol, Iran

Corresponding Author's E-mail: m_mollaeinia@uoz.ac.ir, J.piri@uoz.ac.ir

Received: 02 June 2025

Accepted: 11 July 2025



Homepage: ijwer.uoz.ac.ir

Revised: 11 July 2025

Published: 26 Mar. 2023

Abstract: This study extracted the monthly thermal stratification of the Chahnimeh Reservoir No. 4 (CRN4) from observational data from May 2013 to April 2014. Then, the monthly thermal stratification was simulated by a one-dimensional numerical model, HEC-5Q, and data-driven models including: Extreme Learning Machine (ELM) and Support Vector Regression (SVR). The results showed that the continuous 120-day wind, along with the high evaporation rate, cause the lake to experience top-down circulation at least twice a year, thereby leading to the recovery of dissolved oxygen and providing an environment for aquatic life to survive in the hypolimnion, which occurs in autumn and winter. Furthermore, the results showed that, in general, the AI methods are more robust compared to the classical model while requiring less data.

Keywords: Lake Stratification; Reservoir No. 4 of Chahnimeh; Extreme Learning Machine; Support Vector Regression; HEC-5Q

Introduction: Layering (vertical stratification) means developing layers of different fluid masses, created by the difference in temperature, soluble and/or suspended compounds (Nandalal 1995, Winton, et al. 2019). Vertical stratification decreases dissolved oxygen concentration (Elçi 2008) and increases the unpleasant taste and smell of water (Cheng, et al. 2018; Lee, et al. 2018).

The layering persistence time is contingent upon the degree of the flow turbulence, distribution of flow rate, the flow profile, energy, and the variations in the cross-section of the stream (Winton, et al. 2019, Townsend 1998). Layering durability may last several years, resulting in anoxic bottom waters (Boehrer, et al. 2009).

Significant progress has been made in large-scale representation and modeling the effects of reservoir water management on streamflow (Cheng, et al. 2018) and temperature (Miara, et al. 2017, Niemeyer, et al. 2018 (Roozbehani & Saedi 2008) (2008) showed the possibility of the thermal layering phenomenon using the HEC-5Q model in the reservoir of the Chai Message dam. (Noshadi & Sadeghnejad 2009, Sokoot 2006) indicated the high performance of HEC-5Q and WASP7 models to estimate the nitrate-nitrogen and orthophosphate in different depths of the Doroodzan Dam.

The research presents the vertical distribution of water temperature (stratification) for Chahnimeh reservoir number four (CRN4) that may influence the lake's water quality. CRN4 experiences adverse meteorological conditions, constructed to supply reliable water for agricultural and, specifically, residential purposes to prevent immigration. Simulations were then conducted using two artificial intelligence methods, ELM and SVR, and analytical HEC-5Q models.

Methodology: To reduce the losses caused by drought and floods, four water reservoirs have been built by the Iranian government at the mouth of the Hirmand River in the Sistan region (Whitney 2006), called Chahnimeh Reservoirs and numbered 1 to 4. They are located in the Sistan Plain (Fig. 1). CRN4 collects excess water from the capacity of the Chahnimeh reservoirs 1 to 3. Table 1 shows the general characteristics of the reservoir.

To simulate water stratification in the RN4C area, temperature was measured at a point with coordinates 30°47'01"N and 61°36'02"E in the RN4C area, twice a month from May 2013 to April 2014 (study period). temperature values were recorded from 1 m below the water surface at 2 m depth intervals. Moreover, Meteorological data were obtained by the synoptic meteorological stations of Zahak.

The vertical hydrograph of temperature provided and compared with results obtained by HEC-5Q, ELM, and SVR models. ELM considers a single hidden layer feed-forward neural network (SLFN) with L hidden nodes, [Fig. 2](#).

One of the important features of the Sistan region is the 120-day wind pattern, which begins approximately in spring and continues until the end of summer ([Fig. 3](#)). From May to August, the 120-day wind speed increases to about ten meters per hour (36 km/h) and even to more than 70 km/h.

ELM obtains the weights of the output layers using the least squares method without iteration (Ding, et al. 2015), Eqns.(1)-(7). SVR is constructed based on statistical learning theory and the structural risk minimization principle. SVR applies a linear regression to map the data into an N-dimensional feature space, Eqns.(8)-(11).

Three statistical variables, including mean absolute error (MAE), Eqn. (12), root mean square error (RMSE), Eqn. (13), and index of agreement (d), Eqn. (14), were used here for the models' evaluation.

Results and Discussion: The sinusoidal changes of vertical profiles, [Fig. 4](#), indicate the temperature predominantly propagates by convection, which is mainly induced by wind. CRN4's water temperature approximately varies around 20-22 °C from top to bottom in May, i.e., the lake is not stratified. May starts about midseason of the spring in Iran when the 120-day winds begin to blow, [Fig. 3](#). The wind moves inverse temperature gradients vertically across the thermal profile (Boehrer, et al. 2008).

Besides, the air temperature takes off to an amount of more than 40 °C. The water absorbs a large portion of solar radiation entering the lake, thus providing an internal heating source (Dittko, et al. 2013), evaporating water. The wind sweeps the vapors along its movement direction and increases the rate of evaporative heat loss (Saber, et al. 2018, leading to a colder epilimnetic layer, which moves vertically down at a low speed. It was continuing during summer until establishing an inverse stratification in CRN4 in August. The inverse stratification in the last month of summer could be the stratifying characteristic of CRN4 because the inverse stratification has been reported in winter or spring (Boehrer, et al. 2008, Bueche & Vetter 2014, Engelhardt & Kirillin 2014).

The lake underwent a regular weak stratification during September. It intuitively reveals that the second homeothermy (uniform temperature from top to bottom) occurred between August and September. Thus the lake's pattern of circulation is best described as discontinuous polymictic (Townsend 1998, Labaj, et al. 2018).

[Table 3](#) represents the statistical parameters applied to provide a quantitative estimate for the ability of models HEC-5Q, ELM, and SVR to reproduce spatial temperatures at various depths of RN4C. Besides, [Fig. 6](#) shows the comparison between the monthly thermal stratification of the lake RN4C produced using predicted and observed temperatures over the deepest point (15 m) in the lake.

ELM simulated the lake stratification somewhat higher than HEC-5Q. However, both estimated the temperature for some months with very low precision, such as August and October. In contrast to them, SVR can estimate with a substantial (d is more than 0.6) or perfect (d is more than 0.8) index of agreement for almost all months. Thus, it is the most capable model.

In general, artificial intelligence methods are superior to the simulation of lake stratification, while they require fewer data than HEC-5Q.

Conclusion: The research illustrated thermal stratification through field-measured values and what was obtained by three simulation models, over the reservoir of RN4C, where the wind approximately blows all year.

Results showed a homoeothermic layer formed in May. Although the air temperature rises during spring and summer, the water temperature of the surface was decreased, and stratification took inversely place during July. It shows continuous-high-speed (120-days) winds along with high evaporation caused extreme heat loss appeared to cool surface water, contributing high to set up the thermal structure. The lake turnover takes place two times from spring to middle autumn.

Furthermore, the values of statistical measures demonstrates SVR reproduces the temperatures and consequently stratification trends more efficiently than HEC-5Q and ELM in the majority of months. In conclusion, SVR

provided robust and reliable results for long-term simulations and represented all annual stratifications.

© 2023 University of Zabol, Zabol, Iran.



This is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>)

ارزیابی لایه‌بندی حرارتی مخازن چاه‌نیمه در معرض شرایط نامساعد آب و هوایی

محمود رضا ملائی‌نیا^{۱*}، جمشید پیری^{۲*}

^۱دانشیار، گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه زابل، زابل، ایران
^۲استادیار، گروه علوم مهندسی آب، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

پست الکترونیکی نگارنده مسئول: m_mollaieniania@uoz.ac.ir، J.piri@uoz.ac.ir

وبگاه نشریه: ijwer.uoz.ac.ir



تاریخ دریافت: ۱۴۰۴/۰۳/۱۲ تاریخ پذیرش: ۱۴۰۴/۰۴/۲۰

تاریخ ویرایش: ۱۴۰۴/۰۴/۲۰ تاریخ چاپ: ۱۴۰۲/۰۱/۰۶

چکیده: در این مطالعه، لایه‌بندی حرارتی ماهانه مخزن چاه‌نیمه شماره ۴ (CRN4) با استفاده از داده‌های مشاهداتی از اردیبهشت ۱۳۹۲ تا فروردین ۱۳۹۳ استخراج شد. سپس، لایه‌بندی حرارتی ماهانه توسط مدل تحلیلی یک‌بعدی HEC-5Q و مدل‌های داده‌محور شامل: ماشین یادگیری شدید (ELM) و رگرسیون بردار پشتیبان (SVR) شبیه‌سازی شد. نتایج نشان داد که باد مداوم ۱۲۰ روزه، همراه با نرخ تبخیر بالا، باعث می‌شود دریاچه حداقل دو بار در سال، گردش از بالا به پایین را تجربه کند و در نتیجه منجر به بازیابی اکسیژن محلول و فراهم شدن محیطی برای حیات آبریان در هیپولیمنیون شود که در پاییز و زمستان رخ می‌دهد؛ علاوه بر این، نتایج نشان داد که به طور کلی، روش‌های هوش مصنوعی در مقایسه با مدل کلاسیک قوی‌تر هستند و در عین حال به داده‌های کمتری نیاز دارند.

کلیدواژه‌ها: لایه‌بندی دریاچه؛ مخزن شماره ۴ چاه‌نیمه؛ Extreme Learning Machine؛ Support Vector
HEC-5Q؛ Regression

۱- مقدمه

تغییرات سطح مقطع جریان بستگی دارد (Winton, et al. 1998, Townsend 2019). در مخازن بزرگ، دوام لایه‌بندی اغلب چندین سال طول می‌کشد و منجر به آب‌های بی‌هوایی کف می‌شود (Boehrer, et al. 2009). در حالی که در دریاچه‌های کوچک، حدود یک هفته طول می‌کشد. اگر زمان ماند آب کوتاه باشد، جریان ورودی به مخزن، کیفیت آب آن را کنترل می‌کند، طوری که آب سردی که ممکن است در طول تابستان از مخازن بالادست جریان یابد،

لایه‌بندی (لایه‌بندی عمودی) به معنای ایجاد لایه‌هایی از توده‌های مختلف سیال است که از طریق اختلاف دما یا ترکیبات محلول و معلق ایجاد می‌شوند (Nandalal 1995, Winton, et al. 2019). لایه‌بندی عمودی، غلظت اکسیژن محلول را کاهش داده (Elçi 2008) و طعم و بوی نامطبوع آب را افزایش می‌دهد (Cheng, et al. 2018; Lee, et al. 2018). زمان ماندگاری لایه‌بندی به میزان آشفتگی جریان، الگوی توزیع سرعت جریان، پروفیل جریان، انرژی و

برای پارامترهای کیفیت آب در همه مخازن وجود ندارد؛ این امر، منجر به تأثیرات منفی بر تحقیقات بیشتر (مگادزا، ۲۰۰۶، هامل و همکاران، ۲۰۱۸) یا منجر به توضیحات مبهم، و اغلب نتیجه‌گیری‌های متفاوت (کالامیتا و همکاران، ۲۰۱۹، ماهره و همکاران، ۲۰۱۴) می‌شود. توسعه‌دهندگان مدل، جوامع علمی و مهندسی را با ذینفعان محلی، برنامه‌ریزان دولتی، و صنایع مرتبط، ایجاد کرده‌اند؛ و زمینه‌های چندرشته‌ای برای ارزیابی کیفیت آب (Mohamed, et al. 2015) و مدیریت پایدار منابع آب (Tomić, et al. 2016, Nourani, et al. 2014) ایجاد شده است.

این تحقیق توزیع عمودی دمای آب (لایه‌بندی) را برای مخزن شماره چهار چاه‌نیمه (CRN4) ارائه می‌دهد که درک فرآیندهای گردش آب و اکوسیستم مؤثر بر کیفیت آب دریاچه را تسهیل می‌کند. CRN4 یکی از چهار مخزن چاه-نیمه است که برای تامین آب مطمئن در کشاورزی و به ویژه آب شرب برای جلوگیری از مهاجرت ساخته شده و در معرض شرایط آب و هوایی بسیار سخت قرار دارد. همچنین، کارایی دو مدل هوش مصنوعی یعنی ELM و SVR، و مدل‌های تحلیلی HEC-5Q را برای تخمین لایه‌بندی باهم مقایسه می‌کند.

۲- روش‌شناسی

۲-۱- منطقه مورد مطالعه

برای کاهش خسارات ناشی از خشک‌سالی و سیل، چهار مخزن آب توسط دولت ایران در دهانه رودخانه هیرمند در منطقه سیستان ساخته شده است (ویتنی، ۲۰۰۶). این مخازن چاه‌نیمه نامیده می‌شوند و با شماره‌های ۱ تا ۴ شماره‌گذاری شده‌اند. این مخازن در دشت سیستان، ۳۰ کیلومتری زابل، در طول جغرافیایی ۶۱ درجه و ۳۳ دقیقه و عرض جغرافیایی ۳۰ درجه و ۴۵ دقیقه قرار دارند (شکل ۱). دشت سیستان دارای آب و هوای نیمه‌خشک و گرم است. رودخانه هیرمند از افغانستان سرچشمه می‌گیرد و به تالاب هامون می‌ریزد.

می‌تواند لایه‌بندی را در مخازن پایین دست تقویت یا حتی ایجاد کند (Zargarpur, et al. 2007). همچنین، اختلاف دما بین لایه‌های بالایی و پایینی ممکن است به بیش از ۱۵ درجه سانتی‌گراد برسد (Churchill 1957). در مقابل، لایه‌بندی روزانه ملایم و ناپایدار است که ممکن است در طول روز توسط باد با سرعت محدود از بین برود. بنابراین، لایه‌بندی روزانه عملاً هیچ تأثیر بحرانی بر کیفیت آب ندارد. در دریاچه‌های گل‌آلود که آب به اندازه آب‌های یوتروفیک شفاف نیست، لایه‌بندی حرارتی ممکن است برای چند روز ادامه یابد.

محققان از رویکردهای شبیه‌سازی برای نشان دادن اثرات لایه‌بندی بر کیفیت آب دریاچه‌ها و مخزن‌ها استفاده کرده‌اند. مزیت مدل‌سازی درک تأثیر کلی مدولاسیون‌های هیدرولوژیکی بر کیفیت آب است. پیشرفت‌های قابل توجهی در نمایش و مدل‌سازی در مقیاس بزرگ اثرات مدیریت آب مخزن بر جریان رودخانه (Cheng, et al. 2018) و دما (Miara, et al. 2017, Niemeyer, et al. 2018) حاصل شده و یافته‌های مدل‌ها به نتایج اندازه‌گیری شده نزدیک است.

(Roosbehani & Saedi 2008) (۲۰۰۸) احتمال وقوع پدیده لایه‌بندی حرارتی را با استفاده از مدل HEC-5Q در مخزن سد پیام‌چای نشان دادند. (Noshadi & Sadeghinejad 2009, Sokoot 2006) نیترا-نیتروژن و ارتوفسفات را در اعماق مختلف سد درودزن به مدت یک سال اندازه‌گیری و نشان دادند که مدل‌های HEC-5Q و WASP7 از عملکرد بالایی برخوردار هستند. مطالعات انجام شده روی مخزن کاخوکا و رودخانه دنیپر در اوکراین (هوبی و همکاران، ۲۰۰۲) و (نستروف و مادیریچ، ۲۰۰۸) که بر مدل‌های کیفی یک، دو و سه‌بعدی آب برای مخزن و رودخانه متمرکز بودند، نشان دادند که زهکشی کم مخزن، دلیل اصلی کاهش اکسیژن محلول در رودخانه پایین دست است.

تحلیل دریاچه‌ها و سدها به پایگاه‌های داده کیفیت آب متکی است که با اندازه‌گیری خواص آب در طول زمان فراهم می‌شوند. با این حال، هیچ پایگاه داده قابل اعتمادی

که تقریباً از اواسط فصل بهار شروع می‌شود و تا پایان تابستان ادامه می‌یابد (شکل ۳). با شروع ماه می تا اوت^۱، سرعت بادهای ۱۲۰ روزه به حدود ده متر بر ثانیه (۳۶ کیلومتر بر ساعت) و حتی به بیش از ۷۰ کیلومتر بر ساعت افزایش می‌یابد.

۲-۲- شبیه‌سازی

برای شبیه‌سازی لایه‌بندی آب در مخزن CRN4، دمای آب در عمیق‌ترین نقطه مخزن (Target Point, P_T) با مختصات $36^{\circ}13'04.7''$ شمالی و $61^{\circ}36'02.1''$ شرقی در مخزن CRN4، از ماه مه ۲۰۱۳ تا آوریل ۲۰۱۴ (دوره مطالعه)، دو بار در ماه، از عمق ۱ متری سطح آب در فواصل عمقی ۲ متری اندازه‌گیری شد درجه حرارت آب در اعماق مورد نظر با ترمومتر دیجیتالی اندازه‌گیری شد.

داده‌های هواشناسی شامل دمای هوا، نقطه شبنم، رطوبت نسبی، سرعت باد، درصد پوشش ابر، تابش موج کوتاه، نسبت ساعات آفتابی موجود به حداکثر ساعات آفتابی ممکن (nN-1)، دمای مرطوب و خشک، فشار بارومتر، فشار بخار، بارش، تبخیر و تعرق و تعرق توسط ایستگاه‌های

مطالعات انجام شده بر روی مخازن چاه‌نیمه بر کیفیت آب (Bazrafshan, et al. 2016, Mir, et al. 2017, Hosseini, et al. 2019)، تبخیر (Piri, et al., 2023; Akbarzadeh, et al. 2019)، تخصیص آب از مخازن ۱ تا ۳ (al. 2015, Piri, et al. 2009 Dahmardeh Ghaleno, et al. 2017, Mosannen) (Mozaffari 2014, Shahraki, et al. 2019) متمرکز بوده است، زیرا مخازن ۱ تا ۳ از سال ۱۹۸۱ در حال بهره‌برداری بوده‌اند (Dahmardeh Ghaleno, et al. 2017).

به هر حال، پژوهش‌های انجام‌شده در زمینه لایه‌بندی حرارتی مخزن چاه‌نیمه‌ها، فقط CRN3 برای چند ماه مطالعه شده است (Ebrahimzadeh, 2016).

CRN4 آب اضافی از ظرفیت مخزن‌های چاه‌نیمه‌های ۱ تا ۳ را، به‌ویژه در هنگام طغیان رودخانه هیرمند، جمع‌آوری می‌کند. این مخزن می‌تواند سطح زیر کشت منطقه را افزایش و شیلات را بهبود بخشد (دهمرده قلعه نو و همکاران، ۲۰۱۷). جدول ۱ مشخصات کلی مخزن را نشان می‌دهد.

ویژگی مهم منطقه سیستان، وزش بادهای ۱۲۰ روزه است

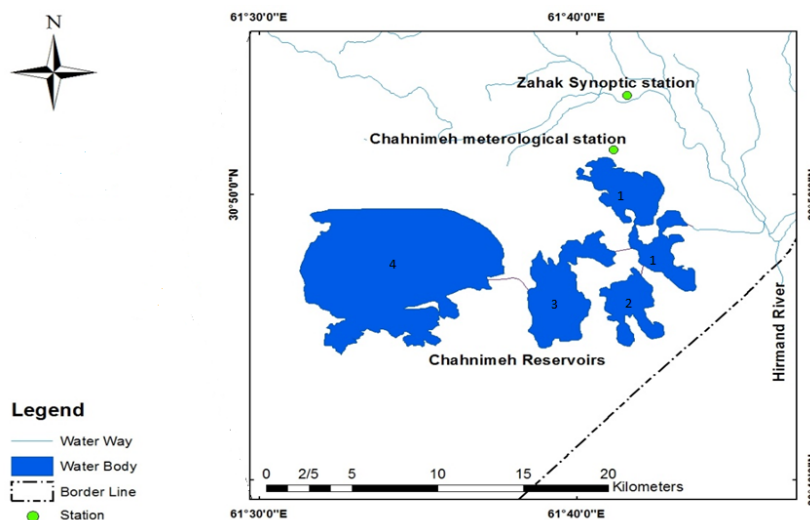


Fig. 1 Location of the Reservoir No. 4 of Chahnimeh in Sistan Plain.

شکل ۱ موقعیت مخزن شماره ۴ چاه‌نیمه در دشت سیستان

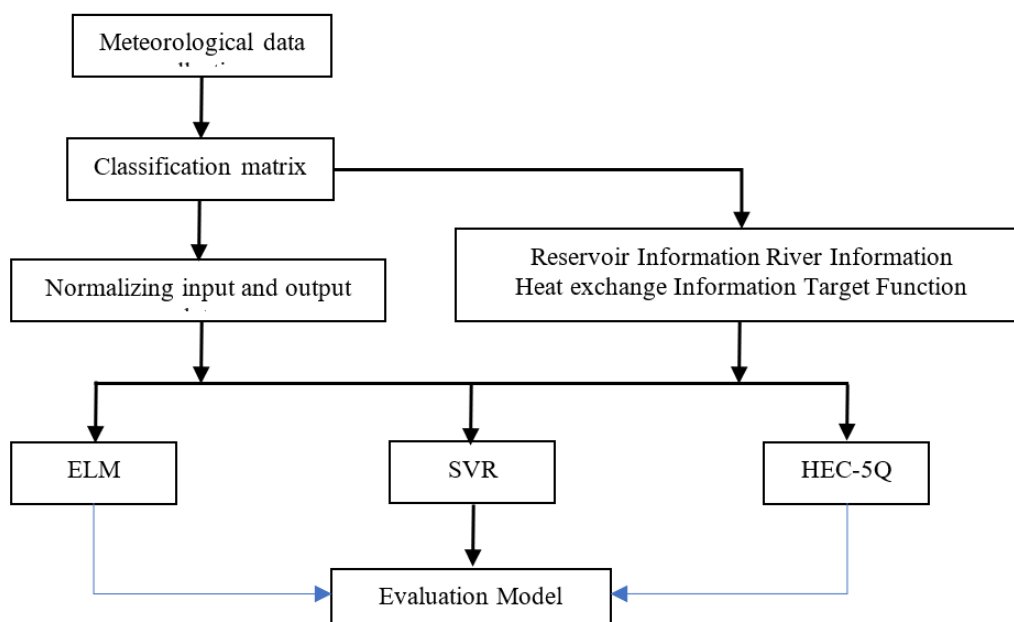


Fig. 2 The flowchart of the research work

شکل ۲ نمودار گردش کار پژوهش

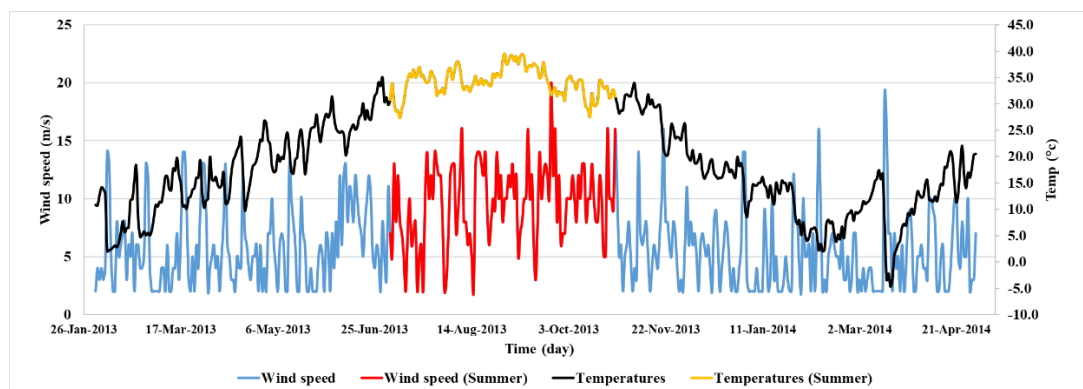


Fig. 3 The variograms of wind speed and temperature

شکل ۳ واریوگرام‌های سرعت باد و دما، میانگین دما (°C) و دامنه آن برای هر ماه، در طول دوره مطالعه

مدل از رابطه (۱) برای شبیه‌سازی رفتار حرارتی مخزن استفاده می‌کند (اکبریور و همکاران، ۱۳۸۵). انتقال دما در جهت عمق (عمودی) رخ می‌دهد.

$$V \frac{\partial T}{\partial t} = \begin{cases} \Delta z Q_z \frac{\partial T}{\partial T} \\ + \Delta z Q_z D_z \frac{\partial^2 T}{\partial z^2} \\ + Q_i T_i \\ - Q_0 T M \\ - T \frac{\partial v}{\partial t} \end{cases} \quad (1)$$

هواشناسی سینوپتیک زهک (۵۲.۹'۵۳°۳۰" شمالی، ۴۰°۶۱'۳۱" شرقی) برای همین دوره زمانی به دست آمد. شکل ۲ نمودار مراحل مدل‌سازی برای هر سه مدل را نشان می‌دهد.

شبیه‌سازی با مدل HEC-5Q

مدل HEC-5Q یک مدل یک‌بعدی است که به‌طور گسترده در شبیه‌سازی مخازن و دریاچه‌ها مورد استفاده قرار می‌گیرد و عملکرد مطلوب خود را در برنامه‌ریزی کمی و کیفی سیستم‌های رودخانه-مخزن نشان داده است. این

تطبیقی تنظیم کند و وزن‌های ورودی و بایاس‌های لایه پنهان را به صورت تصادفی اختصاص دهد. سپس، وزن‌های لایه خروجی را با استفاده از روش حداقل مربعات و بدون تکرار به دست می‌آورد (Ding, et al. 2015).

برای توضیح الگوریتم ELM، N نمونه دلخواه را برای مرحله آموزش در نظر بگیرید؛

$$(x_i, y_i) \in R^n \times R^m \quad (i = 1, 2, 3, \dots, N) \quad (3)$$

یک شبکه پیش‌خور دارای یک لایه پنهان، SLFN، با L گره را می‌توان به صورت ماتریسی بیان کرد،

$$H\beta = Y \quad (4)$$




Fig. 4 The structure of the ELM model. Atiquzzaman and Kandasamy, 2016

شکل ۴ ساختار مدل ELM. Atiquzzaman and Kandasamy, 2016

در این رابطه T ($^{\circ}C$)، V حجم المان (m^3)، t زمان (s)، Z مختصات فضائی (m)، Q_z جریان درونی المان (m^3/s)، A_z مساحت سطح روئی المان عمود بر راستای جریان (m^2)، Dz ضریب پخش موثر (m^2/s)، Q_i جریان ورودی موضعی (m^3/s)، T_i دمای آب ورودی ($^{\circ}C$)، H منبع‌ها و مصرف‌کننده‌های بیرونی حرارت ($Kcal/m^2/s$)، p چگالی آب (Kg/m^3)، c گرمای ویژه آب ($Kcal/Kg^{\circ}C$).

ارتباط بین پارامترهای موثر بر بیلان حرارتی در مدل HEC-5Q را می‌توان با رابطه (۲) بیان کرد:

$$H_n = \begin{cases} H_s - H_{sr} + H_a - H_{ar} \\ \mp H_c - H_{br} - H_e \end{cases} \quad (2)$$

در این رابطه H_n جابجایی خالص دما، H_s تشعشع خورشیدی موج کوتاه که به سطح آب می‌رسد، H_{sr} بازتاب تشعشع موج کوتاه، H_a تشعشع جوی موج بلند، H_{ar} بازتاب تشعشع جوی موج بلند، H_c انتقال گرمای ناشی از رسانش، H_{br} تشعشع برگشتی از سطح آب، H_e اتلاف دمای ناشی از تبخیر.

شبیه‌سازی با مدل ELM

شکل ۴، ماشین یادگیری حدی ELM را نشان می‌دهد که در حوزه‌های مختلف هیدرولوژی (Yaseen, et al. 2019; Yaseen, et al. 2016; Taormina and Chau 2015) به کار می‌رود و می‌تواند تعداد گره‌های لایه پنهان را به صورت

جدول ۱ مشخصات کلی مخزن CRN4 و سد کنترل آن

Table 1 The general specifications of the CRN4 and its control dam

Structural characteristics			Overflow profile			Hydrological view			Practical purposes		
Crown (m)	Crown width (m)	Height from floor (m)	Overflow type	Overflow capacity (CMS)	Total volume (MCM)	Volume (MCM)	Adjustable volume (MCM)	Lake area (Hec)	Gross land (Hec)	Drinking (MCM)	Agriculture (MCM)
16000	8	59	Trapezoidal concrete	50	820	620	620	95	120000	0	460

شبیه‌سازی با مدل SVR

ماشین بردار پشتیبان از زمان اولین پیشنهاد توسط (Vapnik 2013) به دلیل عملکرد بالای آن در دسته‌بندی و رگرسیون شبکه‌های عصبی پرسپترون چندلایه در بسیاری از پژوهش‌ها (Deo & Samui 2017, Ghumman, et al. 2018) به کار گرفته شده است. این روش بر اساس نظریه یادگیری آماری و اصل کمینه‌سازی ریسک ساختاری ساخته شده است. SVM از یک رگرسیون خطی برای نگاشت داده‌ها به یک فضای ویژگی N بعدی استفاده می‌کند. با فرض N نمونه دلخواه،

$$(x_i, y_i) \in R^n \times R^m$$

می‌توان نوشت:

$$f(x) = \sum_{i=1}^N w_i \cdot x_i + b \quad (10)$$

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i + \xi_i^* \quad (11)$$

$$s. t. \begin{cases} y_i - w_i \cdot x_i - b \leq \varepsilon + \xi_i \\ w_i \cdot x_i - y_i + b \leq \varepsilon + \xi_i \\ \xi_i \geq 0, \xi_i^* \geq 0, i = 1, 2, \dots, N \end{cases} \quad (12)$$

$\|w\|$ نشان‌دهنده نرم درجه ۱ اقلیدسی است،

ξ_i یک متغیر کمکی است که نقض حاشیه را اندازه‌گیری می‌کند، و

C ثابتی بزرگ‌تر از صفر است و جریمه‌ها را تعیین می‌کند. با حل مسئله بهینه‌سازی از طریق شرایط کاروش-کوهن-تاگر، القای ضرایب لاگرانژی $(\alpha_1, \alpha_2, \dots, \alpha_M)$ و استفاده از تابع هسته که نشان‌دهنده حاصل ضرب عددی در فضای ویژگی D بعدی است، تابع تخمین به صورت رگرسیون غیرخطی در می‌آید.

$$f(x, \alpha, \alpha^*) = \sum_{i=1}^D (\alpha_i - \alpha_i^*) K(x_i \cdot y) \quad (13)$$

که در آن

$$\begin{cases} H = \begin{bmatrix} f(w_1 \cdot x_1 + b_1) & \dots & f(w_L \cdot x_1 + b_L) \\ \vdots & \dots & \vdots \\ f(w_1 \cdot x_N + b_1) & \dots & f(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \\ \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_L^T \end{bmatrix}_{N \times m} \end{cases} \quad (5)$$

9

$$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T \quad (6)$$

$$\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T \quad (7)$$

که در آن‌ها

H : ماتریس خروجی لایه پنهان شبکه عصبی،

w_i : بردار وزنی متصل‌کننده i th گره پنهان و گره‌های ورودی،

b_i : آستانه i th گره پنهان،

β_i : بردار وزنی که گره پنهان و گره‌های خروجی را به هم متصل می‌کند، و

$w_i \cdot x_j$: حاصل ضرب اسکالر بردارهای w_i و x_j

آموزش SFLN، معادله‌های خطی حل شده را به یک راه‌حل حداقل مربعات تبدیل می‌کند (دینگ و همکاران، ۲۰۱۵) و در نتیجه

$$\hat{\beta} = H^+ Y \quad (8)$$

H^+ معکوس تعمیم‌یافته مور-پنروز از ماتریس خروجی لایه پنهان H را نشان می‌دهد و $\hat{\beta}$ راه‌حل بهینه است.

در این مطالعه، تابع فعال‌سازی مورد استفاده در لایه پنهان،

$$f_{radbas}(a, b, x) = \exp(-(ax + b)^2) \quad (9)$$

و یک تابع انتقال خطی در لایه خروجی. از آنجایی که هنوز هیچ پیشینه نظری محکمی برای تعیین ارتباطات میانی بین نورون‌ها وجود ندارد، می‌توان تعداد گره پنهان لایه هر مدل را از طریق یک فرآیند آزمون و خطا به دست آورد.

سانتی‌گراد از بالا به پایین در ماه مه تغییر می‌کند، یعنی دریاچه لایه‌بندی نشده است. ماه مه تقریباً در اواسط فصل بهار در ایران شروع می‌شود، زمانی که وزش بادهای ۱۲۰ روزه شروع می‌شود.

عمل باد بر روی آب سطحی، آب دریاچه را به گردش در می‌آورد، آب سطحی را با آب‌های پایین‌تر مخلوط می‌کند و گرادیان‌های دمایی معکوس را به صورت عمودی در سراسر پروفیل حرارتی حرکت می‌دهد (Boehrer, et al. 2008). علاوه بر این، دمای هوا به حدود ۴۰ درجه سانتی‌گراد و بیشتر می‌رسد. آب بخش بزرگی از تابش خورشیدی ورودی به دریاچه را جذب می‌کند و بنابراین یک منبع گرمایش داخلی (Dittko, et al. 2013) را فراهم می‌کند و آب را تبخیر می‌کند. باد بخار را در امتداد جهت حرکت خود جابجا می‌کند و باعث ایجاد اختلاف زیادی بین فشار بخار اشباع و فشار بخار هوا می‌شود، بنابراین تبخیر و میزان اتلاف حرارت تبخیری افزایش می‌یابد (Saber, et al. 2018). بیشترین تبخیر سالانه بیش از ۴ متر از سطح آزاد دریاچه در طول تابستان اتفاق می‌افتد و بیشترین اتلاف حرارت سطحی را ایجاد می‌کند (Saber, et al. 2018).

جدول ۲ میانگین دما (°C) و دامنه آن برای هر ماه، در طول دوره مطالعه

Table 2 The mean temperature (°C) and its range for every month, during the study period.

Month	Measured temperature	
	Average	Range
May	21	20-22
June	23	21-28
July	22.13	18-25
August	22.75	18-30
September	20.63	18-25
October	22	19-27
November	21.4	18-26
December	22.5	21-27
January	22.13	20-26
February	23.75	21-27
March	20.5	17-28
April	23.75	21-31
Annual	22.13	17-31

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0, \alpha_i \geq 0, c \leq \alpha_i^* \quad (14)$$

ارزیابی مدل

ترکیبی از معیارهای مختلف کارایی آماری و معیارهای ارزیابی آماری، مانند خطای مطلق یا نسبی، می‌تواند برای تعیین دقیق خطای بین نتایج شبیه‌سازی و اندازه‌گیری‌های میدانی استفاده شود. در اینجا، سه متغیر آماری میانگین خطای مطلق (MAE)، جذر میانگین مربعات خطا (RMSE) و شاخص توافق (d) (ویلموت ۱۹۸۲) استفاده شد. معیارهای آماری انتخاب شده اغلب برای پژوهش‌های مدل‌سازی استفاده شده‌اند (فوکات و همکاران ۲۰۱۶، موریاسی و همکاران ۲۰۰۷، کوئه و همکاران ۲۰۱۸)، چائو و همکاران ۲۰۰۷، برگر و همکاران ۲۰۰۸، پرورد و همکاران ۲۰۰۹). فرض کنید P_i مقدار داده‌های شبیه‌سازی شده، Q_i بزرگی داده‌های واقعی و n تعداد داده‌ها باشد؛ شاخص‌های آماری را می‌توان با رابطه‌های (۱۷)–(۱۵) بیان کرد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (15)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (16)$$

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (17)$$

۳- نتایج و بحث

۳-۱- لایه‌بندی حرارتی دریاچه

جدول ۲ نشان می‌دهد که حداکثر دمای ۳۱ درجه سانتی‌گراد در سطح مخزن در ماه آوریل رخ داده است، در حالی که حداقل دمای ۱۷ درجه سانتی‌گراد در کف دریاچه در ماه مارس مشاهده شده است.

تغییرات سینوسی پروفیل‌های عمودی، **شکل ۵**، نشان می‌دهد که دما عمدتاً توسط همرفت منتشر می‌شود که عمدتاً توسط باد القا می‌شود. با شروع از شرایط همگن، زمانی که دمای آب CRN4 تقریباً در حدود ۲۰ تا ۲۲ درجه

در فصل پاییز نشان می‌دهد. متالیمنیون، که معمولاً ۲ تا ۴ متر ضخامت دارد، بین دو لایه قرار دارد. دمای آب در داخل متالیمنیون تفاوت‌های قابل توجهی را نشان می‌دهد، به طوری که ممکن است بر اثرات کاهش تولید اکسیژن غلبه نکند.

آخرین ماه زمستان، دمای هوا در حال افزایش بود که فرآیند لایه زدایی آغاز شد. با افزایش سرعت باد و کاهش دمای آب (Desai, et al. 2009)، آب سرد اپی‌لیمنیون عمیق‌تر و متراکم‌تر می‌شود و مخلوط شدن لایه‌ها اتفاق می‌افتد، لایه‌بندی دریاچه را درهم می‌شکند و آب کف با آب سطحی مخلوط می‌شود و منجر به جابجایی دریاچه در ماه مه می‌شود.

جدول ۳ پارامترهای آماری اعمال شده برای ارائه یک تخمین کمی از توانایی مدل‌های HEC-5Q، ELM و SVR در بازتولید دماهای مکانی در اعماق مختلف CRN4 را نشان می‌دهد. علاوه بر این، **شکل ۶** مقایسه بین لایه‌بندی حرارتی ماهانه دریاچه CRN4 تولیدشده با استفاده از دماهای پیش‌بینی‌شده و مشاهده شده تا عمیق‌ترین نقطه (۱۵ متر) در دریاچه را نشان می‌دهد.

نتایج آماری نشان می‌دهد که مقادیر RMSE برای همه مدل‌ها به طور مداوم بالاتر از MAE است. میزان فراتر رفتن مقدار RMSE از MAE، شاخصی از میزان داده‌های پرت در داده‌های منعکس‌شده توسط شاخص توافق است (Bueche & Vetter 2014). هنگامی که RMSE بالا باشد، شاخص توافق کوچک است. در جایی که پارامترهای خطا (MAE و RMSE) در محدوده نزدیکی باقی بمانند، مقادیر شاخص توافق بالا است و دقت شبیه‌سازی افزایش خواهد یافت. برای مثال، در ژانویه و فوریه، محدوده نزدیک‌تری از MAE و RMSE وجود دارد که منجر به تولید دمای دقیق‌تر می‌شود، در حالی که در اوت، دقت نتایج به دلیل محدوده وسیع‌تر، پایین بود.

از دست دادن گرمای سطحی منجر به یک لایه اپی‌لیمنیتیک سردتر می‌شود که با سرعت کم به صورت عمودی به سمت پایین حرکت می‌کند. این روند در طول تابستان ادامه داشت تا اینکه در ماه اوت یک لایه‌بندی معکوس در RN4C ایجاد شد. لایه‌بندی معکوس در آخرین ماه تابستان می‌تواند ویژگی لایه‌بندی CRN4 باشد زیرا لایه‌بندی معکوس در زمستان یا بهار گزارش شده است (Boehrer, et al. 2008, Engelhardt & Kirillin 2014). هنگامی که یک لایه متراکم‌تر روی یک لایه سبک‌تر قرار می‌گیرد، ستون بسیار ناپایدار است و چرخش جریان (Turnover) رخ می‌دهد (Niemeyer, et al. 2018). بنابراین، دریاچه در طول ماه سپتامبر یک لایه‌بندی ضعیف منظم را تجربه کرد. این به طور شهودی نشان می‌دهد که هوموترمی دوم (دمای یکنواخت از بالا به پایین) بین ماه‌های اوت و سپتامبر رخ داده است. بنابراین الگوی چرخش جریان دریاچه به بهترین وجه به عنوان پلی‌میکتیک ناپیوسته توصیف می‌شود (Labaj, et al. 2018).

اگرچه لایه‌بندی دریاچه در ماه اکتبر ضعیف شد، لایه‌بندی عمودی منظم در ماه‌های سرد نوامبر تا فوریه، زمانی که سرعت باد کمترین بود، پایدار بود. دریاچه گرما دریافت می‌کند و به سه لایه تا حدودی اپی‌لیمنیون، متالیمنیون و هیپولیمنیون تقسیم می‌شود. نور خورشید سطح دریاچه را سریع‌تر از آنکه دریاچه بتواند مخلوط شود، گرم می‌کند و آب گرم کم‌چگال‌تر به سطح آب می‌آید و یک اپی‌لیمنیون اپیزودیک با ضخامت ۳ تا ۵ متر تشکیل می‌دهد. هیپولیمنیون به آب بین عمق ۹ متر و عمیق‌ترین نقطه دریاچه اشاره دارد. دمای آن بین ۱۸ تا ۲۲ درجه سانتی‌گراد متغیر است. هیپولیمنیون محدود می‌شود و دیگر با اپی‌لیمنیون گرم مخلوط نمی‌شود. با این حال، گردش آب دریاچه، اکسیژن محلول را بازیابی می‌کند (Koue, et al. 2018, Boehrer, et al. 2008, Saber, et al. 2018). حرکت ماهی‌ها را تسهیل می‌کند. این ادعا توسط Sayadi (2016) و Ghaleno & Ghalei تایید شده است که کیفیت عالی آب را

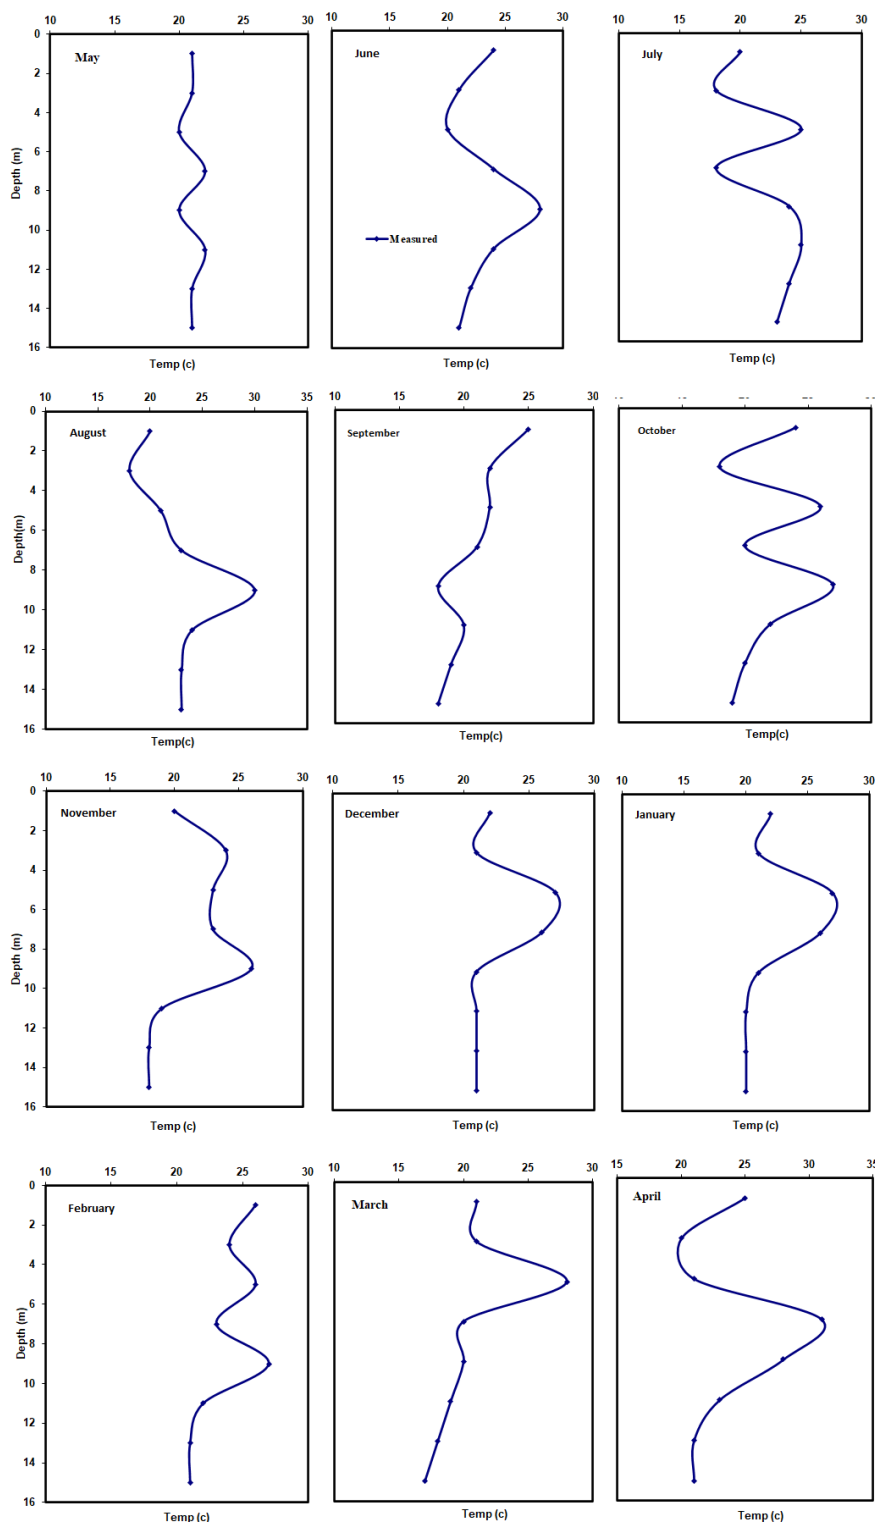


Fig. 5 The vertical profile of the temperature measured at P^T in RN4C in 2014 for each month
 شکل ۵ نیمرخ عمودی دمای آب اندازه‌گیری شده در نقطه P^T در RN4C در سال ۲۰۱۴ برای هر ماه

۳-۲- ارزیابی مدل‌ها

کمتری نسبت به HEC-5Q نیاز دارد، و SVR تخمین‌های قوی‌تری برای همه ماه‌ها ارائه داده است. بنابراین، در این پژوهش، روش‌های هوش مصنوعی نسبت به شبیه‌سازی HEC-5Q لایه‌بندی دریاچه برتر هستند.

شکل ۶ بیان می‌کند که SVR می‌تواند پروفایل‌های عمودی دما را با توافق نزدیک پیش‌بینی کند و روند تغییرات را به خوبی تعریف کند. این **شکل**، شرایط مختلف لایه‌بندی حرارتی در دریاچه را تقریباً در تمام ماه‌ها نشان می‌دهد، از جمله الف) هموترمی در ماه مه، ب) لایه‌بندی معکوس تابستان در طول ماه‌های ژوئیه و اوت، ج) لایه‌بندی پاییز-زمستان از نوامبر تا دسامبر، و د) تعاملات بین لایه‌های اپی‌لیمنیون و ترموکلاین. با این حال، HEC-5Q و ELM در ساخت لایه‌بندی دریاچه از نوامبر تا دسامبر دقیق‌تر هستند. علاوه بر این، دمای پیش‌بینی‌شده در سطح آب و هیپولیمنیون به طور قابل توجهی نزدیک به مشاهدات است؛ در حالی که دمای پیش‌بینی‌شده در ترموکلاین از شاخص توافق بالایی برخوردار نیست زیرا تغییرات دینامیکی قابل توجهی را تجربه می‌کند.

از نظر HEC-5Q، فوریه بیشترین مقدار شاخص توافق ۰.۹۴ را دارد، اما کمترین مقدار RMSE و MAE، به ترتیب ۰.۸۴ و ۰.۸، بالاترین دقت را برای شبیه‌سازی دما در دسامبر تضمین می‌کند. با وجود این، بدترین توافق بین دمای مشاهده شده و شبیه‌سازی شده در اوت است که RMSE، d و MAE به ترتیب ۹.۳۳، ۰.۱۳ و ۲.۵۲ هستند.

علاوه بر این، عملکرد ELM برای شبیه‌سازی تغییرات دما تا حدودی بالاتر از HEC-5Q است. با این حال، هر دو می‌توانند دما را برای برخی از ماه‌ها با دقت بسیار کمی، مانند اوت و اکتبر، تخمین بزنند. در مقابل آن‌ها، SVR می‌تواند تقریباً برای همه ماه‌ها با شاخص توافق قابل توجه (d معنادارتر از ۰.۶) یا کامل (d معنادارتر از ۰.۸) تخمین بزند. این امر منجر به داشتن بیشترین شاخص توافق سالانه در بین این سه مدل شد و در کل، به نظر می‌رسد که این مدل توانمندترین مدل است.

به طور کلی، می‌توان دریافت که ELM دما را با دقت بیشتری تخمین زده است، با وجود اینکه به داده‌های

جدول ۳ مقادیر متغیرهای آماری مدل‌ها

Table 3 The magnitudes of statistical variables of the models

Month	Statistical parameters for the evaluation of								
	HEC-5Q			ELM			SVR		
	MAE	d	RMSE	MAE	d	RMSE	MAE	d	RMSE
May	0.97	0.87	1.35	1.1	0.87	1.4	0.38	0.98	0.19
June	1.41	0.7	3.66	2.1	0.44	6.5	1.07	0.85	1.72
July	1.51	0.73	2.84	1.28	0.8	2.13	1.43	0.78	2.38
Aug.	2.52 [†]	0.13	9.33	2.22	0.31	7.18	1.54	0.63	4.00
Sep.	1.76	0.5	5.72	1.51	0.65	4.1	1.05	0.87	1.55
Oct.	2.27	0.36	6.7	2.39	0.35	6.92	1.52	0.68	3.39
Nov.	1.36	0.83	1.96	1.28	0.82	2.1	1.57	0.73	3.1
Dec.	0.91	0.9	1.2	0.47	0.94	0.73	0.94	0.76	2.76
Jan.	1.42	0.74	3.17	1.39	0.73	3.43	1.11	0.77	2.66
Feb.	0.8 [‡]	0.94	0.84	0.47	0.98	0.33	1.43	0.73	3.36
Mar.	2.58	0.31	8.49	2.12	0.51	6.87	1.51	0.75	3.27
Apr.	1.54	0.64	4.42	1.7	0.61	4.81	1.64	0.51	5.98
Annual	1.59	0.64	4.14	1.50	0.67	3.88	1.27	0.75	2.86

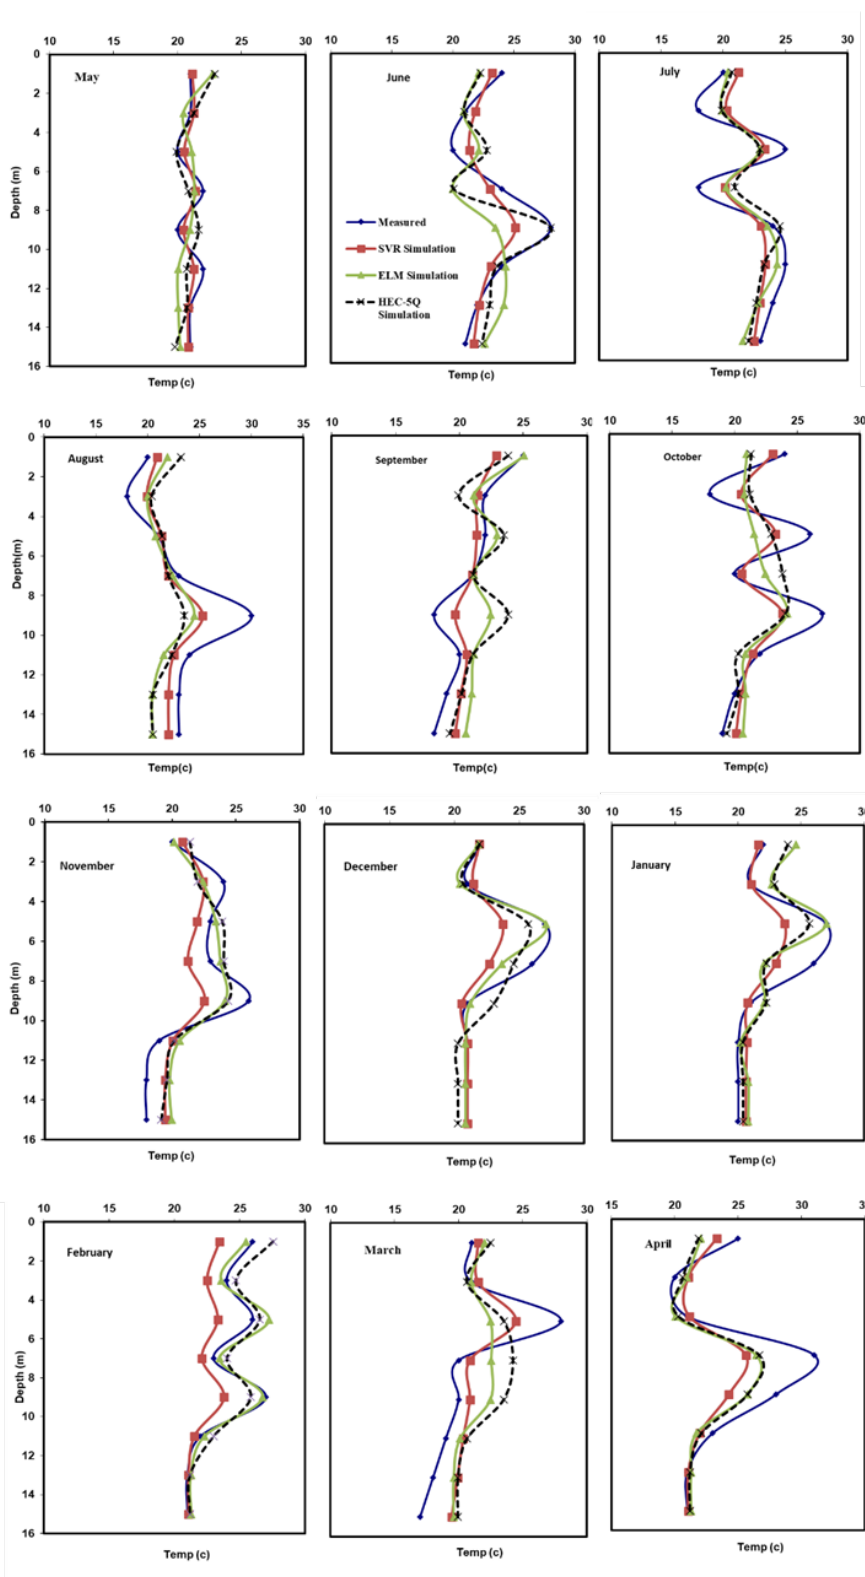


Fig. 6 The depths profile of temperature measured and simulated by HEC-5Q, ELM, and SVR in RN4C, monthly in 2014.
 شکل ۶ پروفیل عمقی دما به صورت ماهانه در سال ۲۰۱۴ توسط HEC-5Q، ELM و SVR در RN4C اندازه‌گیری و شبیه‌سازی شده

۴- نتیجه‌گیری

علاوه بر این، تحلیل شاخص‌های آماری بیان می‌کند که مدل‌های HEC-5Q، SVR و ELM توانایی بالایی برای شبیه‌سازی دمای آب دریاچه CRN4 در اعماق مختلف دارند. همچنین، SVR در اکثر ماه‌ها، دماها و در نتیجه روندهای لایه‌بندی را با کارایی بیشتری نسبت به HEC-5Q و ELM بازتولید می‌کند.

به طور کلی، چرخش عمودی لایه‌های دریاچه دو بار از بهار تا اواسط پاییز رخ می‌دهد و شرایط هواشناسی (بادهای پرسرعت ۱۲۰ روزه و تبخیر زیاد) بر ساختار لایه‌بندی در CRN4 نافذ است.

این تحقیق، لایه‌بندی حرارتی را از طریق مقادیر اندازه‌گیری شده میدانی و آنچه توسط سه مدل شبیه‌سازی به دست آمده است، بر روی مخزن CRN4، جایی که تقریباً در تمام طول سال باد می‌وزد، نشان داد.

نمای حرارتی عمودی نشان می‌دهد که لایه‌بندی حرارتی در ماه‌های سرد نوامبر تا مارس توسعه یافته است. برعکس، در طول بهار و تابستان، اگرچه دمای هوا در طول بهار و تابستان افزایش یافته، دمای آب سطح کاهش یافته و لایه‌بندی در طول ماه ژوئیه به طور معکوس اتفاق افتاده است.

5- List of symbols

T ($^{\circ}C$)	Temperature
V (m^3)	Element volume
t (s)	Time
Z (m)	Spatial coordinates
Q_z (m^3/s)	Element internal flow
A_z (m^2)	Surface area of the element perpendicular to the flow direction
Dz (m^2/s)	Effective diffusion coefficient
Q_i (m^3/s)	Local input current
T_i ($^{\circ}C$)	Inlet water temperature
H ($Kcal/m^2/s$)	External heat sources and consumers
ρ (Kg/m^3)	Density of water
c ($Kcal/Kg/^{\circ}C$)	Specific heat of water
H_n	Net temperature transfer
H_s	Shortwave solar radiation reaching the water surface
H_{sr}	Reflection of shortwave radiation
H_a	Longwave atmospheric radiation
H_{ar}	Reflection of long-wave atmospheric radiation
H_c	Heat transfer due to conduction
H_{br}	Radiation reflected from the water surface
H_e	Heat loss due to evaporation
\mathbf{H}	The output matrix of the neural network hidden layer
\mathbf{w}_i	The weight vector connecting hidden node and the input nodes
β_i	The weight vector connecting the i^{th} hidden node and the output nodes
b_i	The threshold of hidden node
\mathbf{H}^{\dagger}	Moore–Penrose matrix of \mathbf{H}
$\hat{\beta}$	The optimal solution

$\ \mathbf{w}\ $	The Euclidean 1-norm
ξ_i	A slack variable

Acknowledgments

The authors express their sincere gratitude to the Sistan and Baluchestan Regional Water Organization for providing essential data, technical support, and access to the Chah Nimeh reservoirs during this research. We also thank the staff who assisted with field measurements and shared valuable insights into the hydrological conditions of the region.

Credit Authorship Contribution Statement

Conceptualization, M.R.M. and J.P.; Methodology, M.R.M. and J.P.; Software, J.P.; data analysis, M.R.M. and J.P.; Writing-Original Draft Preparation, J.P.; Writing-Review and Editing, M.R.M. Supervision, M.R.M. and J.P.. All authors have read and agreed to the published version of the manuscript.

Funding

This research was supported by the University of Zabol through research grant number 8861 UOZ-GR-8861. The authors also acknowledge partial financial support from the Ministry of Science, Research and Technology of Iran. The funders had no role in the study design, data collection, analysis, interpretation, writing of the paper, or decision to publish the results.

Data Availability Statement

Data supporting this study are available upon reasonable request from the corresponding author. Some restrictions may apply to access certain raw data due to privacy or ethical considerations. The

processed data used for model validation and the model codes developed in this study are available in the institutional repository of the University of Zabol.

Conflicts of Interest

The authors declare no conflict of interest.

References

- Nandalal, K. D. W., 1995: Reservoir management under consideration of stratification and hydraulic phenomena. -- Nandalal, Wageningen.
- Winton, R. S., Calamita, E. and Wehrli, B., 2019: Reviews and syntheses: Dams, water quality and tropical reservoir stratification. *Biogeosciences* 16: 1657-1671. <https://doi.org/10.5194/bg-16-1657-2019>
- Elçi, Ş., 2008: Effects of thermal stratification and mixing on reservoir water quality. *Limnology* 9: 135-142. <https://doi.org/10.1007/s10201-008-0240-x>
- Cheng, Y., Niemeyer, R. J., Mao, Y., Yearsley, J. R., Voisin, N. and Nijssen, B., 2018: A thermally-stratified reservoir module for large scale stream temperature model with implementation in the Tennessee River Basin. <https://ui.adsabs.harvard.edu/abs/2018AGUFM.U12B..11C>
- Lee, G. S., Cho, H. Y. and An, S. M., 2018: Thermal stratification modeling in the inner coastal bays. *Journal of Coastal Research* 85: 1451-1455. <https://doi.org/10.2112/SI85-291.1>
- Boehrer, B., Fukuyama, R., Chikita, K. and Kikukawa, H., 2009: Deep water stratification in deep caldera lakes Ikeda, Towada, Tazawa, Kuttara, Toya and Shikotsu. *Limnology* 10: 17-24. <https://doi.org/10.1007/s10201-008-0257-1>
- Zargarpur, H., Qa'ravi, M. and Dahghan, J., 2007: Thermal Stratification in Tandem Reservoirs Case Study: Karun 1, Karun 2, and Karun 3 Reservoirs. *Iran Water Resources Research* 2: 71-77.
- Churchill, M. A., 1957: Effects of storage impoundments on water quality. *Journal of the Sanitary Engineering Division* 83: 1-48. <https://doi.org/10.1061/JSEDAI.0000053>
- Niemeyer, R. J., Cheng, Y., Mao, Y., Yearsley, J. R. and Nijssen, B., 2018: A Thermally Stratified Reservoir Module for Large-Scale Distributed Stream Temperature Models With Application in the Tennessee River Basin. *Water Resources Research* 54: 8103-8119. <https://doi.org/10.1029/2018WR022615>
- Roozbehani, A. and Saedi, A., 2008: Simulation Water temperature reservoir to determine the levels of dewatering and water quality management. Third International Conference on Water Resources Management. Tabriz University, Iran, Tabriz.
- Noshadi, M. and Sadeghnejad, M., 2009: Measuring and Simulating of Nitrate and Orthophosphate in Doroudzan Dam Reservoir Using HEC-5Q and WASP7 Models. *Iran-Watershed Management Science & Engineering* 3: 43-61. <https://sid.ir/paper/134665/en>
- Sokoot, M., 2006: Evaluation of status of water quality and eutrophication in the reservoir dam and simulation reservoir with model HEC-5Q. *Irrigation and Drainage Master*. Shiraz University, Iran, Shiraz.
- Mahere, T., Mtsambiwa, M., Chifamba, P. and Nihwatiwa, T., 2014: Climate change impact on the limnology of Lake Kariba, Zambia–Zimbabwe. *African Journal of Aquatic Science* 39: 215-221. <https://doi.org/10.2989/16085914.2014.927350>
- Mohamed, I., Othman, F., Ibrahim, A. I., Alaa-Eldin, M. and Yunus, R. M., 2015: Assessment of water quality parameters using multivariate analysis for Klang River basin, Malaysia. *Environmental Monitoring and Assessment* 187: 4182. <https://doi.org/10.1007/s10661-014-4182-y>
- Tomić, A. N. Š., Antanasijević, D. Z., Ristić, M. Đ., Perić-Grujić, A. A. and Pocajt, V. V., 2016: Modeling the BOD of Danube River in Serbia using spatial, temporal, and input variables optimized artificial neural network models. *Environmental monitoring and assessment* 188: 300. <https://doi.org/10.1007/s10661-016-5308-1>
- Nourani, V., Baghanam, A. H., Adamowski, J. and Kisi, O., 2014: Applications of hybrid wavelet–artificial intelligence models in hydrology: a review. *Journal of Hydrology* 514: 358-377. <http://dx.doi.org/10.1016/j.jhydrol.2014.03.057>
- Dahmardeh Ghaleno, M. R., Sadoddin, A., Sheikh, V. and Sabouhi Sabouni, M., 2017: Optimal utilization of the chahnimeh water reservoirs in Sistan region of Iran using goal programming method. *Ecopersia* 5: 1641-1654. <http://dx.doi.org/10.18869/modares.Ecopersia.5.1.1641>
- Hosseini, H., Shakeri, A., Rezaei, M., Dashti Barmaki, M. and Shahraki, M., 2019: Application of water quality index (WQI) and hydro-geochemistry for surface water quality assessment, Chahnimeh reservoirs in the Sistan and Baluchestan Province. *Iranian Journal of Health and Environment* 11: 575-586. <https://ijhe.tums.ac.ir/article-1-6141-en.pdf>
- Mir, A., Piri, J. and Kisi, O., 2017: Spatial monitoring and zoning water quality of Sistan River in the wet and dry years using GIS and geostatistics. *Computers and Electronics in Agriculture* 135: 38-50. <https://doi.org/10.10>

- [16/j.compag.2017.01.022](#)
- Sayadi, M. and Ghaleno, O. R., 2016: Study of water quality using the NSFQI in the year 2014 case study: Chahnimeh reservoir of Sistan. *Int. J. Chem. Stud* 4: 35-37. <https://www.researchgate.net/publication/304675442>
- Bazrafshan, E., Mostafapour, F. K., Esmaelnejad, M., Ebrahimzadeh, G. R. and Mahvi, A. H., 2016: Concentration of heavy metals in surface water and sediments of Chah Nimeh water reservoir in Sistan and Baluchestan province, Iran. *Desalination and Water Treatment* 57: 9332-9342. <https://doi.org/10.1080/19443994.2015.1027958>
- Akbarzadeh, M., Haghghatjou, P. and Bagheri, M., 2015: Estimates of Evaporation from Surface Water Bodies with Sebal Algorithm Using Remote Sensing Techniques (Case Study: Chahnimeh's Fresh Water Reservoirs of Sistan). *Iranian Journal of Irrigation and Drainage* 9: 510-521.
- Piri, J., Mollaeinia, M., & Mostafaie, A. (2023). Assessment of response surface method and hybrid models to predict evaporation (case study: Chahnimeh and Pishein reservoirs in Sistan and Baluchestan Province of Iran). *Arabian Journal of Geosciences*, 16(5), 346. <https://doi.org/10.1007/s12517-023-11330-3>
- Piri, J., Amin, S., Moghaddamnia, A., Keshavarz, A., Han, D. and Remesan, R., 2009: Daily pan evaporation modeling in a hot and dry climate. *Journal of Hydrologic Engineering* 14: 803-811. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000056](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000056)
- Mosannen Mozaffari, M., 2014: Development of the Water Resources Management Model in Sistan Region. Department of Agricultural Economic D.Ph of T Ph.D. University of Zabol, Iran.
- Shahraki, J., Sardar, S. A. and Nouri, S., 2019: Application of met heuristic algorithm of ant Colony optimization in optimal allocation of water resources of Chah-Nime of Sistan under managerial scenarios. *Iranian Journal of Ecohydrology* 5: 1063-1078.
- Huang, G.-B., Zhu, Q.-Y. and Siew, C.-K., 2006: Extreme learning machine: theory and applications. *Neurocomputing* 70: 489-501. <http://doi.org/10.1016/j.neucom.2005.12.126>
- Yaseen, Z. M., Sulaiman, S. O., Deo, R. C. and Chau, K.-W., 2019: An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology* 569: 387-408. <https://doi.org/10.1016/j.jhydrol.2018.11.069>
- Yaseen, Z. M., Jaafar, O., Deo, R. C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A., 2016: Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. *Journal of Hydrology* 542: 603-614. <http://dx.doi.org/10.1016/j.jhydrol.2016.09.035>
- Taormina, R. and Chau, K.-W., 2015: Data-driven input variable selection for rainfall-runoff modeling using binary-coded particle swarm optimization and extreme learning machines. *Journal of hydrology* 529: 1617-1632. <http://dx.doi.org/10.1016/j.jhydrol.2015.08.022>
- Atiquzzaman, M. and Kandasamy, J., 2016: Prediction of hydrological time-series using extreme learning machine. *Journal of Hydroinformatics* 18: 345-353. <https://doi.org/10.2166/hydro.2015.020>
- Ding, S., Zhao, H., Zhang, Y., Xu, X. and Nie, R., 2015: Extreme learning machine: algorithm, theory, and applications. *Artificial Intelligence Review* 44: 103-115. <https://doi.org/10.1007/s10462-013-9405-z>
- Vapnik, V., 2013: *The nature of statistical learning theory*. Springer-VerlagBerlin, Heidelberg, Germany.
- Deo, R. C. and Samui, P., 2017: Forecasting evaporative loss by least-square support-vector regression and evaluation with genetic programming, Gaussian process, and minimax probability machine regression: case study of Brisbane City. *Journal of Hydrologic Engineering* 22: 05017003:1-15.
- Ghumman, A. R., Ahmad, S. and Hashmi, H. N., 2018: Performance assessment of artificial neural networks and support vector regression models for stream flow predictions. *Environmental Monitoring and Assessment* 190: 704. <https://doi.org/10.1007/S10661-018-7012-9>
- Koue, J., Shimadera, H., Matsuo, T. and Kondo, A., 2018: Evaluation of thermal stratification and flow field reproduced by a three-dimensional hydrodynamic model in Lake Biwa, Japan. *Water* 10: 47. <https://doi.org/10.3390/w10010047>
- Boehrer, B., Fukuyama, R. and Chikita, K., 2008: Stratification of very deep, thermally stratified lakes. *Geophysical Research Letters* 35: 5. <https://doi.org/10.1029/2008GL034519>
- Dittko, K. A., Kirkpatrick, M. P. and Armfield, S. W., 2013: Large eddy simulation of complex sidearms subject to solar radiation and surface cooling. *Water Research* 47: 4918-4927. <https://doi.org/10.1016/j.watres.2013.05.045>
- Saber, A., James, D. E. and Hayes, D. F., 2018: Effects of seasonal fluctuations of surface heat flux and wind stress on mixing and vertical

- diffusivity of water column in deep lakes. *Advances in Water Resources* 119: 150-163. <https://doi.org/10.1016/j.advwatres.2018.07.006>
- Najafi, A. and Vatanfada, J., 2011: Environmental challenges in trans-boundary waters, case study: Hamoon Hirmand Wetland (Iran and Afghanistan). *International Journal of Water Resources and Arid Environments* 1: 16-24.
- Hosseini, H., Shakeri, A., Rezaei, M., Barmaki, M. D. and Mehr, M. R., 2020: Water chemistry and water quality pollution indices of heavy metals: a case study of Chahnimeh Water Reservoirs, Southeast of Iran. *International Journal of Energy and Water Resources* 4: 63-79. <https://doi.org/10.1007/s42108-019-00051-7>
- Bueche, T. and Vetter, M., 2014: Simulating water temperatures and stratification of a pre-alpine lake with a hydrodynamic model: calibration and sensitivity analysis of climatic input parameters. *Hydrological Processes* 28: 1450-1464. <https://doi.org/10.1002/hyp.9687>
- Engelhardt, C. and Kirillin, G., 2014: Criteria for the onset and breakup of summer lake stratification based on routine temperature measurements. *Fundamental and Applied Limnology/Archiv für Hydrobiologie* 184: 183-194. <https://doi.org/10.1127/1863-9135/2014/0582>
- Labaj, A. L., Michelutti, N. and Smol, J. P., 2018: Annual stratification patterns in tropical mountain lakes reflect altered thermal regimes in response to climate change. *Fundamental and Applied Limnology/Archiv für Hydrobiologie* 191: 267-275. <https://doi.org/10.1127/fal/2018/1151>
- Desai, A. R., Austin, J. A., Bennington, V. and McKinley, G. A., 2009: Stronger winds over a large lake in response to weakening air-to-lake temperature gradient. *Nature Geoscience* 2: 855-858. <https://doi.org/10.1038/ngeo693>