

Research Article

Performance of Dragonfly Algorithm Hybrid Model - Artificial Neural Network of Earth Dam During Construction for Modeling Settlement

H Hakimi Khansar^{1*}, A Hosseinzadeh Dalir², J Parsa³, J Shiri⁴

Received: June 26, 2022

Accepted: September 5, 2022

Received in Revised: September 3, 2022

Published online: September 23, 2023

1-Ph. D Candidate, Department of Water Engineering, University of Tabriz, Iran

2-Prof., Department of Water Engineering, University of Tabriz, Iran

3-Assist. Prof., Department of Water Engineering, University of Tabriz, Iran

4-Assoc. Prof., Department of Water Engineering, University of Tabriz, Iran

*Corresponding Author, Email: hakimi1904@yahoo.com

Abstract

Background and Objectives

Pour water pressure, stress and settlement are the most important geotechnical parameters that must be constantly monitored during the construction of earth dams. Since measuring dam settlement directly at the time of dam construction requires cost and time, the development of artificial intelligence methods can be very effective. Most studies have been done in the field of modeling earth dams during construction with a numerical model; therefore the need for artificial intelligence modeling in this field seems to be necessary. Artificial intelligence models, including neural networks, are used for study and modeling many engineering sciences. Also, with the development of meta-heuristic algorithms, their combination with neural networks has become very wide-spreading due to more accurate results. So, The purpose of this study is to determine the most effective features in modeling settlement in the body of earthen dams at the time of construction as a case study (Kaboud-val dam) using the hybrid algorithm Dragonfly - artificial neural network in different points of the body of earthen dam at the time of construction. Therefore, in this research, new inputs in artificial intelligence modeling have been proposed for this purpose and their importance in different levels of installation has been investigated.

Methodology

Kaboud-val Dam is located in Golestan province of Gorgan and around the city of Aliabad. This dam is homogeneous and has a filter and inclined drainage. In order to obtain the deformations of the body and the foundation of Kaboud-val dam, settlement plates have been installed in different sections of the body and its foundation during the construction. In this study, instrumental data related to the section of 19 Kaboud-val dam were used. Also, out of 17 pages, 4 pages named M1, M5, M9 and M13 (installed in the body and Kabudwal dam at levels 140, 152, 164 and 180 meter, respectively) have been used for modeling. By analyzing the data of section 19 pages, fill level (F), reservoir level (RL), dam construction time (T), fill rate (FR) and impounding rate (RV) for inlet and landing (P) on terms of (kp), was selected as the output of the hybrid model in the feature selection method. In this study, in order to select the best combination of input features in the artificial neural network, the dragonfly algorithm was used. Feature selection is a method of selecting a subset of related attributes (the best combination of them) that is relevant to a particular goal. The most important principle is to choose stable features and remove extra data. The



combination of dragonfly algorithm with artificial neural network as DA-ANN is shown, Therefore, the dragonfly algorithm (DA) models a variety of different combinations of features with an artificial neural network and selects the best least error combination (RMSE) as the optimal artificial neural network model.

Findings

By performing a hybrid algorithm, sensitivity analysis and feature selection method, combining the four features on pages M1, M5, M9 and M13 with error values (RMSE) of 0.0023(kPa), 0.0024(kPa), 0.0026(kPa), respectively, and combining the three features on the M13 page with the value Error (RMSE) equal to 0.0035(kPa) was the best input combination. The three features of construction time, fill level and reservoir level as common features in all plates are the most effective features in modeling the settlement on selected plates. On plates mounted at higher levels, the modeling error increases, because during the test period and for plate M13 (with the highest mounting level), according to the statistical indices R^2 , SI, NSE and NRMSE are equal to the values of 0.9998, 0.0062, 0.9998 and 0.0062 respectively, have poorer performance than other pages. The effect of reservoir level feature on the plates installed at higher levels due to the high sensitivity coefficient is more than other points and the fill level feature has the least effect on subsidence modeling.

Conclusion

The results are very important considering the cost of installing the measuring equipment and the significance of estimating the actual values in the future. The present study shows that the DA-ANN hybrid model is an important tool in predicting and selecting the best input combination for the intelligent model of the target variable of the settlement at the time of construction of earth dams. However, assessment of this model using the input data studied in different dams is necessary to ensure the application of these models in different conditions.

Keywords: Construction time, Dam cross section, Dragonfly Algorithm, Feature selection, Settlement.

مقاله پژوهشی

ارزیابی مدل هیبریدی الگوریتم سنجاقک - شبکه عصبی مصنوعی برای مدل‌سازی نشست سدهای خاکی هنگام ساخت

حسین حکیمی خانسر^{*}، علی حسین زاده دلیر^۲، جواد پارسا^۳، جلال شیری^۴

تاریخ پذیرش: ۱۴۰۱/۰۶/۱۴

تاریخ دریافت: ۱۴۰۰/۰۴/۰۵

تاریخ انتشار آنلاین: ۱۴۰۲/۰۷/۰۱

تاریخ دریافت ویرایش: ۱۴۰۱/۰۶/۱۲

- ۱- دانشجوی دکترا، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
 - ۲- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
 - ۳- استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
 - ۴- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
- *مسئول مکاتبات، پست الکترونیک: hakimi1904@yahoo.com

چکیده

برای اندازه‌گیری تغییر شکل‌های مقطع ۱۹ سد کبودال، انحراف سنج‌های قائم و صفحات مغناطیسی نشست‌سنجی به تعداد ۱۷ عدد (M1 تا M17) در بدنه و پی آن، در دوران ساخت نصب گردیده است. در این مطالعه قابلیت الگوریتم هیبریدی DA-ANN در زمینه مدل‌سازی نشست در زمان ساخت و تعیین ویژگی‌های مؤثر بر آن مورد مطالعه قرار گرفته است. برای ورودی مدل هیبریدی، پنج ویژگی شامل تراز خاک ریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاک ریزی انتخاب گردیده است. با اجرای الگوریتم هیبریدی، آنالیز حساسیت و روش انتخاب ویژگی ترکیب سه، سه و دو ویژگی در صفحات M1، M5 و M9 به ترتیب با مقادیر خطا (RMSE) برابر ۰/۰۰۲۳، ۰/۰۰۲۴، ۰/۰۰۲۶ و ترکیب چهار ویژگی در صفحه M13 با مقدار خطا (RMSE) برابر ۰/۰۰۳۵ بهترین ترکیب ورودی بوده است. سه ویژگی زمان ساخت، تراز خاکریزی و تراز آبگیری به عنوان ویژگی‌های مشترک در همه صفحات، مؤثرترین ویژگی‌ها در مدل‌سازی نشست در صفحات منتخب بوده است. در صفحات نصب‌شده در ترازهای بالاتر، خطای مدل‌سازی افزایش یافته است زیرا در صفحه M1 (دارای پایین‌ترین تراز نصب)، مدل ANN با توجه به شاخص‌های آماری SI ، R^2 و NSE به ترتیب برابر مقادیر ۰/۹۹۹۷، ۰/۰۰۷۹ و ۰/۹۹۹۷ و در دوره آزمون دارای بهترین عملکرد نسبت به سایر صفحات داشته است. تأثیر ویژگی‌های تراز آب مخزن بر صفحات نصب‌شده در ترازهای بالاتر با توجه به ضریب حساسیت بالا، بیشتر از سایر نقاط بوده است و تراز خاکریزی کمترین تأثیر را بر مدل‌سازی نشست داشته است.

واژه‌های کلیدی: الگوریتم سنجاقک، انتخاب ویژگی، زمان ساخت سد، مقطع عرضی سد، نشست.

مقدمه

سدها و مخازن ذخیره آب نقش مهمی در مسائل مربوط به اقتصاد و تأمین نیاز آب در کشور دارند (حکیمی خانسر ۲۰۲۱). سدهای خاکی در بین انواع سدهای مختلف به دلایل صرفه‌های اقتصادی، آسانی در اجرا، مصالح در دسترس و عملکرد سازه‌های دارای اهمیت بالایی هستند (پارسا و همکاران ۲۰۲۱، نوواکوویچ و همکاران ۲۰۱۴). فشار آب منفذی، تنش‌های ایجادشده و نشست، مهم‌ترین پارامترهای خاک هستند که در دوران ساخت سدهای خاکی باید دائماً بررسی شوند (سلماسی و همکاران ۲۰۱۹). با توجه به اینکه اندازه‌گیری نشست سد در زمان ساخت به طور مستقیم نیاز به هزینه و زمان دارد، توسعه روش‌های داده محور می‌تواند بسیار موثر واقع شود. مدل‌های هوش مصنوعی از جمله شبکه‌های عصبی به منظور بررسی و مدل‌سازی در علوم مهندسی کاربرد دارد (نورانی و همکاران ۲۰۱۲). با پیشرفت مدل‌سازی ترکیب الگوریتم‌های فرا ابتکاری^۱، با شبکه‌های عصبی به دلیل نتایج دقیق‌تر بسیار متداول شده است (پارسا و همکاران ۲۰۲۱). فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه‌بندی^۲ ویژگی‌ها کاربرد دارد (وو و همکاران ۲۰۱۴). تخمین بهترین ترکیب ورودی در مدل‌های هوش مصنوعی همیشه نظارت شده^۳ است، درحالی‌که طبقه‌بندی ویژگی‌ها را می‌توان نظارت شده و یا در برخی موارد غیر نظارت شده^۴ انجام داد (کوکوی و همکاران ۲۰۱۵). در صورت استفاده از تکنیک‌های انتخاب ویژگی می‌توان دقت پیش‌بینی را بهبود بخشید و زمان اجرای محاسبات را کاهش داد (چاندراشکار و شاهین ۲۰۱۴).

مطالعه‌هایی در زمینه مدل‌سازی نشست سدهای خاکی در زمان ساخت با مدل عددی (حکیمی خانسر و همکاران ۲۰۱۴)، (سلماسی و همکاران ۲۰۱۹) و (حکیمی خانسر

۲۰۱۲) در سد کبودوال صورت پذیرفته است. دانش مدل‌سازی نشست مشاهده‌شده در زمان ساخت سدهای خاکی، از اهمیت زیادی برخوردار است زیرا مدیریت، عملکرد سد خاکی و پایداری آن وابسته به آن است. با توجه به اینکه اندازه‌گیری نشست سد در زمان ساخت به طور مستقیم نیاز به هزینه و زمان دارد، توسعه روش‌های داده محور می‌تواند بسیار موثر و مکمل مدل‌سازی عددی است.

با توجه به منابع مطالعاتی تحقیقی در مورد مدل‌سازی نشست در زمان ساخت سدهای خاکی با مدل‌های هوشمند صورت نگرفته است و هدف از این پژوهش، تعیین مؤثرترین ویژگی‌ها در مدل‌سازی این پدیده به صورت مطالعه موردی (سد کبودوال) با استفاده از الگوریتم هیبرید سنجاکک - شبکه عصبی مصنوعی در نقاط مختلف بدنه سد خاکی در زمان ساخت بوده است، بنابراین در این تحقیق ورودی‌های جدید در مدل‌سازی هوش مصنوعی برای این منظور پیشنهاد گردیده و اهمیت آن‌ها در ترازهای مختلف نصب بررسی شده است.

مواد و روش‌ها

سد مورد مطالعه

سد کبودوال (قره‌سو زرینگل) در استان گلستان گرگان و در اطراف شهر علی‌آباد، قرار گرفته است. این سد در حد فاصل طول جغرافیایی ۵۴ درجه و ۴۰ دقیقه تا ۵۴ درجه و ۵۶ دقیقه شرقی و عرض‌های جغرافیایی ۳۶ درجه و ۵۴ دقیقه تا ۳۷ درجه و ۶۰ دقیقه شمالی قرار گرفته است. (حکیمی خانسر و همکاران ۲۰۱۴). برای دستیابی به تغییر شکل‌های بدنه و پی، انحراف سنج‌های قائم به همراه صفحات مغناطیسی نشست سنجی در مقاطع مختلف بدنه و پی سد کبودوال استفاده شده است، بنابراین در مقطع ۱۹ استفاده‌شده در این تحقیق مانند سایر مقاطع سد کبودوال، صفحات نشست سنجی با توجه به شکل (۱) از تراز ۱۴۰ تا تراز ۱۹۲ به تعداد ۱۷ عدد نصب شده است (سلماسی و همکاران ۲۰۱۹). برای

1 Meta Heuristic

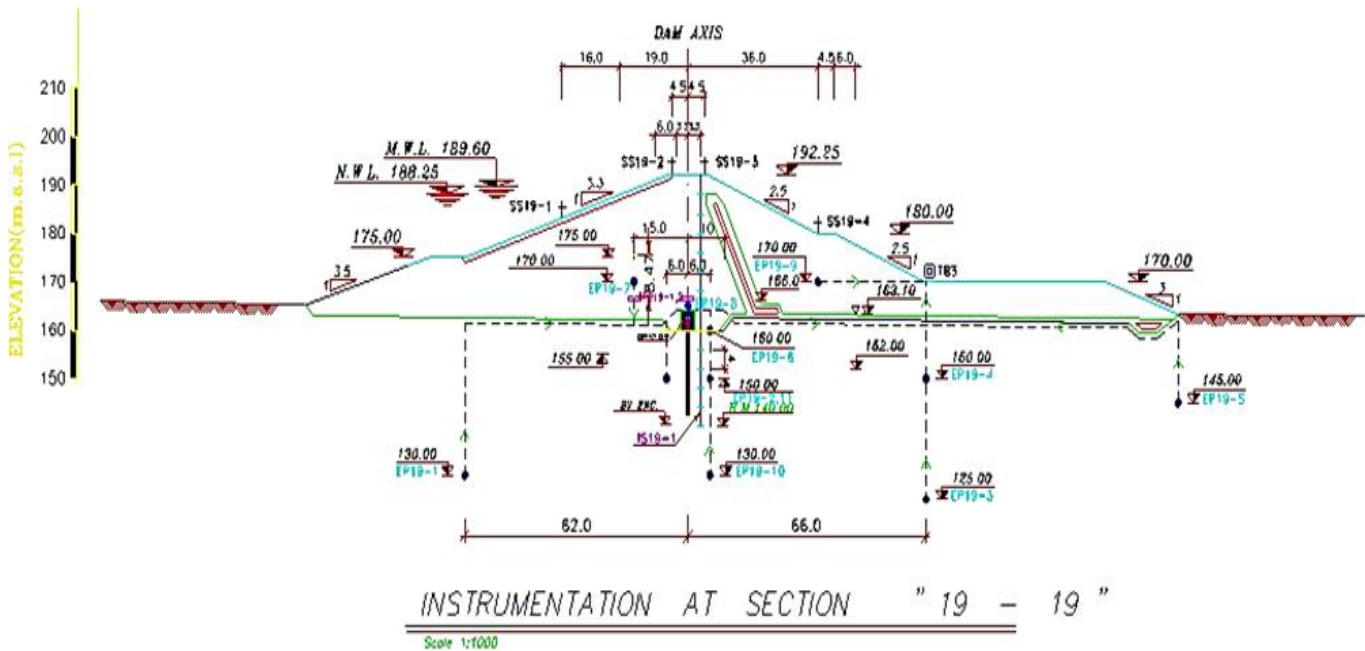
2 Prediction and classification

3 supervised Learning

4 Unsupervised Learning

نام‌های M1, M5, M9 و M13 نصب شده در بدنه و پی سد کبودوال به ترتیب در ترازهای ۱۴۰، ۱۵۲، ۱۶۴ و ۱۸۰ برای مدل‌سازی استفاده شده است. در ادامه کارایی مدل هوشمند در تخمین نشست در ترازهای مختلف بهتر مورد ارزیابی قرار گرفته است.

انجام پژوهش حاضر از داده‌های ابزار دقیق سد کبودوال (از تاریخ ۱۳۸۸/۳/۱۵ تا ۱۳۹۱/۱۱/۱۵)، اخذ شده از شرکت آب منطقه‌ای استان گلستان، استفاده شده است (حکیمی خانسر و همکاران ۲۰۱۴). در این تحقیق از بین ۱۷ صفحه مذکور، تعداد ۴ صفحه نشست سنج به



شکل ۱- موقعیت جغرافیایی، مقطع تیپ و جا نمایی ابزار دقیق در مقطع عرضی شماره ۱۹.

شبکه‌های عصبی مصنوعی (ANN)

(۲۰۱۲). وزن‌های شبکه عصبی در لایه‌های میانی و خروجی متفاوت هستند و مقادیر آن‌ها می‌تواند در طول فرآیند آموزش شبکه تغییر نماید (باقرزاده و همکاران ۲۰۲۰، دانش فراز و همکاران ۲۰۲۰). در این پژوهش، تابع انتقال شامل توابع سیگموئید و خطی، به ترتیب برای

برای مدل‌سازی پدیده‌ها در علوم مختلف مهندسی با شبکه‌های عصبی مصنوعی، شبکه‌های چند لایه پیشرو با الگوریتم یادگیری پس انتشار بسیار متداول است (نورانی و باباخانی ۲۰۱۳). ثابت شده است که مدل شبکه پس انتشار با سه لایه برای پیش‌بینی و شبیه‌سازی در هر گونه مسائل مهندسی کافی است (نورانی و همکاران

شکل ۳- هوش جمعی پویا (الف) و هوش جمعی ایستا (ب) سنجاک‌ها (ج) (میر جلیلی ۲۰۱۶).

پنج عامل اصلی در به‌روزرسانی موقعیت نمونه در رفتار ازدحامی با توجه به این دو رفتار وجود خواهد داشت (شکل ۴) (میر جلیلی ۲۰۱۶). مرحله اول تفکیک نام دارد. مدل‌سازی ریاضی این مرحله با استفاده از رابطه زیر صورت می‌گیرد.

$$S_i = - \sum_{j=1}^N (X - X_j) \quad [1]$$

در رابطه بالا X موقعیت فعلی سنجاک، X_j نشان‌دهنده j امین همسایه سنجاک و N تعداد سنجاک‌های همسایه است. مرحله دوم مرحله هم تراز است. مدل‌سازی ریاضی این مرحله با رابطه زیر انجام می‌گیرد.

$$A_i = \frac{\sum_{j=1}^N V_j}{N} \quad [2]$$

که در آن V_j سرعت j امین همسایه سنجاک را نشان می‌دهد. مرحله سوم انسجام نام دارد. مدل‌سازی ریاضی این مرحله به کمک رابطه زیر قابل انجام است.

$$C_i = \frac{\sum_{j=1}^N X_j}{N} - X \quad [3]$$

که در آن X موقعیت فعلی سنجاک، X_j موقعیت j امین همسایه سنجاک و N برابر تعداد سنجاک‌های همسایه است. مرحله چهارم جذب به سمت شکار است. مدل‌سازی ریاضی مرحله جذب به سمت شکار با رابطه زیر نشان داده می‌شود.


$$F_i = X^+ - X \quad [4]$$

که در آن X موقعیت فعلی سنجاک و X^+ موقعیت غذا است. مرحله آخر دوری از دشمن است. مدل‌سازی ریاضی مرحله دوری از دشمن با استفاده از رابطه زیر بیان می‌شود.

$$E_i = X^- + X \quad [5]$$

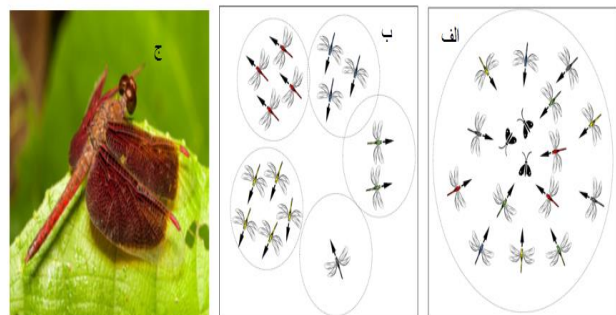
لایه پنهان و خروجی بوده است (شیری ۲۰۱۹، نورانی و همکاران ۲۰۱۲).

همچنین تابع آموزش تابع لونیبرگ-مارکواریت^۵ انتخاب شده است (شکل ۲). همچنین تعداد ورودی‌ها ۱ تا ۵ در نظر گرفته شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی در پژوهش. الگوریتم بهینه‌سازی سنجاک^۶ (DA)

برای نخستین بار الگوریتم بهینه‌سازی سنجاک توسط (میر جلیلی ۲۰۱۶) توسعه داده شد. منشأ اصلی این الگوریتم از رفتارهای هوش جمعی ایستا^۷ و هوش جمعی پویا^۸ است که این دو رفتار هوش جمعی با مراحل اصلی از بهینه‌سازی با الگوریتم‌های فرا ابتکاری یعنی اکتشاف و استخراج شباهت دارد (شکل ۳). سنجاک‌ها گروه‌های کوچکی را تشکیل می‌دهند و در مناطق مختلف به صورت یک گروه ایستا پرواز می‌کنند و این کار مهم‌ترین هدف در مرحله اکتشاف است. در مرحله استخراج و در گروه پویا، رفتار مطلوب سنجاک‌ها این است که در گروه‌های بزرگ‌تر و در امتداد یک جهت حرکت کنند (میر جلیلی ۲۰۱۶).



⁵ Levenberg-Marquardt

⁶ Dragonfly Algorithm

⁷ Static dragonfly swarms

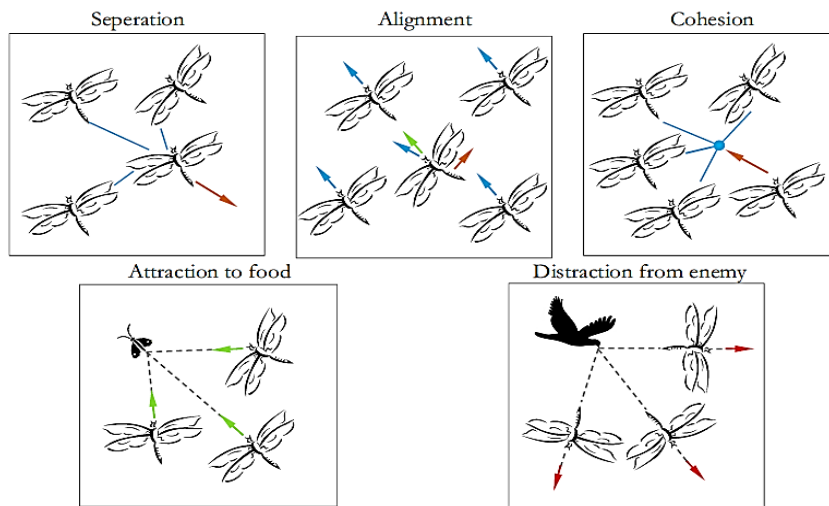
⁸ Dynamic dragonfly swarms

ترازی، A_i نشان‌دهنده حرکت اصولی i امین سنجاک، c نشان‌دهنده ضریب انسجام، C_i نشان‌دهنده انسجام i امین سنجاک، f ضریب جذب منبع غذا، F_i نشان‌دهنده منبع غذای i امین سنجاک، e نشان‌دهنده ضریب دوری از دشمن، E_i نشان‌دهنده موقعیت دشمن از i امین سنجاک و w نشان‌دهنده ضریب اینرسی است. همچنین X_{t+1} و X_t مکان سنجاک‌ها در تکرارهای t و $t+1$ را بیان می‌کنند. (میر جلیلی ۲۰۱۶).

که در آن X نشان‌دهنده موقعیت فعلی سنجاک و X^- موقعیت دشمن است. ترکیبی از این پنج گروه، رفتار سنجاک‌ها را نشان می‌دهد. بردار گام با هدف به‌روزرسانی موقعیت سنجاک‌ها در فضای جستجو و شبیه‌سازی حرکت‌های آن‌ها، با استفاده از رابطه زیر قابل به‌روزرسانی است:

$$X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i + wX_t) \quad [6]$$

که در آن، S نشان‌دهنده ضریب تفکیک و S_i نشان‌دهنده مجزا بودن i امین سنجاک، a نشان‌دهنده ضریب هم



شکل ۴- پنج عامل اصلی در به‌روزرسانی موقعیت نمونه در رفتار ازدحامی سنجاک‌ها (میر جلیلی ۲۰۱۶).

ترکیب آن‌ها) با یک هدف به کار می‌رود. مهم‌ترین اصل در آن، انتخاب ویژگی‌های پایدار و حذف داده‌های اضافی است (کومار و مینز ۲۰۱۴). در این مطالعه ترکیب الگوریتم سنجاک با شبکه عصبی به صورت DA-ANN نشان داده شده است. بنابراین، الگوریتم فرا ابتکاری سنجاک انواع ترکیب‌های متفاوت ویژگی‌ها را با شبکه عصبی مدل‌سازی نموده و بهترین ترکیب با کمترین خطا (RMSE) را به عنوان مدل بهینه شبکه عصبی انتخاب می‌کند. همچنین داده‌های صفحات به طور تصادفی به دو دسته آموزشی و آزمون به ترتیب ۷۰ و

ترکیب شبکه عصبی با الگوریتم سنجاک

برای ترکیب الگوریتم‌های فرا ابتکاری با شبکه عصبی مصنوعی سه روش متفاوت کاربرد دارد. روش اول بهینه‌سازی ساختار شبکه عصبی مصنوعی است و دومین روش بهینه‌سازی وزن‌های آن است (امیری میجان و همکاران ۲۰۱۹). در روش سوم استفاده‌شده در این پژوهش به منظور انتخاب بهترین ترکیب از ویژگی‌های ورودی در شبکه عصبی از الگوریتم‌ها سنجاک استفاده شد. انتخاب ویژگی، روشی است برای انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط (بهترین

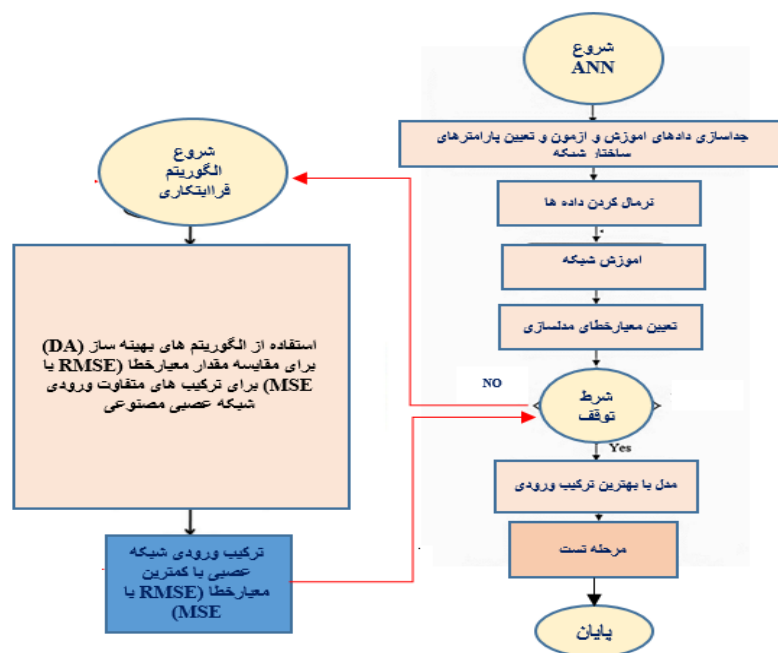
آموزشی حاصل می‌شود. شکل ۵، نحوه ترکیب مدل شبکه عصبی و الگوریتم سنجاقک برای استخراج بهترین ترکیب ویژگی‌ها را نشان می‌دهد (پارسا و همکاران ۲۰۲۱). با واکاوی و کاوش در مورد داده‌های صفحات نشست سنجی در مقطع ۱۹، تراز خاک ریزی (F) بر حسب (m.a.s.l)، تراز آب مخزن (RL) بر حسب (m.a.s.l)، زمان ساخت سد (T) بر حسب (day)، سرعت خاک ریزی (FR) بر حسب (m.a.s.l day⁻¹) و سرعت آبیاری (RV) بر حسب (m.a.s.l day⁻¹) به عنوان ورودی و نشست (P) بر حسب (kp) ایجادشده بر بدنه سد خاکی در زمان ساخت، به عنوان خروجی مدل هیبریدی در روش انتخاب ویژگی، انتخاب شد.

۳۰ درصد دسته‌بندی شده و از میانگین وزنی خطاهای آموزشی و آزمون برای محاسبه خطای مدل هیبریدی، طبق رابطه زیر استفاده شده است:

$$Error_f = 0.8error_{tr} + 0.2error_{te} \quad [V]$$

در رابطه بالا، $Error_f$ ، خطای نهایی مدل، $error_{tr}$ خطای داده‌های آموزشی و $error_{te}$ خطای داده‌های آزمون مدل هستند. در این مطالعه، شاخص خطا RMSE است.

خطای مربوط به داده‌های آموزشی در فرآیند انتخاب ویژگی اهمیت بالاتری از داده‌های آزمون دارد، چون هدف این فرایند تشخیص ویژگی‌های موثر بر متغیر هدف است و نه تخمین آن، بنابراین رابطه بین ویژگی‌های ورودی و خروجی مدل به کمک داده‌های



شکل ۵- نحوه ترکیب مدل شبکه عصبی و الگوریتم سنجاقک برای استخراج بهترین ترکیب ویژگی‌ها.

مدل نسبت به متغیرهای ورودی به دست می‌آید. مقادیر حساسیت بالاتر برای یک متغیر ورودی، تأثیر بیشتر آن را بر متغیر هدف نشان می‌دهد (هیل ۲۰۰۰).

آنالیز حساسیت

آنالیز حساسیت به‌کاررفته در این مطالعه، روش هیل (هیل ۲۰۰۰) است. در روش هیل، با تغییر هر یک از متغیرها ورودی، به یک مقدار معین، تأثیر آن‌ها بر خروجی مدل به دست آمده و در نتیجه مقدار حساسیت

ارزیابی مناسب بودن مدل و نرمال سازی داده‌ها

در مطالعه حاضر، از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، نش ساتکلیف (NSE) و نیز میانگین هندسی نسبت خطا (GMER) برای ارزیابی و عملکرد مدل‌ها استفاده شده است. شاخص‌های مذکور با روابط زیر قابل محاسبه است:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad [۸]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad [۹]$$

$$NRRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}}}{\bar{O}_i} \quad [۱۰]$$

$$SI = \frac{NRRMSE}{\bar{O}_i} \quad [۱۱]$$

$$NSE = \left| 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \right| \quad [۱۲]$$

$$GMER = \exp \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad [۱۳]$$

در روابط بالا O_i مقدار مشاهداتی، P_i مقدار محاسبه شده از مدل هوشمند، \bar{O}_i مقادیر میانگین مشاهداتی، \bar{P}_i میانگین مقادیر محاسبه شده و N نمایانگر تعداد داده‌ها است. هر چه شاخص نش ساتکلیف، ضریب تبیین (R^2) نزدیک تر به یک و هر اندازه که جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) به صفر نزدیک تر باشند، نشان می‌دهد که خروجی‌ها دقیق تر بوده و مقادیر واقعی و پیش‌بینی شده به هم نزدیک‌ترند (نوری و سلماسی ۲۰۱۹). از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص نمودن بیش برآورد و یا کم برآورد مدل، استفاده شد. اگر مقدار GMER کمتر یا بیشتر از یک باشد به ترتیب بیان‌کننده کم برآورد یا بیش برآورد مدل‌ها است (امیری میجان و همکاران ۲۰۱۹).

با استفاده از رابطه ۱۴ داده‌ها بین ۰/۱ تا ۰/۹ نرمال شده است تا برای معرفی به شبکه‌های عصبی در مراحل آموزش و آزمون آماده شوند.

$$x_n = \left(0.8 * \left(\frac{(x - x_{min})}{(x_{max} - x_{min})} \right) \right) + 0.1 \quad [۱۴]$$

در رابطه بالا مقادیر x ، x_n ، x_{min} ، x_{max} به ترتیب داده‌های نرمال شده، داده‌های اصلی، کمینه داده‌ها، بیشینه داده‌ها است.

نتایج و بحث

انتخاب ویژگی با استفاده از الگوریتم هیبریدی-DA-ANN

در این قسمت در مورد بهترین تعداد ترکیب‌های متفاوت ورودی بحث شده است. همان طور که بیان شد از ترکیب ۱ تا ۵ ویژگی برای مدل‌سازی نشست و انتخاب بهترین ترکیب ویژگی‌ها با الگوریتم هیبریدی DA-ANN برای صفحه‌های مذکور استفاده گردیده است. تمام صفحات در محور و قسمت میانی سد نصب گردیده است. دو صفحه M1 و M5 در پی سد و در ترازهای ۱۴۰ و ۱۵۲ قرار دارند ولی دو صفحه M9 و M13 در بدنه سد و در ترازهای ۱۶۴ و ۱۸۰ نصب شده‌اند (شکل ۱). نتایج به دست آمده از الگوریتم هیبریدی DA-ANN در شکل ۶ در مورد صفحات M1 و M5 نشان داد که از بین ۵ ویژگی ورودی، انتخاب ترکیب سه ویژگی بیش‌ترین تأثیر را در مدل‌سازی نشست خاک داراست زیرا با توجه به این شکل، ترکیب سه‌تایی ویژگی‌ها در صفحه M1، کمترین خطا (مقدار NRMSE برابر ۰/۰۰۴۷) را در مدل‌سازی نشست دارد. برای صفحه M5 مقدار RMSE برابر ۰/۰۰۵۸ است که از سایر زیرمجموعه (ترکیب) ویژگی‌ها، کمتر است.

در صفحه M9 انتخاب ترکیب سه ویژگی بیش‌ترین تأثیر را در مدل‌سازی نشست خاک دارد زیرا زیرمجموعه یا ترکیب ۳ تایی، کمترین خطا (مقدار RMSE برابر ۰/۰۰۴۰) را در مدل‌سازی نشست دارد. همچنین روند نمودار ویژگی-خطا در این سه صفحه تقریباً مشابه هم





می‌رسد، صفحات نصب‌شده در ترازهای بالاتر دارای داده‌های کمتری هستند و تأخیر زمانی که در داده‌های ورودی وجود دارد باعث این تغییرات می‌شود.

آنالیز حساسیت


برای مشخص کردن درجه اهمیت هر کدام از ویژگی‌های ورودی، آنالیز حساسیت ویژگی‌های ورودی صورت پذیرفته است.

بر اساس نتایج حاصل از آنالیز حساسیت (شکل ۸)، در صفحه M1 که در قسمت میانی و محور سد، در تراز ۱۴۰ متر قرار دارد از بین ۵ ویژگی ورودی، سه ویژگی به ترتیب شامل زمان ساخت، تراز خاک ریزی و تراز آبیگری با توجه به ضریب حساسیت بالاتر، بیش‌ترین تأثیر را در مدل‌سازی نشست خاک دارا است.

است. نتایج در صفحه M13 نشان داد که روند نمودار ویژگی-خطا در این صفحه کمی متفاوت از سه صفحه دیگر است. علت این امر احتمالاً به خاطر قرار گرفتن این صفحه در تراز بالاتر و تأثیر آن بر روند انتخاب ویژگی است. با توجه به شکل ۷ این صفحه بیش‌ترین خطا (مقدار RMSE برابر ۰/۰۰۸۰) را در مدل‌سازی دارد. در این صفحه ترکیب ۴ تایی، کمترین خطا (مقدار RMSE برابر ۰/۰۰۴۰) را در مدل‌سازی ویژگی هدف نشست دارد. البته نتایج نشان داد اختلاف خطا یا مقدار RMSE در بین ترکیب‌های دو تا پنج‌تایی در این صفحات بسیار ناچیز است. با مقایسه نتایج در صفحات و با توجه به شکل‌های ۶ و ۷، مشخص شد که خطای مدل‌سازی با زیاد شدن ارتفاع نصب، افزایش می‌یابد. دلیل این امر به این خاطر است که با توجه به اینکه ساخت سد از ترازهای پایین‌تر شروع شده و به ترازهای بالاتر



شکل ۶- مقادیر خطای ترکیب ویژگی‌ها برای صفحات مختلف.



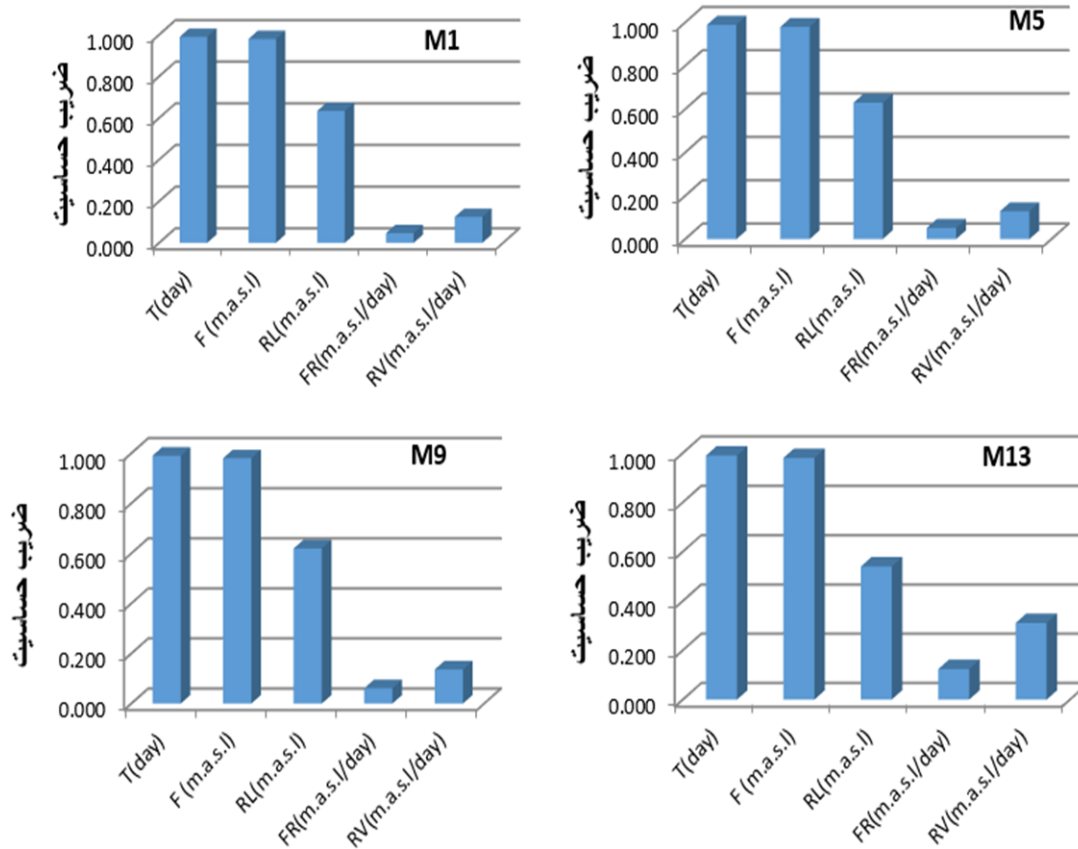
شکل ۷- مقدار خطای صفحات مختلف برای بهترین ترکیب ویژگی‌ها.

ویژگی به ترتیب شامل زمان ساخت سد، تراز خاک ریزی، تراز آب مخزن و سرعت آبیگری بیشترین تأثیر را در مدل‌سازی نشست خاک دارا بوده است.

انتخاب تأخیرهای زمانی ویژگی‌ها

آنالیز همبستگی برای تصمیم‌گیری درباره تأخیر زمانی داده‌ها و بررسی درستی نتایج مدل هیبریدی به کمک نرم‌افزار SPSS نسخه ۲۰۱۴ انجام گرفت. همچنین برای برآورد تأخیرهای زمانی از تابع خود همبستگی متقابل و تأخیرهای زمانی (۲۰ تا -۲۰) و محدوده اطمینان ۹۵ درصد استفاده شده است (اسدی و همکاران ۲۰۱۹) (شکل‌های ۹ تا ۱۲). در این نمودارها مقادیر منفی، نشان‌دهنده زمان قبل و مقادیر مثبت، نشان‌دهنده زمان بعد است.

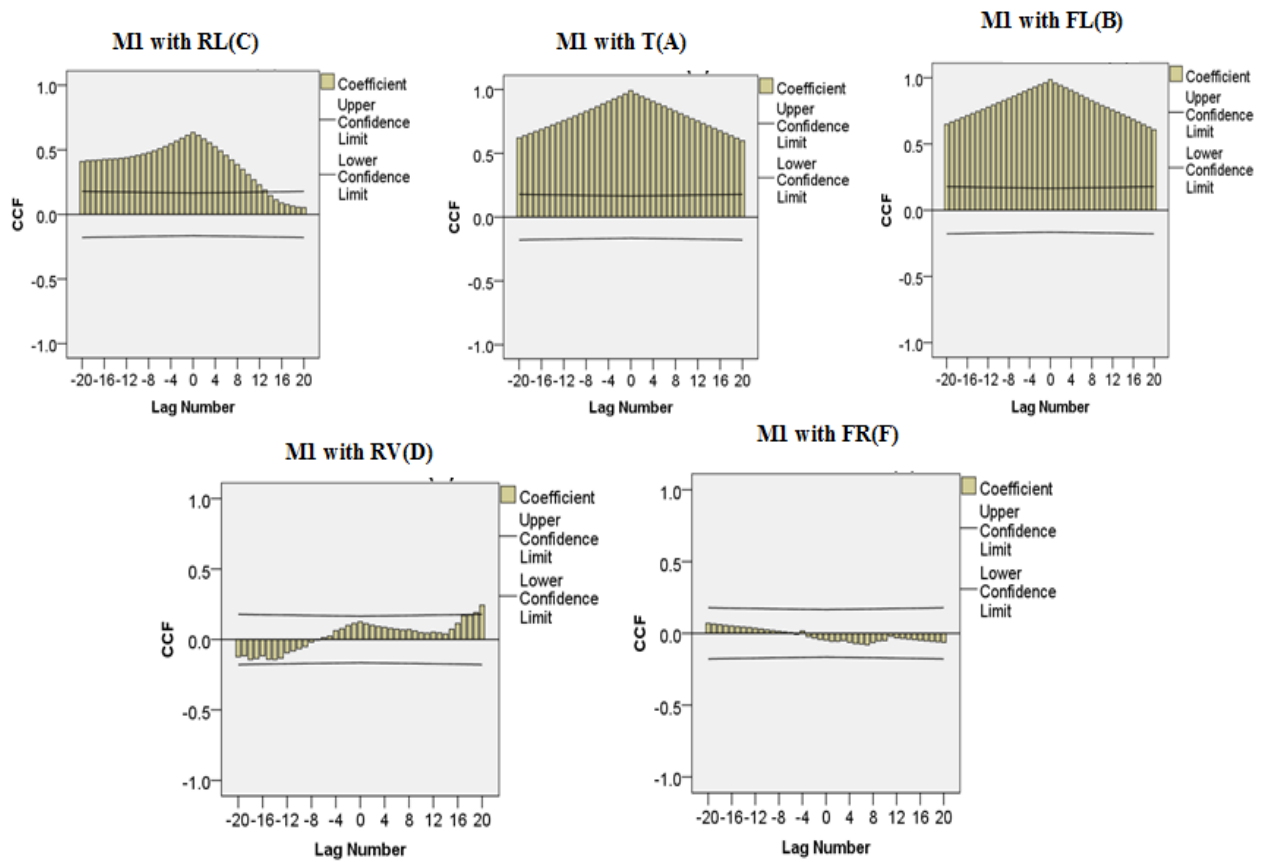
در صفحه M5 که در تراز ۱۵۲ متر قرار دارد، از بین ۵ ویژگی ورودی، سه ویژگی به ترتیب شامل زمان ساخت، تراز خاک ریزی، تراز آبیگری با توجه به ضریب حساسیت بالاتر، بیشترین تأثیر را در مدل‌سازی نشست خاک داراست. در صفحه M9 که در قسمت میانی و محور سد در تراز ۱۶۴ متر نصب شده است، نتایج نشان داد که در این صفحه از بین ۵ ویژگی ورودی، دو ویژگی به ترتیب شامل زمان ساخت، تراز خاک ریزی با توجه به ضریب حساسیت بالاتر، بیشترین تأثیر را در مدل‌سازی نشست خاک داراست. تأثیر ترکیب باهم این سه ویژگی در این صفحات، نشان‌دهنده این واقعیت است که این ویژگی‌ها بر مقدار نشست در آنها تأثیر بالایی دارند. در صفحه M13 که در تراز ۱۸۰ متر نصب شده است، نتایج نشان داد که از بین ۵ ویژگی ورودی، چهار



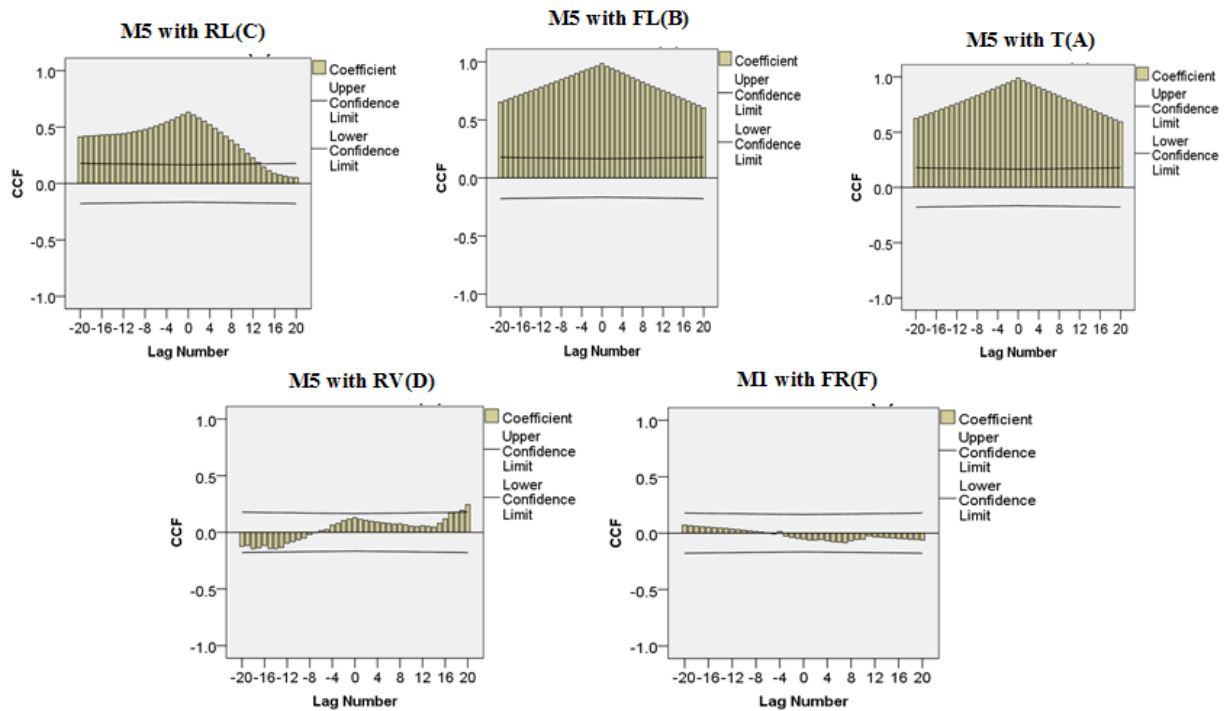
شکل ۸- آنالیز حساسیت ویژگی‌های ورودی استفاده از روش هیل.

M13 ویژگی سرعت خاکریزی به علت همبستگی پایین و نیز قرار نگرفتن در محدوده اطمینان از ورودی مدل‌ها حذف می‌شوند که این نتایج با نتایج مدل هیبریدی و آنالیز حساسیت یکسان است. بنابراین با توجه به آنالیز همبستگی داده‌ها، خروجی مدل هیبریدی به خوبی توانسته ویژگی‌های اضافی را حذف کرده و بهترین ویژگی‌ها را برای مدل‌سازی ضریب نشست انتخاب کند. با توجه به شکل‌های ۹ تا ۱۲، همبستگی معکوس بین تراز خاکریزی با نشست و همبستگی مستقیم بین سایر ویژگی‌ها با نشست وجود دارد.

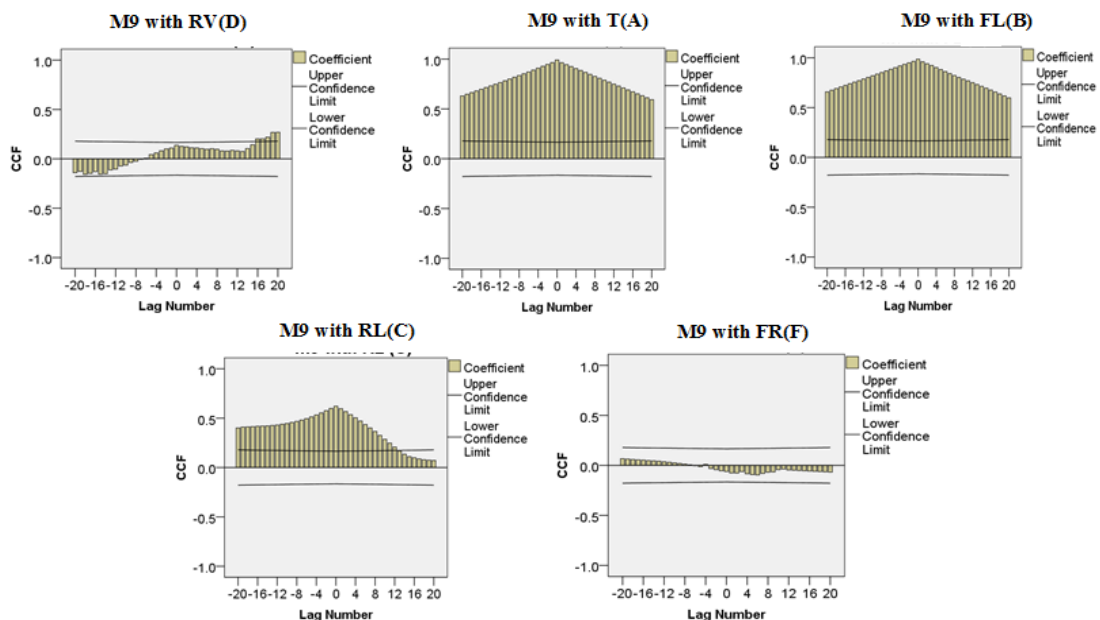
در شکل‌های ۹ تا ۱۲ زمان‌های تأخیر روزانه و محور Y نشان‌دهنده مقادیر همبستگی بین ویژگی‌ها با نشست (تا ۲۰ روز قبل) است. با توجه به خروجی نرم‌افزار SPSS در شکل‌های ۹ تا ۱۲ در همه صفحه‌ها واضح است که با تأخیر زمانی منفی همبستگی بین ویژگی‌ها کاهش یافته یا ثابت مانده است، بنابراین می‌توان گفت که شرایط فعلی مقادیر تراز خاکریزی، تراز آگیری، زمان ساخت، سرعت خاکریزی و سرعت آگیری می‌توانند به عنوان ورودی برای مدل‌های هوشمند در همه صفحه‌ها کافی بوده است (جدول ۲). همچنین در صفحات M1، M5 و M9 ویژگی‌های سرعت آگیری و خاکریزی و در صفحه



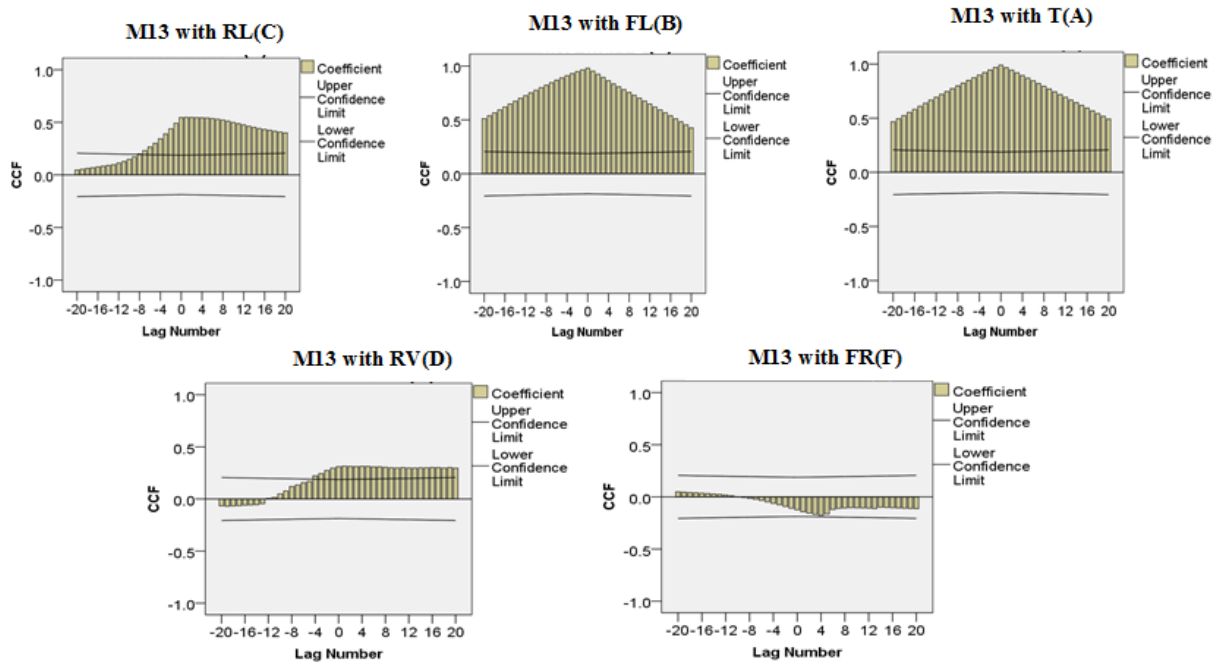
شکل ۹- آنالیز همبستگی داده‌های مورد استفاده در صفحه MI: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (F) همبستگی متقابل بین سرعت خاکریزی و نشست.



شکل ۱۰- آنالیز همبستگی داده‌های مورد استفاده در صفحه M5: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (F) همبستگی متقابل بین سرعت خاکریزی و نشست.



شکل ۱۱- آنالیز همبستگی داده‌های مورد استفاده در صفحه M9: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (F) همبستگی متقابل بین سرعت خاکریزی و نشست.



شکل ۱۲- آنالیز همبستگی داده‌های مورد استفاده در صفحه M13: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (E) همبستگی متقابل بین سرعت خاکریزی و نشست.

همان طور که در جدول ۲ مشاهده می‌کنید با توجه به مؤلفه‌های آماری مربوط، مدل ANN در دوره آموزش به خوبی توانسته عمل مدل‌سازی متغیر هدف (نشست) را انجام دهد. البته در صفحه M13 که در تراز بالاتری قرار دارد، مدل ANN نسبت به سایر صفحات در تخمین نشست با توجه به مؤلفه‌های آماری، کمی ضعیف‌تر عمل کرده است که با توجه به خطای بالای این صفحه در مدل هیبریدی قابل انتظار بود. در این صفحه با توجه به جدول ۲ و شاخص‌های آماری در دوره آزمون R^2 ، SI، NSE و NRMSE به ترتیب برابر مقادیر ۰/۹۹۹۸، ۰/۰۰۶۲ و ۰/۹۹۹۸، مدل ANNN در دوره آزمون دارای عملکرد ضعیف‌تری نسبت به سه صفحه دیگر دارد. از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص نمودن بیش برآورد و یا کم برآورد مدل، استفاده شد. همان طور که از جدول ۲

مدل‌سازی نشست با استفاده از ویژگی‌های انتخاب‌شده با روش ANN

در این قسمت بعد از انتخاب ویژگی ورودی‌ها و تحلیل حساسیت و آنالیز همبستگی مدل‌سازی با مدل شبکه عصبی مصنوعی انجام گرفته است. جدول ۱ بهترین ترکیب ویژگی‌ها به عنوان ورودی مدل ANN، در صفحات مختلف را نشان می‌دهد.

جدول ۱ - ورودی‌های مدل‌های هوشمند

ورودی‌های مدل هوشمند	صفحه نشست سنج
RL,T,F	M1
RL,T,F	M5
RL,T,F	M9
RV,RL,T,F	M13

RLRV و T به ترتیب سرعت آبیگری، تراز آب مخزن، زمان ساخت و تراز

خاکریزی هستند.

بهتری نسبت به سه صفحه دیگر دارد. در شکل‌های ۱۳ و ۱۴ برای هر صفحه در مراحل آموزش و آزمون ۴ نمودار وجود دارد. که نمودارهای رگرسیونی، خطا و نمودار مشاهداتی-پیش بینی و نمودار جعبه‌ای توزیع خطا نام دارند. در نمودار توزیع خطا، خطاها به صورت نرمال توزیع شده است، که نشان‌دهنده عملکرد مناسب مدل ANN است.

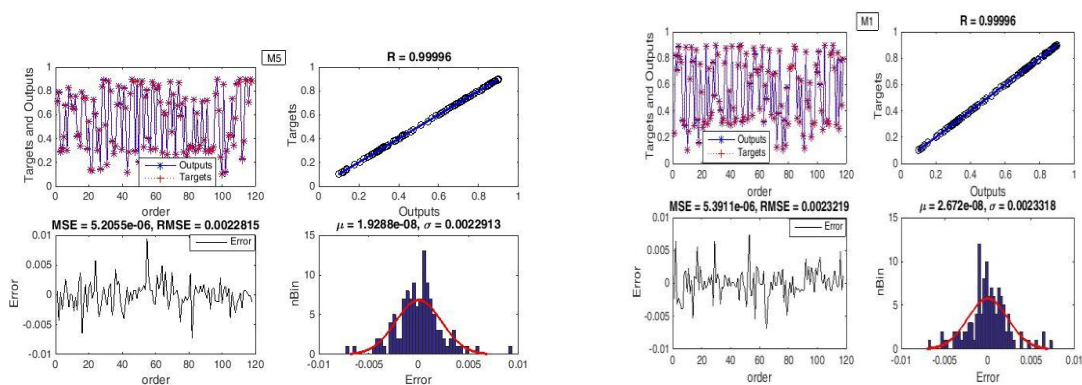
استنباط می‌شود، در بخش آموزش، همه صفحات مذکور به جز M9 بیش برآورد جزئی رخ داده است و در بخش آزمون در تمام صفحات بیش برآورد جزئی رخ داده است. مطابق جدول ۲، در صفحه M1 در دوره آزمون با توجه به شاخص‌های آماری R^2 ، SI، NSE و NRMSE به ترتیب برابر مقادیر ۰/۹۹۹۷، ۰/۰۰۷۹، ۰/۹۹۹۷ و ۰/۰۰۷۹ مدل ANNN در دوره آزمون دارای عملکرد

جدول ۲- شاخص‌های آماری صفحات مختلف در دوره آموزش و آزمون مدل بهینه ANN.

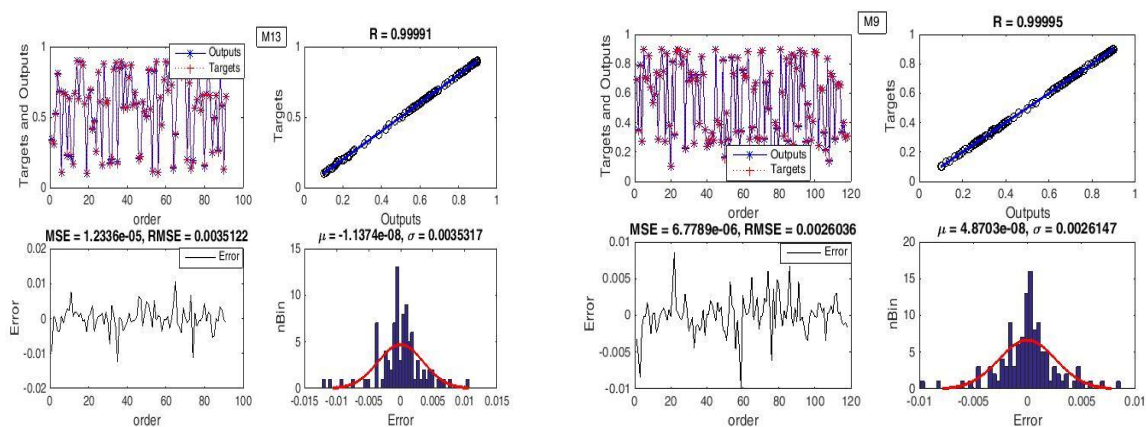
ساختار	آزمون					آموزش					صفحه
	GMRE	NRMSE	NSE	SI	R2	GMRE	NRMSE	NSE	SI	R^2	
MLP 4-9-1	۱/۰۰۰۱	۰/۰۰۷۹	۰/۹۹۹۷	۰/۰۰۷۹	۰/۹۹۹۷	۱/۰۰۰۱	۰/۰۰۴۲	۰/۹۹۹۹	۰/۰۰۴۲	۰/۹۹۹۹	M1
MLP 4-9-1	۱/۰۰۰۱	۰/۰۱۰۴	۰/۹۹۹۵	۰/۰۱۰۴	۰/۹۹۹۵	۱/۰۰۰۱	۰/۰۰۴۱	۰/۹۹۹۹	۰/۰۰۴۱	۰/۹۹۹۹	M5
MLP 4-9-1	۱/۰۰۰۱	۰/۰۱۰۹	۰/۹۹۹۴	۰/۰۱۰۹	۰/۹۹۹۴	۱/۰۰۰۱	۰/۰۰۴۷	۰/۹۹۹۹	۰/۰۰۴۷	۰/۹۹۹۹	M9
MLP 3-7-1	۱/۰۰۰۲	۰/۰۱۴۴	۰/۹۹۹۳	۰/۰۱۴۴	۰/۹۹۹۳	۱/۰۰۰۲	۰/۰۰۶۲	۰/۹۹۹۸	۰/۰۰۶۲	۰/۹۹۹۹	M13

همچنین شکل ۱۵، نحوه همگرایی الگوریتم سنجاک در تمام صفحات به سمت پاسخ بهینه را نشان می‌دهد. به طور کلی، حتی در غیاب داده‌های نشست مشاهده شده در زمان ساخت سدهای خاکی، می‌توان با آموزش مدل ANN با استفاده از داده‌های ورودی پیشنهادی، برآورد و تخمین قابل‌اعتمادی را به دست آورد. نتایج به دست آمده با توجه به هزینه نصب تجهیزات اندازه‌گیری نشست و اهمیت تخمین مقادیر واقعی در آینده بسیار با اهمیت است. مطالعه حاضر نشان داده است که مدل هیبریدی DA-ANN یک ابزار مهم در پیش‌بینی و استخراج ترکیب ورودی مناسب مدل هوشمند در مورد متغیر هدف نشست در زمان ساخت سدهای خاکی است. با در نظر گرفتن شرایط متفاوت هر سد، روش‌های هوش مصنوعی پس از تحلیل‌ها و دریافت اطلاعات ابزار دقیق، امکان استفاده خواهند داشت.

شکل ۱۳ و ۱۴ نمودار پراکندگی نتایج مدل ANN را نشان می‌دهد. همان‌طور که مشاهده می‌شود، توانایی و دقت عملکرد تمامی الگوریتم‌های هیبریدی فوق در تخمین نشست بر اساس نمودارهای پراکندگی قابل تأیید است. همان‌طور که در شکل‌های ۱۳ و ۱۴ مشاهده می‌شود مدل ANN به خوبی توانسته عمل شبیه‌سازی را انجام داده و به خوبی روند افزایش و کاهش تغییرات نشست را تخمین زده است. در ادامه پارامترهای کنترلی بهینه الگوریتم سنجاک بعد از سعی و خطا در جدول ۲ نشان داده شده است. در مدل هیبریدی، اندازه جمعیت برابر ۱۰۰ و تعداد تکرار ۱۰۰۰ و کران بالا و پایین به ترتیب ۰ و ۱ انتخاب شد که با فرآیند آزمون و خطا شناسایی شدند. نتایج نشان داد که اگر جمعیت و تعداد تکرار کمتر از ۳۰ باشد، عملکرد کاهش می‌یابد. همچنین در تعداد تکرار بیش از ۱۰۰۰ و تعداد جمعیت بیشتر از ۱۰۰ تأثیری بر نتایج به دست آمده، حاصل نشده است.




شکل ۱۳- مقادیر نشست محاسباتی و مشاهده شده در دوره آزمون در صفحات M5 و M1.



شکل ۱۴- مقادیر نشست محاسباتی و مشاهده شده در دوره آزمون در صفحات M13 و M9.

جدول ۳- پارامترهای کنترلی بهینه الگوریتم سنجاک.

تعداد تکرار	تعداد جمعیت سنجاک	کران پایین و بالا	تعداد ترکیب
۱۰۰۰	۱۰۰	LB=0; UB=1	۱ تا ۸



شکل ۱۵- روند همگرایی الگوریتم DA در صفحات مختلف برای ترکیب ویژگی‌های برتر.

پنج ویژگی شامل تراز خاک ریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت

نتیجه‌گیری کلی

نشست هستند در نتیجه خطای مدل‌سازی بیشتر خواهد شد. الگوریتم هیبریدی DA-ANN توانایی خوبی برای تخمین نشست نشان داده است، ولی آزمایش این مدل هیبریدی در سدهای دیگر با خواص ژئوتکنیکی متفاوت، برای اطمینان از عملکرد آن در شرایط واقعی ضروری می‌باشد. مدل هیبریدی DA-ANN استفاده شده در این مطالعه ممکن است در شرایط تغییر ژئوتکنیک دقیق نباشد، در نتیجه با ارزیابی عملکرد این مدل در شرایط تغییر ژئوتکنیک می‌توان نتایج این مدل را بهبود بخشید. به دلیل شرایط متفاوت سدها، روش مذکور پس از تحلیل‌ها و دریافت اطلاعات مربوطه، قابل‌استفاده خواهد بود.

خاک ریزی به عنوان ورودی مدل هیبریدی DA-ANN برای مدل‌سازی نشست سد خاکی کبودال در دوران ساخت انتخاب شدند. سه ویژگی تراز خاک ریزی و زمان ساخت و تراز آب مخزن در همه صفحات بیشترین تأثیر را (با توجه به ضریب حساسیت بالا) بر مدل‌سازی نشست خاک در زمان ساخت سدهای خاکی دارند. نتایج نشان داد که خطای مدل‌سازی در صفحاتی که در تراز بالاتر نصب شده‌اند بیشتر از نقاط دیگر است. در این صفحات روند نمودار ویژگی-خطا در آن کمی متفاوت از سه صفحه دیگر است که نشان‌دهنده تأثیر تراز ارتفاعی نصب بر روند انتخاب ویژگی‌های موثر بر مدل‌سازی نشست است. صفحات نصب‌شده در ترازهای بالاتر دارای داده‌های کمتری برای مدل‌سازی

منابع مورد استفاده

- Amiri Mijan F, Shirani H, Esfandiarpour I, Besalatpour A and Shekofteh H, 2019. Identifying the determinant factors influencing S index in calcereous soils using annealing simulated– artificial neural network hybrid algorithm. *Water and Soil Science*, 23(3): 381-394. (in Persian with English abstract)
- Asadi H, Shahedi K, Sidle RC and Kalami Heris S M, 2019. Prediction of suspended sediment using hydrologic and hydrogeomorphic data within intelligence models. *Iran-Water Resources Research*, 15(3): 105-119 (in Persian with English abstract)
- Bagherzadeh M, Mousavi SF, Manafpour M, Mirzaee R, and Hoseini K. 2020. Numerical simulation and application of soft computing in estimating vertical drop energy dissipation with horizontal serrated edge. *Water Supply*, 22:15-30.
- Chandrashekar G and Sahin F, 2014. A survey on feature selection methods. *Computers and Electrical Engineering*, 40(1): 16-28.
- Cucci G, Lacolla G, Pagliai M and Vignozzi N, 2015. Effect of reclamation on the structure of silty-clay soils irrigated with saline-sodic waters. *International agrophysics*, 29(1):15-32.
- Daneshfaraz R, Bagherzadeh M, Esmaeeli R, Norouzi R, and Abraham J, 2020. Study of the performance of support vector machine for predicting vertical drop hydraulic parameters in the presence of dual horizontal screens. *Water Supply*, 21(1): 217-231.
- Hakimi Khansar H, 2021. Simulation of behavior the Kabudval Dam during construction with 3D numerical modeling. *Amirkabir Journal of Civil Engineering*, 53(9): 20-20. (in Persian with English abstract)
- Hakimi Khansar H, Golmaei H, and Sheidaei M, 2014. Evaluating of Kaboodval dam during construction using finite element method with software PLAXIS and a comparison with the actual values of instrumentation data. *Journal of Water Science and Engineering*, 4(9): 33-50. (in Persian with English abstract)
- Hakimi Khansar H, Golmaei SH, and Sheydaei M, 2014. Numerical analysis of embankment dam monitoring during construction of the finite element method with software SIGMA / W (Case study: Kaboodval dam). *Journal of Water Science and Engineering*. 3(7): 67-83. (in Persian with English abstract)
- Hill MC. 1998. *Methods and Guidelines for Effective Model Calibration*. U.S. Geological Survey Water-Resources Investigations Report, 98-4005. pp. 1-98.
- Kumar V, and Minz S, 2014. Feature selection: a literature review. *SmartCR*. 4(3): 211-229.
- Mirjalili S, 2016. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. *Neural Computing and Applications*, 27(4): 1053-1073.

- Norouzi R, Sihag P, Daneshfaraz R, Abraham J, and Hasannia V, 2021. Predicting relative energy dissipation for vertical drops equipped with a horizontal screen using soft computing techniques. *Water Supply*. 21(8):4493-513.
- Nourani V and Babakhani A, 2013. Integration of artificial neural networks with radial basis function interpolation in earthfill dam seepage modeling. *Journal of Computing in Civil Engineering*. 27(2), 183-195.
- Nourani V, Sharghi, E and Aminfar M, 2012. Integrated ANN model for earthfill dams seepage analysis: Sattarkhan Dam in Iran. *Artificial Intelligence Research*. 1(2): 22-37.
- Nouri M and Salmasi F, 2019. Predicting seepage of earth dams using artificial intelligence techniques. *Irrigation Sciences and Engineering*. 42(1): 83-97. (in Persian with English abstract)
- Novakovic A, Rankovic V, Grujovic N, Divac D, and Milivojevic N, 2014. Development of neuro-fuzzy model for dam seepage analysis. *Annals of the Faculty of Engineering Hunedoara*. 12(2): 133-136.
- Parsa J, Hakimi Khansar H, Hoseinzadeh dalir A, and Shiri J, 2021. Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features. *Amirkabir Journal of Civil Engineering*. 54(1): 14-30. (in Persian with English abstract)
- Salmasi F, Hakimi Khansar H and Norani B, 2019. Investigation of the structure of the dam body during construction and its comparison with the analytical results using pLAXIS software (the Case Study of Kaboodvall Dam). *Journal of Water and Soil Science*, 22(4): 155-171. (in Persian with English abstract)
- Shiri J, 2019. Modeling reference evapotranspiration in island environments: assessing the practical implications. *Journal of Hydrology*. 570: 265-280.
- Wu K, Soci C, Shum PP and Zheludev NI, 2014. Computing matrix inversion with optical networks. *Optics Express*, 22(1): 295-304.