Archive of SID.ir

Water and Soil Science, Vol.33, NO.3, Autumn 2023, pp. 163-181.

DOI: 10.22034/ws.2022.50325.2459 ISSN:2717-3755 https://water-soil.tabrizu.ac.ir/

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 Dalir[2], J Parsa[3], J Shiri[4]

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

©: The Author(S)
Publisher: University of Tabriz

Archive of SID.ir

Archive of SID.ir

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.

Archive of SID.ir

Archive of SID.ir

نشریه دانش آب و خاک / جلد ۳۳ شماره ۳ صفحه‌های ۱۶۳ تا ۱۸۱/ سال ۱۴۰۲

مقاله پژوهشی

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

حسین حکیمی خانسر[1*]، علی حسین زاده دلیر[2]، جواد پارسا[3]، جلال شیری[4]

تاریخ دریافت: ۱۴۰۰/۰۴/۰۵ تاریخ پذیرش: ۱۴۰۱/۰۶/۱۴

تاریخ دریافت ویرایش:۱۴۰۱/۰۶/۱۲ تاریخ انتشار انلاین :۱۴۰۲/۷/۱

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 کبودوال، 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، ۰/۰۰۲۶و 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 R^2، SI، NSE و NRMSE به ترتیب برابر مقادیر ۰/۹۹۹۷، ۰/۰۰۷۹، ۰/۹۹۹۷ و ۰/۰۰۷۹ 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.

Archive of SID.ir

Archive of SID.ir

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 سازه‌ای دارای اهمیت بالایی هستند (پارسا و همکاران ۲۰۲۱، نوواکوویچ و همکاران ۲۰۱٤). 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[1]، با شبکه‌های عصبی به دلیل نتایج دقیق‌تر بسیار متداول شده است (پارسا و همکاران ۲۰۲۱). فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه‌بندی[2] ویژگی‌ها کاربرد دارد (وو و همکاران ۲۰۱٤). تخمین بهترین ترکیب ورودی در مدل های هوش مصنوعی همیشه نظارت شده[3] است، درحالی‌که طبقه‌بندی ویژگی‌ها را می‌توان نظارت شده و یا در برخی موارد غیر نظارت شده[4] انجام داد (کوکی 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 ۲۰۱٤).

مطالعه‌هایی در زمینه مدل‌سازی نشست سدهای خاکی در زمان ساخت با مدل عددی (حکیمی خانسر و همکاران ۲۰۱٤)، (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 سنجاقک - 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

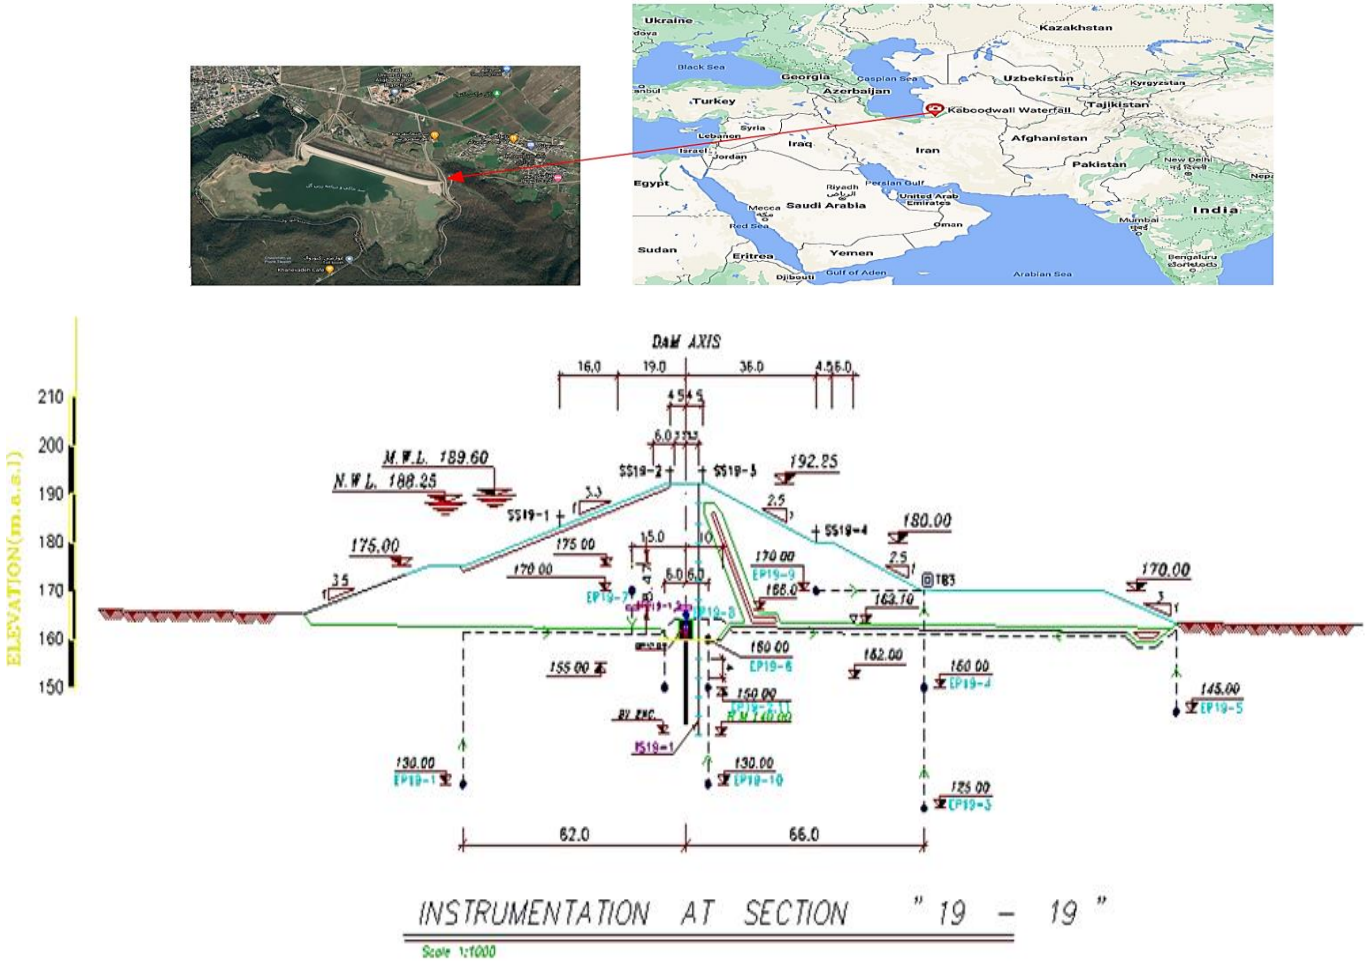
سد کبودوال (قره‌سو زرینگل) در استان گلستان گرگان و در اطراف شهر علی‌آباد، قرارگرفته است. این سد در حد فاصل طول جغرافیایی ٥٤ درجه و ٤٠ دقیقه تا ٥٤ درجه و ٥٦ دقیقه شرقی و عرض‌های جغرافیای ٣٦ درجه و ٥٤ دقیقه تا ٣٧ درجه و ٦٠ دقیقه شمالی قرار گرفته است. (حکیمی خانسر و همکاران ۲۰۱٤). برای دستیابی به تغییر 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 ۱٤۰ 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

Archive of SID.ir

Archive of SID.ir

انجام پژوهش حاضر از داده‌های ابزار دقیق سد کبودوال (از تاریخ ۱۳۸۸/۳/۱۵تا ۱۳۹۱/۱۱/۱۵)، اخذشده از شرکت آب منطقه‌ای استان گلستان، استفاده شده است (حکیمی خانسر و همکاران ۲۰۱٤). در این تحقیق از بین ۱۷ صفحه مذکور، تعداد ٤ صفحه نشست سنج به نام‌های M1، M5، M9 و M13 نصب‌شده در بدنه و پی سد کبودوال به ترتیب در ترازهای ۱٤۰، ۱۵۲، ۱٦٤ و ۱۸۰ برای مدل‌سازی استفاده شده است. در ادامه کارایی مدل هوشمند در تخمین نشست در ترازهای مختلف بهتر مورد ارزیابی قرار گرفته است.



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

شبکه‌های عصبی مصنوعی(ANN)

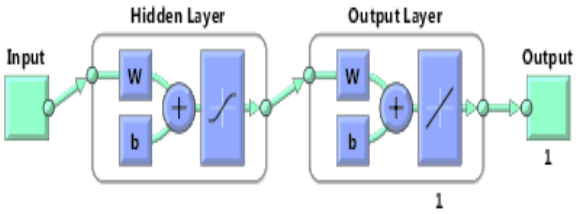
برای مدل‌سازی پدیده‌ها در علوم مختلف مهندسی با شبکه‌های عصبی مصنوعی، شبکه‌های چند لایه پیشرو با الگوریتم یادگیری پس انتشار بسیار متداول است (نورانی و باباخانی ۲۰۱۳). ثابت شده است که مدل شبکه پس انتشار با سه لایه برای پیش‌بینی و شبیه‌سازی در هر گونه مسائل مهندسی کافی است (نورانی و همکاران ۲۰۱۲). وزن‌های شبکه عصبی در لایه‌های میانی و خروجی متفاوت هستند و مقادیر آن‌ها می‌تواند در طول فرآیند آموزش شبکه تغییر نماید (باقر زاده و همکاران ۲۰۲۰، دانش فراز و همکاران ۲۰۲۰). در این پژوهش، تابع انتقال شامل توابع سیگموئید و خطی، به ترتیب برای

Archive of SID.ir

Archive of SID.ir

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

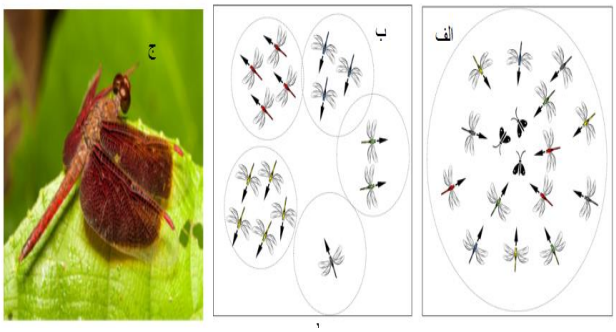
همچنین تابع آموزش تابع لونبرگ-مارکوارت[5] انتخاب شده است (شکل ۲). همچنین تعداد ورودی‌ها ۱ تا ۵ در نظر گرفته شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی در پژوهش.

الگوریتم بهینه‌سازی سنجاقک[6] (DA)

برای نخستین بار الگوریتم بهینه‌سازی سنجاقک توسط (میر جلیلی ۲۰۱۶) توسعه داده شد. منشأ اصلی این الگوریتم از رفتارهای هوش جمعی ایستا[7] و هوش جمعی پویا[8]است که این دو رفتار هوش جمعی با مراحل اصلی از بهینه‌سازی با الگوریتم‌های فرا ابتکاری یعنی اکتشاف و استخراج شباهت دارد (شکل ۳). سنجاقک‌ها 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 سنجاقک‌ها این است که در گروه‌های بزرگ‌تر و در امتداد یک جهت حرکت کنند (میر جلیلی ۲۰۱۶).



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

پنج عامل اصلی در به‌روزرسانی موقعیت نمونه در رفتار ازدحامی با توجه به این دو رفتار وجود خواهد داشت (شکل ٤) (میر جلیلی ۲۰۱٦). مرحله اول تفکیک نام دارد. مدل‌سازی ریاضی این مرحله با استفاده از رابطه زیر صورت می‌گیرد.

$$S_i = -\sum_{j=1}^{N}(X - X_j) \qquad [۱]$$

در رابطه بالا X موقعیت فعلی سنجاقک، X_j نشان‌دهنده j اُمین همسایه سنجاقک و N تعداد سنجاقک‌های همسایه است. مرحله دوم مرحله هم ترازی است. مدل‌سازی ریاضی این مرحله با رابطه زیر انجام می‌گیرد.

$$A_i = \frac{\sum_{j=1}^{N} V_j}{N} \qquad [۲]$$

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

$$C_i = \frac{\sum_{j=1}^{N} X_j}{N} - X \qquad [۳]$$

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

$$F_i = X^+ - X \qquad [٤]$$

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

$$E_i = X^- + X \qquad [۵]$$

[5] Levenberg-Marquardt
[6] Dragonfly Algorithm
[7] Static dragonfly swarms
[8] Dynamic dragonfly swarms

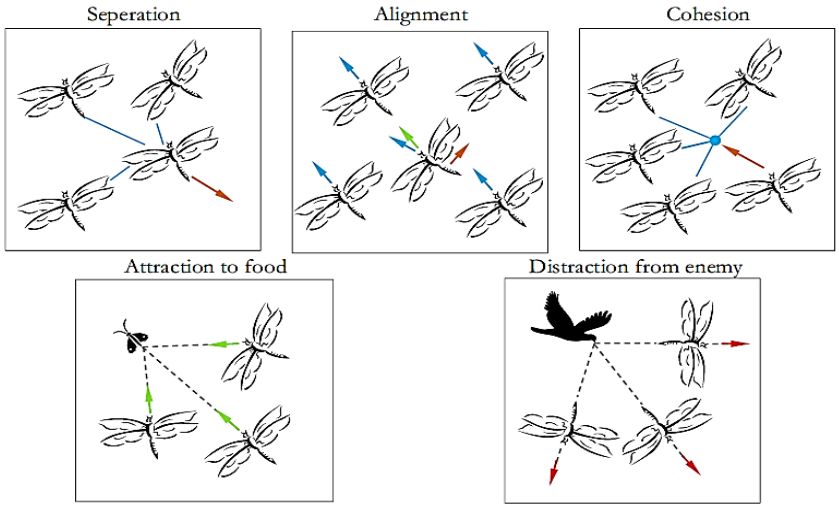
Archive of SID.ir

Archive of SID.ir

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

$$X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i + wX_t) \quad [٦]$$

که در آن، S نشان‌دهنده ضریب تفکیک و S_i نشان‌دهنده مجزا بودن i امین سنجاقک، a نشان‌دهنده ضریب هم ترازی، A_i نشان‌دهنده حرکت اصولی i امین سنجاقک، c نشان‌دهنده ضریب انسجام، C_i نشان‌دهنده انسجام i امین سنجاقک، f ضریب جذب منبع غذا، F_i نشان‌دهنده منبع غذای i امین سنجاقک، e نشان‌دهنده ضریب دوری از دشمن، E_i نشان‌دهنده موقعیت دشمن از i امین سنجاقک و w نشان‌دهنده ضریب اینرسی است. همچنین X_t و X_{t+1} مکان سنجاقک‌ها در تکرارهای t و t+1 را بیان می‌کنند. (میر جلیلی ۲۰۱٦).



شکل ۴- پنج عامل اصلی در به‌روزرسانی موقعیت نمونه در رفتار ازدحامی سنجاقک‌ها (میر جلیلی ۲۰۱٦).

ترکیب شبکه عصبی با الگوریتم سنجاقک

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 سنجاقک استفاده شد. انتخاب ویژگی، روشی است برای انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط (بهترین ترکیب آن‌ها) با یک هدف به کار می‌رود. مهم‌ترین اصل در آن، انتخاب ویژگی‌های پایدار و حذف داده‌های اضافی است (کومار و مینز ۲۰۱٤). در این مطالعه ترکیب الگوریتم سنجاقک با شبکه عصبی به صورت DA-ANN نشان داده شده است. بنابراین، الگوریتم فرا ابتکاری سنجاقک 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

Archive of SID.ir

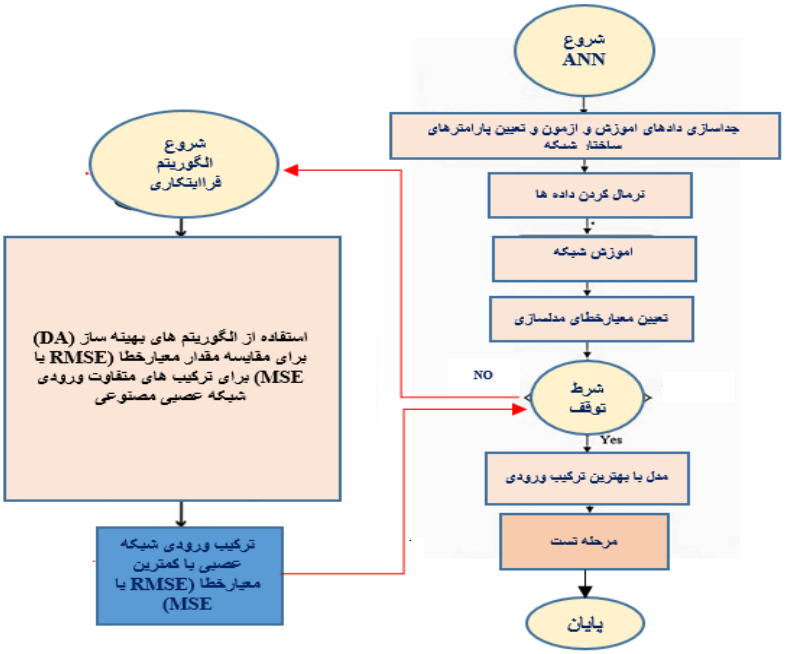
Archive of SID.ir

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

$$\mathrm{Error}_f = 0.8\mathrm{error}_{tr} + 0.2\mathrm{error}_{te} \quad [۷]$$

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 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 $(\mathrm{m.a.s.l\ day^{-1}})$ و سرعت آبگیری (RV) بر حسب $(\mathrm{m.a.s.l\ day^{-1}})$ 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.



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

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 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).

Archive of SID.ir

Archive of SID.ir

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 قابل‌محاسبه است:

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

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

$$\text{NRRMSE} = \frac{\sqrt{\frac{\sum_{i=1}^{n}(p_i-o_i)^2}{N}}}{\overline{O_i}} \quad [۱۰]$$

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

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

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

در روابط بالا O_i مقدار مشاهداتی ، P_i مقدار محاسبه‌شده از مدل هوشمند، $\overline{O_i}$ مقادیر میانگین مشاهداتی،$\overline{P_i}$ میانگین مقادیر محاسبه‌شده 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 پیش‌بینی‌شده 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 مقدارGMER 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 ۱٤ داده‌ها بین ۰/۱ تا ۰/۹ نرمال شده است تا برای معرفی به شبکه‌های عصبی در مراحل آموزش و آزمون آماده شوند.

$$x_n = \left(0.8 * \left(\frac{(x-x_{min})}{(x_{max}-x_{min})}\right)\right) + 0.1 \quad [۱٤]$$

در رابطه بالا مقادیر x_n ،x ،x_{min} ،x_{max} به ترتیب داده‌های نرمال شده، داده‌های اصلی، کمینه دادها، بیشینه داده ها 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 ترکیب۱ تا ٥ 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 گریده است. دو صفحه M1 و M5 در پی سد و در ترازهای ۱٤۰ و ۱٥۲ قرار دارند ولی دو صفحه M9 و M13 در بدنه سد و در ترازهای ۱٦٤ و ۱۸۰ نصب‌شده‌اند (شکل ۱). نتایج به دست آمده از الگوریتم هیبریدی DA-ANN در شکل ٦ در مورد صفحات M1 و M5 نشان داد که از بین ٥ 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 برابر۰/۰۰٤۷) را در مدل‌سازی نشست دارد. برای صفحه M5 مقدار RMSE برابر ۰/۰۰٥۸ 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 ۰/۰۰٤۰) را در مدل‌سازی نشست دارد. هم‌چنین روند نمودار ویژیگی–خطا در این سه صفحه تقریباً مشابه هم

Archive of SID.ir

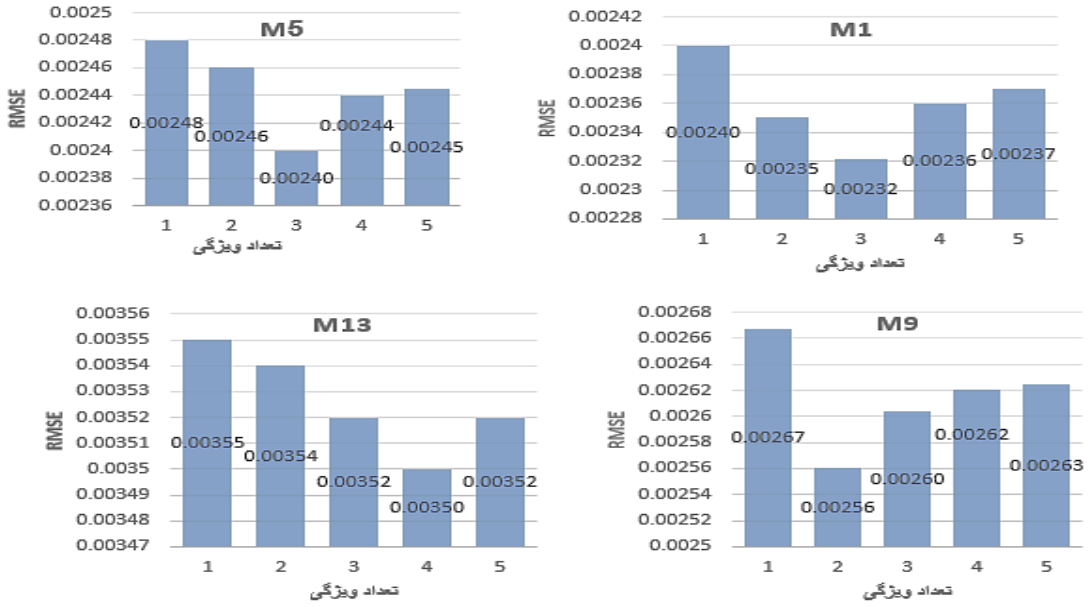
Archive of SID.ir

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 ٤ تایی، کمترین خطا (مقدار RMSE برابر ۰/۰۰٤۰) را در مدل‌سازی ویژگی هدف نشست دارد. البته نتایج نشان داد اختلاف خطا یا مقدارRMSE در بین ترکیب‌های دو تا پنج‌تایی در این صفحات بسیار ناچیز است. با مقایسه نتایج در صفحات و با توجه به شکل‌های ٦ و ۷، مشخص شد که خطای مدل‌سازی با زیادشدن ارتفاع نصب، افزایش می‌یابد. دلیل این امر به این خاطر است که با توجه به اینکه ساخت سد از ترازهای پایین‌تر شروع‌شده و به ترازهای بالاتر 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.

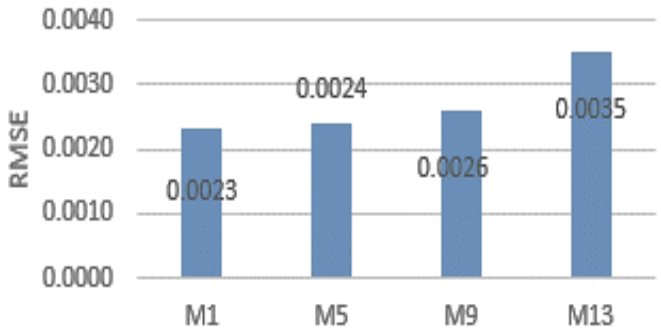
بر اساس نتایج حاصل از آنالیز حساسیت (شکل ۸)، در صفحه M1 که در قسمت میانی و محور سد، در تراز ۱٤۰ متر قرار دارد از بین ٥ ویژگی ورودی، سه ویژگی به ترتیب شامل زمان ساخت، تراز خاک ریزی و تراز آبگیری با توجه به ضریب حساسیت بالاتر، بیش‌ترین تأثیر را در مدل‌سازی نشست خاک دارا است.



شکل۶- مقادیر خطای ترکیب ویژگی‌ها برای صفحات مختلف.

Archive of SID.ir

Archive of SID.ir



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

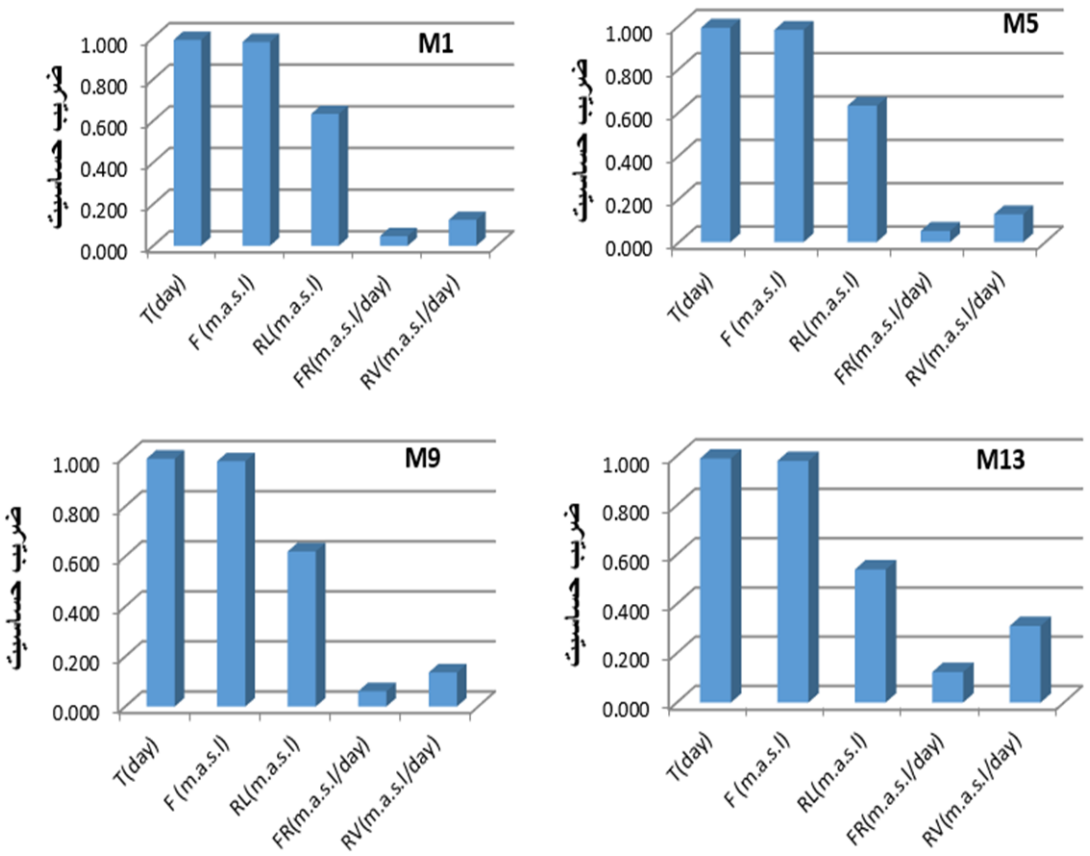
در صفحه M5 که در تراز ۱۵۲متر قرار دارد، از بین ۵ ویژگی ورودی، سه ویژگی به ترتیب شامل زمان ساخت، تراز خاک ریزی، تراز آبگیری با توجه به ضریب حساسیت بالاتر، بیش‌ترین تأثیر را در مدل‌سازی نشست خاک داراست. در صفحه M9 که در قسمت میانی و محور سد در تراز ١٦٤ متر نصب شده است، نتایج نشان داد که در این صفحه از 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 ویژگی به ترتیب شامل زمان ساخت سد، تراز خاک ریزی، تراز آب مخزن و سرعت آبگیری بیش‌ترین تأثیر را در مدل‌سازی نشست خاک دارا بوده است.

انتخاب تأخیرهای زمانی ویژگی‌ها

آنالیز همبستگی برای تصمیم‌گیری دربارهٔ تأخیر زمانی داده‌ها و بررسی درستی نتایج مدل هیبریدی به کمک نرم‌افزار SPSS نسخه ٢٠١٤ انجام گرفت . همچنین برای برآورد تأخیرهای زمانی از تابع خود همبستگی متقابل و تأخیرهای زمانی (۲۰ تا ۲۰-) و محدودهٔ 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.

Archive of SID.ir

Archive of SID.ir

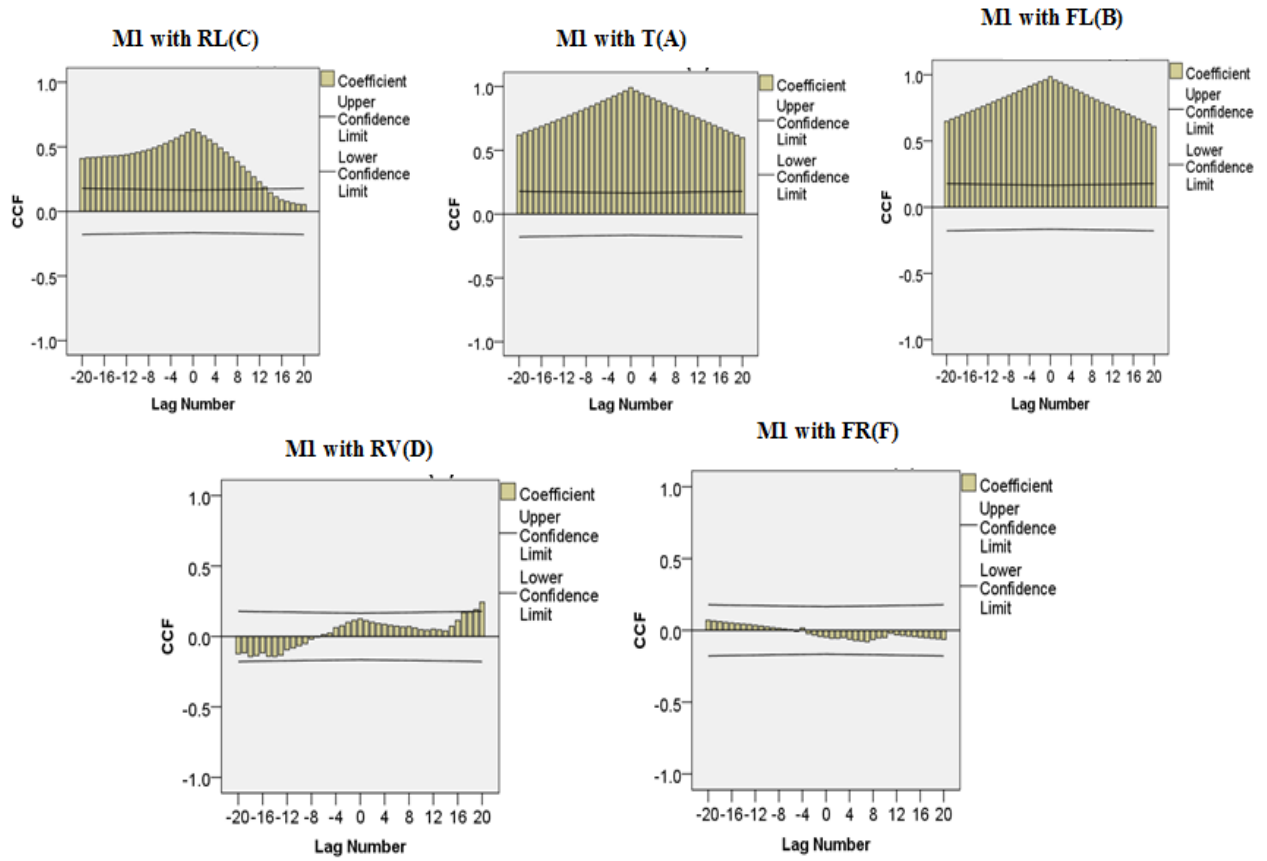


شکل۸- آنالیز حساسیت ویژگی‌های ورودی استفاده از روش هیل.

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 کاهش‌یافته یا ثابت مانده است، بنابراین می‌توان گفت که شرایط فعلی مقادیر تراز خاکریزی، تراز آبگیری، زمان ساخت، سرعت خاکریزی و سرعت آبگیری می‌توانند به عنوان ورودی برای مدل‌های هوشمند در همه صفحه‌ها کافی بوده است (جدول ۲). همچنین در صفحات M1، M5 و M9 ویژگی‌های سرعت آبگیری و خاکریزی و در صفحه M13 ویژگی سرعت خاکریزی به علت همبستگی پایین و نیز قرار نگرفتن در محدوده اطمینان از ورودی مدل ها 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.

Archive of SID.ir

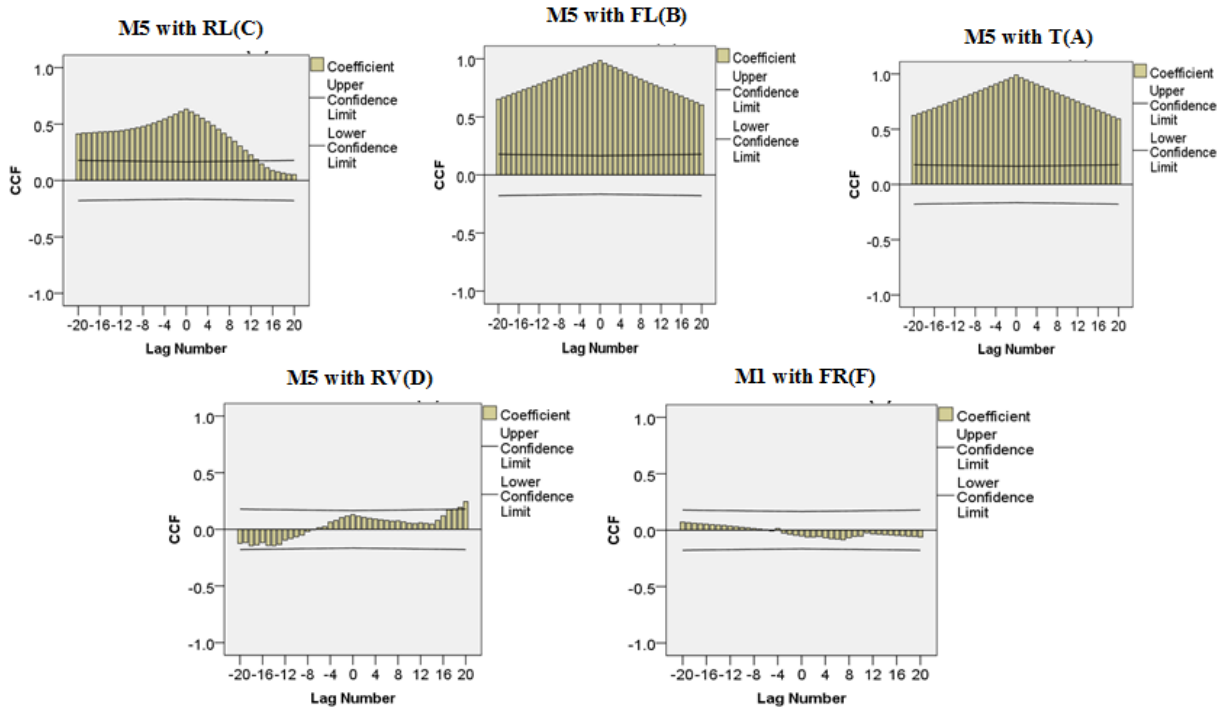
Archive of SID.ir



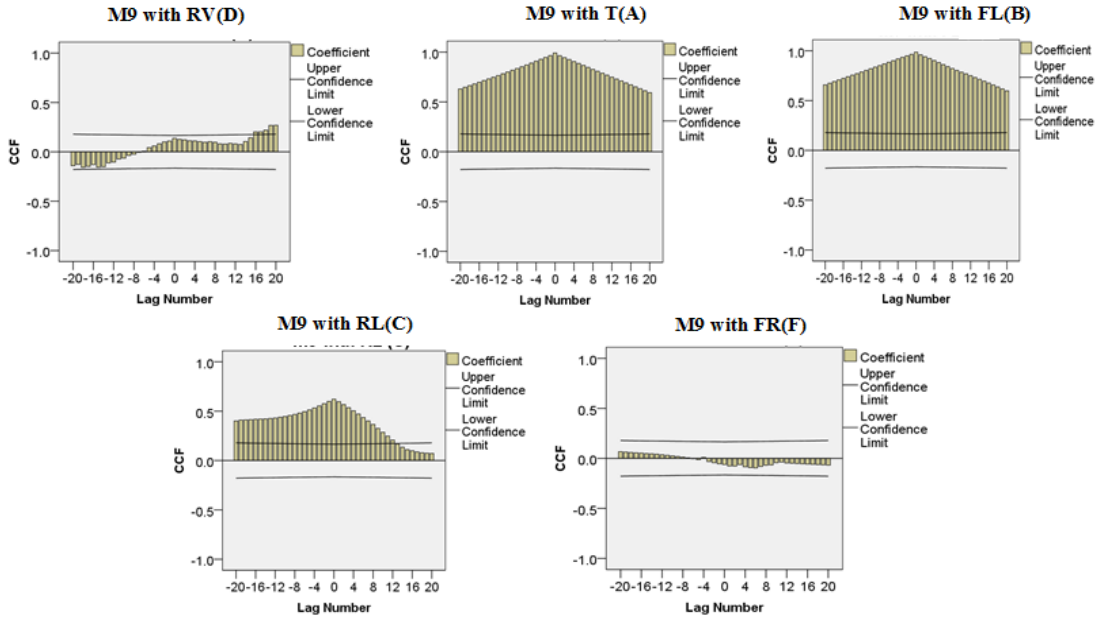
شکل ۹- آنالیز همبستگی داده‌های مورد استفاده در صفحه M1: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (F) همبستگی متقابل بین سرعت خاکریزی و نشست.

Archive of SID.ir

Archive of SID.ir



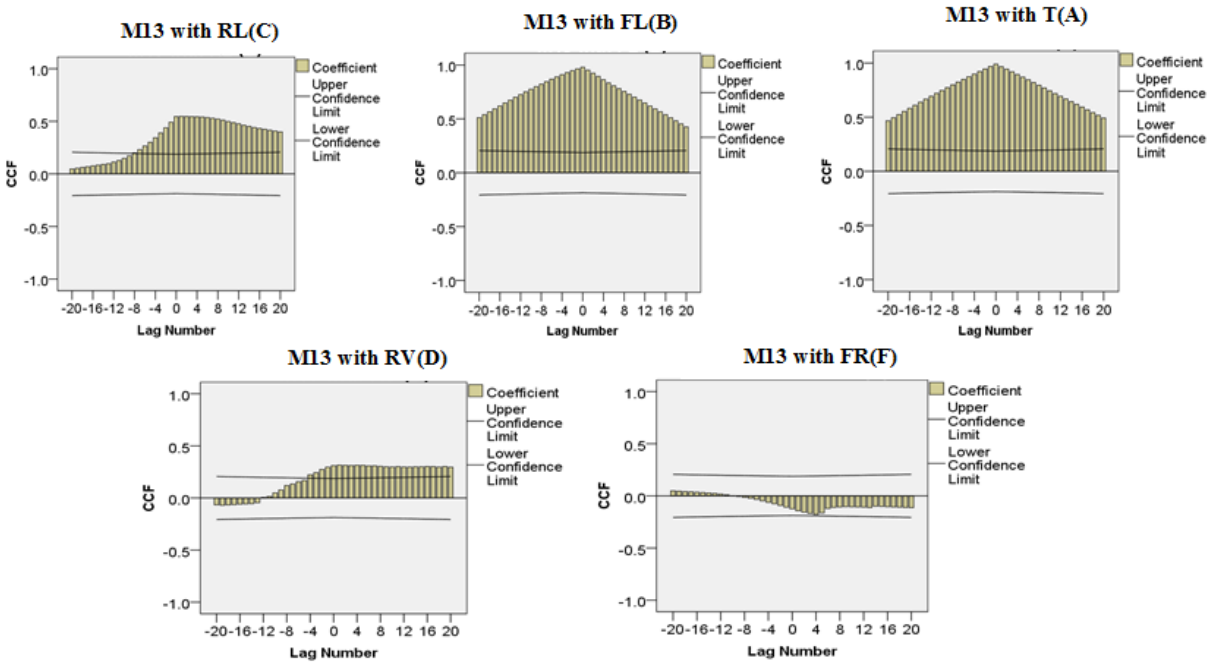
شکل ۱۰- آنالیز همبستگی داده‌های مورد استفاده در صفحه M5: شکل (A) همبستگی متقابل بین زمان ساخت و نشست، شکل (B) همبستگی متقابل بین تراز خاکریزی و نشست، شکل (C) همبستگی متقابل بین تراز آب مخزن و نشست، شکل (D) همبستگی متقابل بین سرعت آب گیری و نشست، شکل (F) همبستگی متقابل بین سرعت خاکریزی و نشست.



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.

Archive of SID.ir

Archive of SID.ir



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 (F) همبستگی متقابل بین سرعت خاکریزی و نشست.

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 می دهد.

جدول۱ - ورودی های مدل‌های هوشمند

صفحه نشست سنج	ورودی های مدل هوشمند
M1	RL،T ،F
M5	RL،T ،F
M9	RL،T ،F
M13	RV،RL،T ،F

RV،RL،TوF به ترتیب سرعت آبگیری، تراز آب مخزن، زمان ساخت و تراز خاکریزی هستند.

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، ۰/۹۹۹۸ و ۰/۰۰۶۲ 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

Archive of SID.ir

Archive of SID.ir

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 بهتری نسبت به سه صفحه دیگر دارد. در شکل‌های ۱۳ و ۱٤ برای هر صفحه در مراحل آموزش و آزمون ٤ 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.

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

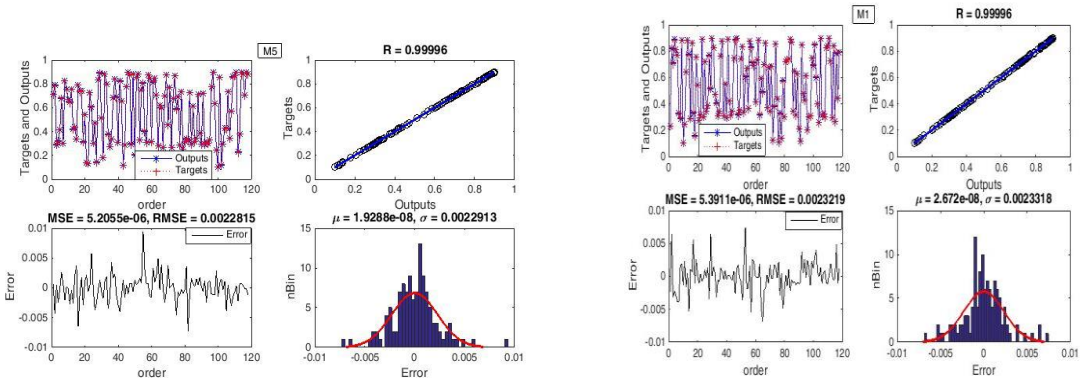
صفحه	آموزش					آزمون					ساختار
	R^2	SI	NSE	NRMSE	GMRE	R2	SI	NSE	NRMSE	GMRE	
M1	۰/۹۹۹۹	۰/۰۰٤۲	۰/۹۹۹۹	۰/۰۰٤۲	۱/۰۰۰۱	۰/۹۹۹۷	۰/۰۰۷۹	۰/۹۹۹۷	۰/۰۰۷۹	۱/۰۰۰۱	MLP 4-9-1
M5	۰/۹۹۹۹	۰/۰۰٤۱	۰/۹۹۹۹	۰/۰۰٤۱	۱/۰۰۰۱	۰/۹۹۹٥	۰/۰۱۰٤	۰/۹۹۹٥	۰/۰۱۰٤	۱/۰۰۰۱	MLP 4-9-1
M9	۰/۹۹۹۹	۰/۰۰٤۷	۰/۹۹۹۹	۰/۰۰٤۷	۱/۰۰۰۱	۰/۹۹۹٤	۰/۰۱۰۹	۰/۹۹۹٤	۰/۰۱۰۹	۱/۰۰۰۱	MLP 4-9-1
M13	۰/۹۹۹۹	۰/۰۰٦۲	۰/۹۹۹۸	۰/۰۰٦۲	۱/۰۰۰۲	۰/۹۹۹۳	۰/۰۱٤٤	۰/۹۹۹۳	۰/۰۱٤٤	۱/۰۰۰۲	MLP 3-7-1

شکل ۱۳ و ۱٤ نمودار پراکندگی نتایج مدل ANN را نشان می‌دهد. همان طور که مشاهده می‌شود، توانایی و دقت عملکرد تمامی الگوریتم‌های هیبریدی فوق در تخمین نشست بر اساس نمودارهای پراکندگی قابل تأیید است. همان طور که در شکل‌های ۱۳ و ۱٤ 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 سنجاقک 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.

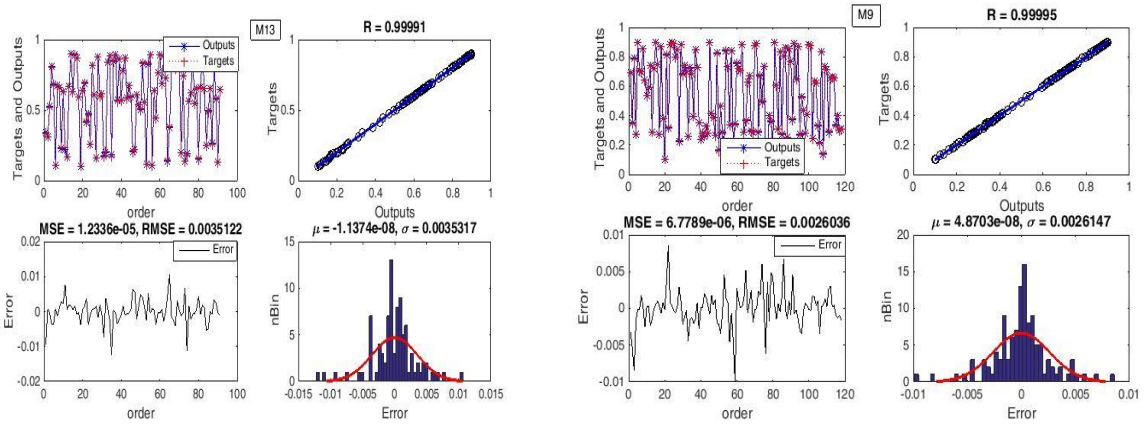
همچنین شکل ۱۵، نحوه همگرایی الگوریتم سنجاقک در تمام صفحات به سمت پاسخ بهینه را نشان می‌دهد. به طور کلی، حتی در غیاب داده‌های نشست مشاهده‌شده در زمان ساخت سدهای خاکی، می‌توان با آموزش مدل ANN با استفاده از داده‌های ورودی پیشنهادی، برآورد و تخمین قابل‌اعتمادی را به دست آورد. نتایج به دست آمده با توجه به 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.

Archive of SID.ir

Archive of SID.ir



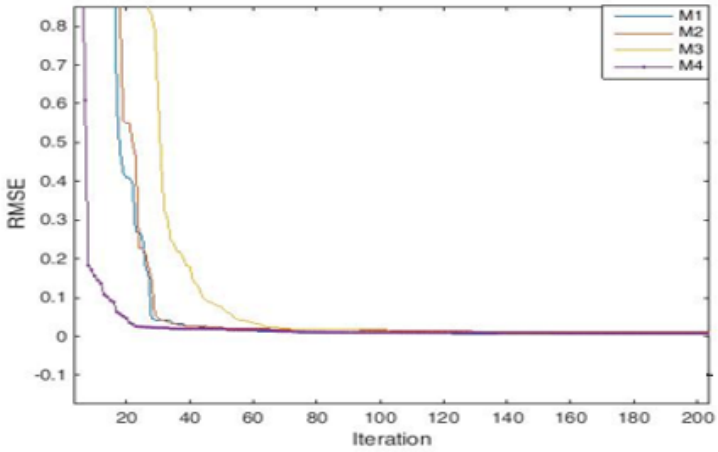
شکل ۱۳- مقادیر نشست محاسباتی و مشاهده‌شده در دوره آزمون در صفحات M1 و M5.



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

جدول ۳- پارامترهای کنترلی بهینه الگوریتم سنجاقک.

تعداد تکرار	تعداد جمعیت سنجاقک	کران پایین و بالا	تعداد ترکیب
۱۰۰۰	۱۰۰	LB=0; UB=1	۱ تا ۵



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

نتیجه‌گیری کلی

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

Archive of SID.ir

Archive of SID.ir

خاک ریزی به عنوان ورودی مدل هیبریدی DA-ANN برای مدل‌سازی نشست سد خاکی کبودوال 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 نصب‌شده‌اند 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 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 استفاده‌شده 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.

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 anneling 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 Sheidaeian M, 2014. Evaluting of Kaboodval dam during construction using finite clement 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 Sheydaeian, 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.

Archive of SID.ir

Archive of SID.ir

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.

Archive of SID.ir