

Estimation of Water Level Changes Using Image Processing and Artificial Bee Colony Algorithm

Rasoul Jani^{1,2*}

1-Department of Civil Engineering, Ta.C, Islamic Azad University, Tabriz, Iran.

2-Robotics and Soft Technologies Research Center, Ta.C, Islamic Azad University, Tabriz, Iran.

Received: 07 April 2026

Accepted: 17 June 2026

Revised: 12 May 2026

Published online: 21 June 2026

*Corresponding Author's Email: jani1358@iau.ac.ir

ARTICLE INFO

ABSTRACT

Keywords:

Flood,
Image processing,
Metaheuristic models,
Smartphone camera,
Support vector machine (SVM),
Water level estimation

Estimating water level is essential for managing water resources and reducing flood effects. However, direct measurement is often costly and time-consuming, and in many cases impractical. This study aimed to use a standard smartphone camera to evaluate the effectiveness of an image-based water level detection system, adding new insights to the field. To this end, we compared a standard support vector machine (SVM) with three hybrid SVM models incorporating invasive weed optimization (IWO), the artificial bee colony algorithm (ABC), and the cultural algorithm (CA). The results showed that the SVM-ABC hybrid outperformed the others, achieving the highest accuracy and lowest error (RMSE=5.49 mm, MAE=4.29 mm). These findings indicate that metaheuristic models can increase computational speed and reduce estimation errors, especially in hard-to-reach areas where high-precision measurements are difficult to obtain.

Introduction

Given the importance of continuous water level monitoring in rivers and irrigation canals for preventing critical events such as floods and erosion, developing a system that addresses the shortcomings of manual measurement while providing robust detection and measurement capabilities is essential.

Ashori et al. (2021) applied deep neural network-based image processing to measure copper in drinking water. Their system, implemented in python using Py Torch and open CV, used 70% of the data for training, 15% for validation, and 15% for testing, achieving 97% accuracy in detecting heavy metal contamination. Akhoni pourhosseini et al. (2023) examined water quality in Iran's Babolrood River. They employed several SVM-based hybrid models, incorporating cultural optimization, the harmony search algorithm, and teaching-learning to predict TDS. The monthly dataset (1968-2016) included Ca, Mg, Na, HCO₃, SO₄, Cl, pH, and TDS. Statistical index analysis revealed that the SVM model outperformed the others in predicting the water quality in the basin.

The objective of this study is twofold: first, to employ a conventional smartphone camera for evaluating the performance of an image-based water level detection system, and second, to expand the current knowledge in this domain. The main emphasis is placed on utilizing the capabilities of multiple machine learning approaches, including support vector machine (SVM), and invasive weed optimization, the honey bee colony algorithm, and the cultural algorithm, to enable precise water surface estimation through processing and analysis.

How to cite:

Jani, R. Estimation of Water Level Changes Using Image Processing and Artificial Bee Colony Algorithm. Journal of Hydraulics and Water Science, 36 (1):11-24. <https://doi.org/10.22034/hws.2026.71880.1052>



This is an open-access article under the CC BY NC license
(<https://creativecommons.org/licenses/by-nc/4.0/>)



Materials and Methods

The first step involves images visualization. Converting graphic images into digital images is one of the fundamental processes in image processing. This process is a key aspect of digital image processing, where graphical data are converted into a digital format to extract useful information or enhance image quality. In this research, measurements and observations were conducted in the hydraulic laboratory at the Department of Hydraulic Engineering, University of Tabriz. A total of 244 images were used to model and estimate the water surface under two conditions: clear and opaque water (with sediment). Among these, 201 images were used for training and 43 for testing. The methods employed for simulation include the support vector machine (SVM) and metaheuristic algorithms. The proposed method is based on statistical learning theory, which follows the principle of structural risk minimization. Artificial bee colony (ABC) is an optimization method inspired by the social behavior of honey bees, where bees collectively search for optimal food resources within the search space. Cultural algorithms are, on the other hand, evolutionary algorithms that, in addition to maintaining a population space based on Darwinian evolution, also possess a belief space. This belief space represents knowledge and experience collected from the best members of population and acts as a reference to guide the evolution process. The invasive weed optimization (IWO) method was introduced by Mehrabiyan and Lucas (2007) as a nature-inspired algorithm. This algorithm is highly effective at finding optimal locations and is based on the natural colonization characteristics of weeds in a colony. After analyzing the data using different methods and models, it is necessary to evaluate their performance. In this research, the most widely criteria in water engineering were applied, including the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE).

Results and Discussion

After removing outliers, the data were converted to normal distribution to enhance modeling accuracy. Then, using metaheuristic methods, the support vector machine (SVM) was simulated with invasive weed optimization algorithm, the artificial bee colony, and the cultural algorithm. The results show that the SVM-ABC metaheuristic model delivers the best performance based on the evaluation metrics. According to the criteria measured used in this study, the SVM-ABC model was able to simulate water levels more satisfactorily than the other models. In the validation phase, a coefficient of determination (R^2) of 0.999, a root mean square error (RMSE) of 5.49 mm, and a mean absolute error (MAE) of 4.29 mm were achieved, which is considered acceptable.

Conclusion

Given the importance of automatic and continuous control of water level for planning, decision making, and management of critical situations such as flood and river flooding, this study aimed to identify water levels in images through image processing and simulation by using image processing and simulation. To achieve this, we employed support vector machine (SVM) combined with three metaheuristic algorithms: SVM - IWO, SVM - CA, and SVM - ABC. In the modeling phase, the SVM-ABC model achieved excellent performance during validation, with a coefficient of determination (R^2) of 0.999, a root mean square error (RMSE) of 5.49 mm, and a mean absolute error (MAE) of 4.29 mm. Our proposed method is based on this integrated approach. Furthermore, the results indicate that metaheuristic models can be effectively used for water level estimation when compared with LS - SVM and BNN models.

Keywords: Flood, Image processing, Metaheuristic models, Smartphone camera, Support vector machine (SVM), Water level estimation



تخمین تغییرات سطح آب با استفاده از پردازش تصویر و مدل فراابتکاری کلونی زنبور عسل

رسول جانی^{*۱,۲}

تاریخ دریافت: ۱۴۰۵/۰۱/۱۸ تاریخ پذیرش: ۱۴۰۵/۰۳/۲۷
تاریخ ویرایش: ۱۴۰۵/۰۲/۲۲ تاریخ انتشار آنلاین: ۱۴۰۵/۰۳/۳۱
۱- دانشیار گروه مهندسی عمران، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران.
۲- مرکز تحقیقات رباتیک و فناوری های نرم، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران
✉ نویسنده مسئول: Jani1358@iaui.ac.ir

چکیده

برای تعیین وضعیت مدیریت منابع آب، تخمین سطح آب ضروری می باشد. تعیین سطح آب جهت کاهش اثرات سیلاب حائز اهمیت می باشد. با توجه به اینکه تعیین سطح آب هزینه زیادی دارد و وقت گیر می باشد، در بسیاری از موارد مانع اندازه گیری آن می شود. هدف این تحقیق، استفاده از یک دوربین گوشی هوشمند معمولی و ارزیابی اثربخشی یک سیستم تشخیص سطح آب مبتنی بر تصویر و افزودن دانش در مورد این موضوع است. در این مطالعه، از قابلیت های مدل های مختلف یادگیری ماشین، مدل ماشین بردار پشتیبان و سه مدل فراابتکاری شامل علف های هرز مهاجم، الگوریتم بهینه سازی کلونی زنبور عسل، الگوریتم فرهنگی که از کاربردی ترین الگوریتم ها در مدل سازی می باشد، استفاده شد. نتایج مدل سازی هوشمند نشان داد که بهترین نتایج تخمین سطح آب، مربوط به مدل کلونی زنبور عسل SVM-ABC با دقت بیشتر و خطای کمتر ($RMSE=5.49$ mm و $MAE=4.29$ mm) می باشد. این نتایج نشان می دهد مدل های فراابتکاری باعث افزایش سرعت در محاسبات و کاهش میزان خطا در تخمین سطح آب در مناطقی که صعب العبور و دشوار به درستی و با دقت بالا اندازه گیری را انجام دهند.

کلمات کلیدی: پردازش تصویر، تخمین سطح آب، دوربین گوشی هوشمند، سیلاب، ماشین بردار پشتیبان، مدل های فراابتکاری

۱- مقدمه

با توجه به اهمیت کنترل مستمر تراز سطح آب در رودخانه‌ها و کانال‌های آبیاری و جلوگیری از هرگونه وقایع بحرانی مانند سیل و فرسایش، ضروری است سیستمی ایجاد گردد تا محدودیت‌های اندازه‌گیری دستی را برطرف نموده و از قابلیت بالایی در جهت تشخیص و اندازه‌گیری برخوردار باشد (Abdi et al., 2024). بهترین مدیریت منابع آبی منطقه در گرو اندازه‌گیری مستمر پارامترهای سطح آب است که کاری زمان‌بر و پرهزینه می‌باشد (Abdi et al., 2025). سطح آب در کانال‌های کشاورزی نقش مهمی در تضمین توزیع کارآمد و مؤثر آب به محصولات دارد. توانایی آبیاری محصولات به‌طور مستقیم تحت تأثیر سطح آب در کانال‌ها است (Meijer et al., 2006). HassanNeghad et al. (2017) با توجه به اهمیت ضریب زبری در مطالعات مهندسی رودخانه، ۷/۵ کیلومتر از رودخانه شلمان گیلان را به روش دانه‌بندی با الک با استفاده از رابطه چاون^۱ و پردازش تصویر با مدل هیدرولیکی Hec-Ras برای محاسبه ضریب زبری مورد بررسی قرار دادند. همچنین از دو دوربین با کیفیت‌های ۱۰ و ۱۶ مگاپیکسلی نیز استفاده کردند که دوربین ۱۶ مگاپیکسلی عملکرد بهتری نسبت به دوربین ۱۰ مگاپیکسلی داشت و از طرفی پردازش تصویر در برآورد ضریب زبری، دقت بالا و هزینه کمتری را در مقایسه با دیگر روش‌ها نشان داد. (Ashori & Pourreza, 2023) جهت اندازه‌گیری میزان فلز سنگین مس موجود در آب شرب از پردازش تصویر مبنی بر شبکه عصبی عمیق که در سه گام پیش‌پردازش، استخراج ویژگی و طبقه‌بندی صورت گرفت، استفاده کردند. همچنین ۷۰ درصد داده‌ها در فاز آموزش، ۱۵ درصد فاز اعتبارسنجی و ۱۵ درصد فاز آزمون سیستم پیشنهادی را با نرم‌افزار پایتون و کتابخانه‌های Py Torch و Open Cv مدل‌سازی کردند. برای انجام این آزمایش از ماهی‌های زبرا فیش به علت شباهت بسیار زیاد به انسان از نظر ساختار زیست‌شناسی بهره بردند. نتایج، صحت بالای ۹۷ درصد را برای تشخیص آلودگی فلز سنگین مس موجود در آب شرب را نشان داد.

(Nikoufar & Nourani, 2024) در این پژوهش، عملکرد الگوریتم ژنتیک (GA)، الگوریتم ازدحام ذرات (PSO) و الگوریتم ترکیبی GA-PSO در بهره‌برداری بهینه از مخزن سد علویان با روش برنامه‌ریزی غیرخطی مقایسه شد. نتایج نشان داد که الگوریتم ترکیبی با دستیابی به بهترین مقدار تابع هدف (۰/۶۲) و تأمین حدود ۸۵ درصد نیاز آبی کشاورزی پایین‌دست سد، عملکرد بهتری نسبت به سایر روش‌ها داشته است. بر این اساس، الگوریتم ترکیبی به‌عنوان کارآمدترین روش برای تعیین پارامترها و سیاست بهره‌برداری بهینه از مخزن سد علویان معرفی شد.

(Akhoni Pourhosseini et al. (2023) برای شبیه‌سازی کیفیت

آب رودخانه بابلرود و سفیدرود از روش‌های هوش مصنوعی استفاده کردند. در این مطالعه از سه مدل فراابتکاری علف‌های هرز مهاجم، کلونی زنبور عسل و ازدحام ذرات و مدل ماشین بردار پشتیبان استفاده شد. نتایج نشان داد کلونی زنبور عسل در هر دو رودخانه با دقت بیشتر و خطای کمتر شبیه‌سازی کیفی آب رودخانه را انجام داده است. Abdi et al. (2024) جهت تخمین سطح آب از یادگیری عمیق (DL) و شبکه‌های عصبی کانولوشن (CNN) استفاده کردند. نتایج نشان داد عملکرد مدل CNN نسبت به DL بیشتر و میزان خطای کمتری را دارد.

(Abdi et al. (2025) برای تخمین سطح آب، از رویکرد جدیدی از تلفیق پردازش تصویر و یادگیری ماشین استفاده کردند. در این تحقیق، از دو مدل شبکه عصبی مصنوعی و یادگیری عمیق (DL) استفاده شد. نتایج این مدل‌ها نشان داد مدل یادگیری عمیق، نتایج قابل قبول ارائه داده است. با توجه به شاخص‌های ارزیابی، مدل یادگیری عمیق میزان خطای کمتری نسبت به سایر مدل‌ها داشته و به عنوان بهترین مدل انتخاب گردید.

(Kharade et al. (2017) از یادگیری ماشین برای تجزیه و تحلیل تصاویر در MATLAB برای تعیین سطح آب در محازن کانال‌ها استفاده کردند. (Muhadi et al. (2020) بر روی رودخانه‌ای در منطقه سیل‌خیز سالنگور^۲ مالزی در دو حالت عادی و سرریز تصویربرداری انجام دادند و تصاویر گرفته شده را به سه منطقه آستانه، منطقه درحال رشد و منطقه ترکیبی تقسیم‌بندی کرده و در متلب مورد بررسی قرار دادند که ضریب تشابه تاس^۳ ۹۷/۷۷ درصد و شاخص ژاکارد^۴ ۹۵/۵ درصد به‌دست آمد که نشان‌دهنده دقت بالای مدل ارائه شده می‌باشد. (Kwon et al. (2023) به منظور پایش دقیق و مدیریت بهتر سطح آب مخزن کشاورزی از دوربین‌های مدار بسته استفاده کردند. هدف آنها در این مطالعه ارائه رویکردی جدید مبتنی بر یادگیری عمیق و پردازش تصویر بود. سه بخش اصلی این رویکرد شامل (۱) ساخت مجموعه داده، (۲) تقسیم‌بندی تصاویر با استفاده از الگوریتم U-Net و (۳) تشخیص سطح آب مبنی بر دوربین مدار بسته با استفاده از شبکه عصبی کانولوشن و ResNet بود. همچنین نتایج به‌دست آمده نشان داد که روش پیشنهادی با دقت ۸۰ درصد قابل قبول بوده و در اندازه‌گیری‌ها می‌تواند مفید باشد.

(Vandaele et al. (2023) با ایجاد رویکردی خودکار برای تشخیص شاخص‌های سطح آب، از تصاویر رودخانه‌های بریتانیا و ایرلند به منظور پایش سیل استفاده کردند. سپس با پردازش ۳۲۷۱۵ تصویر که از ۹۵ دوربین در نقاط مختلف ثبت شده بود و ایجاد مدل شبکه عصبی کانولوشن، سطح آب را به‌طور پیوسته تعیین و وقوع سیل را مورد ارزیابی قرار دادند. (Akhoni Pourhosseini et al. (2022) به بررسی کیفیت آب رودخانه بابلرود در ایران پرداختند. در این مطالعه،

³ Dice coefficient

⁴ Jaccard index

¹ Cawn

² Selangor

می‌شود. سیستم تأمین آب شامل سه عدد مخزن زمینی به حجم تقریبی ۷ متر مکعب بوده که مجهز به دو دستگاه پمپ گریز از مرکز با مجموع ظرفیت تقریبی ۶۰ لیتر بر ثانیه با توان ۱۰۰ اسب بخار بوده و آب را به یک مخزن هوایی پمپاژ می‌نمایند و این مخزن به ارتفاع حدود ۲/۵ متر در ابتدای فلوم واقع شده است. شکل ۱ محل تصویربرداری، ابعاد کانال و تنظیمات آزمایشگاهی را نشان می‌دهد.

جدول ۱- ویژگی‌های آماری داده‌های مشاهداتی و محاسباتی

Table 1. Statistical features of observed and computational datasets

داده های مشاهداتی		
Observed data		
ویژگی‌های آماری	آموزش	آزمون
Statistical properties	Train	Test
میانگین	251.92	300.44
Average		
حداقل	0	0
Min		
حداکثر	472	475
Max		
انحراف معیار	143.98	146.84
SD		
مجموع	50636	12919
Sum		
تعداد	201	43
Number		

چند مدل ترکیبی با استفاده از ماشین بردار پشتیبان شامل الگوریتم بهینه‌سازی فرهنگی (SVM-CA¹)، الگوریتم هامونی (SVM-HS²) و الگوریتم مبتنی بر آموزش و یادگیری (SVM-TLBO³) برای پیش‌بینی TDS در رودخانه بابلرود استفاده گردید. داده‌های ماهانه اندازه‌گیری‌شده و منتشرنشده شامل Ca ، Mg ، HCO_3 ، Na ، SO_4 ، Cl ، pH و TDS از سال‌های ۱۹۶۸ تا ۲۰۱۶ می‌باشد. بر اساس آنتروپی شانن، مؤثرترین ورودی‌ها در پنج سناریو شناسایی شدند. نتایج با استفاده از چند شاخص آماری از جمله میانگین قدرمطلق خطا، عدم قطعیت در سطح اطمینان ۹۵ درصد، ریشه میانگین مربعات خطا و نمودار تیلور تحلیل شدند. مدل SVM-TLBO نسبت به سایر مدل‌های مورد استفاده، بهترین نتایج را برای پیش‌بینی کیفیت آب در حوضه مورد نظر ارائه نمود.

هدف اصلی تحقیق حاضر، استفاده از یک دوربین گواشی هوشمند معمولی و ارزیابی اثربخشی یک سیستم تشخیص سطح آب مبتنی بر تصویر و افزودن دانش در مورد این موضوع است. تمرکز اصلی در این تحقیق، استفاده از قابلیت‌های مدل‌های مختلف یادگیری ماشین، مدل ماشین بردار پشتیبان و مدل‌های هیبردی علف‌های هرز مهاجم (IWO⁴)، الگوریتم بهینه‌سازی کلونی زنبور عسل (ABC⁵)، الگوریتم فرهنگی (CA) برای تخمین دقیق سطح آب از طریق پردازش و تحلیل تصویر می‌باشد. علت انتخاب این مدل‌ها، به روز رسانی مطلوب مدل‌ها، افزایش دقت و کاهش خطا در نتایج مدل‌های هیبردی به کار برده شده، استفاده کاربردی و نتایج مطلوب مدل‌های هیبردی در زمینه مهندسی آب می‌باشد. این تحقیق مبتنی بر گرفتن تصاویر از سطوح مختلف آب، تعیین مرز آب بر روی یک اشل اندازه‌گیری و استفاده از این مدل‌ها برای محاسبه سطح تراز آب است و ارائه یک تحلیل مقایسه‌ای از عملکرد این مدل‌ها می‌باشد.

۲- مواد و روش‌ها

مرحله اول شامل پیش‌پردازش تصاویر می‌باشد. عملیات تبدیل تصاویر گرافیکی به عکس یکی از فرآیندهای پردازش تصویر است. این فرآیند یک جنبه اساسی از پردازش تصویر دیجیتال است که در آن داده‌های گرافیکی به شکل دیجیتال تبدیل می‌شوند و برای استخراج اطلاعات مفید یا افزایش کیفیت تصویر به کار می‌رود. ویژگی‌های آماری داده‌های استفاده شده در جدول ۱ ارائه شده است.

در این تحقیق، اندازه‌گیری‌ها و مشاهدات در آزمایشگاه هیدرولیک گروه مهندسی آب دانشگاه تبریز مورد بررسی قرار گرفت. فلوم آزمایشگاهی مورد نظر، دارای مقطع مستطیلی به عرض ۰/۵۱، طول ۱۰ و ارتفاع دیواره‌های ۰/۵ متر می‌باشد. کف کانال فلزی بوده و در تمام مدت آزمایش افقی (شیب ناچیز در حدود ۰/۰۰۰۵) فرض



شکل ۱- تجهیزات آزمایشگاهی و ابعاد فلوم در آزمایشگاه هیدرولیک دانشگاه تبریز

Fig 1. Experimental equipment and dimensions of the flume in the hydraulic laboratory of tabriz university

در این تحقیق، جهت سهولت و انعطاف‌پذیری هر چه بیشتر، از دوربین تلفن همراه هوشمند استفاده گردید. تلفن همراه جهت ثبت تصاویر طوری به بدنه کانال متصل شد که تصاویر گرفته شده شامل سطح آب و خطکش اندازه‌گیری می‌باشد. این تلفن هوشمند دارای

⁴Invasive Weed Optimization Algorithm

⁵ Artificial Bee Colony

¹ Cultural algorithm

² Harmony search algorithm

³ Teaching-learning based optimization algorithm

متوسط	60	12
Meduim		
پایین	81	12
Low		
کل	201	43
Total		

۱-۲- مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM)

اساس روش ماشین بردار پشتیبان بر پایه تئوری یادگیری آماری ارائه شده است که از حداقل سازی ریسک ساختاری پیروی می کند. Sanchez et al. (2011) روش حداقل مربعات ماشین بردار پشتیبان را ارائه دادند. این مدل برخلاف مدل SVM به جای مسئله برنامه نویسی درجه دوم در حل از معادلات خطی استفاده می کند. بنابراین، دقت محاسباتی بیشتری نسبت به ماشین بردار پشتیبان کلاسیک دارد. مدل رگرسیون LS-SVM از رابطه زیر پیروی می کند:

$$y(x_i) = w^T \cdot \varphi(x_i) + b \quad (1)$$

که در آن، w و b به ترتیب مقادیر وزن ها و اربابی تابع رگرسیون هستند که از طریق حداقل سازی تابع هدف در رابطه (۲) تعیین می شود:

$$\min_{w, e, b} J(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (2)$$

با محدودیت رابطه (۳):

$$\gamma_i = w^T \cdot \varphi(x_i) + b + x_i \quad (3)$$


که در آن، γ پارامتر تنظیم کننده بخش خطا و e_i خطای داده های آموزشی می باشد.

۲-۲- الگوریتم بهینه سازی کلونی زنبور عسل (ABC)

الگوریتم کلونی زنبور عسل مصنوعی یک روش بهینه سازی الهام گرفته از رفتار اجتماعی زنبورهای عسل است که در آن زنبورها به صورت جمعی به دنبال منابع غذایی بهینه در فضای جستجو می گردند. هر منبع غذایی در این الگوریتم نمادی از یک جواب ممکن برای مسئله بهینه سازی است و تعداد منابع اولیه معمولاً برابر با تعداد زنبورهای موجود در کلونی تعیین می شود. در فرآیند شبیه سازی، زنبورها با تبادل اطلاعات درباره کیفیت منابع غذایی، به تدریج به سمت بهترین راه حل ها هدایت می شوند و توانایی این الگوریتم در کاوش و بهره برداری همزمان از فضای جستجو، آن را به ابزاری مؤثر برای مسائل بهینه سازی پیچیده تبدیل کرده است. مراحل اجرای الگوریتم به شرح

دوربینی با کیفیت تصویربرداری ۵۰ مگاپیکسل موقعیتی ثابت داشته و میزان روشنایی آن در حالت متوسط قرار گرفت. همچنین میزان روشنایی آزمایشگاه طوری تنظیم شد که خط کش اندازه گیری و سطح آب قابل رؤیت باشد (میزان روشنایی نرمال).

شکل ۲ نمونه ای از تصاویر ثبت شده را نشان می دهد. در این مطالعه، به طور کلی از ۲۴۴ تصویر در دو حالت آب صاف و کدر به عنوان ورودی مدل (دارای رسوب) و تخمین سطح آب استفاده شد، که ۲۰۱ تصویر مربوط به آموزش و ۴۳ تصویر مربوط به آزمون می باشد، و خروجی مدل ها سطح تراز آب در کانال می باشد.



(الف)



(ب)

شکل ۲ - نمونه تصاویر گرفته شده به وسیله دوربین تلفن همراه هوشمند در دو حالت: (الف) آب گل آلود و (ب) آب صاف

Fig 2. Sample taken by smart mobile phone camera in two cases: (a) muddy water and (b) clear water

جدول ۲ - تقسیم بندی تعداد تصاویر برای سطوح مختلف
Table 2. Partitioning the number of images for different levels

سطح	آموزش (تصویر)	آزمون (تصویر)
Level	Train	Test
پایین	60	19
High		

زیر می‌باشد:

۱. تعیین اولیه منابع غذا (Karaboga, 2005)

$$x_{ij} = x_j^{\min} + rand(0.1)(x_j^{\max} - x_j^{\min}) \quad (4)$$

به‌طوری که $i=1,2,3,\dots,SN$ ، $j=1,2,3,\dots,D$ ، SN تعداد منابع غذایی، $x_j^{\min}$ و $x_j^{\max}$ به ترتیب حداکثر و حداقل مقدار پارامتر j می‌باشد.

۲. حرکت زنبورهای کارگر به سمت منابع غذا و تعیین منابع غذایی مجاور

$$V_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (5)$$

که در آن، j و k به ترتیب پارامترهای منتخب تصادفی و همسایگان تصادفی، ϕ_{ij} یک عدد تصادفی بین ۱ و -۱ می‌باشد.

۳. تعیین یک منبع غذایی جدید به نام V_i و حذف x_i در صورتی که مقدار شهد منبع جدید (V_i) بهتر از منبع قبل (x_i) باشد.

۴. حرکت زنبورهای جستجو به سمت منابع غذا تعیین همسایه‌های جدید طبق مراحل ۲ و ۳:

$$p_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad fitness_i$$

$$= \begin{cases} \frac{1}{1 + fit_i} & fit \geq 0 \\ 1 + abs(fit_i) & fit < 0 \end{cases} \quad (6)$$

به‌طوری که fit_i هزینه برای منبع غذا، $fitness_i$ مقدار شهد منبع غذا x_i می‌باشد.

۵. مراحل ۲ تا ۴ تا زمانی که مقدار بهینه یافت شود، تکرار می‌شود.

۲-۳- ساختار الگوریتم فرهنگی (CA)

الگوریتم‌های فرهنگی توسعه‌ای از الگوریتم‌های ژنتیک هستند که علاوه بر فضای جمعیت مبتنی بر تکامل داروینی، دارای یک فضای باور نیز می‌باشند. این فضای باور، نمایانگر دانش و تجربیات جمع‌آوری شده از بهترین اعضای جامعه است و به عنوان یک مرجع برای هدایت فرآیند تکامل عمل می‌کند. در این الگوریتم، گروهی از افراد نخبه بر اساس عملکردشان انتخاب شده و دانش آن‌ها در فضای باور ثبت می‌شود؛ سپس این دانش بر روی تولید نسل‌های بعدی جمعیت اثر گذاشته و

جستجو را به سمت نواحی با کیفیت‌تر و امیدوارکننده‌تر هدایت می‌کند. اضافه شدن حوزه دانش موجب افزایش کارایی الگوریتم‌های تکاملی، کاهش احتمال گرفتار شدن در کمینه‌های محلی و هوشمندسازی روند جستجو می‌شود. این الگوریتم دارای دانش‌های مختلفی در فضای باور خویش است که به امر جستجو کمک می‌کند. اجزای الگوریتم فرهنگی شامل فضای جمعیت^۱، فضای باور^۲، تابع پذیرش^۳ و تابع تاثیر^۴ می‌باشد (Akhoni Pourhosseini et al., 2023).

الف) فضای جمعیت

فضای اصلی با مقدار دهی اولیه کار خود را شروع کرده و استخراج فرهنگ و ذخیره آن در فضای باور در این قسمت انجام می‌گیرد. مولفه جمعیت یک الگوریتم فرهنگی تقریباً مشابه همین مولفه در الگوریتم ژنتیک است.

ب) فضای باور

فضای باور یک الگوریتم فرهنگی به بخش‌های مختلف تقسیم‌بندی می‌شود. این بخش‌ها نماینده حوضه‌های مختلف دانشی هستند که جمعیت از فضای جستجو دارد. در فضای باور، تجربیات عمومی شده افراد موفق از فضای جمعیتی، به‌دست آمده و این تجارب در سراسر نسل و نسل‌های بعدی شکل گرفته و ذخیره می‌شود. در اینجا دانش موقعیتی بهترین دوره سراسری است و طبق رابطه زیر فضای فرهنگ به روز می‌شود:

$$y(t+1) = \begin{cases} \min f(x_i(t)) & \min f(x_i(t)) \leq f(y(t)) \\ x_i(t) & x_i(t) \\ y(t) & otherwise \end{cases} \quad (7)$$

این دانش طبق رابطه زیر اعمال می‌شود. در اینجا n معرف تعداد ابعاد مسئله است و هر X به صورت زیر تعریف می‌شود:

$$N = \{x_1, x_2, x_3, \dots, x_n\}$$

$$x_i = [l_i \ u_i \ L_i \ U_i] \quad (8)$$

که در آن، u_i و l_i به ترتیب حد پایین و حد بالا بعد i ام می‌باشند، و L_i مقدار تابع شایستگی در آن حدود می‌باشند. طبق این دانش فضای جستجو رفته رفته کوچکتر و به ناحیه‌های خوب نزدیکتر می‌شود. دانش معیار طبق روابط زیر به‌روز می‌شود (Reynolds, 1994):

³ Acceptance

⁴ Influence function

¹ Population Space

² Belief spaces

$$\begin{aligned}
 x_{min,j}(t+1) &= \begin{cases} (x_{lj}(t)) & \text{if } x_{lj}(t) \leq (x_{min,j}(t) \text{ or } f(x_l(t)) < L_j(t)) \\ (x_{min,j}(t)) & , \text{ otherwise} \end{cases} \\
 x_{max,j}(t+1) &= \begin{cases} (x_{lj}(t)) & \text{if } x_{lj}(t) \leq (x_{max,j}(t) \text{ or } f(x_l(t)) < U_j(t)) \\ (x_{max,j}(t)) & , \text{ otherwise} \end{cases} \\
 L_j(t+1) &= \begin{cases} f(x_l(t)) & \text{if } x_{lj}(t) \leq x_{min,j}(t) \text{ or } f(x_l(t)) < L_j(t) \\ L_j(t) & , \text{ otherwise} \end{cases} \\
 U_j(t+1) &= \begin{cases} f(x_{lj}(t)) & \text{if } x_{lj}(t) \geq x_{max,j}(t) \text{ or } f(x_l(t)) < U_j(t) \\ U_j(t) & , \text{ otherwise} \end{cases}
 \end{aligned}$$

(۹)

پ) تابع پذیرش

ت) تابع تأثیر^۱

در بیشتر موارد در فضای باور، از مؤلفه وضعی برای تعیین جهت حرکت و مؤلفه هنجاری برای تعیین میزان حرکت برای تغییر پاسخها طبق رابطه زیر استفاده می‌شود:


$$\begin{aligned}
 x_{ij} &= \begin{cases} x_{ij}(t) + \sigma_{ij}|N(0,1)| & x_{ij}(t) < y_{ij}(t) \\ x_{ij}(t) - \sigma_{ij}|N(0,1)| & x_{ij}(t) > y_{ij}(t) \\ x_{ij}(t) + \sigma_{ij}N(0,1) & \text{Otherwise} \end{cases} \\
 \sigma_{ij}(t) &= \alpha[x_j^{max}(t) - x_j^{min}(t)]
 \end{aligned}
 \quad (11)$$

از انواع تابع پذیرش استاتیک و دینامیک در این الگوریتم می‌توان استفاده کرد. در بیشتر مسائل، از تابع دینامیک به صورت زیر استفاده می‌شود. تعداد نفراتی که بر روی فرهنگ تأثیر می‌گذارند، در هر تکرار متغیر بوده و تعداد اعضای جمعیت از رابطه زیر به دست می‌آید:

(۱۰)

$$n = \left\lfloor \frac{n_s \times \gamma}{t} \right\rfloor$$

که در آن، n_s اندازه جمعیت و γ یک عدد تصادفی بین صفر و یک است و t شماره تکرار الگوریتم می‌باشد.



شکل ۳- ساختار مدل الگوریتم فرهنگی (jafari et al., 2019)

Fig 3. Structure of CA model (jafari et al., 2019)

۲-۴- الگوریتم بهینه‌سازی علف‌های هرز

مهاجم (IWO)

بر اساس ویژگی‌های اولیه و طبیعی علف‌های هرز در یک کلونی عمل می‌کند. مراحل انجام الگوریتم به شرح زیر معرفی می‌شود.

تعیین مقدار جمعیت اولیه: ابتدا یک جمعیت محدود اولیه در فضای حل مسئله به صورت تصادفی تولید و پراکنده می‌شود.

تولید مثل: در این روش بهینه‌سازی هر عضو از جمعیت با توجه به میزان توانایی‌هایشان دانه تولید می‌کنند. تعداد دانه‌هایی که هر گیاه

روش بهینه‌سازی علف‌های هرز مهاجم توسط Mehrabian & Lucas, (2007) با الهام گرفتن از طبیعت معرفی و مورد استفاده قرار گرفت. این الگوریتم در یافتن نقاط بهینه، بسیار مؤثر و سریع بوده و

¹ Influence Function

(MAE) استفاده گردید (روابط ۱۳ تا ۱۵). در این روابط، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد داده‌ها، $\bar{x}$ و $\bar{y}$ میانگین مقادیر مشاهداتی و محاسباتی دبی می‌باشند (Behar et al., 2015).

$$R^2 = \left[\frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \cdot \sum_{i=1}^N (y_i - \bar{y})^2}} \right]^2 \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (14)$$

$$MAE = \frac{1}{N} \left[\sum_{i=1}^N |y_i - x_i| \right] \quad (15)$$

۳- نتایج و بحث

در این مطالعه با پیاده سازی روش‌های مختلف پردازش تصویر که شامل تغییر ابعاد، برش، تغییر کانال رنگی از RGB^۱ به خاکستری و محاسبه میانگین‌های متحرک می‌باشد، سطح تراز آب در دو حالت آب صاف و آب کدر تعیین شد. همچنین این آزمایش در سه سطح تراز پایین، متوسط و بالا صورت گرفت.

با تعیین تراز سطح آب در تصویر، مقایسه اندازه‌گیری‌های انجام شده با مقادیر واقعی بهتر صورت گرفته و می‌توان به صحت روش اندازه‌گیری پی برد (Zhu, & Chang, 2020). شکل ۴ که نمونه تصاویر از تعیین سطح آب در حالت‌های مختلف آب و در ترازهای متفاوت را نشان می‌دهد، بیانگر عملکرد قابل قبول روش استفاده شده می‌باشد. با توجه به این شکل، می‌توان دریافت که روش به کار گرفته شده که بر پایه پردازش تصویر می‌باشد، ترازهای صفر را نیز شامل می‌شود و همچنین قابلیت تشخیص سطح آب را در حالات نوسانی که شبیه حالت رودخانه‌ای است را دارا می‌باشد.

بعد از حذف داده‌های پرت، جهت بالا رفتن دقت مدل‌سازی، داده‌ها به صورت نرمال تبدیل شد (Nourani, et al., 2025). سپس با استفاده از مدل‌های فراابتکاری ماشین بردار پشتیبان شامل علف‌های هرز مهاجم (IWO)، الگوریتم بهینه‌سازی کلونی زنبور عسل (ABC) و الگوریتم فرهنگی (CA) شبیه‌سازی شد. علت انتخاب این مدل‌ها، به روزرسانی مطلوب مدل‌ها، افزایش دقت و کاهش خطا در نتایج مدل‌های هیبردی به کار برده شده، استفاده کاربردی و نتایج مطلوب مدل‌های هیبردی در زمینه مهندسی آب می‌باشد. جدول ۳ توضیح پارامترهای استفاده شده در مدل‌های SVM-IWO، SVM-ABC و CA را نشان می‌دهد. مطابق جدول ۴ که معیارهای ارزیابی مرحله تست را برای سه مدل SVM-IWO، SVM-ABC و

می‌تواند تولید کند، به طور خطی کمترین تعداد دانه ممکن تا بیشترین تعداد تغییر می‌کند و علف هرز با سازگاری بهتر دانه بیشتر تولید می‌کند. رابطه تولید تعداد دانه به صورت زیر می‌باشد (Mehrabian & Lucas, 2007).

$$Seed_n = \frac{f - f_{min}}{f_{max} - f_{min}} (S_{max} - S_{min}) + S_{min} \quad (12)$$

که در آن، $Seed_n$ تعداد دانه‌های تولید شده، f سازگاری علف‌های هرز فعلی، f_{min} ، f_{max} به ترتیب کمترین و بیشترین سازگاری از جمعیت فعلی، و S_{min} ، S_{max} به ترتیب حداکثر و حداقل مقدار ممکن تولید دانه می‌باشد.

پراکندگی فضایی: در این مرحله دانه‌های تولید شده به صورت تصادفی در فضای چند بعدی مسئله پراکنده می‌شود. تابع توزیع تصادفی، تابعی نرمال بوده و تضمین می‌کند دانه‌ها که به صورت تصادفی تقسیم شده‌اند بسیار نزدیک به گیاه والدشان می‌باشد. ارتباط بین پارامترهای بالا و انحراف معیار را می‌توان به صورت رابطه (۱۳) بیان کرد (Mehrabian & Lucas, 2007):

$$\sigma_{iter} = \frac{(iter_{max} - iter)^n}{(iter_{max})^n} (\sigma_{initial} - \sigma_{final}) + \sigma_{final} \quad (13)$$

که در این رابطه، $iter_{max}$ بیشترین تعداد دفعات تکرار، σ_{iter} مقدار انحراف معیار در مرحله انجام عملیات و n شاخص غیرخطی بودن مدولاسیون یا شاخص نوسان غیرخطی می‌باشد.

حذف رقابتی: در الگوریتم‌های علف‌های هرز مهاجم بعد از چند مرحله تکرار، تعداد دانه‌های کلونی در اثر تولید مثل به بیشترین حد خود (P_{max}) می‌رسد و سپس مکانیزمی برای حذف دانه‌های ضعیف به کار گرفته می‌شود (Mehrabian & Lucas, 2007).

در این مطالعه، از مجموعه داده‌های متشکل از ۲۴۴ تصویر مشاهده‌ای که با استفاده از دوربین تلفن همراه گرفته شده بود استفاده شد. این تصاویر به دو مجموعه مجزا تقسیم شدند: ۸۰ درصد داده‌ها برای آموزش که شامل ۲۰۱ تصویر برای آموزش و ۲۰ درصد داده‌ها برای آزمون که شامل ۴۳ تصویر برای آزمون می‌باشد، انتخاب شد. این بخش برای بهینه‌سازی فرایندهای یادگیری و اعتبارسنجی مدل طراحی شده است.


۲-۵- معیارهای ارزیابی

پس از تحلیل داده‌ها با انواع روش‌ها و مدل‌ها لازم است عملکرد آن‌ها مورد ارزیابی قرار گیرد، در این تحقیق، از معیارهای ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا

¹ Red Green Blue

بهترین شبیه سازی را انجام داده است.

SVM-CA جهت تخمین سطح آب نشان می‌دهد، مدل فراابتکاری SVM-ABC با توجه به بررسی شاخص‌های ارزیابی،



شکل ۴- نمونه تصاویر از تعیین سطح آب در ترازها و حالت‌های مختلف آب

Fig 4. Sample images of water level determination in water level and different water conditions

در نظر گرفته شده است. این پارامتر در رگرسیون SVM (SVR) تعیین می‌کند که خطاهای کوچک تا چه حد بدون جریمه مجاز باشند. جدول ۴- ارزیابی مدل‌های فراابتکاری SVM-IWO، SVM-ABC و SVM-CA در بخش صحت‌سنجی

Table 4. Evaluation of SVM-ABC, SVM-CA and SVM-IWO models in the validation section

صحت‌سنجی Test			مدل Model
MAE(mm)	RMSE (mm)	R ²	
4.29	5.49	0.999	SVM-ABC
5.02	8.09	0.996	SVM-IWO
4.97	7.19	0.997	SVM-CA

با توجه به نتایج معیارهای ارزیابی، مدل SVM-ABC نسبت به سایر مدل‌ها توانسته است به شکل قابل قبولی شبیه‌سازی سطح آب را انجام دهد. در بخش صحت‌سنجی، مقادیر ضریب تبیین (R^2) ۰/۹۹، جذر میانگین مربعات خطا (RMSE) ۵/۴۹ میلی‌متر و میانگین قدر مطلق خطا (MAE) ۰/۲۹ میلی‌متر به دست آمد که مقادیر قابل قبولی می‌باشد. روند تغییرات داده‌های مشاهداتی و محاسبه‌شده و میزان پراکندگی خطاها حاصل از مدل‌های بهینه SVM-ABC، SVM-IWO و SVM-CA به ترتیب در شکل‌های ۵ تا ۷ نشان داده شده است.

جدول ۳- پارامترهای استفاده شده در مدل SVM-ABC و SVM-CA و IWO

Table 3. The parameters used in SVM-ABC, SVM-CA, SVM-IWO


تابع هسته Kernel Function	Polynomial	SVM-IWO
مقیاس هسته Kernel Scale	17.06	
Epsilon	2.14	
تابع هسته Kernel Function	RBF	SVM-CA
مقیاس هسته Kernel Scale	16.59	
Epsilon	25.43	
تابع هسته Kernel Function	RBF	SVM-ABC
مقیاس هسته Kernel Scale	0.59	
Epsilon	1.08	

تابع هسته^۱ در مدل SVM-ABC از نوع RBF می‌باشد. این تابع تعیین می‌کند داده‌ها به چه صورت به فضای با ابعاد بالاتر منتقل شوند تا جداسازی یا پیش‌بینی دقیق‌تر شود. مقیاس هسته^۲ مقدار در مدل SVM-ABC برابر با ۰/۵۹ انتخاب شده است. این پارامتر بر میزان تأثیر فاصله‌ها در تابع هسته مؤثر دارد و شکل مرز تصمیم‌گیری را تنظیم می‌کند. اپسیلون^۳ مقدار در مدل SVM-ABC برابر با ۱/۰۸


³ Epsilon

¹ Kernel Function

² Kernel Scale




(ب)




(الف)

شکل ۵- پیش‌بینی و دقت مدل SVM-ABC در بخش صحت‌سنجی سطح آب

Fig. Model and accuracy of the SVM-ABC model in the water level verification section




(ب)




(الف)

شکل ۶- الف و ب) پیش‌بینی و دقت مدل SVM-IWO در بخش صحت‌سنجی سطح آب

Fig 5. Model and accuracy of the SVM-IWO model in the water level verification section



(ب)



(الف)

شکل ۷- پیش‌بینی و دقت مدل SVM-CA در بخش صحت‌سنجی سطح آب


Fig 5. Model and accuracy of the SVM-CA model in the water level verification section

تصویر و شبیه‌سازی با استفاده از مدل‌های فراابتکاری ماشین بردار پشتیبان شامل مدل هیبریدی علف‌های هرز مهاجم (SVM-IWO) و الگوریتم بهینه‌سازی کلونی زنبور عسل (SVM-ABC) و الگوریتم فرهنگی (SVM-CA)، سطح آب روی تصاویر شناسایی شده و مقدار عددی تراز سطح آب در دو حالت آب صاف و کدر تخمین زده شود.

ترکیب روش‌های پردازش تصویر و شبیه‌سازی با مدل‌های فراابتکاری برای تعیین دقیق سطح آب بسیار مهم است. تحقیقات نشان داده است که استفاده از شبیه‌سازی با مدل‌های هوشمند و پردازش تصویر، به‌طور قابل توجهی دقت و کارایی نظارت بر سطح آب را افزایش می‌دهد. این رویکرد نه تنها دقت را بهبود می‌بخشد، بلکه نظارت مستمر را نیز تضمین می‌کند و آن را برای سناریوهای مختلف، از جمله محیط‌های پیچیده آبی مانند تنظیمات سمی یا آلوده، مناسب می‌کند.

در بخش مدل‌سازی، مطابق جدول ۴ مدل‌های به کار برده شده از نظر ضریب تبیین اختلاف چندانی با هم ندارد. با این حال، اختلاف میزان شاخص میانگین مربعات خطا در بین این مدل‌ها بیشتر بوده و مدل SVM-ABC در بخش صحت‌سنجی با دارا بودن ضریب تبیین ۰/۹۹۹، ریشه میانگین مربعات خطا ۵/۴۹ میلی‌متر و میانگین مطلق خطا ۴/۲۹ میلی‌متر، بهترین عملکرد را نسبت به میزان خطا، در مواجهه با سایر مدل‌ها ارائه نمود. مدل‌های SVM-IWO و SVM-CA در مرتبه‌های بعدی قرار گرفتند. همچنین می‌توان گفت مدل‌های فراابتکاری با توجه به کارایی مناسب در تخمین سطح آب نسبت به مدل‌های LS-SVM و BNN می‌توانند در اولویت قرار گیرند.

مطابق جدول ۴، با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد که هر سه مدل SVM-ABC، SVM-IWO و SVM-CA با دقت خوبی و خطای کمتر می‌توانند سطح آب را شبیه‌سازی کنند. با توجه به جدول ۴ مشاهده می‌شود که مدل SVM-ABC بیشترین دقت و کمترین ریشه میانگین مربعات خطا در مرحله صحت‌سنجی را دارا می‌باشد. در شکل ۸ نتایج مقادیر مشاهداتی و محاسباتی مقادیر بهینه مدل SVM-ABC بخش صحت‌سنجی ارائه شده است.



شکل ۸- مقایسه مقادیر مشاهداتی و پیش‌بینی شده مقادیر بهینه مدل SVM-ABC برای داده‌های صحت‌سنجی

Fig 8. Comparison between observed and predicted values of the optimal values of svm - abc model for verification data

۴- نتیجه‌گیری نهایی

با توجه به اهمیت کنترل خودکار و پیوسته تراز سطح آب به منظور برنامه‌ریزی، تصمیم‌گیری و مدیریت هرچه بهتر مواقع بحرانی نظیر سیل و طغیان رودخانه، در این تحقیق سعی گردید با روش پردازش

منابع

- Akhoni Pourhosseini, F., Ebrahimi, K., and Omid, M.H., 2022 . Evaluation of intelligent models in water quality simulation of the Babolrood and Sefidrood Rivers, Iran. Iranian Journal of Watershed Management Science and Engineering, 16(58), 53 – 62, doi.org/10.1001.1.20089554.1401.16.58.6.7 (In Persian)
- Akhoni Pourhosseini F, 2024. River water quality numerical modelling involving intelligent approaches, Tehran university. PhD Thesis (In Persian).
- Ashori A, and Pourreza h, 2023. Detection of heavy metal pollution in drinking water by deep learning based on deep learning, 12th national conference and 2nd international conference on machine vision and atm, Tehran,Iran. (In Persian).
- Abdi E, Jani R, and Darbandi S, 2024. Comparing the efficacy of deep learning Models and convolutional neural network for water Level estimation using smartphone, and image processing. Iran-Water Resources Research, 20(2), 61-73, doi.org/10.22034/iwrr.2024.445181.2744 (In Persian).
- Abdi E, Jani R, and Darbandi S, 2025. Dynamic modeling of water level changes using Image Processing and Machine Learning. Journal of Watershed Management Research, 16(1), 71-83, [doi:10.61882/jwmr.2024.1270](https://doi.org/10.61882/jwmr.2024.1270) (In Persian).
- Behar O, Khellaf A, and Mohammadi K, 2015. Comparison of solar radiation models and their validation under algerian climate–The case of direct irradiancance. Energy Conversion and Management, 98, 236–251, doi.org/10.1016/j.enconman.2015.03.067.
- HassanNeghad Sharifi F, Samadi A, and Azizayan Ghatar A, 2017. Evaluation of image processing technique in estimating the manning's roughness coefficient in the surface layer of riverbeds. Iran Water and Water Research Magazine, 74(7), 433-477, [DOI:10.22059/ijswr.2016.59978](https://doi.org/10.22059/ijswr.2016.59978) (In Persian).
- Jafari M, Salajegheh E, and Salajegheh J, 2019. An efficient hybrid of elephant herding optimization and cultural algorithm for optimal design of trusses. Engineering with Computers, 35(3), 781-801, [DOI.org/10.1007/s00366-018-0631-5](https://doi.org/10.1007/s00366-018-0631-5).
- Kwon SH, Ha C, and Lee S, 2023. A study on the application of the agricultural reservoir water level recognition model using CCTV image data. Journal of Korea Water Resources Association, 56(4), 245-259, [DOI.org/10.3741/JKWRA.2023.56.4.245](https://doi.org/10.3741/JKWRA.2023.56.4.245).
- Kharade, A., Gendle, M., Lodha, T., Jadhav, M. T. (2017). Water Level Measurement and Detection of Flow Direction Using Image Processing. International Journal of Innovations in Engineering Research and Technology (IJERT), Conference Proceedings of TECHNO-2K17, pp. 1–4 .
- Karaboga D, 2005. An idea based on honey bee swarm for numerical optimization, Technical Report-TR06, Department of Computer Engineering, Engineering Faculty. Erinyes University.
- Muhadi NA, Abdullah AF, Bejo SK, Mahadi MR, and Mijic A, 2020. Image segmentation methods for flood monitoring system. Water , 12(6), [DOI.org/10.3390/w12061825](https://doi.org/10.3390/w12061825).
- Mehrabian AR, and Lucas C, 2007. A novel numerical optimization algorithm inspired from weed colonization. Ecological Informatics, 1(4): 355–366, [DOI.org/10.1016/j.ecoinf.2006.07.003](https://doi.org/10.1016/j.ecoinf.2006.07.003).
- Meijer K, Boelee E, Augustijn D, and van der Molen I, 2006. Impacts of concrete lining of irrigation canals on availability of water for domestic use in southern Sri Lanka . Agricultural water management, 83(3), 243-251, [DOI.org/10.1016/j.agwat.2005.12.007](https://doi.org/10.1016/j.agwat.2005.12.007).
- Nourani, B. , Kamalinezhad, S. , Salmasi, F. , Roumianfar, S. and Ansari, M. (2025). Estimating the Uplift Pressure under Hydraulic Structures with Dual end Cutoff Walls with Finite Element, Regression and Intelligent Approaches. Hydraulics and Water Science, 35(4).[DOI:10.22034/hws.2026.70179](https://doi.org/10.22034/hws.2026.70179). 1038. (In Persian).
- Nikoufar, B. and Nourani, V. (2024). Determining the optimal operation parameters of Alavian dam using the combination of genetic and particle swarm algorithms. Hydraulics and Water Science, 34(4), 89-110. [doi:10.22034/hws.2024.18918](https://doi.org/10.22034/hws.2024.18918). (In Persian).
- Akhoni Pourhosseini F, Ebrahimi K, and Omid MH, 2023. Prediction of total dissolved solids based on optimization of new hybrid SVM models. Engineering Applications of Artificial Intelligence, 126, Part A,106780, [DOI.org/10.1016/j.engappai.2023.106780](https://doi.org/10.1016/j.engappai.2023.106780).
- Reynolds R, 1994. An introduction to cultural algorithms. In: Proceedings of the 3rd Annual on Evolutionary Programming. World Scientific, River Edge, pp. 131–139.
- Sánchez AS, Nieto PG, Fernández PR, del Coz Diaz JJ, and Iglesias-Rodr FJ, 2011. Application of an SVM-based regression model to the air quality study at local scale in the Avilés urban area (Spain). Mathematical and Computer Modelling, 54(5-6):1453-1466, [DOI.org/10.1016/j.mcm.2011.04.017](https://doi.org/10.1016/j.mcm.2011.04.017).
- Vandaele R, Dance SL, and Ojha V, 2023. Calibrated river-level estimation from river cameras using convolutional neural

-
- networks. Environmental Data Science, 2, e11, [DOI.org/10.1017/eds.2023.6](https://doi.org/10.1017/eds.2023.6).
- Zhu C, and Chang YZ, 2020. Stereo matching for infrared images using guided filtering weighted by exponential moving average. IET Image Processing, 14(5), 830-837, [DOI.org/10.1049/iet-ipr.2019.0144](https://doi.org/10.1049/iet-ipr.2019.0144).