Sari Agriculture Sciences and Natural Resources University

Journal of Watershed Management Research, Vol. 16, Issue 1, 2025 p: 71-83

OPEN ACCESS

Research Paper

# Dynamic Modeling of Water Level Changes Using Image Processing and Machine Learning

**Erfan Abdi[1], Rasool Jani[2], and Sabereh Darbandi[3]**

1- M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran
2- Assistant Professor, Department of Civil Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran, (Corresponding Author: Jani@iaut.ac.ir)
3- Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

Received: 30 May 2024 Revised: 10 September 2024 Accepted: 30 September 2024

## Extended Abstract

**Background:** Studying and monitoring the water level of rivers and canals by the Ministry of Energy and related organizations is an important part of water resources management in the catchment area. On the other hand, water level measurement is a vital task in hydrological monitoring, but it often faces limitations such as a lack of resources, high costs, and high time requirements. These limitations often lead to delays in measurements and potential inaccuracies, especially in remote or harsh environments. In general, most of the traditional methods have significant errors and costs and make continuous monitoring and control almost impossible. Recent advances in technology have led to a paradigm shift toward image-processing systems for water level monitoring. These non-contact methods have attracted attention due to their high potential in terms of accuracy, reliability, cost-effectiveness, and reduced time required. This research presents a new approach of combining image processing and machine learning in an attempt to reduce costs and increase performance to extract water level indicators and measure the water level instantly and automatically. This approach is based on creating a set of gauge images recorded by a smartphone (which is a common device with easy access) for clear and turbid water states to train machine learning-based models. Unlike the traditional methods with instantaneous and continuous measurement of the water level, this method makes water supply systems work better and manage critical situations such as floods, river overflows, and erosion.

**Methods:** This paper contributes to this growing research by evaluating an image-based water level detection system using a standard smartphone camera. In this research, the RGB image-processing algorithms include filtering, noise reduction, color detection, resizing, grayscale conversion, Hough detection and transformation, and projection to obtain digital characters and watermarks that only include the area of scale lines. Moreover, all the mentioned steps and modeling steps have been done in Mathematica software. The experimental data include 244 observation data, which were randomly considered to be 201 training data images, and 43 test data images, which were captured by a mobile phone camera with a fixed position. Considering the capabilities of various machine learning models, including artificial neural networks (ANNs) and deep learning (DL) in image processing and analysis, this study focused on these models for accurate water level estimation. Our study involves taking water level images, identifying the water edge in a gauge, and using these models to estimate the water level. Machine learning, a branch of artificial intelligence, aims to develop computer systems with the capacity to learn from data. This process involves computer learning through hands-on experience, starting with organizing data, choosing a machine learning algorithm, entering data, and enabling the model to independently learn patterns or generate predictions, and gain self-programming capability. In general, the comparative analysis of the performance of these models aims to show the potential of combining image processing and machine learning in overcoming the traditional obstacles of water level measurement in hydrological studies.

**Results:** The results of the model were evaluated using three evaluation criteria: coefficients of determination (R), root mean square error (RMSE), and Nash-Sutcliffe agreement coefficient (NSE), as well as visual charts. In this research, two ANNs and DL models, which are the subsets of machine learning models, were used to estimate the water level in muddy and clear conditions by image processing. The results showed that the DL model was acceptable in both conditions of performance. According to the evaluation indicators of the DL model with the lowest error of 28.39 mm and the highest R-value (0.973), it was chosen as the best model for water level estimation. Therefore, according to the performance of the DL model, it is possible to

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]

[ DOI: 10.61882/jwmr.2024.1270 ]

Copyright ©2025 Abdi et al. Published by Sari Agricultural Sciences and Natural Resources University.
This work is licensed under a Creative Commons Attribution-Non-Commercial 4.0 Unported License, which allows users to read, copy, distribute, and make derivative works for non-commercial purposes from the material, as long as the author of the original work is cited properly.

automatically and continuously examine the process of examining and monitoring the water level, in addition to laboratories, in hard-to-reach places and without high costs, and prevent possible accidents by making the right decisions.

**Conclusion:** Due to the problems of manual measurement and field monitoring, automatic and continuous monitoring of the water level by humans becomes difficult and even impossible. Despite these obstacles, researchers' interest in image processing systems has currently increased with the advancement of technology. According to the work done to detect and estimate the water level, most of the current methods go toward achieving maximum efficiency with the minimum facilities. Finally, two methods for extracting information from digital images for water level monitoring systems are compared here. Combined techniques for water level detection in clear and muddy images were compared based on visual evaluation and statistical accuracy. Based on the experimental results, these techniques and models were all able to extract water level information from the image. The image processing technique and DL model for detecting and estimating water surface features from images, which include two turbid and clear states at three levels of low, medium, and high altitudes, had acceptable results and high efficiency. Due to the increasing progress in the field of image processing and machine learning, future research can add different states of water and create models based on new algorithms of machine learning and artificial intelligence.

**Keywords:** Artificial Neural Networks, Deep Learning, Laboratory Study, Modeling, Water Level

**How to Cite This Article:** Abdi, E., Jani, R., & Darbandi, S. (2025). Dynamic Modeling of Water Level Changes Using Image Processing and Machine Learning. *J Watershed Manage Res*, 16(1), 71-83. DOI: 10.61882/jwmr.2024.1270

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]

[ DOI: 10.61882/jwmr.2024.1270 ]

دانشگاه علوم کشاورزی و منابع طبیعی ساری

مقاله پژوهشی

# مدل‌سازی پویا جهت پایش تغییرات سطح آب با استفاده از پردازش تصویر و یادگیری ماشین

عرفان عبدی[۱]، رسول جانی[۲] و صابره دربندی[۳]

۱- دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
۲- استادیار، گروه مهندسی عمران، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، (نویسنده مسوول: Jani@iaut.ac.ir)
۳- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

تاریخ دریافت: ۱۴۰۳/۰۳/۱۰ تاریخ ویرایش: ۱۴۰۳/۰۶/۲۰ تاریخ پذیرش: ۱۴۰۳/۰۷/۰۹
صفحه ۷۱ تا ۸۳

## چکیده مبسوط

**مقدمه و هدف:** مطالعه و پایش سطح آب رودخانه‌ها و مسیل‌ها توسط وزارت نیرو و سازمان‌های ذیربط بخش مهمی از مدیریت منابع آب در حوضه آبریز است. از طرفی اندازه‌گیری سطح آب یک کار حیاتی در پایش هیدرولوژیکی است، اما اغلب با محدودیت‌هایی مانند کمبود منابع، هزینه‌های بالا و نیازهای زمانی زیاد مواجه است. این محدودیت‌ها اغلب منجر به تأخیر در اندازه‌گیری‌ها و عدم دقت بالقوه، به‌ویژه در محیط‌های دور یا سخت می‌شوند. به‌طور کلی، اکثر روش‌های سنتی دارای خطاها و هزینه‌های قابل‌توجهی هستند و تقریباً پایش و کنترل پیوسته را ناممکن می‌سازند. پیشرفت‌های اخیر در فناوری منجربه تغییر الگو به سمت سیستم‌های پردازش تصویر برای نظارت بر سطح آب شده‌اند. این روش‌های غیر تماسی به‌دلیل پتانسیل بالا از نظر دقت، قابلیت اطمینان، مقرون‌به‌صرفه بودن و کاهش زمان موردنیاز مورد توجه قرار گرفته‌اند. در این تحقیق، با ارائه رویکردی جدید از تلفیق پردازش تصویر و یادگیری ماشین سعی شده‌است از حداقل امکانات برای کاهش هزینه‌ها و افزایش عملکرد برای استخراج شاخص‌های سطح آب واسنجی شده و سطح آب به‌صورت لحظه‌ای و خودکار اندازه‌گیری گردد. این رویکرد مبتنی بر ایجاد مجموعه‌ای از تصاویر گیج ثبت شده توسط گوشی هوشمند (که یک دستگاه معمولی با دسترسی آسان است) برای حالت‌های آب شفاف و کدر، برای آموزش مدل‌های مبتنی بر یادگیری ماشین ایجاد شده است. بر خلاف روش‌های سنتی، این روش با اندازه‌گیری لحظه‌ای و پیوسته سطح آب موجب عملکرد مطلوب سیستم‌های آبرسانی و مدیریت بهتر مواقع بحرانی مانند سیل، طغیان رودها و فرسایش می‌گردد.

**مواد و روش‌ها:** این مقاله با ارزیابی یک سیستم تشخیص سطح آب مبتنی‌بر تصویر با استفاده از یک دوربین گوشی هوشمند استاندارد به این تحقیق روبه‌رشد کمک می‌کند. الگوریتم‌های پردازش تصویر RGB در این تحقیق شامل فیلتر کردن، کاهش نویز، تشخیص رنگ، تغییر اندازه، تبدیل مقیاس خاکستری، تشخیص و تبدیل Hough و طرح‌ریزی برای به‌دست آوردن کاراکترهای دیجیتال و خط‌کش آب که فقط شامل مساحت خطوط مقیاس است، استفاده شدند. همچنین، تمام مراحل ذکرشده و مراحل مدل‌سازی در نرم‌افزار مثمتیکا (Mathematica) انجام شده‌است. داده‌های تجربی شامل ۲۴۴ داده مشاهده‌ای بودند که به‌صورت تصادفی ۲۰۱ تصویر داده آموزشی و ۴۳ تصویر داده آزمایشی در نظر گرفته شد که توسط دوربین تلفن همراه با موقعیت ثابت تصویر برداری شده بودند. با توجه به قابلیت‌های مدل‌های مختلف یادگیری ماشین، از جمله شبکه‌های عصبی مصنوعی (ANN) و یادگیری عمیق (DL) در پردازش و تحلیل تصویر، بر روی این مدل‌ها برای تخمین دقیق سطح آب تمرکز شد. این مطالعه شامل گرفتن تصاویر سطح آب، شناسایی لبه آب در یک خط‌کش اندازه‌گیری، و استفاده از این مدل‌ها برای تخمین سطح آب است. یادگیری ماشین، شاخه‌ای از هوش مصنوعی، با هدف توسعه سیستم‌های کامپیوتری با ظرفیت یادگیری از داده‌ها است که این فرآیند شامل رایانه‌هایی با یادگیری از طریق تجربه عملی، شروع با سازماندهی داده‌ها، انتخاب الگوریتم یادگیری ماشینی، واردکردن داده‌ها، و توانمندسازی مدل برای یادگیری مستقل الگوها یا تولید پیش‌بینی، توانایی خودبرنامه‌ریزی را به‌دست می‌آورند. به‌طور کلی، تجزیه و تحلیل مقایسه‌ای عملکرد این مدل‌ها با هدف نشان دادن پتانسیل ترکیب پردازش تصویر و یادگیری ماشین در غلبه بر موانع سنتی اندازه‌گیری سطح آب در مطالعات هیدرولوژیکی است.

**یافته‌ها:** نتایج مدل با استفاده از سه معیار ارزیابی ضرایب تعیین (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب توافق نش–ساتکلیف (NSE) و نمودارهای بصری مورد ارزیابی قرارگرفت. در این تحقیق، از دو مدل شبکه عصبی مصنوعی (ANN) و یادگیری عمیق (DL)، که زیرمجموعه‌هایی از مدل‌های یادگیری ماشین هستند، برای تخمین سطح آب در شرایط گل‌آلود و شفاف به‌همراه پردازش تصویر استفاده شد. نتایج نشان دادند که مدل یادگیری عمیق در هر دو شرایط عملکرد قابل قبول و همچنین با توجه به بررسی شاخص‌های ارزیابی، مدل یادگیری عمیق با کمترین خطای ۲۸/۳۹ میلی‌متر و بیشترین ضریب تعیین ۰/۹۷۳ به‌عنوان بهترین مدل برای برآورد سطح آب انتخاب شد. از این‌رو، با توجه به عملکرد مدل یادگیری عمیق، می‌توان فرایند بررسی و پایش سطح آب را علاوه بر آزمایشگاه‌ها در مکان‌های صعب‌العبور و بدون هزینه‌های زیاد جهت اندازه‌گیری به‌طور خودکار و پیوسته بررسی نمود و با اتخاذ تصمیمات درست از حوادث احتمالی جلوگیری کرد.

**نتیجه‌گیری:** با توجه به مشکلات اندازه‌گیری دستی و پایش میدانی، پایش خودکار و مستمر سطح آب توسط انسان دشوار و حتی غیرممکن می‌شود. با وجود این موانع، امروزه علاقه محققان به سیستم‌های پردازش تصویر با پیشرفت تکنولوژی افزایش یافته است. با توجه به کارهای انجام‌شده برای تشخیص و برآورد سطح آب، امروزه اکثر روش‌ها به‌سمت دستیابی به حداکثر بازده با حداقل امکانات پیش می‌روند. در نهایت، دو روش برای استخراج اطلاعات از تصاویر دیجیتال برای سیستم‌های پایش سطح آب مقایسه می‌شوند. تکنیک‌های ترکیبی برای تشخیص سطح آب در تصاویر شفاف و گل‌آلود بر اساس ارزیابی بصری و دقت آماری مقایسه شدند. بر اساس نتایج تجربی، این تکنیک‌ها و مدل‌ها همگی قادر به استخراج اطلاعات سطح آب از تصویر بودند. تکنیک پردازش تصویر و مدل یادگیری عمیق برای تشخیص و تخمین ویژگی‌های سطح آب از تصاویری که شامل دو حالت کدر و شفاف در سه سطح ارتفاع کم، متوسط و زیاد است، نتایج قابل قبول و کارایی بالایی داشتند. با توجه به پیشرفت‌های روز افزون در زمینه پردازش تصاویر و یادگیری ماشین، تحقیقات آینده می‌توانند افزودن حالت‌های مختلف آب و ایجاد مدل‌هایی بر پایه‌ی الگوریتم‌های جدید یادگیری ماشین و هوش مصنوعی باشند.

**واژه‌های کلیدی:** سطح آب، شبکه‌های عصبی مصنوعی، مدل‌سازی، مطالعه آزمایشگاهی، یادگیری عمیق

## مقدمه

مطالعه و پایش سطح آب رودخانه‌ها و مسیل‌ها توسط وزارت نیرو و سازمان‌های مرتبط بخش مهمی از مدیریت منابع آب در حوضه آبریز را تشکیل می‌دهد. طبیعتاً بهترین مدیریت منابع آب منطقه در گرو اندازه‌گیری مستمر این پارامترها است که کاری زمان‌بر و پرهزینه است. از طرفی، اندازه‌گیری مداوم سطح آب در اکثر ایستگاه‌های هیدرومتری گاهی به‌دلیل وجود شرایط بحرانی اندازه‌گیری به تعویق می‌افتد و یا دستگاه‌های

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]

[ DOI: 10.61882/jwmr.2024.1270 ]

اندازه‌گیری نیاز به مراقبت و واسنجی مکرر دارند و محدودیت‌هایی مانند حساسیت به دما، رطوبت، غلظت آب، و هزینه‌های نگهداری و نصب را شامل می‌شوند. همچنین اجسامی مانند شاخه و برگ درختان، کنده‌ها، زباله‌ها و یا باد باعث تلاطم آب‌های سطحی می‌شوند که منجر به ناهماهنگی در قرائت خواهد شد.

به‌طور کلی، اکثر روش‌هایی که امروزه در این زمینه صورت می‌گیرند دارای خطاها و هزینه‌های قابل‌توجهی هستند. با وجود این موانع، امروزه علاقه محققان به سیستم‌های پردازش تصویر با پیشرفت تکنولوژی افزایش یافته است. بسیاری از محققان به‌دنبال راه‌حل‌هایی با قابلیت اطمینان و دقت بالا، زمان و هزینه کم بر اساس دوربین هستند (Sabbatini *et al*., 2021). این روش، با بررسی و ارزیابی تصاویر از طریق یادگیری ماشینی، نتایج مطلوب‌تری را برای پیشبرد اهداف ممکن می‌سازد (Heydarzadeh, 2023). در ادامه برخی از تحقیقات انجام شده آورده شده است.

ارتیگوسا و همکاران (Ortigossa *et al*., 2015) در دو مکان مختلف سائو کارلوس برزیل، تصاویر را با استفاده از دوربین گوشی هوشمند گرفتند و تصاویر با استفاده از نرم‌افزار C++ برای تعیین سطح آب تجزیه و تحلیل شدند. خراده و همکاران (kharade *et al*., 2015) با تعیین فلش‌های قرمز رنگ و عکس‌برداری از این فلش‌ها با شیب‌های مختلف در محیط آزمایشگاه، به سطح آب و جهت جریان پی‌بردند. همچنین، آن‌ها از یادگیری ماشین برای بررسی و ارزیابی تصاویر گرفته شده در MATLAB استفاده کردند و توانستند روشی را برای اندازه‌گیری سطح آب و جهت جریان در مخازن و کانال‌ها ایجاد کنند. ژنگ و همکاران (Zhang *et al*., 2019) به‌منظور اندازه‌گیری سطح آب رودخانه یانگلو در ژجیانگ چین، در شرایط آب و هوایی مختلف، از سیستم‌های تصویربرداری مادون قرمز نزدیک (NIR) و مرئی (VIS) و دو روش محاسبه فیلتر کردن سفارشی (OSF) در نرم‌افزارهای Hydro View و Open cv استفاده کردند. گااو و همکاران (Gao *et al*., 2019) از پردازش تصویر برای تشخیص سطح آب در نیروگاه برق‌آبی برای تأمین برق رودخانه لانکانگ در چین بهره بردند. همچنین آن‌ها از پهپاد برای تصویربرداری، و نرم‌افزار Visual Studio 2008 و پلت‌فرم Open cv برای تجزیه و تحلیل تصویر استفاده کردند. چوی و همکاران (Choi *et al*., 2019) برای پیش‌بینی سطح آب روزانه از سال ۲۰۰۹ تا ۲۰۱۵ در تالاب اوپو[1] واقع در چانگ‌نیونگ گان[2] و جئونگ‌سانگ نامدو[3] کره، از مدل‌های شبکه عصبی مصنوعی (ANN)[4]، درخت تصمیم (DT)[5]، جنگل تصادفی (RF)[6] و ماشین بردار پشتیبان (SVM)[7] استفاده کردند که مدل جنگل تصادفی نتیجه مطلوبی داشت. موهادی و همکاران (Muhadi *et al*., 2020) در رودخان‌های در منطقه سیل خیز سلانگور[8] مالزی در دو حالت عادی و سرریز عکس گرفتند و تصاویر را به سه منطقه آستانه، منطقه رشد و منطقه ترکیبی تقسیم و سپس برای برآورد سطح آب از نرم‌افزار MATLAB استفاده کردند. سباتینی و همکاران (Sabbatini *et al., 2021*) برای بهبود عملکرد در برخی شرایط بحرانی مانند سیل، زمانی‌که اندازه‌گیری سطح آب تقریباً غیرممکن است یا با تأخیر انجام می‌شود، با نصب دوربین‌ها و گیج‌های اندازه‌گیری در شهر سنگال ایتالیا، تصاویری از سطح آب ثبت کردند. آن‌ها سطح آب را با ارائه دو مدل مدل‌سازی کردند و با طبقه‌بندی تصاویر، سطح تراز آب را تشخیص دادند.

این مقاله با ارزیابی یک سیستم تشخیص سطح آب مبتنی بر تصویر با استفاده از یک دوربین تلفن هوشمند استاندارد، به این تحقیق رو به‌رشد کمک می‌کند. با توجه به قابلیت‌های مدل‌های مختلف یادگیری ماشین، از جمله شبکه‌های عصبی مصنوعی (ANN)، و یادگیری عمیق (DL) در پردازش و تجزیه و تحلیل تصاویر، برای تخمین دقیق سطح آب بر روی این مدل‌ها تمرکز شد. این مطالعه شامل گرفتن تصاویر سطح آب، شناسایی لبه آب بر روی یک گیج اندازه‌گیری، و استفاده از این مدل‌ها برای تخمین سطح آب است. در کل، یک تحلیل مقایسه‌ای از عملکرد این مدل‌ها با هدف نشان دادن پتانسیل ترکیب پردازش تصویر و یادگیری ماشین در غلبه بر موانع سنتی اندازه‌گیری سطح آب در مطالعات هیدرولوژیکی است.

در این تحقیق، با ارائه یک رویکرد جدید سعی شده است از حداقل امکانات برای کاهش هزینه‌ها و افزایش عملکرد برای استخراج شاخص‌های سطح آب واسنجی شده و تخمین عددی به‌صورت لحظه‌ای و خودکار صورت گرفت. این رویکرد مبتنی بر ایجاد مجموعه داده‌ای از تصاویر گیج استخراج شده در گوشی هوشمند (که یک دستگاه معمولی با دسترسی آسان است) برای آب شفاف و کدر برای آموزش مدل‌های شبکه‌های عصبی است.

## مواد و روش‌ها

در این تحقیق، از تصاویر گرفته شده توسط دوربین تلفن همراه نصب شده در نزدیکی گیج در کانال آزمایشگاهی به‌عنوان داده‌های ورودی استفاده شد (شکل ۱). این عملیات با استفاده از نرم‌افزار Mathematica 13.3 پیاده‌سازی شده و مدل‌ها مورد ارزیابی قرارگرفتند. مرحله اولیه شامل پیش‌پردازش تصویر است. الگوریتم‌های پردازش تصویر RGB شامل فیلترکردن، کاهش نویز، تشخیص رنگ، تغییر اندازه، تبدیل مقیاس خاکستری، سپس طرح‌ریزی برای به‌دست آوردن کاراکترهای دیجیتال و خط‌کش آب که فقط شامل خطوط مقیاس است، هستند. در مرحله دوم که شامل تشخیص هوشمند است، برای به‌دست آوردن مقادیر کاراکترها و سطح آب به‌صورت عددی، از مدل‌های ANN و DL برای شناسایی این کاراکترها و از روش پیمایش پیکسل برای شناسایی خطوط مقیاس استفاده شد (Dou *et al*., 2022) و در نهایت، سطح

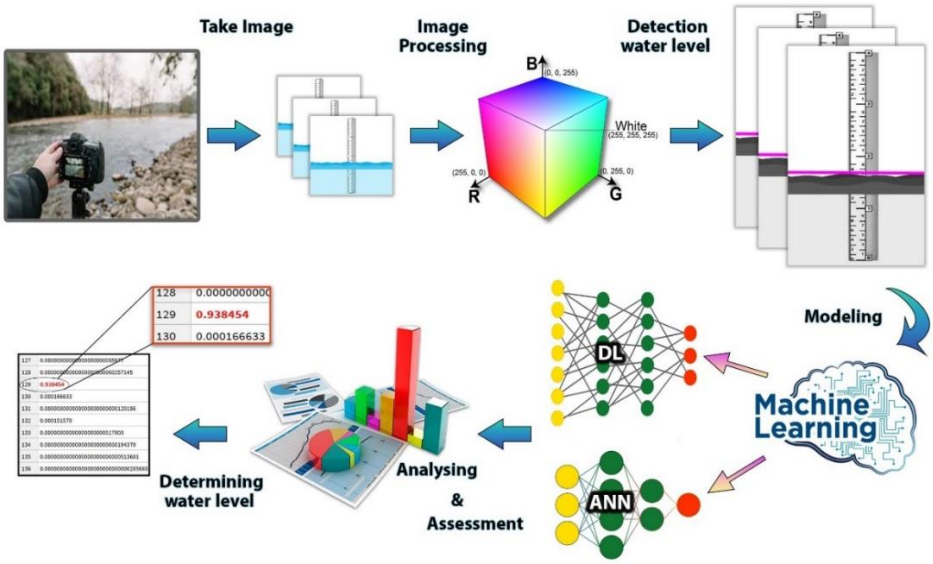
[1] Opu
[2] Changnyong-gun
[3] Jeongsang Namdo
[4] Artificial neural network
[5] Decision tree
[6] Random forest
[7] Support vector machine
[8] Selangor

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]

آب با استفاده از ریاضیات و احتمال تعیین شد. مراحل انجام شده در این پژوهش به‌طور کلی در شکل ۲ آمده‌اند.




شکل ۱- تصویری از تنظیمات آزمایشی در آزمایشگاه هیدرولیک دانشگاه تبریز
Figure 1. A picture of the experimental settings in the hydraulic laboratory of Tabriz University




شکل ۲- فلوچارت مراحل انجام شده در این تحقیق
Figure 2. The flowchart of the steps performed in this research

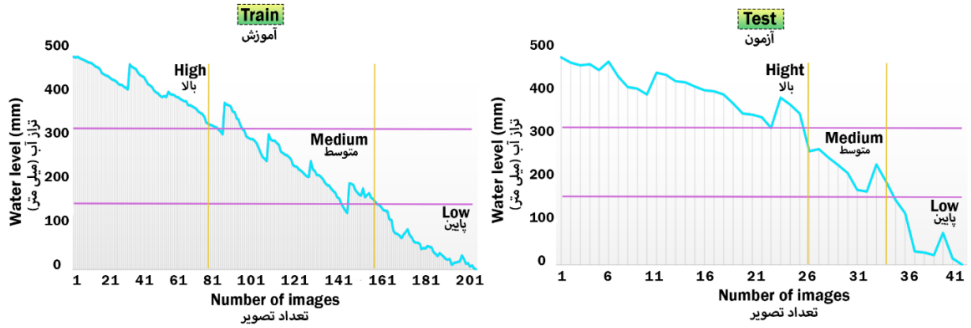
**مجموعه تصاویر**

بعد از پیش‌پردازش تصاویر، به‌منظور ورودی جهت مدل‌سازی با مدل‌های شبکه عصبی مصنوعی و یادگیری عمیق، داده‌های تصویری شامل ۲۴۴ داده مشاهده‌ای به‌صورت تصادفی ۲۰۱ تصویر برای آموزش و ۴۳ تصویر برای آزمایش انتخاب شدند. جدول ۱ و شکل ۳ تعداد تصاویر را در سه سطح (بالا، متوسط و کم) نشان می‌دهند.

جدول۱- تعداد تصاویر در سطوح مختلف
Table 1. The number of images at different levels

| سطح Level | آزمون (تصویر) Test (Image) | آموزش (تصویر) Train (image) |
|---|---|---|
| بالا High | 19 | 60 |
| متوسط Medium | 12 | 60 |
| پایین Low | 12 | 81 |
| کل Total | 43 | 201 |

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]

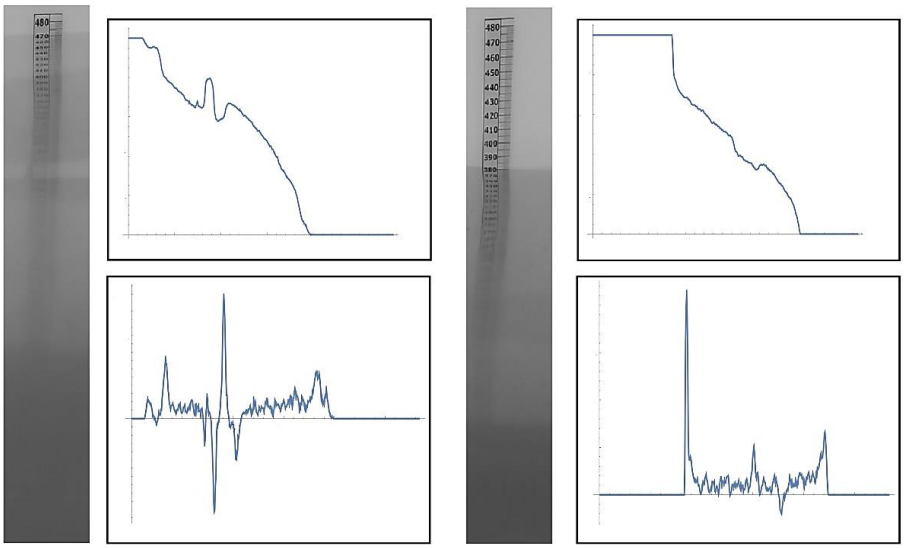



شکل ۳- تقسیم‌بندی تعداد تصاویر برای سطوح مختلف
Figure 3. Distribution of the number of images for different levels

## تشخیص و تخمین سطح آب

در این تحقیق، تصاویر سطح آب در دو حالت تمیز و گل‌آلود با استفاده از دوربین گوشی هوشمند در موقعیت ثابت گرفته شده‌اند. نمونه‌ای از تصاویر نهایی که تراز سطح آب در آن تشخیص داده شده است در شکل ۶ آمده است. گام اول) ابتدا تصاویر با کانال رنگی RGB گرفته شد که این تصاویر دارای دو جزء اصلی خط‌کش اندازه‌گیری و سطح آب هستند. گام دوم) برای بهبود تشخیص سطح آب فضاهای غیر از خط‌کش به‌گونه‌ای برش داده شدند که شامل خط‌کش و سطح آب باشند. گام سوم) برای یکسان‌سازی همه تصاویر، ابعاد تصاویر به ۶۵۰ × ۹۰۰ تغییر داده شد.

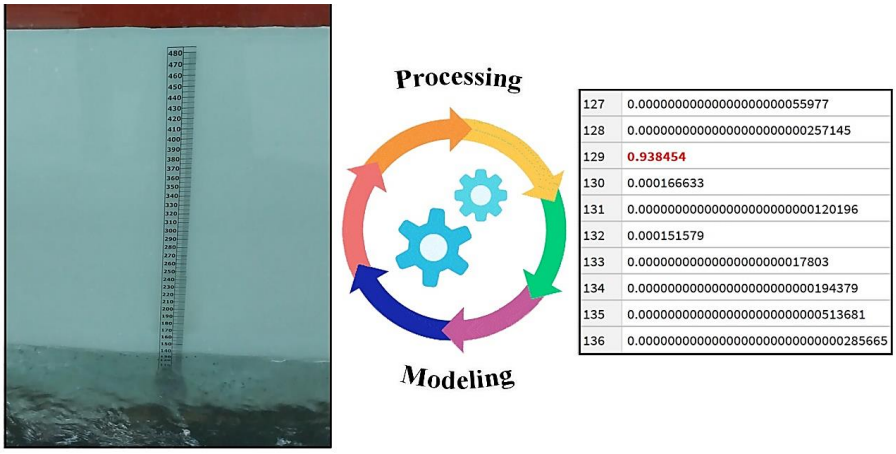
در تصویر از نوع RGB، رنگ پیکسل در موقعیت فضایی $f(x, y)$ از مؤلفه قرمز $R(x, y)$، سبز $G(x, y)$ و آبی $B(x, y)$ استفاده می‌کند (Kumar & Verma, 2010). فرآیند تبدیل یک تصویر رنگی به تصویر با مقیاس خاکستری، پردازش مقیاس خاکستری تصویر نامیده می‌شود و می‌تواند کارایی اجرای الگوریتم‌های بعدی را تا حد زیادی بهبود بخشد (Gu *et al.*, 2019). گام چهارم) به‌همین منظور تصاویر از حالت رنگی به خاکستری تغییر یافتند. گام پنجم) در این مرحله، جهت تشخیص بهتر تغییرات رنگ، قسمتی از تصویر که شامل خط‌کش نمی‌شود برش داده شد و برای شناسایی مناطقی که تغییر رنگ رخ داده بود، پروفایل‌های میانگین ستونی تغییرات رنگ برای تصاویر ایجاد شدند. هر جایی که تغییر رنگ در تصویر واضح باشد، شکستگی رخ می‌دهد، که در شکل ۴ نشان داده شده‌است.



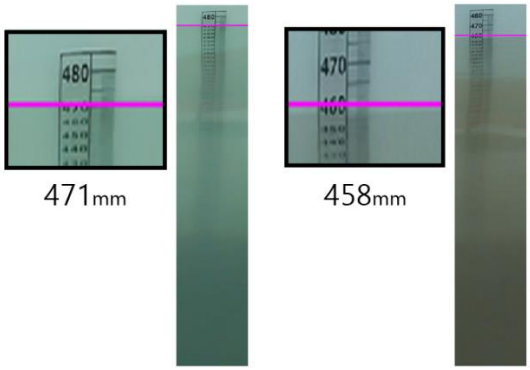
شکل ۴- نمونه‌ای از تصاویر با مقیاس خاکستری و پروفیل تغییر رنگ
Figure 4. An example of images with the gray scale and the color change profile

پس از انجام مراحل فوق، گام ششم) سطح آب روی خط‌کش اندازه‌گیری مشخص می‌گردد. گام هفتم) سپس این تصاویر به‌عنوان داده‌های ورودی برچسب‌گذاری شده و به‌عنوان ورودی به مدل‌های ANN و DL داده می‌شوند تا سطح آب به‌صورت عددی و با احتمال بیشتری تخمین زده شود. نمونه‌ای از تصویر گرفته شده و تخمین سطح آب در شکل ۵ آمده‌است.

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]




شکل ۵- نمونه‌ای از تصویر گرفته شده و تخمین احتمالی سطح آب
Figure 5. An example of the captured image and the possible estimation of the water level

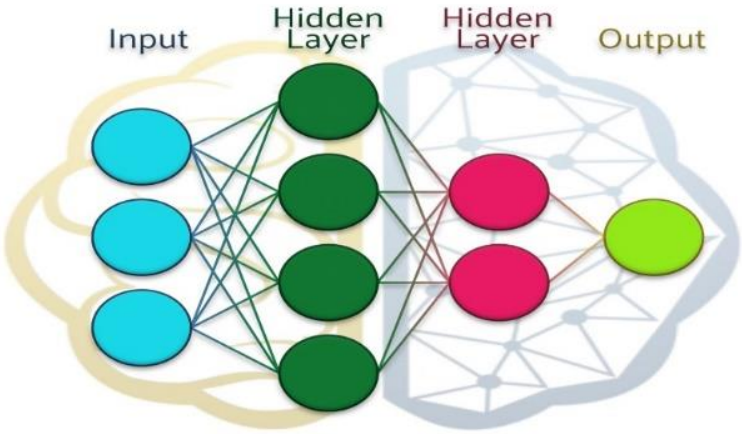



شکل ۶- نمونه تصاویر تشخیص سطح آب در دو حالت صاف و کدر
Figure 6. Examples of water level detection images in two clear and muddy states

## شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی خانواده‌ای از مدل‌ها هستند که از شبکه‌های عصبی بیولوژیکی الهام گرفته‌اند (won Seo 2016 *et al.*,) و به‌طور خاص به مغز انسان و نوعی سیستم عصبی مرکزی حیوانات اشاره دارد (Heddam, 2014). معماری یک ANN به این صورت است که از ورودی، خروجی و لایه پنهان تشکیل شده است. به‌طور کلی، شبکه عصبی مصنوعی را می‌توان به‌عنوان سیستمی از نورون‌های به‌هم پیوسته نشان داد (Wang *et al.*, 2008) که اساس عملکرد شبکه عصبی را تشکیل می‌دهند. پارامترهای وزن و توابع فعال‌سازی بخشی از نورون‌ها هستند (Maier *et al.*, 2000). هنگامی‌که نورون‌ها اطلاعاتی را از ورودی‌های مختلف دریافت می‌کنند، از طریق توابع فعال‌سازی غیرخطی اقدام به عملیات مدل‌سازی می‌کنند (chen *et al.*, 2020). به‌طور خلاصه، ساختار یک مدل *ANN* با اتصالات متقابل، توابع فعال‌سازی و قوانین یادگیری تعریف می‌شود که تعداد و انواع لایه‌ها و معماری کلی شبکه را تعیین می‌کنند. مدل‌های ANN به‌شدت به کمیت داده‌ها بستگی دارند (Loke *et al.*, 1997). بنا بر این، استفاده از اندازه‌های داده نسبتاً کوچک برای پیش‌بینی‌کننده‌ها (ورودی‌ها) توصیه نمی‌شود. این به این دلیل است که برخی از اطلاعات مفید در داده‌های کوتاه‌مدت از دست می‌رود، که ممکن است منجربه نتایج پیش‌بینی ضعیف شود (Liu *et al.*, 2012). در شکل ۷، ساختار مدل شبکه عصبی مصنوعی نشان داده شده‌است.

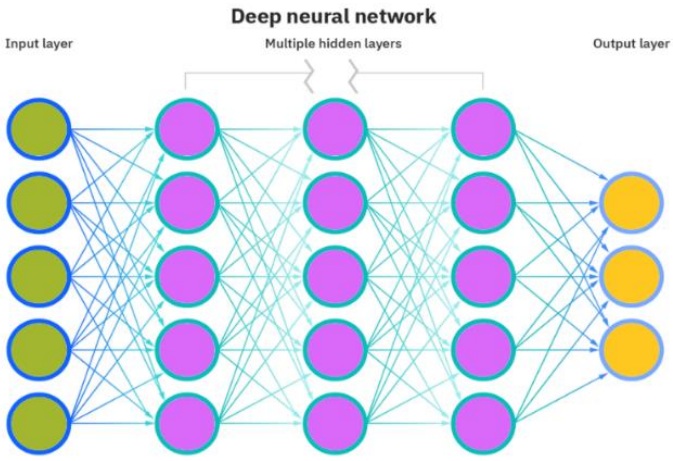
[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]




شکل ۷- تصویر مدل شبکه عصبی مصنوعی
Figure 7. Schematic of an artificial neural network model

## یادگیری عمیق (DL)

حل مسئله پیچیده از طریق اجرای شبکه‌های عصبی در یادگیری عمیق، یک حوزه تخصصی در یادگیری ماشین، امکان‌پذیر می‌شود (Choubin & Bashirgonbad, 2023). یادگیری عمیق به مدل‌های محاسباتی که از لایه‌های پردازشی چندگانه تشکیل شده‌اند اجازه می‌دهد تا نمایش داده‌ها را با سطوح انتزاعی متعدد بیاموزند (LeCun *et al*., 2015). روش‌های یادگیری عمیق، مانند شبکه‌های عصبی مصنوعی عمیق، از لایه‌های پردازشی متعدد برای کشف الگوها و ساختار در مجموعه‌های داده بسیار بزرگ استفاده می‌کنند و هر لایه مفهومی را از داده‌هایی که لایه‌های بعدی بر روی آن‌ها ساخته می‌شوند، یاد می‌گیرد. هرچه سطح بالاتر باشد، مفاهیمی که آموخته می‌شوند انتزاعی‌تر هستند (Rusk, 2016). این شبکه‌های عصبی، چندین لایه از گره‌های به‌هم پیوسته دارند که هر لایه بر روی آخرین لایه برای اصلاح و بهینه‌سازی پیش‌بینی‌ها و طبقه‌بندی‌ها ساخته شده‌است. یادگیری عمیق به پردازش داده‌های قبلی بستگی ندارد و به‌طور خودکار ویژگی‌ها را استخراج می‌کند (Shirazi *et al.*, 2023). یادگیری عمیق روش‌هایی را برای طبقه‌بندی میلیون‌ها تصویر به تعداد کلاس‌های کمتر ارائه می‌کند، که درصد خطا را کاهش می‌دهد (Krizhevsky *et al*., 2017). از طرفی، معماری و طراحی‌های مختلفی را می‌توان برای بهینه‌سازی محاسباتی برای روش‌های یادگیری عمیق برای تشخیص تصویر استفاده کرد (Szegedy *et al*., 2015). در شکل ۸، مدل تصویری برای یادگیری عمیق آمده‌است. مدل‌های یادگیری عمیق معمولاً از اجزای کلیدی مانند لایه ورودی، لایه پنهان، توابع فعال‌سازی، وزن‌ها و جهت‌گیری‌ها، لایه خروجی، الگوریتم‌های بهینه‌سازی و تکنیک‌های منظم‌سازی تشکیل می‌شوند. ترکیب این مؤلفه‌ها به‌صورت ساختاریافته به مدل‌های یادگیری عمیق اجازه می‌دهد تا الگوها و روابط پیچیده در داده‌ها را به‌طور مؤثر یاد بگیرند و آن‌ها را به ابزارهای قدرتمندی برای طیف وسیعی از وظایف تبدیل کنند. در شکل ۹ ساختار دو مدل استفاده شده در این مطالعه که ANN و DL هستند با جزئیات کامل آمده‌است.




شکل ۸- تصویر مدل یادگیری عمیق
Figure 8- Schematic of thedeep learning model

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]

**ANN**

| Layer (Type) | Output Shape |
|---|---|
| Input | Array (size: 3×128×128) |
| Linear Layer | Vector (size: 200) |
| Linear Layer | Vector (size: 32) |
| Softmax Layer | Vector (size: 491) |
| Output | Class |

**DL**

| Layer (Type) | Output Shape |
|---|---|
| Input | Array (size: 3×128×128) |
| Linear Layer | Vector (size: 200) |
| Tan | Vector (size: 200) |
| Linear Layer | Vector (size: 32) |
| Batch Normalization Layer | Vector (size: 32) |
| Linear Layer | Vector (size: 32) |
| Tan | Vector (size: 32) |
| Linear Layer | Vector (size: 491) |
| Softmax Layer | Vector (size: 491) |
| Output | Class |

شکل ۹- ساختار مدل‌های یادگیری عمیق و شبکه عصبی مصنوعی در این تحقیق
Figure 9. The structures of deep learning and artificial neural network models in this research

## نتایج و بحث

در این مطالعه، ابتدا لبه سطح آب در تصاویر گرفته شده شناسایی و سپس از دو مدل ANN و DL برای تخمین عددی سطح آب استفاده شد. سپس، از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی (R)، و ضریب نش ساتکلیف (NSE) برای ارزیابی عملکرد مدل‌ها استفاده شد. ضریب کارایی نش ساتکلیف یک معیار ارزیابی حیاتی است که در مدل‌سازی هیدرولوژیکی برای ارزیابی مهارت تخمین مدل‌ها استفاده می‌شود. عملکرد هر مدل در جدول ۲ و شکل ۱۰ مشخص شده‌است. نمودار میله‌ای خطا برای هر مدل در شکل ۱۱ آمده‌است.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(P_i - O_i)^2} \quad (۱)$$

$$R = \frac{\sum_{i=1}^{n}(O_i-\bar{O})(P_i-\bar{P})}{\sqrt{\sum_{i=1}^{n}(O_i-\bar{O})^2 \sum_{i=1}^{n}(P_i-\bar{P})^2}} \quad (۲)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^{n}(O_i-P_i)^2}{\sum_{i=1}^{n}(O_i-O)^2}\right] \quad (۳)$$

در روابط (۳-۱)، پارامترهای $Pi$ و $Oi$ به‌ترتیب مقادیر پیش‌بینی شده و مشاهده شده هستند.

جدول۲- نتایج معیارهای ارزیابی برای مدل‌های استفاده شده و شاخص‌های آماری داده‌های مشاهداتی
Table 2. Results of evaluation criteria for the used models and statistical indicators of observational data

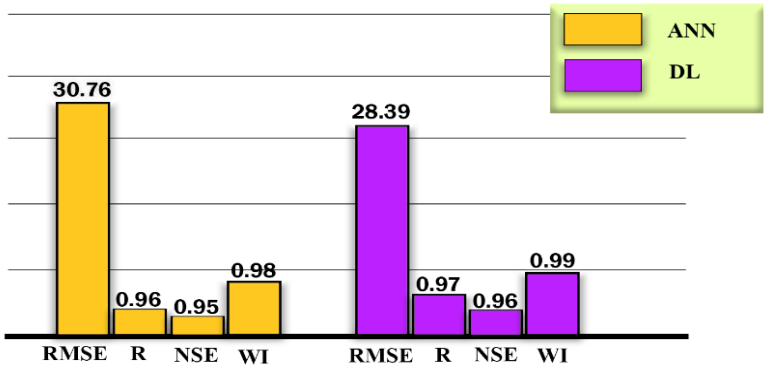
| مدل Model | نش ساتکلیف NSE | همبستگی R | ریشه میانگین مربعات خطا (میلی‌متر) RMSE (mm) |
|---|---|---|---|
| ANN | 0.955 | 0.968 | 30.76 |
| DL | 0.962 | 0.973 | 28.39 |

| شاخص آماری Statistical index | مدل Model: یادگیری عمیق DL | مدل Model: شبکه عصبی مصنوعی ANN | مشاهداتی Observations: آزمایش Test | مشاهداتی Observations: آموزش Train |
|---|---|---|---|---|
| میانگین Average | 308.69 | 310.16 | 300.44 | 251.92 |
| حداقل Minimum | 9 | 3 | 0 | 0 |
| حداکثر Maximum | 465 | 463 | 475 | 472 |
| انحراف معیار Standard deviation | 138.75 | 140.03 | 146.84 | 143.98 |
| مجموع Total | 13274 | 13337 | 12919 | 50636 |
| تعداد Count | 43 | 43 | 43 | 201 |

با استنباط از جدول ۲ که معیارهای ارزیابی را برای دو مدل یادگیری عمیق و شبکه عصبی مصنوعی نشان می‌دهد، می‌توان نتیجه گرفت که مدل DL با کمترین ریشه میانگین مربعات خطا و بالاترین میزان همبستگی نسبت به مدل ANN عملکرد بالایی دارد. با توجه به این‌که ضریب NSE یک معیار اساسی در واسنجی و ارزیابی مدل‌ها است و بینش‌های ارزشمندی در مورد دقت و قابلیت اطمینان مدل‌های هیدرولیکی ارائه می‌دهد، نتایج به‌دست آمده از این معیار برای مدل یادگیری عمیق که برابر با ۰/۹۶۲ است حاکی از بالا بودن قابلیت اطمینان این مدل برای اندازه‌گیری سطح آب است.

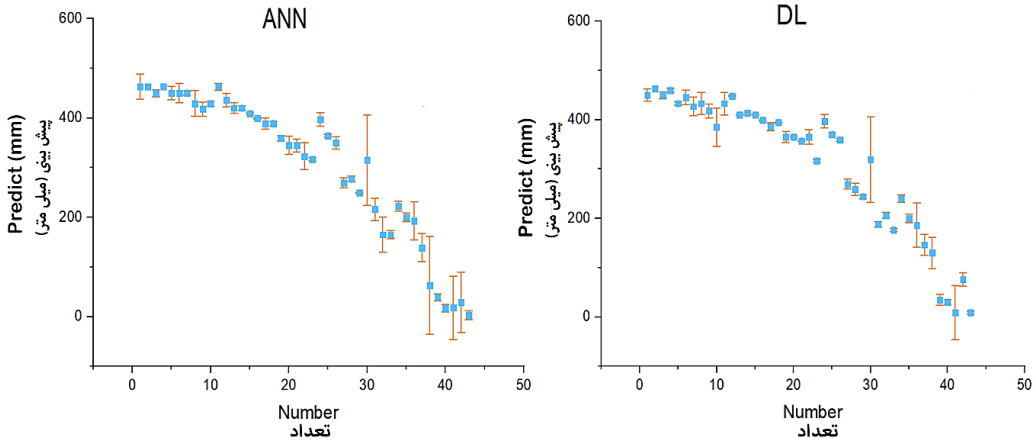
سیستم‌های اندازه‌گیری سطح آب مبتنی‌بر تصویر، با ارائه داده‌های خام قابل تأیید و تفسیر مجدد، همان‌طور که بیرگاند و همکاران (Birgand *et al*., 2022) اشاره کردند، مزیت قابل‌توجهی نسبت به روش‌های سنتی ارائه می‌کنند. همچنین، فرصت منحصر به‌فردی را برای ارزیابی کامل عملکرد سیستم در طول محدوده اندازه‌گیری و تصمیم‌گیری در مورد نیاز به تعمیر و نگهداری (حتی توسط پرسنل آموزش ندیده) فراهم می‌کنند. پایش و نظارت بر سطح آب که یک شاخص پویا است، مستلزم کنترل مستمر در برخی موقعیت‌ها و مکان‌ها است که به صرف زمان و هزینه زیاد برای اپراتور نیاز دارد.

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]




شکل ۱۰- مقایسه شاخص‌های ارزیابی دو مدل *ANN* و *DL*
Figure 10. Comparison of evaluation indices of two ANN and DL models

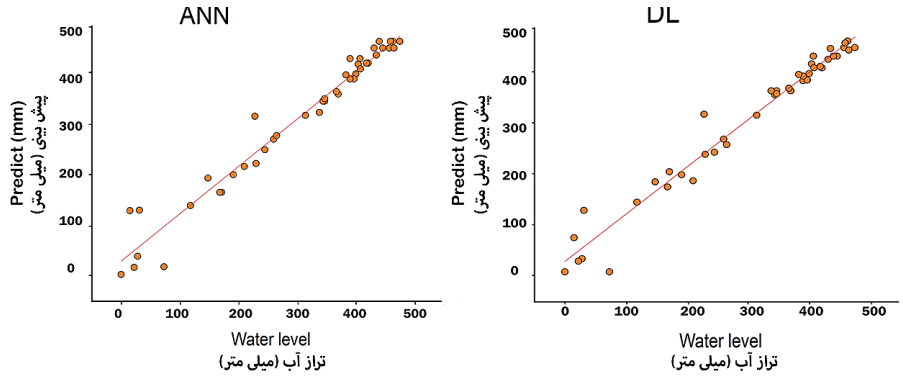
مطالعات زیادی در مورد پایش سطح آب با دستگاه‌ها و مدل‌های مختلف در دنیا انجام شده‌اند. در برخی تحقیقات، از دستگاه V-IoT، رادار و دوربین مدار بسته، از طرفی از دوربین‌ها و مدل‌های یادگیری عمیق، الگوریتم پیچیده YOLOv5s و الگوریتم U-NET برای تعیین سطح آب در مخازن، رودخانه‌ها و کانال‌های آزمایشگاهی استفاده کردند (Noto *et al.*, 2021; Kwon *et al.*, 2022; Muhadi *et al.*, 2023; Qiao *et al.*, 2021; Vandeale *et al.*, 2022). از سوی دیگر، مطالعاتی که در آن‌ها یادگیری عمیق و دوربین تلفن همراه عملکرد قابل قبولی داشته‌اند عبارتند از استفاده از یادگیری عمیق برای تخمین سطح رودخانه با استفاده از داده‌های تصویری دوربین که در پایان به این نتیجه رسیدند، این نوع از شبکه‌ها قادر به تولید دقیق دو نوع شاخص‌های سطح آب رودخانه واسنجی شده از تصاویر هستند که یکی برای نظارت مداوم سطح آب رودخانه و دیگری برای تشخیص رویداد سیل هستند (Fleury *et al.*, 2016; Vandeale *et al.*, 2021). این کار گام مهمی در جهت استفاده خودکار از دوربین‌ها برای نظارت‌بر سیل و طغیان رودخانه‌ها است.



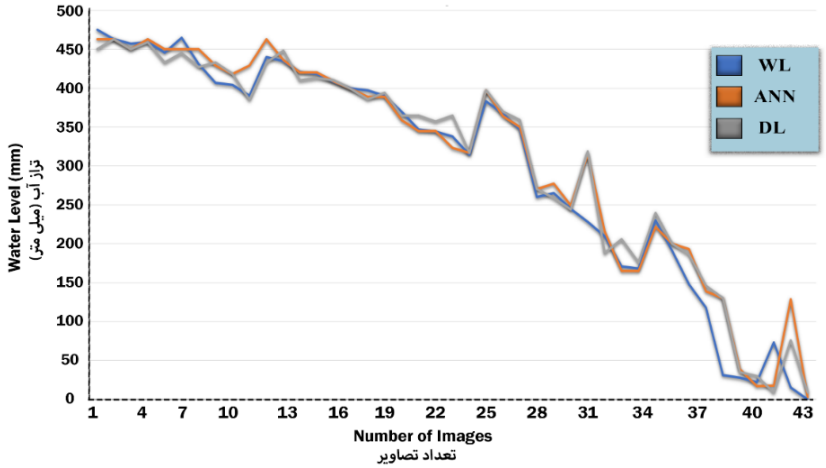

شکل۱۱- نمودار میله‌ای خطا برای دو مدل *ANN* و *DL*
Figure 11. The error bar chart for two ANN and DL models

با توجه به مشکلات اندازه‌گیری دستی و پایش میدانی، پایش خودکار و مستمر سطح آب توسط انسان دشوار و حتی غیرممکن می‌شود. با توجه به کارهای انجام شده برای تشخیص و برآورد سطح آب، امروزه اکثر روش‌ها به‌سمت دستیابی به حداکثر بازده با حداقل امکانات پیش می‌روند. در این تحقیق برای سادگی، تصاویر با دوربین گوشی هوشمند، وسیله‌ای با دسترسی آسان، اخذ شدند. همچنین، با استفاده از نرم‌افزارهای ریاضی و ایجاد دو مدل ANN و DL، تصاویر پردازش و سطح آب شناسایی شد، و در آخر از احتمالات به منظور تعیین عددی سطح آب استفاده گردید. نمودار پراکندگی برای هر مدل و نمودار مقایسه‌ای مدل‌های مورد استفاده در شکل‌های ۱۲ و ۱۳ نشان داده شده‌اند.

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]




شکل ۱۲- نمودار پراکندگی برای دو مدل استفاده شده
Figure 12. The scatter diagram for two used models




شکل ۱۳- نمودار مقایسه‌ای بین مقادیر مشاهداتی و تخمین‌زده شده
Figure 13. The comparison chart between observed and estimated values

## نتیجه‌گیری کلی

در دهه گذشته، محققان به‌طور فزاینده‌ای از رویکردهای بینایی کامپیوتری برای بهبود سیستم‌های تشخیص و نظارت بر سطح آب و در نتیجه مدیریت و تصمیم‌گیری بهتر استفاده کرده‌اند. دوربین‌های بینایی و گیج کامپیوتری تصاویر را با استفاده از تکنیک‌های تقسیم‌بندی برای درک محتوای آن‌ها ضبط و پردازش می‌کنند. با این‌حال، توسعه فناوری گوشی‌های هوشمند و پردازش تصویر با سرعتی باورنکردنی در حال پیشرفت است (Elias & Maas, 2022).

نتایج امیدوارکننده این مطالعه، توان روش‌های یادگیری عمیق را برای تشخیص کاراکترهای خط‌کش اندازه‌گیری و تخمین سطح آب برای نظارت بهتر به وسیله دوربین‌های تلفن هوشمند نشان دادند. این یک جایگزین انعطاف‌پذیر، مقرون به‌صرفه و دقیق برای روش‌های مرسوم‌تر و سنتی برای نظارت بر سطح آب است و این پتانسیل را دارد که به جلوگیری از خسارات اقتصادی، اجتماعی و شخصی بیشتر کمک کند (Vandaele *et al.*, 2021).

در این مقاله، مقایسه دو روش برای استخراج اطلاعات از تصاویر دیجیتال برای سیستم‌های پایش سطح آب ارائه شد. تکنیک‌های ترکیبی جهت تشخیص سطح تراز آب در تصاویر صاف و گل‌آلود بر اساس ارزیابی بصری و دقت آماری مقایسه شدند. براساس نتایج تجربی، این تکنیک‌ها و مدل‌ها همگی قادر به استخراج اطلاعات سطح آب از تصویر بودند. تکنیک پردازش تصویر و مدل یادگیری عمیق برای تشخیص و تخمین ویژگی‌های سطح آب از تصاویر، نتایج قابل‌قبول و عملکرد بالایی داشتند. این روش که در حال حاضر با رشد زیادی در کل جهان روبه‌رو است، پایش و کنترل سطح آب را در مناطق سخت و دشوار بهبود می‌بخشد و از طرفی با اندازه‌گیری بدون محدودیت زمانی، مکانی و به‌طور خودکار می‌تواند کاربرد مفیدی در سیستم‌های آبرسانی و نظارت و پیش‌بینی وقوع سیل داشته باشد. تحقیقات آینده را می‌توان با تمرکز روی اضافه کردن الگوریتم‌های بهینه‌سازی مختلف برای افزایش دقت، توسعه روش‌های تشخیص و تخمین پیشرفته‌تر برنامه‌ریزی کرد. همچنین، با اعمال سیستم هشداردهنده اولیه در مطالعات پیش‌رو می‌توان به تصمیم‌گیری‌ها جهت بروز هر گونه حادثه بحرانی کمک کرد.

## تشکر وقدردانی

گروه نویسندگان مراتب تشکر و قدردانی خود را از بخش مرکز تحقیقات رباتیک و فناوری‌های نرم دانشگاه آزاد، واحد تبریز، به خاطر فراهم نمودن تجهیزات این پژوهش ابراز می‌نمایند.

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]
[ DOI: 10.61882/jwmr.2024.1270 ]

**References**

Birgand, F., Chapman, K., Hazra, A., Gilmore, T., Etheridge, R., & Staicu, A. M. (2022). Field performance of the GaugeCam image-based water level measurement system. *PLoS Water*, 1(7). https://doi.org/10.1371/journal.pwat.0000032

Choi, C., Kim, J., Han, H., Han, D., & Kim, H. S. (2019). Development of water level prediction models using machine learning in wetlands: A case study of Upo wetland in South Korea. *Water*, 12(1), 93. https://doi.org/10.3390/w12010093

Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. *Applied Sciences*, 10(17), 5776. https://doi.org/10.3390/app10175776

Choubin, M., & Bashirgonbad, M. (2023). Evaluation of IHACRES, Conceptual Rainfall Runoff Model and Artificial Neural Network Models in Simulation and Stream flow Prediction in Bakhtiary River Basin. *Journal of Watershed Management Research*, *14*(27), 115-122. [In Persian]

Dou, G., Chen, R., Han, C., Liu, Z., & Liu, J. (2022). Research on water-level recognition method based on image processing and convolutional neural networks. *Water*, 14(12), 1890. https://doi.org/10.3390/app10175776

Elias, M., & Maas, H. G. (2022). Measuring Water Levels by Handheld Smartphones: A contribution to exploit crowdsourcing in the spatio-temporal densification of water gauging networks. *The International Hydrographic Review*, (27), 9-22. https://journals.lib.unb.ca/index.php/ihr/article/view/33130

Fleury, G. R. D. O., do Nascimento, D. V., Galvão Filho, A. R., Ribeiro, F. D. S. L., de Carvalho, R. V., & Coelho, C. J. (2020). Image-Based River Water Level Estimation for Redundancy Information Using Deep Neural Network. *Energies*, 13(24), 6706. https://doi.org/10.3390/en13246706

Gao, A., Wu, S., Wang, F., Wu, X., Xu, P., Yu, L., & Zhu, S. (2019). A newly developed unmanned aerial vehicle (UAV) Imagery based technology for field measurement of water level. *Water*, 11(1), 124. https://doi.org/10.3390/w11010124

Gu, M., Su, B., Wang, M., & Wang, Z. (2019). Survey on decolorization methods. *Applied Research Computing*, *36*, 1286-1292.

Heddam, S. (2014). Modelling hourly dissolved oxygen concentration (DO) using dynamic evolving neural-fuzzy inference system (DENFIS)-based approach: case study of Klamath River at Miller Island Boat Ramp, OR, USA. *Environmental Science and Pollution Research*, 21(15), 9212-9227. https://doi.org/10.1007/s11356-014-2842-7

Heydarzadeh, M. (2023). Evaluation of the correlation of plant indices with meteorological and biological variables using Google Earth Engine system. *Journal of Water and Soil Conservation Research,* 30(2), 1-26. doi: 10.22069/jwsc.2023.20667.3584

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. https://doi.org/10.1145/3065386

Kharade, A., Gendle, M., & Lodha, T. (2017). Water level measurement and detection of flow direction using image processing. *International Journal of Innovations in Engineering Research and Technology*, 1-4.

Kumar, T., & Verma, K. (2010). A Theory Based on Conversion of RGB image to gray image. *International Journal of Computer Applications*, *7*(2), 7-10.

Kwon, S. H., Ha, C., & 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. https://doi.org/10.3741/JKWRA.2023.56.4.245

Loke, E., Warnaars, E. A., Jacobsen, P., Nelen, F., & do Ceu Almeida, M. (1997). Artificial neural networks as a tool in urban storm drainage. *Water Science and Technology,* 36(8-9), 101-109. https://doi.org/10.1016/S0273-1223(97)00612-4

Liu, S., Yan, M., Tai, H., Xu, L., & Li, D. (2012). Prediction of dissolved oxygen content in aquaculture of Hyriopsis cumingii using Elman neural network. In Computer and Computing Technologies in Agriculture V: 5th IFIP TC 5/SIG 5.1 Conference, CCTA 2011, Beijing, China, October 29-31, 2011, Proceedings, Part III 5, 508-518. https://doi.org/10.1007/978-3-642-27275-2

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. https://doi.org/10.1038/nature14539.

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]

[ DOI: 10.61882/jwmr.2024.1270 ]

Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software,* 15(1), 101-124. https://doi.org/10.1016/S1364-8152(99)00007-9

Muhadi, N. A., Abdullah, A. F., Bejo, S. K., Mahadi, M. R., & Mijic, A. (2021). Deep learning semantic segmentation for water level estimation using surveillance camera. *Applied Sciences*, 11(20), 9691. https://doi.org/10.3390/app11209691

Noto, S., Tauro, F., Petroselli, A., Apollonio, C., Botter, G., & Grimaldi, S. (2022). Low-cost stage-camera system for continuous water-level monitoring in ephemeral streams. *Hydrological Sciences Journal*, 67(9), 1439-1448. https://doi.org/10.1080/02626667.2022.2079415

Ortigossa, E. S., Dias, F., Ueyama, J., & Nonato, L. G. (2015). Using digital image processing to estimate the depth of urban streams. In *Proceedings of the Workshop of Undergraduate Works in Conjunction with Conference on Graphics, Patterns and Images (SIBGRAPI), Bahia, Brazil* (26-29).

Qiao, G., Yang, M., & Wang, H. (2022). A water level measurement approach based on YOlOv5s. *Sensors*, 22(10), 3714. https://doi.org/10.3390/s22103714

Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35. https://doi.org/10.1038/nmeth.3707

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1-9.

Sabbatini, L., Palma, L., Belli, A., Sini, F., & Pierleoni, P. (2021). A Computer Vision System for Staff Gauge in River Flood Monitoring. *Inventions*, 6(4), 79. https://doi.org/10.3390/inventions6040079

Shirazi, F., Zahiri, A., Piri, J., Dehghani, A. A. (2023). Development a new hydraulic method for prediction of river flood discharge. *Journal of Watershed Management Research*, 14(28), 110-123. doi:10.61186/jwmr.14.28.110. [In Persian]

Vandaele, R., Dance, S. L., & Ojha, V. (2021). Deep learning for automated river-level monitoring through river-camera images: an approach based on water segmentation and transfer learning. *Hydrology and Earth System Sciences*, 25(8), 4435-4453. https://doi.org/10.5194/hess-25-4435-2021

won Seo, I., Yun, S. H., & Choi, S. Y. (2016). Forecasting water quality parameters by ANN model using pre-processing technique at the downstream of Cheongpyeong Dam. *Procedia Engineering,* 154, 1110-1115. https://doi.org/10.1016/j.proeng.2016.07.519

Wang, T. S., Tan, C. H., Chen, L., & Tsai, Y. C. (2008). Applying artificial neural networks and remote sensing to estimate chlorophyll-a concentration in water body. In *2008 Second International Symposium on Intelligent Information Technology Application*, 540-544. https://doi.org/10.1109/IITA.2008.279

Zhang, Z., Zhou, Y., Liu, H., & Gao, H. (2019). In-situ water level measurement using NIR-imaging video camera. *Flow Measurement and Instrumentation*, 67, 95-106. https://doi.org/10.1016/j.flowmeasinst.2019.04.004

[ Downloaded from jwmr.sanru.ac.ir on 2026-11-07 ]

[ DOI: 10.61882/jwmr.2024.1270 ]