



## Research Paper

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

Erfan Abdi<sup>1</sup>, Rasool Jani<sup>2</sup>, and Sabereh Darbandi<sup>3</sup>

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



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



## مقاله پژوهشی

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

عرفان عبدی<sup>۱</sup>، رسول جانی<sup>۲</sup> و صابره دربندی<sup>۳</sup>

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 پذیرش: ۱۴۰۳/۰۷/۰۹

تاریخ ویرایش: ۱۴۰۳/۰۶/۲۰  
صفحه ۷۱ تا ۸۳

تاریخ دریافت: ۱۴۰۳/۰۳/۱۰

## 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 منجر به تغییر الگو به سمت سیستم‌های پردازش تصویر برای نظارت بر سطح آب شده‌اند. این روش‌های غیر تماسی به دلیل 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 ابرسانی و مدیریت بهتر مواقع بحرانی مانند سیل، طغیان رودها و فرسایش می‌گردد.

**مواد و روش‌ها:** این مقاله با ارزیابی یک سیستم تشخیص سطح آب مبتنی بر تصویر با استفاده از یک دوربین گوشی هوشمند استاندارد به این تحقیق رویه‌برداری 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 ذکر شده و مراحل مدل‌سازی در نرم‌افزار ممتیکا (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، و توانمندسازی مدل برای یادگیری مستقل الگوها یا تولید پیش‌بینی، توانایی خودبرنامه‌ریزی را به‌دست می‌آورد. 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 قرار گرفت. 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 پایه الگوریتم‌های جدید یادگیری ماشین و هوش مصنوعی باشند.

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

## مقدمه

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

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

استانه، منطقه رشد و منطقه ترکیبی تقسیم و سپس برای برآورد سطح آب از نرم افزار MATLAB استفاده کردند. سباتینی و همکاران (Sabbatini et al., 2021) برای بهبود عملکرد در برخی شرایط بحرانی مانند سیل، زمانی که اندازه گیری سطح آب تقریباً غیرممکن است یا با تأخیر انجام می شود، با نصب دوربین ها و گیج های اندازه گیری در شهر سنگال ایتالیا، تصاویری از سطح آب ثبت کردند. آن ها سطح آب را با ارائه دو مدل مدل سازی کردند و با طبقه بندی 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 به رشد کمک می کند. با توجه به قابلیت های مدل های مختلف یادگیری ماشین، از جمله شبکه های عصبی مصنوعی (ANN)، و یادگیری عمیق (DL) در پردازش و تجزیه و تحلیل تصاویر، برای تخمین دقیق سطح آب بر روی این مدل ها تمرکز شد. این مطالعه شامل گرفتن تصاویر سطح آب، شناسایی لبه آب بر روی یک گیج اندازه گیری، و استفاده از این مدل ها برای تخمین سطح آب است. در کل، یک تحلیل مقایسه ای از عملکرد این مدل ها با هدف نشان دادن پتانسیل ترکیب پردازش تصویر و یادگیری ماشین در غلبه بر موانع سنتی اندازه گیری سطح آب در مطالعات هیدرولوژیکی است.

در این تحقیق، با ارائه یک رویکرد جدید سعی شده است از حداقل امکانات برای کاهش هزینه ها و افزایش عملکرد برای استخراج شاخص های سطح آب و اسنجی شده و تخمین عددی به صورت لحظه ای و خودکار صورت گرفت. این رویکرد مبتنی بر ایجاد مجموعه داده ای از تصاویر گیج استخراج شده در گوشی هوشمند (که یک دستگاه معمولی با دسترسی آسان است) برای آب شفاف و کدر برای آموزش مدل های شبکه های عصبی است.

### مواد و روش ها

در این تحقیق، از تصاویر گرفته شده توسط دوربین تلفن همراه نصب شده در نزدیکی گیج در کانال آزمایشگاهی به عنوان داده های ورودی استفاده شد (شکل ۱). این عملیات با استفاده از نرم افزار Mathematica 13.3 پیاده سازی شده و مدل ها مورد ارزیابی قرار گرفتند. مرحله اولیه شامل پیش پردازش تصویر است. الگوریتم های پردازش تصویر RGB شامل فیلتر کردن، کاهش نویز، تشخیص رنگ، تغییر اندازه، تبدیل مقیاس خاکستری، سپس طرح ریزی برای به دست آوردن کاراکترهای دیجیتال و خط کش آب که فقط شامل خطوط مقیاس است، هستند. در مرحله دوم که شامل تشخیص هوشمند است، برای به دست آوردن مقادیر کاراکترها و سطح آب به صورت عددی، از مدل های 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

اندازه گیری نیاز به مراقبت و واسنجی مکرر دارند و محدودیت هایی مانند حساسیت به دما، رطوبت، غلظت آب، و هزینه های نگهداری و نصب را شامل می شوند. همچنین اجسامی مانند شاخه و برگ درختان، کنده ها، زباله ها و یا باد باعث تلاطم آب های سطحی می شوند که منجر به ناهماهنگی در قرائت خواهد شد.

به طور کلی، اکثر روش هایی که امروزه در این زمینه صورت می گیرند دارای خطاها و هزینه های قابل توجهی هستند. با وجود این موانع، امروزه علاقه محققان به سیستم های پردازش تصویر با پیشرفت تکنولوژی افزایش یافته است. بسیاری از محققان به دنبال راه حل هایی 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 مطلوب تری را برای پیشبرد اهداف ممکن می سازد (Heydarzadeh, 2023). در ادامه برخی از تحقیقات انجام شده آورده شده است.

ارتیگوسا و همکاران (Ortigossa et al., 2015) در دو مکان مختلف ساو کارلوس برزیل، تصاویر را با استفاده از دوربین گوشی هوشمند گرفتند و تصاویر با استفاده از نرم افزار ++C برای تعیین سطح آب تجزیه و تحلیل شدند. خراده و همکاران (kharade et al., 2015) با تعیین فلش های قرمز رنگ و عکس برداری از این فلش ها با شیب های مختلف در محیط آزمایشگاه، به سطح آب و جهت جریان پی بردند. همچنین، آن ها از یادگیری ماشین برای بررسی و ارزیابی تصاویر گرفته شده در MATLAB استفاده کردند و توانستند روشی را برای اندازه گیری سطح آب و جهت جریان در مخازن و کانال ها ایجاد کنند. ژنگ و همکاران (Zhang et al., 2019) به منظور اندازه گیری سطح آب رودخانه یانگلو در ژجیانگ چین، در شرایط آب و هوایی مختلف، از سیستم های تصویربرداری مادون قرمز نزدیک (NIR) و مرئی (VIS) و دو روش محاسبه فیلتر کردن سفارشی (OSF) در نرم افزارهای Hydro View و Open cv استفاده کردند. گاو و همکاران (Gao et al., 2019) از پردازش تصویر برای تشخیص سطح آب در نیروگاه برق آبی برای تأمین برق رودخانه لانگانگ در چین بهره بردند. همچنین آن ها از پهناد برای تصویربرداری، و نرم افزار Visual Studio 2008 و پلت فرم Open cv برای تجزیه و تحلیل تصویر استفاده کردند. چوی و همکاران (Choi et al., 2019) برای پیش بینی سطح آب روزانه از سال ۲۰۰۹ تا ۲۰۱۵ در تالاب اوپو<sup>۱</sup> واقع در چانگ نیونگ گان<sup>۲</sup> و جئونگ سانگ نامدو<sup>۳</sup> کره، از مدل های شبکه عصبی مصنوعی (ANN)<sup>۴</sup>، درخت تصمیم (DT)<sup>۵</sup>، جنگل تصادفی (RF)<sup>۶</sup> و ماشین بردار پشتیبان (SVM)<sup>۷</sup> استفاده کردند که مدل جنگل تصادفی نتیجه مطلوبی داشت. موهادی و همکاران (Muhadi et al., 2020) در رودخان های در منطقه سیل خیز سلانگور<sup>۸</sup> مالزی در دو حالت عادی و سرریز عکس گرفتند و تصاویر را به سه منطقه

<sup>5</sup> Decision tree

<sup>6</sup> Random forest

<sup>7</sup> Support vector machine

<sup>8</sup> Selangor

<sup>1</sup> Opu

<sup>2</sup> Changnyong-gun

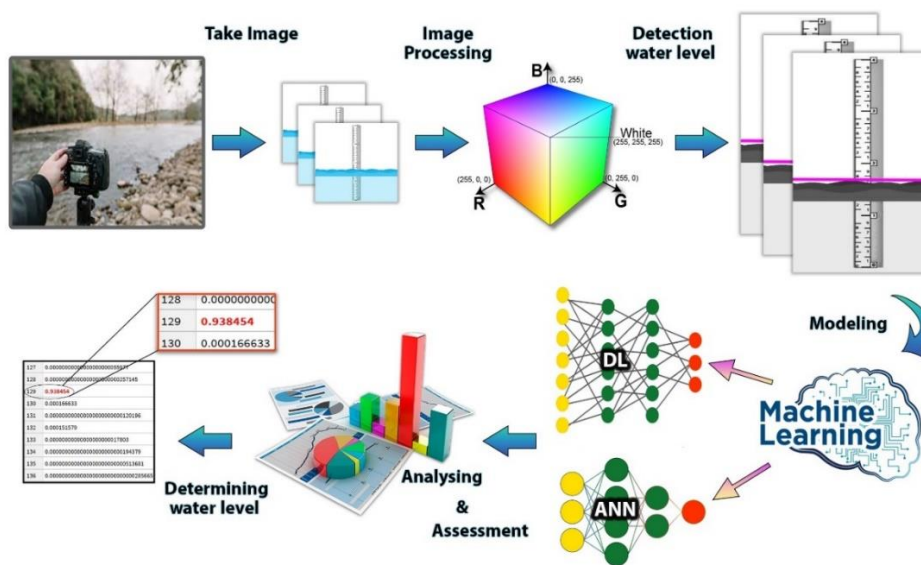
<sup>3</sup> Jeongsang Namdo

<sup>4</sup> Artificial neural network

آب با استفاده از ریاضیات و احتمال تعیین شد. مراحل انجام شده در این پژوهش به طور کلی در شکل ۲ آمده اند.



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

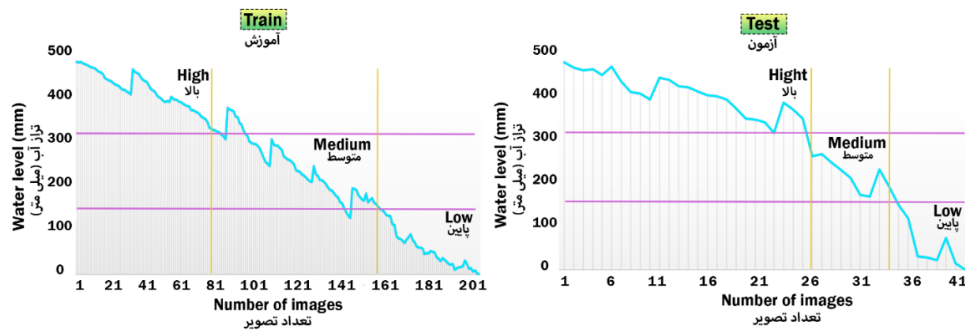
تصادفی ۲۰۱ تصویر برای آموزش و ۴۳ تصویر برای آزمایش انتخاب شدند. جدول ۱ و شکل ۳ تعداد تصاویر را در سه سطح (بالا، متوسط و کم) نشان می‌دهند.

**مجموعه تصاویر**  
بعد از پیش‌پردازش تصاویر، به منظور ورودی جهت مدل‌سازی با مدل‌های شبکه عصبی مصنوعی و یادگیری عمیق، داده‌های تصویری شامل ۲۴۴ داده مشاهده‌ای به صورت

جدول ۱- تعداد تصاویر در سطوح مختلف

Table 1. The number of images at different levels

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



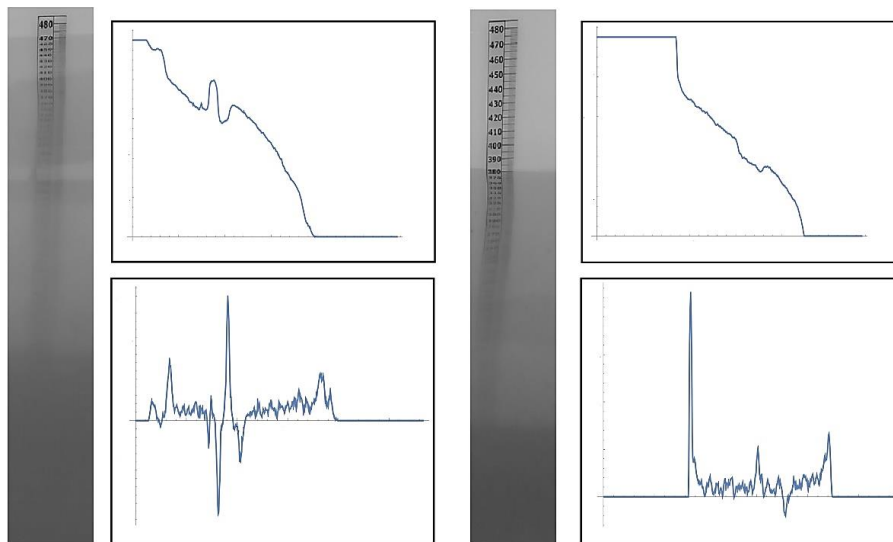
شکل ۳- تقسیم‌بندی تعداد تصاویر برای سطوح مختلف  
Figure 3. Distribution of the number of images for different levels

### تشخیص و تخمین سطح آب

در این تحقیق، تصاویر سطح آب در دو حالت تمیز و گل‌آلود با استفاده از دوربین گوسی 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  $650 \times 900$  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

فرآیند  $B(x, y)$  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 (2019 Gu et al.,). 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.

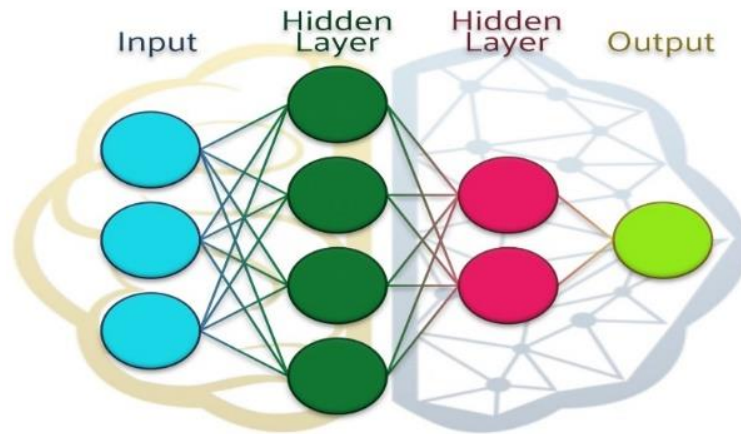


شکل ۴- نمونه‌ای از تصاویر با مقیاس خاکستری و پروفیل تغییر رنگ  
Figure 4. An example of images with the gray scale and the color change profile

سطح آب به‌صورت عددی و با احتمال بیشتری تخمین زده شود. نمونه‌ای از تصویر گرفته شده و تخمین سطح آب در شکل ۵ آمده‌است.

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






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

را استخراج می کند (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 آمده است. 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 به صورت ساختار یافته به مدل‌های یادگیری عمیق اجازه می‌دهد تا الگوها و روابط پیچیده در داده‌ها را به طور 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 آمده است.

### 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 بهم پیوسته دارند که هر لایه بر روی آخرین لایه برای اصلاح و بهینه‌سازی پیش‌بینی‌ها و طبقه‌بندی‌ها ساخته شده است. یادگیری عمیق به پردازش داده‌های قبلی بستگی ندارد و به طور خودکار ویژگی‌ها



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

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

مشخص شده است. نمودار میله‌ای خطا برای هر مدل در شکل ۱۱ آمده است.

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

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

$$NSE = 1 - \left[ \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right] \quad (3)$$

در روابط (۱-۳)، پارامترهای  $P_i$  و  $O_i$  به ترتیب مقادیر پیش‌بینی شده و مشاهده شده هستند.

### 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 ساتکلایف (NSE) برای ارزیابی عملکرد مدل‌ها استفاده شد. ضریب کارایی نش ساتکلایف 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

جدول ۲- 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

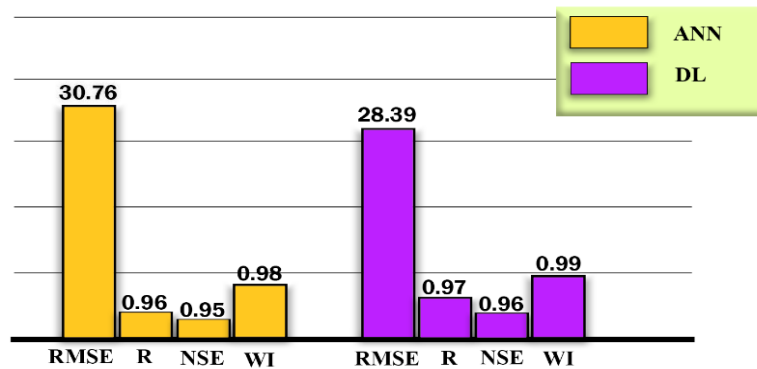
مدل	نش ساتکلایف	همبستگی	ریشه میانگین مربعات خطا (میلی‌متر)
Model	NSE	R	RMSE (mm)
ANN	0.955	0.968	30.76
DL	0.962	0.973	28.39

مشاهداتی		مدل	
Observations	Model	شبکه عصبی مصنوعی	یادگیری عمیق
آموزش	آزمایش	ANN	DL
Train	Test	ANN	DL
251.92	300.44	310.16	308.69
0	0	3	9
472	475	463	465
143.98	146.84	140.03	138.75
50636	12919	13337	13274
201	43	43	43

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 این که ضریب NSE یک معیار اساسی در واسنجی و ارزیابی مدل‌ها است و بینش‌های ارزشمندی در مورد دقت و قابلیت اطمینان مدل‌های هیدرولوژیکی 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.

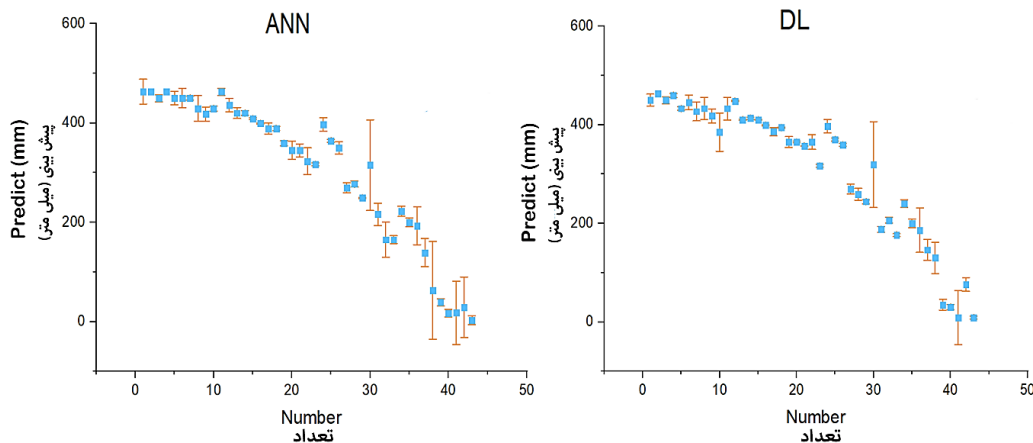
سیستم‌های اندازه‌گیری سطح آب مبتنی بر تصویر، با ارائه داده‌های خام قابل تأیید و تفسیر مجدد، همان‌طور که بیرگاند و همکاران (Birgand et al., 2022) اشاره کردند، مزیت قابل توجهی نسبت به روش‌های سنتی ارائه می‌کنند. همچنین، فرصت منحصر به فردی را برای ارزیابی کامل عملکرد سیستم در طول محدوده اندازه‌گیری و تصمیم‌گیری 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.



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

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 و اسنجی شده از تصاویر هستند که یکی برای نظارت مداوم سطح آب رودخانه و دیگری برای تشخیص رویداد سیل هستند (Fleury *et al.*, 2021; Vandeale *et al.*, 2021). این کار گام مهمی در جهت استفاده خودکار از دوربین‌ها برای نظارت بر سیل و طغیان رودخانه‌ها است.


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; Qiao *et al.*, 2022; Kwon *et al.*, 2023; Muhadi *et al.*, 2021; Vandeale *et al.*, 2022). از سوی دیگر، مطالعاتی که در آن‌ها یادگیری عمیق و دوربین تلفن همراه عملکرد قابل



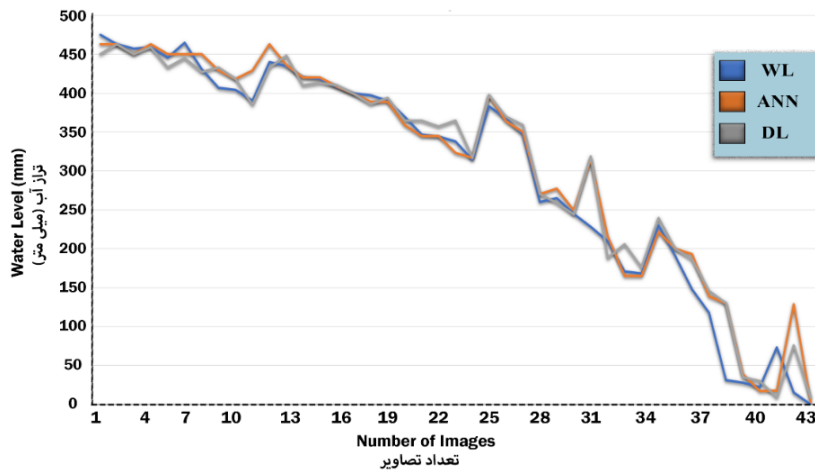
شکل ۱۱- نمودار میله‌ای خطا برای دو مدل ANN و DL  
Figure 11. The error bar chart for two ANN and DL models

وسيله‌ای 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.

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 به سمت دستیابی به حداکثر بازده با حداقل امکانات پیش می‌روند. در این تحقیق برای سادگی، تصاویر با دوربین گوشی هوشمند،



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



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

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 قابل قبول 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 پایش بینی 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 و قدردانی

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.

### 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 این حال، توسعه فناوری‌های 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

## 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>
- Flcury, 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., Warnars, 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](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>

- 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](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>