

Research Paper

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

Erfan Abdi¹, Rasool Jani², and Sabereh Darbandi³

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. <i>J Watershed Manage Res</i> , 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^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 مسؤول: 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 رودخانه ها و مسیل ها توسط وزارت نیرو و سازمان های ذیربط بخش مهمی از مدیریت منابع آب در حوضه آبریز است. از طرفی اندازه گیری سطح آب یک کار حیاتی در پایش هیدرولوژیکی است، اما اغلب با محدودیت هایی مانند کمبود منابع، هزینه های بالا و نیازهای زمانی زیاد مواجه است. این محدودیت ها اغلب منجر به تأخیر در اندازه گیری ها و عدم دقت بالقوه، به ویژه در محیط های دور یا سخت می شوند. به طور کلی، اکثر روش های سنتی دارای خطاها و هزینه های قابل توجهی هستند و تقریباً پایش و کنترل پیوسته را ناممکن می سازند. پیشرفت های اخیر در فناوری منجر به تغییر الگو به سمت سیستم های پردازش تصویر برای نظارت بر سطح آب شده اند. این روش های غیر تماسی به دلیل پتانسیل بالا از نظر دقت، قابلیت اطمینان، مقرون به صرفه بودن و کاهش زمان مورد نیاز مورد توجه قرار گرفته اند. در این تحقیق، با ارائه رویکردی جدید از تلفیق پردازش تصویر و یادگیری ماشین سعی شده است از حداقل امکانات برای کاهش هزینه ها و افزایش عملکرد برای استخراج شاخص های سطح آب و انسجی شده و سطح آب به صورت لحظه ای و خودکار اندازه گیری گردد. این رویکرد مبتنی بر ایجاد مجموعه ای از تصاویر گنچ ثبت شده توسط گوشی هوشمند (که یک دستگاه معمولی با دسترسی آسان است) برای حالت های آب شفاف و کدر، برای آموزش مدل های مبتنی بر یادگیری ماشین ایجاد شده است. بر خلاف روش های سنتی، این روش با اندازه گیری لحظه ای و پیوسته سطح آب موجب عملکرد مطلوب سیستم های ابرسانی و مدیریت بهتر مواقع بحرانی مانند سیل، طغیان رودها و فرسایش می گردد.

مواد و روش ها: این مقاله با ارزیابی یک سیستم تشخیص سطح آب مبتنی بر تصویر با استفاده از یک دوربین گوشی هوشمند استاندارد به این تحقیق روبه رشد کمک می کند. الگوریتم های پردازش تصویر RGB در این تحقیق شامل فیلتر کردن، کاهش نویز، تشخیص رنگ، تغییر اندازه، تبدیل مقیاس خاکستری، تشخیص و تبدیل Hough و طرح ریزی برای به دست آوردن کاراکترهای دیجیتال و خط کش آب که فقط شامل مساحت خطوط مقیاس است، استفاده شدند. همچنین، تمام مراحل ذکر شده و مراحل مدل سازی در نرم افزار ممتیکا (Mathematica) انجام شده است. داده های تجربی شامل ۲۴۴ داده مشاهده ای بودند که به صورت 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 قابلیت های مدل های مختلف یادگیری ماشین، از جمله شبکه های عصبی مصنوعی (ANN) و یادگیری عمیق (DL) در پردازش و تحلیل تصویر، بر روی این مدل ها برای تخمین دقیق سطح آب تمرکز شد. این مطالعه شامل گرفتن تصاویر سطح آب، شناسایی لبه آب در یک خط کش اندازه گیری، و استفاده از این مدل ها برای تخمین سطح آب است. یادگیری ماشین، شاخه ای از هوش مصنوعی، با هدف توسعه سیستم های کامپیوتری با ظرفیت یادگیری از داده ها است که این فرآیند شامل رایانه هایی با یادگیری از طریق تجربه عملی، شروع با سازماندهی داده ها، انتخاب الگوریتم یادگیری ماشینی، وارد کردن داده ها، و توانمندسازی مدل برای یادگیری مستقل الگوها یا تولید پیش بینی، توانایی خودبرنامه ریزی را به دست می آورند. به طور کلی، تجزیه و تحلیل مقایسه ای 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.

یافته ها: 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 زیرمجموعه هایی از مدل های یادگیری ماشین هستند، برای تخمین سطح آب در شرایط گل آلود و شفاف به همراه پردازش تصویر استفاده شد. نتایج نشان دادند که مدل یادگیری عمیق در هر دو شرایط عملکرد قابل قبول و همچنین با توجه به بررسی شاخص های ارزیابی، مدل یادگیری عمیق با کمترین خطای ۲۸/۳۹ میلی متر و بیشترین ضریب تعیین ۰/۹۷۳، به عنوان بهترین مدل برای برآورد سطح آب انتخاب شد. از این رو، با توجه به عملکرد مدل یادگیری عمیق، می توان فرایند بررسی و پایش سطح آب را علاوه بر آزمایشگاه ها در مکان های صعب العبور و بدون هزینه های زیاد جهت اندازه گیری به طور خودکار و پیوسته بررسی نمود و با اتخاذ تصمیمات درست از حوادث احتمالی جلوگیری کرد.

نتیجه گیری: با توجه به مشکلات اندازه گیری دستی و پایش میدانی، پایش خودکار و مستمر سطح آب توسط انسان دشوار و حتی غیرممکن می شود. با وجود این موانع، امروزه علاقه محققان به سیستم های پردازش تصویر با پیشرفت تکنولوژی افزایش یافته است. با توجه به کارهای انجام شده برای تشخیص و برآورد سطح آب، امروزه اکثر روش ها به سمت دستیابی به حداکثر بازده با حداقل امکانات پیش می روند. در نهایت، دو روش برای استخراج اطلاعات از تصاویر دیجیتال برای سیستم های پایش سطح آب مقایسه می شوند. تکنیک های ترکیبی برای تشخیص سطح آب در تصاویر شفاف و گل آلود بر اساس ارزیابی بصری و دقت آماری مقایسه شدند. بر اساس نتایج تجربی، این تکنیک ها و مدل ها همگی قادر به استخراج اطلاعات سطح آب از تصویر بودند. تکنیک پردازش تصویر و مدل یادگیری عمیق برای تشخیص و تخمین ویژگی های 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 پیشرفت های روز افزون در زمینه پردازش تصاویر و یادگیری ماشین، تحقیقات آینده می توانند افزودن حالت های مختلف آب و ایجاد مدل هایی بر پایه الگوریتم های جدید یادگیری ماشین و هوش مصنوعی باشند.

واژه های کلیدی: سطح آب، شبکه های عصبی مصنوعی، مدل سازی، مطالعه آزمایشگاهی، یادگیری عمیق

مقدمه

آب منطقه در گرو اندازه گیری مستمر این پارامترها است که کاری زمان بر و پرهزینه است. از طرفی، اندازه گیری مداوم سطح آب در اکثر ایستگاه های هیدرومتری گاهی به دلیل وجود شرایط بحرانی اندازه گیری به تعویق می افتد و یا دستگاه های

مطالعه و پایش سطح آب رودخانه ها و مسیل ها توسط وزارت نیرو و سازمان های مرتبط بخش مهمی از مدیریت منابع آب در حوضه آبریز را تشکیل می دهد. 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 واسنجی 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 گویی 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 سائو کارلوس برزیل، تصاویر را با استفاده از دوربین گویی 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^۱ واقع در چانگ نیونگ گان^۲ و جئونگ سانگ نامدو^۳ کره، از مدل های شبکه عصبی مصنوعی (ANN)^۴، درخت تصمیم (DT)^۵، جنگل تصادفی (RF)^۶ و ماشین بردار پشتیبان (SVM)^۷ استفاده کردند که مدل جنگل تصادفی نتیجه مطلوبی داشت. موهادی و همکاران (Muhadi et al., 2020) در رودخان های در منطقه سیل خیز سلانگور^۸ مالزی در دو حالت عادی و سرریز عکس گرفتند و تصاویر را به سه منطقه

⁵ Decision tree

⁶ Random forest

⁷ Support vector machine

⁸ Selangor

¹ Opu

² Changnyong-gun


³ Jeongsang Namdo

⁴ 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 می دهند.

مجموعه تصاویر
بعد از پیش پردازش تصاویر، به منظور ورودی جهت مدل سازی با مدل های شبکه عصبی مصنوعی و یادگیری عمیق، داده های تصویری شامل ۲۴۴ داده مشاهده ای 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- تقسیم بندی 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 گل آلود با استفاده از دوربین گوسی هوشمند در موقعیت ثابت گرفته شده اند. نمونه ای 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 خط کش اندازه گیری و سطح آب هستند. گام دوم) برای بهبود تشخیص سطح آب فضاهای غیر از خط کش به گونه ای برش داده شدند که شامل خط کش و سطح آب باشند. گام سوم) برای یکسان سازی همه تصاویر، ابعاد تصاویر به 650×900 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 می کند (Kumar & Verma, 2010). فرآیند تبدیل یک تصویر رنگی به تصویر با مقیاس خاکستری، پردازش مقیاس خاکستری تصویر نامیده می شود و می تواند کارایی اجرای الگوریتم های بعدی را تا حد زیادی بهبود بخشد (2019 Gu et al.). گام چهارم) به همین منظور تصاویر از حالت رنگی به خاکستری تغییر یافتند. گام پنجم) در این مرحله، جهت تشخیص بهتر تغییرات رنگ، قسمتی از تصویر که شامل خط کش نمی شود برش داده شد و برای شناسایی مناطقی که تغییر رنگ رخ داده بود، پروفایل های میانگین ستونی تغییرات رنگ برای تصاویر ایجاد شدند. هر جایی که تغییر رنگ در تصویر واضح باشد، شکستگی رخ می دهد، که در شکل ۴ نشان داده شده است.



شکل ۴- نمونه ای 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 به صورت عددی و با احتمال بیشتری تخمین زده شود. نمونه ای از تصویر گرفته شده و تخمین سطح آب در شکل ۵ آمده است.

پس از انجام مراحل فوق، گام ششم) سطح آب روی خط کش اندازه گیری مشخص می گردد. گام هفتم) سپس این تصاویر به عنوان داده های ورودی برچسب گذاری شده و به عنوان ورودی به مدل های ANN و DL داده می شوند تا



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). هنگامی که نورون‌ها اطلاعاتی را از ورودی‌های مختلف دریافت می‌کنند، از طریق




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 روش هایی را برای طبقه بندی میلیون ها تصویر به تعداد کلاس های کمتر ارائه می کند، که درصد خطا را کاهش می دهد (Krizhevsky *et al.*, 2017). از طرفی، معماری و طراحی های مختلفی را می توان برای بهینه سازی محاسباتی برای روش های یادگیری عمیق برای تشخیص تصویر استفاده کرد (Szegedy *et al.*, 2015). در شکل ۸، مدل تصویری برای یادگیری عمیق آمده است. مدل های یادگیری عمیق معمولاً از اجزای کلیدی مانند لایه ورودی، لایه پنهان، توابع فعال سازی، وزن ها و جهت گیری ها، لایه خروجی، الگوریتم های بهینه سازی و تکنیک های منظم سازی تشکیل می شوند. ترکیب این مؤلفه ها به صورت ساختار یافته به مدل های یادگیری عمیق اجازه می دهد تا الگوها و روابط پیچیده در داده ها را به طور مؤثر یاد بگیرند و آن ها 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 شبکه های عصبی در یادگیری عمیق، یک حوزه تخصصی در یادگیری ماشین، امکان پذیر می شود (Choubin & Bashirgonbad, 2023). یادگیری عمیق به مدل های محاسباتی که از لایه های پردازشی چندگانه تشکیل شده اند اجازه می دهد تا نمایش داده ها را با سطوح انتزاعی متعدد بیاموزند (LeCun *et al.*, 2015). روش های یادگیری عمیق، مانند شبکه های عصبی مصنوعی عمیق، از لایه های پردازشی متعدد برای کشف الگوها و ساختار در مجموعه های داده بسیار بزرگ استفاده می کنند و هر لایه مفهومی را از داده هایی که لایه های بعدی بر روی آن ها ساخته می شوند، یاد می گیرد. هرچه سطح بالاتر باشد، مفاهیمی که آموخته می شوند انتزاعی تر هستند (Rusk, 2016). این شبکه های عصبی، چندین لایه از گره های به هم پیوسته دارند که هر لایه بر روی آخرین لایه برای اصلاح و بهینه سازی پیش بینی ها و طبقه بندی ها ساخته شده است. یادگیری عمیق به پردازش داده های قبلی بستگی ندارد و به طور خودکار ویژگی ها



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 شده‌است. نمودار میله‌ای خطا برای هر مدل در شکل ۱۱ آمده‌است.

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

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

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

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 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


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 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

مشاهداتی Observations		مدل Model	
آموزش Train	آزمایش Test	شبکه عصبی مصنوعی ANN	یادگیری عمیق 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

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.

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.




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.*, 2016). 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; Kwon *et al.*, 2023; Muhadi *et al.*, 2021; Qiao *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

وسایلهای 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 مشاهداتی 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 پایش‌بینی 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>
- 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.
- Heddarn, 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>