

Comparing the Efficacy of Deep Learning Models and Convolutional Neural Network for Water Level Estimation Using Smartphone, and Image Processing

E. Abdi^{1*}, R. Jani², and S. Darbandi³

Abstract

Water level estimation is essential for understanding and managing water resources, predicting and mitigating flood effects, and water resource management decisions but it is often hindered by limited resources, capitals and time. This study investigates the performance of a non-contact, image-based water level measurement system using advances in smartphone imaging technology. For this purpose, a smartphone equipped with a camera was used to record the desired images. The images were then processed by image processing to identify and measure the water level. The core of this study involved the development and comparison of two computational models: deep learning (DL) and convolutional neural networks (CNN). These models were used to estimate the water level based on the processed image data. The results showed a different degree of accuracy among the models; the CNN model showed better performance than the DL, which had the lowest root mean square error of 24.36 mm. In contrast, the DL model with the root mean square error of 28.39 mm showed that the relative effectiveness of the convolutional neural network in this study is better than deep learning in terms of accuracy and high reliability. The study showed that it is possible to monitor and control the water level in remote and difficult places completely automatically without the need for relevant personnel.

Keywords: Non-Contact Measurement, Hydrological Monitoring, Image Analysis, Convolutional Neural Networks, Computational Hydrology.

Received: February 21, 2024

Accepted: June 22, 2024

مقایسه کارایی مدل‌های یادگیری عمیق و شبکه عصبی کانولوشن برای تخمین سطح آب با استفاده از پردازش تصویر و تلفن هوشمند

عرفان عبدی^{۱*}، رسول جانی^۲ و صابره دربندی^۳

چکیده

تخمین سطح آب برای درک و مدیریت منابع آب، پیش‌بینی و کاهش اثرات سیلاب و اطلاع‌رسانی برای تصمیمات مدیریت منابع آب ضروری است، اما اغلب با محدودیت‌هایی مانند کمبود منابع، هزینه‌های بالا و نیازهای زمانی زیاد مانع از انجام آن می‌شود. این مطالعه کارایی یک سیستم اندازه‌گیری سطح آب بدون تماس و مبتنی بر تصویر را با استفاده از پیشرفت‌ها در فناوری تصویربرداری تلفن هوشمند را بررسی می‌کند. به این منظور، از یک تلفن هوشمند که مجهز به دوربین بوده، تصاویر مورد نظر ثبت و سپس جهت شناسایی و اندازه‌گیری سطح آب از پردازش تصویر استفاده شد. هسته اصلی این مطالعه شامل توسعه و مقایسه دو مدل محاسباتی بود: یادگیری عمیق (DL) و شبکه‌های عصبی کانولوشن (CNN). این مدل‌ها وظیفه تخمین سطح آب را بر اساس داده‌های تصویری پردازش شده داشتند. نتایج نشان‌دهنده درجه متفاوتی از دقت در بین مدل‌ها بود، مدل CNN عملکرد بهتری را نسبت به DL نشان داد که از کمترین میانگین مربع خطای ریشه ۲۴/۳۶ میلی‌متر برخوردار بود. در مقابل، مدل DL با ریشه میانگین مربع خطای ۲۸/۳۹ میلی‌متر نشان داد که اثربخشی نسبی شبکه عصبی کانولوشن در این مطالعه از لحاظ دقت و قابلیت اطمینان بالا بهتر از یادگیری عمیق است. به این ترتیب می‌توان پیش و کنترل سطح آب را در نقاط سخت و دشوار بدون نیاز به پرسنل مربوطه و کاملاً خودکار انجام داد.

کلمات کلیدی: اندازه‌گیری بدون تماس، پیش‌بینی هیدرولوژیک، تحلیل تصویر، شبکه‌های عصبی کانولوشن، هیدرولوژی محاسباتی.

تاریخ دریافت مقاله: ۱۴۰۲/۱۲/۲

تاریخ پذیرش مقاله: ۱۴۰۳/۴/۲

1- M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran. Email: erabdi78@gmail.com

2- Assistant Professor, Department of Civil Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran. Email: Jani@iaut.ac.ir

3- Associate Professor, Department of Water Engineering, University of Tabriz, Tabriz, Iran. Email: sdarbandi.tabrizu@yahoo.com

*- Corresponding Author

Doi: [10.22034/IWRR.2024.445181.2744](https://doi.org/10.22034/IWRR.2024.445181.2744)

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.

۳- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان پائیز ۱۴۰۳ امکانپذیر است.



(Kharade et al., 2017) است که از یادگیری ماشین برای تجزیه و تحلیل تصاویر در MATLAB برای تعیین سطح آب در مخازن و کانالها استفاده کردند. به طور مشابه، Zhang et al. (2019) ترکیبی از تصویربرداری مادون قرمز نزدیک (NIR^3) و مرئی (VIS^4) با روش‌های محاسبه پیشرفته برای اندازه‌گیری سطح آب در رودخانه یانگلو چین، تحت شرایط آب و هوایی متفاوت بهره بردند. Kou et al. (2022) جهت اندازه‌گیری سطح آب به صورت خودکار از فناوری نگاشت پرسپکتیو معکوس (IPM^5) برای تصحیح نویزهای تصویر و کاهش خطای بهره بردند. Chaudhary et al. (2019) برای پیش‌بینی وقوع سیل با استفاده از پردازش تصویر و یادگیری عمیق توانستند تصاویر ثبت شده را کلاس‌بندی کرده و تراز سطح آب را تخمین بزنند. Fleury et al. (2020) برای پایش و کنترل خودکار سطح تراز آب در حوضه رودخانه مادیرا^۶ در برزیل از روش‌های پردازش تصویر و شبکه عصبی کانولوشن استفاده کردند.

دستگاه‌ها و مدل‌های مختلفی در مطالعات متعدد با تمرکز بر پایش سطح آب به کار گرفته شده‌اند. نمونه‌هایی شامل اندازه‌گیری تغییرات سطح آب با دستگاه‌های V-IoT (Sabbatini et al., 2021)، استفاده از دوربین و مدل‌های یادگیری عمیق برای تعیین سطح آب (Muhadi et al., 2021; Vandaele et al., 2021)، اندازه‌گیری سطح آب مبتنی بر رادار (Hies et al., 2012)، استفاده از کاربرد الگوریتم‌های تلفیق یادگیری ماشین و پردازش تصویر مانند YOLOv5s (Qiao et al., 2022)، نظارت در جریانهای متلاطم در رودخانه و سیل با استفاده از دوربین‌ها (Noto et al., 2020)، و تشخیص سطح آب مخزن کشاورزی با استفاده از داده‌های دوربین مدار بسته و الگوریتم U-Net (Kwon et al., 2023).

هدف این مقاله تحقیقاتی استفاده از یک دوربین گوشی هوشمند معمولی و ارزیابی اثربخشی یک سیستم تشخیص سطح آب مبتنی بر تصویر و افزودن دانش در مورد این موضوع است. تمرکز اصلی ما در استفاده از قابلیت‌های مدل‌های مختلف یادگیری ماشین، به ویژه یادگیری عمیق (DL^7) و شبکه‌های عصبی کانولوشن (CNN^8)، برای تخمین دقیق سطح آب از طریق پردازش و تحلیل تصویر است. این تحقیق مبتنی بر گرفتن تصاویر از سطوح مختلف آب، تعیین مرز آب بر روی یک اشل اندازه‌گیری و استفاده از این مدل‌ها برای محاسبه سطح تراز آب است و ارائه یک تحلیل مقایسه‌ای از عملکرد این مدل‌ها، با هدف نشان دادن اینکه چگونه ترکیب پردازش تصویر و یادگیری ماشین می‌تواند بر موانع سنتی اندازه‌گیری سطح آب در مطالعات هیدرولوژیکی غلبه کند. علاوه بر مزیت‌های این روش،

اندازه‌گیری دقیق سطح آب در رودخانه‌ها و کانال‌ها سنگ بنای مدیریت مؤثر منابع آب است. این وظیفه که اغلب توسط نهادهایی مانند وزارت نیرو نظارت می‌شود، برای کنترل سیل، مدیریت آبیاری و حفظ اکوسیستم حیاتی است. تکنیک‌های اندازه‌گیری سنتی در حالی که به طور گسترده مورد استفاده قرار می‌گیرند با چالش‌هایی از جمله هزینه‌های عملیاتی بالا، حساسیت به شرایط محیطی، و نیاز به نگهداری منظم و کالیبراسیون مجدد مواجه هستند. این محدودیت‌ها اغلب منجر به تأخیر در اندازه‌گیری و عدم دقت احتمالی، به ویژه در محیط‌های دور یا سخت می‌شود. پیشرفتهای اخیر در فناوری منجر به تغییر الگو به سمت سیستم‌های پردازش تصویر برای نظارت بر سطح آب شده است. این روش‌های غیر تماسی به دلیل پتانسیل بالا برای دقت، قابلیت اطمینان، مقرون‌به‌صرفه بودن و کاهش زمان مورد نیاز، مورد توجه قرار گرفته‌اند. مطالعات در تنظیمات هیدرولوژیکی متنوع، کاربرد این تکنیک‌ها را نشان داده است. به عنوان مثال، Ortigosa et al. (2015) از دوربین‌های گوشی‌های هوشمند در سائو کارلوس^۹، برزیل، برای تجزیه و تحلیل سطح آب استفاده کردند، در حالی که Sabbatini et al. (2021) از سیستم‌های دوربین در سنگال، ایتالیا، برای نظارت بر سطح آب در طول شرایط سیل استفاده کرده، سپس از طبقه‌بندی تصویر و گیج اندازه‌گیری برای تفسیر داده‌ها استفاده کردند.

روش‌های هوش مصنوعی (AI^2) مبتنی بر چندین فرض است که توسعه و کاربرد آنها را هدایت می‌کند. این مفروضات را می‌توان در سه حوزه اصلی داده‌ها، الگوریتم‌ها و ارزیابی دسته‌بندی کرد. روش‌های هوش مصنوعی بر این فرض تکیه می‌کنند که داده‌های مورد استفاده برای آموزش و آزمایش آنها معرف، دقیق و کامل هستند. این فرض بسیار مهم است؛ زیرا مدل‌های هوش مصنوعی از داده‌هایی که بر روی آنها آموزش دیده‌اند یاد می‌گیرند، و اگر داده‌ها مغرضانه، ناقص یا نادرست باشند، مدل‌های هوش مصنوعی ناقص یا نادرست خواهند بود. بنابراین، کاوش، پیش‌پردازش و اعتبارسنجی داده‌ها گام‌های اساسی در توسعه هوش مصنوعی هستند تا اطمینان حاصل شود که داده‌ها با کیفیت بالا و عاری از خطای قابل ملاحظه هستند (Kim et al., 2022).

به موازات توسعه سیستم‌های پردازش تصویر، یادگیری ماشینی به عنوان یک ابزار قدرتمند برای تجزیه و تحلیل و تفسیر داده‌های هیدرولوژیکی ظاهر شده است. از طرفی ادغام یادگیری ماشین با پردازش تصویر راه‌های جدیدی را برای تخمین سطح آب باز کرده است. تحقیقات قابل توجهه در این زمینه شامل کارهای

محدودیت‌هایی مانند تلاطم سطح آب (موج)، کدورت آب و میزان نور محیط می‌توانند بر دقت تشخیص و تخمین سطح آب اثرگذار باشند.

۲- مواد و روش‌ها

در مطالعه حاضر مرحله اولیه شامل پردازش تصویر است. با توجه به موقعیت ثابت دوربین، که در جهت‌گیری تصاویر گرفته شده ثابت است. الگوریتم‌های پیش پردازش اعمال شده بر روی تصاویر RGB شامل چندین فرآیند کلیدی بودند: فیلتر کردن برای افزایش وضوح تصویر، کاهش نویز برای به حداقل رساندن مصنوعات، تشخیص رنگ برای شناسایی ویژگی‌های مرتبط، تغییر اندازه تصویر برای یکنواختی، تبدیل مقیاس خاکستری برای ساده‌سازی تحلیل. پس از پیش پردازش، مرحله تشخیص هوشمند است که برای تفسیر کاراکترهای دیجیتال و کمی کردن سطح آب بسیار مهم است. برای رسیدن به این هدف، ترکیبی از مدل‌های DL و CNN برای شناسایی و تفسیر کاراکترهای عددی روی خط‌کش اندازه‌گیری طراحی شده‌اند. علاوه بر این، از روش پیمایش پیکسلی برای شناسایی خط مقیاس استفاده شد که یک جزء حیاتی در تعیین سطح آب است. در نهایت، سطح آب با ترکیبی از رویکردهای ریاضی و احتمالی مشخص شد. این فرآیند شامل ادغام داده‌های به‌دست‌آمده از مرحله تشخیص هوشمند و استفاده از الگوریتم‌های ریاضی برای تعیین دقیق سطح آب بود.

۲-۱- مجموعه تصاویر

در این مطالعه از مجموعه داده ای متشکل از ۲۴۴ تصویر مشاهده‌ای که با استفاده از دوربین تلفن همراه گرفته شده بود استفاده شد. این تصاویر به دو مجموعه مجزا تقسیم شدند: ۲۰۱ تصویر برای آموزش و ۴۳ تصویر برای آزمون. این بخش برای بهینه‌سازی فرآیندهای یادگیری و اعتبارسنجی مدل طراحی شده است. برای اطمینان از تجزیه و تحلیل جامع در شرایط مختلف، تصاویر بر اساس سطوح آب، به‌عنوان مثال بالا، متوسط و کم طبقه‌بندی شدند.

جدول ۱ که در زیر ارائه شده است، توزیع تصاویر را در سطوح مختلف آب برای هر دو مرحله آموزش و آزمایش نشان می‌دهد. این طبقه‌بندی در توسعه و اعتبارسنجی دو مدل یادگیری ماشین: DL و CNN بسیار مفید بود. این مدل‌ها با استفاده از داده‌های به دست آمده از تجزیه و تحلیل تصویر، همانطور که قبلاً در بخش مواد و روش‌ها مشخص شد، آموزش و آزمایش شدند.

تنظیمات آزمایشی که در بخش روش‌ها به تفصیل شرح داده شده است، به صورت بصری در شکل ۱ نشان داده شده است. شکل ۱

محل تصویربرداری (آزمایشگاه هیدرولیک دانشگاه تبریز)، ابعاد کانال و تنظیمات آزمایشگاهی را نشان می‌دهد. شکل ۲ منتخبی از تصاویر ثبت شده در فلوم آزمایشگاه را در حالت‌های مختلف، مانند شرایط صاف و کدر نشان می‌دهد. این تصاویر نگاهی اجمالی به انواع سناریوهای آزمایش شده برای اطمینان از عملکرد مدل‌ها ارائه می‌دهند.

Table 1- The number of images at different levels
جدول ۱- تعداد تصاویر در سطوح مختلف

Level	Train (image)	Test (image)
High	60	19
Medium	60	12
Low	81	12
Total	201	43

۲-۲- تشخیص سطح آب

در این تحقیق، تصاویر سطح آب در دو حالت تمیز و گل آلود با استفاده از دوربین تلفن هوشمند با وضوح ۵۰ مگاپیکسل در ابعاد مختلف ثبت شد. فرآیند تشخیص سطح آب و پردازش تصویر شامل مراحل زیر است:

مرحله ۱) ضبط تصویر: تصاویر مورد نیاز با استفاده از یک تلفن هوشمند با کانال‌های رنگی RGB گرفته شد. این تصاویر در درجه اول از دو جزء تشکیل شده‌اند: خط‌کش اندازه‌گیری و سطح آب. برای افزایش دقت تشخیص سطح آب، قسمت‌های غیر از خط‌کش برش داده شد. بنابراین، تصاویر به گونه‌ای برش یافتند که فقط شامل خط‌کش اندازه‌گیری و سطح آب باشند. سپس همه تصاویر به ابعاد یکسان ۹۰×۶۵۰ پیکسل تغییر یافتند.

مرحله ۲) تبدیل مقیاس خاکستری: در مدل RGB، رنگ یک پیکسل در موقعیت مکانی (x, y) با اجزای R، G و B آن تعریف می‌شود (Kumar & Verma, 2010). تبدیل این تصاویر رنگی به مقیاس خاکستری یک گام مهم در ساده‌سازی مراحل پردازش بعدی و بهبود کارایی الگوریتم است (Gu et al., 2019). این تبدیل، به ویژه در کاهش نویز و افزایش وضوح تغییرات رنگ در تصاویر بسیار کارآمد است.

مرحله ۳) شناسایی تغییر رنگ: قسمت‌های غیر خط‌کش تصاویر برای تمرکز بر روی نواحی که شامل تغییر رنگ شدید است کوتاه شدند. سپس سطوح تصویر به گونه‌ای تنظیم شد که محدوده‌ای از صفر تا ۱ را دربر بگیرد.

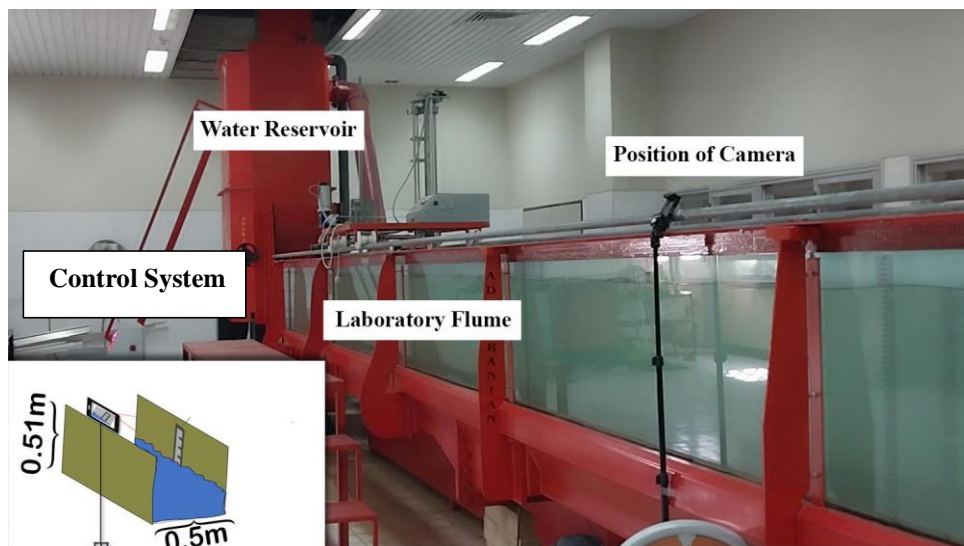


Fig. 1- The experimental settings and dimensions of the flume in the hydraulic laboratory of University of Tabriz

شکل ۱- تصویری از تنظیمات آزمایشی و ابعاد فلوم در آزمایشگاه هیدرولیک دانشگاه تبریز




Fig. 2- Sample image of a flume with clear water and murky water (with sediment)

شکل ۲- نمونه تصویر از فلوم با آب صاف و آب کدر (دارای رسوب)

خطا تا حد ممکن کاهش می‌یابد (Sauvola and Pietikäinen, 2000). تصویر دوتایی شده، با نمایش جلوه سیاه و سفید واضح، شناسایی قله‌ها در مقادیر مقیاس خاکستری را تسهیل می‌کند.

مرحله ۵) تعیین سطح آب: پس از طی مراحل فوق، سطح آب روی گنج تعیین شد (شکل ۳ ب). سپس این تصاویر پردازش شده برچسب‌گذاری شدند و به عنوان داده‌های ورودی برای مدل مورد استفاده قرار گرفتند، که سطح آب را با درجه احتمال بیشتری تخمین زدند. نمونه‌ای از فرآیند تخمین سطح آب در شکل ۳ پ) نشان داده شده است.

سپس پروفایل‌های میانگین ستونی برای تصاویر ایجاد شد تا مناطقی با تغییرات رنگ قابل توجه شناسایی شوند. همانطور که در شکل ۳ الف) آمده، یک تفاوت غلظتی بین میانگین‌های متحرک برای شناسایی نقاط اولین شیب در این پروفایل‌ها استفاده شد که نشان‌دهنده تغییرات رنگ شدید است.

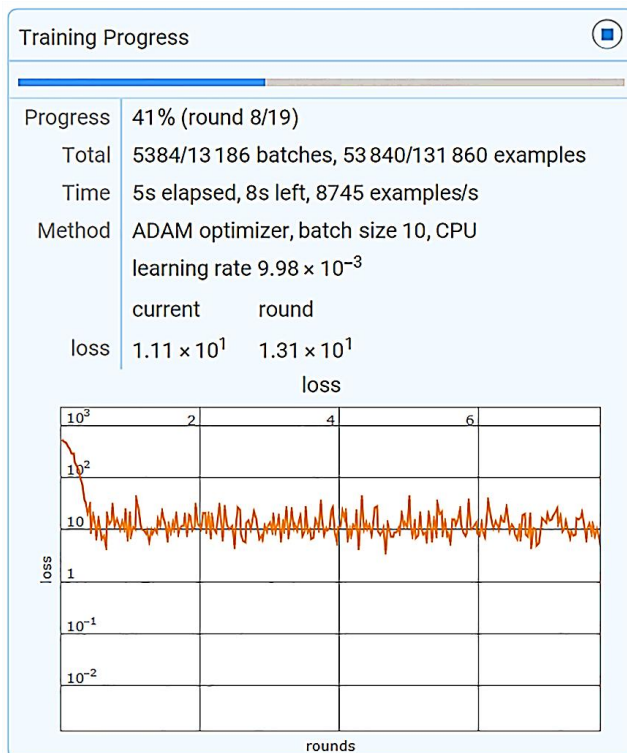
مرحله ۴) دوتایی کردن^۹ و تشخیص پیک: به دلیل وجود آب گل آلود، تغییرات رنگی قوی در تصاویر می‌تواند منجر به خطاهایی در تشخیص شود. با استفاده از روش دوتایی کردن تصویر، تشخیص مقدار آستانه برای محاسبه اولین پیک از لحاظ تغییر رنگ پیکسل‌ها آسان شده و

معماری شبکه‌های یادگیری عمیق شامل چندین لایه از گره‌های به هم پیوسته است که هر لایه پیچیدگی پیش‌بینی‌ها و طبقه‌بندی‌ها را افزایش می‌دهد. به طور خلاصه، اجزای یادگیری عمیق شامل شبکه‌های عصبی، لایه‌ها، گره‌ها، توابع فعال‌سازی، وزن‌ها و بایاس‌ها، تکنیک‌های بهینه‌سازی و شبکه‌های عصبی عمیق می‌شوند. توابع فعال‌سازی غیرخطی بودن را به شبکه عصبی وارد می‌کند و مدل را قادر می‌سازد تا الگوها و روابط پیچیده در داده‌ها را بیاموزد. توابع فعال‌سازی رایج عبارتند از واحد خطی اصلاح شده^۱ و توابع Sigmoid. یکی از نقاط قوت اصلی یادگیری عمیق استقلال آن از پردازش داده‌های قبلی است؛ زیرا به طور خودکار ویژگی‌ها را مستقیماً از داده‌ها استخراج می‌کند و یاد می‌گیرد (Rusk, 2016). این قابلیت به طور موفقیت‌آمیزی در زمینه‌هایی مانند طبقه‌بندی تصاویر به کار گرفته شده است، به طوری که یادگیری عمیق به طور قابل توجهی نرخ خطا را در دسته‌بندی میلیون‌ها تصویر در کلاس‌های متعدد کاهش داده است (Krizhevsky et al., 2017). معماری‌های مختلف ساختاری برای بهینه‌سازی هزینه‌های محاسباتی و افزایش کارایی در تشخیص تصویر از مزیت یادگیری عمیق است (Szegedy et al., 2015). در این مطالعه، یک مدل یادگیری عمیق با ساختار و مجموعه‌ای از پارامترهای خاص برای تخمین سطح آب از تصاویر گیج اندازه‌گیری طراحی شد. شکل ۴ پیکربندی این مدل یادگیری عمیق را نشان می‌دهد و انواع لایه‌های بکار گرفته شده و اشکال خروجی مربوطه آن‌ها را شرح می‌دهد.

پس از تشخیص موفقیت‌آمیز لایه سطح آب در تصویر گیج، این مدل‌های یادگیری ماشینی مقدار سطح آب را تخمین می‌زنند. این تخمین بر اساس تجزیه و تحلیل قرائت‌های دیجیتال گیج و خطوط مقیاس مربوطه است که از تعیین دقیق و خودکار سطح آب اطمینان حاصل می‌کند. این روش نشان‌دهنده پیشرفت قابل توجهی در پایش سطح آب است که جایگزینی ساده‌تر، مقرون به صرفه‌تر و دقیق‌تر برای روشهای اندازه‌گیری سنتی ارائه می‌دهد.

۲-۴- یادگیری عمیق (DL)

یادگیری عمیق که زیرشاخه‌ای از یادگیری ماشینی است، در حل مسائل پیچیده از طریق شبکه‌های عصبی فوق پیشرفته بسیار مهم است. این شامل استفاده از مدل‌های محاسباتی با لایه‌های پردازش چندگانه است که امکان یادگیری داده‌ها را در سطوح مختلف افزایش می‌دهد (LeCun et al., 2015). روش‌های یادگیری عمیق، مانند شبکه‌های عصبی مصنوعی عمیق، با توجه به ظرفیت خود برای کشف الگوها و ساختارها در مجموعه داده‌های گسترده متمایز می‌شوند. هر لایه در این شبکه‌ها مفهومی را می‌آموزد که توسط لایه‌های بعدی اصلاح و ساخته می‌شود و از مفاهیم پایه به مفاهیم انتزاعی فزاینده پیش می‌رود (Rusk, 2016).



Layer (Type)	Output Shape
Input	Array (size: $3 \times 128 \times 128$)
Linear Layer	Vector (size: 200)
Linear Layer	Vector (size: 491)
Linear Layer	Vector (size: 32)
Linear Layer	Vector (size: 491)
Softmax Layer	Vector (size: 491)
Output	Class

Fig. 4- Structure and executive characteristics of the training data modeling for the deep learning model in this research

شکل ۴- ساختار و مشخصات اجرایی مدل‌سازی داده‌های آموزش برای مدل یادگیری عمیق در این پژوهش

۲-۵- شبکه عصبی کانولوشن (CNN)


یادگیری را کاهش داده و به جلوگیری از برازش بیش از حد کمک می‌کنند. فیلتر که با ارتفاع (FH) و عرض (FW) مشخص می‌شود، برای استخراج ویژگی‌ها روی تصاویر ورودی اعمال می‌شود (Krizhevsky et al., 2017). لایه‌گذاری^{۱۳}، شامل اضافه کردن مقادیر صفر در اطراف تصویر، برای حفظ اطلاعات و ویژگی در مرزهای تصویر استفاده می‌شود (Dumoulin & Visin, 2016). پارامتر گام^{۱۴} میزان بزرگی مراحل فیلترها را هنگام انجام فرآیند پیچیدگی کنترل می‌کند (Acharya et al., 2017). در این مطالعه، CNN با پارامترها و لایه‌های ساختاری خاص، همانطور که در شکل ۵ نشان داده شده است، طراحی شد. این طراحی متناسب با هدف بهینه‌سازی توانایی شبکه برای تخمین دقیق سطح آب از تصاویر ورودی است.

شبکه عصبی کانولوشن به دلیل مهارت خود در تشخیص الگو در تصاویر و استفاده از لایه‌های کانولوشن برای نمایش ویژگی‌های تصویر مشهور است (Deng et al., 2009). CNN به دلیل عملکرد استثنایی خود در زمینه‌های مختلف به رسمیت شناخته شده است. با این حال، بسیاری از مطالعات، در درجه اول، بر آموزش مدل‌های عمیق CNN برای مشکلات خاص تمرکز دارند، که اغلب محدودیت‌های داده‌های محدود و ماهیت زمان بر این فرآیند را نادیده می‌گیرند (Li et al., 2017). برای کارهایی که شامل تجزیه و تحلیل تصویر و ویدئو می‌شود، CNN به طرز ماهرانه‌ای برای پردازش ساختارهای دو بعدی، مانند تصاویر یا سیگنال‌های گفتاری، طراحی شده است.

۲-۶- ارزیابی عملکرد مدل‌ها

در این تحقیق جهت بررسی عملکرد دو مدل انتخابی، از شاخص‌های آماری ریشه میانگین مربعات خطا^{۱۵} (RMSE)، ضریب تعیین^{۱۶} (R^2)، خطای نش- ساتکلیف^{۱۶} (NSE) استفاده شد.

معماری یک لایه کانولوشن با چندین پارامتر تعریف می‌شود: لایه‌های کانولوشن، توابع فعال‌سازی، لایه‌های ترکیبی^{۱۱}، لایه‌های کاملاً متصل^{۱۲}، اندازه فیلتر، لایه‌بندی و گام. لایه‌های ترکیبی برای نمونه‌برداری از ویژگی‌های تصاویر استفاده می‌شوند، تعداد پارامترهای



Layer (Type)	Output Shape
Input	Array (size: $3 \times 128 \times 128$)
Convolution Layer	Array (size: $20 \times 126 \times 126$)
Ramp	Array (size: $20 \times 126 \times 126$)
Pooling Layer	Array (size: $20 \times 63 \times 63$)
Convolution Layer	Array (size: $30 \times 61 \times 61$)
Ramp	Array (size: $30 \times 61 \times 61$)
Pooling Layer	Array (size: $30 \times 30 \times 30$)
Flatten Layer	Vector (size: 27000)
Linear Layer	Vector (size: 400)
Ramp	Vector (size: 400)
Linear Layer	Vector (size: 491)
Softmax Layer	Vector (size: 491)
Output	Class

Fig. 5- Structure and executive characteristics of the training data modeling for the convolutional neural network model in this research

شکل ۵- ساختار و مشخصات اجرایی مدل‌سازی داده‌های آموزش برای مدل شبکه عصبی کانولوشن در این پژوهش

با توجه به جدول ۲ و معیارهای ارزیابی استفاده شده می‌توان به این نتیجه رسید که مدل DL با خطای ۲۸/۳۹ میلی‌متر و ضریب تعیین ۰/۹۴۶ عملکرد قابل قبولی در تعیین سطح آب دارد. اما در مقایسه با مدل CNN که دارای خطای ۲۴/۳۶ میلی‌متر و ضریب تعیین ۰/۹۷۲ است از عملکرد ضعیفی برخوردار بوده و دقت پایینی دارد. همچنین، از شکل ۶- (ب) می‌توان نتیجه گرفت که مدل DL در ترازهای بالا و پایین خطای بیشتری نسبت به تراز متوسط دارد. از طرفی مدل CNN در دو تراز بالا و متوسط دقت نسبتاً بالایی داشته ولی در ترازهای پایین همانند مدل DL دارای خطا می‌باشد. در کل مدل CNN با ساختار پیشرفته نسبت به مدل DL از قابلیت اطمینان بالایی برخوردار بوده و در تحقیقات آتی می‌تواند در این زمینه مفید واقع شود.

با توجه به چالش‌های اندازه‌گیری دستی و پایش میدانی، پایش خودکار و مداوم سطح آب اهمیت فزاینده‌ای پیدا می‌کند. این مطالعه با ساده‌سازی فرآیند، با استفاده از دوربین گوشی‌های هوشمند برای ثبت تصویر، به این زمینه کمک می‌کند. با استفاده از نرم‌افزارهای ریاضی و توسعه مدل‌های DL و CNN، سطح آب با دقت بالایی شناسایی و تخمین زده شد. سیستم‌های اندازه‌گیری سطح آب مبتنی بر تصویر قابل مقایسه با تکنیک‌های مرسوم، مزیت قابل توجهی دارند؛ زیرا نتایج قابل فهمی را ارائه می‌دهند که می‌توانند به راحتی تأیید و تفسیر شوند (Birgand et al., 2022). ماهیت دینامیکی سطح آب مستلزم نظارت مستمر و کنترل شده است که می‌تواند زمان‌بر و پرهزینه باشد. با این پیشرفت چشمگیر در پایش سطح آب، حتی افراد بی‌تجربه نیز می‌توانند ارزیابی‌های کامل را انجام دهند و در صورت نیاز تعمیر و نگهداری را انجام دهند.

تاکنون مطالعات اثربخش و قابل توجهی در استفاده از مدل CNN و دوربین‌های تلفن همراه انجام شده است. Vandaele et al. (2023) با به کارگیری مدل CNN برای تخمین سطح رودخانه و کنترل سیل، از داده‌های تصویر دوربین تلفن هوشمند استفاده کردند و نتیجه نشان داد که این شبکه‌ها می‌توانند به طور دقیق سطح آب رودخانه‌ها را پایش کرده و رویدادهای سیل را تشخیص دهند. Elias & Maas (2022) با استفاده از تصاویر تلفن‌های هوشمند، و با طراحی سیستم تشخیص آب پایش سطح آب را در رودخانه انجام دادند. Nicholaus et al. (2021) اثربخشی مدل CNN را در تشخیص ناهنجاری‌های آب به خوبی نشان دادند و در آخر نتایج نشان داد که این مدل در مقایسه با مدل‌های دیگر عملکرد بالایی دارد. Oliveira et al. (2020) همچنین، نرخ خطای پایینی را در تخمین سطح آب با استفاده از تحلیل تصویر مبتنی بر CNN نشان داد.

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

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

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

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

۳- نتیجه و بحث

در این مطالعه ابتدا لبه سطح آب در تصاویر گرفته شده شناسایی شده و از مدل‌های CNN و DL برای تخمین عددی سطح آب استفاده شد. عملکرد و نمودار مقایسه‌ای مدل‌های مورد استفاده در جدول ۲ و شکل ۶ و شاخص‌های آماری داده‌های مشاهداتی و مقادیر تخمی زده شده با دو مدل استفاده شده در جدول ۳ مشخص شده است. همچنین، نمودار پراکندگی برای هر مدل در شکل ۷ آمده است.

Table 2- Results of evaluation criteria for used models

Model	RMSE (mm)	R ²	NSE
CNN	24/36	0/972	0/971
DL	28/39	0/946	0/962

Table 3- Statistical indices of observed and estimated data with DL and CNN models
جدول ۳- شاخص‌های آماری داده‌های مشاهداتی و تخمین زده شده با دو مدل DL و CNN

Statistical index	Observed		Model	
	Tain	Test	CNN	DL
Average	251/92	300/44	306/65	308/69
Minimum	0	0	9	9
Maximum	472	475	471	465
Standard Deviation	143/98	146/84	143/24	138/75
Sum	50636	12919	13186	13274
Count	201	43	43	43

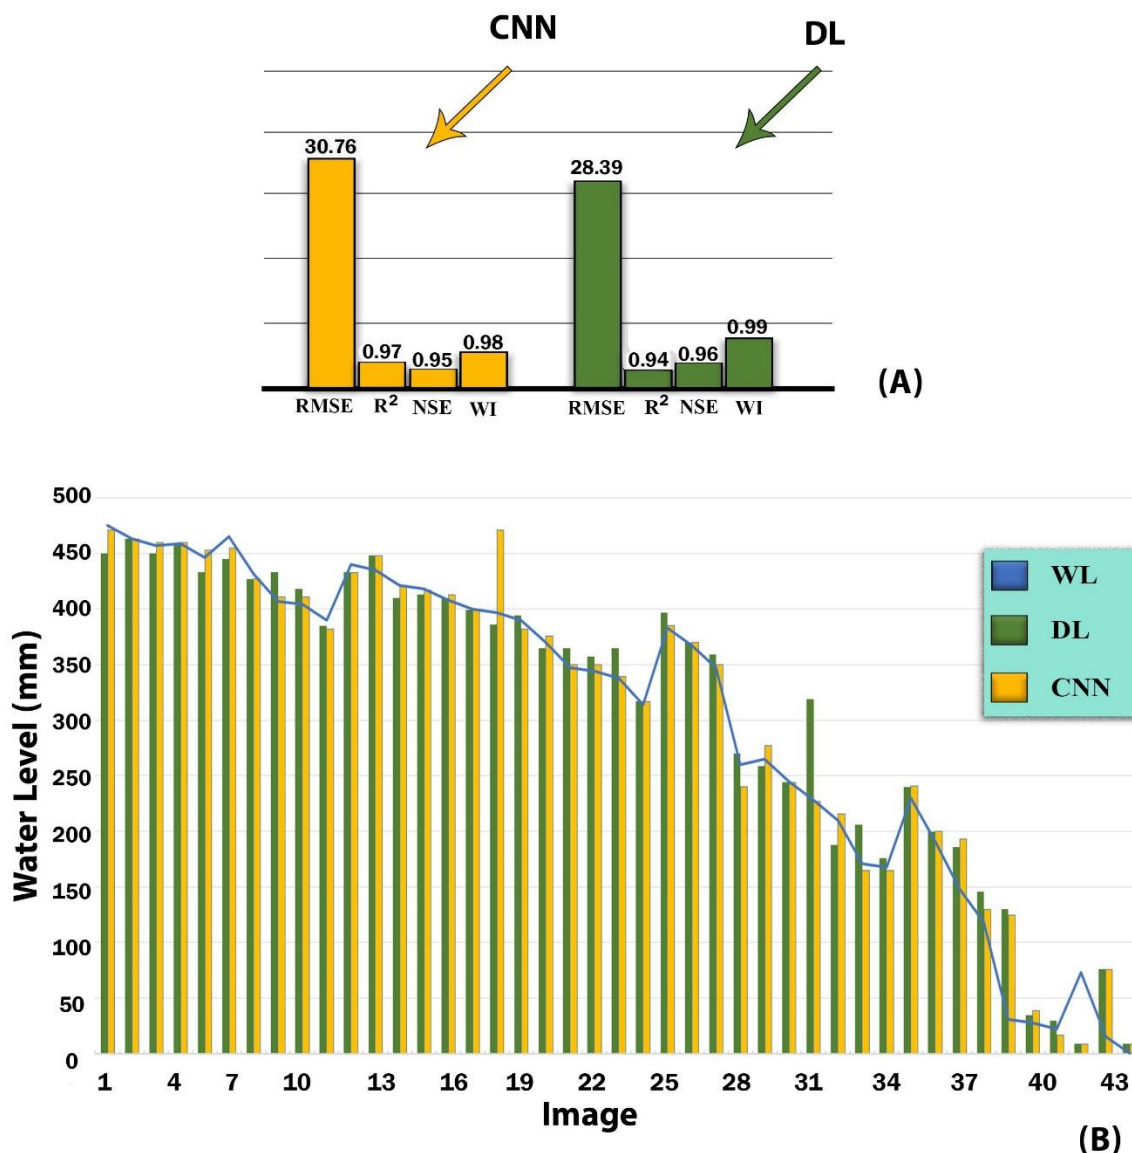


Fig. 6- (a) Comparison of evaluation indices and (b) comparison diagram of CNN and DL models
 شکل ۶- (الف) مقایسه شاخص‌های ارزیابی و (ب) نمودار مقایسه‌ای دو مدل CNN و DL

شده توسط مدل CNN به مقادیر مشاهده‌ای، عملکرد این مدل در پردازش تصویر بالا، و از قابلیت اطمینان بیشتری برخوردار است.

نمودار جعبه‌ای جهت مقایسه دو مدل با مقادیر واقعی تراز آب در شکل ۸ ارائه شده است. همچنین، از شکل ۸ می‌توان استنباط کرد که با نزدیک بودن مقادیر مینیمم، میانگین و ماکسیمم مقادیر تخمین زده

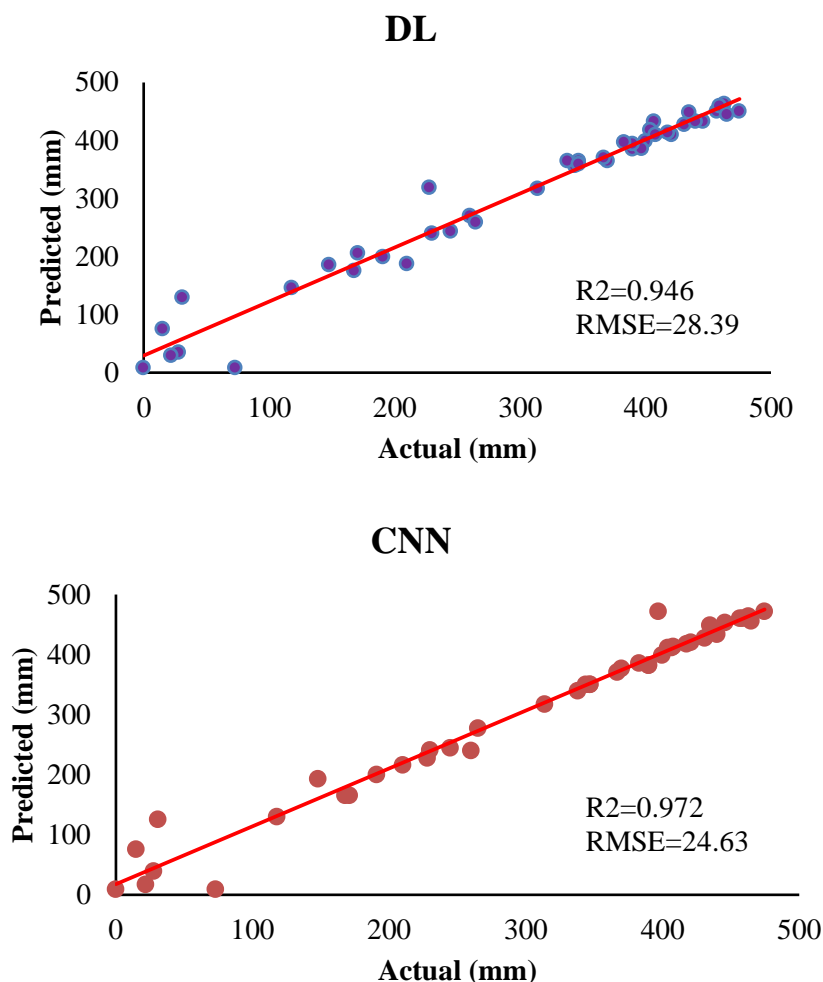


Fig. 7- Scatter plot for CNN and DL models for validation data
 شکل ۷- نمودار پراکنده‌گی برای دو مدل CNN و DL برای داده‌های اعتبارسنجی

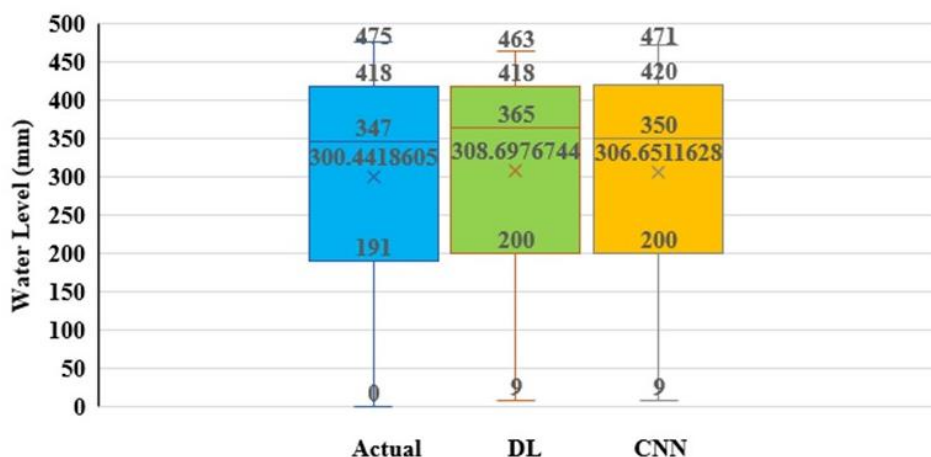


Fig. 8- Box diagram to compare the estimation performance of minimum, medium, and high levels by deep learning, convolutional neural network models and observational data

شکل ۸- نمودار جعبه‌ای جهت مقایسه عملکرد تخمین ترازهای حداقل، متوسط و بالا، با دو مدل یادگیری عمیق، شبکه عصبی کانولوشن و داده‌های مشاهداتی

۴- نتیجه گیری

در سال‌های اخیر، ادغام تکنیک‌های یادگیری ماشین در سیستم‌های تشخیص و پایش سطح آب پیشرفت قابل توجهی داشته و به مدیریت مؤثرتر و فرآیندهای تصمیم‌گیری کمک کرده است. با استفاده از دوربین‌های گنج، تصاویر در سیستم یادگیری ماشین ضبط و پردازش می‌شوند و شامل استفاده از تکنیک‌های تقسیم‌بندی برای تفسیر محتوای آنها می‌شود. پیشرفت سریع در فناوری گوشی‌های هوشمند و قابلیت‌های پردازش تصویر، همانطور که (Elias & Maas (2022 اشاره کردند، پتانسیل این روش‌ها را بیشتر افزایش داده‌اند.

این تحقیق بر پایه تجزیه و تحلیل مقایسه‌ای دو روش یادگیری ماشین برای استخراج اطلاعات سطح آب از تصاویر دیجیتال است. عملکرد این روش‌ها که برای تصاویر آب صاف و گل آلود اعمال شد، بر اساس اثربخشی بصری و دقت آماری ارزیابی شد. نتایج تجربی نشان داد که تمامی تکنیک‌ها و مدل‌های مورد استفاده در استخراج داده‌های سطح آب از تصاویر ثبت شده، عملکرد قابل قبولی داشتند. از طرفی تکنیک پردازش تصویر میانگین موفقیت بیش از ۹۰ درصد را در تخمین ویژگی‌های سطح آب نشان داد.

در آینده، تحقیقات آینده‌نگر می‌تواند بر ادغام الگوریتم‌های بهینه‌سازی متنوع برای بهبود و افزایش دقت و توسعه روش‌های تشخیص و تخمین پیشرفته‌تر متمرکز شود. همچنین، با اضافه کردن مدلی که بتواند سرعت و دبی آب را به همراه سطح تراز با پردازش

تصویر بر آورد کند، از لحاظ کاربردی جایگاه ویژه‌ای خواهد داشت. از طرفی با ایجاد سیستم هشدار اولیه می‌توان از بالا آمدن سطح آب در رودخانه‌ها و فلوم‌ها آگاهی یافته و تصمیمات سریعی جهت پیشگیری از حوادث اتخاذ کرد. با توجه به مزایای که این روش دارد مانند: تشخیص و اندازه‌گیری خودکار سطح آب در دو حالت آب صاف و دارای رسوب، دقت بالای اندازه‌گیری در هر سه تراز بالا، متوسط و کم محدودیت‌هایی را نیز شامل می‌شود. از محدودیت‌های تحقیق حاضر که باعث کاهش دقت و عملکرد ضعیف مدل می‌شود، می‌توان به تلاطم سطح آب (سطح آب موجدار)، نور بسیار زیاد یا کم و شبیدار بودن سطح آب اشاره کرد.

پی‌نوشت‌ها

- 1- São Carlos
- 2- Artificial Intelgance
- 3- Near infrared
- 4- visible
- 5- Inverse Perspective Mapping
- 6- Madeira
- 7- Deep Learning
- 8- Convulotion Neural Network
- 9- Binarization
- 10- ReLU
- 11- Pooling Layers
- 12- Fully Connected Layers
- 13- Padding
- 14- Stride
- 15- Root Mean Square Error
- 16- Nash Sutcliffe Efficiency

۵- مراجع

- Acharya U R, Fujita H, Lih OS, Hagiwara Y, Tan J H, and Adam M (2017) Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network. *Information Sciences* 405:81-90
- Birgand F, Chapman K, Hazra A, Gilmore T, Etheridge R, and Staicu A M (2022) Field performance of the GaugeCam image-based water level measurement system. *PLoS Water* 1(7):p.e0000032
- Chaudhary P, D'Aronco S, Moy de Vitry M, Leitão J P, & Wegner J D (2019) Flood-water level estimation from social media images. *ISPRS Annals of the Photogrammetry. Remote Sensing and Spatial Information Sciences* 4(2/W5):5-12
- Dou G, Chen R, Han C, Liu Z, and Liu J (2022) Research on water-level recognition method based on image processing and convolutional neural networks. *Water* 14(12):1890
- Dumoulin V and Visin F (2016) A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*
- Deng J, Dong W, Socher R, Li LJ, Li K, and Fei-Fei L (2009) Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp.248-255
- Elias M and 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* 22-9:(27)28
- Fleury G R D O, do Nascimento D V, Galvão Filho A R, Ribeiro F D S L, de Carvalho R V, and Coelho C J (2020) Image-based river water level estimation for redundancy information using deep neural network. *Energies* 13(24):p.6706
- Gao A, Wu S, Wang F, Wu X, Xu P, Yu L, and Zhu S (2019) A newly developed unmanned aerial vehicle (UAV) imagery based technology for field measurement of water level. *Water* 11(1):124
- Gu M, Su B, Wang M, and Wang Z (2019) Survey on decolorization methods. *Journal of Applied Computing Research* 36:1286-1292
- Hies T, Parasuraman S, Wang Y A D O N G, Duester R U D O L P H, Eikaas H, and Tan K M (2012) Enhanced water-level detection by image processing. In *10th International Conference on Hydroinformatics (Vol. 1)*. Hamburg, Germany
- Krizhevsky A, Sutskever I, and Hinton G E (2017) ImageNet classification with deep convolutional neural networks. *Communications of the ACM* 60(6):84-90
- Kharade A, Gendle M, and Lodha T, (2017) Water level measurement and detection of flow direction using image processing. *International Journal of Innovations in Engineering Research and Technology* 17(52):1-4
- Kuo L C, and Tai C C (2022) Robust image-based water-level estimation using single-camera monitoring. *IEEE Transactions on Instrumentation and Measurement* 71:1-11
- Kumar T and Verma K (2010) A Theory Based on Conversion of RGB image to gray image. *International Journal of Computer Applications* 7(2):7-10
- Kim D, Alber M, Kwok M W, Mitrović J, Ramirez-Atencia C, PÉrez J A R, and Zille H (2022) Clarifying assumptions about artificial intelligence before revolutionising patent law. *GRUR International* 71(4):295-321
- Kumar T and Verma K (2010) A theory based on conversion of RGB image to Gray image. *International Journal of Computer Applications* 7(2):7-10
- LeCun Y, Bengio Y, and Hinton G (2015) Deep learning. *Nature* 521(7553):436-444
- Li E, Xia J, Du P, Lin C, and Samat A (2017) Integrating multilayer features of convolutional neural networks for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing* 55(10):5653-5665
- Muhadi N A, Abdullah A F, Bejo S K, Mahadi M R, and Mijic A (2021) Deep learning semantic segmentation for water level estimation using surveillance camera. *Applied Sciences* 11(20):9691
- Noto S, Tauro F, Petroselli A, Apollonio C, Botter G, and Grimaldi S (2022) Low-cost stage-camera system for continuous water-level monitoring in ephemeral streams. *Hydrological Sciences Journal* 67(9):1439-1448
- Nicholaus I T, Lee J S, and Kang D K (2022) One-class convolutional neural networks for water-level anomaly detection. *Sensors* 22(22):8764
- Ortigossa E S, Dias F, Ueyama J, and 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: pp. 26-29

- Qiao G, Yang M, and Wang H (2022) A water level measurement approach based on YOLOv5s. *Sensors* 22(10):3714
- Rusk N (2016) Deep learning. *Nature Methods* 13(1):35
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, and Rabinovich A (2015) Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*: pp. 1-9
- Sauvola J and Pietikäinen M (2000) Adaptive document image binarization. *Pattern Recognition* 33(2):225-236
- Sabbatini L, Palma L, Belli A, Sini F, and Pierleoni P (2021) A computer vision system for staff gauge in river flood monitoring. *Inventions* 6(4):79
- Vandaele R, Dance S L, and 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
- Vandaele R, Dance S L, and Ojha V (2023) Calibrated river-level estimation from river cameras using convolutional neural networks. *Environmental Data Science* 2(11):1-19
- Zhang Z, Zhou Y, Liu H, and Gao H (2019) In-situ water level measurement using NIR-imaging video camera. *Flow Measurement and Instrumentation* 67:95-106