



Research Paper

Classification of Water Turbidity and Depth of Secchi Disk using Convolutional Neural Network

Hajar Feizi¹, Mohammad Taghi Sattari^{2*} and Mohammad Mosaferi³

¹Ph.D, Department of Water Engineering, Faculty of Agriculture, Tabriz University, Tabriz, Iran

²Assoc. Professor, Department of Water Engineering, Faculty of Agriculture, Tabriz University, Tabriz, Iran

³Professor, Department of Environmental Health Engineering, Faculty of Health, Tabriz University of Medical Sciences, Tabriz, Iran

Article information

Received: February 10, 2022

Revised: July 26, 2022

Accepted: July 27, 2022

Keywords:

Deep Learning

Image

Laboratory

Python Software

Water Quality

*Corresponding author:

mtsattar@tabrizu.ac.ir



Abstract

Among the important parameters in water quality, are the amount of turbidity and the depth of light penetration in water. One common way to determine water turbidity is to use a Secchi disk, but this method is time-consuming and expensive, so an alternative method should be considered. Deep learning methods can play an important role in this field. The purpose of this study was to classify water quality based on turbidity and Secchi disk depth using a convolutional neural network method implemented in a Python programming environment. For this purpose, a simulated reservoir was used in the laboratory and the turbidity was increased step by step by increasing the clay in the reservoir water. Simultaneously with measuring the depth of the Secchi disk and water turbidity, the samples were imaged. These images were given to the convolutional neural network together with the obtained data. The results showed that the convolutional neural network with 300 epochs, can estimate the water quality class with 95% accuracy and 93% kappa statistic, and it has only a 5% error rate.

© Authors, Published by **Environment and Water Engineering** journal. This is an open-access article distributed under the CC BY (license <http://creativecommons.org/licenses/by/4.0/>).



Introduction

Knowledge of water quality is essential for the health of humans and living organisms. Turbidity measurement is a key test to measure water quality. Water turbidity causes filters to clog and prevent them from working effectively, filling reservoirs and pipes with mud and damaging faucets and valves. Also, high turbidity causes light scattering and in turn, reduces the process of photosynthesis of water-dependent plants. One

of the common methods of determining water turbidity is using a Secchi disk, which is time-consuming and expensive and depends on the accuracy of the observer's reading. Therefore, it is necessary to use an alternative method. Until now, various methods have been used to measure the water turbidity and the depth of the Secchi disk. With the development of computing systems in recent years, artificial intelligence methods have grown significantly and led to the



emergence of deep learning methods. In this study, the convolutional neural network method based on deep learning was used to classification of water turbidity and the depth of the Secchi disk.

Material and Methods

The present study was conducted to evaluate water turbidity and depth of the Secchi disk using images of laboratory samples. All the experiments were done in the Environmental Chemistry Laboratory, Tabriz University of Medical Sciences located in Tabriz, Iran. To measure the depth of the Secchi disk, a glass reservoir with dimensions of 120 x 50 cm was prepared. Then clay was added in different amounts into the reservoir water. At each step, by lowering the Secchi disk, the depth of the Secchi disk was read, and the image was taken. The turbidity of reservoir water was measured using the AL250T-IR Turbidity Meter. Then these read numbers were classified in certain intervals. The classification of water turbidity was based on the studies of Kamboj and Kamboj (2019), which is presented in Table (1). The depth of the Secchi disk measured based on the classification of turbidity has been added to Table (1).

Table 1 Classification of water turbidity and Secchi disk

Secchi Disk Depth (cm)	Turbidity (NTU)	Class	Water Quality
110-120	0-5	A	Excellent
100-110	5-10	B	Acceptable
70-100	10-100	C	Slightly Polluted
20-70	100-250	D	Polluted
10-20	>250	E	Highly Polluted

After labeling, these images entered the convolutional neural network. In order to obtain better results and avoid the effect of light, imaging was done in the same environmental conditions. TES-1339R light meter was used to measure the amount of ambient light. All images were captured in the ambient light of lx 320.4. A Canon 1300D camera was used for imaging. 100 images were prepared and 20 images were placed in each class, 70% of them were used for training (14 images), 10% for model evaluation (2 images), and the remaining 20% (4 pictures) were used for testing.

The results obtained from the deep learning method were compared with the results obtained from laboratory measurements. If the results are close to each other, it means that the model works correctly and has sufficient accuracy. In this study, three numerical criteria (accuracy, error rate, and Kappa statistic) and one graphical criterion (confusion matrix) were used to evaluate the model.

Results

This study used the CNN method to classify water turbidity and depth of the Secchi disk. The model was programmed using Python and the TensorFlow deep learning library. This model was implemented in Google Colab, which is an online browser-based platform. The model was implemented with 150, 200, 250, and 300 epochs, and the learning rate was obtained as $1e-5$ through trial and error. The number of neurons in each layer was extracted through trial and error, the number of which was 200 in the first layer and 50 in the last layer. The results of model implementation for different epochs are presented in Table (2).

Table 2 CNN results for different epochs

Test		Train			Time	Epoch		
Mistake number	Kappa statistic	Error rate	Accuracy	Kappa statistic			Error Rate	Accuracy
4	0.75	0.20	0.80	0.79	0.16	0.84	75s	150
2	0.87	0.10	0.90	0.93	0.03	0.97	80s	200
2	0.87	0.10	0.90	0.91	0.06	0.94	108s	250
1	0.93	0.05	0.95	0.94	0.03	0.97	118s	300

As shown in Table (2), the accuracy of the model in the low epochs is low, and its error is higher. Out of a total of 20 images for the test section, in epochs of 150, 200, 250, and 300, respectively, samples 4, 2, 2, and 1 were classified in the incorrect class. Imaging errors and the resulting similarity between different samples of the

classes have caused these errors. In addition, the only difference between turbidity images is their RGB color, and there is no other indicator to distinguish them. The best performance is related to the number of 300 epochs where the accuracy of the model is around 95% and only 5% of the data is incorrectly classified.

Conclusions

In this study, the classification of water turbidity and depth of the Secchi disk based on deep learning is presented, and the results are as follows:

1. The results of the presented method are consistent with the laboratory results obtained for the classification of water turbidity and depth of the Secchi disk.
2. The best results were obtained from the implementation of the convolution neural network with a number of epochs of 300.
3. According to the disturbance matrix in the number of repetitions of 300, only one error is misclassified, which is related to class C.
4. The presented method in laboratory conditions is able to estimate the turbidity class of the water and the depth of the Secchi disk with an accuracy of 95%.

Acknowledgment

We would like to thank the head of the Environmental Chemistry Laboratory, Faculty of Health, Tabriz University of Medical Sciences, and the expert of the East Azerbaijan Regional Water Authority province for their sincere cooperation in collecting data and advancing this study.

Data Availability

In this research, the data recorded in the laboratory have been used, some of which are presented in the manuscript of the article, but all the data generated in this research cannot be published due to its use in the PhD Thesis.

Conflicts of interest

The authors of this paper declared no conflict of interest regarding the authorship or publication of this article.

ارزیابی، داده‌های زمینی و سنجش از دور فرا طیفی به ترتیب ضریب تبیین ۸۴ و ۸۶٪ را برای عمق دیسک سکی و کدورت آب رودخانه نشان داد. (Taheri Shahraeini 2014) به‌منظور پایش عمق سکی در دریای خزر از ۲۵ تصویر سنجنده مریس^۲ استفاده کرد. نتایج نشان داد حدود ۸۶٪ همبستگی بین اندازه‌گیری‌های میدانی و تصاویر سنجنده مریس وجود دارد.

با توسعه سامانه‌های محاسباتی در سال‌های اخیر، روش‌های هوش مصنوعی رشد چشمگیری داشته و منجر به پیدایش روش‌های یادگیری عمیق شدند. یادگیری عمیق به استفاده از معماری شبکه‌های عصبی مصنوعی اشاره دارد که شامل تعداد زیادی لایه پردازش است. این روش‌ها اخیراً در مطالعات مرتبط با آب توسط محققان زیادی از جمله Feizi et al. (2022) مورد استفاده قرار گرفته است. همچنین، شبکه‌های یادگیری عمیق در زمینه‌های دیگر همچون تخمین کیفیت هوا توسط محققانی مانند Zhang et al. (2020) استفاده شده است. شبکه‌های عصبی کانولوشن (CNN) نمونه‌ای از شبکه‌های عصبی عمیق هستند که در زمینه‌های مختلف خصوصاً تشخیص تصویر تمرکز داشته و برای طبقه‌بندی تصاویر مناسب هستند (Ferentinos 2018). در این روش، تصاویر ثبت‌شده به‌عنوان داده‌های آموزش و برچسب‌های به‌دست‌آمده از آزمایش مربوط به آن نمونه به مدل داده می‌شود. سپس بدون مشخص کردن ویژگی خاصی، مدل با استفاده از لایه‌های متفاوت، مهندسی ویژگی انجام داده و برای داده‌های آزمون کیفیت آب را تشخیص می‌دهد. در واقع، ماشین در این روش‌ها قادر به تصمیم‌گیری بوده و نیازی به نظارت کامل انسان برای مشخص کردن اطلاعات لازم ماشین در هر لحظه نیست. در این حالت ماشین توانایی کار با تعداد داده زیاد را داشته و هیچ محدودیتی ندارد.

Oga et al. (2019) برای بررسی کیفیت آب رودخانه بر اساس تصویر از شبکه عصبی کانولوشن با معماری‌های مختلف استفاده کردند. جهت طبقه‌بندی، مجموعه داده‌های عکس را به دو گروه تمیز و گل‌آلود تقسیم کردند. در تمامی ساختارها، دقت بالای ۹۰٪ برای طبقه‌بندی داده‌ها به دست آمد. (Montassar and Benazza-Benyahia 2020) از شبکه عصبی یادگیری عمیق برای طبقه‌بندی کدورت آب

سبب مسدود کردن پالایه‌ها (صافی‌های آبی) و بازداشتن آن‌ها از کار کردن مؤثر، پر کردن مخازن و لوله‌ها با گل‌ولای و صدمه زدن به شیرآلات و سوپاپ‌ها می‌شود. همچنین کدورت، سبب کاهش اثربخشی گندزدایی شده و نیاز به مصرف کلر را افزایش خواهد داد (WHO 2011). آب بسیار کدر سبب پراکنش نور شده و به‌نوبه خود باعث کاهش روند فتوسنتز گیاهان وابسته به آب می‌شود (Hussain et al. 2016). با افزایش کدورت آب آبیاری، سرعت نفوذپذیری کاهش بیشتری می‌یابد که این امر ناشی از کاهش تخلخل خاک در اثر حمل ذرات معلق و کلوئیدی با آب آبیاری و جایگزین شدن آن‌ها در خلل و فرج ریز خاک است (Salamati and Moazed 2008). کدورت در آب آشامیدنی نیز موجب به خطر انداختن سلامتی انسان می‌شود. برای آب آشامیدنی سالم، مقدار کدورت باید کم‌تر از ۱ NTU و در حالت حداکثر باید کمتر از 5 NTU باشد (Karnawat and Patil 2016). یکی از روش‌های رایج تعیین کدورت آب، استفاده از دیسک سکی است که وابسته به دقت قرائت ناظر بوده و ممکن است همراه با خطا باشد. عمق دیسک سکی، عمقی است که قسمت‌های سفید و سیاه دیسک سکی در آن عمق با چشم قابل مشاهده و تفکیک است. این روش یکی از راه‌های ساده برای اندازه‌گیری شفافیت و یا میزان کدورت آب است که در مخازن و رودخانه‌ها نیز کاربرد دارد (Preisendorfer 1986).

تاکنون از روش‌های مختلفی برای اندازه‌گیری میزان کدورت آب و عمق دیسک سکی استفاده شده است. Aghighi et al. (2008) برای برآورد عمق دیسک سکی در خلیج گرگان از تصاویر سنجنده LIII-III ماهواره IRS استفاده کردند. نتایج نشان داد که ضریب تبیین بین داده‌های سنجنده و اندازه‌گیری‌های میدانی حدود ۷۷٪ است. Kallio et al. (2008) از تصاویر ماهواره ETM به‌منظور تخمین کیفیت آب شامل کدورت، عمق دیسک سکی و مواد آلی رنگی محلول در دو رودخانه از فنلاند استفاده کردند. نتایج نشان داد که خطای نسبی در تخمین کدورت ۲۳٪، برای عمق دیسک سکی ۲۱/۱٪ و برای مواد آلی رنگی محلول ۱۷/۴٪ است. (Rangzan et al. 2012) با استفاده از سنجنده هایپریون کدورت و عمق سکی در رودخانه کارون در محدوده اهواز را مورد بررسی قرار دادند. با توجه به نتایج

²MERIS¹Nephelometric Turbidity Units



شکل ۱- مخزن شبیه‌سازی شده برای اندازه‌گیری عمق دیسک سکی

Fig. 1 Simulation reservoir to measure the depth of the Secchi disk

جدول ۱- طبقه‌بندی کدورت آب و عمق دیسک سکی

Table (1) Water turbidity classification and Sacchi disk depth (Kamboj and Kamboj 2019)

Secchi Disk Depth (cm)	Turbidity (NTU)	Class	Water Quality
110-120	0-5	A	Excellent
100-110	5-10	B	Acceptable
70-100	10-100	C	Slightly Polluted
20-70	100-250	D	Polluted
10-20	>250	E	Highly Polluted

این تصاویر پس از برچسب‌گذاری، وارد شبکه عصبی کانولوشن شدند. برای به دست آوردن نتایج بهتر و جلوگیری از اثر نور، تصویربرداری در شرایط محیطی یکسان انجام گرفت. برای اندازه‌گیری میزان نور محیط از دستگاه لایت‌متر مدل TES-1339R استفاده شد. تمامی تصاویر در نور محیطی 320.4 lx تصویربرداری شد. برای تصویربرداری از دوربین Canon مدل 1300D استفاده شد.

تعداد ۱۰۰ عکس تهیه و در هر طبقه ۲۰ تصویر قرار گرفت که حدود ۷۰٪ از آن‌ها برای قسمت آموزش (۱۴ تصویر)، ۱۰٪ ارزیابی مدل (۲ تصویر) و ۲۰٪ باقیمانده (۴ تصویر) برای قسمت آزمون مورد استفاده قرار گرفت. از هر طبقه ۵ تصویر به صورت تصادفی توسط نرم‌افزار پایتون انتخاب شده و در شکل (۲) نمایش داده شده است.


استفاده کردند. در بهترین حالت، دقت به دست آمده حدود ۹۸٪ بود.

در مناطق گرم و خشک، بارش‌های شدید باعث فرسایش حوضه و انتقال رسوب معلق به رودخانه می‌شود. در این حالت جریان رودخانه غلیظ و گل‌آلود شده و به دلیل تلاطم و اختلاط جریان، رسوبات معلق در کل بدنه جریان پخش می‌شوند. این جریان در هنگام ورود به مخزن سد و با کاهش شدید سرعت جریان، به شکل یک توده جریان گل‌آلود در کف مخزن به سمت بدنه سد حرکت می‌نماید. بنابراین یکی از راهکارهای مهم مدیریت رسوب در مخازن سدها، استفاده از پدیده کدورت آب است (Wang and Chunhong, 2009) با توجه به مطالعات انجام شده، تاکنون از روش‌های یادگیری عمیق برای تخمین عمق دیسک سکی استفاده نشده است. بنابراین، در این مطالعه، به طبقه‌بندی کدورت آب و عمق دیسک سکی با استفاده از روش شبکه عمیق کانولوشن پرداخته می‌شود.

۲- مواد و روش‌ها

پژوهش حاضر برای ارزیابی کدورت آب و عمق دیسک سکی با استفاده از تصویر در نمونه‌های آزمایشگاهی انجام شد. تمامی آزمایش‌ها در آزمایشگاه شیمی محیط، در دانشگاه علوم پزشکی تبریز صورت گرفت. برای اندازه‌گیری عمق دیسک سکی، مخزن شیشه‌ای به ابعاد ۵۰×۱۲۰×۵۰ cm تهیه شد (شکل ۱). سپس خاک رس در مقادیر مختلف به داخل آب مخزن اضافه شد. در هر مرحله با پایین بردن دیسک سکی، عمق دیسک سکی قرائت شد و تصویربرداری انجام گرفت.

در هر مرحله، اندازه‌گیری کدورت با استفاده از دستگاه کدورت‌سنج مدل AL250T-IR انجام شد و دقت اندازه‌گیری از طریق کالیبره کردن دستگاه و اندازه‌گیری‌های مکرر به دست آمد. سپس این اعداد قرائت شده، در بازه‌های معین طبقه‌بندی شدند. طبقه‌بندی کدورت آب بر اساس مطالعات and Kamboj Kamboj (2019) انجام گرفت که در جدول (۱) ارائه شده است. عمق دیسک سکی اندازه‌گیری شده بر اساس طبقه‌بندی میزان کدورت‌ها، به جدول (۱) اضافه شده است.



شکل ۲- نمونه تصاویر برای هر کلاس
Fig. 2 Sample images for each class

۲-۱- روش‌های یادگیری عمیق

یادگیری عمیق^۱ زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به منظور پردازش سیگنال‌های حسی مانند صدا و تصویر استفاده می‌کند. ماشین در این روش هر مفهوم پیچیده را به مفاهیم ساده‌تری تبدیل می‌کند و با ادامه این روند به مفاهیم پایه‌ای می‌رسد که قادر به تصمیم‌گیری برای آن‌ها است و بدین ترتیب نیازی به نظارت کامل انسان برای مشخص کردن اطلاعات لازم ماشین در هر لحظه نیست.

۲-۱-۱- شبکه عصبی کانولوشن

شبکه‌های عصبی کانولوشن^۲ (CNN) یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند. این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی

کامپیوتر است و در پیدا کردن ویژگی‌های موجود در تصاویر به خوبی عمل می‌کند (Pan et al. 2019). لایه‌های اصلی برای ساخت یک معماری شبکه کانولوشن عبارت‌اند از: لایه ورودی، لایه کانولوشن، لایه Pooling و لایه تماماً متصل (FC)^۳، که این لایه‌ها روی هم قرار می‌گیرند تا یک معماری کامل از شبکه کانولوشن ایجاد کنند. در هر لایه، یک شبکه عصبی کانولوشن نورون‌های خود را در سه بعد عرض، ارتفاع و عمق مرتب می‌کند. در واقع، هر لایه یک ورودی سه‌بعدی را دریافت کرده و آن را از طریق یک تابع مشتق‌پذیر به یک توده سه‌بعدی خروجی تبدیل می‌کند. لایه ورودی^۴ شامل مقادیر پیکسل‌های خام تصویر ورودی‌ها است. لایه کانولوشن خروجی نورون‌هایی را که به نواحی محلی در ورودی متصل هستند محاسبه می‌کند. عمل محاسبه هم از طریق ضرب نقطه‌ای بین وزن‌های هر نورون و


³Fully connected dense layer

⁴Input layer

¹Deep learning

²Convolutional Neural Network

ناحیه‌ای که آن‌ها به توده فعال‌سازی ورودی متصل هستند، صورت می‌گیرد.



شکل ۳- ساختار شبکه عمیق کانولوشن

Fig. 3 Deep Convolution network structure

به‌درستی عمل می‌کند و از دقت کافی برخوردار است. در این مطالعه از سه معیار عددی (دقت، نرخ خطا و آماره کاپا) و یک معیار گرافیکی (ماتریس اغتشاش) برای ارزیابی مدل استفاده شد.

۲-۲-۱- دقت

مهم‌ترین معیار برای تعیین کارایی یک الگوریتم طبقه‌بندی، دقت^۴ یا نرخ طبقه‌بندی است. در واقع این معیار مشهورترین و عمومی‌ترین معیار محاسبه کارایی الگوریتم‌های طبقه‌بندی است. دقت یا آهنگ طبقه‌بندی نشان می‌دهد که الگوریتم طراحی شده چند درصد از کل مجموعه رکوردهای آزمایشی را به‌درستی طبقه‌بندی کرده است (رابطه ۱).

$$Accuracy = \frac{TN+TP}{TP+TN+FP+FN} \quad (1)$$

که، TP و TN به ترتیب تعداد نمونه‌های طبقه مثبت و منفی است که به‌درستی طبقه‌بندی شده‌اند. FN تعداد نمونه‌های طبقه مثبت است که به‌اشتباه منفی پیش‌بینی شده‌اند و FP تعداد نمونه‌های منفی است که به‌اشتباه مثبت پیش‌بینی شده‌اند (Baratloo et al. 2015).

۲-۲-۲- آهنگ خطا

آهنگ خطا^۵ دقیقاً برعکس معیار دقت طبقه‌بندی است. بیش‌ترین مقدار آن زمانی که الگوریتم طبقه‌بندی کم‌ترین کارایی را دارد، برابر یک و کمترین مقدار آن زمانی که الگوریتم طبقه‌بندی بهترین کارایی را دارد، برابر صفر است (رابطه ۲).

$$Error\ rate = 1 - Accuracy \quad (2)$$

لایه Pooling ابعاد ورودی (تصویر) را کاهش می‌دهد و در اصل از طریق عملیات این لایه است که در انتهای شبکه کانولوشن می‌توان به یک بردار امتیاز دست پیدا کرد. لایه FC وظیفه محاسبه امتیاز طبقه‌ها^۱ را دارد (Pan et al. 2019). معمولاً برای کاهش بیش‌برازش^۲ مدل در شبکه‌های CNN از عملگر Dropout استفاده می‌شود. Drop out باید در هنگام train بین لایه‌های FC قرار گیرد که یادگیری بر روی معماری‌های متفاوت با مجموعه نورون‌های متفاوت صورت بگیرد. در این مطالعه بین لایه‌های FC از Dropout=20% استفاده شده است. تابع فعال‌سازی Softmax معمولاً در لایه خروجی استفاده می‌شود. لایه خروجی وظیفه دارد با توجه به ورودی‌های خود، خروجی تولیدشده را به مقیاس مطلوب ببرد. نرخ یادگیری^۳ هم یکی از هاپیر پارامترها است که پیدا کردن مقدار بهینه آن ضروری است و معمولاً مقداری بین ۱e-۱ تا ۱e-۷ می‌گیرد. در واقع نرخ یادگیری اندازه گام‌های حرکت توسط شبکه را بیان می‌کند (Apaydin et al. 2020). در شکل (۳) ساختار شبکه عمیق کانولوشن استفاده شده در این مطالعه ترسیم شده است که شامل ۵ لایه کانولوشن، سه لایه Pooling و سه لایه FC است.

۲-۲- معیارهای ارزیابی مدل

نتایج به‌دست‌آمده از روش یادگیری عمیق با نتایج به‌دست‌آمده از اندازه‌گیری‌های آزمایشگاهی مقایسه شد. چنانچه نتایج نزدیک به هم باشند، بیانگر آن است که مدل

¹Class

²Overfitting

³Learning rate

⁴Accuracy

⁵Error rate

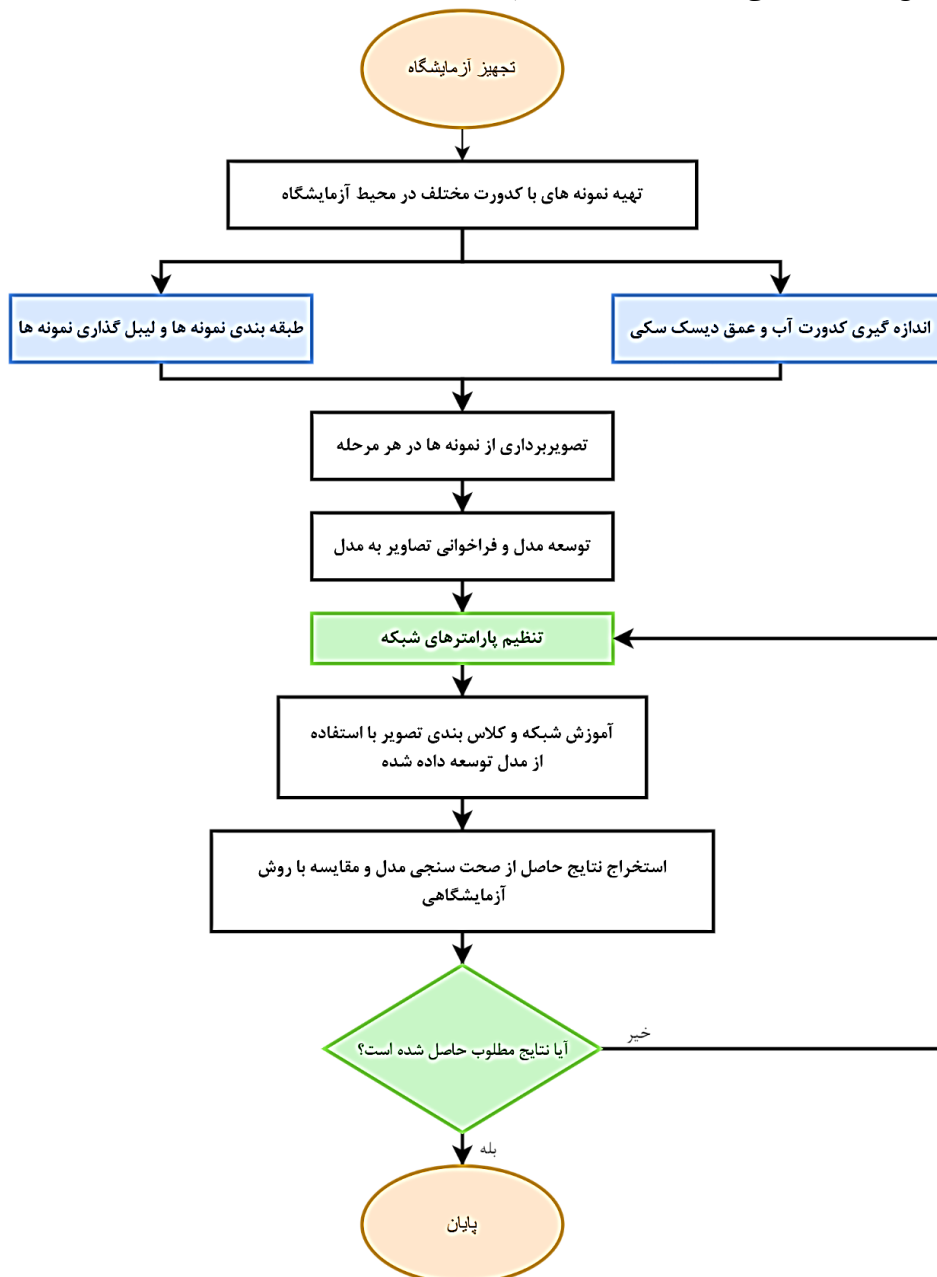
۳-۲-۲- آماره کاپا

به صورت رابطه (۳) تعریف می‌شود (Naresh Kumar et al. 2009):

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (3)$$

مقادیر K کم‌تر از ۰/۴ نشان‌دهنده توافق ضعیف تا خیلی ضعیف، مقادیر ۰/۴-۰/۵۵ نشان‌دهنده توافق متوسط، مقادیر ۰/۵۵-۰/۷۰ نشان‌دهنده توافق خوب و مقادیر بیش از ۰/۷۰ نشان‌دهنده توافق خیلی خوب تا عالی است (Naresh Kumar et al. 2009).

آماره کاپا نخستین بار در سال ۱۹۶۸ معرفی شد. فرض کنید P_{ij} نسبت کل اجزایی است که به طبقه i از یک سری و به طبقه j از سری دوم اختصاص دارد. این نسبت‌ها می‌توانند داخل یک ماتریس شکل بگیرند که قطر اصلی آن شامل نسبت‌های منحصربه‌فرد P_{ii} است که در هر دو سری مطابقت دارند. P_0 مجموع مقادیر P_{ii} است. با در نظر گرفتن $P_{e,ii}$ به عنوان حاصل ضرب مجموع نسبت‌های ردیف و ستون مربوطه، مقدار قابل‌انتظار توافق برابر است با جمع مقادیر $P_{e,ii}$ که این جمع P_e نامیده می‌شود. بنابراین آماره کاپا



شکل ۴- روند نمای مراحل انجام پژوهش
Fig 4 Flowchart of research stages

۴-۲-۲- ماتریس اغتشاش

معیار دیگر ارزیابی، ماتریس اغتشاش^۱ است که در این ماتریس هر چه نمونه‌های بیش‌تری در قطر اصلی قرار گیرند، بیانگر این است که مدل دقت بالایی دارد. مقادیر خارج از قطر اصلی نشان می‌دهد که چه تعداد از نمونه‌ها در دسته اشتباه طبقه‌بندی شده‌اند. ماتریس اغتشاش دارای ۴ عنصر به‌شرح ذیل است (Han et al. 2011). منفی صادق، بیانگر تعداد رکوردهایی است که کلاس واقعی آن‌ها منفی بوده و الگوریتم طبقه‌بندی نیز کلاس آن‌ها را به‌درستی، منفی تشخیص داده است. مثبت صادق، بیانگر تعداد رکوردهایی است که کلاس واقعی آن‌ها مثبت بوده و الگوریتم طبقه‌بندی نیز کلاس آن‌ها را به‌درستی مثبت تشخیص داده است. مثبت کاذب، بیانگر تعداد رکوردهایی است که کلاس واقعی آن‌ها منفی بوده و الگوریتم طبقه‌بندی کلاس آن‌ها را به‌اشتباه مثبت تشخیص داده است. منفی کاذب، بیانگر تعداد رکوردهایی است که کلاس واقعی آن‌ها مثبت بوده و الگوریتم طبقه‌بندی کلاس آن‌ها را به‌اشتباه منفی تشخیص

داده است. مراحل انجام این پژوهش در شکل (۴) نمایش داده شده است.

۳- یافته‌ها و بحث

در این مطالعه از روش CNN برای طبقه‌بندی کدورت آب و عمق دیسک سکی استفاده شد. این مدل با استفاده از برنامه‌نویسی پایتون و کتابخانه یادگیری عمیق Tensorflow پیاده‌سازی شد. اجرای مدل بر روی Google Colab انجام شد که یک پلتفرم مبتنی بر مرورگر آنلاین است. سپس، مدل با تعداد تکرارهای ۱۵۰، ۲۰۰، ۲۵۰ و ۳۰۰ اجرا گردید. نرخ یادگیری از طریق سعی و خطا ۱e-۵ به دست آمد. همچنین تعداد نرون‌های موجود در هر لایه با سعی و خطا استخراج شد که تعداد آن در لایه‌های اول ۲۰۰ و در لایه آخر ۵۰ عدد به‌دست آمد. نتایج حاصل از اجرای مدل برای تکرارهای مختلف در جدول (۲) ارائه شده است.

جدول ۲- نتایج حاصل از CNN برای تکرارهای مختلف

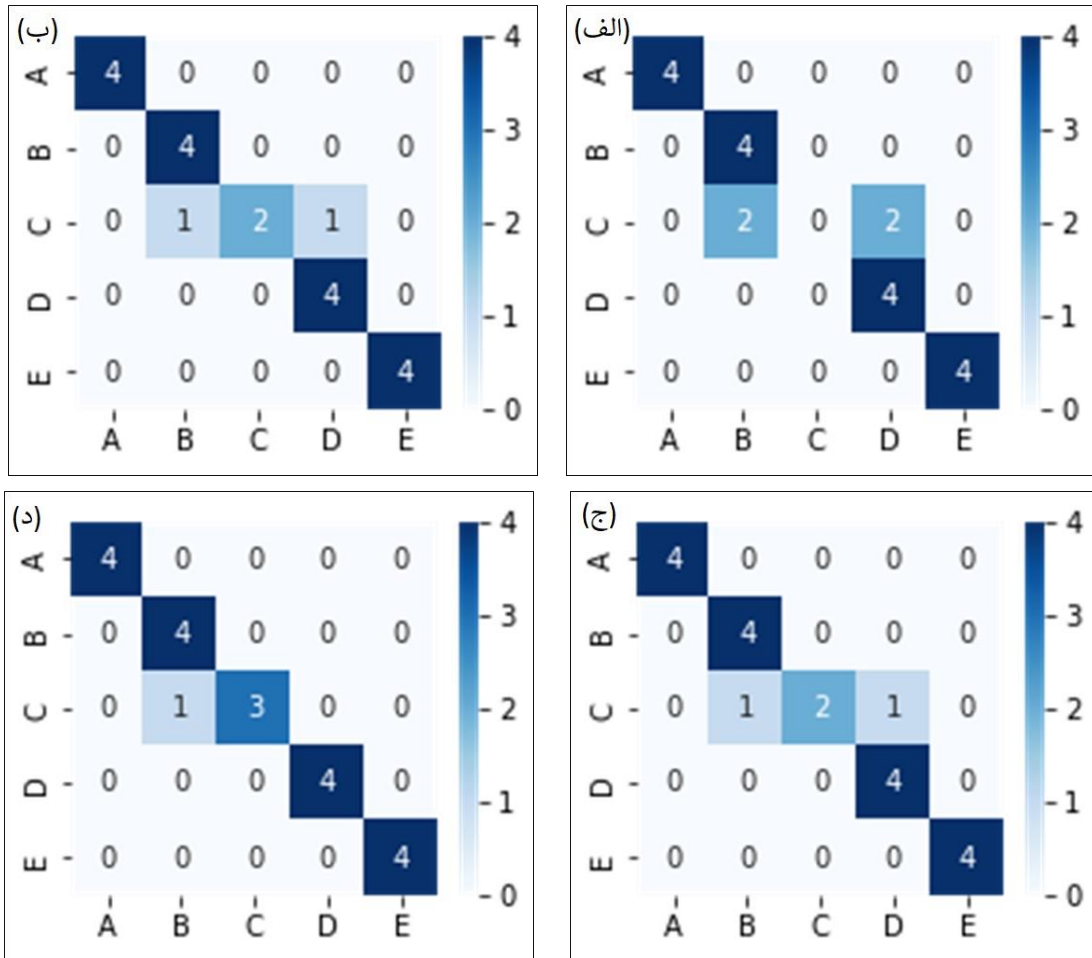
Table 2 CNN results for different epochs

Epoch	Time	Train			Test		
		Accuracy	Error Rate	Kappa statistic	Accuracy	Error rate	Kappa statistic
150	75s	0.84	0.16	0.79	0.80	0.20	0.75
200	80s	0.97	0.03	0.93	0.90	0.10	0.87
250	108s	0.94	0.06	0.91	0.90	0.10	0.87
300	118s	0.97	0.03	0.94	0.95	0.05	0.93

همان‌طور که در جدول (۲) مشاهده می‌شود دقت مدل در تعداد تکرار کم، پایین بوده و خطای آن بیش‌تر است. با زیاد کردن تعداد تکرار مدل رفته‌رفته همگرا شده است و در صورت زیاد کردن تعداد تکرار، تفاوت معناداری در نتایج ایجاد نمی‌شود. از مجموع ۲۰ داده برای قسمت تست، در تکرارهای ۱۵۰، ۲۰۰، ۲۵۰ و ۳۰۰ به‌ترتیب تعداد ۴، ۲، ۲ و ۱ نمونه در طبقه اشتباه قرار گرفته‌اند. خطای تصویربرداری و در نتیجه ایجاد شباهت بین نمونه‌های مختلف طبقه‌ها، سبب به وجود آمدن این اشتباهات شده است. علاوه بر این، وجه تمایز تصاویر کدورت با همدیگر فقط رنگ RGB آن‌هاست و هیچ شاخص دیگری برای تشخیص تمایز آن‌ها وجود ندارد. بهترین عملکرد مربوط به تعداد تکرار ۳۰۰ است که در آن حداکثر است.

دقت مدل حدود ۹۵٪ بوده و تنها ۵٪ از تصاویر به‌اشتباه طبقه‌بندی شده‌اند. ماتریس اغتشاش حاصل از اجرای شبکه عمیق کانولوشن با تعداد تکرارهای متفاوت برای قسمت تست در شکل (۵) آمده است. این ماتریس عملکرد یک مدل طبقه‌بندی شده را شرح می‌دهد و نتایج حاصل از طبقه‌بندی را بر اساس اطلاعات اندازه‌گیری شده موجود، نمایش می‌دهد. هر ستون ماتریس، نمونه‌ای از مقدار پیش‌بینی شده را نشان می‌دهد. در صورتی‌که هر سطر نمونه اندازه‌گیری شده (درست) را در بردارد. اعداد روی قطر اصلی ماتریس، نمایش تعداد طبقه‌بندی‌های درست هستند. بنابراین، در صورتی‌که تمام اعداد غیر روی قطر اصلی صفر باشند، الگوریتم دارای دقت حداکثر است.

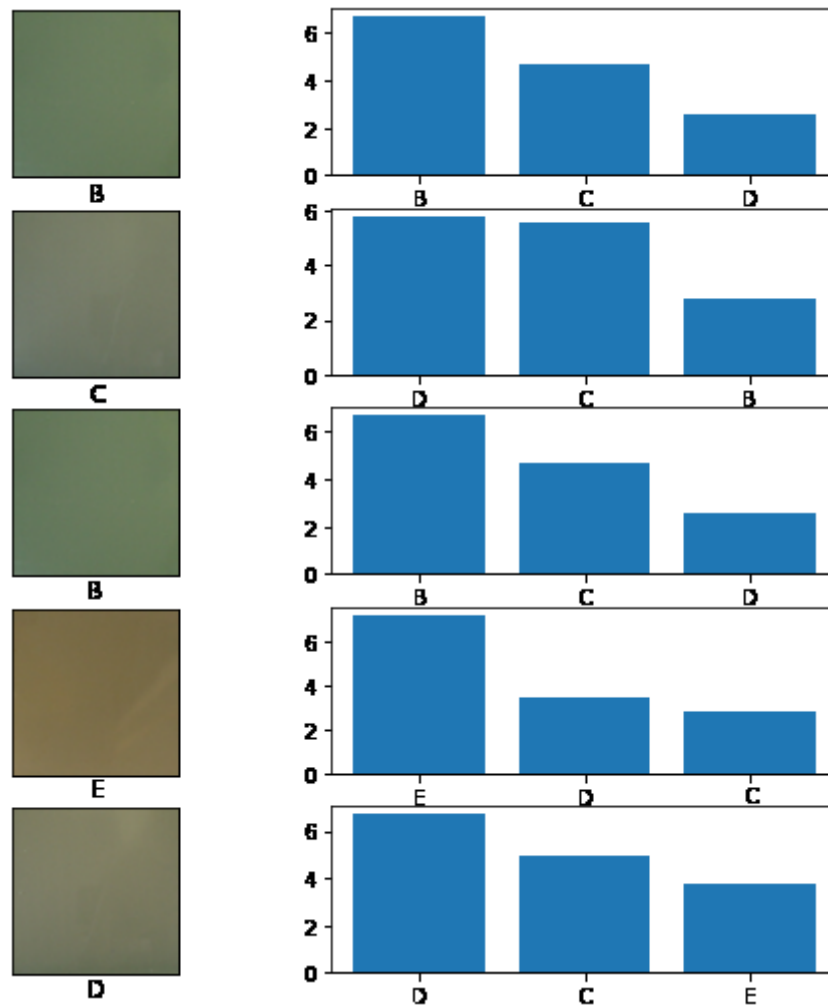
همان‌طور که در جدول (۲) مشاهده می‌شود دقت مدل در تعداد تکرار کم، پایین بوده و خطای آن بیش‌تر است. با زیاد کردن تعداد تکرار مدل رفته‌رفته همگرا شده است و در صورت زیاد کردن تعداد تکرار، تفاوت معناداری در نتایج ایجاد نمی‌شود. از مجموع ۲۰ داده برای قسمت تست، در تکرارهای ۱۵۰، ۲۰۰، ۲۵۰ و ۳۰۰ به‌ترتیب تعداد ۴، ۲، ۲ و ۱ نمونه در طبقه اشتباه قرار گرفته‌اند. خطای تصویربرداری و در نتیجه ایجاد شباهت بین نمونه‌های مختلف طبقه‌ها، سبب به وجود آمدن این اشتباهات شده است. علاوه بر این، وجه تمایز تصاویر کدورت با همدیگر فقط رنگ RGB آن‌هاست و هیچ شاخص دیگری برای تشخیص تمایز آن‌ها وجود ندارد. بهترین عملکرد مربوط به تعداد تکرار ۳۰۰ است که در آن حداکثر است.



شکل ۵- ماتریس اغتشاش در دوره تست برای تکرارهای مختلف: الف- ۱۵۰، ب- ۲۰۰، ج- ۲۵۰، و د- ۳۰۰
 Fig. 5 Confusion matrix in Test section for different epochs: a) 150, b) 200, c) 250, and d) 300

در نهایت، شکل (۵-د) طبقه‌بندی نمونه‌ها با تعداد ۳۰۰ تکرار را نشان می‌دهد. در این حالت بهترین دقت طبقه‌بندی نمونه‌ها با استفاده از شبکه عمیق کانولوشن صورت گرفته است. در این حالت از کل ۲۰ نمونه، فقط یک نمونه در طبقه نادرست قرار گرفته است که مربوط به طبقه C بوده و در دسته B طبقه‌بندی شده است. نمونه‌های سایر طبقه‌ها کاملاً در طبقه درست قرار گرفته‌اند. در واقع با توجه به مشابهت بین تصاویر، طبقه‌بندی نمونه‌های نادرست در دسته‌هایی صورت گرفته است که نزدیک‌ترین طبقه به نمونه‌ها بوده و شباهت زیادی به آن طبقه‌ها دارند. در شکل (۶)، نمونه‌های تصادفی از قسمت تست مربوط به بهترین حالت یعنی ۳۰۰ تکرار استخراج شده است. این شکل احتمال تعلق نمونه‌ها به سه طبقه نزدیک (TOP-3) را نشان می‌دهد.

برای قسمت تست به‌طور کلی از ۲۰ نمونه استفاده شد که در هر طبقه تعداد ۴ نمونه وجود دارد. شکل (۵-الف) ماتریس اغتشاش را برای تعداد تکرار ۱۵۰ نشان می‌دهد که کمترین دقت و بیشترین خطا را به خود اختصاص داده است. در این حالت، نمونه‌های موجود در طبقه‌های A، B، D و E کاملاً درست طبقه‌بندی شده‌اند و روی قطر اصلی قرار دارند. تعداد ۴ نمونه در طبقه اشتباه طبقه‌بندی شده‌اند که مربوط به طبقه C هستند. از این ۴ نمونه، ۲ نمونه به‌اشتباه در طبقه A و دو نمونه دیگر به‌اشتباه در طبقه D قرار گرفته‌اند. شکل‌های (۵-ب) و (۵-ج) طبقه‌بندی نمونه‌ها با تعداد ۲۰۰ و ۲۵۰ تکرار را نشان می‌دهند. در این حالت، ۲ نمونه در طبقه نادرست طبقه‌بندی شده‌اند که هر دو مربوط به طبقه C هستند که یکی از آن‌ها به‌اشتباه در طبقه B و دیگری در طبقه D دسته‌بندی شده‌اند.



شکل ۶- احتمال تعلق نمونه‌ها به سه طبقه نزدیک

Fig. 6 Top-3 predicted labels

از روش شبکه‌های عصبی عمیق برای طبقه‌بندی تصاویر، دقت ۹۸٪ را به دست آوردند.

۴- نتیجه‌گیری

در این مطالعه طبقه‌بندی کدورت آب و عمق دیسک سکی مبتنی بر یادگیری عمیق ارائه شده است که نتایج حاصل از آن به صورت زیر است:

۱- نتایج حاصل از روش ارائه شده با نتایج آزمایشگاهی به دست آمده برای طبقه‌بندی کدورت آب و عمق دیسک سکی مطابقت دارد.

۲- بهترین نتایج از اجرای شبکه عمیق کانولوشن با تعداد تکرار ۳۰۰ به دست آمد.

۳- با توجه به ماتریس اغتشاش در تعداد تکرار ۳۰۰، فقط یک خطا به اشتباه طبقه‌بندی شده است که مربوط به کلاس C است.

با توجه به شکل (۶)، شبکه کانولوشن تشخیص داده است که نمونه B با احتمال بالایی به طبقه B تعلق دارد، اما تا حدودی به طبقه‌های C و D شباهت دارد. نمونه C، به ترتیب شباهت زیادی به طبقه‌های D، C و B دارد، یعنی درست است که این نمونه در طبقه نادرست قرار گرفته است اما برچسب C جزو سه طبقه‌ای است که شبکه تشخیص داده است. نمونه E به درستی تشخیص داده شده است، اما تا حدودی به طبقه‌های D و C هم شباهت دارد. همچنین نمونه D به درستی در دسته D طبقه‌بندی شده است و به تشخیص شبکه، بیشترین شباهت را به طبقه D دارد، اما به طبقه‌های C و E هم شباهت دارد. (Oga et al. (2019).
برای طبقه‌بندی کیفیت آب بر اساس تصویر از شبکه عمیق کانولوشن استفاده و دقت بالای ۹۰٪ به دست آوردند. (Montassar and Benazza-Benyahia (2020) با ایجاد کدورت در آب، در هر مرحله از نمونه‌ها تصویربرداری کردند و تصاویر را در سه طبقه مختلف قرار دادند. سپس با استفاده

حاصل شده پیشنهاد می‌شود در مطالعات آینده، این آزمایش‌ها در شرایط مزرعه‌ای و طبیعی صورت گیرد.

سیاسگزاری

از همکاری صمیمانه مسئول آزمایشگاه شیمی محیط، دانشکده بهداشت دانشگاه علوم پزشکی تبریز و کارشناس سازمان آب منطقه‌ای استان آذربایجان شرقی در جمع‌آوری داده‌ها و پیشبرد این مطالعه، تشکر و قدردانی می‌شود.

دسترسی به داده‌ها

در این پژوهش از داده‌های ثبت شده در آزمایشگاه استفاده شده است که تعدادی از آن‌ها در متن مقاله ارائه شده است ولی همه داده‌های تولید شده در این پژوهش به دلیل استفاده از آن در رساله دکتری قابل انتشار نمی‌باشند.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که، هیچ‌گونه تضاد منافعی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

References

- Aghighi, H., Ali Mohammadi, A., Serajian, M. and Ashurlu, d. (2008). Estimation of Gorgan Bay water turbidity using IRS LISS-III images. *J. Space Plan. Design*, 13(3), 55-72 [In Persian].
- Anonymous (2011). Evaluating household water treatment options. World Health Organization. Available on: <https://apps.who.int>.
- Apaydin, H., Feizi, H., Sattari, M. T., Colak, M. S., Shamshirband, S. and Chau, K. W. (2020). Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting. *J. Water*, 12(5), 1500. DOI: [10.3390/w12051500](https://doi.org/10.3390/w12051500).
- Baratloo, A., Hosseini, M., Negida, A. and El Ashal, G. (2015). Part 1: simple definition and calculation of accuracy, sensitivity and specificity. *Educat.*, 3(2), 48-49.
- Feizi, H., Apaydin, H., Sattari, M. T., Colak, M. S. and Sibtain, M. (2022). Improving reservoir inflow prediction via rolling window and deep learning-based multi-model approach: case study from Ermenek Dam, Turkey. *Stochastic Environ. Res. Risk Assess.*, 36, 1-21. DOI: [10.1007/s00477-022-02185-3](https://doi.org/10.1007/s00477-022-02185-3).
- Ferentinos, K. (2018). Deep learning models for plant disease detection and diagnosis. *Comput. Electron. Agri.*, 145, 311-318. DOI: [10.1016/j.compag.2018.01.009](https://doi.org/10.1016/j.compag.2018.01.009)
- Han, J., Pei, J. and Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.
- Hussain, I., Ahamad, K. and Nath, P. (2016). Water turbidity sensing using a smartphone. *RSC Adv.*, 6(27), 22374-22382. DOI: [10.1039/C6RA02483](https://doi.org/10.1039/C6RA02483)
- Kallio, K., Attila, J., Härmä, P., Koponen, S., Pulliainen, J., Hyytiäinen, U. M. and Pyhälähti, T. (2008). Landsat ETM+ images in the estimation of seasonal lake water quality in boreal river basins. *Environ. Manage.*, 42(3), 511-522. DOI: [10.1007/s00267-008-9146-y](https://doi.org/10.1007/s00267-008-9146-y).
- Kamboj, N. and Kamboj, V. (2019). Water quality assessment using overall index of pollution in riverbed-mining area of Ganga-River Haridwar, India. *Water Sci.*, 33(1), 65-74. DOI: [10.1080/11104929.2019.1626631](https://doi.org/10.1080/11104929.2019.1626631).
- Karnawat, V. and Patil, S. L. (2016). Turbidity detection using image processing. In 2016 International Conference on Computing, Communication and Automation (ICCCA) (pp. 1086-1089). IEEE. DOI: [10.1109/ICCCA.2016.7801086](https://doi.org/10.1109/ICCCA.2016.7801086)

- [10.1109/CCAA.2016.7813877](https://doi.org/10.1109/CCAA.2016.7813877).
- Montassar, I. and Benazza-Benyahia, A. (2020). Water turbidity estimation in water sampled images. In 2020 5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), 1-5. DOI: [10.1109/ATSIP49331.2020.9231862](https://doi.org/10.1109/ATSIP49331.2020.9231862).
- Najafzadeh, M., Ghaemi, A. and Emamgholizadeh, S. (2019). Prediction of water quality parameters using evolutionary computing-based formulations. *Int. J. Environ. Sci. Technol.*, 16(10), 6377-6396. DOI: [10.1007/s13762-018-2049-4](https://doi.org/10.1007/s13762-018-2049-4).
- Naresh Kumar, M., Murthy, C. S., Sessa Sai, M. V. R. and Roy, P. S. (2009). On the use of standardized precipitation index (SPI) for drought intensity assessment. *Meteorol. Appl.* 16, 381–389. DOI: [10.1002/met.136](https://doi.org/10.1002/met.136).
- Oga, T., Umeki, Y., Iwahashi, M. and Matsuda, Y. (2018). River water quality estimation based on convolutional neural network. *Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*. 1305-1308. DOI: [10.23919/APSIPA.2018.8659554](https://doi.org/10.23919/APSIPA.2018.8659554).
- Pan, B., Hsu, K., AghaKouchak, A. and Sorooshian, S. (2019). Improving precipitation estimation using convolutional neural network. *Water Resour. Res.*, 55(3), 2301-21. DOI: [10.1029/2018WR024090](https://doi.org/10.1029/2018WR024090).
- Preisendorfer, W. (1986). *Secchi disk science: Visual optics of natural waters*. DOI: [10.4319/lo.1986.31.5.0909](https://doi.org/10.4319/lo.1986.31.5.0909).
- Rangzan, k., Fattahi Moghaddam, M., Saberi, A., Hosseini Zare, n. and Mobad, P. (2012). Estimation of water quality of Karun River in Ahvaz area by ground data, field spectroscopy 3 and hyperspectral data of hyperion sensor. *Adv. Appl. Geol.*, 2(4), 98-108 [In Persian].
- Salamati, N. and Moazed, H. (2008). Investigation of the effects of irrigation water turbidity on some physical and hydraulic properties of soil. *Agri. Res. Water Soil Plant. Agri.*, (1)8, 113-123 [In Persian].
- Taheri Shahraeini, H. (2014). Experimental modeling of transparency in the Caspian Sea using MERIS data. *J. Space Sci. Technol.*, (2)7, 11-21 [In Persian].
- Wang, Z. Y. and Chunhong, H. U. (2009). Strategies for managing reservoir sedimentation. *Int. J. Sediment Res.*, 24(4), 369-384. doi.org/10.1016/S1001-6279(10)60011-X.
- Zhang, K., Thé, J., Xie, G. and Yu, H. (2020). Multi-step ahead forecasting of regional air quality using spatial-temporal deep neural networks: a case study of Huaihai Economic Zone. *J. Clean. Product.*, 277, 123231. DOI: [10.1016/j.jclepro.2020.123231](https://doi.org/10.1016/j.jclepro.2020.123231).

How to cite this paper:

Feizi, H., Sattari, M. T. and Mosaferi, M. (2023). Classification of water turbidity and depth of secchi disk using convolutional neural network. *Environ. Water Eng.*, 9(2), 211–225. DOI: [10.22034/ewe.2022.349535.1795](https://doi.org/10.22034/ewe.2022.349535.1795)