

established in
2016



MAS JOURNAL of Applied Sciences

ISSN 2757-5675

DOI: <http://dx.doi.org/10.52520/masjaps.226>

Araştırma Makalesi

Yapay Zeka Modeli İle Sulama Barajlarında Gövde Yüksekliği Tahmini

Şükrü ĞAYA¹ (Orcid ID: 0000-0003-4074-4234), Gizem ŞAHİN¹ (Orcid ID: 0000-0003-1482-7597), Ergin ĞAYA¹ (Orcid ID: 0000-0003-4074-4234), Ayfer KOYUNOĞLU¹ (Orcid ID: 0000-0002-0974-4183), Selami ŞAHİN¹, (Orcid ID: 0000-0001-5608-5611), Murat CANPOLAT¹ (Orcid ID: 0000-0003-4074-4234)

¹Milli Eğitim Bakanlığı

*Sorumlu yazar: murkar444@gmail.com

Geliş Tarihi: 20.11.2021

Kabul Tarihi: 18.01.2022

Özet

Barajlar ülkemiz için en önemli yapılardan biridir. Barajların gövde yüksekliği, barajların verimliliğinde önemli faktörlerden biridir. Günümüzde barajların gövde yüksekliği mühendisler tarafından hesaplanmaktadır. Çalışmamızın amacı, yapay zekanın derin öğrenme modeli ile baraj yüksekliğini hesaplamaktır. Modelleme python yazılımı ile kodlanmıştır. Baraj verilerinin analizi için Numpy pandas kütüphaneleri kullanıldı. Verileri görselleştirmek için Matplotlib ve seaborn kullanıldı. Derin öğrenme modellemesi için Sklearn, tensorflow ve keras kütüphaneleri kullanıldı. Baraj verileri Türkiye'deki sulama barajları ile sınırlıdır. Veri analizi için yükseklik, yükseklik, hacim, alan, sıcaklık ve yağış özellikleri dikkate alınmıştır. Çalışmamız sonucunda, baraj verileri derin öğrenme modelinin çok katmanlı yapay sinir ağları üzerinden makineye öğretilerek baraj gövde yüksekliği tahmini yapılmıştır. Vücut boyu tahminlerindeki sapma, verilerin yetersiz olması nedeniyle daha yüksek bulundu.

Anahtar Kelimeler: Yapay zeka, derin öğrenme, baraj, gövde yüksekliği

Body Height Estimation In Irrigation Dams With Deep Learning Model

Abstract

Dams are one of the most important constructions for our country. The body height of the dams is one of the important factors in the efficiency of the dams. Today, the body height of dams is calculated by engineers. The aim of our study is to calculate the dam height with the deep learning model of artificial intelligence. Modeling was coded with python software. Numpy pandas libraries were used for the analysis of dam data. Matplotlib and seaborn were employed to visualize the data. Sklearn, tensorflow and keras libraries were used for deep learning modeling. Dam data are limited to irrigation dams in Turkey. For data analysis, the altitude, height, volume, area, temperature and precipitation characteristics were taken into consideration. As a result of our study, the dam body height estimation was done by teaching the dam data to the machine through multi-layer artificial neural networks of the deep learning model. The deviation in the body height estimations was found to be higher due to the insufficient data.

Keywords: Artificial intelligence, deep learning, dam, body height

GİRİŞ

Canlıların en önemli kaynaklarından birisi sudur. Su, vazgeçilmesi mümkün olmayan canlıların en önemli doğal kaynaklarından birisidir. Yeryüzündeki suların sadece %3'ü atlı sudur. Tatlı suların da %78'i kutuplarda bulunmaktadır. Bu durum suyun kullanım durumunu sınırlamaktadır (Tepe, Karakaya, Şahin, Sesli, Küçükylmaz ve Aksağan, 2018). Baraj, suyun bir yerde toplanılarak elektrik üretme, selleri önleme, su ihtiyacını karşılama ve sulamada kullanılması amacıyla akarsu üzerine inşa edilen bent demektir. Barajlar ayrıca su tedariki, taşkınları kontrol altına alma, enerji üretme, ulaşım, balıkçılık, tuzluluk oranını kontrol etme ve yeraltındaki suları beslenmeye yönelik olarak yapılır (Dorum, Bolat ve Akkaya, 2010). Gelişen inşaat mühendisliği sayesinde günümüzde artık daha yüksek barajlar yapılmaktadır. Barajlar büyüklüğüne göre;

- Büyük barajlar; Temelden krete kadar olan bölümü 15m'den büyük yada yüksekliği 10-15 m arasında olan barajlardır.
- Küçük barajlar; 15 m'den daha düşük yükseklikte olan barajlardır (Güven ve Aydemir 2014).

Tarihte en büyük üç olaydan birincisi kainatın oluşumu, ikincisi yaşamın başlangıcının olması üçüncüsü de yapay zekanın ortaya çıkmasıdır (Pirim, 2016). Yapay zeka; insan davranışlarını taklit etme, tahmin etme, hareket etme, konuşma ve ses algılama gibi özelliklerden oluşur. Yazılım ve donanım özelliklerinden birlikte faydalanır. Yapay zeka tamamen yapay araçlar ile insana ait olan davranışlar ve hareketleri taklit eden teknolojik makine sistemleridir (Sucu ve Ataman, 2020). Yapay zekanın alt dallarından biri olan makine öğrenmesi, yapay zeka

algoritmalarının programlanması ile bu algoritmaların ayrıştırdığı verilerden öğrendikleri ile kararlar verebilen işlemdir (Şapçı ve Taşlı Pektaş, 2021). Derin öğrenme, beynimizde bulunan yapay sinir ağları olarak isimlendirilen sistemden ortaya çıkan makine öğrenmesi algoritmasıdır. Yapay nöronlar giriş biyolojik nöronlar gibi sinyallerini alır, toplar ve işleyerek çıkışlara iletir. (Şişmanoğlu, Koçer, Önde ve Şahingöz, 2020). Günümüzde baraj gövde yüksekliği mühendislik hesaplamalarıyla sonuca varırken, yapay zekanın derin öğrenme modeli ile Türkiye'de bulunan tüm barajların verileri kullanılarak yükseklik hesabı yapmak mümkündür.

AMAÇ

- Türkiye'deki barajların verileri makinaya öğretmek,
- Barajların gövde yükseklikleri yapay zeka ile tahmin etmek,
- Yeni yapılacak sulama barajlarında gövde yüksekliği belirlemede yapay zeka tahmini kullanmak amaçlarımızdır.

ÖNEM

Yapay zekanın derin öğrenme modellemesi kullanılarak baraj gövde yüksekliği tahmini konusunda daha önce yapılmış herhangi bir bilimsel yayına, patent ve tez çalışmasına rastlanmamıştır. Derin öğrenme modeli ile gövde yükseklik tahmini çalışmamız bu alanda yapılan ilk çalışma olma özelliğine sahip olduğu düşünülmektedir.

YÖNTEM

Araştırma modeli

Çalışmamızda niceliksel araştırma yöntemlerinden deneysel model uygulanmıştır.

Veri toplama araçları ve özellikleri

Bu çalışmada kullanılan cihazlar ve malzemelerin özellikleri şu şekildedir:

- Python 3.9: Python, nesne yönelimli, yorumlamalı, birimsel ve etkileşimli yüksek seviyeli bir programlama dilidir.
- Jupyter Notebook: Çeşitli programlama dilleri için etkileşimli bir ortam sağlayan açık kaynak kodlu bir programdır.
- Numpy: Python programlama dili için büyük, çok boyutlu dizileri ve matrisleri destekleyen, bu dizilere üst düzey matematiksel işlevler ekleyen bir kitaplıktır.
- Pandas: Veri işleme ve analizi için yazılmış olan bir yazılım kütüphanesidir.
- Matplotlib: Python ve sayısal matematik uzantısı NumPy için çizim kitaplığıdır.
- Seaborn: Python'da ilgi çekici ve bilgilendirici istatistiksel grafikler yapmak için kullanılan bir kütüphanedir.
- Sklearn: Python Programlama dili için ücretsiz bir makine öğrenimi kitaplığıdır.
- Tensorflow: Makine öğrenimi için ücretsiz ve açık kaynaklı bir yazılım kütüphanesidir. Bir dizi görevde kullanılabilir, ancak derin sinir ağlarının eğitimi ve çıkarımına özel olarak odaklanmaktadır.
- Keras: Python'da yazılmış açık kaynaklı bir sinir ağı kütüphanesidir.

• Microsoft Excel: Microsoft tarafından Microsoft Windows ve Apple Macintosh işletim sistemleri tabanında çalışmak üzere yazılan ve dağıtımı yapılan bir tablolu programdır.

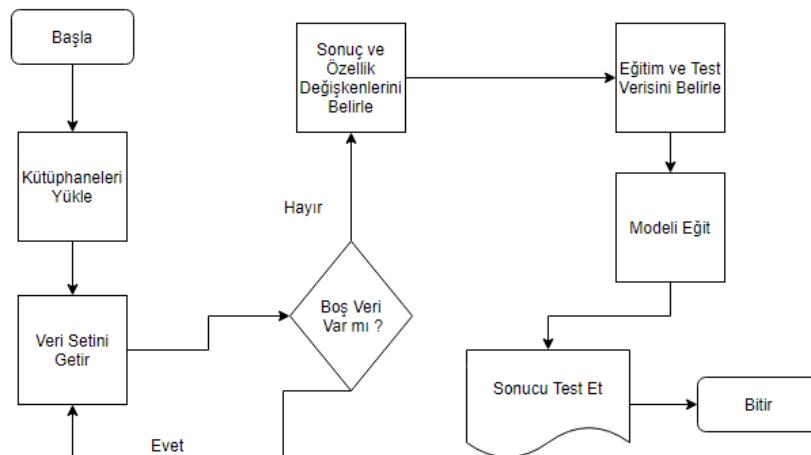
Verilerin toplanması için;

- Literatür taraması 60 gün sürmüştür.
- Veri seti oluşturulması 30 gün sürmüştür
- Algoritma hazırlanması ve yazılımın kodlanması 60 gün sürmüştür.
- Verilerin toplanması ve analizi (deneysel yöntem) 30 gün sürmüştür.
- Sonuçların raporlandırılması ve rapor yazımı 60 gün sürmüştür.
- Çalışmalar pandemi koşulları ve iş sağlığı ve güvenliği şartlarına göre önlem alınarak tamamlanmıştır.

İşlem Adımları

Çalışmamız aşağıdaki algoritma çerçevesinde gerçekleştirilmiştir.

1. Problem tespit edildi
2. Literatür taraması yapıldı.
3. Hipotez ileri sürüldü.
4. Baraj veri seti hazırlandı. Türkiye'de bulunan ve sulama amaçlı kullanılan toplam 238 baraj bilgisi kullanılarak oluşturuldu. (Ek 1)
5. Yazılım algoritması tasarlandı (Şekil 1).



Şekil 1. Yazılım algoritması

6. Jupyter notebook programı üzerinden python ile yapay zeka yazılımı kodlandı.

Çalışmanın yazılımının detaylı anlatımı:

a) Yazılımda kullanılacak olan kütüphaneler yüklendi .

```
import pandas as pd
```

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
import seaborn as sbn
```

b) Baraj veri seti (Ek 1) yazılıma eklendi ve ilk 5 veri görüntülendi.

```
dataFrame=pd.read_excel("sulama.xlsx")
```

```
dataFrame.head()
```

sulama	rakim	yukseklık	hacim	alan	sıcaklık	yagis
27050.0	60	66.0	87.50	6.70	18.3	556.0
4254.0	1112	60.0	36.42	1.94	12.3	481.0
3000.0	1213	54.0	24.00	1.70	11.7	377.0
44030.0	1268	95.0	500.00	18.60	8.8	733.0
3262.0	119	44.5	91.75	4.28	14.6	806.0

	sulama	rakim	yukseklık	hacim	alan	sıcaklık	yagis
count	238.000000	238.000000	238.000000	238.000000	238.000000	238.000000	238.000000
mean	17162.106765	821.441176	57.67437	130.052227	13.197870	12.787395	642.774118
std	61649.741695	556.713225	25.67732	266.583418	57.870655	10.463350	195.127316
min	10.924000	13.000000	7.50000	0.900000	0.100000	2.500000	7.240000
25%	2152.500000	255.250000	42.00000	18.470000	1.362500	9.900000	499.750000
50%	5181.500000	892.000000	53.00000	43.495000	3.050000	11.550000	616.500000
75%	12841.750000	1191.250000	70.00000	105.500000	6.700000	14.600000	768.000000
max	874200.000000	2451.000000	169.00000	2025.000000	817.000000	136.000000	1218.000000

c) Veri setinin özellikleri görüntülendi.

```
dataFrame.describe()
```

d) Boş veri olup olmadığı kontrol edildi ve boş veri olmadığı görüldü.

```
dataFrame.isnull().sum()
```

```
sulama 0
```

```
rakim 0
```

```
yukseklık 0
```

```
hacim 0
```

```
alan 0
```


```
sıcaklık 0
```

```
yagis 0
```

```
dtype: int64
```

e) Seaborn kütüphanesi ile “Yükseklik” verisinin dağılım grafiği çizildi (Grafik 1).

```
sbn.distplot(dataFrame["yukseklık"])
```



Grafik 1. Yükseklik Verisi Dağılım Grafiği

f) Sonuç(y) ve özellik(x) değişkenleri belirlendi. Sonuç ulaşmak istediğimiz “yükseklik verisi, özellik ise yüksekliği etkileyen özellikler olarak belirlenmiştir

```
y=dataFrame["yükseklik"].values
x=dataFrame.drop("yükseklik","rakim",
axis=1).values
```

g) Sklearn kütüphanesi kullanılarak eğitim ve test verileri belirlendi. Olarak Verilerin yüzde 33’ü test verisi olarak belirlendi.

```
from sklearn.model_selection import
train_test_split
x_train,x_test,y_train,y_test=train_test_
split(x,y,
test_size=0.33, random_state=10)
```

h) Sklearn kütüphanesi kullanılarak veri ölçeklemesi ve normalleşmesi yapılarak tüm veriler 0 ile 1 arasına ölçeklendirildi (Scaling).

```
from sklearn.preprocessing import
MinMaxScaler
scaler=MinMaxScaler()
x_train=scaler.fit_transform(x_train)
x_test=scaler.transform(x_test)
```

i) Tensorflow ve Keras kütühanesi

ile derin öğrenme modeli ve katmanlar oluşturuldu.

```
from tensorflow.keras.models import
Sequential
```

```
from tensorflow.keras.layers import
Dense
```

```
model=Sequential()
model.add(Dense(10,activation="relu"))
model.add(Dense(10,activation="relu"))
model.add(Dense(10,activation="relu"))
model.add(Dense(10,activation="relu"))
model.add(Dense(1))
model.compile(optimizer="adam",loss=
"mse")
```

j) Hazırladığımız model x_test ve y_test verileri ile eğitildi (fit fonksiyonu).


```
model.fit(x=x_train,y=y_train,validatio
n_data=(x_test,y_test),batch_size=4,epo
chs=20)
```

k) Kayıp fonksiyonun oranı belirlendi ve eğitilen modelin grafiği çıkarıldı.

```
kayıpverisi=pd.DataFrame(model.histor
y.history)
```

```
kayıpverisi.head()
```

loss	val_loss
3869.766113	4145.505859
3809.660400	4036.255127
3611.790039	3640.785156
2915.788574	2370.953369
1353.936646	634.589844




Grafik 2. Loss, Val Loss Grafiği

- l) Test verileriyle tahmin işlemi gerçekleştirilerek grafiğe döküldü.
- ```

tahminDizisi=model.predict(x_test)
plt.scatter(y_test,tahminDizisi)
plt.plot(y_test,y_test)

```



Grafik 3. Test Verilerinin Tahmin Grafiği

m) Sonuçlar test edilmesi için tahmin sapma miktarı tespit edildi. Modelin eğitilmesinde sapmanın 17 metre olduğu görüldü.

`mean_absolute_error(y_test,tahminDizisi)`

n) Predict fonksiyonu ile baraj yükseklikleri tahmin edildi.

```

yeniSonuc=[[15006,910,106,6,13,410]]
yeniSonuc=scaler.transform(yeniSonuc)
model.predict(yeniSonuc)

```

7. Hipotezin geçerliliğini sınamak için hazırlanan yazılım test edildi.

8. Sonuçlar yorumlanıp raporlaştırıldı.

**System Sistemin çalışma prensibi**

Python yazılımı ve jupyter notebook programı kullanılarak Türkiye’deki baraj verileri yapay zekaya derin öğrenme modeli ile öğretildi. Modelin öğrenmesi ile baraj gövde yükseklik tahmini gerçekleştirildi.

**SONUÇ**

“dataFrame.corr()["yükseklik"].sort\_values()” kod satırı ile yüksekliğin diğer özelliklere bağlı ilişkisi çıkarılmıştır.

|                  |                  |
|------------------|------------------|
| <b>Rakım</b>     | <b>-0.050422</b> |
| <b>Sıcaklık</b>  | 0.089145         |
| <b>Yağış</b>     | 0.113927         |
| <b>Alan</b>      | 0.313895         |
| <b>Sulama</b>    | 0.362527         |
| <b>Hacim</b>     | 0.374830         |
| <b>Yükseklik</b> | 1.000000         |

**Tablo 2.** Yükseklik ve Diğer Değişkenlerin Korelasyon İlişkisi

Tablo 2’ye göre yüksekliğin en çok akarsu/göl hacmiyle ilişkili olduğu görülmektedir. Ayrıca “sulama alanı” ve “akarsu/göl alanı” ile de yüksek ilişkili olduğu, bölgedeki ortalama “yağış” ve “sıcaklık” ile daha az ilişkili olduğu görülmüştür. Barajın kurulacağı yerin “rakım” bilgisinin baraj gövde yüksekliği ile negatif ilişkide olduğu görülmüştür.

```
“from sklearn.metrics import
mean_squared_error,mean_absolute_err
or”
```

```
“mean_absolute_error(y_test,tahminDiz
isi)”
```

kod dizeleri ile test edilen verinin sapma payı ölçümü için gerekli kütüphane

eklenerek sapma payı bulgusu “17.849326150628585” metre olarak hesaplanmıştır.

Yazılım üzerinde tahminde bulunma bulguları Tablo 3’de görüldüğü gibi sonuçlanmıştır. Sonuçlar her seferinde bir değişkenin değiştirilip, diğer değişkenlerin sabit tutularak denenmiştir. Tablo 3’de açıkça görüldüğü gibi “yükseklik” “hacim” değişkenine bağlı olarak ciddi oranda etkilenmiştir. En az etkilenme “alan” ve “sıcaklık” değişkeninde olduğu görülmüştür. Bunun sebebi ise alan ve sıcaklık ortalama değerlerinde ciddi artışların yazılamamasıdır.

| Sulama       | Rakım     | Hacim     | Alan      | Sıcaklık | Yağış      | Tahmin |
|--------------|-----------|-----------|-----------|----------|------------|--------|
| <b>20000</b> | 1000      | 800       | 12        | 10       | 300        | 82     |
| <b>20000</b> | <b>10</b> | 800       | 12        | 10       | 300        | 78     |
| <b>50000</b> | 1000      | 800       | 12        | 10       | 300        | 73     |
| <b>20000</b> | 1000      | <b>50</b> | 12        | 10       | 300        | 67     |
| <b>20000</b> | 1000      | 800       | <b>16</b> | 10       | 300        | 82     |
| <b>20000</b> | 1000      | 800       | 12        | <b>3</b> | 300        | 80     |
| <b>20000</b> | 1000      | 800       | 12        | 10       | <b>800</b> | 94     |

**Tablo3.** Tahminde Bulunma Bulgularına Ait Sonuçlar

Hazırladığımız yazılım ile derin öğrenme modeli kullanılarak baraj

verileri makineye öğretilmiştir. Verilerini kullanarak yapay zeka baraj

gövde yükseklik tahmininde bulunmuştur. Çalışmanın üstün yönleri;

- Baraj gövde yüksekliklerinin yapay zeka ile tahmin edilebilmesi,

- Tahminin yazılım ile hazırlanmasından dolayı maliyet oluşturmaması

- Yazılımın inşaat mühendisleri tarafından kolaylıkla kullanabilmesidir.

Çalışmanın zayıf yönleri;

- Yazılımda sadece sulama barajlarının yükseklik tespiti ile hazırlanması

- Veri setinin 238 adet baraj verisiyle sınırlı olması

- Kullanılan veride bazı barajların hem hidroelektrik hem de sulama amaçlı kullanılmasından dolayı yükseklik farkının fazla olması

- Yükseklik farkından dolayı yazılım sapma katsayısının fazla olması

Çalışmanın uygulanabilirliği;

Çalışmamız yeni yapılacak barajlarda mühendisler tarafından yükseklik hesabı yapılarak yapay zeka tahminiyle karşılaştırmalı kullanılabilir. Özellikle veri seti arttırılıp öğrenmenin daha başarılı hale getirilebilirse, yapay zeka tahmini yükseklik hesabında ciddi veriler sağlayacaktır

## KAYNAKLAR

Tepe, R., Karakaya, G., Şahin, A. G., Sesli, A., Küçükylmaz, M., Aksağan, A. 2018. Karkamış Baraj Gölü Trofik Durumu . International Journal of Innovative Engineering Applications, 2 (1): 1-3

Dorum, A., Bolat, H., Akkaya, U. 2010. Sürdürülebilirlik Açısından Baraj Gövde Tipinin Seçimini Etkileyen Faktörler . Engineering Sciences, 5 (4): 649-657.

Aytaç-Güven, Alper Aydemir, 2014. Toprak Dolgu Barajlar İçin Risk Değerlendirmesi, Uluslararası Katılımlı Iv. Ulusal Baraj Güvenliği Sempozyumu

Pirim, H. 2006. Yapay Zeka. Yaşar Üniversitesi E-Dergisi, 1(1): 81-93.

Şişmanoğlu, G., Koçer, F., Önde, M.A., Sahingöz, O.K. 2020. Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1): 434-445.

Şapıcı, B., Taşlı Pektaş, Ş. 2021. Makine Öğrenmesi Aracılığı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Süreçleriyle Bütünleştirilmesi. Journal of Computational Design , 2 (1): 67-94

Sucu, İ., Ataman, E. 2020. Dijital Evrenin Yeni Dünyası Olarak Yapay Zeka Ve Her Filmi Üzerine Bir Çalışma. Yeni Medya Elektronik Dergisi, 4(1): 40-52.