

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**FARKLI KAPAK GEOMETRİSİNE SAHİP KONDÜİTLERDE
HAVALANDIRMA PERFORMANSININ YAPAY ZEKÂ
YÖNTEMLERİYLE BELİRLENMESİ**

Zeynep KILIÇ

Yüksek Lisans Tezi

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

İnşaat Mühendisliği Teknolojileri Programı

Hidrolik Bilim Dalı

MAYIS 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İnşaat Mühendisliği Anabilim Dalı
İnşaat Mühendisliği Teknolojileri Programı

Yüksek Lisans Tezi

FARKLI KAPAK GEOMETRİSİNE SAHİP KONDÜİTLERDE
HAVALANDIRMA PERFORMANSININ YAPAY ZEKÂ
YÖNTEMLERİYLE BELİRLENMESİ

Tez Yazarı
Zeynep KILIÇ

Danışman
Prof. Dr. Fahri ÖZKAN

İkinci Danışman

MAYIS 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İnşaat Mühendisliği Anabilim Dalı
İnşaat Mühendisliği Teknolojileri Programı

Yüksek Lisans Tezi

Başlığı:	Farklı Kapak Geometrisine Sahip Kondütlerde Havalandırma Performansının Yapay Zekâ Yöntemleriyle Belirlenmesi
Yazarı:	Zeynep KILIÇ
İlk Teslim Tarihi:	11.04.2022
Savunma Tarihi:	10.05.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Fahri ÖZKAN Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Ahmet BAYLAR Eskişehir Teknik Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Alp Buğra AYDIN Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Farklı Kapak Geometrisine Sahip Kondütlerde Havalandırma Performansının Yapay Zekâ Yöntemleriyle Belirlenmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

10.05.2022

Zeynep KILIÇ



ÖNSÖZ

Hızlı nüfus artışı, sanayi ve teknolojinin hızlı gelişmesi gibi nedenlerle su kullanımı artmakta ve doğal olarak da su kirliliği oluşmaktadır. Bu kirlilik, sudaki çözünmüş oksijen konsantrasyonu azaltmaktadır. Sudaki çözünmüş oksijen konsantrasyonunun azalması, canlı yaşamı için büyük bir tehlike oluşturmaktadır. Bu tehlikenin ortadan kaldırılması için atmosferdeki oksijenin su içerisine transfer edilmesi gerekmektedir. Doğal ortamda bu transferin gerçekleşmesi için uzun bir zamana ve mesafeye ihtiyaç olduğundan, daha kısa sürede daha fazla oksijenin transfer edilmesini sağlayan aralarında yüksek basınçlı kondütlerin de olduğu bazı yapay havalandırma sistemleri geliştirilmiştir.

Yüksek basınçlı kondütlerin havalandırma performansının belirlenmesi için çok sayıda parametrenin olduğu zor ve zaman alıcı deneyler yapılmaktadır. Yapılan deneylerdeki zorlukların ve deneysel hataların azaltılması oldukça önemlidir. Bazı yapay zekâ yöntemleri kullanılarak yapılan analizler ile bu problemler büyük ölçüde ortadan kaldırılabilmektedir. Bu tez çalışmasında, farklı yapay zekâ teknikleri ile havalandırma veriminin hesaplanmasında kullanılan hava debisi değerlerinin tahmin edilebileceği varsayılmıştır. Ayrıca kullanılan yapay zekâ yöntemlerinin, fiziksel bir şekilde yapılan bazı deneylerin yerine kullanılabileceği öngörülmüştür.

Bu çalışmada kullanılan deney verileri TÜBİTAK tarafından desteklenen 215M046 nolu projeden alınmıştır. Desteklerinden ötürü TÜBİTAK'a teşekkür ederim.

Çalışmalarım süresince benden desteklerini esirgemeyen, sahip olduğu akademik bilgileri benimle paylaşarak sorularımı cevaplayan danışman hocam Sayın Prof. Dr. Fahri ÖZKAN'a çok teşekkür ederim.

Çalışmalarım boyunca fikir ve önerileriyle tez çalışmamı geliştiren ve destekleyen hocam Sayın Dr. Öğr. Üyesi Güngör YILDIRIM'a çok teşekkür ederim.

Son olarak, haklarını hiçbir zaman ödeyemeyeceğim, her günümde yanımda olan ve her koşulda beni destekleyen, bugünlere gelebilmemi sağlayan değerli aileme saygılarımı ve teşekkürlerimi sunarım.

Zeynep KILIÇ
ELAZIĞ, 2022

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xii
SİMGELER	xiii
KISALTMALAR	xiv
1. GİRİŞ	1
2. SUYUN HAVALANDIRILMASI.....	3
2.1. Su Kalitesi	3
2.2. Havalandırma	3
2.2.1. Çift Film Teorisi.....	4
2.2.2. Havalandırma Verimi	7
2.2.3. Havalandırmayı Etkileyen Faktörler	7
2.2.4. Havalandırma Teknikleri ve Ölçüm Metotları	8
3. ÇALIŞMADA KULLANILAN VERİ SETİNİN ELDE EDİLDİĞİ PROJE	16
3.1. Yapılan Deneyler.....	16
3.2. Veri Setinin Elde Edilmesi	19
4. TEZ ÇALIŞMASININ HEDEFLERİ	20
4.1. Yapay Sinir Ağları.....	20
4.1.2. Yapay Sinir Ağlarının Sınıflandırılması	22
4.1.3. Yapay Sinir Ağlarının Ana Unsurları.....	24
4.2. Kullanılan Regresyon Analizleri	24
4.2.2. Doğrusal Regresyon Analizi	24
4.2.3. Polinomal Regresyon Analizi.....	25
4.2.4. Destek Vektör Makineleri (Support Vector Machine)	26
4.2.5. Karar Ağaçları (Decision Tree) Regresyon Analizi	26
4.2.6. Rastgele Orman (Random Forest) Regresyon Analizi	27
4.2.7. Gauss Süreç Regresyon Analizi (Gaussian Processes).....	27
4.2.8. En Yakın Komşu Regresyon Analizi (K-Nearest Neighbors).....	28
4.3. Kullanılan Sınıflandırma Algoritmaları	28
4.3.1. Naïve Bayesian Algoritması.....	28
4.3.2. Lojistik Sınıflandırma Algoritması.....	28
4.3.3. SMO Algoritması	29
4.3.4. IBk Algoritması.....	29
4.3.5. JRip Algoritması	29
4.3.6. J48 Algoritması	29
4.3.7. RF Algoritması.....	29
5. DENEYLER VE SONUÇLAR.....	30
5.1. Multi Regresyon Analizi	30

5.2. Polinomal Regresyon Analizi	34
5.3. SVR Regresyon Analizi.....	37
5.4. DT Regresyon Analizi	41
5.5. RF Regresyon Analizi	44
5.6. GP Regresyon Analizi	47
5.7. KNN Regresyon Analizi.....	50
5.8. Sinir Ağları (Neural Network).....	53
5.9. Naive Bayesian Sınıflandırma Uygulaması	58
5.10. Lojistik Sınıflandırma Uygulaması.....	58
5.11. SMO Sınıflandırma Uygulaması	58
5.12. IBk Sınıflandırma Uygulaması	59
5.13. JRip Sınıflandırma Uygulaması.....	59
5.14. J48 Sınıflandırma Uygulaması	59
5.15. RF Sınıflandırma Uygulaması	60
6. MATERYAL VE METOT	61
7. BULGULAR VE TARTIŞMA	62
8. SONUÇLAR.....	63
ÖNERİLER	64
KAYNAKLAR.....	65
ÖZGEÇMİŞ	

ÖZET

Farklı Kapak Geometrisine Sahip Kondütlerde Havalandırma Performansının Yapay Zekâ Yöntemleriyle Belirlenmesi

Zeynep KILIÇ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

İnşaat Mühendisliği Teknolojileri Programı

Mayıs 2022, Sayfa: xiv + 67

Hızlı nüfus artışı, sanayileşme ve çarpık kentleşme gibi nedenlerle su kaynaklarının aşırı ve bilinçsiz kullanılması su kirliliğine sebep olmakta ve sudaki çözünmüş oksijen konsantrasyonunu azaltmaktadır. Ekolojik dengenin sağlanabilmesi için azalan oksijen konsantrasyonunun artırılması gerekmektedir. Oksijen konsantrasyonunun artırılması için, atmosferdeki oksijenin suya kazandırılması gerekmektedir. Fiziksel bir şekilde gerçekleştirilen bu işleme havalandırma adı verilmektedir. Suyun en verimli ve en ekonomik şekilde nasıl havalandırılacağı konusunda zor ve zaman alıcı birçok deneysel çalışma yapılmaktadır. Yapılan deneysel çalışmalar, hava giriş mekanizmasını ve oksijen transferini etkileyen birçok parametre içerdiği için oldukça zaman alıcıdır. Ayrıca kullanılan parametre sayısının fazla olması deneysel hata oranlarını artırmaktadır. Yapılan deneylerdeki bu sorunları en aza indirgeyebilmek oldukça önemlidir. Bu nedenlerle son zamanlarda mühendislik alanında oldukça sık bir şekilde kullanılan yapay zekâ yöntemleri, havalandırma çalışmalarında da kullanılmaya başlamıştır. Bu tez çalışmasında, yapay zekâ yöntemleri ile havalandırma veriminin bulunmasında kullanılan hava debisi değerlerinin tahmin edilmesi önerilmiştir. Ayrıca kondüt kapakları, kalın ve ince kenarlı olmak üzere iki sınıfta değerlendirildiği zaman ilgili parametrelere göre bu kapak tipinin yapay zekâ algoritmaları ile belirlenebileceği gösterilmiştir.

Bu tez çalışmasında, hava giriş oranlarını ölçme amaçlı yapılan deneylerden elde edilen 1008 veriden oluşan veri seti ile hava debisi değerleri tahmin edilmiştir. Çalışmada yedi farklı regresyon analizi ve bir sinir ağı modeli kullanılmıştır. Kullanılan regresyon analizi yöntemleri multi regresyon, polinomal regresyon, destek vektör makineleri, karar ağaçları regresyonu, rastgele orman regresyonu, gauss süreç regresyonu ve en yakın komşu regresyonudur. Ana veri setinin %80'i olan birinci alt küme eğitim aşamasında, ana veri setinin %20'si olan ikinci alt küme ise test aşamasında kullanılmaktadır. Eğitilen modeller, başarı değerlendirmesi için ikinci alt küme verileriyle test edilmiştir. Ayrıca kondüt kapakları Naive Bayesian, lojistik, SMO, IBk, JRip, J48 ve RF olmak üzere yedi farklı sınıflandırma algoritması kullanılarak kalın ve ince kenarlı olmak üzere sınıflandırılmıştır.

Kullanılan yöntemlerin başarısı, regresyon analizlerinde R^2 ve korelasyon değerleri bulunarak; sınıflandırma algoritmalarında ise doğruluk oranları bulunarak ölçülmüştür. Çalışmalar sonucunda, en başarılı regresyon analizlerinin polinomal ve SVR polinomal regresyonları, en başarılı sınıflandırma algoritmalarının ise RF, J48 ve IBk algoritmaları olduğu görülmüştür. Yüksek başarı gösteren bu analiz ve algoritmalar, zor ve zaman alıcı geleneksel deneyler ile elde edilebilecek sonuçların yapay zekâ yöntemleriyle de kısa sürede ve düşük maliyet ile kolayca elde edilebileceğini göstermektedir.

Anahtar Kelimeler: Havalandırma, Oksijen transferi, Havalandırma verimi, Yapay zekâ, Regresyon analizleri, Sınıflandırma Algoritmaları

ABSTRACT

Determination of Aeration Performance in Conduits With Different Cross Section Geometries by Artificial Intelligence Methods

Zeynep KILIÇ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences

Department of Civil Engineering
Civil Engineering Technologies
May 2022, Pages: xiv + 67

Rapid population growth, industrialization and unplanned urbanization causes excessive and inefficient use of water resources, water pollution, and reduces the dissolved oxygen concentration in the water. To achieve ecological balance, the decreased oxygen concentration should be increased by adding the oxygen in the atmosphere to the water. This process is called aeration. Many experimental studies have been carried out on how to aerate of water most efficient and economically. These studies are quite time consuming since they include many parameters that affect the air intake and oxygen transfer mechanism. In addition, the large number of parameters used increases the experimental error rates. It is very important to minimize these problems in the experiments. Artificial intelligence methods, which have been used frequently in engineering applications recently, have also started to be used in aeration studies. In this thesis, it is proposed that the air flow values used to find aeration efficiency can be estimated with artificial intelligence methods. In addition, it has been shown that when conduit gates are evaluated in two classes as radial and sluice, this gate type can be determined by artificial intelligence methods according to the relevant parameters.

In this thesis, air flow rate has been estimated by artificial algorithms trained with a data set containing 1008 data obtained from experiments to measure air intake rates. The study uses seven different regression methods and neural networks with two layers. The regression analysis methods used are multi regression, polynomial regression, support vector machines, decision tree regression, random forest regression, gaussian process regression and nearest neighbor regression. The data set used has been divided into two sub-data sets. The first subset which is 80% of the main data set is used in the training stage and the second subset which is 20% of the main data set is used in the test stage. The trained models have been tested with the second subset of data for the success evaluation. In addition, the class of conduit gates, which must be used, are found with seven different classification algorithms, namely Naive Bayesian, logistics, SMO, IBk, JRip, J48 and RF.

The metrics used for success evaluations are R^2 and correlation values in regression analyzes and accuracy rates in classification algorithms. As a result, it has been seen that the most successful regression models are polynomial and SVR polynomial regressions, and the most successful classification algorithms are RF, J48 and IBk algorithms. The results show that air flow values can be calculated in a short time and at low cost with artificial intelligence models trained with real data, instead of difficult and time-consuming traditional experiments.

Keywords: Aeration, Oxygen transfer, Aeration efficiency, Artificial intelligence, Regression analysis, Classification Algorithms

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Yatay ve dikey borularda iki fazlı akım durumları.....	4
Şekil 2.2. Çift film teorisinin a) mekanizması b) grafiksel gösterimi.....	5
Şekil 2.3. Hidrolik sıçrama.....	9
Şekil 2.4. Hidrolik sıçrama çeşitleri; a) Ondüler sıçrama; b) Zayıf sıçrama; c) Dalgalı sıçrama; d) Düzenli sıçrama; e) Kuvvetli sıçrama	10
Şekil 2.5. Oksijen transfer sistemleri; a) Düzgün jet; b) Dalgalı jet; c) Pürüzlü jet; d) Parçalanmış jet	11
Şekil 2.6. Bir ventüri aygıtının görünümü.....	12
Şekil 2.7. Bir ventüri aygıtının teorik değişkenleri.....	13
Şekil 2.8. Klasik venturilerdeki boyutsal değerler.....	13
Şekil 2.9. Venturilerin oksijen transfer maksatlı kullanımı	14
Şekil 2.10. Kapaklı kondüit mansabında iki fazlı akım.....	14
Şekil 2.11. Kapaklı kondüit içerisindeki iki fazlı akım rejimleri; a) Sadece hava akışı; b) Sprey (püskürme şeklinde) akım; c) Serbest yüzeyli akım; d) Köpüklü akım; e) Hidrolik sıçrama-1; f) Hidrolik sıçrama-2; g) Sadece su akışı.....	15
Şekil 3.1. Hava giriş deneyleri için yüksek basınçlı kapaklı kondüit düzeneği-ince kenarlı kapak	16
Şekil 3.2. Hava giriş deneyleri için yüksek basınçlı kapaklı kondüit düzeneği-kalın kenarlı kapak	17
Şekil 3.3. Dairesel ve dikdörtgen kondüit enkesitleri.....	17
Şekil 3.4. 60/100 dikdörtgen enkesitli kondüit kapak açıklık oranları	17
Şekil 3.5. 100/60 dikdörtgen enkesitli kondüit kapak açıklık oranları	18
Şekil 3.6. Dairesel enkesitli kondüit kapak açıklık oranları	18
Şekil 4.1. Biyolojik sinir hücresi ve yapay sinir ağı	20
Şekil 4.2. Yapay sinir hücresi.....	21
Şekil 4.3. Tek katmanlı bir algılayıcının modellenmesi	22
Şekil 4.4. Çok katmanlı bir algılayıcının modellenmesi.....	23
Şekil 4.5. İleri beslemeli yapay sinir ağı	23
Şekil 4.6. Geri beslemeli yapay sinir ağı	24
Şekil 4.7. Basit bir karar ağacı modeli.....	27
Şekil 5.1. Multi regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği. 30	
Şekil 5.2. Multi regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	31
Şekil 5.3. Multi regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	31
Şekil 5.4. Multi regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği. 32	

Şekil 5.5. Multi regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi	32
Şekil 5.6. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği	34
Şekil 5.7. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği.....	34
Şekil 5.8. Polinomal (6. derece) regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	35
Şekil 5.9. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği	35
Şekil 5.10. Polinomal (6. derece) regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi	36
Şekil 5.11. SVR (polinomal) regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği	37
Şekil 5.12. SVR (polinomal) regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	38
Şekil 5.13. SVR (polinomal) regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	38
Şekil 5.14. SVR (polinomal) regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği	39
Şekil 5.15. SVR (polinomal) regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi	39
Şekil 5.16. DT regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği ..	41
Şekil 5.17. DT regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	41
Şekil 5.18. DT regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği	42
Şekil 5.19. DT regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği ..	42
Şekil 5.20. DT regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi.	43
Şekil 5.21. RF regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği...	44
Şekil 5.22. RF regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	44
Şekil 5.23. RF regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	45
Şekil 5.24. RF regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği ..	45
Şekil 5.25. RF regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi .	46
Şekil 5.26. GP regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği...	47
Şekil 5.27. GP regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	47
Şekil 5.28. GP regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	48

Şekil 5.29. GP regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği ..	48
Şekil 5.30. GP regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi .	49
Şekil 5.31. KNN regresyon analizi (k = 8 için) sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği	50
Şekil 5.32. KNN regresyon analizi (k = 8 için) sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	50
Şekil 5.33. KNN regresyon analizi (k = 8 için) sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği.....	51
Şekil 5.34. KNN regresyon analizi (k = 8 için) sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği	51
Şekil 5.35. KNN regresyon analizi (k = 8 için) sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi	52
Şekil 5.36. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği.....	53
Şekil 5.37. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği	54
Şekil 5.38. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği	54
Şekil 5.39. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği.....	55
Şekil 5.40. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi	55
Şekil 5.41. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen epoch - hata grafiği (1).....	56
Şekil 5.42. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen LR – R2 grafiği.....	56
Şekil 5.43. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen epoch -hata grafiği (2).....	57

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Hidrolik sıçramanın Fr1 sayısına göre sınıflandırılması	10
Tablo 3.1. Deney serilerinin ana hatları	18
Tablo 4.1. Biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları.....	21
Tablo 5.1. Kondüit uzunluğu parametresi hesaba katılarak yapılan multi regresyon analizi sonuçları	33
Tablo 5.2. Kondüit uzunluğu parametresi hesaba katılmadan yapılan multi regresyon analizi sonuçları....	33
Tablo 5.3. Farklı polinom dereceleri için, kondüit uzunluğunun hesaba katıldığı polinomal regresyon analizi sonuçları	37
Tablo 5.4. Farklı polinom dereceleri için, kondüit uzunluğunun hesaba katılmadığı polinomal regresyon analizi sonuçları	37
Tablo 5.5. SVR türüne göre kondüit uzunluğunun hesaba katıldığı SVR regresyon analizi sonuçları	40
Tablo 5.6. SVR türüne göre kondüit uzunluğunun hesaba katılmadığı SVR regresyon analizi sonuçları ...	40
Tablo 5.7. Farklı k değerlerine göre kondüit uzunluğunun hesaba katıldığı KNN regresyon analizi sonuçları	53
Tablo 5.8. Farklı k değerlerine göre kondüit uzunluğunun hesaba katılmadığı KNN regresyon analizi sonuçları.....	53
Tablo 5.9. NN uygulaması sonuçları.....	57
Tablo 5.10. NaiveBayes yöntemi ile elde edilen değerler.....	58
Tablo 5.11. Lojistik sınıflandırma yöntemi ile elde edilen değerler	58
Tablo 5.12. SVM sınıflandırma yöntemi ile elde edilen değerler	58
Tablo 5.13. SVM sınıflandırma yöntemi ile elde edilen değerler	59
Tablo 5.14. JRip sınıflandırma yöntemi ile elde edilen değerler	59
Tablo 5.15. J48 sınıflandırma yöntemi ile elde edilen değerler	60
Tablo 5.16. RF sınıflandırma yöntemi ile elde edilen değerler	60

SİMGELER

A	: Kütle transfer alanı
b_k	: Bias değerleri
C	: Su içerisindeki çözünmüş oksijen seviyesi
C_d	: Mansaptaki çözünmüş oksijen konsantrasyonu
C_s	: Su içerisindeki çözünmüş oksijenin doymunluk konsantrasyonu
C_{s1}	: Çözünmüş oksijenin doyma konsantrasyonunun gerçek atmosfer basıncındaki değeri
C_u	: Membadaki çözünmüş oksijen konsantrasyonu
E	: Havalandırma verimi
E_{20}	: 20 °C'deki oksijen transfer verimi
f_1, f_2	: Aktivasyon fonksiyonu
f_{wq}	: Su kalitesini gösteren boyutsuz bir katsayıyı
K_g	: Kütle transfer katsayısı
P	: Gerçek atmosfer basıncı
P_v	: Buhar basıncı
P_{at}	: Standart atmosfer basıncı
r	: Oksijen eksiklik oranı
T	: Su sıcaklığı
V	: Sistemdeki toplam hacim
w_{kj}	: Ağırlık
x	: Ortalama fonksiyon
x_j	: Girdiler
X_1	: Açıklayıcı Değişken
Y	: Yanıt değişkeni
y_i	: Gerçek değerler
$\hat{y}_i$	: Tahmini değerler
α	: Öğrenme oranı
γ	: Suyun birim hacim ağırlığı

KISALTMALAR

DT	: Decision tree
GP	: Gaussian Processes
HD	: Hava debisi
KA	: Kapak açıklığı
KG	: Kesit geometri
KG1	: 60/100 dikdörtgen enkesitli radyal kapak
KG2	: 60/100 dikdörtgen enkesitli ince kenarlı kapak
KG3	: 100/60 dikdörtgen enkesitli radyal kapak
KG4	: 100/60 dikdörtgen enkesitli ince kenarlı kapak
KG5	: Dairesel enkesitli radyal kapak
KG6	: Dairesel enkesitli ince kenarlı kapak
KNN	: K-Nearest Neighbors
KU	: Konduit uzunluğu
LR	: Learning rate
NN	: Neural Network
RF	: Random Forest
SD	: Su debisi
SVM	: Support Vector Machines
SVR	: Support Vector Regression
YSA	: Yapay sinir ağları

1. GİRİŞ

Dünya nüfusunun hızlı artışı, sanayi ve teknolojinin hızla gelişmesi temiz su kaynaklarına olan ihtiyacı artırmakla birlikte var olan su kaynaklarında da ciddi bir kirliliğe neden olmaktadır. Kirlenme neticesinde sudaki canlılığın devamı için gerekli çözünmüş oksijen konsantrasyonu azalmaktadır ve doğal ortamda bu konsantrasyonun sınır değerlere ulaşması için uzun bir zamana ve mesafeye ihtiyaç vardır. Ancak yapılan çalışmalar, aralarında basınçlı kondütlerin de olduğu bazı hidrolik akım sistemleri yardımıyla yapılan havalandırma işlemlerinin kısa sürede, çözünmüş oksijen konsantrasyonu değerlerini istenilen seviyelere getirilebildiğini göstermiştir. Kondütlerin havalandırma performanslarının geliştirilmesi ve hangi şartlar altında ne kadar verimli olduklarının belirlenmesi amacıyla çalışmalar yürütülmektedir. Bu çalışmalarda değiştirilen her hidrolik parametre için (kapak açıklığı, boru boyu, debi değeri, kapak geometrisi vb.) onlarca ve toplamda da yüzlerce yorucu, maliyetli ve zaman alıcı deney yapılması ve bu deneylerin değerlendirilmesi gerekmektedir. Hem bu zorlukları azaltmak ve hem de yapılabilecek deney hatalarını en aza indirebilmek büyük önem arz etmektedir.

Bu çalışmada son yıllarda birçok mühendislik alanında sıkça kullanılan yapay zekâ yöntemleri yardımıyla farklı enkesit ve kapak geometrilerine sahip kondütlerde havalandırma performansının daha kısa sürede ve daha kolay bir şekilde belirlenmesi amaçlanmaktadır. Bu amaçla, farklı kapak geometrisine ait kondütlerde havalandırma performansını araştıran TUBİTAK 215M046 projesinde yapılan deneyler sonucunda elde edilen veriler yapay zekâ sistemleriyle incelenmiştir. Kapak açıklığı, kondüt uzunluğu, su debisi ve kesit geometrisi parametrelerinin kullanıldığı çeşitli regresyon analizleri (multi, polinomal, SVR, DT, RF, GP, KNN) ve sinir ağları (NN) ile veri setindeki hava debisinin gerçek değerlerine yakın olan tahmini değerler elde edilmeye çalışılmıştır. Kullanılan yapay zekâ metotları ile doğruya en yakın sonucun elde edildiği analizlerin polinomal ve SVR polinomal regresyon analizleri olduğu görülmüştür. Ayrıca regresyon analizleri, kondüt uzunluğu parametresinin hesaba katılmadığı veri seti üzerinde de uygulanmıştır ve bu parametrenin deney sonuçlarında büyük değişimlere yol açmadığı gözlenmiştir. Yapılan çalışmada ayrıca yedi adet farklı sınıflandırma algoritması (Naive Bayesian, lojistik, SMO, IBk, JRip, J48, RF) kullanılarak kapak niteliklerinin (kalın veya ince kenarlı kapak) sınıflandırılması amaçlanmıştır. Bu sınıflandırma çalışmasında, %98.0159 başarı oranıyla en yüksek başarıya sahip algoritma RF algoritması olmuştur. Literatürde farklı nitelik verilerine sahip veri setlerinin farklı yapay zekâ yöntemleri ile incelendiği bilinmektedir. Uygulanabilirliği ispatlanmış olan bu yöntemler bu çalışmanın sonuca ulaşmasında da yardımcı olmuştur.

Mehmet Ünsal, A. Serdar Yılmaz ve Pelin Yücel [1] yaptıkları çalışmada, yapay sinir ağları ile dairesel kesitli yüksek basınçlı kapaklı kondütlerin hava delik çapının havalandırma performansı üzerindeki etkisini modellemişlerdir. Bu modeller ve yapılan deneyler ile ulaşılan

sonuçlar arasında yüksek bir korelasyon gözlenmiş olup R^2 değeri 0.98 olarak bulunmuştur. Bu değerler, yapay sinir ağlarının çalışmanın amacı doğrultusunda etkili bir biçimde kullanılabileceğini göstermektedir.

Ahmet Baylar, Mehmet Ünsal ve Davut Hanbay [2] yaptıkları çalışmada, kanal eğimi, enerji kayıp oranı ve akış rejimi değişkenleri yardımıyla kademeli kaskatlarda havalandırma verimini tahmin etmeye çalışmışlardır. Bu tahminler için ise LS-SVM, ANN ve ANFIS metotları ile çeşitli modellemeler oluşturmuşlardır. Kademeli kaskatlar üzerinde yapılan deneylerin ve kullanılan yapay zekâ metotlarının sonuçları karşılaştırılarak yapılan tahminlerin doğruluğu test edilmiştir. En yüksek doğruluk oranının elde edildiği model ise R^2 değerinin 0.9728 olarak bulunduğu LS-SVM modeli olmuştur.

Emrah Doğan, Bülent Şengörür ve Rabia Köklü [3] yaptıkları çalışmada, biyolojik oksijen ihtiyacının tahmin edilmesi için yapay sinir ağlarını kullanmışlardır. 2001-2002 seneleri arasında, Melen Nehri Havzasındaki 11 örnekleme sahasında, biyolojik oksijen ihtiyacının yoğunluğu üzerinde etkili olan parametrelerin büyük bir kısmı (kimyasal oksijen ihtiyacı, sıcaklık, çözünmüş oksijen, su akışı, klorofil ve besin maddeleri, amonyak, nitrit, nitrat) toplanmıştır. Veriler, yapılacak tahmin için eğitim ve test setleri olarak iki parçaya ayrılmıştır. 2, 3, 5, 10 sayılarında düğümler kullanılarak en iyi tahmin sonucuna ulaşılması amaçlanmıştır. Deneyler sonucunda 8 giriş, 3 düğüm ve 1 gizli katmana sahip olan model en iyi tahmin değerini vermiştir.

Zeynep Banu Özger, Ayşe Ece Yağcı ve Mehmet Ünsal [4] yaptıkları çalışmada, girişim-kanallı kanalların havalandırma performansını modelleyebilecek fonksiyonlara ulaşmak amacıyla yapay arı kolonisi programlamasını (ABCP) kullanmışlardır. Çalışmada, değişik daralma miktarlarına sahip olan 2 adet girişim üzerinde yapılan deneyler ile elde edilen veriler ve eğitilmiş verilerin sonuçları, yapay sinir ağları ve genetik programlama kıyaslanmıştır ve en iyi sonucu 0.99 R^2 değeri ile ABCP vermiştir. Bu değer, ABCP yönteminin çalışmanın amacına uygun bir şekilde kullanılabileceğini göstermektedir.

Ahmet Baylar, Mehmet Ünsal ve Fahri Özkan [5] yaptıkları çalışmada, kademeli kaskadlar üzerinde nap, geçiş ve kayma akış rejimlerinde oksijen transfer verimini tahmin etme amacıyla çeşitli modeller oluşturmuşlardır. Bunun için, genetik ekspresyon programlaması tercih edilmiştir. Bu programlama, genetik programlamayı andırsa da genetik programlama ile tamamen aynı değildir. Çalışmada nap, geçiş ve kayma akış rejimleri parametrelerinin bulunduğu veri seti kullanılarak üç çeşit model meydana getirilmiştir. Deneyler sonucunda ulaşılan değerlerin korelasyonunun çok büyük olduğu görülmüştür. Bununla birlikte minimum kare hata değerlerinin 0,0033 değerinden küçük olduğu görülmüştür. Bu sebeplerle, genetik ekspresyon programlaması, çalışmanın amacına uygun olarak başarılı bir şekilde kullanılabilir.

Bu araştırma, daha sonra yapılacak çalışmalar için zaman tasarrufu sağlamakla birlikte maddi açıdan da büyük faydalar sağlayabilir.

2. SUYUN HAVALANDIRILMASI

Sudaki canlı yaşamının devam edebilmesi için, su içerisindeki çözünmüş oksijen konsantrasyonunun belli bir seviyede olması gerekmektedir. Ancak nüfus artışı, sanayi ve teknolojinin hızla gelişmesi gibi nedenlerden dolayı sudaki çözünmüş oksijen konsantrasyonu istenen seviyenin altına düşmektedir. Bu durumun önüne geçebilmek için, doğal veya yapay sistemler ile atmosferdeki oksijenin suya kazandırılması ve bu sayede sudaki oksijen konsantrasyonunun artırılması işlemine suyun havalandırılması denir.

2.1. Su Kalitesi

Su; canlılığın sürdürülebilmesi için en önemli doğal kaynaklardan biridir. Su; ekosistem dengesini sağlamak, enerji üretmek ve ekonomik kalkınmaya katkıda bulunmak gibi birçok amaç için kullanılabilir. Bu nedenle su kalitesi kavramı oldukça önemli bir parametre haline gelmektedir. Su kalitesinin belirlenmesinde, su içerisindeki çözünmüş oksijen konsantrasyonu büyük rol oynamaktadır. Suda yaşayan canlıların cinsine göre, su içerisindeki çözünmüş oksijen konsantrasyonu değerinin minimum 5 mg/l olması gerekmektedir [6]. Bu konsantrasyon seviyesi arttıkça su kalitesi de artar. Ancak dünya nüfusunun hızlı artışı ve teknolojinin gelişmesi gibi nedenlerle birlikte su ihtiyacı artarken, sudaki çözünmüş oksijen konsantrasyonu azalmıştır ve su kirliliği seviyesi ciddi boyutlara ulaşmıştır. Azalan konsantrasyon değerlerinin kısa sürede artırılması için havalandırma işlemleri yapılmaktadır.

2.2. Havalandırma

Havalandırma, atmosferdeki oksijenin suya transfer edilmesiyle sudaki çözünmüş oksijen konsantrasyonunun artırılması işlemidir. Aşağıda verilen çevresel durumlar için hidrolik yapılar kullanılarak havalandırma işleminden yararlanılabilir:

- Sudaki demir ve manganın oksidasyonunda,
- Suda bulunan çözünmüş haldeki gazların neden olduğu tat ve kokuların azaltılmasında,
- Amonyumun giderilmesinde,
- Sudaki metan ve hidrojen sülfür gibi gazların giderilmesinde,
- Sudaki karbondioksit miktarının azaltılmasında,
- Biyolojik tasfiyede gerekli olan oksijenin sisteme transfer edilmesinde,
- Atık sularda bulunan süspanse maddelerin yüzdürülerek uzaklaştırılmasında,
- İçme sularının arıtılmasında.

Havalandırma işleminin doğal yollarla gerçekleşebilmesi için uzun bir mesafeye ve zamana ihtiyaç vardır. Hidrolik yapılar ile bu sorun aşılmaya çalışılmaktadır. Hidrolik yapılar su ile kısa bir

süre temas halinde bulunmasına karşın sistemlerdeki oksijen seviyesi üzerinde oldukça etkili olan ve klasik havalandırma sistemleriyle kıyaslandığında daha ekonomik olan yapılardır. Bu yapılarla su içerisine oksijen transfer edilerek havalandırma işlemi yapılır. Bu oksijen transferi suyun içerisine hava kabarcıkları sürüklemek suretiyle gerçekleştirilir. Hava ve su arasındaki temas yüzeyi arttıkça havalandırma hızı da artar.

Farklı yöntemlerle yüksek basınçlı kondütlerin içine atmosferden hava alınmasıyla iki fazlı akım sistemleri meydana gelir (Şekil 2.1.). Bu sistemlerde havalandırma işlemi, su içerisine büyük miktarda hava kabarcığı girişi temin edilerek ve dolayısıyla hava ve su arasındaki temas yüzeyi artırılarak hızlandırılabilir. Ayrıca akıma sokulan hava kabarcıklarının boyutu küçüldükçe temas yüzeyi artacağı için yapılan oksijen transferi de artmış olur. Böylece atmosferden su içerisine kısa zamanda çok miktarda oksijen transfer edilmiş olur [7].




Şekil 2.1. Yatay ve dikey borularda iki fazlı akım durumları [7]

Sıvı bir ortam gaz ya da gaz karışımlarıyla temasta ise; gaz ve sıvı arasındaki denge sağlanana kadar gazdan sıvıya ya da sıvıdan gaza transfer olayı gerçekleşir. Oluşan bu denge durumunda sıvıdaki gaz moleküllerinin konsantrasyonu doygun haldedir. İki fazlı akımlarda (gaz ve sıvı) kütle transferi için en çok kullanılan teorilerden biri çift film teorisidir.

2.2.1. Çift Film Teorisi

Gaz ile sıvı kütle transferi için kullanılan bir teori olan çift film teorisi 1925 senesinde Lewis ve Whitman tarafından ortaya atılmıştır. Bu teori gaz ve sıvı ara yüzeyinde çift tabakanın olduğu fiziksel bir modelden oluşmaktadır. Bu iki tabakanın dışında bulunan sıvı ve gaz fazları, gaz moleküllerinin bu fazlar arasındaki geçişine karşı direnç gösterir. Gaz fazından sıvı fazına geçişte; su içindeki çözünürlüğü düşük seviyede olan gazlar asıl direnci sıvı tabakadan, çözünürlüğü yüksek seviyede olan gazlar gaz tabakadan, çözünürlüğü orta seviyede olan gazlar ise

hem sıvı hem gaz tabakadan görür [8]. Şekil 2.2.'de çift film teorisinin mekanizması ve grafiksel gösterimi verilmiştir.



Şekil 2.2. Çift film teorisinin a) mekanizması b) grafiksel gösterimi [9]

Bir ara yüzde gazın kütle transfer hızı, gazın dengedeki ve mevcut durumdaki miktarı arasındaki farkla orantılıdır. Böyle sistemler için gazın transfer hızı aşağıda verilen denklem ile gösterilebilir [10].

$$\frac{dm}{dt} = K_g A (C_s - C) \quad (2.1)$$

Denklemdaki dm/dt kütle transfer hızını (g/s), t kütle transferinin gerçekleşme süresini (s), K_g kütle transfer katsayısını, A kütle transfer alanını (m^2), C_s su içerisindeki çözünmüş oksijenin doymunluk konsantrasyonunu (mg/L), C ise su içerisindeki çözünmüş oksijen seviyesini (mg/L) ifade etmektedir. Eğer yerel atmosfer basıncı standart deniz seviyesindeki değerinden farklı ise su

içerisindeki çözünmüş oksijenin doyma konsantrasyonunun elde edilmesi için aşağıdaki denklem kullanılabilir.

$$C_{s1} = \frac{C_s (P - P_v)}{P_{at} - P_v} \quad (2.2)$$

Bu denklemde C_{s1} çözünmüş oksijenin doyma konsantrasyonunun gerçek atmosfer basıncındaki değerini, C_s çözünmüş oksijenin doyma konsantrasyonunun standart atmosfer basıncındaki değerini, P gerçek atmosfer basıncını, P_v buhar basıncını, P_{at} ise standart atmosfer basıncını ifade eder. Ayrıca gaz moleküllerinin kütle transfer hızı, konsantrasyon değişim hızı türünden aşağıda verilen denklem ile gösterilebilir.

$$\frac{dm}{dt} = V \frac{dC}{dt} \quad (2.3)$$

Bu denklemde V sistemdeki toplam hacmi (m^3) ifade eder. Bu ifade 2.1 numaralı denklemde yerine yazılırsa aşağıdaki denklem elde edilir.

$$\frac{dC}{dt} = \frac{K_g A}{V (C_s - C)} \quad (2.4)$$

Gaz fazından sıvı fazına geçişte; asıl direnç sıvı tabaka olduğu için, birim su hacminin başına denk gelen hava ile su arasındaki yüzey alanını ifade eden “ a ” ve “ K_L ” birleştirilirse, kütle transfer katsayısını belirten “ $K_L a$ ” ifadesi kullanılabilir. Bu ifade yerine yazıldığında 2.4 numaralı denklem aşağıdaki gibi yazılabilir.

$$\frac{dC}{dt} = K_L a (C_s - C) \quad (2.5)$$

Bu denklemdeki dC/dt konsantrasyon değişim hızını ($mg/L.s$), $K_L a$ kütle transfer katsayısını (l/s), C_s su içerisindeki çözünmüş oksijenin doyma konsantrasyonunu (mg/L), C ise su içerisindeki çözünmüş oksijen seviyesini (mg/L) ifade etmektedir. C_s değerinin sabit olduğu düşünülürse, 2.5 numaralı denklemin bir hidrolik yapının membandan mansabına doğru integre edilmesi sonucunda aşağıda verilen denklem ortaya çıkar.

$$r = \frac{C_s - C_u}{C_s - C_d} = \exp [K_L a] \quad (2.6)$$

Bu denklemde r oksijenin eksiklik oranını, C_u mambadaki çözünmüş oksijen konsantrasyonunu (mg/L), C_d ise mansaptaki çözünmüş oksijen konsantrasyonunu ifade etmektedir.

2.2.2. Havalandırma Verimi

Havalandırma verimi suyun doymuş bir seviyeye gelebilmesi için yapının oksijen kazandırma kabiliyeti olarak tanımlanabilir[9]. C_s değerini su ile atmosfer bölümlerinin belirlediği varsayılırsa, C_s değeri zamana göre sabit olur. Havalandırma verimi ise aşağıdaki denklemle gösterilebilir [11].

$$E = \frac{C_d - C_u}{C_s - C_u} \quad (2.7)$$

Bu denklemde E; havalandırma verimini ifade etmektedir. $E = 0$ değeri yapıda havalandırma işleminin gerçekleşmediğini, $E = 1$ değeri mansaptaki suyun doymuş seviyeye geldiğini, $E > 1$ değeri ise mansaptaki suyun aşırı doymuş seviyeye ulaştığını belirtir.

Havalandırma verimi su sıcaklığına karşı hassastır. Bu nedenle araştırmacılar tek türde temel oluşturmak için E değerini genellikle 20 °C standardına normalleştirmişlerdir. Bu işlem için Gulliver ve arkadaşlarının aşağıda gösterilen denklemi tercih edilebilir [12].

$$1 - E_{20} = (1 - E)^{1/f} \quad (2.8)$$

Bu denklemde E_{20} değeri 20 °C’ deki oksijen transfer verimi, f ise aşağıdaki gibi tanımlanan üstür.

$$f = 1.0 + 0.02103 (T - 20) + 8.261 \times 105 (T - 20) \quad (2.9)$$

Burada T su sıcaklığını ifade etmektedir.

2.2.3. Havalandırmayı Etkileyen Faktörler

Su sıcaklığı oksijen transferini etkileyen faktörlerden biridir. Suyun sıcaklığının değişmesiyle birlikte akışkanın özgül kütlesi, viskozitesi, yüzey gerilmesi ve kütle transfer katsayısı değişirken gazın sudaki doymuşluk miktarı değişir [13].

Oksijen transferini etkileyen bir diğer faktör su kalitesidir. Su ne kadar temizse oksijenin sudaki çözünürlük miktarı da o kadar fazladır. Farklı su kalitelerinin kullanıldığı araştırmaların aynı şartlar altında incelenebilmesi için Gameson [14] aşağıdaki denklemi önermiştir.

$$(r - 1)_{wq.b} = (r - 1)_{wq} / f_{wq} \quad (2.10)$$

Bu denklemde; $(r - 1)_{wq.b}$ değeri su kalitesinde ölçülen oksijen eksiklik katsayısını, $(r - 1)_{wq}$ değeri yapılan araştırmada ölçülen oksijen eksiklik katsayısını, f_{wq} ise su kalitesini gösteren boyutsuz bir katsayıyı ifade etmektedir. Laboratuvar araştırmalarında f_{wq} değeri temiz su için 1; az kirli su için 0.89; orta seviyede kirli su için 0.56; çok kirlenmiş su için ise 0.36 olarak alınmaktadır [13].

Hava kabarcıklarının hidrolik bir yapının mansap bölgesindeki suyun içinde kaldığı süre de oksijen transferini doğrudan etkileyen bir faktördür. Bu süre hava kabarcıklarının ulaştığı

uzaklıkla orantılıdır. Çıkış suyunun derinliği ise verimlilikle orantılıdır. Dolayısıyla hava kabarcıklarının su içinde kalma süresi, oksijen transfer verimi için oldukça önemli bir konuma gelmektedir [8].

Düşü yüksekliği oksijen transferini etkileyen bir diğer faktördür. Basamaklı hidrolik yapılardaki düşü yüksekliği, nap akımı rejimi için basamak yüksekliğine göre değişmektedir. Bu akım rejiminde bir basamaktan diğer basamağa çarparak yükselen suya transfer olan oksijen miktarı, basamağın yüksekliği ile orantılıdır. Sıçramalı akım rejiminde ise savağın yüksekliği ile yapılan oksijen transferi orantılıdır. Ayrıca bu akımda serbest yüzey arttıkça oksijen transferi de artar [15].

2.2.4. Havalandırma Teknikleri ve Ölçüm Metotları

Havalandırma işleminin gerçekleştirilmesi için birçok doğal ve yapay teknik bulunmaktadır. Bu teknikler aşağıda kısaca açıklanmıştır.


Doğal Havalandırma: Atmosferdeki oksijenin bir alet kullanılmadan su içerisine transfer olmasına doğal havalandırma denir. Akarsu akışı, şelaleler, su yüzeyindeki çalkantılar ve serbest yüzeyli akımda oluşan hidrolik sıçrama gibi hadiseler doğal havalandırmanın gerçekleştirmesine yardımcı olan mekanizmalardan bazılarıdır. Hareket halindeki suyun havalandırılmasında verimliliği ölçmek için çeşitli metotlar bulunmaktadır. Bu metotlar sudaki hava miktarının ölçülmesi, sudaki çözünmüş oksijen konsantrasyonunun ölçülmesi ve iz tekniği olarak üç grupta incelenebilir.

Sudaki Hava Miktarının Ölçülmesi: Su içerisine oksijen transferi yapıldığında sıvı ve gazdan oluşan çift fazlı akım meydana gelmektedir. Bu olay sonucunda, akıma ait elektrik iletkenliği ve ses yansıtma gibi fiziksel özelliklerde bir değişim söz konusu olmaktadır. Örneğin suyun elektrik akımına karşı oluşturduğu direnç havanın oluşturduğu dirençten 1000 kat daha azdır [16]. Değişen fiziksel özellikler sonunda elektrik iletkenliği ve ses yansıtma miktarları fiber- optik ve elektriği ileten probalar ile ölçülüp sudaki hava miktarı belirlenebilir. Bu probalar ile hava miktarının belirlenebilmesinin yanı sıra su içerisindeki hava kabarcıklarının sayısı ve boyutları da belirlenebilmektedir [13].

Sudaki Çözünmüş Oksijen Konsantrasyonunun Ölçülmesi: Oksijen probaları, su içerisindeki çözünmüş oksijen konsantrasyonunun belirlenmesi için sıkça kullanılmaktadır. Bu probalar ile oksijen sensörünün zarından geçen oksijenin kısmi basıncına göre sudaki çözünmüş oksijen konsantrasyonu belirlenebilmektedir. Çünkü oksijenin kısmi basıncı ve çözünmüş oksijen miktarı orantılıdır. Suyun oksijene doymuş olduğu durumlarda oksijen transferi yapıldığında çözünmüş oksijen miktarı değişmemektedir. Böyle zamanlarda oksijen transferinin gerçekleştirilebilmesi için sudaki çözünmüş oksijen miktarının azaltılması gerekmektedir [13].


İz Tekniği: Havalandırma süresince atmosferde yer almayan ya da çok az yer alan SF_6 gibi uçucu gazların akıma verilmesiyle birlikte bu gazlar havaya geçiş yaparlar. Dolayısıyla bu gazların yoğunluğu akım içerisinde azalmış olur. Bu azalış miktarı belirlenerek oksijen transfer verimi de belirlenebilmektedir. Cırpka ve diğ. iz tekniğini kullanarak oksijen transfer verimini ölçmüşlerdir. Bunun için aynı akım koşulları altında SF_6 için ($H=82.4$) $E= 0.33$, CHBr_3 için ($H = 0.007$) ise $E= 0.03$ değerlerini elde etmişlerdir. Bu araştırmanın sonunda, kimyasal ve oksijene ait Henry katsayı değerlerinin birbirine yaklaşması ile havalandırma veriminin arttığı görülmüştür [13].

Hidrolik Sıçrama: Mansap bölgesindeki su seviyesinin yükselmesiyle birlikte, akımın kritik üstü rejimden (sel rejimi) kritik altı rejime (nehir rejimi) geçmesine hidrolik sıçrama denir [17]. Hidrolik sıçrama esnasında yüksek miktardaki hava kabarcıkları ve türbülans karışımıyla oksijen transferi gerçekleşmiş olur. Hidrolik sıçrama olayında, topuktaki su içerisine yüksek oranda oksijen transfer edilir. Bu oksijen transferi sonucunda hava kabarcıkların mansap bölgesine dağılmasıyla birlikte su önemli bir ölçüde havalandırılmış olur. Şekil 2.3.'te hidrolik sıçrama olayı gösterilmiştir.



Şekil 2.3. Hidrolik sıçrama

Hidrolik sıçramanın öncesine ve sonrasına ait suyun derinliklerine sırasıyla h_1 ve h_2 derinlikleri, yani eşlenik derinlikler denir. Su derinliğinin bu hızlı değişimi neticesinde büyük miktarda enerji kaybı meydana gelir. Hidrolik sıçrama, akım koşullarına göre farklı şekillerde gerçekleşebilir. Memba şartlarını gösteren Fr_1 değerine göre hidrolik sıçrama çeşitleri şekil 2.4'te gösterilmiştir. Şekle bakıldığında Fr_1 değerinin artmasıyla enerji kaybında büyük miktarda artışın ortaya çıktığı görülmektedir [17]. Tablo 2.1'de ise hidrolik sıçramanın Fr_1 değerine göre sınıflandırılması verilmiştir.



Şekil 2.4. Hidrolik sıçrama çeşitleri; a) Ondüler sıçrama; b) Zayıf sıçrama; c) Dalgalı sıçrama; d) Düzenli sıçrama; e) Kuvvetli sıçrama [17]


Tablo 2.1. Hidrolik sıçramanın Fr_1 sayısına göre sınıflandırılması [18]

Fr_1 Sayısı Değer Aralığı	Hidrolik Sıçrama	Özellikleri
1 – 1.7	Dalgalı sıçrama	Mansap tarafında uzun mesafeler boyunca dalgalanmalar oluşur. Enerji kaybı ihmal edilebilecek kadar azdır.
1.7 – 2.5	Zayıf sıçrama	Az miktarda enerji kaybı olur.
2.5 – 4.5	Titreşimli sıçrama	Düzensiz ve büyük dalgalar oluşur. Zamanla değişen titreşimli sıçrama oluşur. Mümkünse kaçınılmalıdır.
4.5 - 9	Stabil sıçrama	%45 – 70 oranında enerji kaybı olur. Mansap düzenlemelerinden bağımsızdır. En ekonomik tasarımıdır.
> 9	Etkin ve sert sıçrama	%85 oranında enerji kaybı vardır. Kanal yatağında oyulma riski vardır.

Basıncılı Akım Sistemleri ile Suyun Havalandırılması: Basıncılı akım, su yüklenen hidrolik bir yapının içerisindeki akımın atmosfer ile temas etmediği akımdır. Basıncılı akımlar; tünel, galeri kuyu gibi yapılarda ortaya çıkabilir. Bu akımların ortaya çıktığı yapılar rastgele bir kısımdan delinirse, yapıların içindeki su basıncılı bir şekilde dışarıya çıkar. Suyun havalandırılması için su jetleri, ventüriler ve kondüitler gibi basıncılı akım sistemleri kullanılabilir [19].

Su Jetleri: Su jetleri, inşaat ve çevre mühendisliğinin yanı sıra farklı mühendislik kollarında da kullanılan hidrolik yapılardır. Su jetleri, bir ağızlıktan atmosfere açılan yapılar olup içerisinde yüksek bir akış hızı barındırırlar. Su jetinin etrafında farklı bir sıvı varsa su jeti, batık su jeti; yoksa batmamış su jeti adını alır [20].

Su jetleri havadan su havuzuna hızla değerek su içerisine büyük miktarda hava kabarcığı transfer eder; böylece gaz ve sıvıdan oluşan çift fazlı bir alan meydana getirir. Oluşan bu fazlar arasında oksijen transferi gerçekleşir. Dolayısıyla havuzdaki su havalandırılmış olur. Su jetleri ile havalandırılma yapılmasıyla ilgili yapılan çalışmalara bakıldığında, çalışmaların büyük bir kısmında dairesel ağızlığa sahip su jetlerinin tercih edildiği görülmektedir[19]. Ervin et al [21] su jeti ile oksijen transferi için dört farklı sistem tavsiye etmiştir. Tsang [22] ise bu sistemleri normal ve paralel savaklardan serbest düşen su jetlerine uyarlayarak su jeti ile yapılan oksijen transfer sistemlerini şekil 2.4. te görüldüğü gibi düzgün, dalgalı, pürüzlü ve parçalanmış jet olmak üzere dörde ayırmıştır.



Şekil 2.5. Oksijen transfer sistemleri; a) Düzgün jet; b) Dalgalı jet; c) Pürüzlü jet; d) Parçalanmış jet [23]


Düzgün jetlerde havalandırmanın temel kaynağı, su jetinin etrafını saran ve çarpmayla birlikte suya taşınan ince bir tabakadır. Bu yüzden yapılan havalandırma kısıtlıdır. Şekil 2.5.-a'da görüldüğü üzere su havuzundaki su yüzeyinde az miktarda bozulma meydana gelmiştir [23].

Dalgalı jetlerde havalandırmanın temel kaynağı, jet ile su havuzunun yüzeyi arasındaki sıkışık halde olan büyük hava boşluklarıdır. Burada su havuzunun yüzeyi oldukça hareketlidir (Şekil 2.5.-b) [23].

Pürüzlü jetlerde havalandırmanın temel kaynağı, jet yüzeyinin pürüzlülüğü ile su havuzu arasındaki sıkışık durumda olan ufak hava boşluklarıdır. Çarpma ile birlikte su jeti, suyun yüzeyinde dalgalar meydana getirir. Bu jet tipi, benzer şartlar altında pürüzsüz jetlerle kıyaslandığında, hava kabarcıkları çift fazlı bölgede daha büyük miktarda biriktiği için penetrasyon derinliğinin daha az, havalandırma miktarının ise daha çok olduğu görülür (Şekil 2.5.-c) [23].


Parçalanmış jetlerde su havuzunun yüzeyi şiddetli bir biçimde hareketlidir. Jet parçalarının su havuzunun yüzeyine çarpmasıyla, yüzey silindirlerinin hareketleri ve hava kabarcıklarının su içerisine alınması havalandırmaya yardımcı olur. Şekil 2.5.-d’de görüldüğü üzere hava kabarcıkları genelde sadece sığ derinliklere taşınır. Bu tür jetler daha büyük yüzey alanına sahip olan katı jetlerde oranla daha avantajlıdır [23].

Ventüriler: Ventüriler, uzun zamandan beri bir borudaki deşarj edilen akışkan akımının debisinin ölçülmesi amacıyla kullanılan cihazlardır. Şekil 2.6.’da görüldüğü gibi ventürilerin boğaz bölgeleri, borudaki akışkan akımının hızını artırmak amacıyla ağız bölgelerine göre daha dar yapılmaktadır. Böylece, ventürilerin boğaz kısmında atmosfer basıncından daha düşük olan bir basınç oluşmaktadır. Bu nedenle, boğaz kısmındaki hava deliğinden içeriye hava girişi meydana gelmektedir. Ayrıca bu basınç farkı ile akımın debisi hidrolik olarak ölçülmektedir [24].



Şekil 2.6. Bir ventüri aygıtının görünümü [25]

Bir ventürinin teorik değişkenleri ve matematiksel değerleri şekil 2.7’de gösterilmiştir.



Şekil 2.7. Bir ventüri aygıtının teorik değişkenleri [24]

a-a nivo seviyesine göre; 1 ve 2 numaralı bölgelerdeki basınçlar için aşağıdaki denklemler yazılabilir.

$$P_1 + \gamma \cdot z_1 = P_2 + \gamma \cdot z_2 \quad (2.11)$$


$$P_1 - P_2 = \gamma (z_2 - z_1) \quad (2.12)$$

Piyezometrelerde $z_1 > z_2$ olduğu için $(z_2 - z_1)$ yerine $-z$ yazılacak olunursa;


$$\frac{P_1 - P_2}{\gamma} = -z \quad (2.13)$$

denklemini bulunur. Bu denkleme göre 2 numaralı bölgede negatif basınç meydana gelmektedir. Burada, $P_1 = 1$ numaralı kesitteki basınç (kg/m^2), $P_2 = 2$ numaralı kesitteki basınç (kg/m^2), $h_1 = 1$ numaralı kesitin basınç yüksekliği (m), $h_2 = 2$ numaralı kesitin basınç yüksekliği (m) ve $\gamma =$ suyun birim hacim ağırlığıdır (kg/m^3) [25].

Şekil 2.8.'de klasik ventürilerdeki boyutlandırma değerleri, Şekil 2.9'da ise ventürilerin oksijen transfer maksatlı kullanımı gösterilmiştir.




Şekil 2.8. Klasik ventürilerdeki boyutsal değerler [25]




Şekil 2.9. Venturilerin oksijen transfer maksatlı kullanımı [25]

Basıncılı Kondüitler: Kapaklı kondüitlerde, suyun kapak altından hızla geçmesiyle birlikte kapak mansabında atmosfer basıncından daha düşük olan bir basınç meydana gelir. Bu düşük basınç, bir vakumlama etkisi oluşturarak hava borusundan içeriye kabarcıklar şeklinde hava taşınmasına sebep olur (Şekil 2.10.). Akımın içine hava taşınması, oksijen transfer hızının artırılmasının yanı sıra kavitasyon hasarlarının azaltılması ve vibrasyon etkisi ile kararlı akım şatlarının sınır değerlerine çekilmesi amacıyla da kullanılmaktadır [26].



Şekil 2.10. Kapaklı kondüit mansabında iki fazlı akım [26]

Kapaklı kondüitlerde kapak mansabında meydana gelebilecek çift fazlı akım rejimleri şekil 2.11.'de görülmektedir [27].




Şekil 2.11. Kapaklı konduit içerisindeki iki fazlı akım rejimleri; a) Sadece hava akışı; b) Sprey (püskürme şeklinde) akım; c) Serbest yüzeyli akım; d) Köpüklü akım; e) Hidrolik sıçrama-1; f) Hidrolik sıçrama-2; g) Sadece su akışı [27]

3. ÇALIŞMADA KULLANILAN VERİ SETİNİN ELDE EDİLDİĞİ PROJE


Bu tez çalışmasında, farklı kapak geometrisine ait kondüitlerde havalandırma performansını araştıran TUBİTAK 215M046 projesinde yapılan deneyler sonucunda elde edilen veriler kullanılmıştır. Bu veriler kullanılarak 7 çeşit regresyon analizi ve sinir ağı yöntemi ile hava debisi değerleri tahmin edilmeye çalışılmıştır. Ayrıca kapak çeşitleri, kenar tiplerine göre (ince ve kalın kenarlı) 7 çeşit sınıflandırma algoritması kullanılarak sınıflandırılmıştır. Bu bölümde TUBİTAK 215M046 projesinde yapılan deneyler ve bu deneyle sonucunda elde edilen veri seti kısaca açıklanacaktır.

3.1. Yapılan Deneyler

Bu projede bütün deneyler, Fırat Üniversitesi İnşaat Mühendisliği Hidrolik Laboratuvarında hazırlanan deney mekanizması ile yapılmıştır. Deneylerde şebeke suyu kullanılmış olup havalandırma verimine etki edebilecek olan yüzen ve organik maddeler ile tuzun tesiri görülmemiştir. Şekil 3.1.'de ince kenarlı kapak için, şekil 3.2.'de ise kalın kenarlı (radyal) kapak için kullanılan deney mekanizması verilmiştir. Burada sistem devirli bir şekilde işletilmiştir. 1.5x1.5x2.0 m boyutlarına sahip olan bir tank kullanılmış olup bu tankın içerisindeki su, emiş hortumu ile pompaya aktarılmıştır. Su, pompa sayesinde sisteme basınçlı bir şekilde iletilmiştir.




Şekil 3.1. Hava giriş deneyleri için yüksek basınçlı kapaklı konduit düzeneği-ince kenarlı kapak




Şekil 3.2. Hava giriş deneyleri için yüksek basınçlı kapaklı konduit düzeneği-kalın kenarlı kapak


Düzeneğe iletilen suyun debisi, akım kontrol vanası ve Kohne marka elektromanyetik debimetre ile ayarlanmıştır. Suyun konduitlere aktarılmasını sağlayan boru hattının çapı, yersel yük kayıplarını yok etmek için pompanın çıkış çapı ile eşit boyutta olup 3 inçtir. Konduit kapak enkesitlerinin hava giriş verimindeki etkisini belirlemek için şekil 3.3.'te görüldüğü gibi üç çeşit enkesit kullanılmıştır. Yersel yük kayıplarının yok edilmesi için, dairesel konduitin çapı ile boru hattının çapının eşit boyutlarda (3 inç) olması tercih edilmiştir. Dairesel ile dikdörtgen konduitlerin karşılaştırılabilmesi için ise dikdörtgen konduitlerin boyutları 100x60x3 mm olarak seçilmiştir. Tüm enkesitlerde ince ve kalın kenarlı kapak uygulaması gerçekleştirilmiştir. Ayrıca bütün enkesitler için kapak açıklık oranları %10, 15, 20, 30, 40 ve 60 olarak seçilmiştir (Şekil 3.4., Şekil 3.5., Şekil 3.6.). Yapılan deneylerin ana hatları tablo 3.1.'de verilmiştir.




Şekil 3.3. Dairesel ve dikdörtgen konduit enkesitleri



Şekil 3.4. 60/100 dikdörtgen enkesitli konduit kapak açıklık oranları



Şekil 3.5. 100/60 dikdörtgen enkesitli kondüit kapak açıklık oranları



Şekil 3.6. Dairesel enkesitli kondüit kapak açıklık oranları

Tablo 3.1. Deney serilerinin ana hatları

Kondüit Enkesit Şekli	Kapak Açıklık Oranı	Kapak Tipi	Kondüit Uzunluğu
60x100 Dikdörtgen	%10	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%15	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%20	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%30	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%40	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
100x60 Dikdörtgen	%10	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%15	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%20	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%30	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m

Tablo 3.1. (Devamı)

	%40	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%60	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
Dairesel	%10	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%15	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%20	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%30	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%40	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m
	%60	Radyal	L=1 m, 2 m, 4 m, 6 m
		İnce Kenarlı	L=1 m, 2 m, 4 m, 6 m

Atmosferdeki havayı su içerisine aktarmak için kapakların mansabına hava giriş borusu eklenmiştir. Deneylerde 15, 30 ve 45 mm çaplarında ve 200 mm yüksekliğinde olan üç çeşit hava giriş borusu tercih edilmiştir. Ayrıca kondüit uzunluğunun havalandırma verimi üzerindeki etkisinin belirlenmesi için 1, 2, 4 ve 6 m uzunluklarında dört çeşit kondüit kullanılmıştır.

3.2. Veri Setinin Elde Edilmesi

Projede oluşturulan veri seti; kapak açıklığı, kondüit uzunluğu, su debisi, Froude sayısı, su hızı, hava debisi ve hava giriş verimi olmak üzere yedi nitelikten meydana gelmektedir. Sistem içerisine giren havanın hızı, Testo 435 model anemometre ile ölçülmüştür. Bu ölçümde 45 mm çapa sahip olan hava giriş borusu kullanılmıştır. Küçük Froude sayılarında ise 30 ve 15 mm çapa sahip olan hava giriş boruları tercih edilmiştir. Deneylerde farklı debi değerleri kullanılmış ve bu değerler Froude sayısının hesaplanması için kullanılmıştır. Froude sayısının hesaplanması, denklem 3.1’de verilmiştir. Tüm hava hızı ölçümleri 60 saniye süresince yapılarak ortalama hava hızları bulunmuştur. Bu ortalama hava hızları, hava giriş borusunun alanıyla çarpılıp hava debisi değerleri elde edilmiştir. Hava giriş verimleri ise hava debisinin su debisine bölümü ile elde edilmiştir.

$$Fr = \frac{V_s}{\sqrt{g h}} \quad (3.1)$$


V_s =Kapak altındaki su hızı, h =Kapak yüksekliği, g =Yerçekimi ivmesidir.

4. TEZ ÇALIŞMASININ HEDEFLERİ

Tez çalışmasında, hava debisi değerlerinin tahmin edilmesi ve kondüit kapaklarının tipine göre (kalın ve ince kenarlı) sınıflandırılması amaçlanmıştır. Hava debisi değerlerini tahmin etmek için multi, polinomal, SVR, DT, RF, GP ve KNN olmak üzere 7 çeşit regresyon analizi ile bir sinir ağı modeli kullanılmıştır. Hava debisine ait tahmin değerlerinin gerçek değerlere yakın olması durumunda zor ve zaman alıcı klasik deneyler yapılmadan hava giriş veriminin hesaplanabileceği varsayılmıştır. Bu bölümde yapay sinir ağları, kullanılan regresyon analizleri ve sınıflandırma algoritmaları hakkında bilgi verilecektir.

4.1. Yapay Sinir Ağları

Araştırmacılar, insan beyninin kusursuz niteliklerinden ilham alarak beynin nörofiziksel yapısını matematiksel olarak ifade etmek için birçok çalışma yapmışlardır. Beyin yapısını tümüyle taklit edilebilme düşüncesi ile türlü yapay sinir ağı şekilleri oluşturulmuştur. Böylelikle bilimde “yapay sinir ağları” olarak adlandırılan yeni bir branş ortaya çıkmıştır [28]. Yapay sinir ağları, insan beynine ait en ana özellik olan öğrenmeyi hedef alan, bilgiyi öğrendikten sonra elinde tutmaya devam eden ve bunları sunulan örnekler sayesinde başaran bilgisayar sistemleridir. Yapay sinir ağları, birbirine bağlı olan yapay sinir hücrelerinden meydana gelir. Yapılan her bağlantıya ait bir ağırlık değeri bulunmaktadır. YSA'nın edindiği bilgiler bu ağırlık değerlerinde mevcut olmakla birlikte ağı yayılmış şekilde bulunmaktadır. Şekil 4.1.'de biyolojik nöron ve yapay sinir ağı modellenmiş olup tablo 4.1.'de biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları gösterilmiştir.




Şekil 4.1. Biyolojik sinir hücresi ve yapay sinir ağı [29]

Tablo 4.1. Biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları [29]

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar


Biyolojik sinir hücresi Şekil 4.1.'de görüldüğü gibi çekirdek, gövde, dentrit ve aksondan meydana gelmektedir. Dentritin görevi giriş bilgilerini almak iken, aksonun görevi çıkış bilgilerini diğer sinir hücrelerine aktarmaktır. Dentrit ve aksonun birleştiği yer olan sinapslar, sinir hücrelerinden aldığı sinyalleri değerlendirerek eşik değerinin üstünde bir giriş söz konusu ise bunu devamındaki nörona taşır. Yapay bir sinir ağı hücresi, biyolojik sinir hücresine benzemekle birlikte bundan daha basit bir yapıya sahiptir. Biyolojik sinir hücresinde olduğu gibi yapay sinir hücresi de diğer bir sinir hücresinden aldığı sinyalleri toplar ve toplanan sinyal miktarı belli bir eşik değerini geçtiğinde sahip olduğu sinyali bir diğer yapay sinir hücresine aktarır. Yapay sinir hücresinde girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkılar olmak üzere beş adet temel öge bulunmaktadır. Şekil 4.2. ye bakıldığında, yapay sinir hücresine n adet girdi verildiği görülmektedir. Ağırlıklar yardımıyla dış ortamdan içeriye alınan verilerin yapay sinir hücresine bağlanmasıyla girdi etkisi belirlenir. Girdiler ve bu girdiler ile ilgili ağırlıkların çarpılması sonucunda net girdi bulunmuş olur. Aktivasyon fonksiyonu ise bu süreçte net çıktıyı hesaplayarak çıktının bulunmasını sağlar [29].




Şekil 4.2. Yapay sinir hücresi [29]

4.1.2. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları; tek ve çok katmanlı algılayıcılar ile ileri ve geri beslemeli yapay sinir ağları olarak dört başlık altında toplanabilir. Tek katmana sahip olan yapay sinir ağları, yalnızca girdi ile çıktıdan meydana gelmektedir ve doğrusal problemleri çözmek için kullanılmaktadır. Yani elde edilen çıktı değeri doğrusal olup 1 veya -1 değerine sahip olmaktadır. Çıktının 1'e eşit olması durumunda ilk gruba, -1'e eşit olması durumunda ise ikinci gruba dâhil edilmesi söz konusudur [29]. Şekil 4.3.'te tek katmanlı bir algılayıcının modellenmesi gösterilmiştir. Burada X_1 ve X_2 , girdi değerlerini; W_1 ve W_2 , girdilere karşılık gelen ağırlıkları; ϕ , eşik girdisini; ζ ise çıktı değerini ifade etmektedir. Eşik girdisi, tek katmanlı ağlarda sinir hücresine ait elemanlar ile çıktı değerinin sıfır olmasının önüne geçmektedir. Eşik girdisinin değeri her zaman 1'e eşit olmaktadır [30]. Tek katmanlı algılayıcılar sadece doğrusal problemleri çözmede başarılı olduğu için doğrusal olmayan problemleri çözmek amacıyla çok katmanlı algılayıcılar üzerinde çalışılmaya başlanmıştır. Çok katmanlı algılayıcılar içerisinde girdi ile ara katman ve çıktı katmanı olmak üzere üç çeşit katman bulundurmaktadır. Ara (gizli) katman sayısı birden fazla olabilmektedir. Şekil 4.4.'te çok katmanlı algılayıcıların yapısı verilmiştir.




Şekil 4.3. Tek katmanlı bir algılayıcının modellenmesi [29]




Şekil 4.4. Çok katmanlı bir algılayıcının modellenmesi [30]

Çok katmanlı bir algılayıcının sahip olduğu her katmana ait bir ya da birden çok işlem elemanı vardır. Bir katmanda bulunan tüm bu elemanlar üst katmanındaki tüm işlem elemanları ile bağlantılı durumdadır. Yapay bir sinir ağında, bilgilerin girdiden çıktıya doğru tek yönlü bir şekilde alındığı ağlar “ileri beslemeli yapay sinir ağları” olarak adlandırılmaktadır [28]. İleri beslemeli yapay sinir ağlarında, giriş bölgesine ulaşan bilgiler herhangi bir değişiklik geçirmeden ara katmanda bulunan sinir hücrelerine aktarılır. Sonrasında ara katmandan çıkış katmanına ulaşan bilgiler burada işlenir ve dış ortama verilir [29]. Şekil 4.5.’te ileri beslemeli yapay bir sinir ağı gösterilmiştir. Geri beslemeli yapay sinir ağlarında, ileri beslemeli yapay sinir ağlarının aksine bir sinir hücresinden elde edilen çıktı yalnızca sonraki sinir hücresinin bulunduğu katmana iletilmez. Elde edilen çıktı değeri, bir katmanda bulunan yapay sinir hücreleri arasında da katmanlar arasında olan yapay sinir hücreleri arasında da girdi şeklinde yer alabilmektedir. Bu özelliği ile bu ağlar, doğrusal olmayan dinamik bir tutum ortaya koymaktadır [28]. Hopfield, Elman ile Jordan yapay sinir ağları bu tür yapay sinir ağları için birer örnektir. Şekil 4.6.’da geri beslemeli bir yapay sinir ağının modeli gösterilmiştir.



Şekil 4.5. İleri beslemeli yapay sinir ağı



Şekil 4.6. Geri beslemeli yapay sinir ağı [29]

4.1.3. Yapay Sinir Ağlarının Ana Unsurları

Yapay sinir ağları; öğrenme algoritması ile aktivasyon fonksiyonu olmak üzere genel olarak iki ana unsurdan meydana gelmektedir.

Öğrenme Algoritması: Yapay sinir ağlarına ait başlıca özelliklerden biri öğrenme kabiliyetidir [29]. Bu kabiliyet, sistemin mevcut örnekleri kullanarak iyi sonuçlara ulaşmasını sağlamaktadır. Biyolojik sinir hücrelerinde öğrenme işlemi, yapay sinir ağlarında sinapsa denk gelen ağırlıkların alabileceği en uygun değerler bulunarak gerçekleştirilmektedir. YSA'lar öğrenme işlemi sırasında sahip olduğu verileri ağırlık şeklinde tutar. Dolayısıyla bu ağırlıklar YSA'ların verileri iyi bir biçimde kullanabilmesi için gereken bilgilere sahiptir. YSA'larda öğrenme işlemi örnekler yardımıyla gerçekleştirilmektedir. Bu yöntem ile yapay sinir ağları, oluşan bir durum ile ilgili daha önce meydana gelen örneklerden faydalanarak bu durumun girdi ile çıktıları arasındaki bağlantılarını öğrenir ve bu bağlantılara dayanarak sonradan ortaya çıkabilecek yeni örneklerin çıktılarını bulur. Öğrenilen girdi ile çıktı arasındaki bağlantının, oluşan durumun neredeyse tümünü yansıtan bilgileri kapsadığı düşünülmektedir. Çeşitli örneklerin kullanılması ile oluşan durumlar farklı yönlerden öğrenilebilmektedir. Öğrenme işlemi için sisteme yalnızca örnekler gösterilip bunlardan başka bir bilgi işlenmemektedir. Öğrenme işlemini yapacak sistem, sahip olduğu algorithmadan yararlanarak aradaki bağlantıları bulmaktadır [28].

Aktivasyon Fonksiyonu: Yapay bir sinir hücresi, aktivasyon fonksiyonunda girdi değerlerini işleyerek net çıktı değerlerine ulaşır. Bir yapay sinir ağının başarılı olması için uygun bir aktivasyon fonksiyonun tercih edilmesi oldukça önemlidir. Seçilen aktivasyon fonksiyonuna bağlı olarak çıktı çoğunlukla $[-1,1]$ ya da $[0,1]$ kapalı aralıklarında olmaktadır. Aktivasyon fonksiyonu, çoğunlukla doğrusallık göstermemektedir. Bu özelliği ile YSA'ların kompleks problemler karşısında başarı elde etmesine neden olmuştur. En fazla tercih edilen aktivasyon fonksiyon çeşitleri sigmoid ve hiperbolik tanjanttır.

4.2. Kullanılan Regresyon Analizleri

Regresyon analizi fizik, kimya, tıp gibi birçok dalda iki ya da daha çok sayıda olan değişkenler arasındaki ilişkiyi belirlemek amacıyla oldukça sık bir şekilde kullanılan yöntemlerden biridir [31]. Doğrusal regresyon, polinomal regresyon, destek vektör makineleri, karar ağaçları regresyonu, rastgele orman regresyonu, gauss süreç regresyonu ve en yakın komşu regresyonu gibi çok sayıda regresyon analizi çeşidi bulunmaktadır.

4.2.2. Doğrusal Regresyon Analizi

Doğrusal regresyon analizi; basit ve çoklu doğrusal regresyon analizi olmak üzere ikiye ayrılmaktadır. Eğer yanıt değişkeni ve tek açıklayıcı değişken arasındaki doğrusal ilişki belirlenmek isteniyorsa basit regresyon; tek yanıt değişkeni ile birden çok açıklayıcı değişken arasındaki doğrusal ya da eğrisel ilişki belirlenmek isteniyorsa çoklu doğrusal regresyon analizi kullanılmalıdır [32]. Basit doğrusal regresyon aşağıdaki denklem ile ifade edilebilir.

$$Y = \beta_0 + \beta_1 X_{1i} + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (4.1)$$

Çoklu doğrusal regresyon ise p tane açıklayıcı değişken ile n tane gözlem olmak üzere aşağıdaki denklem ile ifade edilebilir.

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (4.2)$$

Bu denklemlerde Y yanıt değişkenini, X_1 açıklayıcı değişkeni, β_0 ile β_1 bu değişkenin bilinmeyen parametrelerini, ε_i ise şansa göre değişen hata terimlerini göstermektedir [33].

Doğrusal regresyon analizi çeşitli varsayımlara dayanmaktadır. Regresyon analizi neticesinde güvenilir parametre kestirimlerinin elde edilebilmesi için bu varsayımlar şarttır. Basit doğrusal regresyon için bu varsayımlar şöyle açıklanabilir:

- Hata payları rastlantısal bir değişkendir.
- Beklenen hata değerlerinin 0 ortalamaya sahip olması, varyansının ise homojen ve σ^2 değerine eşit olması gerekmektedir.
- Hata değerleri normal bir dağılıma sahip olmalıdır.
- Hata terimleri birbirinden bağımsız olmalıdır [34].

Bu varsayımlara ek olarak çoklu doğrusal regresyon analizinde açıklayıcı değişkenler de birbirinden bağımsız olmalıdır [31]. Bu varsayıma istatistikte “çoklu doğrusal bağlantı olmaması hali” denilmektedir. Ayrıca bu varsayım; açıklayıcı değişkenler arasındaki basit doğrusal korelasyon katsayılarının sıfır ya da sıfıra çok yakın olması koşulu olarak da izah edilebilir. Bu yüzden açıklayıcı değişkenlerin seçiminde, açıklayıcı değişkenlerin yanıt değişkenleri ile olan korelasyon katsayılarının fazla (1’e yakın), açıklayıcı değişkenlerin arasındaki korelasyon katsayılarının az (0’a yakın) olması önemlidir [35].

4.2.3. Polinomal Regresyon Analizi

Polinomal regresyon sadece bir bağımsız değişkenin kullanıldığı, çoklu regresyonun özel bir durumu olarak tanımlanabilir. Dağılımının tamamen lineer olmadığı veriler için sık kullanılan bir metottur. Polinomal regresyon aşağıdaki gibi ifade edilebilir [36].

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + \dots + \beta_k X_i^k + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (4.3)$$

Burada k, polinomun derecesini ifade etmektedir.

4.2.4. Destek Vektör Makineleri (Support Vector Machine)

Destek vektör makineleri, istatistiki teorilere dayalı olan bir makine öğrenmesi metodudur. DVM hem sınıflandırma hem de regresyon analizleri için kullanılabilir. Bu algoritmanın diğer yöntemlere göre üstünlüğü, çözülmek istenen problemi karesel programlama problemine çevirerek çözmesidir. Bunun yanı sıra genelleştirme konusunda da büyük bir başarı göstermektedir [37].


Destek vektör makinelerinin amacı, bir düzlem üzerindeki noktaları ayırmak için bir doğru çizip ortalama bir sonuca ulaşmaktır. Elde edilen sonuçlar, gelecekteki çıktı değerlerini kestirmek için kullanılmaktadır. SVR aşağıdaki gibi ifade edilebilir.

$$f(x) = wx + b, \quad i = 1 \dots n \quad (4.4)$$

4.2.5. Karar Ağaçları (Decision Tree) Regresyon Analizi

Karar ağaçları (decision tree) modeli, sınıflandırma ve regresyon analizlerinde yaygın bir şekilde kullanılan bir yöntemdir. Bu yöntem, tahmin elde etmek için tercih edilen yöntemleri büyük bir doğruluk ile desteklemektedir. Karar ağaçlarının türü, bu algoritma içerisinde kullanılacak olan bağımlı değişkenin kategorik veya sürekli olmasına göre belirlenmektedir. Bağımlı değişkenin kategorik olması durumunda sınıflandırma, sürekli olması durumunda ise regresyon ağacı tercih edilmektedir [38].

Temel bir karar ağacı düğüm, dal ve yaprak olarak ifade edilen üç ana kısımdan oluşmaktadır. Modelin üst bölümü kökten, alt bölümü ise yapraklardan meydana gelmektedir. Alt ve üst bölge arasında bağlantı kuran bölge ise dallardan oluşmaktadır. Bu yapı şekil 4.7.'de gösterilmiştir. Bu algoritmadaki ana ilke, veri setine sorular yöneltilmesi ve karar kuralları meydana getirilmesidir. Bir karar ağacı uygulaması yapılırken, sorular düğüme yöneltilir ve yaprak bölgesine gelinceye dek dallanmalar büyüyerek ilerler [39].



Şekil 4.7. Basit bir karar ağacı modeli [39]

4.2.6. Rastgele Orman (Random Forest) Regresyon Analizi

Rastgele orman regresyonu, karar ağaçlarının bir çeşidi olarak tanımlanabilir. Bu regresyonun karar ağaçlarından farkı, birden çok sayıda ağaç oluşturabilmesidir. Her ağaç, eğitim verilerinden rastgele seçilen değerlerden oluşmaktadır. Sonuç ise bu regresyon ağaçlarının ortalamasının alınması ile elde edilir.

RF analizinde farklı karar ağaçlarının korelasyonunun önlenmesi için orijinal veri setlerinden çok sayıda alt kümeler meydana getirilmektedir. Yapılan bu işleme torbalama (bagging) adı verilmektedir. Torbalama işlemi neticesinde bazı veriler eğitimde bir kereden fazla kullanılırken bazıları ise hiç kullanılmamış olabilmektedir. Böylece girdi verilerinde ufak değişiklikler ile karşılaşıldığı zaman tahmin doğruluk oranını yükseltildiği için kararlılık oranı daha yüksek olmaktadır [40].

4.2.7. Gauss Süreç Regresyon Analizi (Gaussian Processes)

Parametrik varsayımla yapılan uygulamalarda bazı sınırlamalar mevcut olduğu için bu uygulamaları kullanmak her zaman uygun olmayabilir. Gauss süreç regresyonu karmaşık veri setlerinin kullanılabilirdiği, parametrik olmayan bir regresyon türüdür. Bu analiz, istatistiki modellemelerde de kullanılabilir. Eğitim verilerinin bulunduğu grup $D = \{(x_i, f_i), i = 1, \dots, n\}$ olup $f_i = f(x_i)$, x_i ifadesinin fonksiyondaki değerine tekabül etmektedir. Gauss süreci aşağıdaki gibi ifade edilebilir [41].

$$f(x) \sim GP(m(x_i), k(x_i, x_j)) \quad (4.5)$$

Denklemden $\bar{x}$, ortalama; $k(x_i, x_j)$ ise kovaryans fonksiyonunu ifade etmektedir. Kovaryans matrisinin sahip olduđu elemanlar, rastgele parametreler arasında bulunan benzerliđi göstermektedir [41].

4.2.8. En Yakın Komşu Regresyon Analizi (K-Nearest Neighbors)

Parametrik olmayan bir metot olan en yakın komşular regresyonu, tahmin için benzerlik bilgisini kullanır. Temel prensip, tahmin edilmesi istenen nitelik bilgilerinin ($X = \{x_1, x_2, \dots, x_m\}$) veri setinde bulunan her bir veri ile olan benzerlik bilgilerinin bulunmasıdır. X 'in j . veri ile benzerlik değeri, denklem 4.6'da verilen Minkowski yöntemi ile hesaplanabilir. Bulunan benzerlik, $p = 1$ olası durumunda Manhattan benzerlik, $p = 2$ olması durumunda Euclidean benzerlik olarak adlandırılır. Daha sonra hesaplanan benzerlik değeriyle göre en yakın K komşu değeri, verinin bağımlı deđişken (y) değeriyle ortalamasının tahmin değeri verir (Denklem 4.7).

$$\text{Benzerlik} = \left[\sum_{i=1}^m \left(|x_i - x_i^{(j)}| \right)^p \right]^{\frac{1}{p}} \quad (4.6)$$

$$KNN_{\text{tahmin}}(X) = \frac{1}{K} \sum_{i=1}^K Ng_i^y, \quad Ng \in \text{Komşu seti} \quad (4.7)$$

4.3. Kullanılan Sınıflandırma Algoritmaları

4.3.1. Naive Bayesian Algoritması

Naive Bayesian sınıflandırması istatistiksel bir sınıflandırma türüdür. Bu yöntem ile belli bir örneğin belli bir sınıfa ait olma olasılığı tahmin edilebilir. Bayesian sınıflandırması, Bayes'in teoremine dayanmaktadır. Naive Bayesian sınıflandırıcıları, bir öznelik değeriyle belirli bir sınıf üzerindeki etkisinin, diđer özneliklerin değeriyle bağımsız olduğunu varsaymaktadır. Bu varsayıma "sınıf şartlı bağımsızlık" denir. Her biri kendi etiketine sahip olan k tane sınıf $C_1, C_2, \dots, C_k$ şeklinde, her örneğin n boyutlu bir vektörle temsil edilmesi ise $X = \{x_1, x_2, \dots, x_n\}$ şeklinde ifade edilirse; Bayesian denklemi aşağıdaki gibi ifade edilebilir.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (4.8)$$

4.3.2. Lojistik Sınıflandırma Algoritması

Lojistik regresyon analizi; süreklilik, eşvaryanslık gibi varsayımlara ihtiyacın olmadığı ve iki veya daha çok sınıf ile açıklanabilen bir regresyon modelidir.

Lojistik sınıflandırma yapılırken bağımlı deđişken büyük rol oynar. Lojistik regresyon analizi, bağımlı deđişkene bağılı olarak ikili, multinominal ve sıralı lojistik regresyon olmak üzere

üç sınıfa ayrılmaktadır. Eğer bağımlı değişken iki gruptan oluşuyorsa, ikili; ikiden fazla gruptan oluşuyorsa, multinominal; ikiden fazla gruptan oluşuyorsa ve sıralı bir durum mevcut ise sıralı lojistik regresyon analizi tercih edilmektedir [42].

Lojistik sınıflandırma yapılırken kullanılan bir diğer etken bağımsız değişkendir. Lojistik regresyon analizi içinde bir adet bağımsız değişken bulunduruyor ise, tek değişkenli; iki ya da daha çok bağımsız değişken bulunduruyor ise, çoklu lojistik regresyon analizi adını almaktadır [42].

4.3.3. SMO Algoritması

SMO sınıflandırması, fazladan bir matris depolaması yapmadan ve bütün sayısal QP (Quadratic Programming) optimizasyon basamaklarını kullanmadan problemi çözer. Bu yöntem, tüm öznitelikleri daha önceden belirlenmiş değerler ile normalize eder.

4.3.4. IBk Algoritması

IBk yöntemi KNN içerisinde yer almakla beraber en kolay sınıflandırma yöntemlerinden biridir. Bu yöntem, k (en yakın komşu değeri) değerine kadar en yakın komşuya göre bir sınıflandırma gerçekleştirir.

4.3.5. JRip Algoritması

JRip en çok kullanılan sınıflandırma algoritmalarından biridir. Bu algoritma, bütün sınıflar için tümü pozitif örneklerden meydana gelen bir kural kümesi oluşturur. JRip algoritması, varsayılan bir kural ile başlar ve bir eğitim veri seti kullanır. Ayrıca büyük veri setleri için oldukça uygun bir algoritma çeşididir.

4.3.6. J48 Algoritması

J48 yöntemi Ross Quinlan tarafından geliştirilmiş olan bir karar ağacı algoritmasıdır. Bu yöntem veri setini özyinelemeli bir şekilde sınıflandırır. Bu adım, her ne kadar eğitim verilerinin başarısını yükseltse de bu verilerin yalnızca belli özelliklerini tanımlayan aşırı kurallar meydana getirebilir.


4.3.7. RF Algoritması

RF algoritması, birden fazla sınıflandırıcı oluşturur ve daha sonra onların kestirimlerinden elde edilen oylar ile verileri sınıflandırır. Bu algoritma, büyük veri setleri için uygundur. Ayrıca bu algoritmanın düzensiz veri setlerindeki hataları dengeleme özelliği de bulunmaktadır.

5. DENEYLER VE SONUÇLAR


Bu çalışmada, kullanılan veri setinde bulunan parametreler yardımıyla hava debisi değerleri tahmin edilmeye çalışılmıştır. Bunun için veri setindeki parametreler, nümerik ve kategorik olarak ayrılarak programa uyarlanabilir hale getirilmiştir. SVR regresyon analizinde ve NN yaklaşımında veri setindeki değerler normalize edilerek kullanılırken, diğer regresyon analizi türlerinde gerçek değerler kullanılmıştır. Aşağıda, yapılan regresyon analizleri ile tahmin edilen değerler ile gerçek değerler arasındaki ilişki, her analiz türü için ayrı grafiklerle gösterilmiştir. Tahmin çalışmalarına ek olarak kondüit kapakları, 7 farklı sınıflandırma algoritması kullanılarak kalın ve ince kenarlı olmak üzere iki sınıfa ayrılmaya çalışılmıştır. Bunun için; NaiveBayes, lojistik, SVM, KNN, JRip, J48 ve RF sınıflandırma yöntemleri kullanılmıştır.

5.1. Multi Regresyon Analizi




Şekil 5.1. Multi regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği

Şekil 5.1.'de multi regresyon analizi ile elde edilen, kapak açıklığı ve hava debisi arasındaki değişimi gösteren (hem gerçek hem de tahmini değerler için) bir grafik gösterilmiştir. Bu grafikte hava debisinin 30 L/s'den büyük olduğu bölgelerdeki tahminlerin doğruluğunun çok düşük olduğu görülmekle birlikte, tahmin doğruluğunun en yüksek olduğu kapak açıklıklarının %40 ve %60 olduğu görülmektedir.



Şekil 5.2. Multi regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.2.'de multi regresyon analizi ile elde edilen kondüit uzunluğu ve hava debisi arasındaki değişimi gösteren (hem gerçek hem de tahmini değerler için) bir grafik verilmiştir. Bu grafikte; kapak açıklığının hava debisine göre değişimin verildiği grafikte (şekil 5.1.) olduğu gibi, hava debisinin 30 L/s'den büyük olduğu bölgelerdeki tahminlerin doğruluğunun çok düşük olduğu görülmektedir.



Şekil 5.3. Multi regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği


Şekil 5.3.'te multi regresyon analizi ile elde edilen su ve hava debisi (hem gerçek hem de tahmini değerler için) grafiği verilmiştir. Şekil 5.1. ve Şekil 5.2.'de olduğu gibi bu grafikte de hava debisinin

30 L/s'den büyük olduğu bölgelerdeki su debisi değerlerinin tahmin doğruluklarının çok düşük olduğu görülmektedir.



Şekil 5.4. Multi regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.1, Şekil 5.2, Şekil 5.3 ve Şekil 5.4. göz önünde bulundurulduğunda, grafiklerin hepsinde hava debisi değerinin 30 L/s'den fazla olduğu bölgelerdeki tahmin doğruluklarının çok düşük olduğu, 30 L/s'den az olduğu bölgelerde ise bu doğrulukların arttığı; ancak yine de yeterince yüksek olmadığı görülmektedir. Verilen tüm kesitlerdeki doğruluk değerleri birbirine yakın olsa da, tahmin doğruluğunun en yüksek olduğu kesit KG2 (60/100 dikdörtgen enkesitli ince kenarlı kapak), en düşük olduğu kesit ise KG5 (dairesel enkesitli radyal kapak) olarak bulunmuştur.



Şekil 5.5. Multi regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Bu analiz türü ile korelasyon değeri 0.794 olarak bulunmuştur. Bu değer iyi olsa da çok yüksek değildir. Bu durum, gerçek ve tahmin değerleri arasındaki ilişkinin gösterildiği şekil 5.5.'e bakıldığında da korelasyonun dağınıklığından anlaşılabilir.

Multi regresyon analizi ile elde edilen R^2 değeri 0.593 olmuştur. Bu değer çok yüksek olmamakla birlikte çok düşük de değildir. P değerinin 0.05'ten büyük olması, iki değişken arasındaki ilişkinin istatistiksel olarak anlamlı olmadığı anlamına gelmektedir. Multi regresyon analizi ile elde edilen Tablo 5.1.'e bakıldığında x2 parametresine karşılık gelen P değerinin 0.229 olduğu görülmektedir. Bu nedenle x2 parametresi hesaba katılmadan yeniden bir analiz yapılmıştır. Bu analiz ile elde edilen değerler Tablo 5.2.'de gösterilmiştir. Burada x2 parametresi kondüit uzunluğunu ifade etmektedir. Tablo 5.1. ve Tablo 5.2.'deki R^2 ile düzeltilmiş R^2 değerleri karşılaştırıldığında, bu değerler arasında 0.001'lik çok küçük bir fark görülmektedir. Bu nedenle kondüit uzunluğunun deneylere olan etkisinin anlaşılabilmesi için, yapılan her regresyon analizinde bu parametrenin hesaba katılmadığı uygulamalar da yapılmıştır.


Tablo 5.1. Kondüit uzunluğu parametresi hesaba katılarak yapılan multi regresyon analizi sonuçları

	coef	std err	t	P> t	[0.025	0.975]
const	15.8198	0.729	21.715	0.000	14.390	17.250
x1	-66.0828	2.387	-27.683	0.000	-70.769	-61.397
x2	-0.2021	0.168	-1.205	0.229	-0.531	0.127
x3	1.5183	0.054	28.039	0.000	1.412	1.625
x4	-1.6582	0.724	-2.291	0.022	-3.079	-0.238
x5	5.8722	0.742	7.918	0.000	4.416	7.328
x6	-0.2567	0.748	-0.343	0.022	-1.724	1.211
x7	6.0163	0.734	8.195	0.000	4.575	7.457
x8	-0.9222	0.757	-1.218	0.000	-2.408	0.564
x9	6.7685	0.737	9.184	0.000	5.322	8.215
OLS Regression Results						
Dep. Variable:	y			R-squared:	0.561	
Model:	OLS			Adj. R-squared:	0.557	


Tablo 5.2. Kondüit uzunluğu parametresi hesaba katılmadan yapılan multi regresyon analizi sonuçları

	coef	std err	t	P> t	[0.025	0.975]
const	15.2759	0.572	26.710	0.000	14.153	16.399
x1	-66.2255	2.385	-27.769	0.000	-70.907	-61.544
x2	1.5199	0.054	28.068	0.000	1.414	1.626
x3	-1.7646	0.719	-2.456	0.014	-3.175	-0.354
x4	5.7739	0.737	7.831	0.000	4.327	7.221
x5	-0.3383	0.745	-0.454	0.650	-1.800	1.124
x6	5.9394	0.732	8.118	0.000	4.503	7.376
x7	-1.0042	0.754	-1.331	0.183	-2.485	0.476
x8	6.6697	0.733	9.104	0.000	5.232	8.108
OLS Regression Results						
Dep. Variable:	y			R-squared:	0.560	
Model:	OLS			Adj. R-squared:	0.556	


5.2. Polinomal Regresyon Analizi



Şekil 5.6. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği




Şekil 5.7. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği




Şekil 5.8. Polinomal (6. derece) regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği

Şekil 5.6.'da polinomal (6. derece) regresyon analizi ile elde edilen kapak açıklığının, şekil 5.7.'de kondüit uzunluğunun, şekil 5.8'de ise su debisinin hava debisine göre değişimi (hem tahmini hem de gerçek değerler için) gösterilmektedir. Bu üç grafikte, hava debisi değerinin 30 L/s'nin altında olduğu bölgelerde yapılan tahminlere ait doğruluk değerlerinin oldukça yüksek olduğu görülürken, 30 L/s'den daha büyük olduğu bölgelerde bu doğruluk değerlerinin kısmen düştüğü görülmektedir.



Şekil 5.9. Polinomal (6. derece) regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.9.'da polinomal (6. derece) regresyon analizi ile elde edilen hava debisinin 6 farklı kesit geometrisi için değişimi gösterilmektedir. Burada, hava debisinin 30 L/s'den küçük olduğu bölgelerde tüm kesit geometrileri için elde edilen tahmin değerleri hem birbirine hem de gerçek değerlere oldukça yakındır. Hava debisinin tüm değerleri göz önüne alındığında, doğruluğu en yüksek olan tahminlerin KG3 kesitinde (100/60 dikdörtgen enkesitli radyal kapak), en düşük tahminlerin ise KG5 (dairesel enkesitli radyal kapak) kesitinde bulunduğu görülmektedir.



Şekil 5.10. Polinomal (6. derece) regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.10.'da gerçek ve tahmin değerleri arasındaki korelasyon gösterilmektedir. Burada korelasyon değeri 0.986 olup 1'e çok yakındır. Ayrıca bu şekle bakıldığında korelasyonun genellikle düzgün bir şekilde ilerlediği görülmektedir. Bunlar da tahmini ve gerçek değerlerin birbirine oldukça yakın olduğunu göstermektedir.

Polinomal regresyon analizi yapılırken farklı polinom dereceleri kullanılarak en iyi sonuca ulaşılmaya çalışılmıştır. 1'den 8'e kadar derecelendirme yapılmış ve her değer için R^2 ve korelasyon değerleri hesaplanmıştır. Hesaplamalar sonucunda en düşük R^2 değeri 0.593, korelasyon değeri ise 0.794 olarak bulunmuştur. Bu değerler 1. dereceye aittir. En yüksek R^2 (0.971) ve korelasyon değeri (0.986) ise 6. dereceye aittir. Bu değerler oldukça yüksek olup tahmini ve gerçek değerlerin birbirine çok yakın olduğunu göstermektedir.

Farklı polinom dereceleri için; Tablo 5.3.'te kondüit uzunluğu parametresi hesaba katılarak; Tablo 5.4.'te ise bu parametre hesaba katılmayarak bulunan R^2 ve korelasyon değerleri verilmiştir.

Kondüit uzunluğunun hesaba katılmadığı analizlerde ise R^2 değeri 0.874, korelasyon değeri 0.935 olarak bulunmuştur.


Tablo 5.3. Farklı polinom dereceleri için, kondüit uzunluğunun hesaba katıldığı polinomal regresyon analizi sonuçları

Polinom Derecesi								
	1	2	3	4	5	6	7	8
R^2	0.593	0.881	0.936	0.962	0.971	0.971	0.934	0.659
Coref	0.794	0.945	0.968	0.981	0.985	0.986	0.967	0.849

Tablo 5.4. Farklı polinom dereceleri için, kondüit uzunluğunun hesaba katılmadığı polinomal regresyon analizi sonuçları


Polinom Derecesi								
	1	2	3	4	5	6	7	8
R^2	0.599	0.830	0.868	0.874	0.880	0.874	0.872	0.846
Coref	0.798	0.913	0.932	0.935	0.938	0.935	0.934	0.920

5.3. SVR Regresyon Analizi




Şekil 5.11. SVR (polinomal) regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği

Şekil 5.11.'de SVR (polinomal) regresyon analiziyle elde edilen kapak açıklığının hava debisine göre değişimini gösteren (hem gerçek hem tahmini) grafik verilmiştir. Bu şekle bakıldığında, tüm kapak açıklıklarında gerçek ve tahmini değerlerin birbirine oldukça yakın olduğu görülmekle birlikte hava debisinin 1 L/s'den (normalize değer) büyük olduğu bölgelerde hata oranının az da olsa arttığı görülmektedir.



Şekil 5.12. SVR (polinomal) regresyon analizi sonucunda elde edilen kondüt uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.12.'de SVR (polinomal) regresyon analiziyle elde edilen kondüt uzunluğunun hava debisine göre değişimini gösteren (hem gerçek hem tahmini) grafik verilmiştir. Bu grafikte tüm kondüt uzunlukları için bulunan tahmini değerler ile gerçek değerlerin birbirine oldukça yakın olduğu görülmektedir. Bununla birlikte kapak açıklığı parametresinin kullanıldığı analizde (şekil 5.11.) de olduğu gibi, hava debisinin 1 L/s'den büyük olduğu bölgelerde hata oranının az da olsa arttığı görülmektedir.



Şekil 5.13. SVR (polinomal) regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği


Şekil 5.13.'te SVR (polinomal) regresyon analiziyle elde edilen su debisinin hava debisine göre değişimini gösteren (hem gerçek hem tahmini) grafik verilmiştir. Bu grafikte, özellikle hava ve su

debisinin 1 L/s olduğu alanlardaki tahmin doğruluklarının yüksek olduğu, 1 L/s'den büyük olduğu alanlarda ise bu tahmin doğrulukların az da olsa azaldığı görülmektedir.



Şekil 5.14. SVR (polinomal) regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.14'te SVR (polinomal) regresyon analiziyle elde edilen, hava debisinin kesit geometrisine göre değişimini gösteren (hem gerçek hem tahmini) grafik verilmiştir. Bu grafikte, tahmin değerlerinin gerçek değerlere en yakın olduğu kesitin KG3 (100/60 dikdörtgen enkesitli radyal kapak), en uzak olduğu kesitin ise KG2 (60/100 dikdörtgen enkesitli ince kenarlı kapak) olduğu görülmektedir. KG4 (100/60 dikdörtgen enkesitli ince kenarlı kapak) ve KG6 (daireysel enkesitli ince kenarlı kapak) kesitlerinde ise tahmin doğruluk değerlerinin 0.988 olup aynı olduğu görülmektedir.



Şekil 5.15. SVR (polinomal) regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.15.'te SVR (polinomal) regresyon analiziyle elde edilen, gerçek ve tahmini değerler arasındaki korelasyonu gösteren grafik verilmiştir. Bu grafiğe göre gerçek ve tahmin değerlerinin 1'den sonra korelasyonunun azaldığı görülse de, grafiğe genel olarak bakıldığında oldukça düzenli yapıda olan bir korelasyon çizgisi görülmektedir. Ayrıca bu regresyon tipi, 0.982 değerinde çok yüksek bir korelasyon değeri vermiştir.

SVR regresyon analizi yapılırken lineer, polinomal ve RBF regresyon olmak üzere üç çeşit tahmin algoritması kullanılmıştır. Yapılan analizler, R^2 ve korelasyon değerlerinin en yüksek olduğu regresyon tipinin SVR polinomal, en düşük olduğu regresyon tipinin ise SVR lineer regresyon olduğunu göstermiştir. Tablo 5.5'te kondüit uzunluğu hesaba katılarak, Tablo 5.6'da ise bu parametre hesaba katılmadan yapılan analizler ile elde edilen R^2 ve korelasyon değerleri verilmiştir.

SVR polinomal regresyon analizinde R^2 değerinin 0.965 olup yüksek bir gerçeklik oranına sahip olduğu görülmüştür. Bu regresyon sonucundaki R^2 ve korelasyon değerlerinin yüksek olması, yapılan analizin büyük bir başarı sağladığının göstergesidir.

SVR polinomal regresyon analizinde, kondüit uzunluğunun hesaba katılmadığı analizde R^2 değeri 0.88, korelasyon değeri ise 0.938 olarak bulunmuştur. Bu değerler, kondüit uzunluğunun hesaba katıldığı analizde elde edilen değerlerle karşılaştırıldığında aralarında büyük bir fark görülmemektedir. Özellikle korelasyon değerleri birbirine oldukça yakındır.


Tablo 5.5. SVR türüne göre kondüit uzunluğunun hesaba katıldığı SVR regresyon analizi sonuçları

SVR Türü	R^2	Coref
Lineer	0.532	0.743
Polinomal	0.965	0.982
RBF	0.958	0.979

Tablo 5.6. SVR türüne göre kondüit uzunluğunun hesaba katılmadığı SVR regresyon analizi sonuçları


SVR Türü	R^2	Coref
Lineer	0.535	0.744
Polinomal	0.880	0.938
RBF	0.861	0.929

5.4. DT Regresyon Analizi



Şekil 5.16. DT regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği


Şekil 5.16.'da DT regresyon analizi ile elde edilen kapak açıklığı ve hava debisi grafiği verilmiştir. Bu grafiğe göre hava debisinin 20 L/s'den küçük olduğu bölgeler, tahmin doğruluğunun en yüksek olduğu bölgelerdir. Hava debisinin 20 L/s'den büyük olduğu bölgelerde ise hata oranı gittikçe artmıştır. Ayrıca hava debisi değerinin 0-30 L/s aralığında olduğu bölgede, %40 kapak açıklığı en başarılı olan açıklık oranı olarak görülmektedir.



Şekil 5.17. DT regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.17.'de DT regresyon analizi sonucunda elde edilen kapak açıklığı - hava debisi grafiği verilmiştir. Kapak açıklığı - hava debisi grafiğinde (şekil 5.16.) de olduğu gibi bu grafikte de hava debisinin 20 L/s'den küçük olduğu bölgeler, tahmin doğruluğunun en yüksek olduğu bölgeler

olarak görülürken, hava debisinin 20 L/s’den büyük olduğu bölgelerde hata oranının giderek arttığı görülmektedir. Bununla birlikte şekil 5.17. ye göre hava debisi değerinin 0-20 L/s aralığında olduğu bölgelerde en başarılı tahminler, kondüit uzunluğunun 1 m olduğu durumdaki tahminlerdir. Hava debisi değerinin daha büyük olduğu bölgelerde ise kondüit uzunluğunun 2 m olduğu durumlarda yapılan tahminlerin oldukça başarılı olduğu görülmektedir.




Şekil 5.18. DT regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği

Şekil 5.18.’de DT regresyon analizi sonucunda elde edilen kondüit uzunluğu – hava debisi grafiği verilmiştir. Bu grafiğe göre, su ve hava debisi değerleri arttıkça doğruluk değeri azalmaktadır. Genel olarak su debisinin 15, hava debisinin ise 20 L/s ye kadar olan değerlerinde yapılan tahminlerin en doğru tahminler olduğu söylenebilir.



Şekil 5.19. DT regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.19.'da DT regresyon analiziyle elde edilen kesit geometri - hava debisi grafiği verilmiştir. Bu grafiğe göre tüm kesitlerdeki tahmin doğruluğu oldukça yüksek ve birbirine yakın değerlerdedir. Ancak tahmin doğruluğunun en yüksek olduğu kesit tipinin KG6 (dairesel enkesitli ince kenarlı kapak), en düşük olduğu kesit tipinin ise KG1 (60/100 dikdörtgen enkesitli radyal kapak) olduğu görülmektedir. Ayrıca Şekil 5.16., Şekil 5.17. ve Şekil 5.18.'de olduğu gibi bu grafikte de hava debisinin 20 L/s'den büyük olduğu bölgelerde tahmin doğruluğunun azaldığı görülmektedir.




Şekil 5.20. DT regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.20.'de DT regresyon analiziyle elde edilen gerçek – tahmin değer grafiği verilmiştir. Bu grafikte de özellikle gerçek ve tahmin değerlerinin 20 L/s olduğu bölgedeki korelasyonun oldukça yüksek olduğu görülmektedir. Korelasyon her ne kadar gittikçe azalmış olsa da, genel olarak düzenli bir yapıdadır. Ayrıca yapılan regresyon ile korelasyon değeri 0.937 olarak hesaplanmıştır. Bu değer de tahmini ve gerçek değerlerin birbirine oldukça yakın olduğunu göstermektedir.

DT regresyon analizi sonucunda R^2 değeri 0.851 olarak bulunmuştur. Bu değer, yapılan tahminlerin doğruluğunun yüksek olduğunu göstermektedir.


Kondüit uzunluğunun hesaba katılmadığı DT analizinde elde edilen R^2 değeri 0.833, korelasyon değeri ise 0.914'tür. Bu değerler, kondüit uzunluğunun hesaba katıldığı analiz ile elde edilen değerlerle karşılaştırıldığında aralarında çok küçük bir fark görülmektedir. Bu da kondüit uzunluğunun yapılan hesaba çok az etki ettiğini göstermektedir.

5.5. RF Regresyon Analizi



Şekil 5.21. RF regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği


Şekil 5.21.'de RF regresyon analiziyle elde edilen kapak açıklığı – hava debisi grafiği verilmiştir. Bu grafiğe göre tahminlerin en doğru yapıldığı kapak açıklıkları %40 ve %60'tır. Kapak açıklığının %30 olduğu durumda, hava debisinin 30 L/s'nin altında olduğu değerlerde tahmin doğruluğu oldukça yüksektir. Hava debisi değerinin 30 L/s'nin üstünde olduğu bölgelerde ise bu doğruluğun az da olsa azaldığı görülmektedir.



Şekil 5.22. RF regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.22.'de RF regresyon analiziyle elde edilen kondüit uzunluğu – hava debisi grafiği verilmiştir. Bu grafiğe genel olarak bakıldığında, yapılan tahminlerin gerçek değerlere en yakın

olduğu kondüit uzunluklarının 4 ve 6 m olduğu görülmektedir. Bununla birlikte hava debisi değerinin 0 – 30 L/s olduğu bölgelerde, tüm kondüit uzunluklarında tahmin doğruluğu son derece yüksek olarak görülmektedir.




Şekil 5.23. RF regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği

Şekil 5.23.'te RF regresyon analiziyle elde edilen su debisi – hava debisi grafiği verilmiştir. Bu grafik incelendiğinde, su ve hava debisinin artmasıyla birlikte yapılan tahminlerin başarısının azaldığı görülmektedir. Genel olarak su debisinin 15, hava debisinin ise 20 L/s'ye kadar olan değerlerinde yapılan tahminlerin en doğru tahminler olduğu söylenebilir.



Şekil 5.24. RF regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.24'te RF regresyon analiziyle elde edilen kesit geometri – hava debisi grafiği verilmiştir. Bu grafiğe göre, tüm kesit geometrilerinde bulunan doğruluk oranları birbirine oldukça yakın olup yüksek değerlere sahiptir. Doğruluğun en yüksek olduğu kesit geometrisi 0.991 değerine sahip olan KG6 (dairesel enkesitli ince kenarlı kapak), en düşük olduğu kesit geometrisi ise 0.948 değerine sahip olan KG5 (dairesel enkesitli radyal kapak) olmuştur.




Şekil 5.25. RF regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.25.'te RF regresyon analiziyle elde edilen gerçek – tahmin değer grafiği verilmiştir. Bu grafikte, özellikle tahmini ve gerçek değerlerin 20 L/s'den küçük olduğu alanlardaki korelasyonun çok yüksek olduğu görülmektedir. Bu değerlerin 20 L/s'den büyük olduğu alanlarda da korelasyon oldukça yüksek olarak görülmektedir. Bu analiz tipinde korelasyon değeri 0.964 olarak bulunmuştur. Bu değerin 1'e çok yakın olması da korelasyon grafiğini doğrulamaktadır. RF analiz tipinde R^2 değeri 0.926 olarak bulunmuştur. Bu değerin yüksek olması analizin başarısının bir göstergesidir.


Kondüit uzunluğunun hesaba katılmadığı RF analizinde elde edilen R^2 değeri 0.839, korelasyon değeri ise 0.927'dir. Bu değerler, kondüit uzunluğunun hesaba katıldığı analizde elde edilen değerlerle karşılaştırıldığında aralarında büyük bir fark görülmemektedir. Özellikle korelasyon değerleri birbirine oldukça yakındır.

5.6. GP Regresyon Analizi



Şekil 5.26. GP regresyon analizi sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği


Şekil 5.26.'da GP regresyon analiziyle elde edilen kapak açıklığı – hava debisi grafiği verilmiştir. Bu grafiğe göre, hava debisinin 40 L/s'den küçük değerlerinde tahminlerin doğruluk oranı yüksekken, 40 L/s'den büyük değerlerinde neredeyse tüm tahminler hatalıdır. Ayrıca grafikte, tahmin doğruluklarının en yüksek olduğu kapak açıklıklarının %40 ve %60 olduğu görülmektedir.



Şekil 5.27. GP regresyon analizi sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.27.'de GP regresyon analiziyle elde edilen kondüit uzunluğu – hava debisi grafiği verilmiştir. Bu grafiğe göre, hava debisinin 30 L/s'ye kadar olan değerlerinde, tüm kondüit uzunluklarında yapılan tahminlerin doğruluk oranları yüksektir. Bu grafiğe genel olarak

bakıldığında ise, kondüit uzunluğunun 1 ve 2 m olduğu durumlardaki doğruluk oranlarının 4 ve 6 m olduğu durumlardaki doğruluk oranlarına göre daha yüksek olduğu görülmektedir.




Şekil 5.28. GP regresyon analizi sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği

Şekil 5.28.’de GP regresyon analizi ile elde edilen su debisi – hava debisi grafiği verilmiştir. Kapak açıklığı parametresinin kullanıldığı grafikte olduğu gibi (şekil 6.26.) bu grafikte de, hava debisinin 40 L/s’den küçük değerlerinde tahminlerin doğruluk oranı yüksekken, 40 L/s’den büyük değerlerinde neredeyse tüm tahminlerin hatalı olduğu görülmektedir.



Şekil 5.29. GP regresyon analizi sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.29.'da GP regresyon analiziyle elde edilen kesit geometri – hava debisi grafiği verilmiştir. Bu grafiğe göre tüm kesit geometrilerinde, hava debisinin 40 L/s ye kadar olduğu bölgelerde tahmin doğrulukları oldukça yüksektir. Hava debisinin 40 L/s'den büyük olduğu durumlarda ise tahminlerin tamamı yanlıştır. Tüm kesit geometrilerindeki doğruluk değerleri birbirine oldukça yakın olsa da, en yüksek doğruluğa sahip olan kesit 0.945 doğruluk değeriyle KG4 (100/60 dikdörtgen enkesitli ince kenarlı kapak), en düşük doğruluğa sahip olan kesit ise 0.879 doğruluk değeriyle KG5 (dairesel enkesitli radyal kapak) olarak bulunmuştur.




Şekil 5.30. GP regresyon analizi sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.30'da GP regresyon analiziyle elde edilen gerçek – tahmin değer grafiği verilmiştir. Yapılan regresyon ile korelasyon değeri 0.918 olarak hesaplanmıştır. Bu değerden ve şekil 5.30.'daki korelasyonun düzenli bir yapıda olmasından, tahmini ve gerçek değerlerin birbirine oldukça yakın olduğu anlaşılmaktadır.

GP regresyon analizi sonucunda R^2 değeri 0.831 olarak bulunmuştur. Bu değer, yapılan tahminlerin doğruluk oranının oldukça yüksek olduğunu göstermektedir.


Kondüit uzunluğunun hesaba katılmadığı GP analizinde elde edilen R^2 değeri 0.836, korelasyon değeri ise 0.917'tür. Bu değerler, kondüit uzunluğunun hesaba katıldığı analizde elde edilen değerlerle karşılaştırıldığında aralarında çok küçük bir fark görülmektedir. Bu da kondüit uzunluğunun yapılan hesaba çok az etki ettiğini göstermektedir.

5.7. KNN Regresyon Analizi




Şekil 5.31. KNN regresyon analizi ($k = 8$ için) sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği

Şekil 5.31’de KNN regresyon analiziyle elde edilen kapak açıklığı – hava debisi grafiği verilmiştir. Bu grafiğe bakıldığında, tüm kapak açıklıkları için yapılan tahminlerin hata paylarının oldukça yüksek olduğu, özellikle hava debisi değerinin 30 L/s’den fazla olduğu durumlarda yapılan tahminlerin neredeyse tümünün yanlış olduğu görülmektedir.




Şekil 5.32. KNN regresyon analizi ($k = 8$ için) sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği

Şekil 5.32.'de KNN regresyon analiziyle elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği verilmiştir. Bu grafiğe göre tüm kondüit uzunluklarında, hava debisinin 20 L/s ye kadar olan değerlerinde yapılan tahminler ortalama bir doğruluğa sahiptir. Hava debisi değerinin 20 L/s'den büyük olmaya başlamasıyla birlikte bu doğruluk oranı azalmaya başlamış olup hava debisinin 40 L/s olduğu değerden sonra 0'a kadar düşmüştür.




Şekil 5.33. KNN regresyon analizi (k = 8 için) sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği

Şekil 5.33.'te KNN regresyon analiziyle elde edilen su debisi (SD) – hava debisi (HD) grafiği verilmiştir. Bu grafiğe göre, yapılan tahminlerin başarısı çok düşüktür. Özellikle hava debisi değerinin 30 L/s'den büyük olduğu bölgelerde yapılan tahminlerin tümü başarısızdır.



Şekil 5.34. KNN regresyon analizi (k = 8 için) sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.34.'te KNN regresyon analiziyle elde edilen kesit geometri – hava debisi grafiği verilmiştir. Grafiğe göre tüm kesit alanlarında, yapılan tahminlerin doğruluğu oldukça düşüktür. Özellikle hava debisi değerinin 30 L/s'den büyük olduğu durumlarda yapılan tahminlerin neredeyse tümü yanlıştır. Ancak yine de kesit geometrileri kıyaslandığında tahminlerin en başarılı olduğu kesitin 0.632 değeriyle KG6 (dairesel enkesitli ince kenarlı kapak), en başarısız olduğu kesitin ise KG5 (dairesel enkesitli radyal kapak) olduğu görülmektedir.



Şekil 5.35. KNN regresyon analizi ($k = 8$ için) sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.35.'te KNN regresyon analiziyle elde edilen gerçek ve tahmini değerlerin grafiği verilmiştir. Bu grafikte şeklin oldukça dağınık bir yapıya sahip olduğu ve bu nedenle korelasyonun oldukça düşük olduğu görülmektedir. Ayrıca bu analizde korelasyon değeri 0.549 olarak bulunmuştur. Korelasyon değerinin düşük olması da bu grafik yorumunu doğrulamaktadır.

KNN regresyonu, en yakın komşu adı verilen k sayısına 2, 3, 5 ve 8 değerleri verilerek uygulanmıştır. Her bir uygulama için R^2 ve korelasyon değerleri bulunmuştur. Bu uygulama sonucunda en düşük R^2 ve korelasyon değerini veren k değeri 2, en yüksek R^2 ve korelasyon değerini veren k değeri ise 8 olarak bulunmuştur. Farklı k değerleri için; Tablo 5.7.'de kondüit uzunluğu parametresi hesaba katılarak; Tablo 5.8.'de ise bu parametre hesaba katılmayarak bulunan R^2 ve korelasyon değerleri verilmiştir. Yukarıdaki şekillerde ise k 'nin 8'e eşit olduğu bir uygulamayla elde edilen grafikler verilmiştir. Bu analizde R^2 değeri 0.29'a eşit olup son derece düşüktür. R^2 ve korelasyon değerlerinin düşük olması nedeniyle KNN regresyon analizinin bu çalışmada yetersiz olduğu söylenebilir. Kondüit uzunluğunun hesaba katılmadığı KNN analizinde elde edilen R^2

değeri 0.354, korelasyon değeri ise 0.608 olarak bulunmuştur. Bu değerler, kondüit uzunluğunun hesaba katıldığı analizlerde elde edilen değerlere göre daha yüksektir.


Tablo 5.7. Farklı k değerlerine göre kondüit uzunluğunun hesaba katıldığı KNN regresyon analizi sonuçları

k	R ²	Coref
2	-0.069	0.337
3	0.098	0.418
5	0.215	0.493
8	0.290	0.549

Tablo 5.8. Farklı k değerlerine göre kondüit uzunluğunun hesaba katılmadığı KNN regresyon analizi sonuçları


k	R ²	Coref
2	0.821	0.908
3	0.779	0.884
5	0.515	0.725
8	0.354	0.608

5.8. Sinir Ağları (Neural Network)




Şekil 5.36. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği

Şekil 5.36.'da NN (2 katman, 16 düğüm için) sonucunda elde edilen kapak açıklığı (KA) – hava debisi (HD) grafiği verilmiştir. Bu grafiğe göre tüm kapak açıklıklarında, hava debisinin -1 ile 0 L/s (normalize değerler) arasında olduğu bölgelerdeki tahminlerin doğruluğu en fazladır. Hava debisinin 1'den büyük olmasıyla birlikte hata oranları artmıştır. Hava debisinin 2-3 olduğu bölgelerde ise hata oranı maksimum değerini almıştır.



Şekil 5.37. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kondüit uzunluğu (KU) – hava debisi (HD) grafiği


Şekil 5.37.'de NN (2 katman, 16 düğüm için) uygulamasıyla elde edilen kondüit uzunluğu – hava debisi grafiği verilmiştir. Bu grafiğe genel olarak bakıldığında, şekil 5.6.'da da olduğu gibi hava debisi değerinin -1 ile 0 arasında olduğu bölgelerdeki tahmin doğruluğunun en fazla olduğu ve hava debisinin 1'den büyük olmasıyla birlikte hata oranlarının arttığı görülmektedir. Hata oranlarının en yüksek olduğu bölgelerin -2 ile -1, 2 ile 3 aralıklarındaki bölgeler olduğu görülmektedir.



Şekil 5.38. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen su debisi (SD) – hava debisi (HD) grafiği


Şekil 5.38.'de NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen su debisi – hava debisi grafiği verilmiştir. Bu grafiğe göre tahmin doğruluklarının en yüksek olduğu bölgeler, hava debisinin -1 ile 0 arasında olduğu bölgelerdir. Hava debisinin 1'den büyük olmasıyla birlikte hata

oranları artmıştır. Hava ve su debisinin 2-3 olduğu bölgelerde ise hata oranı maksimum değerini almıştır.




Şekil 5.39. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kesit geometri (KG) – hava debisi (HD) grafiği

Şekil 5.39.'da NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen kesit geometri – hava debisi grafiği verilmiştir. Bu grafiğe göre tahmin değerleri tüm kesit tiplerinde birbirine çok yakın olsa da, tahminlerin gerçeğe en yakın olduğu kesit tipi 0.98 değeriyle KG6 (dairesel enkesitli ince kenarlı kapak), en uzak olduğu kesit tipi ise 0.947 değeriyle KG1 (60/100 dikdörtgen enkesitli radyal kapak)'dir.




Şekil 5.40. NN (2 katman, 16 düğüm için) uygulaması sonucunda elde edilen gerçek ve tahmini değerlerin grafiksel gösterimi

Şekil 5.40'ta NN (2 katman, 16 düğüm için) uygulamasıyla elde edilen gerçek – tahmin değer grafiği verilmiştir. NN uygulaması ile elde edilen korelasyon değeri 0.962 olup oldukça yüksektir. Bu grafiğe bakıldığında da korelasyonun oldukça düzenli bir yapıda olduğu görülmektedir.




Şekil 5.41. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen epoch - hata grafiği (1)

Şekil 5.41.'de NN (2 katman, 16 düğüm) uygulamasıyla elde edilen epoch – hata grafiği verilmiştir. NN uygulamasında model eğitilirken verilerin tümü aynı anda kullanılmaz. Önce veri seti parçalara ayrılır, daha sonra ilk parça eğitilip bu parçanın başarısı test edilir. Daha sonra bu başarıya göre ağırlıklar güncellenir. Bu işlem defalarca tekrarlanarak en uygun ağırlıklar bulunur. Bu basamaklara “epoch” adı verilmektedir. Epoch sayısı arttıkça hata miktarı azalır. Şekil 5.41.'deki grafiğe bakıldığında bu durum görülmektedir. Burada epoch sayısının 1000 olduğu durum, hata miktarının en az olduğu durumdur.



Şekil 5.42. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen LR – R2 grafiği

Şekil 5.42.'de NN (2 katman, 16 düğüm) uygulamasıyla elde edilen LR - R^2 grafiği verilmiştir. LR öğrenme oranı anlamına gelmektedir. Bu grafikte LR değerinin 0.06 olduğu durumda R^2 en büyük değerini almıştır.



Şekil 5.43. NN (2 katman, 16 düğüm) uygulaması sonucunda elde edilen epoch -hata grafiği (2)

Şekil 5.43.'te NN (2 katman, 16 düğüm) uygulamasıyla elde edilen epoch – hata grafiği verilmiştir. Bu grafikte farklı LR değerlerinin kullanıldığı durumlarda, epoch sayısının artmasıyla hata miktarlarının ne kadar değiştiği görülmektedir.

Bu çalışmada son olarak bir NN uygulaması yapılmıştır. En iyi sonucu veren düğüm ve katman sayılarının bulunması için 2 adet katman ile 4, 9, 16, 24 ve 32 adet düğüm ayrı ayrı kullanılmıştır ve böylece 2 adet katmanla kullanıldığında en iyi sonucu veren düğüm sayısı 16 olarak bulunmuştur. Daha sonra 16 adet düğüm ile 3 ve 5 adet katman ayrı ayrı kullanılmıştır ve en iyi değeri veren katman sayısı 2 olarak bulunmuştur. Şekil 5.8.'de en iyi sonucu vermiş olan 2 katman ve 16 düğümlü uygulamanın sonuçları verilmiştir. Ayrıca toplamda 7 kez uygulama yapılan bu analizin sonuçları Tablo 5.9.'da gösterilmiştir.

Tablo 5.9. NN uygulaması sonuçları

Katman Sayısı	Düğüm Sayısı	R^2	Coref
2	4	0.489	0.750
2	9	0.762	0.886
2	16	0.892	0.962
2	24	0.767	0.885
2	32	0.795	0.899
3	16	0.848	0.923
5	16	0.097	0.541

5.9. Naive Bayesian Sınıflandırma Uygulaması

Naive Bayesian yöntemi ile yapılan sınıflandırma çalışmasında, %56.9444 değerinde bir başarı elde edilmiştir. Bu değer çok yüksek olmamakla birlikte çok düşük de değildir. Yapılan sınıflandırmanın detayları tablo 5.10.'da verilmiştir. F ölçütünün (F-Measure) ve MCC değerinin 1'e yaklaşması ile yapılan sınıflandırmanın başarısı artmaktadır.

Tablo 5.10. NaiveBayes yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0.601	0.415	0.491	0.146	K
0.553	0.724	0.627	0.146	I
0.577	0.569	0.559	0.146	

5.10. Lojistik Sınıflandırma Uygulaması

Lojistik sınıflandırma çalışmasında, %70.1389 değerinde bir başarı elde edilmiştir. Bu değer NaiveBayes yöntemine göre daha yüksek olup başarılıdır. Bu sınıflandırma ile elde edilen değerler tablo 5.11.'de verilmiştir.

Tablo 5.11. Lojistik sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0.691	0.728	0.709	0.403	K
0.713	0.675	0.693	0.403	I
0.702	0.701	0.701	0.403	

5.11. SMO Sınıflandırma Uygulaması

SMO sınıflandırma çalışmasında, %69.7421 değerinde bir başarı elde edilmiştir. Bu değer yüksek olması SMO sınıflandırmasının başarısını göstermektedir. SMO sınıflandırması ile elde edilen veriler tablo 5.12.'de verilmiştir.

Tablo 5.12. SVM sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0,684	0,734	0,708	0,396	K
0,713	0,661	0,686	0,396	I
0,698	0,697	0,697	0,396	

5.12. IBk Sınıflandırma Uygulaması

KNN sınıflandırma çalışmasında %92.5595 değerinde bir başarıya ulaşılmıştır. Bu değer, KNN sınıflandırmasının, bu çalışma için çok yüksek bir başarı gösterdiğini ifade etmektedir. KNN sınıflandırması ile elde edilen veriler tablo 5.13.'te verilmiştir.

Tablo 5.13. SVM sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0,907	0,948	0,927	0,852	K
0,946	0,903	0,924	0,852	I
0,926	0,926	0,926	0,852	

5.13. JRip Sınıflandırma Uygulaması

JRip sınıflandırma çalışmasında %88.9881 değerinde bir başarı elde edilmiştir. Bu değer KNN sınıflandırması ile elde edilen değerden daha düşük olsa da, çok yüksek bir başarıyı ifade etmektedir. JRip sınıflandırması ile elde edilen veriler tablo 5.14.'te verilmiştir.

Tablo 5.14. JRip sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0,889	0,891	0,890	0,780	K
0,891	0,889	0,890	0,780	I
0,890	0,890	0,890	0,780	

JRip sınıflandırması ile ince kenarlı kapak için 26 adet kural elde edilmiştir. Bu kurallardan üç tanesi aşağıda verilmiştir.

(HD $\geq$ 19.149) ve (SD $\leq$ 7.1) $\Rightarrow$ KG=I (63.0/0.0)

(KA $\geq$ 0.6) ve (HD $\geq$ 20.342) $\Rightarrow$ KG=I (6.0/0.0)

(KA $\geq$ 0.2) ve (HD $\geq$ 11.165) and (SD $\leq$ 9) $\Rightarrow$ KG=I (32.0/0.0)

5.14. J48 Sınıflandırma Uygulaması

J48 sınıflandırma çalışması ile %95.9325 oranında bir başarı elde edilmiştir. Bu değer çok yüksek olup J48 sınıflandırmasının bu çalışmadaki başarısının çok yüksek olduğunu göstermektedir. Bu sınıflandırma ile elde edilen değerler tablo 5.15.'te verilmiştir.

Tablo 5.15. J48 sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0,966	0,952	0,959	0,919	K
0,953	0,966	0,960	0,919	I
0,959	0,959	0,959	0,919	

5.15. RF Sınıflandırma Uygulaması

RF sınıflandırma uygulaması ile %98.0159 oranında bir başarıya ulaşılmıştır. Bu değer, yapılan sınıflandırmalar arasındaki en başarılı uygulamanın RF uygulamasını olduğunu göstermektedir. Bu sınıflandırma çalışması ile elde edilen değerler tablo 5.16.'da verilmiştir.

Tablo 5.16. RF sınıflandırma yöntemi ile elde edilen değerler

Precision	Recall	F-Measure	MCC	Class
0,975	0,986	0,980	0,960	K
0,986	0,974	0,980	0,960	I
0,980	0,980	0,980	0,960	

6. MATERYAL VE METOT

Tez çalışmasının amacı, farklı kapak geometrisine sahip yüksek basınçlı kondütlerde havalandırma performansının yapay zekâ yöntemleriyle tahmin edilmesidir. Bu amaçla, TUBİTAK 215M046 projesinde yapılan deneyler sonucunda elde edilen veriler kullanılmış olup bu veriler yapay zekâ yöntemleriyle incelenmiştir. Bu yöntemler; multi, polinomal, SVR, DT, RF, GP ve KNN regresyon analizi ile sinir ağlarını (NN) içermektedir. Yapılacak tahminler için Python programı kullanılmıştır. Öncelikle veri seti eğitim ve test grubu olmak üzere ikiye ayrılmıştır. Daha sonra, eğitim ve test verileri karşılaştırılarak yapılan tahminlerin doğruluğu elde edilmiştir.

Tez çalışmasında ayrıca kapak niteliklerinin sınıflandırılması amacıyla; Naive Bayesian, lojistik, SMO, IBk, JRip, J48 ve RF olmak üzere 7 çeşit sınıflandırma algoritması kullanılmıştır. Bu algoritmalar, Weka 3.8.6 programı kullanılarak çalıştırılmıştır.

7. BULGULAR VE TARTIŞMA

Yapılan regresyon analizleri ve sinir ağıları çalışmaları karşılaştırıldığında, polinomal (polinom derecesi = 6 için) ve SVR (polinomal) analizlerinin hava debisi değerlerini tahmin etmede en başarılı analizler olduğu görülmüştür. Polinomal ve SVR (polinomal) analizleri sonunda elde edilen R^2 değerleri sırasıyla 0.971 ve 0.965; korelasyon değerleri ise 0.986 ve 0.982 olmuştur. Bu değerlerin 1'e oldukça yakın olması, yapılan tahminlerin başarısının yüksek olduğunu göstermektedir. Dolayısıyla bu iki regresyon analizi, tezin amacına uygun olarak etkili bir biçimde kullanılabilir.

Kullanılan sınıflandırma algoritmaları kıyaslandığında; RF, J48 ve IBk algoritmalarının kapak niteliklerini (kalın ve ince kenarlı) sınıflandırma en başarılı algoritmalar olduğu görülmüştür. RF, J48 ve IBk algoritmaları ile elde edilen başarı yüzdeleri sırasıyla %98.0159, %95.9325 ve %92.5595 olmuştur. Bu oranların yüksek olması yapılan sınıflandırmaların oldukça başarılı olduğunu göstermektedir.

8. SONUÇLAR

- 1) Yapılan analizler içinde en başarılı sonuçları veren analizler polinomal (6. derece için) ve SVR polinomal regresyon analizleri olmuştur.
- 2) Yapılan analizler içinde en başarısız sonuçları veren analiz KNN ($k = 2$ için) regresyon analizi olmuştur.
- 3) Bu çalışma için; polinomal (dereceye göre), SVR polinomal, SVR- RBF, DT, GP, RF ve NN (düğüm ve katman sayısına göre) analizlerinin başarılı, multi, SVR lineer, ve KNN regresyon analizlerinin ise başarısız olduğu söylenebilir.
- 4) Polinomal ve SVR polinomal regresyonda en başarılı tahminlerin yapıldığı kesit geometrisi KG3 (100/60 dikdörtgen enkesitli radyal kapak) olmuştur.
- 5) Kondüit uzunluğu parametresinin hesaba katıldığı ve katılmadığı analizler ile elde edilen R^2 ve korelasyon değerleri arasında genellikle küçük farklar görülmüştür. Bu da kondüit uzunluğunun deneylere olan etkisinin çok yüksek olmadığını göstermektedir.
- 6) Kapak niteliğinin (kalın ve ince kenarlı) sınıflandırılması için kullanılan algoritmalar arasında en başarı sonucu veren algoritmalar RF, J48 ve IBk olmuştur.
- 7) Kapak niteliğinin (kalın ve ince kenarlı) sınıflandırılması için kullanılan algoritmalar arasında en başarısız sonucu veren algoritma Naive Bayesian olmuştur.
- 8) Normal şartlarda büyük ve zor deneyler ile ulaşılabilecek sonuçlara regresyon analizleriyle ve sınıflandırma algoritmalarıyla ulaşılmış olunması, hidrolik alanında büyük kolaylık sağlayacaktır.

ÖNERİLER

- 1) Bu çalışmada kullanılan özellikle sınıflandırma çalışmaları kara kutu (blackbox) yöntemler olup yorumlanabilirlikleri nispeten düşüktür. Bu nedenle bu veri setlerinin yorumlanabilir yöntemlerle analiz edilmesi, teknik manada hangi niteliklerin etkin olduğunu daha net açığa çıkarılacaktır. Bu yöntemlerin araştırılması gerekir.



KAYNAKLAR

- [1] Ünsal, M., Yılmaz, A. S., Yücel, P. (2016). Dairesel Kondütlerde Hava Delik Çapının Hava Giriş Oranına Etkisinin Yapay Sinir Ağları ile Modellenmesi, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, C. 19(3), 99-102.
- [2] Baylar, A., Ünsal, M., Hanbay, D. (2011). Alternative Models For Prediction Of Aeration Efficiency In Stepped Cascades, *Sigma Mühendislik ve Fen Bilimleri Dergisi*, C. 29, 372-382.
- [3] Dogan, E., Sengorur, B., Koklu, R. (2009). Modeling biological oxygen demand of the Melen River in Turkey using an artificial neural network technique, *Journal of Environmental Management*, C. 90(2), 1229-1235.
- [4] Özger, Z. B., Yağcı, A. E., Ünsal, M. (2022). Estimating The Aeration Performance Of Venturi-Conduit By Artificial Bee Colony Programming, *Politeknik Dergisi*, C. 25(1), 389-398.
- [5] Baylar, A., Ünsal, M., Ozkan, F. (2011). GEP Modeling of Oxygen Transfer Efficiency Prediction in Aeration Cascades, *KSCE Journal of Civil Engineering*, C. 15(5), 799-804. doi: 10.1007/s12205-011-1282-x
- [6] Özkan, F. (2005). *Basınçlı Su Borularında Hava İletimi ve Oksijen Transferinin İncelenmesi*, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü.
- [7] Ünsal, M. (2007). *Suların Havalandırılmasında Yüksek Basınçlı ve Serbest Yüzeyle Kondütlerin Kullanılması*, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü.
- [8] Aras, E. (2009). *Hidrolik Yapılar Üzerinde Gerçekleşen Havalanmanın Nehirlerdeki Çözünmüş Oksijen Dengesi ve Atık Su Arıtma Sistemlerinin Optimizasyonu Üzerine Etkileri*, Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [9] Yücel, P. (2019). *Dairesel Kondütlerde Hava Delik Çapının Havalandırma Performansına Etkisi*, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü.
- [10] Baylar, A., Ünsal, M., Özkan, F., Kayadelen, C. (2014). Estimation of Air Entrainment and Aeration Efficiencies of Weirs Using Genetic Expression Programming, *KSCE Journal of Civil Engineering*, C. 18(6), 1632-1640.
- [11] Baylar, A., Kişi, Özgür., Emiroğlu, M. E. (2009). Modeling Air Entrainment Rate and Aeration Efficiency of Weirs Using ANN Approach, *Gazi University Journal of Science*, C. 22(2), 107-116.
- [12] Gulliver, J. S., Thene, J. R., Rindels, A. J. (1990). Indexing Gas Transfer in Self-Aerated Flows, *Journal of environmental engineering*, C. 116(3), 503-523.
- [13] Küçükali, S., Çokgör, Ş. (2006). Hidrolik Sıçramanın Havalandırma Verimliliğinin İncelenmesi, *İtÜ Dergisi/d*, C. 5(5), 56-66.
- [14] Truesdale, G. A., Gameson, A. L. H. (1957). The Solubility of Oxygen in Saline Water, *Ices Journal of Marine Science*, C. 22(2), 163-166.
- [15] Toombes, L. ve Chanson, H. (2005). Air-Water Mass Transfer on a Stepped Waterway, *Journal of Environmental Engineering*, C. 131(10), 1377-1386.
- [16] Chanson, H. (2002). Air-Water Flow Measurements With Intrusive, Phase-Detection Probes: Can We Improve Their Interpretation?, *Journal of Hydraulic Engineering*, C. 128(3), 252-255.
- [17] Parmaksız, M. (2019). *Serbest Hidrolik Sıçramanın Deneysel ve Sayısal Modellemesi*, Doktora Tezi, Harran Üniversitesi, Fen Bilimleri Enstitüsü.
- [18] Ekinci, L. K. (2005). *Hidrolik Sıçrama Etkisiyle Tabanda Oluşan Basınç Çalkantıları*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

- [19] Baylar, A., Özkan, F., Ünsal, M. (2007). Suların Havalandırma Veriminin Arttırılmasında Kullanılabilecek Basınçlı Akım Sistemleri, *III. Ulusal Su Mühendisliği Sempozyumu*, Gümüş, İzmir.
- [20] Kartal, V., Emiroğlu, M. E. (2021). Su Jetlerinde Oyulmanın Karakteristiklerinin Deneysel İncelenmesi, *Su Kaynakları*, C. 6(1), 15-29.
- [21] Ervine, D. A., McKeogh, E., Elsayy, E. M. (1980). Effect of Turbulence Intensity on the Rate of Air Entrainment by Plunging Water Jets, *Proceedings of the Institution of Civil Engineers*, C. 69(2), 425-445.
- [22] Tsang, C. (1987). *Hydraulic and Aeration Performance of Labyrinth Weirs*, Doctoral Dissertation, University of London.
- [23] Baylar, A., Hanbay, D., Ozpolat, E. (2008). An expert system for predicting aeration performance of weirs by using ANFIS, *Expert Systems with Applications*, C. 35(3), 1214-1222. doi: 10.1016/j.eswa.2007.08.019
- [24] Cici, İ. (2019). *Sayısal Yöntemler Kullanılarak Suların Havalandırılmasında Yeni Venturi Aygıtı Tasarımlarının Araştırılması*, Yüksek Lisans Tezi, İnönü Üniversitesi, Fen Bilimleri Enstitüsü.
- [25] Bağatur, T., Baylar, A. (2001). Venturi Aygıtının Çok Amaçlı Kullanılması, *I. Türkiye Su Kongresi*, İstanbul, C. 2, 431-438.
- [26] Ünsal, M., Tuğal, M., Özkan, F. (2005). Kapaklı Konduitlerde Boy Uzunluğunun Havalandırma Performansına Etkisi, *Fırat Üniversitesi Doğu Araştırmaları Dergisi*, C. 3(3), 132-137.
- [27] Chaudhry M.H., Yevjevich V. (1981). Closed-Conduit Flow, *Water Resources Publication*, Michigan, USA.
- [28] Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi, *Öneri Dergisi*, C. 10(39), 101-115.
- [29] Öztürk, K., Şahin, M. E. (2018). Yapay Sinir ağları ve Yapay Zekâ'ya Genel Bir Bakış, *Takvim-i Vekayi*, C. 6(2), 25-36.
- [30] Arı, A., Berberler, M. E. (2017). Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı, *Acta Infologica*, C. 1(2), 55-73.
- [31] Vural, A. (2007). *Aykırı Değerlerin Regresyon Modellerine Etkileri ve Sağlam Kestiriciler*, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü.
- [32] Okur, S. (2009). *Parametrik ve Parametrik Olmayan Basit Doğrusal Regresyon Analiz Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi*, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü.
- [33] Kutner, M. H., Nachtsheim, C. J., Neter, J., Li, W. (2005). *Applied Linear Statistical Models*, McGraw-Hill Irwin Companies, New York.
- [34] Alma, G.Ö., Vupa, Ö., (2008). Regresyon Analizinde Kullanılan En Küçük Kareler Ve En Küçük Medyan Kareler Yöntemlerinin Karşılaştırılması, *SDÜ Fen Edebiyat Fakültesi Fen Dergisi*, C. 3(2), 219-229.
- [35] Bekiroğlu, N., Konyalıoğlu, R., Karahan, D. (2013). Çoklu doğrusal regresyon sonuçlarının Jackknife tekniği ile tekrarlanabilirliğinin değerlendirilmesi, *Marmara Medical Journal*, C. 2(26), 63-67. doi: 10.5472/MMJ.2013.02499.1

- [36] Ostertagová, E. (2012). Modelling using polynomial regression, *Procedia Engineering*, C. 48, 500-506. doi: 10.1016/j.proeng.2012.09.545
- [37] Güner, N., Çomak, E. (2011). Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarısının Destek Vektör Makineleri Kullanılarak Tahmin Edilmesi, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, C. 17(2), 87-96.
- [38] Özgür, E. G., Erdoğan, B. D. (2020). Bilgisayar Uyarlamalı Test (BUT) Uygulamalarında Regresyon Ağacı Yaklaşımı: Regresyon Karar Ağaçları ile Psikometrik Model Kullanan Standart BUT Algoritmasının Yapay Bir Veri Üzerinde Değerlendirilmesi, *Ankara Sağlık Bilimleri Dergisi*, C. 9(1), 161-167. doi: 10.46971/ausbid.741777
- [39] Kavzoğlu, T., Şahin, E. K., Çölkesen, İ. (2012). Heyelan Duyarlılığının İncelenmesinde Regresyon Ağaçlarının Kullanımı: Trabzon örneği, *Harita Dergisi*, C. 147(3), 21-33.
- [40] Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., Chica-Rivas. (2015). Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines, *Ore Geology Reviews*, C. 71, 804-818.
- [41] Taşkın, G. (2022). Manifold öğrenme yöntemlerinin ileri seviye regresyon yöntemleri ile geliştirilmesi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, C. 37(1), 485-496.
- [42] Şenel, S., Alatlı, B. (2014). Lojistik Regresyon Analizinin Kullanıldığı Makaleler Üzerine Bir İnceleme, *Journal of Measurement and Evaluation in Education and Psychology*, C. 5(1), 35-52.

ÖZGEÇMİŞ

Zeynep KILIÇ

Category	Percentage	Category	Percentage
Very good	10%	Very good	10%
Good	20%	Good	20%
Fair	30%	Fair	30%
Poor	40%	Poor	40%
Very poor	50%	Very poor	50%

Age Group	Percentage Vaccinated
18-24	100%
25-34	80%
35-44	60%

[REDACTED]

[REDACTED]

■ [REDACTED] [REDACTED]

■ [REDACTED] [REDACTED]