

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

İKLİM DEĞİŞİKLİĞİNİN VE SOSYO-EKONOMİK PARAMETRELERİN
ALTYAPI PROJELERİ ÜZERİNDEKİ ETKİSİNİN YAPAY ZEKÂ
KULLANILARAK TAHMİN EDİLMESİ: ADANA İLİ ÖRNEĞİ

DOKTORA TEZİ

Yusuf BALTACI

OCAK 2025
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**İKLİM DEĞİŞİKLİĞİNİN VE SOSYO-EKONOMİK PARAMETRELERİN
ALTYAPI PROJELERİ ÜZERİNDEKİ ETKİSİNİN YAPAY ZEKÂ
KULLANILARAK TAHMİN EDİLMESİ: ADANA İLİ ÖRNEĞİ**

YUSUF BALTACI

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"DOKTOR (İNŞAAT MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 16 / 12 / 2024

Tezin Savunma Tarihi : 10 / 01 / 2025

Tez Danışmanı : PROF. DR. TAYFUN DEDE

ÖNSÖZ

Bu tez çalışması Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Ana Bilim Dalı'nda Doktora tezi olarak hazırlanmıştır.

Tez çalışmam süresince akademik birikimi ve tecrübeleriyle çalışmama ışık tutan, her aşamada destek veren ve gösterdiği ilgi, anlayış ve özveriyle beni yönlendiren saygıdeğer hocam Prof. Dr. Tayfun DEDE'ye minnet ve şükranlarımı sunarım.

Tez savunma komitesinde yer alarak değerli zamanlarını ayıran, görüş ve önerileriyle tezin zenginleştirilmesine katkıda bulunan hocalarım Prof. Dr. Rıfat AKBIYIKLI, Doç. Dr. Hasan Basri BAŞAĞA, Doç. Dr. Gökhan ÖZÇELİK ve Doç. Dr. Savaş BAYRAM'a en içten teşekkürlerimi sunarım.

Tez çalışmam sırasında karşılaştığım sorunların çözümünde bilgi ve tecrübeleriyle destek olan Dr. Öğr. Üyesi Bayram Ali TEMEL'e; doktora sürecim boyunca öneri, destek ve yardımlarıyla tezime değerli katkılar sağlayan çalışma arkadaşlarım Abdurrahman KAYGUSUZ, Alpay YILDIRIM, Figen ORTAK, Metin ÜN, M. Azim İRGEŞ, Rasim ALACA ve Serhat ALTUNER'e; ayrıca çalışmamda verdikleri özel katkılar için ASKİ Genel Müdürlüğü inşaat mühendisi Anıl Kaan KEMER ve Şube Müdür V. Behçet KILINÇ'a içten teşekkürlerimi sunarım.

Hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım, her zaman yanımda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Ayşe BALTACI, babam Muhammet BALTACI ve kardeşim Betül BALTACI'ya sonsuz minnettarlığımı sunarım.

Yusuf BALTACI

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “*İklim Değişikliğinin ve Sosyo-Ekonomik Parametrelerin Altyapı Projeleri Üzerindeki Etkisinin Yapay Zekâ Kullanılarak Tahmin Edilmesi: Adana İli Örneği*” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Tayfun DEDE’nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 10/01/2025

Yusuf BALTACI

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XV
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Tezin Amacı ve Kapsamı	5
1.3. Araştırma Yöntemi	6
1.4. Literatür Taraması	7
1.4.1. Ulusal Düzeyde Yapılan Çalışmalar	7
1.4.2. Uluslararası Düzeyde Yapılan Çalışmalar	13
1.5. İklim Değişikliği.....	33
1.6. Altyapı ve Altyapı Projeleri	39
1.7. Çok Ölçütlü Karar Verme (ÇÖKV) Yöntemleri	45
1.7.1. SWARA Yöntemi	47
1.8. Temel Birleşen Analizi (PCA).....	49
1.9. Yapay Zekâ.....	51
1.9.1. Ridge Regresyon	55
1.9.2. Lasso Regresyon	56
1.9.3. XGBoost Regresyon	58
1.9.4. SVR Regresyonu.....	59
2. YAPILAN ÇALIŞMALAR.....	62
2.1. Giriş.....	62
2.1.1. İklim Değişikliğinin Önemi	63
2.2. Tahmin Modellerinde Kullanılacak Verilerin Belirlenmesi.....	64
2.2.1. SWARA Yönteminin Uygulaması.....	65

2.2.2. Aydeniz Yöntemi	70
2.2.3. Temel Bileşen Analizinin Uygulanması	72
2.2.4. Tahmin Modellerinde Kullanılacak Verilerin Seçimi.....	75
2.3. Tahmin Model Çalışmaları.....	76
2.4. Denetimli Makine Öğrenmesi ile Tahmin Modeli	81
3. BULGULAR VE İRDELEME	89
3.1. Dağıtım Debisi Tahmin Modellerine İlişkin Bulgular	89
3.1.1. Ridge Algoritması ile Tahmin Modeli	89
3.1.2. Lasso Algoritması ile Tahmin Modeli	96
3.1.3. XGBoost Algoritması ile Tahmin Modeli	102
3.1.4. SVR Algoritması ile Tahmin Modeli.....	108
3.1.5. Dağıtım Debisi Tahmin Modellerinin Karşılaştırılması	114
3.2. Ridge Algoritması Proje Büyüklüğü Tahmin Modellerne İlişkin Bulgular	117
3.2.1. Ridge Algoritması ile İçmesuyu Proje Büyüklüğü Tahmin Modeli	118
3.2.2. Ridge Algoritması ile Atıksu Proje Büyüklüğü Tahmin Modeli	125
3.3. SVR Algoritması Proje Büyüklüğü Tahmin Modellerine İlişkin Bulgular.....	132
3.3.1. SVR Algoritması ile İçmesuyu Proje Büyüklüğü Tahmin Modeli	132
3.3.2. SVR Algoritması ile Atıksu Proje Büyüklüğü Tahmin Modeli	137
3.4. Proje Büyüklüğü Tahmin Modellerinin Karşılaştırılması	142
3.5. Proje Büyüklüğü Tahmin Değerleri	145
4. TARTIŞMALAR	147
5. SONUÇLAR.....	152
6. ÖNERİLER.....	157
7. KAYNAKLAR	159
8. EKLER.....	170
ÖZGEÇMİŞ	

ÖZET

Doktora Tezi

İKLİM DEĞİŞİKLİĞİNİN VE SOSYO-EKONOMİK PARAMETRELERİN ALTYAPI PROJELERİ ÜZERİNDEKİ ETKİSİNİN YAPAY ZEKÂ KULLANILARAK TAHMİN EDİLMESİ: ADANA İLİ ÖRNEĞİ

Yusuf BALTACI

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Tayfun DEDE
2025, 169 Sayfa, 6 Sayfa Ek

Altyapı projelerinin büyüklüğü ve karmaşıklığı, toplumun uzun vadeli ihtiyaçlarını karşılamada kritik bir öneme sahiptir. Bu projeler, sürdürülebilir ve güvenilir altyapılar oluşturarak, gelecek nesillere yaşanabilir bir çevre sunmayı hedeflemektedir. Bu tez çalışmasında, Adana ilinde iklim değişikliği ve sosyo-ekonomik parametrelerin içme suyu ve atıksu altyapı projeleri üzerindeki etkilerini incelemek amacıyla yapay zekâ destekli makine öğrenmesi algoritmaları kullanılmıştır. Modellerde kullanılacak parametrelerin belirlenmesi için SWARA (Adım Adım Ağırlık Değerlendirme Oranı Analizi) ve PCA (Temel Bileşen Analizi) yöntemleri uygulanmıştır. 2006-2023 yılları arasındaki veriler dikkate alınarak, dağıtım debisi ve buna bağlı olarak içme suyu ve atıksu proje büyüklüklerinin geleceğe yönelik tahmini için Lasso, Ridge, XGBoost ve SVR gibi makine öğrenmesi algoritmaları kullanılmıştır. Kurulan modellerin performansı MAE, RMSE, R^2 ve Nash-Sutcliffe Verimliliği (NSE) katsayıları ile değerlendirilmiştir. Sonuçlar, şehir gelişmişliği, yerleşim nüfusu ve kayıtlı abone sayısı gibi üç sosyo-ekonomik parametre ile Aydeniz Kuraklık İndeksi (sıcaklık, güneşlenme süresi, yağış miktarı ve nem) olmak üzere toplam dört bağımsız değişkenin, altyapı projelerinin maliyet bileşenleri üzerinde belirgin etkiler oluşturduğunu göstermiş olup bu etkilerin, altyapı projelerinin planlama ve tasarım süreçlerinde dikkate alınmasının önemi vurgulanmıştır.

Anahtar Kelimeler: Altyapı projesi, Yapay zekâ tabanlı makine öğrenme algoritmaları, İklim değişikliği, Tahmin modelleri, SWARA, PCA.

SUMMARY

PhD. Thesis

PREDICTING THE IMPACT OF CLIMATE CHANGE AND SOCIO-ECONOMIC PARAMETERS ON INFRASTRUCTURE PROJECTS USING ARTIFICIAL INTELLIGENCE: THE CASE OF ADANA PROVINCE

Yusuf BALTACI

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Civil Engineering Graduate Program
Supervisor: Prof. Dr. Tayfun DEDE
2025, 169 Pages, 6 Pages Appendix

The scale and complexity of infrastructure projects are critically important for meeting the long-term needs of society. These projects aim to establish sustainable and reliable infrastructure systems, ensuring a livable environment for future generations. In this thesis, machine learning algorithms were employed to examine the impacts of climate change and socio-economic parameters on drinking water and wastewater infrastructure projects in Adana Province. To determine the parameters to be used in the models, SWARA (Step-wise Weight Assessment Ratio Analysis) and PCA (Principal Component Analysis) methods were applied. Based on data from 2006 to 2023, Lasso, Ridge, XGBoost, and SVR were used to forecast distribution flow rates and, consequently, the future scale of drinking water and wastewater projects. The performance of the developed models was evaluated using MAE, RMSE, R^2 and Nash-Sutcliffe Efficiency (NSE) metrics. The results demonstrated that three socio-economic parameters urban development, population, and registered subscribers along with the Aydeniz Drought Index (a combination of temperature, sunshine duration, precipitation and humidity), significantly influenced the cost components. These findings emphasize the importance of considering such factors in the planning and design processes of infrastructure projects.

Key Words: Infrastructure project, Artificial intelligence-based machine learning algorithms, Climate change, Prediction models, SWARA, PCA.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. İklim değışikliđinin ana unsurları	33
Şekil 2. Su ve kanalizasyon altyapısının hizmetlerinin sistematik yapısı.....	42
Şekil 3. SWARA yöntemi ile parametre ağırlıklarının belirlenmesi	48
Şekil 4. PCA veri boyut indirgeme şeması	51
Şekil 5. Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi	52
Şekil 6. Makine öğrenmesi türleri.....	53
Şekil 7. Denetimli ve denetimsiz öğrenme süreçleri	53
Şekil 8. Denetimli öğrenme algoritmaları.....	55
Şekil 9. XGBoost algoritmasının gelişim süreci.....	58
Şekil 10. Destek Vektörlerin Düzlem Oluşturması.....	59
Şekil 11. SWARA yönteminde AKV'lere göre parametrelerin ağırlıkları ve önem sırası	67
Şekil 12. Temel bileşen sayısı-toplam açıklanan varyans grafiđi.....	74
Şekil 13. Optimum modelde içmesuyu proje büyüklüğü, atıksu proje büyüklüğü, su dağıtım debisi değışkenleri için eğitim (a), test (b) ve tahmin (c) veri setlerine ait zaman serileri	79
Şekil 14. Makine öğrenmesi temel süreci.....	81
Şekil 15. Dağıtım debisi tahminine (I. Aşama) yönelik akış diyagramı.....	85
Şekil 16. Proje büyüklükleri tahminine (II. Aşama) yönelik akış diyagramı	86
Şekil 17. Dağıtım debisi tahmin modelinin phyton koduna ait ekran alıntısı.....	87
Şekil 18. Dağıtım debisi model grafiklerinin phyton koduna ait ekran alıntısı	87
Şekil 19. İçmesuyu proje büyüklüğü tahmin modelinin phyton koduna ait ekran alıntısı	88
Şekil 20. Atıksu proje büyüklüğü tahmin modelinin phyton koduna ait ekran alıntısı	88
Şekil 21. Ridge algoritması alpha (α) değışim grafiđi	90
Şekil 22. Ridge algoritması dağıtım debisi değışkenine ait zaman serisi grafiđi	92
Şekil 23. Ridge algoritması dağıtım debisi değışkenine ait eğitim veri seti saçılım grafikleri	93
Şekil 24. Ridge algoritması dağıtım debisi değışkenine ait test veri seti saçılım grafikleri	93
Şekil 25. Ridge algoritması tahmin modeline ait zaman serisi grafiđi	95

Şekil 26.	Lasso algoritması Alpha (α) değişim grafiği	96
Şekil 27.	Lasso algoritması dağıtım debisi değişkenine ait zaman serisi grafiği.....	98
Şekil 28.	Lasso algoritması dağıtım debisi değişkenine ait eğitim veri setlerinin saçılım grafikleri	99
Şekil 29.	Lasso algoritması dağıtım debisi değişkenine ait test veri setlerinin saçılım grafikleri	99
Şekil 30.	Lasso algoritması tahmin modeline ait zaman serisi grafiği	101
Şekil 31.	XGBoost algoritması hiper parametre- RMSE- değişim grafiği	103
Şekil 32.	XGBoost algoritması dağıtım debisi değişkenine ait zaman serisi grafiği.....	105
Şekil 33.	XGBoost algoritması dağıtım debisi değişkenine ait eğitim veri setlerinin saçılım grafikleri	105
Şekil 34.	XGBoost algoritması dağıtım debisi değişkenine ait test veri setlerinin saçılım grafikleri	106
Şekil 35.	XGBoost algoritması tahmin modeline ait zaman serisi grafiği.....	108
Şekil 36.	SVR algoritması C ve Epsilon (ϵ) değişim grafiği	109
Şekil 37.	SVR algoritması dağıtım debisi değişkenine ait zaman serisi grafiği	111
Şekil 38.	SVR algoritması modelinin eğitim ve test veri setlerine ait saçılım grafikleri	111
Şekil 39.	SVR algoritması tahmin modeline ait zaman serisi grafiği	113
Şekil 40.	Dağıtım debisi değişkeni modellerinin karşılaştırmalı saçılım grafiği.....	115
Şekil 41.	Dağıtım debisi değişkeni modellerinin karşılaştırmalı zaman serisi grafiği.....	116
Şekil 42.	Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait zaman serisi grafiği	121
Şekil 43.	Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafikleri	121
Şekil 44.	Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin modelne ait zaman serisi grafiği	124
Şekil 45.	Ridge algoritması atıksu proje büyüklüğü değişkenine ait zaman serisi grafiği.....	128
Şekil 46.	Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafikleri	129
Şekil 47.	Ridge algoritması atıksu proje büyüklüğü tahminine ait zaman serisi grafiği.....	131
Şekil 48.	SVR algoritması C- ϵ ve RMSE ısı haritası.....	134
Şekil 49.	SVR algoritması içmesuyu proje büyüklüğü değişkenine ait zaman serisi grafiği	135

Şekil 50.	SVR algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafiği.....	136
Şekil 51.	SVR algoritması tahmin modeline ait zaman serisi grafiği	137
Şekil 52.	SVR algoritması C-ε değerleri ısı haritası	139
Şekil 53.	SVR algoritması atıksu proje büyüklüğü değişkenine ait zaman serisi grafiği.....	140
Şekil 54.	SVR algoritması atıksu proje büyüklüğü değişkenine ait saçılım grafiği	141
Şekil 55.	SVR algoritması tahmin modeline ait zaman serisi grafiği	142
Şekil 56.	İçmesuyu proje büyüklüğü değişkeni modellerinin karşılaştırmalı saçılım grafiği	144
Şekil 57.	Atıksu proje büyüklüğü değişkeni modellerinin karşılaştırmalı saçılım grafiği.....	144
Şekil 58.	Adana ili içmesuyu proje büyüklüklerine ilişkin tahmin senaryoları.....	146
Şekil 59.	Adana ili atıksu proje büyüklüklerine ilişkin tahmin senaryoları.....	146

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Modellemelerde kullanılan parametre ve yöntemlerin literatür özeti.....	30
Tablo 2. SWARA yönteminde AKV'ye göre parametrelerin ağırlık sonuçları	68
Tablo 3. Aydeniz Yöntemi indeks değerleri	71
Tablo 4. Aydeniz Yöntemine göre hesaplanan yıllık (N_{ks}) ve (K_{ks}) değerleri.....	71
Tablo 5. Bağımsız değişkenlerin PCA karakteristik değerleri.....	73
Tablo 6. Bağımsız değişkenlerin PCA bileşen ağırlıkları (katsayıları)	75
Tablo 7. Verilerin eğitim, test ve tahmin setlerine ayrılması (I. ve II. Aşama)	78
Tablo 8. Tahmin senaryosunun veri seti (I. ve II. Aşama).....	83
Tablo 9. Dağıtım debisi değişkeni için Ridge modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç parametrelili ($\alpha:1$) performans ölçüt istatistikleri	91
Tablo 10. Dağıtım debisi değişkeni için Ridge modellerinin eğitim, test ve tahmin veri setlerine ait optimize parametrelili ($\alpha: 0.1322$) performans ölçüt istatistikleri	91
Tablo 11. Ridge algoritması modelinin fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem	94
Tablo 12. Ridge algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri	94
Tablo 13. Ridge algoritması tahmin modeli sonuçları.....	95
Tablo 14. Dağıtım debisi değişkeni için Lasso modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç parametrelili ($\alpha:1$) performans ölçüt istatistikleri	97
Tablo 15. Dağıtım debisi değişkeni için Lasso modellerinin eğitim, test ve tahmin veri setlerine ait optimize parametrelili ($\alpha: 0.001$) performans ölçüt istatistikleri	97
Tablo 16. Lasso algoritması fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem	100
Tablo 17. Lasso algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri	100
Tablo 18. Lasso algoritması tahmin modeli sonuçları	101
Tablo 19. Dağıtım debisi değişkeni için XGBoost modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç hiper parametrelili performans ölçüt istatistikleri	103

Tablo 20.	Dağıtım debisi değişkeni için XGBoost modellerinin eğitim, test ve tahmin veri setlerine ait optimize hiper parametrelili performans ölçüt istatistikleri	104
Tablo 21.	XGBoost algoritması modellerinin hiper parametre fonksiyonları	107
Tablo 22.	XGBoost algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri	107
Tablo 23.	XGBoost algoritması tahmin modeli sonuçları	107
Tablo 24.	Dağıtım debisi değişkeni için SVR modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç hiper parametrelili performans ölçüt istatistikleri	109
Tablo 25.	Dağıtım debisi değişkeni için SVR modellerinin eğitim, test ve tahmin veri setlerine ait optimize hiper parametrelili performans ölçüt istatistikleri	110
Tablo 26.	SVR algoritması modelinin fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem	112
Tablo 27.	SVR algoritması modelinin dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri	112
Tablo 28.	SVR algoritması tahmin modeli sonuçları.....	113
Tablo 29.	Dağıtım debisi bağımlı değişkeni modellerinin performans istatistiklerinin karşılaştırılması.....	114
Tablo 30.	Makine öğrenmesi algoritma modellerinin dağıtım debisine ilişkin tahmin sonuçları.....	116
Tablo 31.	Ridge modellerinin ($\alpha:1$; $\alpha:100$) çapraz doğrulama performans ölçütleri	118
Tablo 32.	Ridge polinom regresyon başlangıç (k-cv=3) modelinin performans ölçütleri.....	119
Tablo 33.	Ridge polinom regresyonu optimize (k-cv=7) modelinin performans ölçütleri.....	119
Tablo 34.	Ridge regresyon enhanced başlangıç (k-cv=3) modelinin performans ölçütleri.....	120
Tablo 35.	Ridge regresyon enhanced optimizasyon (k-cv=7) modelinin performans ölçütleri.....	120
Tablo 36.	Ridge algoritması modelinin fonksiyonları ve içmesuyu proje büyüklüğü değişkeninin elde edildiği denklem	122
Tablo 37.	Ridge algoritması içmesuyu proje büyüklüğü değişkeninin tahmini için kullanılan değişkenlerin göreceli önemleri.....	123
Tablo 38.	Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin sonuçları.....	124
Tablo 39.	Ridge modellerinin ($\alpha:1$; $\alpha:100$) çapraz doğrulama performans ölçütleri	125
Tablo 40.	Ridge polinom regresyon başlangıç (k-cv=3) modelinin performans ölçütleri.....	126

Tablo 41.	Ridge polinom regresyonu optimize (k-cv=3) modelinin performans ölçütleri.....	126
Tablo 42.	Ridge regresyon enhanced (α :0.042) modelinin performans ölçütleri	127
Tablo 43.	Ridge regresyon enhanced (α :0.002) modelinin performans ölçütleri	128
Tablo 44.	Ridge algoritması modelinin fonksiyonları ve atıksu proje büyüklüğü değişkeninin elde edildiği denklem	130
Tablo 45.	Ridge algoritması atıksu proje büyüklüğü değişkeninin tahmini için kullanılan değişkenlerin göreceli önemleri.....	130
Tablo 46.	Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası atıksu proje büyüklüğü tahmin sonuçları.....	131
Tablo 47.	SVR modelinin (C:1; ϵ :0.1) çapraz doğrulama performans ölçütler	133
Tablo 48.	SVR regresyon (k-cv=4, C:1; ϵ :0.1) genel modelinin performans ölçütleri.....	133
Tablo 49.	SVR regresyon özel modelinin performans ölçütleri	135
Tablo 50.	SVR algoritması modelinin fonksiyonları ve içmesuyu proje büyüklüğü değişkeninin elde edildiği denklem	136
Tablo 51.	SVR algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğü tahmin modeli sonuçları.....	137
Tablo 52.	SVR modelinin (C:1; ϵ :0.01) çapraz doğrulama performans ölçütleri.....	138
Tablo 53.	SVR regresyon (k-cv=7, C:1; ϵ :0.1) genel modelinin performans ölçütleri.....	138
Tablo 54.	SVR regresyon örnek modellerin performans ölçütleri.....	140
Tablo 55.	SVR algoritması modelinin fonksiyonları ve atıksu proje büyüklüğü değişkeninin elde edildiği denklem	141
Tablo 56.	SVR algoritması ile Adana şehir merkezinin 2021-2026 yılları arası atıksu proje büyüklüğü tahmin modeli sonuçları.....	142
Tablo 57.	İçmesuyu proje büyüklüğü bağımlı değişken modeli performans istatistiklerinin karşılaştırılması.....	143
Tablo 58.	Atıksu proje büyüklüğü bağımlı değişken modeli performans istatistiklerinin karşılaştırılması.....	143
Tablo 59.	Adana ili merkez ilçelerine ait toplam içmesuyu ve atıksu altyapı proje büyüklüklerine ilişkin geçmiş ve tahmin değerleri.....	145

SEMBOLLER VE KISALTMALAR DİZİNİ

α	: Ceza parametresi (Ridge ve Lasso Algoritması)
β_0	: Sabit Katsayı (Intercept)
β_n	: Hata Değer Katsayısı
ϵ	: Hata marjı (SVR Algoritması)
c	: Cezalandırma parametresi (SVR Algoritması)
K_{ks}	: Aydeniz Kuraklık Katsayısı
k-cv	: k katlı çapraz doğrulama (k-fold cross validation)
N_{ks}	: Aydeniz Nemlilik Katsayısı
R^2	: Determinasyon Katsayısı
q	: Ağırlık katsayısı
y	: Tahmin fonksiyonu
AHP	: Analitik Hiyerarşi Süreci (Analytic Hierarchy Process)
AKV	: Anket Karar Verici
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
ASKİ	: Adana Su ve Kanalizasyon İdaresi
ÇÖKV	: Çok Ölçütlü Karar Verme (MCDM)
DL	: Derin Öğrenme (Deep Learning)
DSİ	: Devlet Su İşleri
EKK	: En Küçük Kareler Yöntemi (Ordinary Least Squares)
ELECTRA	: Etkin ve Hafif Transfer Öğrenme ile Kodlanmış Temsilciler (Efficiently Learning an Encoder that Classifies Token Replacements Accurately)
GBM	: Gradyan Artırma Makinesi (Gradient Boosting Machine)
GSYH	: Gayrisafi Yurtiçi Hasıla
HP	: Hiper parametre (Hyperparameter)
IPCC	: Hükümetlerarası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change)
İLBANK	: İller Bankası
KİK	: Kamu İhale Kurumu
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
L1	: Manhattan Normu (Lasso Algoritması)

L2	: Öklid Normu (Ridge Algoritması)
LASSO	: En Küçük Mutlak Sapmalar ve Seçim Operatörü (Least Absolute Shrinkage and Selection Operator)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MGM	: Meteoroloji Genel Müdürlüğü
ML	: Makine Öğrenimi (Machine Learning)
MEVBİS	: Meteorolojik Veri Bilgi Sistemi
NSE	: Nash-Sutcliffe Verimlilik Katsayısı (Nash-Sutcliffe Efficiency)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PC _n	: n Numaralı Temel Bileşen (n. Number Principal Component)
PDSI	: Palmer Kuraklık Şiddet İndeksi (Palmer Drought Severity Index)
RBF	: Radyal Tabanlı Fonksiyon (Radial Basis Function)
RIDGE	: Ridge Regresyonu (Ridge Regression)
RMSE	: Kök Ortalama Kare Hata (Root Mean Squared Error)
SBB	: Strateji Bütçe Başkanlığı (Cumhurbaşkanlığı)
SL	: Denetimli Öğrenme (Supervised Learning)
SVM	: Destek Vektör Makinaları (Support Vector Machine)
SVR	: Destek Vektör Regresyonu (Support Vector Regression)
SWARA	: Ağırlıklandırılmış Aritmetik Ortalama ve Sıralama Yaklaşımı (Step-wise Weight Assessment Ratio Analysis)
TOPSIS	: İdeal Çözüme Yakınlıkla Sıralama Tekniği (Technique for Order Preference by Similarity to Ideal Solution)
TÜİK	: Türkiye İstatistik Kurumu
XGBoost	: Aşırı Gradyan Artırma (Extreme Gradient Boosting)
YSA	: Yapay Sinir Ağı

1. GENEL BİLGİLER

1.1. Giriş

Altyapılar, şehirlerin can damarlarıdır. Altyapı projeleri, modern toplumların temel ihtiyaçlarını karşılayacak şekilde tasarlanmaktadır. Bu projeleri oluşturan bileşenler arasında yollar, köprüler, içme suyu ve atıksu sistemleri, enerji hatları, iletişim ağları bulunmakta olup bunların her biri, sosyal ve ekonomik yaşamın sürdürülmesi için hayati öneme sahiptir. Altyapı projelerinin başarılı bir şekilde uygulanması, yapım yönetimi disiplininin merkezinde yer alan etkin bir planlama, koordinasyon ve kontrol sürecine bağlıdır.

Yapım yönetimi, altyapı projelerinin her aşamasında kritik bir rol oynamaktadır. Bir projenin başlangıç aşamasındaki kapsam, maliyet ve zaman yönetimi gibi temel unsurlar başarılı bir projenin temelini oluşturur. Kalite kontrol süreçleri, kaynakların etkin kullanımı ve iş güvenliği standartlarına uygunluk, projenin zamanında ve bütçe dâhilinde tamamlanmasını sağlar. Ayrıca yapım yönetimi, altyapı projelerinin çevresel ve sosyal etkilerini en aza indirerek sürdürülebilir hedeflere ulaşmayı amaçlamaktadır.

Sonuç olarak, altyapı projelerinde yapım yönetimi, projelerin karmaşıklığı ve büyüklüğü dikkate alındığında, tek bir gerekliliğin yanında toplumun genel refahı için de önemli bir gereksinimdir. Altyapı inşaatları ile uzun vadede toplumun ihtiyaçlarını karşılayacak, sürdürülebilir ve güvenilir altyapılar inşa edilir ve böylece gelecek nesiller için yaşanabilir çevreler oluşturulur.

Altyapı hizmetlerinin sürekliliği ve güvenilirliği, modern toplumlar için kritik öneme sahiptir. İklim değişikliği, içme suyu ve atıksu altyapısının performansını ve dayanıklılığını etkileyerek, bu hizmetlerin sürekliliğine ve kalitesine doğrudan etkiler yapabilmektedir. Sıcaklık artışları, değişen yağış rejimleri, ani hava olayları, deniz seviyelerindeki yükselmeler ve iklim göçleri, su kaynaklarının sürdürülebilirliği, altyapı üzerinde ciddi bir risk oluşturmaktadır (Delpla vd., 2009; Wilbanks ve Fernandes, 2018).

Nüfus ve bir bölgenin gelişmişliği gibi sosyo-ekonomik parametreler, içmesuyu ile atıksu projeleri üzerinde çok yönlü önemli etkilere sahiptir. Nüfusun yoğunluğu ve demografik yapısı, altyapı projelerinin planlanması, tasarımı ve uygulanmasında belirleyici faktörler arasında yer alır. Ayrıca gelişmişlik düzeyi de bu projelerin içeriğini ve maliyetini belirler. Hem kentsel hem de kırsal alanlarda, altyapı projelerinin nüfus ve gelişmişlik

düzeyine uygun bir şekilde tasarlanması, su kaynaklarının sürdürülebilir yönetimi ve halk sağlığının korunması açısından büyük önem taşımaktadır (Jithish ve Sankaran, 2017).

Literatürde, içmesuyu ile ilgili çalışmalarda, makine öğrenmesi (ML) teknikleri kapsamında, yapay sinir ağları (YSA) ve diğer makine öğrenmesi algoritmaları (KNN, SVR, XGBoost, Random Forest vs.) kullanılarak çeşitli modeller geliştirilmiştir (Zhou vd., 2014; Ajbar vd., 2015; İbrahim vd., 2020; Yurtsever ve Emeç, 2023). Buna ek olarak, başta elektrik ve doğalgaz tüketimi olmak üzere enerji tüketimi tahmini konusunda da birçok çalışma gerçekleştirilmiştir (Kıran vd., 2012; Uzu vd., 2014; Metin ve Kaçtıoğlu, 2018).

Makine öğrenmesi (ML), veri ile öğrenme süreçlerini otomatikleştiren bir yapay zekâ dalıdır. Bu kapsamda, makine öğrenmesinin çeşitli algoritmalar arasında geniş bir uygulama alanına sahip olduğu bilinmektedir. Yapay Sinir Ağları (YSA) da makine öğrenmesinin bir alt kümesi olarak, biyolojik sinir ağlarından esinlenerek geliştirilen katmanlı bir modelleme yöntemidir (Bingöl vd., 2020). YSA, karmaşık ve doğrusal olmayan veri yapılarında etkili çözümler sunabilirken, yüksek hesaplama gücü ve büyük veri setlerine ihtiyaç duyması, bu yöntemin sınırlayıcı faktörlerinden biridir (Ajbar vd., 2015).

Diğer taraftan, YSA harici diğer makine öğrenme algoritmalarının çoğu, daha düşük hesap yüküyle çalışabilir ve geniş bir veri türü yelpazesinde uygulanabilir. Ancak doğrusal olmayan veri ilişkilerini yakalama yetenekleri, YSA kadar güçlü olmayabilir (Murphy, 2012). Bu farklar, modelleme sürecinde hangi makine öğrenmesi tekniklerinin kullanılacağına karar verilmeden önce, veri yapısının ve modelleme gereksinimlerinin dikkatle değerlendirilmesini zorunlu kılmaktadır.

Bu tez çalışmasında; iklim değişikliği ve sosyo-ekonomik değişkenlerin, altyapı projeleri üzerindeki etkilerinin (maliyet, metraj vs.) incelenmesi amaçlanmıştır. Bu amaç doğrultusunda, yapay zekâ destekli algoritmalar ve veri seti kullanılarak, girdi ve çıktılar arasında ilişkileri öğrenip tahmin yapabilen temsili matematiksel modeller oluşturulması hedeflenmiştir. Çalışmada, “Adana” ili seçilmiş olup bu il kapsamında iklim değişikliği ve sosyo-ekonomik değişkenlerin altyapı projeleri üzerindeki genel yansıması, makine öğrenme yöntemleri ile tahmin edilmiştir. Çalışmada, projelere etki eden parametrelerin katkısı araştırılarak, projeler üzerindeki yansıması irdelenmiştir. Tasarlanan bu modelin uygulanabilirliği ve doğruluğu için yapay zekâ destekli makine öğrenme yöntemlerinin modelleriyle karşılaştırma yapılmıştır. Yıllık bazda yapılan bu çalışmada, hangi parametrenin altyapı projeleri üzerinde ne derece etkisi olduğu ortaya konarak, kullanıcılara yol gösterici olması hedeflenmiştir.

Mevcut literatürdeki çalışmalar, genellikle su tüketimi ve enerji ihtiyacını tahmin etmeye yönelik modellere odaklanmıştır. Ancak, altyapı projeleri için dağıtım debisi, içmesuyu ve atıksu proje büyüklüklerinin (metrajı) tahminine yönelik, çalışma modellerine rastlanmamıştır. Bu çalışmada ise, bu boşluğu doldurmak amacıyla makine öğrenmesi algoritmaları kullanılarak iklim değişikliği ve sosyo-ekonomik değişkenlerin altyapı projeleri üzerindeki nitelikli etkileri, analiz edilerek altyapı proje büyüklüğü tahminleri yapılmıştır. Çalışmanın özgün değeri de buradan gelmekte ve literatüre bu alanda katkı sağlanmaktadır.

Bu çalışmanın amacı, makine öğrenmesi algoritmalarının sunmuş olduğu avantajlardan yararlanarak, ilgili altyapı projelerine ilişkin en uygun dağıtım debisi, içme suyu ve atık su proje büyüklüğü tahminlerinde kullanılabilecek modelleri geliştirmek ve bu modellerin etkinliğini değerlendirmektir. Çalışmada makine öğrenmesi kullanılmasının temel nedeni, altyapı projelerinin dinamik ve karmaşık yapısını, geleneksel yöntemlerle analiz etmenin sınırlılıklarını aşarak daha etkin ve doğru tahminler yapılmasını sağlamaktır.

Makine öğrenmesi algoritmaları, yalnızca mevcut verilerin analiziyle sınırlı kalmayıp, çeşitli senaryolar altında karar destek mekanizmalarına entegre edilebilmesi açısından da eşsiz bir avantaj sunmaktadır (Bishop, 2006). Çok boyutlu ve büyük veri setlerinde gizli örüntüleri ortaya çıkarma, doğrusal olmayan ilişkileri modelleme ve geleceğe yönelik öngörüler üretme konusunda üstün bir yeteneğe sahiptir (Raschka ve Mirjalili, 2017). Ayrıca, makine öğrenmesi yöntemleri, veriye dayalı karar verme süreçlerini destekleyerek, altyapı projelerinde iklim değişikliği ve sosyo-ekonomik parametrelerin etkilerinin daha hassas bir şekilde analiz edilmesini mümkün kılmaktadır.

Geleneksel istatistiksel yöntemler genellikle sabit varsayımlar (müstakbel nüfus vs.) üzerine kurulu olduğundan, karmaşık ilişkilerin veya değişkenler arası etkileşimlerin tamamını açıklamakta yetersiz kalabilmektedir. Buna karşın, makine öğrenmesi algoritmaları, hem geçmiş verilerden öğrenerek modellerin doğruluğunu artırmakta hem de yüksek doğruluklu tahminler üreterek karar alıcılara sağlam bir rehber sunmaktadır (Murphy, 2012). Bu nedenle, çalışmada makine öğrenmesi kullanılarak, altyapı projelerinin daha sürdürülebilir, verimli ve ekonomik hale getirilmesi için sağlam temellere dayalı, genellenebilir sonuçlar elde edilmesi hedeflenmiştir. Çalışma aynı zamanda, altyapı projelerinde iklim değişikliği ve sosyo-ekonomik faktörlerin uzun vadeli etkilerinin daha iyi anlaşılmasına yönelik sistematik bir model sunmayı amaçlamaktadır.

Bu amaç doğrultusunda, veri setindeki doğrusal ve doğrusal olmayan ilişkileri etkili bir şekilde modelleme kapasitesi ve tahmin performansı yüksek olan Ridge, Lasso, XGBoost ve Destek Vektör Regresyonu (SVR) algoritmaları kullanılmıştır. Bu algoritmalarla geliştirilen modellerin öğrenme kapasiteleri ve optimum çözüm bulma yetenekleri detaylı bir şekilde incelenmiştir. Kullanılan bu algoritmaların arama (öğrenme) yetenekleri, ortalama mutlak hata (MAE, Mean Absolute Error), ortalama hata kareleri toplamı kökü (RMSE, Root Mean Squared Error), R^2 (Determinasyon Katsayısı) ve NSE (Nash-Sutcliffe Verimlilik) katsayısı performans ölçütleri ile değerlendirilmiş, aynı zamanda elde edilen en uygun tahmin çözümlerinin kalitesi detaylı bir şekilde analiz edilmiştir.

Ayrıca, çok ölçütlü karar verme yöntemlerinden biri olan SWARA (Step Wise Weight Assessment Ratio Analysis) yöntemi, veri setindeki parametrelerin 30 kişilik uzman grubuyla gerçekleştirilen görüşmeler sonucunda anket yöntemiyle önceliklendirilmesi amacıyla kullanılmıştır. Bunun yanı sıra, Temel Bileşen Analizi (Principal Component Analysis, PCA) uygulanarak modelleme öncesinde veri setinin boyutu azaltılmış ve özellik seçimi gerçekleştirilmiştir.

Tez çalışması kapsamında, literatürde yaygın olarak kullanılan 16 parametre (içme suyu proje büyüklüğü, atıksu proje büyüklüğü, dağıtım debisi, yerleşim nüfusu, gayri safi yurtiçi hasıla (GSYH), abone sayısı, yapı ruhsatı sayısı, yapı kullanım izin (iskân) sayısı, tarım alanı, sıcaklık, buharlaşma miktarı, yağış miktarı, güneşlenme süresi, nispi nem, rüzgâr hızı, atmosfer basıncı) başlangıçta belirlenmiştir. Altyapı projeleri konusunda uzman kişilerle gerçekleştirilen görüşmeler sonucunda, çalışmanın iki aşamalı olarak yürütülmesinin daha verimli ve uygun olacağı kanaatine varılmıştır. Bu doğrultuda, dağıtım debisi birinci aşamada, içmesuyu ve atıksu proje büyüklükleri ise ikinci aşamada bağımlı (sonuç) değişkenler olarak belirlenmiştir.

3 bağımlı değişken (dağıtım debisi, içmesuyu ve atıksu proje büyüklüğü) belirlendikten sonra, geriye kalan 13 parametre bağımsız değişken adayı olarak seçilmiştir. Bu parametrelerin önceliklendirilmesi, SWARA yöntemi kullanılarak uzman görüşleri doğrultusunda, anket çalışmaları ile değerlendirilmiştir. Daha sonra, bu bağımsız değişkenler, boyut küçültme ve özellik seçimi amacıyla PCA yöntemiyle analiz edilmiştir. Yapılan analizler sonucunda, şehir gelişmişliği, yerleşim nüfusu ve kayıtlı abone sayısı en önemli üç parametre olarak belirlenmiş ve bu parametrelerin tahmin modellerinde kullanılması gerektiği tespit edilmiştir. Ayrıca, iklim değişikliği etkilerinin modelleme sürecinde güçlü bir şekilde temsil edilebilmesi amacıyla, sıcaklık, güneşlenme süresi, yağış

miktarı ve nem parametrelerinin birleşimiyle oluşturulan Aydeniz Kuraklık İndeksinin de tahmin modellerinde yer alması gerektiği belirlenmiştir.

Çalışmanın ilk aşamasında, şehir gelişmişliği, yerleşim nüfusu, kayıtlı abone sayısı ve Aydeniz Kuraklık İndeksi olmak üzere dört bağımsız değişken kullanılarak, içmesuyu dağıtım debisini tahmin etmeye yönelik makine öğrenmesi tabanlı algoritmalar uygulanmıştır. İkinci aşamada ise ilk aşamada en iyi performansı gösteren makine öğrenmesi algoritmaları kullanılarak, tahmini yapılan dağıtım debisi bağımsız değişken olarak değerlendirilmiş ve içmesuyu ile atıksu proje büyüklükleri (metrajları) bağımlı değişken olarak ele alınarak tahmin modelleri geliştirilmiştir.

Bu çalışma, altyapı projelerinin maliyet planlamasında ve uzun vadeli kaynak yönetiminde kullanılabilecek pratik ve uygulanabilir tahmin modelleri sunmaktadır. İklim değişikliği ve sosyo-ekonomik değişkenlerin maliyet üzerindeki etkilerini dikkate alarak, gelecekteki altyapı ihtiyaçlarına yönelik bütçeleme ve sürdürülebilir planlama süreçlerinde önemli bir referans oluşturmaktadır.

1.2. Tezin Amacı, Kapsamı ve Katkısı

Bu çalışmanın temel amacı, makine öğrenmesi algoritmalarının avantajlarından faydalanarak, iklim değişikliği ve sosyo-ekonomik değişkenlerin, altyapı projelerinin maliyet bileşenleri üzerindeki etkilerini incelemek üzere altyapı projeleri için en uygun dağıtım debisi, içmesuyu ve atıksu proje büyüklüğünü tahmin eden modeller oluşturmaktır. Bu doğrultuda, Ridge, Lasso, XGBoost ve Destek Vektör Regresyonu (SVR) gibi makine öğrenmesi algoritmaları kullanılarak, bu algoritmaların tahmin ve optimum sonuçları bulma yetenekleri incelenmiştir.

Çalışma kapsamında, sınırlı sayıda değişken ile altyapı projeleri üzerinde, modeller geliştirilmiştir. Bu modeller ile altyapı proje ihtiyaçları doğrultusunda gelecek yıllara ait bir tahmin algoritması geliştirilecek olup literatüre katkı sağlanacaktır. Çalışma, altyapı projelerine yönelik tahmin modelleri geliştirerek, makine öğrenmesi tekniklerinin potansiyelini araştırmayı kapsamaktadır. Çalışmada kullanılan veri seti, geçmiş yıllara ait altyapı parametrelerini içermektedir.

Bu tez çalışmasının literatüre temel katkısı, altyapı projelerinde uzun vadeli kaynak planlaması, maliyet tahmini ve sürdürülebilir yönetim süreçleri için yenilikçi bir model geliştirmesidir. Çalışmadan elde edilen bulgular, altyapı projelerinde daha verimli ve

sürdürülebilir yönetim uygulamalarının hayata geçirilmesine katkı sağlamakta ve karar alma süreçlerinin iyileştirilmesi ile desteklenmesi açısından önemli bir potansiyele sahiptir.

1.3. Araştırma Yöntemi

Bu çalışmada, makine öğrenmesi algoritmalarının iklim değişikliği ve sosyo-ekonomik değişkenlerin altyapı projeleri üzerindeki etkilerini incelemek ve söz konusu projelerde dağıtım debisi, içmesuyu ve atıksu proje büyüklüğü tahminlerini elde etmek amacıyla Ridge, Lasso, XGBoost ve Destek Vektör Regresyonuna (SVR) algoritmaları sahip oldukları özellikler nedeniyle modellemelerde tercih edilmiştir. Ridge ve Lasso, doğrusal regresyon modellerinde sırasıyla aşırı uyum sorununu önleme ve önemli değişkenleri seçme kapasiteleri ile öne çıkmaktadır. XGBoost, karar ağaçları tabanlı gradyan artırma yöntemi sayesinde doğrusal olmayan ilişkileri etkili bir şekilde modelleyebilmekte ve yüksek hesaplama performansı sunmaktadır. SVR ise kernel (çekirdek) fonksiyonları ile doğrusal olmayan ilişkileri yüksek boyutlarda modelleme yeteneği sayesinde karmaşık ilişkileri başarılı bir şekilde tahmin etmektedir. Bu algoritmalar, altyapı projelerinde iklim değişikliği ve sosyo-ekonomik değişkenlerin etkilerini doğru ve genelleştirilebilir bir şekilde analiz edebilmek için uygun görülmüştür.

Tez çalışması kapsamında, 16 adet iklim değişikliği ve sosyo-ekonomik parametreler, başlangıçta belirlenmiştir. Oluşturulacak modellerde uzmanlarla yapılan görüşmeler neticesinde; dağıtım debisi ve proje büyüklüğü hedef (bağımlı) değişken olarak, iklim değişikliği (sıcaklık, yağış miktarı, nem, buharlaşma, rüzgâr hızı, güneşlenme süresi ve atmosfer basıncı) ve sosyo-ekonomik (nüfus, bina ruhsat ve kullanıcı sayıları, gelişmişlik, tarım alanı) parametreler girdi (bağımsız) parametre olarak dikkate alınmıştır.

Çalışmanın ilk aşamasını oluşturan dağıtım debisi bağımlı değişkeninin tahmin sürecinde, belirlenen 13 bağımsız parametre, SWARA ve Temel Bileşen Analizi (PCA) yöntemleri ile değerlendirilmiştir. Yapılan analizler sonucunda, şehir gelişmişliği, yerleşim nüfusu ve kayıtlı abone sayısı parametrelerinin ilk aşamadaki tahmin modellerinde kullanılması gerektiği tespit edilmiştir. Ayrıca, iklim değişikliği etkilerinin modelleme sürecinde temsil edilebilmesi amacıyla, sıcaklık, güneşlenme süresi, yağış miktarı ve nem parametrelerinin birleşimiyle oluşturulan Aydeniz Kuraklık İndeksi'nin (K_{ks}) de tahmin modellerine dahil edilmesi gerektiği belirlenmiştir. K_{ks} , belirli bir bölgedeki meteorolojik kuraklık durumunu değerlendirmek üzere meteorolojik verilere dayalı olarak hesaplanan bir

gösterge olup, kuraklık şiddetinin sınıflandırılmasında kullanılmaktadır (MGM, 2016). Çalışmanın ikinci aşamasında ise, ilk aşamada tahmini yapılan dağıtım debisi bağımsız değişken olarak ele alınmış ve içmesuyu ile atıksu proje büyüklüklerinin tahmin edilmesine yönelik modeller geliştirilmiştir.

Kurulan makine öğrenmesi modellerinin; performansını değerlendirmek, modellerin genelleme yeteneği ve eğitim-test süreçlerini optimize etmek ve modelin verilere aşırı uyumundan korumak için çapraz doğrulama ve test ayırma yöntemleri kullanılmıştır.

Elde edilen sonuçlar, her bir modelin performansını karşılaştırmak ve en iyi tahmin çözümlerini belirlemek için analiz edilmiştir. Modellerin MAE, RMSE, R^2 ve NSE değerlerine göre sıralamaları yapılmış ve elde edilen tahminlerin altyapı projeleri için en uygun çözüm olup olmadığı değerlendirilmiştir. Son olarak, farklı modellerin avantajları ve dezavantajları tartışılmış ve gelecekteki çalışmalar için önerilerde bulunulmuştur.

Yukarıda bahsedilen işlemlerin ayrı ayrı uygulanması sayesinde, altyapı projeleri için en uygun dağıtım debisi, içmesuyu ve atıksu proje büyüklüğünü tahmin etmek amacıyla kullanılan ML algoritmalarının etkili bir şekilde değerlendirilmesi sağlanmıştır.

1.4. Literatür Taraması

Tez çalışması kapsamında ulusal ve uluslararası düzeyde yapılan araştırmalar detaylı bir şekilde incelenmiştir. Yapılan çalışmalar, su ve enerji talebinin tahmini, altyapı projelerinin sürdürülebilirlik ve dayanıklılık analizleri, mevcut altyapıların durum değerlendirmesi ve iklim değişikliğinin altyapılar üzerindeki etkileri gibi başlıklara odaklanmıştır. Araştırmalarda geniş bir yelpazede, yapay zekâ, optimizasyon teknikleri ve çok ölçütlü karar verme yöntemleri kullanılmıştır. Özellikle Yapay Sinir Ağları (ANN), Destek Vektör Regresyonu (SVR), Rastgele Orman (RF), XGBoost gibi makine öğrenimi algoritmaları; Parçacık Sürü Optimizasyonu (PSO), Karınca Kolonisi Optimizasyonu (ACO) ve Genetik Algoritma (GA) gibi meta-sezgisel teknikler ile Temel Bileşen Analizi (PCA) gibi veri indirgeme yöntemleri öne çıkmaktadır.

1.4.1. Ulusal Düzeyde Yapılan Çalışmalar

Kıran vd., (2012), Türkiye'nin enerji talebini tahmin etmek için hem Parçacık Sürü Optimizasyonu (PSO) hem de Karınca kolonisi optimizasyonu (ACO) yöntemlerini

birleştiren yeni bir karma yaklaşım (HAP) ortaya koymuştur. Önerilen enerji talebi modeli, PSO ve ACO gibi meta-sezgisel yöntemleri birleştirerek enerji talebini tahmin etmek için kullanılmaktadır. Bu yöntem, tahmin için gayri safi yurt içi hasıla (GSYH), nüfus verileri, ithalat ve ihracat istatistikleri gibi girdileri kullanmaktadır. HAPE (hybrid approach), hem doğrusal ve ham kare olarak iki varyasyon halinde formüle edilmiştir. Elde edilen sonuçlara göre, HAPE modeli en düşük göreceli tahmin hatalarını sergilemektedir ve sosyo-ekonomik göstergelerde gözlenen varyasyonlar nedeniyle kare versiyonu daha doğru çözümler sunmaktadır.

Uzlu vd. (2014), demografik ve sosyo-ekonomik faktörleri temel alarak Türkiye'deki enerji tüketimini tahmin etmeye odaklanan bir model geliştirmiştir. Temel amaç, Türkiye'nin enerji kullanımını tahmin etmek için yenilikçi bir yöntem sunmaktır. Çalışma, Öğretme-Öğrenme Tabanlı Optimizasyon (TLBO) meta-sezgisel algoritmayı kullanarak Yapay Sinir Ağı (ANN) tekniklerinin uygulanmasıyla gerçekleştirilmektedir. Model, Türkiye'nin gayri safi yurtiçi hasılası (GSYH), nüfus rakamları, ithalat ve ihracat gibi girdiler kullanılarak oluşturulmuştur. Türkiye'deki gelecekteki enerji tüketim seviyelerini projelendirmek için üç farklı senaryo kullanılmaktadır. Bulgular, enerji tüketimini tahmin etme konusunda ANN-TLBO modellerinin ANN-BP modellerinden daha iyi performans gösterdiğini göstermektedir.

Nacar vd. (2014), 1998'den 2000'e kadar doğu Karadeniz Havzası'ndaki Haldizen Deresi'nden günlük akış ölçümleri kullanarak geliştirilen modelleri oluşturmak ve değerlendirmek amacıyla bir araştırma sunmuşlardır. Çalışma, akış tahmini için şu modelleri: İleri beslemeli geri yayımlı Çok Katmanlı Yapay Sinir Ağı (ÇK-YSA), Temel Bileşen Analizli Sinir Ağı (TBA-NN) ve Zaman Gecikmeli Öz Yineli Yapay Sinir Ağları (ZGA-YSA) kullanmaktadır. Modellerin performansı çeşitli kriterlerle değerlendirilir, böylece karşılaştırma yapılabilir ve en uygun modeller, en iyi uyum temel alınarak belirlenmektedir.

Safavi vd. (2017), karma tam sayılı lineer programlama kullanarak kanalizasyon ağlarının optimizasyonu üzerine bir çalışma yapmışlardır. Bu araştırmanın temel amacı, kanalizasyon ağını optimize etmek için etkili, güvenilir ve kullanıcı dostu bir yaklaşımı tanıtmaktır. Tüm kısıtlamalar ve hedef, lineer ifadelerle formüle edilmiştir. Daha sonra bu denklemler, kesin bir matematiksel teknik aracılığıyla çözülebilmesini sağlayan Karma Tamsayılı Lineer Programlama (KTLP) modelini oluşturmak için kullanılmıştır. Meta-

heuristik algoritmaların aksine, bu yöntem küresel olarak optimal bir çözümü garanti etmektedir.

Cengiz vd. (2017), duvar ve çatı uygulamalarında kullanılan inşaat malzemeleri için tedarikçi seçimi analizine odaklı kapsamlı bir model geliştirmeyi amaçlamışlardır. Çalışma metodolojisi, ilgili tedarikçi seçimi kriterlerini belirlemek için kapsamlı bir literatür taraması ve uzman paneli tartışmalarını içermektedir. Her bir kritere atanmış ağırlıkları belirlemek için kapsamlı bir anket çalışması yapılmış olup bu ankete inşaat sektöründen, üniversitelerden ve devlet kurumlarından katılımcılar dahil edilmiştir. Araştırmacılar, inşaat malzemeleri alanında tedarikçi seçimine yeni bir yaklaşım sunarak literatüre önemli bir katkı sağlamaktadır. Çalışmada geliştirilen model, inşaat projesi paydaşlarına projenin tüm yaşam döngüsü boyunca karar destek sağlama potansiyeline sahiptir.

Metin ve Kaçtıoğlu (2018), Türkiye örneğinde yapay sinir ağlarını kullanarak güç tüketimi tahmini üzerinde çalışmışlardır. Bir gelişmekte olan ülke olarak Türkiye, enerji talebinin artışı açısından önde gelen ülkelerden biridir. Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre, Türkiye, 2000 yılından bu yana elektrik ve doğalgaz tüketiminde Çin'den sonra en büyük artışı yaşayan ülke konumundadır. 1970 yılında Türkiye'de toplam enerji üretiminin tüketime oranı %76 idi. 2000 yılında bu oran %35'e düşerek, 2010 yılında %26'ya ve tahminlere göre 2020 yılında %23'e düşmesi beklenmiştir.

Başakın vd. (2019), kuraklık oluşumlarını öngörmek için çeşitli kuraklık endekslerinin kullanıldığı bir çalışma sunmuştur. Kuraklık seviyelerindeki dalgalanmaları önceden tahmin etmek için kapsamlı bir araştırma yapılmıştır. Bu araştırma, Kayseri ilinin 116 yıllık Palmer Kuraklık Şiddet İndeksi (PDSI) verilerini modellemek için makine öğrenme tekniklerini kullanmaya odaklanmıştır ve yaklaşan PDSI değerlerini tahmin etmeyi amaçlamıştır. Çalışma özellikle bir, üç ve altı aylık dönemler için kuraklık değerlerini öngörmektedir. Bu tahminler, destek vektör makineleri (SVM) ve K-en yakın komşular (KNN) algoritmaları kullanılarak üretilen ve istatistiksel değerlendirme yoluyla değerlendirilmiştir. Bu araştırmanın bulguları, hidrolojik zorlukları ele almak için makine öğrenme yaklaşımlarının önemli katkısını vurgulamaktadır.

Şahinarslan (2019), tez çalışmasında altı farklı makine öğrenme algoritmasının kullanıldığı bir inceleme yapmıştır. Hafif Gradient Artırma, Doğrusal Regresyon, Ridge Regresyon, Holt-Winters, Üssel Otoregresif Entegre Hareketli Ortalama (ARIMA) ve Prophet Tahmin modeli içermektedir. Çalışma, 1960 ila 2017 yıllarını kapsayan 262 farklı ülkenin 1595 demografik göstergeyi içeren bir veri kümesini kullanmaktadır. Bu veri

noktaları, dünya bankası tarafından sağlanan küresel olarak dağıtılan demografik göstergelerden elde edilmiştir. Bulgular, makine öğrenme algoritmalarının demografik modele göre üstün performans sergilediğini ortaya koymuştur. Sonuç olarak, makine öğrenme algoritmalarının nüfus tahmin süreçlerine entegre edilmesinin, ülkeler için önemli faydalar sunma potansiyeline sahip olduğu ve karar verme sürecini iyileştirerek önemli pozitif etkiler yaratabileceği görülmektedir.

Gündüz ve Saleh (2020), dünya genelinde spor projelerinin teslimatı üzerinde önemli bir etkiye sahip olan temel gecikme faktörlerini tanımlamak ve değerlendirmek amacıyla bir çalışma sunmuşlardır. Önceki literatürün kapsamlı bir incelemesi ve teknik uzmanlarla birebir görüşmeler yaparak, 37 gecikme özelliğini içeren kapsamlı bir liste derlenmiştir. Bu faktörler daha sonra sekiz farklı gruba kategorize edilmiştir. Çevrimiçi bir anket portalı, spor tesisleri profesyonellerine anketi dağıtmak için kullanılmış ve 101 tamamlanmış yanıt elde edilmiştir. Toplanan veriler, İlgili Önem Endeksi, Spearman'ın Sıra Korelasyonu, T-Testi ve Analitik Hiyerarşi Süreci (AHP) dahil çeşitli sıralama yaklaşımları ve çok kriterli karar verme yöntemleri kullanılarak analiz edilmiştir. AHP analizi, danışman deneyiminin düşük olması, müteahhit deneyiminin düşük olması, inşaat malzemelerinin eksikliği ve müteahhit tarafından projenin finansmanında yaşanan zorluklar gibi faktörlerin en kritik gecikme faktörleri olarak tanımlandığını ortaya koymuştur.

Turgut vd. (2020), sıcaklık, nem, rüzgâr hızı ve rüzgar yönü gibi bir dizi sensörün ve bir mikrodenetleyicinin kullanıldığı bir ağ kullanarak kapsamlı bir analiz gerçekleştirmiştir. Bu sistem, verilerin gerçek zamanlı olarak toplanmasını ve kaydedilmesini sağlamaktadır. Kaydedilen veriler, mikrodenetleyiciye bağlı bir Ethernet modülü aracılığıyla sorunsuz bir şekilde bir veri tabanına iletilerek veri transferinin verimli ve doğru olmasını sağlamıştır. Bu araştırmanın temel amacı, sistemden gelen nem, rüzgâr yönü ve rüzgâr şiddeti gibi giriş parametrelerini kullanarak özellikle hava sıcaklığı gibi çıkış parametresini tahmin etmektedir.

Kurt vd (2020), bir ağ trafiği veri kümesi üzerinde XGBoost ve Random Forest makine öğrenme algoritmalarının sınıflandırma yeteneklerini araştırmayı amaçlayan bir çalışma gerçekleştirdi. Çalışmada genellikle algoritmik uygulamalarda ve sızma tespit sistemlerinde kullanılan yaygın "KDD'99" eğitim ve test veri kümesi kullanılmıştır. Araştırma sonuçları, saldırı ve normal örnekler arasındaki ikili sınıflandırma yoluyla sunulmuştur. Sonuçlar özenle analiz edilerek yorumlanmıştır. Çalışmanın, analiz edilen algoritmaların sızma tespit

sistemleri alanında etkili bir şekilde kullanılmasına yönelik önemli bir başvuru noktası oluşturduğu sonucuna varılmıştır.

İbrahim vd. (2020), su talebinin tahmini için makine öğrenimi ve zaman serisi algoritmalarını kullanmışlardır. Çalışma, su dağıtım ağlarının genellikle anlık taleplere dayalı olarak çalıştığını, bu nedenle depolama, işleme ve dağıtım maliyetlerini artırdığını vurgulamaktadır. Gelecekteki talebi tahmin etmeye odaklanan bir su yönetimi stratejisinin geliştirilmesi, bu maliyetlerin azaltılmasına ve operasyonların verimliliğinin artırılmasına katkı sağlamaktadır. Çalışmada, Doğrusal Regresyon (LR), Otoresif Entegre Hareketli Ortalama (ARIMA) ve Destek Vektör Regresyonu (SVR) gibi yöntemler kullanılmıştır. ARIMA modeli, doğruluğu artırmak için geçmiş verilerden sezonsal etkileri ve trendlere dayalı öngörüler yapmıştır. Destek Vektör Regresyonu (SVR) ise özellikle doğrusal olmayan verilere daha iyi uyum sağlayarak üstün performans göstermiştir. Modellerin performans ölçümleri kapsamında Ortalama Mutlak Hata (MAE) ve Ortalama Kare Hata (MSE) değerleri incelenmiş ve en iyi sonuçlar SVR ile elde edilmiştir. SVR modeli ile tahmin doğruluğu %92'ye kadar çıkmış, ARIMA modeli ise %85 doğrulukla ikinci sırada yer almıştır. Çalışma sonucunda, tahmin tabanlı bir su yönetimi yaklaşımının, su talebindeki dalgalanmaları etkin bir şekilde öngörerek operasyonel maliyetleri %15 oranında azaltabileceği ve daha sürdürülebilir bir altyapı yönetimi sağlayabileceği ifade edilmiştir.

Bayrakçı vd. (2021), su tüketimi verilerine dayalı bir veri kümesi oluşturmayı amaçlayan bir araştırma üzerinde çalışmıştır. Bu veriler, il, ilçe ve bitki türü gibi faktörler göz önünde bulundurularak örnek bölgelerden elde edilmiş ve bu bilgiler açık erişimli web sitelerinden toplanmıştır. Daha sonra çeşitli yapay zekâ algoritmaları, su tüketim miktarını tahmin etmek için kullanılmıştır. En kesin yapay zekâ modeli için bir kullanıcı arayüzü programı geliştirilmiştir ve kullanıcı girdi değerlerine dayalı olarak kesin su tüketimi tahminlerini hesaplayan ve sunan bir sistem oluşturulmuştur.

Babacan ve Saka (2022), çalışmada, gelecekteki tahmini deşarj değerleri, sel koruma tesisleri, hidroelektrik enerji santralleri ve arıtma tesisleri gibi yapıların tasarım aşamasında kullanılan olasılıklara dayalı olarak değerlendirerek ve tasarım akış hızını belirlemek için kullanılmıştır. Akış modeli oluşturmak için yapay sinir ağları (YSA) ve klasik regresyon (KR) yöntemleri tercih edilmiştir. Buhar basıncı, yağış ve tarihsel akış verilerini kullanarak, 14 farklı giriş modeli oluşturulmuştur. Bu giriş modelleri, Multi-Katmanlı Algılayıcı (MLP) yöntemi kullanılarak oluşturulan akış tahmin modeli ile test edilmiştir. Sonuç olarak, KR yönteminde makine öğrenimi kullanan modeller gibi, gecikmeli giriş setlerinin

kullanılmasının KR yönteminde performansı artırdığı, MLP yönteminin bölgedeki akış tahmin modelleme konusunda KR yöntemini geride bıraktığı ve tasarım akış hızını belirleme konusundaki uygunluğunun kanıtlandığı sonucuna varılmıştır.

Ağbulut (2022), Türkiye'nin 2050 yılına kadar olan taşımacılık sektöründen kaynaklanan enerji talebi ve CO₂ emisyonlarını tahmin etmeye odaklanan bir çalışma önermiştir. Çalışmada, Türkiye'deki taşımacılıkla ilişkilendirilen CO₂ emisyonlarını ve enerji talebini tahmin etmek için derin öğrenme (DL), destek vektör makinesi (SVM) ve yapay sinir ağı (ANN) gibi üç farklı makine öğrenme algoritması kullanılmıştır. Yapılan çalışmada kullanılan bağımsız değişken (girdi) parametreleri arasında, kişi başına düşen gayri safi yurt içi hasıla (GSYH), nüfus rakamları, araç kilometreleri ve ilgili yıl bulunmaktadır. Tahminlerin sonuçları, Türkiye'deki taşımacılıkla ilişkilendirilen enerji talebi ve CO₂ emisyonları için birleşik yıllık büyüme oranının sırasıyla %3,7 ve %3,65 olacağını göstermektedir. Hem enerji talebi hem de taşımacılık sektöründen kaynaklanan CO₂ emisyonları, 2050 yılına kadar mevcut seviyelerine kıyasla neredeyse 3,4 kat artması beklenmektedir.

Bayram ve Çıtakoğlu (2023), Türkiye'deki uzun dönemli aylık referans evapotranspirasyon (ET₀) tahmini için üç farklı makine öğrenme yöntemi incelenmiştir. Araştırmada, 163 meteoroloji istasyonundan elde edilen aylık güneş radyasyonu (Rs), maksimum hava sıcaklığı (T_{max}) ve rüzgâr hızı (Ws) verileri kullanılmıştır. Farklı veri kombinasyonları oluşturularak analiz edilmiş ve modellerin performansı Nash–Sutcliffe verimliliği, Kling-Gupta verimliliği, göreceli kök ortalama kare hatası, ortalama mutlak yüzde hatası ve determinasyon katsayısı gibi kriterlerle değerlendirilmiştir. Sonuçlar, MGGP modelinin diğer iki modele kıyasla daha üstün performans sergilediğini göstermiştir. Ayrıca, Rs'nin ET₀ tahmini için en etkili değişken olduğu, Ws'nin ise en az etkili değişken olduğu belirlenmiştir.

Yurtsever ve Emeç (2023), içme suyu kalitesinin hızlı ve doğru bir şekilde tahmin edilmesi amacıyla yapay zeka ve makine öğrenimi algoritmalarını kullanmışlardır. Çalışma, küresel iklim değişikliği, sanayileşme ve kentleşmenin mevcut su kaynakları üzerindeki olumsuz etkilerini ele alarak, içme suyu kalitesinin geleneksel yöntemlerden daha verimli bir şekilde tahmin edilebileceğini göstermiştir. Araştırmada, Kaggle'dan elde edilen bir veri seti kullanılmış ve eksik veri noktaları geleneksel yöntemler (ortalama doldurma, çıkarma) ve regresyon yöntemleri ile tamamlanmıştır. Tahmin modelleri için Rastgele Orman (RF), Adaboost, XGBoost algoritmaları uygulanmış, hiperparametre optimizasyonu için

Gridsearch ve Randomsearch yöntemleri kullanılmıştır. En yüksek doğruluk ve F1-skora sahip model, Destek Vektör Regresyonu (SVR) ve XGBoost kombinasyonu ile oluşturulan SXH (SVR-XGBoost Hybrid) yöntemi olmuştur. Bu model, %99,4 doğruluk ve F1-skor ile diğer modellere üstünlük sağlamıştır. Çalışma sonucu, içme suyu kalitesinin izlenmesi ve sürdürülebilir yönetimi için hibrit makine öğrenimi yöntemlerinin yenilikçi bir perspektif sunduğunu göstermektedir.

1.4.2. Uluslararası Düzeyde Yapılan Çalışmalar

Hassan ve Tarek (2008), altyapı yönetimi ile ilgili bir çalışma sunmuşlardır: belediye su ana hatlarının performansını değerlendirmek için entegre Analitik Hiyerarşi Süreci (AHP) ve Yapay Sinir Ağları (YSA) modeli kullanılmıştır. Araştırmacıların amacı, su boru hatlarının durumunu değerlendirmek ve etkinliğini öngörmek için dayanıklı bir model oluşturmaktır. Dahası, AHP/YSA modelini birleştirerek oluşturulan bir web tabanlı altyapı yönetimi aracı olan CR-Predictor, su ana hatlarının durumunu otomatik ve kullanıcı dostu bir şekilde değerlendirmek için geliştirilmiştir. Geliştirilen modellerin ve aracın etkinliği doğrulanmış ve ortalama geçerlilik yüzdesi olarak %98,51 gibi güçlü sonuçlar gösterilmiştir.

Chine vd. (2009), bir rezervuardaki su kalitesini tahmin etmek için Yapay Sinir Ağları (ANN) yöntemlerini kullanmışlardır. Çalışma, su kalitesini etkileyen faktörlerin analizini yaparak bu faktörlere dayalı olarak su kalitesini tahmin etmek için bir model geliştirmeyi hedeflemiştir. Su sıcaklığı, pH, çözülmüş oksijen ve bulanıklık gibi su kalitesi parametreleri, modelin girdisi olarak kullanılmıştır. Su kalitesi tahmin modelleri geliştirilirken, farklı yapay sinir ağı yapıları test edilmiş ve doğruluk oranları karşılaştırılmıştır. Araştırmada, ANN tabanlı modellerin su kalitesini gerçek zamanlı olarak tahmin etmede yüksek doğruluk ve güvenilirlik sunduğu bulunmuştur. Ayrıca, bu tür modellerin, rezervuar yönetimi için kritik öneme sahip olan erken uyarı sistemleri ve karar destek araçları geliştirilmesine yardımcı olabileceği belirtilmiştir. Çalışma sonucunda, ANN tabanlı yaklaşımların su kalitesi izleme ve yönetiminde güçlü bir araç olduğu vurgulanmıştır.

Jeuland (2010), su kaynakları altyapı planlamasına iklim değişikliğinin etkilerini dahil eden kapsamlı bir hidro ekonomik modelleme yaklaşımı geliştirmiştir. Daha sonra bu yaklaşım, Etiyopya'daki Mavi Nil boyunca potansiyel hidroelektrik projesinin iki farklı boyutunu değerlendirmek için uygulanmıştır. Önerilen yaklaşım, su kaynakları projesi değerlendirmesi alanındaki mevcut literatüre iki önemli katkıda bulunmaktadır. İlk olarak,

geleneksel hidrolojik modelleme tekniklerinin, planlama sürecinde bulunan ekonomik belirsizlikleri hesaba katmak için Monte Carlo simülasyonunun dahil edilmesiyle nasıl geliştirilebileceğini göstermektedir. İkincisi, analistlerin iklim değişikliği, hidroloji ve ekonomik üretim bağlantılarını geleneksel planlama modelleri içinde nasıl entegre edebileceğini göstermekte ve bu durumda gelecekteki koşullarla ilişkilendirilen karmaşıklıklar ve önemli belirsizliklerin daha iyi anlaşılmasını sağlamaktadır.

Xia vd. (2011), belediye su temin ağının durumunu tahmin etmeyi amaçlayan çalışmalarında, geri yayılım (Backpropagation, BP) sinir ağı ve genetik algoritma tabanlı bir yaklaşım sunmuşlardır. Yerel minimumlara düşmeyi önleyebilecek şekilde eğitim hızını artırmak amacıyla BP sinir ağının başlangıç ağırlıklarını optimize etmek için GA uygulanmıştır. Sonuçlara göre, mutlak değeri yüzde 5'ten az olan göreceli hata olan örnekler toplamın yaklaşık %85'ini oluşturmakta, bu da modelin uygulanabilirliğini göstermektedir.

Oslakovic vd. (2012), iklim değişikliğinin altyapı performansı üzerindeki etkilerini detaylandırarak, bu değişimlere bağlı olarak altyapı yöneticilerinin karşılaştığı sorunlara odaklanmıştır. Çalışma kapsamında, Hollanda'daki iki demiryolu hattının altyapı performansı ile iklimsel değişkenler arasındaki ilişkiler incelenmiştir. Özellikle iklim değişikliğinin altyapı üzerindeki etkilerinin coğrafi konuma ve mevsimlere göre farklılık göstermesi, altyapı performans değerlendirmelerinde daha ayrıntılı analizlere ihtiyaç olduğunu ortaya koymaktadır. Çalışmada, yaz aylarında aşırı sıcaklıkların ray deformasyonlarına neden olabileceğini ve demiryolu ulaşımında gecikmelere yol açabileceğini göstermiştir. Aynı zamanda, yüksek sıcaklıkların altyapı bakım maliyetlerini artırdığı belirtilmiştir. Kış aylarında ise yoğun kar yağışı ve buzlanma, demiryolu trafiğini aksatan önemli faktörler olarak tanımlanmıştır. Özellikle soğuk hava koşullarında altyapının dayanıklılığı üzerinde daha büyük bir stres olduğu ve bu durumun performans düşüşlerine yol açtığı tespit edilmiştir. Çalışma sonucunda, altyapı yöneticilerine, farklı iklim koşullarının etkilerini öngörme ve buna yönelik stratejik önlemler geliştirme konusunda önemli bir yol haritası sunulmaktadır.

Porthin vd (2013), Batı Finlandiya'daki Pori şehrinden geçen Kokemaki Nehri'nin sel korumasına odaklanan bir vaka çalışması sunan bir makale üzerinde çalışmışlardır. Çalışma, bölgeden önemli paydaşların katıldığı Çok Ölçütlü Karar Verme (ÇÖKV) analizi kullanmıştır. Bu analiz aracılığıyla değerlendirilen sel koruma alternatiflerinin güvenilir bir sıralaması oluşturulmuştur. Paydaşlara göre, bu yaklaşım, sel koruma önlemlerini keşfetmeyi kolaylaştırdığı ve paylaşılan bir anlayışın oluşturulmasına yardımcı olduğu için

değerli bulunmuştur. Çalışma, ÇÖKV'nin iklim değişikliği tarafından şiddetlenen aşırı olaylara uyum bağlamında karar verme için oldukça uygulanabilir olduğunu göstermiştir.

Belayneh ve Adamowski (2013), çalışmalarında standartlaştırılmış yağış indeksi (SPI) kullanmışlardır. İlgili araştırmada yapay sinir ağı (ANN), destek vektör regresyonu (SVR) ve dalgalet analizi (WA) modeller oluşturmak için kullanılmıştır. Üç yöntemin tahmin sonuçları, iki performans ölçütü (RMSE ve R²) kullanılarak karşılaştırılmıştır. Çalışmanın bulguları, dalgalet-ANN (WA-ANN) modellerinin standart modeli aştığını göstermiştir; SPI değerlerini altı ay önceden tahmin etmek için CE değeri 0.67'ye kıyasla 0.79 CE'ye sahiptir. Araştırmacılar, dalgalet-ANN (WA-ANN) modelini SPI 3 (3 aylık SPI) ve SPI 6 (6 aylık SPI) değerlerini tahmin etmek için en doğru model olarak tanımlamışlardır.

Manyeruke vd. (2013), iklim değişikliği ve iklim değişkenliğinin Zimbabwe'deki gıda güvenliği üzerindeki yaygın etkilerini analiz etmişlerdir. İklim değişikliği, Afrika'daki gelişmekte olan ülkelerin gıda güvenliğini ciddi şekilde tehdit etmekte ve bu ülkelerin açlığı önlemek için yabancı yardımlara bağımlı hale gelmesine neden olmaktadır. Çalışma, Zimbabwe'deki yağış düzenlerinin değişmesi, sıcaklıkların artması ve daha sık meydana gelen aşırı hava olaylarının tarım sektörüne ve gıda üretimine olumsuz etkilerini vurgulamaktadır. Dönemsel kuraklıkların mahsul ve hayvancılığı ciddi şekilde etkilediği ve bu durumun ülkenin agroekolojik bölgelerinde değişimlere yol açtığı belirtilmiştir. Ayrıca, hükümetin kuraklıkla mücadele önlemleri, çiftçilerin verimliliğini artırmaya yönelik destek programları ve tarımsal üretimin ölçeğini büyütme girişimleri incelenmiştir. Araştırmacılar, gıda ve su kaynaklarının azalmasının toplumsal huzursuzlukları artırabileceği ve ülkenin siyasi dengelerinde değişimlere neden olabileceğine dikkat çekmektedir.

Zhou vd. (2014), Shenyang Şehri'nde su talebinin tahmini amacıyla, Geri Yayılım (Backpropagation, BP) Sinir Ağları temel alınarak bir çalışma gerçekleştirilmiştir. Çalışma kapsamında, bağımsız değişkenlerin seçilmesi ve modelin tahmin doğruluğunu artırmak amacıyla Temel Bileşen Analizi (Principal Component Analysis, PCA) yöntemi de algoritmaya entegre edilmiştir. Çalışma, 2000 ile 2011 yılları arasındaki Shenyang Şehri'ndeki su talebi verilerini kullanmıştır, bu şehir Çin'in Liaoning Eyaleti'nde bulunmaktadır. Araştırma, temel bileşen analizi aracılığıyla su kaynaklarını etkileyen temel faktörleri belirlemeyi amaçlamaktadır. Ülke genelinde endeks kota yöntemi yaygın olarak kullanılsa da su talebini tahmin etme gibi zorluklar gibi engellerle karşı karşıya kalmaktadır. Shenyang Şehri'nin su gereksinimlerini daha iyi anlamak amacıyla gerçekleştirilen araştırmada, su talebinin tahmini için iki farklı yöntem kullanılmıştır.

Daniel vd. (2014), inşaat sektöründe karar verme alanındaki 22 farklı yöntemin kapsamlı bir gözden geçirmesini yapmışlardır. Bu yöntemler, uygulama alanlarına göre 11 kümeye ayrılmıştır. Çalışma, en dikkat çekici yöntemlerin kısa bir tartışmasını sunar ve onların temel güçlüklerini ve sınırlamalarını vurgulamaktadır. Ayrıca, araştırma süreci sırasında toplanan veriler istatistiksel analize tabi tutulmuştur. Bu analiz, inşaat sektöründe bu karar verme tekniklerinin benimsenmesi ve kullanılmasıyla ilgili eğilimleri belirlemeyi amaçlamaktadır. Farklı yöntemlerin uygunluğunu ve avantajlarını vurgularken sınırlamalarını da kabul ederek farklı senaryolar için en uygun teknikleri seçme konusunda karar vericilere ve araştırmacılara rehberlik ve gelişmiş karar verme sonuçları için birden fazla yöntemin entegrasyonunu teşvik edebilmektedir.

Chinowsky vd. (2015), Malavi, Mozambik ve Zambiya'daki yol altyapısına iklim değişikliğinin etkisine odaklanan bir çalışma sunmuşlardır. Bir stresör-yanıt yaklaşımı kullanarak, araştırma bu ülkelerde yağış, sıcaklık ve sel gibi tahmini değişikliklerin hem asfaltlı hem de asfalt olmayan yolları nasıl etkileyebileceğini değerlendirmiştir. Çalışma, 2010'dan 2050'ye kadar uzanan dönemi kapsayan her tür yol ve politika seçeneği için 425 iklim senaryosunu çalıştırarak kapsamlı bir analiz gerçekleştirmiştir. Bulgular, üç Güney Afrika ülkesinin, iklim değişikliği potansiyeline bağlı olarak 2050'ye kadar yol bakımı ve onarımları için ortalama iklim senaryolarına dayalı olarak yaklaşık 596 milyon dolarlık önemli bir mali yük ile karşılaşabileceğini göstermektedir. Ancak, iklim değişikliği modellemesindeki belirsizlikler göz önüne alındığında, politika yapıcılarının ülkelerinin karşılaşabileceği potansiyel riskleri doğru bir şekilde tahmin etme zorluğuyla yüzleşmektedir.

Haghighi ve Bakhshipour (2015), kanalizasyon toplama ağlarının tasarımı için deterministik bir entegre optimizasyon modeli geliştirmişlerdir. Model, ağ tasarımını optimize etmek için tabu arama (TS) yöntemini kullanmıştır. Çalışmada, ağ düzeni döngü kesme algoritması ile belirlenmiş ve bu düzen üzerinden kanal çapları, yerleştirme derinlikleri ve pompa özellikleri gibi parametreler hidrolik tasarım yoluyla optimize edilmiştir. Model, inşaat maliyetlerini minimize etmeyi amaçlayan bir hedef fonksiyona dayalı olarak çalışmakta olup tüm teknik kısıtlamaları ve kriterleri sistematik olarak sağlamaktadır. Tabu arama algoritması, karar alanında uyarlanabilir bir şekilde hareket ederek düzen oluşturma ve kanal boyutlandırma alt problemlerini eş zamanlı olarak çözmektedir. Çalışma sonucunda, kurulan modelin, bir örnek çalışma üzerinde uygulanması

suretiyle, kanalizasyon ağlarının tasarımında daha sistematik ve hesaplama açısından verimli sonuçlar elde edildiği ve küresel optimuma ulaşmada etkili bir yaklaşım olduğu görülmüştür.

Ajbar vd. (2015), Suudi Arabistan'ın turistik Mekke şehrinde belediye su üretiminin tahminine odaklanmışlardır ve bu amaçla yapay sinir ağları kullanılmıştır. Bu çalışmada, Mekke şehri, Suudi Arabistan için aylık ve yıllık su talebini tahmin etmek için bir yapay sinir ağı modeli geliştirmişlerdir. Önerilen model, su üretiminin tarihsel kayıtlarını ve tahmini ziyaretçi dağılımını kullanarak su talebi tahmini için bir yapay sinir ağı modelini kalibre etmektedir. Yapay sinir ağı modeli, su tüketimi dinamiklerini kısa ve uzun vadeli olarak ekonometrik modele göre üstün bulunmuştur.

Tiwari vd. (2016), su talebini tahmin etmek için ELM (Aşırı Öğrenme Makinesi) modellerini kullanmışlardır. Çalışma, sınırlı veri setlerinden günlük şehir su talebini tahmin etme yeteneğini değerlendirmek üzere, ELM modellerini bağımsız olarak, Dalgacık Analizi (W) ya da Bootstrap (B) yöntemleriyle birleştirerek geliştirmiştir. ELM tabanlı modellerden ELMW (Dalgacık Analizi ile Aşırı Öğrenme Makinesi) ve ELMB (Bootstrap ile Aşırı Öğrenme Makinesi), geleneksel Yapay Sinir Ağları (ANN) Dalgacık Analizi ile Yapay Sinir Ağı (ANNW) ve Bootstrap ile Yapay Sinir Ağı (ANNB) modelleriyle karşılaştırılmıştır. Calgary, Alberta'da 3 yıllık su talebi ve iklim verileri kullanılarak yapılan analizlerde, ELMW modeli, günlük tahminlerde diğer modellere göre üstün performans göstermiştir. ELMW modeli, özellikle pik su talebi tahmininde en yüksek doğruluğu sağlamış ve W (Dalgacık Dönüşümü), modelin genel performansını artırmada önemli bir rol oynamıştır. Bu durum da ELMW'nin diğer modellerden %10 daha yüksek doğruluk sağlamasına katkıda bulunmuştur. Çalışma sonucunda, ELM tabanlı modellerin, özellikle hibrit yaklaşımlar kullanılarak, kısa vadeli su talebi tahmininde etkili bir araç olduğu ifade edilmiştir.

Sabir vd. (2017), kuzey Pakistan'daki Diamer Bhasha Barajı projesinden kaynaklanan çatışmalar üzerine bir analiz yapmışlardır. Çalışma, projenin yerel nüfus ve bölge üzerindeki etkilerinden kaynaklanan çatışmaları tanımlar ve bu çatışmaların bazılarını ele almaya yönelik atılan adımları araştırmaktadır. Özellikle, çatışmalar haksız toprak edinimi, yetersiz yerinden edilme önlemleri, yetersiz tazminat, yerleşim sorunları ve gelecekteki geçim kaygıları gibi konularla ilgilidir. Projenin başarılı bir şekilde tamamlanması, proje finansının güvence altına alınması, çeşitli paydaşlar arasındaki çatışmaların çözülmesi ve tüm tarafların onayının alınması ile yakından ilişkilidir. Bu vaka çalışmasından elde edilen içgörülere dayanarak, makale aynı zamanda altyapı projelerinde yönetişimi geliştirmeye yönelik stratejilere de vurgu yapmaktadır.

Pacchin vd. (2017), Castelfranco-Emilia, İtalya'da 24 saatlik bir zaman çerçevesi içinde su gereksinimlerini tahmin etmek için özelleştirilmiş bir tahmin modeli tanıtmışlardır. Kurulan model, her tahmin aşaması sırasında değerlendirilen iki faktör kullanmaktadır. İlk faktör, tahmin anındaki 24 saatlik ortalama su arzı ile 24 saatlik ortalama su talebi arasındaki yüzdeyi ifade etmektedir. İkinci faktör, 24 saatlik tahmin dönemi içinde belirli bir saatteki ortalama su talebi ile bu süre boyunca ortalama su talebi arasındaki ilişkiyi yansıtmaktadır. Çalışmanın sonuçları, genel olarak yüksek bir tahmin doğruluğu düzeyini ortaya koymuş olup kök ortalama kare hatası (RMSE) değerlerinin 4 ile 6 L/s arasında değiştiğini ve buna karşılık gelen ortalama mutlak hata (MAE) yüzdesinin ise 5 ile 7 % arasında değiştiğini göstermektedir.

Sooji vd. (2017), iklim değişikliğine uyum sağlama amacıyla altyapının ekonomik değerlendirmesi için bir algoritma üzerine bir çalışma yürütmüşlerdir. Bu çalışmada, yerel düzeyde altyapı uyumunun hem karları hem de maliyetlerini değerlendirmek için entegre bir çerçeve önermektedir. Uyum alternatiflerinin ömür boyu maliyetlerini değerlendirirken aşırı iklim değişikliğinin etkilerini ve aşamalı iklim değişikliğini ayırtmaktadır. Çalışma, uyum seçeneklerinin maliyet ve faydalarını sistematik bir şekilde analiz ederek, karar verme süreçlerine bilimsel bir çerçeve sunmayı hedeflemektedir.

Kyeongseok vd. (2017), kentsel alanlardaki adaptasyon projelerinin ekonomik uygulanabilirliğini değerlendirmeyi amaçlayan bir karar verme modeli tanıtmışlardır. Model, kentsel alanlara verilen zararın potansiyel azalmasını temsil eden oynaklığı hesaplamak için iklim senaryolarını, ekonomik faktörleri ve teknik düşünceleri bir araya getirmektedir. Önerilen model, temsilci konsantrasyon yolu (RCP) iklim senaryolarını entegre ederek yatırımların ekonomik değerinin oldukça doğru bir tahminini sağlayabilmektedir. Modelin uygulanabilirliğini göstermek amacıyla, Kore'nin Seul kentindeki bir felaket önleme tesisi odaklı bir vaka çalışması yapılmıştır. Çalışmanın bulguları, modelin kentsel altyapı için sağlam adaptasyon stratejilerinin geliştirilmesine değerli içgörüler sunarak karar verme süreçlerini etkili bir şekilde yönlendirebileceğini göstermektedir. İklim senaryolarını, ekonomik uygulanabilirliği ve yönetsel esnekliği dikkate alarak, model adaptasyon projelerini değerlendirmek ve önceliklendirmek için kapsamlı bir çerçeve sunmaktadır. Sonuç olarak, model iklim değişikliği karşısında kentsel altyapının dayanıklılığını ve sürdürülebilirliğini artırmaya katkıda bulunmaktadır.

Jithish ve Sankaran (2017), evsel su kullanımı tahmini için bir nöro-bulanık yaklaşım adlı bir çalışma sunmuştur. Onlar, nüfus artışı, hızlı kentsel gelişme ve iklim desenlerindeki

değişiklikler gibi faktörlerden kaynaklanan su tüketimindeki kontrolsüz artışın dünya genelindeki politika yapıcılarını için kritik bir endişe olarak ortaya çıktığını belirtmişlerdir. Sonuç olarak, çevresel unsurlar ile konut su kullanımı arasındaki bağı yakalayan bir model oluşturmak için denetimli öğrenme yoluyla öğretilmektedir.

Shevnina vd (2017), Rus Arktik bölgesindeki aşırı sel değişikliklerini değerlendirmek için olasılık modelini kullanarak, tahmini iklim bilgisine dayalı olarak çok yıllık akış verilerinin olasılık yoğunluk fonksiyonu (OYF) parametrelerini simüle etmişlerdir. Modelin performansı, kuzey Rusya'da bulunan 23 gözlem noktasından elde edilen deneysel verilerle modelin OYF'leri arasında çapraz karşılaştırma yaparak doğrulanmıştır. 2010-2039 dönemi için altı iklim modelinin simülasyonları kullanılarak dört iklim senaryosu altında akış derinliği ortalama değerleri ve varyasyon katsayıları değerlendirilmiştir. Bu bağlamda, çalışma, özellikle Nadim'deki Nadym Nehri'nde %1 aşılma olasılığıyla maksimum deşarjlar için mühendislik hesaplarının bir örneğini sunmaktadır. Araştırmacılar, bölgedeki sel risklerini değerlendiren ve yöneten mühendisler ve karar vericiler için değerli içgörüler sunmakta olup uygun altyapı ve azaltma stratejilerini tasarlarken gelecekteki iklim senaryolarını dikkate almanın önemini vurgulamaktadır.

Hong vd. (2017), uzaktan algılama, coğrafi bilgi sistemleri verileri ve istatistiksel analiz yöntemlerini kullanarak bir çalışma gerçekleştirmişlerdir. Çalışmada, Çin'deki ofis binalarının enerji karbon emisyonlarına katkıda bulunan faktörleri belirlenmektedir. Bina inşaat özelliklerinin, sosyo-ekonomik koşulların, iklim koşullarının ve mikro iklimin bu emisyonların sırasıyla %32,27, %18,37, %13,84 ve %10,66'sini oluşturduğunu tespit edilmiştir. Analizleri ayrıca kat alanının, enerji tüketenlerin sayısının, bölgesel bilimsel yatırımın ve ısınma derece günlerinin ofis enerji kullanımı ile pozitif korelasyonlar sergilediğini ortaya koymaktadır. Özellikle enerji tüketenlerin sayısının ofis enerji karbon emisyonları üzerinde en büyük etkiye sahip olduğu, ısınma derece günlerinin ise en az etkiye sahip olduğu belirlenmektedir. Teknolojik ilerlemeler enerji talebini azaltabilirken, anket yapılan birçok yüksek binanın son zamanlarda inşa edildiği ve enerji tasarrufu sağlayan cihazlarla donatıldığı, herhangi bir enerji tasarrufunun daha yüksek gelir düzeyleri ve enerji harcamaları için daha fazla hükümet desteği ile ilişkilendirilen artan enerji kullanımı ile dengelenebileceği görülmüştür. Bu bulgular, emisyon azaltma programları tasarlama ve bu alanda daha fazla çalışma yapma konusunda değerli temel bilgiler sağlamaktadır. Çalışma, ofis binalarından kaynaklanan karbon emisyonlarını azaltmaya yönelik programların

tasarımı için temel bilgiler sunmakta ve daha sürdürülebilir bir kentsel enerji kullanımı için gelecekte yapılacak araştırmalara rehberlik etmektedir.

Shiklomanov vd. (2017), Rusya'daki kalıcı donmuş zemin üzerine inşa edilen kentsel altyapının istikrarı üzerinde projelendirilen iklim değişikliklerinin olası etkilerini incelemişlerdir. Analiz, son iklim modeli karşılaştırma projesine katılan altı seçilmiş genel dolaşım modelinden (GCM) elde edilen verileri kullanmaktadır. Değerlendirme, tüm Rusya kalıcı donmuş zemin etkilenen alanı içermektedir. Analizin bulguları, en az %25'lik bir azalmanın beklenen Rusya kalıcı donmuş bölgesinde iklim kaynaklı faktörlerden kaynaklanan kentsel altyapının istikrarında 21. yüzyıl ortalarına kadar beklenen bir azalma olduğunu göstermektedir. Ancak, GCM'ler tarafından üretilen iklim projeksiyonları ile ilişkilendirilen belirsizlik, kalıcı donmuş altyapı üzerindeki potansiyel iklim etkilerinin kesin hızı ve büyüklüğü hakkında kesin sonuçlar çıkarma yeteneğini sınırlamaktadır. Bu makalede sunulan sonuçlar, Rusya'nın kuzey şehirleri için uygun adaptasyon ve azaltma stratejilerinin geliştirilmesine yönelik değerli rehberlik sağlamaktadır. İklim değişikliği karşısında kentsel altyapıdaki potansiyel zorlukları ve savunmasızlıkları tanıyarak, politika yapıcıları ve paydaşlar bu şehirlerin dayanıklılığını ve sürdürülebilirliğini artırmak için etkili önlemler uygulama yolunda çalışılmıştır.

Antoniou ve Aretoulis (2018), dört farklı çok kriterli karar verme yöntemini: çok özellikli fayda teorisi, ideal duruma benzerlik sırasına göre tercih tekniği, zenginleştirilmiş değerlendirme için tercih sıralama organizasyon yöntemi (PROMETHEE) kullanmışlardır. Bu yöntemler, her biri özgün özelliklere ve ödüllendirme yetkililerinin belirli ihtiyaçlarına sahip iki farklı vaka çalışmasına uygulanmıştır. Amaç, dokuz seçim kriterine dayalı olarak yedi seçenek arasından en uygun sözleşme türünü seçmektir. Bu çalışmanın bulguları, Yunanistan'daki kamu işleri hukukunda yeni sözleşme türlerinin kurulmasının önemini vurgulamaktadır. Ayrıca, sonuçlar dört yöntemin de karar verme sürecinde tarafsızlığı artırarak karar destek sistemleri olarak potansiyel taşıdığını göstermektedir.

Ter-Akopov vd. (2019), Sibiry ve Rusya'nın uzak doğusundaki ulaşım sisteminin gelişimine odaklanan bir çalışma üzerinde çalışmışlardır. Demiryollarının yenilenmesi, yeni bir otoyol ağı kurulması ve havaalanlarının modernizasyonu, devletin verimli işleyişi ve ekonomik bağlantısı için önemli önkoşullardır. Rusya'nın geniş toprak sahası, özellikle uzunluğu ve mekânsal dengesizliği göz önüne alındığında, ulaşım ve lojistik altyapı sorunlarının ele alınması büyük öneme sahiptir. Çalışma, Sibiry ve uzak doğudaki çağdaş ulaşım kompleksinin gelişimindeki ana eğilimleri belirlemektedir. İşleyişini etkileyen kritik

sorun alanlarını tanımlar ve Rusya'nın mekânsal gelişim hedefleri çerçevesinde ulaşım altyapısının gelişimini artırmak için pratik önlemler önermektedir. Çalışmanın bulguları, federal bölge düzeyinde stratejik planlamada pratik sonuçları olan ve aynı zamanda ulusal ve bölgesel düzeyde daha fazla araştırmanın temelini oluşturabilecek niteliktedir.

Huntingford vd (2019), makine öğrenimi algoritmalarının dikkat çekici bir ilerleme kaydettiğini, çeşitli araştırma alanlarını devrimlediğini ve son zamanlarda iklim analizinde değerli bir araç olarak önerildiğini tartışmışlardır. Makine öğrenimi teknikleri, Dünya Sistemi'nin birçok izole özelliğini analiz etmek için uygulansa da tüm iklim sistemi hakkında kapsamlı bir anlayış elde etmek için daha geniş bir uygulama sınırlı kalmaktadır. Yapay zekâ (AI) kullanarak, makine öğrenimi iklim bağlantılarını açığa çıkarabilir ve aşırı olaylar dahil olmak üzere yaklaşan hava olayları için gelişmiş uyarılar sağlayabilmektedir. Ancak mevcut veri ve simülasyonlardan daha derin bir anlayış elde etmek için makine öğrenimi ve yapay zekâ potansiyelini kullanmaya paralel olarak vurgu yapmayı önermektedir.

Henry vd. (2019), güvenilir ve güvenli içme suyu erişiminin insan topluluklarının sürdürülebilir ekonomik ve sosyal gelişimi için önemli olduğunu belirten bir çalışma sunmuşlardır. Bu talep, yeni su temini altyapısının kurulması için uygun alternatiflerin seçilmesi için çok kriterli karar analizi (MCDA) metodolojisinin kullanılmasını gerektirmektedir. Yeni su temini altyapısı inşa bağlamında karar verme sürecini kolaylaştırmak için, bir dizi ekonomik olmayan fayda ve beklenen maliyetlerin birleşik bir indekse dahil edildiği entegre bir MCDA metodolojisi geliştirmişlerdir. Bu metodoloji, mevcut olarak %60 içme suyu eksikliği yaşayan ve artan su talebini karşılamak için kapasitesini genişletme aciliyeti bulunan Kolombiya'nın Santa Marta şehrine uygulanmıştır. Bu çalışmanın sonuçları, Santa Marta'nın su temini sorununu çözmek için en olumlu alternatifin uygulanmasını desteklemekte ve paydaşların tercihlerini dikkate almaktadır.

Guo vd. (2019), su kaynaklarının sürdürülebilir yönetimini desteklemek ve su talebi tahmini doğruluğunu artırmak amacıyla sosyal öğrenme ve Morlet dalgacık mutasyon mekanizmasına dayalı geliştirilmiş bir Balina Optimizasyon Algoritması (WOA) önermişlerdir. WOA, su talebi tahmini için logaritmik, doğrusal-üstel kombinasyon ve doğrusal-üstel-logaritmik hibrit olmak üzere üç farklı modelde uygulanmıştır. Sosyal ağlar üzerinden bilgi paylaşımını sağlayan adaptif komşuluk stratejisi ve dinamik mutasyon mekanizması, algoritmanın arama alanındaki çeşitliliği artırarak yerel optimumlardan kaçmasına olanak tanımıştır. Çalışmada, Shaanxi Eyaleti'nin 2004-2016 yıllarına ait su tüketimi verileri kullanılarak tahmin doğruluğu test edilmiş ve algoritmanın performansı

diğer yöntemlerle karşılaştırılmıştır. Bulgular, algoritmanın %99,68 gibi yüksek bir doğruluk seviyesine ulaştığını ve tahminlerin güvenilirliğini önemli ölçüde artırdığını göstermiştir. Bu yenilikçi yaklaşım, su kaynaklarının etkin ve sürdürülebilir yönetimi için güçlü ve pratik bir araç sunarak, su talebi tahmini alanında önemli bir katkı sağlamıştır. Çalışma, aynı zamanda enerji ve çevre yönetimi gibi diğer alanlarda uygulanabilir bir model olarak değerlendirilmektedir.

Baumli ve Jamasb (2020), Afrika'daki yenilenebilir enerji altyapısına yönelik özel sektör yatırımlarını değerlendirmek için çok kriterli karar analizi (ÇÖKV) yaklaşımını kullanmışlardır. Enerji yoksulluğunun ekonomik kalkınmayı engellediği ve sosyal eşitsizlikleri artırdığı Afrika'da, özel sektör finansmanının yenilenebilir enerji projelerinin hayata geçirilmesi için kritik olduğu vurgulanmaktadır. Çalışmada, yatırım kararlarını etkileyen finansal ve finansal olmayan faktörler analiz edilmiş ve ülkelerin özelliklerinin yatırımcı tercihleri üzerindeki etkileri bulanık TOPSIS yöntemiyle değerlendirilmiştir. Bulgular, yatırımcı güveninin özellikle düzenleyici etkinlik ve yerel kapasite geliştirme gibi faktörlere bağlı olduğunu göstermektedir. Ayrıca, kurumsal engellerin aşılmasına yönelik politika araçlarının geliştirilmesinin ve yerel kapasite artırıcı önlemlerin özel sektör yatırımlarını teşvik etmek için etkili olabileceği belirtilmiştir.

Elzbieta ve Karolina (2020), çevresel açıdan en uygun yol rotası varyantını belirlemek için çok kriterli yöntemlerin kullanılabilirliğini araştırmak için bir çalışma geliştirmişlerdir. İlk aşama, 2010 ile 2019 yılları arasında ulaşımında MCDM/MCDA (Çok Kriterli Karar Verme/Çok Kriterli Karar Analizi) yöntemlerinin kullanımına odaklanan kapsamlı bir literatür taraması yapmayı içermektedir. İnceleme, ulaşım alanındaki çok kriterli karar verme sorunlarını ele almak için en çok kullanılan yöntemlerin, AHP ile değişiklikler, TOPSIS, DEMATEL gibi yöntemler olduğunu ortaya koymaktadır. Ayrıca PROMETHEE ve ELECTRE gibi Avrupa trendi altında yer alan yöntemler de bulunmaktadır. Çalışmanın deneysel bölümünde, dört seçilmiş yöntem kullanılmaktadır. Bu yöntemler, kuzeydoğu Polonya'daki bir otoyol bölümü için en uygun varyantı seçmek için kullanılmıştır. Analizin sonuçları daha sonra incelenen çevresel etki raporunda yapılan seçimle karşılaştırılmıştır. Bu çok kriterli yöntemleri kullanarak, bu araştırma çevre dostu yol rotası varyantlarını seçerken değerli içgörüler sunmayı amaçlamaktadır.

Elshaboury ve Marzouk (2020), su boru hatlarının yapısal durumunu tahmin etmek için makine öğrenimi modellerinin performansını karşılaştırmayı amaçlamışlardır. Su boru hatlarının bozulma ve aşınma sorunlarının yaygın olduğu göz önüne alındığında, yapılan

çalışma, altyapının etkin sürdürülebilir yönetimi ve bakım planlaması için önemli bir katkı sağlamaktadır. Çalışma kapsamında, çoklu doğrusal regresyon, ileri beslemeli sinir ağıları, genel regresyon sinir ağıları ve destek vektör regresyonu (SVR) gibi çeşitli makine öğrenimi algoritmaları uygulanmıştır. Bu modellerin performansı, determinasyon katsayısı (R^2) ve ortalama hata kareleri kökü (RMSE) gibi metriklerle değerlendirilmiştir. Bulgular, modellerin tahmin doğruluğu açısından farklı performanslar sergilediğini göstermiştir. Elde edilen sonuçlar, su altyapısının durum tahmininde makine öğrenimi tekniklerinin potansiyelini ortaya koymuş ve gelecekte daha etkin bakım ve yönetim stratejileri için yol gösterici olmuştur.

Tsyganov (2020), aşırı iklim ve coğrafi koşullarla karakterize edilen büyük ölçekli bir bölgede altyapı gelişimini stratejik olarak yönetmeyi amaçlayan teorik ve metodolojik bir model sunmuştur. Bu model, altyapı gelişimini yönetmek için organizasyonel sistemler ve mekanizmalar dahil olmak üzere çeşitli unsurları içermektedir. Ayrıca iş potansiyeli ve maliyetlere dayalı olarak yatakların gelişim olanaklarını değerlendirmek için bir metodoloji sunulmuştur. Bunun yanı sıra, bölgenin sosyo-ekonomik sisteminin ulaştırma altyapısının gelişimi ile ilişkisini keşfetmek amacıyla bir simülasyon senaryo modeli oluşturulmuştur.

Pidgeon ve Dawood (2021), işbirlikçi Yapı Bilgi Modellemesinin (BIM) başarılmasında temel ve esas bileşen olarak bilgi yönetiminin belirleyici rolünü vurgulayan bir araştırma yürütmüşlerdir. Çalışmada, işbirlikçi BIM'nin geliştirilmesine katkıda bulunmak için Analitik Hiyerarşi Süreci (AHP) temelli bir amaç odaklı uygulama çerçevesi kullanılmıştır. Bu metodoloji, proje takım üyelerinin hedef başarısını belirleme konusunda dinamik bir nitel ve nicel yaklaşım sunarak, ortaklaşa kabul edilen bir amaç odak oluşturur ve kurar, bu sayede proje ekibi üyelerinin hedef başarısının kesinliğini artırmaktadır. Ayrıca, çalışma, standardizasyon ve kalite güvencesi anlaşmazlıklarındaki tutarsızlıkları ortaya çıkarır ve geliştirilen yeni metodoloji tarafından desteklenmektedir. Sonuç olarak, bu strateji, bu anlaşmazlık eksikliğinin sonuçlarını hafifletmeyi amaçlayarak, işbirlikçi Yapı Bilgi Modellemesinin (BIM) gelecekteki daha iyi anlayışını ve uygulanmasını teşvik etmeyi hedeflemektedir.

Li vd. (2021), su tüketimini tahmin etme konusundaki belirsizlikleri ele almayı amaçlayan bir çalışma yürütmüşlerdir ve bu amaçla kernel yoğunluk tahmini-frekansı order ters kümülatif gri model adı verilen yeni bir yaklaşımı tanıtmışlardır. Bu yöntem, kesirli order ters kümülatif gri modelinden gelen hata kalıntılarını kullanarak frekans analizi için kernel yoğunluk tahminini uygulanmıştır. Modelin etkinliği, Beijing, Chongqing ve

Qingdao'dan gelen yıllık kentsel içme suyu tüketimi verilerini kullanarak test edilmiştir. Araştırmacılar, en uygun modeli seçmek için ideal çözüme benzerlik sırası tercihi (TOPSIS) tekniği kullanılmıştır. Bulgular, yeni modelin kentsel içme suyu tüketimini tahmin etmede diğerlerini geride bıraktığını göstermekte ve su kaynağı sektöründe bölgesel kentsel su tüketimi tahminine sağlam bir karar destek sunmaktadır.

Hashad vd (2021), trafik kaynaklı hava kirliliğini (TRAP) azaltmak için yol kenarı yeşil altyapı tasarımlarını makine öğrenimi modelleriyle optimize etmeyi amaçlamışlardır. Trafik kirliliği kaynaklı sağlık etkilerinin yaygın olduğu yol kenarı bölgelerinde, geleneksel tasarım araçlarına erişimin sınırlı olması, etkili mitigasyon stratejilerinin geliştirilmesini zorlaştırmaktadır. Çalışma kapsamında, doğrusal regresyon (LR), destek vektör makineleri (SVM), rastgele orman (RF), XGBoost (XGB) ve sinir ağları (NN) dahil olmak üzere beş makine öğrenimi yöntemi kullanılarak bitki örtüsü bariyer tasarımlarının partikül konsantrasyonlarını azaltma kapasitesi test edilmiştir. 83 farklı hesaplamalı akışkanlar dinamiği (CFD) simülasyonundan elde edilen veriler, modellerin eğitim ve test süreçlerinde kullanılmıştır. RF, NN ve XGB modelleri, %6-7 oranında normalize edilmiş hata (NRMSE) ve 0.91'den fazla test R^2 değeriyle üstün performans sergilerken, SVM ve LR modelleri daha düşük doğruluk göstermiştir. Özellik seçimi analizleri, bitki örtüsünün boyutları ve parçacık boyutlarının, kirlilik tahmininde en etkili değişkenler olduğunu ortaya koymuştur. Çalışma sonucunda, kullanılan makine öğrenimi modellerinin, yerel toplulukların trafik kaynaklı hava kirliliği sorunlarına çözüm geliştirmesine yardımcı olacak hızlı ve erişilebilir araçlar bulunduğu görülmektedir.

Junqueira vd. (2021), Kenya'nın kuzeyinde yer alan Daasanach topluluğunun su kaynaklarına yönelik algılarını ve iklim değişikliği ile büyük altyapı projelerinin birleşik etkilerini ele almışlardır. Daasanach halkının çevresel değişimlere dair gözlemleri, su kaynaklarının erişilebilirliğinin iklimsel ve sosyo-ekonomik faktörlerin karmaşık etkileşimleri sonucunda şekillendiğini ortaya koymaktadır. İklim değişikliği, su kaynaklarına olan mevcut baskıları artırırken, Omo Nehri boyunca kurulan büyük altyapı projeleri bu etkileri daha da şiddetlendirmektedir. Özellikle uzun süreli kuraklıklar ve su kıtlığı, hem topluluğun geçim kaynaklarını hem de biyofiziksel unsurları olumsuz yönde etkilemektedir. Araştırmacılar, yerel ekolojik bilginin çevresel değişimlerin karmaşıklığını anlamada önemli bir araç olduğunu vurgulamış ve kapsayıcı bir yönetim yaklaşımıyla yerel halkın bilgi birikiminin karar alma süreçlerine dahil edilmesi gerektiğini ifade etmişlerdir. Çalışma sonucu, iklim değişikliği ile altyapı projelerinin birleşik etkilerinin azaltılabilmesi

için sosyal ve çevresel faktörler arasında bir dengenin sağlanmasının kritik önem taşıdığını göstermiştir.

Nie vd. (2022), zaman serisi verilerini işlemeye başlayan, düzensiz trend faktörlerini ele almak için zaman serisinin sürekli olduğu bir veri ön işleme aşaması başlattığı yeni bir çalışmayı tanıtmıştır. Buna ek olarak, uygun özelliklerin seçimi için iki katmanlı bir özellik seçme yaklaşımı tanıtılmıştır. Bu yöntem, giriş gecikmeli değişkenlerin ve dışsal değişkenlerin ilgisini aynı anda göz önünde bulundurarak, bunların ilişkilerini ve önemini düşünürken Random Forest (Rastgele Orman, RF) algoritması ve otokorelasyon analizini birleştirir. Ardından, evsel elektrik talebi (HED) için hibrit tahmin yöntemleri oluşturulur. Bu yöntemler, K-en yakın komşu, Destek Vektör Regresyon (SVR), Random Forest ve çok katmanlı perceptron dahil olmak üzere çeşitli makine öğrenmesi algoritma tekniklerini içermektedir. Bu yaklaşım, farklı tahmin senaryolarını etkili bir şekilde yönetmek için her tekniğin güçlü yanlarını kullanır. Çalışmada önerilen yaklaşımlar, enerji talebi yönetiminde 10 dakika ileriye dönük olan kısa vadeli tahminlerin doğruluğunu artırarak, enerji güvenliğinin sağlanmasına ve kriz yönetimine katkıda bulunmaktadır. Elde edilen tahmin sonuçları, kullanılan makine öğrenmesi algoritmalarının elektrik talebindeki dalgalanmaları doğru bir şekilde öngörebildiğini ve enerji yönetimi süreçlerine anlamlı katkılar sağladığını göstermektedir.

Mirzaei vd. (2022), inşaat ve altyapı endüstrileri içinde nokta bulutu veri kümeleri ve bunların otomatik işlenmesi konusundaki en son araştırmaların genel bir değerlendirmesini yapmışlardır. Var olan araştırma boşluklarını belirleyerek, makale bu alandaki gelecekteki araştırmalar için bir çerçeve önermektedir. Bu derleme makalesinin başlıca amacı, araştırmacılara değerli bir kaynak olarak hizmet etmek ve inşaat ve altyapı alanlarında makine işlenmiş nokta bulutu modellerinin en son uygulamaları hakkında bilgi sunmaktır. Ayrıca, inşaat ve altyapı endüstrileri içinde otomatik prosedürler geliştirmek isteyen paydaşlara rehberlik etmeyi amaçlamaktadır.

Yun vd. (2022), ulaşım altyapısı projelerinde maliyet aşımalarının (COO) sosyo-ekonomik koşullarla olan ilişkisini analiz etmek için makine öğrenimi teknikleri ve coğrafi bilgi sistemlerinden (GIS) yararlanmışlardır. Çalışmada, farklı veri setlerinden sosyo-coğrafi özellikleri çıkarılarak Random Forest modeli kullanılmış ve COO ile güçlü ilişkili faktörler belirlenmiştir. Çalışma, proje maliyetlerini etkileyen başlıca unsurlar arasında; orijinal bütçe miktarları, proje süresi, yönetim bölgeleri, şerit sayısı, 16 yaş üstü nüfus, ulaşım davranışları, endüstriyel yapı ve ortalama sıcaklık gibi değişkenlerin olduğunu göstermiştir.

Araştırmacılar, sosyo-ekonomik koşulların proje maliyetleri üzerindeki önemli etkisini vurgulamaktadır. Çalışma sonucunda, uygulayıcıların ve karar vericilerin çevresel ve sosyo-ekonomik koşulları proje planlama, bütçeleme ve bakım süreçlerinde daha iyi öngörebilmelerine ve dikkate alabilmelerine yardımcı olacak öneriler sunulmaktadır.

Belay vd. (2022), farklı proje ekipleri içindeki karar alma süreçlerinin başarısına katkıda bulunan faktörler arasındaki tutarlı ilişkiyi ve bağımlılıkları kurmak için bir çalışma sunmuştur. İnşaat organizasyonlarında doğal olarak bulunan çeşitli kısıtlamaları dikkate alırken öncelikleri belirlemeyi amaçlamaktadır. Bu amaçla, önceden belirlenmiş başarıyla ilgili faktörleri içeren bir yapılandırılmış hiyerarşik matris geliştirilmiştir. Matris, anketin içerik doğrulama sürecinin bir parçası olarak deneyimli profesyoneller tarafından ilk bir değerlendirmeye tabi tutulmuştur. Veri toplamak için, farklı inşaat organizasyonlarından profesyoneller, bir anket çalışmasına katılmak üzere Etiyopya'da davet edilmiştir. Toplanan veriler, uzman seçimine dayalı olarak analiz edilmiş ve hassasiyet performansı analizi sürece dahil edilmiştir. Ayrıca, birden fazla uzman tarafından verilen cevapları incelemek ve karşılaştırmak için Kendall'ın uyum katsayısı kullanılmıştır. Bu metodolojileri kullanarak, bu çalışma proje ekipleri içinde başarılı karar verme süreçlerine katkıda bulunan faktörlere dair içgörüler sunmayı amaçlamaktadır. Bulgular, inşaat organizasyonlarının karşılaştığı özel kısıtlamaları göz önüne alarak bu faktörleri önceliklendirmeye yardımcı olabilmektedir.

Basheer vd. (2023), Nil altyapı sistemini adaptif bir şekilde yönetmeyi sağlayan bir planlama çerçevesini tanıtmışlardır. Yaklaşım, iklim projeksiyonlarını, hidrolojik ve nehir sistem simülatörlerini, ekonomiye etki eden modelleri ve çoklu amaçlı tasarım ve makine öğrenme için yapay zekâ algoritmalarını entegre etmiştir. Bu çerçevenin uygulanmasıyla, Büyük Etiyopya Rönesans Barajı için işbirlikçi bir adaptif yönetim politikası geliştirmenin etkililiğini sergilemektedir. Bu politika, Etiyopya, Sudan ve Mısır'ın hepsinin barajın sınır ötesi etkilerini paylaştığı durumlarda bu ülkelerin ekonomik ve biyofiziksel çıkarlarını başarılı bir şekilde dengelemektedir. Analizleri, bu ülkelerin barajları iş birliği yaparak ve özellikle akış debisindeki en büyük değişiklikleri içeren iklim senaryoları altında adaptif bir şekilde yönettiklerinde elde edilebilecek önemli ulusal düzeyde ekonomik ve dayanıklılık faydalarını vurgulamaktadır.

Wang vd. (2023), entegre gri-yeşil altyapının (IGGI) hidrolojik performansını, iklim değişikliğine yanıt olarak uzun vadeli yağış verileri ve Paylaşılan Sosyo-Ekonomik Yollar (SSP) senaryolarına dayalı olarak değerlendirmişlerdir. Çalışma, Guangzhou, Çin'de bir örnek olay üzerinde uygulanmış ve hem merkezi hem de dağıtılmış IGGI stratejilerinin iklim

değişikliğine karşı kırılgan olduğunu göstermiştir. İklim değişikliğinin dinamik ve durağan olmayan doğasına uygun olarak zaman serisi analizi yapılmış ve iki aşamalı bir değerlendirme yöntemi geliştirilmiştir. Çalışma sonucunda, merkezi ve dağıtılmış sistemler arasında bir denge sağlandığında, IGGI sisteminin hidrolik performansının önemli ölçüde arttığını ve özellikle aşırı yağış olaylarında taşkın akışını azaltmada etkili olduğu görülmüştür. Çalışma ayrıca, yoğun kentsel alanlarda iklim değişikliği ile mücadele için hidrolik değerlendirme ve planlama süreçlerine yeni bir perspektif sunmaktadır.

Frimpong vd. (2023), iklim değişikliğinin altyapı projelerine yönelik büyük tehdit oluşturduğu bir bağlamda, karbon yoğun kamu-özel sektör ortaklığı (PPP) altyapılarının daha düşük karbonlu ve sürdürülebilir bir şekilde yönetilmesine odaklanmışlardır. İklim duyarlı PPP projelerinin geliştirilmesi, özellikle yol taşımacılığı, enerji arzı ve su altyapısı gibi alanlarda giderek önem kazanmaktadır. Çalışmada, iklim dostu PPP altyapılarının hayata geçirilmesine yönelik çözümler, bu süreçteki itici güçler ve uygulama zorlukları sistematik bir literatür incelemesiyle ele alınmıştır. Literatürden elde edilen bulgular, yenilenebilir enerji kullanımı, iklim finansmanı sağlanması ve dirençli altyapıların geliştirilmesinin düşük karbonlu gelişim hedefleri için temel çözümler olduğunu göstermektedir. Ayrıca, inşaat projelerinden kaynaklanan büyük sera gazı emisyonlarını azaltma ve sürdürülebilir yeşil inşaat yönetimine geçiş gibi küresel hedeflerin, iklim dostu PPP projelerine geçişte önemli bir itici güç olduğu vurgulanmıştır. Ancak, politikaların yetersizliği ve sektör içinde koordinasyon eksikliği gibi engeller de dikkate alınmıştır. Çalışma sonucu, düşük karbonlu PPP projelerinin uygulanabilirliğini artıracak stratejiler için rehber niteliğinde öneriler sunmaktadır.

Zhang vd. (2023), altyapı projelerinin sürdürülebilirliğini sağlamak amacıyla, iklim değişikliği, altyapının fiziksel durumu ve ekonomik belirsizliklerden kaynaklanan riskleri ele almıştır. Çalışmada, Çok Amaçlı Parçacık Sürü Optimizasyonu (MOPSO) ve Baskın Olmayan Sıralama Genetik Algoritması-II (NSGA-II) yöntemleri kullanılmış, karar vericilerin farklı bütçe kısıtlamaları altında sürdürülebilir altyapı yönetimi için en uygun çözümleri belirlemeleri sağlanmıştır. Araştırmacılar, yıllık bütçe kısıtlamalarının, pareto cephesi ve bireysel çözümlerin zamanlaması üzerinde önemli bir etkisi olduğunu göstermekle birlikte, geliştirilen yöntemlerin, altyapı yönetiminde çok amaçlı optimizasyon uygulamaları için esnek bir karar analizi aracı olarak kullanılmasını önermektedir.

Ansari vd. (2024), su kalitesini tahmin etmek ve sınıflandırmak için makine öğrenimi tabanlı altı farklı modelin etkinliğini, doğruluk, kesinlik, geri çağırma ve F1 skoru gibi

performans kriterleriyle incelemişlerdir. Çalışmada, KNN modeli, %97,53 doğruluk oranı ve diğer güçlü performans metrikleriyle en iyi sonuçları sunarken, modelin standart bir veri setiyle doğrulanması da su kalitesi analizinde etkili ve ekonomik bir çözüm ortaya koymuştur. Çalışma sonucunda, artan nüfus baskısı ve kirleticilerin su kaynakları üzerindeki olumsuz etkileri göz önüne alınarak, yapay zekâ destekli sistemlerin su kirliliğini kontrol etme ve sürdürülebilir su yönetimi sağlama konusunda önemli bir potansiyele sahip olduğu vurgulanmıştır.

Li vd. (2024), su arıtma cihazlarında makine öğrenimi modellerinin kullanılabilirliğini artırmak ve cihazların performansını iyileştirmek için bir yöntem geliştirmeyi amaçlamıştır. Çalışma kapsamında, dağıtık su arıtma sistemleri için bir elektrokoagülasyon membran katot reaktörü (ECMCR) tasarlanmış ve bu sistemin operasyonel verimliliğini optimize etmek için dokuz farklı makine öğrenimi modeli uygulanmıştır. Bayes optimizasyonu, modellerin hiperparametrelerini belirlemek için kullanılmıştır. LightGBM modeli eğitim sırasında en yüksek doğruluğu ($R^2 = 0.99$, $MSE = 0.0004$) gösterirken, Random Forest modeli de test verilerinde etkili performans ($R^2 = 0.98$, $MSE = 0.0056$) göstermiştir. Çalışma sonucunda, makine öğrenmesi ile su arıtma cihazlarının performansının manuel müdahaleye ihtiyaç duymadan optimize edilebileceği gösterilmiştir.

Feng vd. (2024), güvenli içme suyu temininde makine öğreniminin uygulanabilirliğini ve etkinliğini kapsamlı bir şekilde incelemiştir. Çalışma, geleneksel su kalitesi kontrol yöntemlerinin zorluklarını ele alarak, makine öğrenimi algoritmalarının fiziksel (ör. boru hattı uzunluğu, malzeme, sızıntı), kimyasal (ör. ağır metal konsantrasyonları), mikrobiyolojik (ör. mikrop, patojen) ve çevresel (ör. iklim değişikliği, doğal afetler) parametreleri izleme, simüle etme, tahmin etme ve kontrol etme süreçlerinde nasıl kullanılabileceğini araştırmaktadır. Makine öğrenimi algoritmaları, tahmin ve sınıflandırma başlıkları altında, farklı kıstaslar üzerinden karşılaştırılmış, Random Forest ve XGBoost algoritma modelleri, tahmin doğruluğu açısından diğer yöntemlerden üstün bulunmuştur. Çalışma sonucunda, ML'nin dinamik su kalitesi süreçlerini tahmin etme ve optimize etme açısından geleneksel yöntemlere göre daha etkili olduğu görülmüştür. Ayrıca, bu teknolojinin kamu sağlığını koruma ve sosyoekonomik gelişmeyi destekleme potansiyeline sahip olduğu araştırmacılar tarafından vurgulanmıştır.

Shams vd. (2024), su kalitesinin değerlendirilmesi ve sınıflandırılması için makine öğrenimi (ML) algoritmalarını grid search yöntemiyle optimize ederek model performansını artırmayı amaçlamıştır. Çalışmada, su kalitesi indeksi (WQI) ve su kalitesi sınıflandırması

(WQC) için regresyon ve sınıflandırma modelleri kullanılarak sonuçlar değerlendirilmiştir. Veriler, eksik değer tamamlama ve normalizasyon gibi ön işleme tekniklerinden geçirilmiştir. Sınıflandırma için Rastgele Orman (RF), XGBoost, Gradient Boost (GB) ve Adaptive Boosting (AdaBoost) algoritmaları uygulanırken; regresyon için de K-En Yakın Komşu (KNN), Karar Ağacı (DT), Destek Vektör Regresyonu (SVR) ve Çok Katmanlı Algılayıcı (MLP) algoritmik modelleri uygulanmıştır. Sınıflandırmada en iyi sonuç, %99,50 doğruluk ile GB modeli tarafından sağlanırken, regresyonda MLP modeli %99.8 R^2 ile üstün performans göstermiştir. Çalışma sonucunda, grid search yöntemi ile parametre optimizasyonunun makine öğrenmesi modellerinin su kalitesi tahminlerindeki doğruluğunu önemli ölçüde artırabileceği gösterilmiştir.

Singh vd. (2024), yeraltı suyu seviyelerinin tahmini için hiperparametre optimizasyonunu otomatikleştiren ve en uygun makine öğrenimi modelini seçen bir yaklaşım olan AutoML-GWL'yi geliştirmeyi amaçlamıştır. 1997-2018 yılları arasında biriktirilen uzun süreli veri setlerini (yağış, sıcaklık, buharlaşma, toprak tipi, bağıl nem ve yeraltı suyu seviyesinin gecikmesi gibi değişkenler) kullanılarak model eğitilmiştir. Bayesian optimizasyonuyla da desteklenen bu sistem, yeraltı suyu seviyesi tahmininde yüksek doğruluk (%90), düşük RMSE (1,22) ve minimal hata (0,23) oranlarına ulaşmıştır. Ayrıca, AutoML-GWL modeli 16 farklı makine öğrenimi algoritmasıyla karşılaştırılmış ve performans açısından oldukça üstün bulunmuştur. Çalışma sonucunda, bu yeni yaklaşımın sürdürülebilir su kaynakları yönetimi için güçlü bir çözüm sunduğu belirtilmiştir.

Mabdeh vd. (2024), Hindistan'daki tropikal nehir havzalarında taşkın duyarlılığı haritalarını oluşturmak için makine öğrenimi (ML) ve derin öğrenim (DL) algoritmalarını, gri kurt optimizasyonu (GWO) algoritmasıyla birleştirerek algoritmaların performanslarını artırmayı hedeflemiştir. Çalışmada, taşkın duyarlılığı tahmini için belirlenen 15 bağımsız değişken arasından, eğim, yükseklik, arazi örtüsü ve toprak yapısı gibi taşkın riskini modellemede en etkili olanlar öncelikli olarak değerlendirilmiştir. Çalışma neticesinde, Destek Vektör Regresyonu (SVR), XGBoost ve Yinelenebilir Sinir Ağları (RNN) modellerinin Gri Kurt Optimizasyonu (GWO) ile entegrasyonundan elde edilen sonuçlar, RNN-GWO modelinin %96,8 alan altı eğri (AUC) değeriyle en yüksek performansı sergilediğini ortaya koymuştur. Bulunan sonuçlar, taşkın yönetimi için yenilikçi bir model sunmakta ve risk azaltma stratejilerinin geliştirilmesine yönelik önemli bir kaynak sağlamaktadır.

Literatürde farklı araştırmacılar tarafından yapay zekâ destekli modellerde kullanılan parametreleri ve bu parametrelerin uygulanma yöntemleri Tablo 1'de özetlenmektedir.

Tablo 1. Modellemelerde kullanılan parametre ve yöntemlerin literatür özeti

Yıl	Yazar (lar)	Kullanılan Yöntem (ler)	Kullanılan Parametreler	Açıklamalar
2008	Hassan ve Tarek	Hibrit Yöntem (Analitik Hiyerarşi Süreci (AHP) ve Yapay Sinir Ağları (ANN) yöntemlerinin entegrasyonu)	(boru yaşı, malzeme türü, çapı), (toprak türü, yeraltı su seviyesi), (çalışma basıncı, akış hızı)	Çalışma, belediyelere ait su şebekesi boruların performansını değerlendirmek için Analitik Hiyerarşi Süreci (AHP) ve Yapay Sinir Ağları (ANN) yöntemlerini entegre eden bir model geliştirmeyi amaçlamaktadır. Bu sayede, su borularının durum değerlendirmesi ve bakım önceliklerinin planlaması hedeflenmiştir.
2012	Oslakovic vd.	Veri korelasyonu, Regresyon	Bölgesel iklim verileri, malzeme ve bakım geçmişi	Çalışma, iklim değişikliğinin altyapı performansı üzerindeki potansiyel etkilerini araştırmayı ve bu etkilerin yönetimi için uygun müdahale stratejilerini belirlemeyi amaçlamaktadır.
2014	Zhou vd.	BP, PCA	Nüfus ve artış oranı, GSYH, Büyüme oranı, Sıcaklık, Yağış, Endüstriyel-Tarımsal su kullanımı	Çalışma, Shenyang şehrinin su talebini tahmin etmek amacıyla, Temel Bileşen Analizi (PCA) ile ön işleme tabi tutulan veriler kullanılarak Geri Yayılım (BP) Yapay Sinir Ağları modelinin uygulanmasını amaçlamaktadır. Bu sayede, su talebi tahminlerinin doğruluğunu artırmak hedeflenmektedir.
2014	Uzlu vd.	TLBO, ANN	Nüfus, GSYH, İhracat, İthalat	Çalışma, demografik ve sosyo-ekonomik faktörleri temel alarak Türkiye'deki enerji tüketimini tahmin etmeye odaklanan bir model geliştirmiştir. Gelecekteki enerji tüketim seviyelerini projelendirmek için üç farklı senaryo kullanılmıştır.
2015	Chinowsky vd.	Stres-tepki yaklaşımı	İklim (Yağış, Sıcaklık, Değişkenleri, Altyapı Özellikleri (Yol türü, bakım	Çalışma, iklim değişikliğinin Malawi, Mozambik ve Zambiya'daki yol altyapısı üzerindeki potansiyel etkilerini değerlendirmeyi ve bu etkilere karşı uyum stratejilerini belirlemeyi amaçlamaktadır.
2015	Ajbar vd.	ANN	nüfus artışı, turist sayıları, ortalama sıcaklık, yağış miktarı	Çalışma, Suudi Arabistan'ın turistik Mekke şehrinde aylık ve yıllık belediye su üretimini tahmin etmek amacıyla yapay sinir ağı modeli geliştirmeyi amaçlamaktadır. Bu sayede, ziyaretçi sayısının su tüketimi üzerindeki etkisi analiz edilerek su üretim planlamasının optimize edilmesi hedeflenmektedir.
2016	Tivari vd.	ELM, Wavelet Analizi (W), Bootstrap (B)	Max-min sıcaklık, yağış, geçmiş su tüketim verileri, Gün, Ay, yıl, Resmi tatil ve özel günler	Çalışma, Montreal, Kanada'da günlük kentsel su talebini tahmin etmek amacıyla, Wavelet Analizi (W) ve Bootstrap (B) yöntemleriyle birlikte veya tek başına kullanılan Extreme Learning Machin modellerinin kapasitesini değerlendirmeyi amaçlamaktadır.

Tablo 1'in devamı

2017	Sooji vd.	Yaşam Döngüsü Maliyet Analizi (LCCA)	İklimsel Değişkenler, Altyapı Özellikleri, Çevresel ve Ekonomik parametreler	Çalışma, iklim değişikliğinin altyapı üzerindeki kademeli ve ani etkilerini dikkate alarak, altyapının iklim değişikliğine uyum sağlaması için ekonomik bir değerlendirme algoritması geliştirmeyi amaçlamaktadır.
2017	Jithish vd.	ANFIS	Atmosfer Basıncı, Sıcaklık, Bağıl Nem, Rüzgâr Hız	Çalışma, çevresel faktörler ile evsel su tüketimi arasındaki ilişkiyi modellemek amacıyla, Adaptif Nöro-Bulanık Çıkarım Sistemi (ANFIS) tabanlı hibrit bir zeki sistem geliştirmeyi amaçlamaktadır. Bu sayede, evsel su kullanımının daha doğru tahmin edilmesi hedeflenmektedir.
2019	Gua vd.	GWT, WOA	Nüfus, GSYH, Su Kaynakları, Su tüketimi	Çalışma, su kaynakları talebini tahmin etmek amacıyla, Gri Kurt Teorisi (GWT) ve Balina Optimizasyon Algoritması (WOA) ile desteklenen bir model geliştirmeyi amaçlamaktadır. Bu sayede, su talebi tahminlerinin doğruluğunu artırmak hedeflenmektedir.
2019	Başakın vd.	SVM, KNN	PDSI değerleri (geçmiş bir, üç, altı ay)	Çalışma, Kayseri iline ait 116 yıllık Palmer Kuraklık Şiddet İndeksi (PDSI) verilerini kullanarak bir, üç ve altı ay sonraki kuraklık değerlerini tahmin etmeyi amaçlamaktadır.
2020	Baumli vd.	TOPSİS	Finansal, Siyasal-kurumsal, Teknik-altyapısal, Çevresel Faktörler	Çalışmada, Afrika'da yenilenebilir enerji altyapısına yönelik özel sektör yatırımlarını etkileyen finansal ve finansal olmayan faktörleri analiz etmek amacıyla Çok Kriterli Karar Analizi (MCDA) yöntemini kullanmıştır. Çalışma, Özel sektör yatırımlarını artırmak için hangi faktörlerin kritik olduğunu belirleme amacı taşımaktadır.
2020	İbrahim vd.	SVR, ARIMA	hava sıcaklığı, nem, yağış miktarı ve geçmiş su tüketimi verileri.	Çalışma, su dağıtım sistemlerinde gelecekteki su talebini tahmin ederek operasyonel verimliliği artırmayı amaçlamaktadır. Ayrıca, destek vektör regresyonu ve ARIMA modellerini karşılaştırarak en uygun tahmin yöntemini belirlemeyi hedeflemektedir.
2020	Turgut vd.	ANN, KNN, Random Forest	Nem, rüzgâr yönü ve rüzgâr şiddeti.	Çalışma, yapay zekâ yöntemlerini kullanarak hava sıcaklığı tahmini için bir sistem tasarlamayı ve bu sistemin doğruluk açısından değerlendirmeyi amaçlamaktadır.
2020	Elshaboury ve Marzouk	MLR, SVR, FFNN, GRNN	Boru Özellikleri, Çevresel Faktörler, İşletme Faktörleri ve Arıza Geçmişi	Çalışma, su boru hatlarının yapısal durumunu tahmin etmek amacıyla çeşitli makine öğrenimi modellerini geliştirmeyi ve karşılaştırmayı amaçlamaktadır. Bu sayede, su boru hatlarının durum değerlendirmesi ve bakım önceliklerinin belirlenmesi hedeflenmektedir.

Tablo 1'in devamı


2021	Bayrakçı vd.	Lineer Regresyon, Ridge, Lasso, GBM, XGBoost	İl, ilçe ve bitki türü	Çalışma, tarım arazilerinde bitki türü ve bölgesel özelliklere göre su tüketimini tahmin ederek sulama süreçlerini daha verimli ve sürdürülebilir hale getirmeyi amaçlamaktadır.
2022	Ağbulut	SVM, ANN, Deep Learning	GSYH, nüfus, araç kilometresi ve yıl	Çalışma, ulaşım sektörüne ilişkin enerji talebi ve CO ₂ emisyonlarını tahmin ederek Türkiye'deki çevresel sürdürülebilirliğe katkıda bulunmayı amaçlamaktadır.
2022	Nie vd.	SVR, Random Forest, KNN	Demografik ve Takvimsel Faktörler, Meteorolojik Veriler, Geçmiş Elektrik Tüketimi	Çalışma, hanehalkı elektrik talebini tahmin etmek amacıyla, sakinlerin psikolojik tercihleri ve takvim değişkenlerinin etkilerini dikkate alan hibrit makine öğrenimi tabanlı yöntemler geliştirmeyi amaçlamaktadır. Bu sayede, elektrik talebi tahminlerinin doğruluğunu artırmak hedeflenmektedir.
2023	Bayram ve Çıtakoğlu	MGGP, M5Tree, KNN	Aylık güneş radyasyonu, Rüzgar hızı, Maksimum hava sıcaklığı	Çalışma, 163 meteorolojik istasyondan alınan verilere dayalı olarak Türkiye'deki aylık referans evapotranspirasyon süreçlerini modellemek için makine öğrenimi yöntemlerini incelemektedir.
2024	Ansari vd.	Random Forest, Decision Tree, KNN, Naïve Bayes	Fiziksel, Kimyasal, Biyolojik, Parametreler	Çalışma, makine öğrenimi tabanlı modellerin su kalitesini tahmin etme ve sınıflandırma üzerindeki etkinliğini değerlendirerek, yapay zeka destekli sistemlerin su kirliliğini kontrol etme ve sürdürülebilir su yönetimi sağlamadaki potansiyeli analiz ederek ortaya koymayı amaçlamaktadır.

Bu tez çalışması, literatürde genellikle su tüketimi ve enerji ihtiyacına odaklanan araştırmalardan farklı olarak, altyapı projelerinde dağıtım debisi, içmesuyu ve atıksu proje büyüklüklerinin tahminine yönelik literatürdeki boşluğu doldurmayı hedeflemekte ve bu yönüyle çalışmaya özgün bir değer kazandırmaktadır. Çalışma, makine öğrenmesi algoritmalarının tahmin gücünü, SWARA yöntemiyle elde edilen uzman görüşleri, Temel Bileşen Analizi ve Aydeniz İklim Sınıflandırma yöntemlerini bir araya getirerek altyapı projelerine yönelik kapsamlı bir yaklaşım sunmaktadır. Bu yöntemlerin etkin bir şekilde bir arada kullanılması, çalışmanın literatüre değerli katkılar sağlamasını mümkün kılmaktadır.

Çalışma, iklim değişikliği ve sosyo-ekonomik faktörlerin altyapı projeleri üzerindeki maliyet etkilerini anlamayı amaçlamaktadır. Elde edilen bulgular, gelecekteki altyapı planlamalarında karar vericilere rehberlik edecek yenilikçi ve bilimsel temellere dayalı yönetsel kararların alınmasına katkı sağlamaktadır. Ayrıca, iklim değişikliği ve sosyo-ekonomik dinamiklerin altyapı projelerine etkilerinin öngörülmesi ve bu etkilerin yapım yönetimi süreçlerine entegre edilmesi açısından önemli bir model sunmaktadır.

1.5. İklim Değişikliği

Hava durumu, iklim ve bunların uç değerleri, inşaat mühendisliği tasarımı ve pratiğinde önemli faktörlerdir. Hava durumu, rüzgâr, sıcaklık, bulutluluk, nem, basınç vb. ile ilgili atmosferin durumu olarak tanımlanır (NOAA, 2013). Hava durumu genellikle dakika mertebesinde kısa vadeli dalgalanmaları içerir ve yaklaşık 15 güne kadar uzanır (NSIDC, 2012). İklim ise genellikle ortalama hava durumu veya daha kesin olarak, aylar ile milyonlarca yıl arasında değişen bir dönem boyunca ilgili miktarların ortalaması ve değişkenliği açısından istatistiksel tanımı olarak tanımlanır (IPCC, 2014a). Aynı zamanda, iklim bir bölgenin hava olaylarının özelliklerini ve bitki örtüsünün yapısını da tanımlar (Erdoğan, 2016). İklim değişikliği ise insan faaliyetlerinin doğrudan veya dolaylı olarak küresel atmosferin bileşimini bozması sonucunda meydana gelen değişikliklerdir (UNFCCC, 1992). İklim değişikliğinde, havada asılı parçacıklar (aerosoller), bulutlar, ozon ve sera gazları gibi farklı unsurlar önemli rol oynamaktadır. Bu unsurlar, yeryüzünün ısınmasında son derece etkili olup Şekil 1'de detaylı olarak sunulmaktadır.



Şekil 1. İklim değişikliğinin ana unsurları (Koçar, 2023)

Şekilde 1'de, güneşten atmosferin üst sınırına ulaşan GKR (kısa dalga boylu radyasyon) ve yeryüzünden salınan GUDR (uzun dalga boylu radyasyon) dalgalanmaları;

bulutlar, ozon, aerosoller, sera gazlarının iklim ile olan etkileşimleri, yeryüzündeki ışığı yansıtma (albedo) ve bitki örtüsüne varıncaya kadar iklim değişikliğine neden olan etkileşimleri göstermektedir.

Dünya'nın yaklaşık 4,5 milyar yıl önce oluştuğu kabul edilmektedir. Binlerce ya da milyonlarca yıl öncesine ait belirli bir yerdeki günlük hava durumu tam olarak bilinmese de kayalar, buzullar, ağaçlar, mercanlar ve fosillerdeki bazı dolaylı deliller geçmişte Dünya'nın iklimi hakkında bilgi sunmaktadır. Bu ipuçları, Dünya'nın ikliminin geçmişte birçok kez değiştiğini ortaya koymaktadır (TBMM, 2021).

Hükümetlerarası İklim Değişikliği Panelinin (IPCC) 5. Değerlendirme Sentez Raporu, günümüzde gözlenen iklim değişikliği hakkında aşağıdaki bulguları sunmaktadır (IPCC, 2014b):

- İklim sistemi üzerindeki insan etkisi belirgindir ve sera gazlarının son dönemlerdeki insan kaynaklı emisyonları, tarihteki en yüksek seviyelerdedir. Son iklim değişiklikleri, insan ve doğal sistemler üzerinde yaygın etkiler yaratmıştır.
- İklim sistemindeki ısınma kesindir. Kara ve okyanus yüzey sıcaklık verileri, 1880-2012 yılları arasında sıcaklık eğiliminin 0,85°C olduğunu ortaya koymaktadır. Kar ve buz miktarları azalmış, deniz seviyesi yükselmiştir.
- 1850 yılından bu yana, Dünya yüzeyindeki son üç on yıl, önceki on yıllardan daha sıcak olmuştur. Kuzey Yarımkürede 1983–2012 yılları, son 1400 yılın en sıcak 30 yılını oluşturmuştur. Okyanus ısınması, iklim sisteminde depolanan enerjinin artmasına neden olmaktadır. 1971-2010 yılları arasında biriken enerjinin %90'ı okyanuslar tarafından emilmiştir.
- Son yirmi yılda, Grönland ve Antarktika buz tabakaları kütle kaybetmiştir. Buzullar neredeyse tüm dünyada küçülmeye devam etmekte, Arktik deniz buzunu ve Kuzey Yarımküre ilkbahar kar örtüsü azalmaktadır.
- 1901'den 2010'a kadar, küresel ortalama deniz seviyesi 19 cm yükselmiştir. Deniz seviyesinin yükselme hızı, önceki iki bin yıla göre daha yüksektir.
- Karbon dioksit konsantrasyonları, sanayi öncesi dönemden bu yana, büyük ölçüde fosil yakıt emisyonları ve arazi kullanımı değişiklikleri nedeniyle %40 artmıştır. Okyanuslar, insan kaynaklı CO₂'nin yaklaşık %30'unu emmekte, ancak bu durum okyanusların asitleşmesine neden olmaktadır.

- Sanayi öncesi döneme (1850-1900) kıyasla, 21. yüzyılın sonlarına doğru (2081-2100) küresel yüzey sıcaklığının 2°C'yi aşması beklenmektedir. Bu durum, iklim sisteminde ciddi hasarlara yol açabilir.
- 1950'den bu yana, birçok aşırı hava ve iklim olayında önemli artışlar gözlemlenmiştir. Bu değişiklikler, soğuk hava şartlarının azalması, sıcak hava uç değerlerinin artması, deniz seviyelerinin yükselmesi ve şiddetli yağışların artması gibi unsurları içermektedir. Bu değişikliklerin bazıları insan etkilerine bağlanmaktadır.
- İklim değişikliğinin gıda güvenliği üzerindeki etkisi nedeniyle insanlar göç etmek zorunda kalabilir.
- Karbon bütçemizin (1900 Gt CO₂) %65'i 1870 ile 2011 yılları arasında tüketilmiş olup, 2°C hedefine ulaşmak için sadece 1000 Gt'lik bir bütçe kalmıştır.
- Yıkıcı sonuçları önlemek için hızlı hareket etme gerekliliği vardır. Muhtemel ısınmayı 2°C ile sınırlamak için gereken emisyon azaltımlarını sağlamak için alınabilecek önlemler mevcuttur (2050 yılına kadar %40-70 azaltım ve 2100'de sıfıra yakın sera gazı emisyonu).

Türkiye, orta kuşakta yer alması ve ılıman bir iklim bölgesinde bulunması nedeniyle çeşitli iklim özelliklerine sahiptir. İki yarımadadan oluşan ülke, etrafının denizlerle çevrili olması ve topografik çeşitliliği sayesinde farklı iklim ve ekosistemlere ev sahipliği yapar. Türkiye'de iklim ve biyolojik çeşitliliğin fazla olmasının birçok nedeni bulunmaktadır. Bunlar arasında enlem, karasallık derecesi, yükselti, bakı gibi matematiksel konum ve topografyaya bağlı faktörler ile jeolojik yapı ve toprak örtüsündeki farklılıklar yer alır. Türkiye ve çevresindeki hava kütlesi, bu çeşitliliği daha da zenginleştirir (Yılmaz ve Çiçek, 2016).

Aydeniz yöntemine göre gerçekleştirilen Türkiye iklim sınıflandırması çalışmaları kapsamında Türkiye'de "Çok Nemli, Nemli, Yarı nemli, Yarı Kurak, Kurak ve Çok Kurak" iklim tiplerinin olduğu görülmüştür (Erdoğan, 2016).

İklim değişikliği, dünya genelinde su kaynaklarını ve su altyapısını etkileyen çevresel değişikliklere yol açarken, aynı zamanda iklim göçleri gibi sosyoekonomik dinamikleri de tetiklemektedir. Günümüzde, dünyanın dört bir yanında olduğu gibi ülkemizde de iklim değişikliğinin etkileri hissedilmeye başlamıştır. Gelecekte ülkemizde iklim değişikliğiyle birlikte ortaya çıkabilecek en önemli sorunlar şu şekilde özetlenebilir (TBMM, 2021):

- Sıcak hava dalgaları, orman yangınları, kuraklık, sel, fırtına ve hortum gibi ekstrem meteorolojik olayların artması nedeniyle can ve mal kayıplarında artış yaşanması; sağlık, tarım, su, enerji, ulaşım gibi sektörlerde olumsuz etkiler görülmesi,
- Tarımda kuraklık ve sulama suyu yetersizlikleri nedeniyle verim düşüşü,
- Isınan ve asitleşen denizlerimizde mercan resiflerinin azalması ve istilacı türlerin ortaya çıkması sonucu balıkçılığın olumsuz etkilenmesi,
- Deniz seviyesinin yükselmesiyle birlikte kıyı erozyonu ve akiferlerin tuzlanması,
- Biyoçeşitliliğin azalması ve bazı türlerin yok olması,
- Azalan kar örtüsü nedeniyle kış turizminin düşüşe geçmesi.

Çevre koşullarındaki değişiklikler genellikle hava durumu ve iklimle ilişkilendirilen yapılar ve mühendislik sistemlerini çeşitli şekillerde etkileyebilir. İklim değişikliğinin, altyapı ve mühendislik sistemleri üzerindeki etkileri karmaşıktır ve çeşitli faktörlere bağlı olarak farklılık gösterebilir. Örneğin, yağış miktarındaki artış, su baskınlarının sıklığını ve şiddetini artırabilir, bu da drenaj sistemlerinin kapasitesini zorlayabilir. Kar ve buz yüklerindeki değişiklikler, çatılar ve köprüler gibi yapılar üzerinde ek yükler oluşturabilir. Rüzgâr hızındaki artışlar, yüksek binalar ve enerji iletim hatları gibi yapıların dayanıklılığını test edebilir. Sel riskinin artması, kıyı bölgelerindeki altyapının korunması için ek önlemler gerektirebilir (Ayyub, 2018).

İklim değişikliğine uyum konusundaki araştırmalar, dünya genelinde iklim değişikliğinin son yıllarda giderek daha ciddi zararlara yol açması ve bu etkilerin artan sıklığı nedeniyle hız kazanmıştır (Pehlivan, 2023).

Uyum (adaptasyon); ekolojik, sosyal veya ekonomik sistemlerde, mevcut ya da beklenen iklim değişikliği etkilerine yanıt olarak uygun önlemler almak şeklinde tanımlanır. Potansiyel zararları en aza indirmek ya da iklim değişikliğiyle ilgili fırsatları değerlendirmek amacıyla uygulama ve yapılarda değişiklikler yapılmasını ifade eder. Daha basit bir şekilde, toplumlar ve ülkeler, iklim değişikliğinin şu anda yaşanan etkilerine karşılık vermek ve ileride oluşabilecek etkilere hazırlık yapmak için uyum çözümleri geliştirmeli ve bu çözümleri hayata geçirmelidir (TBMM, 2021).

Özellikle gelişmekte olan ülkelerde, iklim değişikliğinin sebep olduğu olumsuz etkilerle başa çıkabilecek kapasitenin oluşturulması büyük bir önem taşımaktadır. İklimle dayanıklı yapıların ve sistemlerin inşası, önemli yatırımları gerektirmektedir. Bu bağlamda, Birleşmiş Milletler Çevre Programı (UNEP), 2030 yılına kadar iklim değişikliğine uyum maliyetinin yıllık 140-300 milyar ABD doları, 2050 yılına kadar ise 280-500 milyar ABD

doları arasında olacağını öngörmektedir. Aynı çalışmada incelenen 50 gelişmekte olan ülkenin ulusal katkı beyanlarına göre, 2020-2030 dönemi için uyum gereksinimlerinin yıllık 50 milyar ABD dolarını aştığı tespit edilmiştir. Ayrıca, 2030 yılına kadar iklim değişikliğine dayanıklı hale getirilmesi gereken altyapının maliyetinin tahmini olarak 57-95 trilyon ABD doları arasında olacağı öngörülmektedir (Pehlivan, 2023).

Dünya Bankası tarafından hazırlanan Türkiye Ülke İklim ve Kalkınma Raporu'na (CCDR) göre, Türkiye'deki 25 nehir havzasının üçte ikisinden fazlası ciddi su kıtlığı riskiyle karşı karşıya. Su arzında yüzde 10'luk bir azalmanın Türkiye'ye Gayri Safi Yurtiçi Hasıla'nın (GSYİH) yüzde 6'sı kadar bir maliyete yol açacağı, raporda ayrıca tahmin edilmektedir (World Bank, 2022). IMF'nin 2022 yılına ait raporuna göre, çeşitli uyum politikaları içinde en yüksek maliyetin, altyapı sektöründe uyum önlemleri için yapılacak yatırımlardan kaynaklandığı tahmin edilmektedir. Bu bağlamda, küresel ve ulusal düzeyde kentler ve altyapılar için maliyet analizlerinin yapılması büyük önem taşımaktadır (Pehlivan, 2023).

İklim değişikliği ve çevresel yüklerdeki değişikliklerin altyapı ve sistem performansı üzerindeki etkilerini anlamak ve yönetmek için mühendislik uygulamalarının adaptif ve esnek olmalıdır. Değişen çevresel koşullara uyum sağlamak için tasarım ve yönetim stratejilerinin, sürekli olarak gözden geçirilmesi ve güncellenmesi gerekmektedir. Mühendisler, tasarım süreçlerinde belirsizlikleri yönetmek ve gelecekteki riskleri azaltmak için yeni yaklaşımlar geliştirmelidir (Ayyub, 2018).

İklim değişikliği etkisi yarım yüzyıldan uzun bir süredir, genellikle ekoloji ve hidroloji gibi sistemlerde iklim parametrelerindeki değişikliklerin doğrudan etkilerine odaklanmıştır. İnsan yapımı sistemler genellikle insan refahını doğal çevresel kısıtlamalardan korumak için tasarlandığından, iklim değişikliğinin insan altyapıları üzerindeki etkileri özel bir ilgi konusu olmuştur. İklim ve hava olayları, insanların çoğunluğunun önemseydiği hizmetleri doğrudan etkileyebilir, örneğin konfor, rahatlık, hareketlilik, iş gücü verimliliği ve güvenlik gibi. Birçok durumda, en büyük endişeler, özellikle fırtınalar, seller, orman yangınları, kuraklıklar, sıcak hava dalgaları ve daha uzun vadeli iklim süreçleriyle bağlantılı diğer hava olaylarıyla tehdit edilen hassas alanlarda yer alan kentsel alanlarda nüfus ve hizmet yoğunlukları ile ilgilidir (Wilbanks ve Fernandes, 2018).

Su, iklim değişikliğinden doğrudan etkilenen en önemli kaynaklardan biridir. Az gelişmiş ülkelerde yaşayan her üç kişiden biri yeterli ve sağlıklı suya erişim sağlayamamaktadır. Bu bölgelerdeki hastalıkların %80'i ve ölümlerin %30'dan fazlası kirli içme ve kullanma suyundan kaynaklanmaktadır. Bu durum hem tüm dünyada hem de su

kaynakları açısından zengin sayılmayan Türkiye'de su kaynaklarının sürdürülebilir ve bütüncül bir şekilde yönetilmesinin zorunlu olduğunu göstermektedir. İçme ve kullanma suyu temini, en öncelikli konulardan biridir ve iklim değişikliği sürecinde kesintisiz su sağlanması büyük önem taşımaktadır. Artan nüfusa bağlı olarak su taleplerini karşılamak için yeni kaynakların şehirlerimize tahsis edilmesi ve mevcut şebekelerin iyileştirilerek kayıp-kaçak oranlarının makul seviyelere düşürülmesi gereklidir. Bu konuda mevzuatta belirlenen hedeflere ulaşmak için gerekli çalışmaların yapılması ve sürecin yakından izlenmesi önemlidir (TBMM, 2021).

İklim değişikliğinin su döngüsüne olan etkileri, su kaynaklarının mevcudiyetini, kalitesini ve dağılımını etkileyecektir. Su kaynaklarının yönetimi, su temini, kanalizasyon, taşkın kontrolü ve ekosistem hizmetleri gibi alanlarda değişiklikler öngörülmektedir. Aşağıda, su altyapıları üzerindeki iklim değişikliği etkilerine dair bazı önemli noktalar ele alınmıştır (Wilbanks ve Fernandes, 2018):

- İklim değişikliği, yağış miktarlarını ve su akış modellerini değiştirebilir. Bu değişiklikler, su kaynaklarının mevcudiyetini etkileyerek, bazı bölgelerde su kıtlığına, diğer bölgelerde ise aşırı su baskınlarına neden olabilir. Yağış rejimlerindeki değişiklikler, tarımsal sulama ve enerji üretimi gibi sektörleri doğrudan etkileyebilir.
- İklim değişikliği, taşkın risklerini artırabilir. Artan yağış yoğunluğu ve sıklığı, taşkın kontrol yapılarının (barajlar, setler, vb.) kapasitelerini aşmasına neden olabilir. Bu durum, altyapıların güçlendirilmesi ve yeni stratejilerin geliştirilmesini gerektirebilir.
- İklim değişikliği, su kalitesini etkileyebilir. Sıcaklık artışları, suyun kimyasal ve biyolojik özelliklerini değiştirebilir ve bu da içme suyu kalitesini ve ekosistem sağlığını tehdit edebilir. Ayrıca, artan su sıcaklıkları ve kirletici maddelerin konsantrasyonu, su ekosistemlerinin biyolojik çeşitliliğini olumsuz etkileyebilir.
- Deniz seviyesinin yükselmesi, kıyı bölgelerinde tuzlu suyun içme suyu kaynaklarına karışmasına neden olabilir. Bu durum, kıyı bölgelerinde içme suyu teminini zorlaştırabilir. Ayrıca, iklim değişikliği, yeraltı suyu seviyelerini ve yenilenme oranlarını etkileyebilir, bu da su yönetimi politikalarının yeniden değerlendirilmesini gerektirebilir.
- İklim değişikliğinin etkileri, su temini altyapısının kapasitesini ve dayanıklılığını sınavabilir. Aşırı hava olayları, su temini sistemlerinin fiziksel yapılarına zarar

verebilir ve hizmet kesintilerine neden olabilir. Bu nedenle, altyapının iklim değişikliğine karşı daha dayanıklı hale getirilmesi önemlidir.

- İklim değişikliği, su ekosistemleri tarafından sağlanan hizmetleri etkileyebilir. Su kalitesi ve miktarındaki değişiklikler, balıkçılık, rekreasyon ve doğal koruma alanları gibi ekosistem hizmetlerini olumsuz etkileyebilir. Bu hizmetlerin korunması için, entegre su yönetimi stratejilerinin benimsenmesi gerekmektedir.

İklim değişikliği, su kaynaklarının yönetimini daha karmaşık hale getirerek, uyum stratejilerinin geliştirilmesini gerektirir. Bu bağlamda, su yönetimi, risklerin azaltılması ve su kaynaklarının sürdürülebilir bir şekilde kullanılması için kritik bir role sahiptir. Su kaynaklarının korunması ve yönetimi için, yenilikçi teknolojilerin ve entegre yaklaşımların benimsenmesi önemlidir (Wilbanks ve Fernandes, 2018).

Kentsel alanlar için iklim değişikliği meseleleri ve endişeleri, iklim ve hava durumu parametreleri ve/veya olaylarına odaklanmaktadır ve bu olaylar, iklim değişikliği sonucu büyüklük veya süre olarak değişebilir. Kırılganlıklar ve riskler, ortalama sıcaklık ve sıcaklık aşırılıkları dahil olmak üzere, ısı ve/veya soğuk dalgaları; yağış miktarları ve modellerindeki değişiklikler, aşırı yağış olayları ve su baskınları dahil olmak üzere; fırtına yolları, sıklıkları ve yoğunluklarındaki değişiklikler ve deniz seviyesi yükselmesi ile ilişkilidir. Birçok durumda, değişkenlikler ve aşırılıklar, altyapılar ve kentsel sistemler için ortalamalardan daha belirgindir (Wilbanks ve Fernandes, 2018).

1.6. Altyapı ve Altyapı Projeleri

Altyapı, bir işlem veya sistemin temel bileşenlerini ifade eden ve ülkelerin ekonomik istikrarını koruması ile bireylerin yaşamlarını sürdürebilmeleri açısından kritik bir öneme sahip bir kavramdır. Kökeni 1875'te Fransızcaya, 1877'de ise İngilizceye dayanan bu terim, 'infra' (alt) ve 'structure' (yapı) kelimelerinin birleşiminden türemiştir (URL-1). Literatürde altyapı, genellikle bir kuruluş veya sisteme temel oluşturan unsurlar (tesisler, hizmetler veya kurulumlar) olarak tanımlanmaktadır (URL-2).

Amerikan Başkanlık Komisyonunun kritik altyapıların korunmasıyla ilgili raporunda altyapı, bağımsız ve genellikle özel mülkiyette olan insan yapımı sistemler veya süreçlerdir. Bu sistemler bir araya gelerek sinerji yaratarak gerekli mal ve hizmetlerin sürekliliğini sağlar. Komisyon, eksikliği veya yetersizliği savunma zaafı ve ekonomik güvensizlik yaratan sekiz kritik altyapı (telekomünikasyon, elektrik güç sistemleri, petrol ve doğal gaz,

bankacılık ve finans, su temini, kamu hizmetleri ve acil servis) belirlemişlerdir (Ellis vd., 1997).

Çeşitli endüstriler ve finansal sektör kuruluşları tarafından altyapı için bazı temel özellikler belirlenmiştir. Belirlenen bu özellikler altyapı yatırımlarının genel hatlarını çizse de gerçek yaşam koşullarında farklılık gösterebilirler. Kısaca bu özelliklerden bahsedecek olursak (Weber vd., 2016):

- Altyapı varlıkları, su, enerji, ulaşım, eğitim, güvenlik, kültür ve sağlık gibi günlük yaşamın gereksinimlerini karşılamada kritik bir rol oynar ve ekonomik büyüme, refah ve yaşam kalitesinin artırılmasına katkı sağlar.
- Altyapı hizmetlerine olan talep, işlevleri gereği genellikle ekonomik performans ve esneklikten daha az etkilenir ve altyapı yatırımları gayrisafi milli hasıla ile birlikte artış gösterir.
- Altyapı yatırımları, yüksek başlangıç maliyetleri gerektirir ve bu yatırımların taklit edilmesi zordur. Hizmet vermeye başladıktan sonra üretilen her bir ürün ve hizmetin maliyeti, başlangıç maliyetlerine göre düşüktür. Piyasada altyapıya yönelik rekabet genellikle sınırlıdır veya hiç yoktur.
- Düzenleyici kurumlar, minimum ödeme garantisi ve sabit fiyatlar gibi mekanizmalarla piyasayı düzenlerler. Ancak, piyasa riski tamamen ortadan kaldırılamaz.
- Altyapı yatırımları genellikle 100 yıl veya daha uzun bir süre hizmet verir. Bu yatırımların fiziksel ve teknik ömrüne ek olarak, ekonomik ömrü de önemlidir. Yatırımcılar, varlığın ekonomik ömrü boyunca yatırımlarının aşınma payını da dikkate alır.
- Altyapı yatırımları, doğal bir enflasyon koruma mekanizmasına sahiptir. Enflasyonu belirleyen faktörlerle uyumlu olan bu yatırımlar, düzenli gelir, sözleşme garantileri ve benzeri yollarla finanse edilir.
- Altyapı varlıkları, öngörülebilir ve enflasyona karşı koruyucu uzun vadeli gelir sağlar. Bu da ekonomik krizler ve dalgalanmalarda destek ve çözüm sunar.

İçilebilir su, dünya genelinde oldukça sınırlı ve hayati bir doğal kaynaktır. Dünya üzerindeki suyun yaklaşık %97,5'i tuzlu, %2,5'i de tatlı sudan oluşmakta olup bu miktarın da yalnızca %0,3'ü içilebilir durumdadır. Su kaynakları; su kıtlığı, kirlilik ve iklim değişikliği nedeniyle olumsuz etkilenmektedir. Özellikle Kuzey Afrika ve Orta Doğu'daki ülkeler su kıtlığı yaşamakta, temiz suya erişimi büyük bir sorun olmaktadır. Sanayi, tarım ve


şehirleşme su kalitesini ciddi oranda düşürmekte, sağlık için risk teşkil etmektedir. İklim değişikliği de yağışların düzensizliği, kuraklık gibi nedenlerle su kaynakları üzerinde olumsuz etki yapmaktadır (URL-3).

Türkiye yarı kurak iklim özelliklerine sahip olup yağış rejimi iklim ve mevsimsel özelliklere bağlı olarak farklılık göstermektedir. Yıllık ortalama yağış miktarı 574 mm, yıllık yağış miktarı ise 450 milyar metreküp civarlarındadır. 2023 yılında teknik ve ekonomik koşullar çerçevesinde, yerüstü suyu potansiyeli 91,9 milyar m³, yer altı su potansiyeli de 18 milyar m³ olup tüketilebilir su potansiyeli yılda ortalama 110,5 milyar m³'tür. Sektörel bazda ise 39,6 milyar m³ (%74) tarımsal alanda, 12,0 milyar m³'ü (%22) ise içme – kullanma suyu olarak, 1,8 milyar m³'ü (%3) de sanayide kullanılmaktadır (DSİ, 2023).

Ülkeler, su varlığına göre sınıflandırılabilir. Kişi başına yıllık kullanılabilir su miktarı 1000 m³'ten az olan ülkeler 'su fakiri', 2000 m³'ten az olan ülkeler "su stresi (azlığı) olarak kabul edilmektedir. Ülkemizde, kişi başına düşen yıllık kullanılabilir su miktarı ise 2000 yılında 1652 m³, 2010 yılında 1519 m³, 2023 yılın da ise 1294 m³ olarak ölçülmüştür. Bu durum ülkemizin artan nüfusla birlikte ileriki yıllarda, su krizi yaşamaya doğru ilerlediğini göstermektedir (DSİ, 2023).

Gelişmiş ülkelerde altyapı projelerine verilen önem oldukça yüksektir. Güçlü teknik, sosyal ve ekonomik altyapı, bireylerin ihtiyaçlarını etkin bir şekilde karşılamaktadır. Buna karşılık, Üçüncü Dünya Ülkelerinde altyapı yetersizdir ve sunulan imkanlar sınırlıdır. Altyapı varlıkları, caddelerin aydınlatılması, enerji temini, ulaşım, atıkların toplanması ve bertarafı ile iletişim hizmetleri gibi günlük yaşamın pek çok alanında kullanılır. Bu yatırımlar büyük sermaye gerektirir ve devletler, özel şirketler ile çok uluslu yapılar bu yatırımlara katılmaktadır. Altyapı, ulaşım, içme suyu ve atık su, katı atık, enerji, elektrik ve doğal gaz gibi sektörlerle ayrılmaktadır ve bu sektörlerle yönelik projelerle ihtiyaçlar karşılanır (Köseoğlu, 2018).

Bu tez çalışmasının asıl konusu, iklim değişikliği ve sosyo-ekonomik değişkenlerin içmesuyu ve atıksu altyapı projelerinin üzerindeki etkileri olduğundan, bunlara ait altyapı alt sektörü incelenecektir. Söz konusu altyapı türü, suyun kaynaktan kullanıcıya kadar ulaşmasını (temin edilmesi, dağıtılması, atık suyun toplanması) ve ardından güvenli bir şekilde bertaraf (arıtma ve deşarj) edilmesini sağlayan elemanlar bütünüdür. Su temin tesislerine ilişkin su ve kanalizasyon altyapısının sistemik hali Şekil 2'de sunulmaktadır.



Şekil 2. Su ve kanalizasyon altyapısının hizmetlerinin sistematik yapısı (Sevim, 2018)

Türkiye'de içme ve atıksu altyapı projelerinin planlanması, inşası, yönetimi ve denetiminden sorumlu olan çeşitli kurum ve kuruluşlar bulunmaktadır. Bu projeler, hem kentleşmenin hızla arttığı bölgelerdeki ihtiyaçlara yanıt vermek hem de sürdürülebilir kalkınma hedeflerini desteklemek amacıyla hayata geçirilmektedir. Altyapı projeleri için başlıca sorumlu kurum ve kuruluşların görevleri şu şekildedir:

- i) Devlet Su İşleri (DSİ) Genel Müdürlüğü, Su kaynaklarının geliştirilmesi ve yönetilmesi, barajlar ve su depolama yapılarının inşası, sulama projeleri ve içme suyu temin projelerinin planlanması ve uygulanması.
- ii) Belediyeler-Su ve Kanalizasyon İdareleri (SKİ): Şehir içi içmesuyu ve atıksu sistemlerinin planlanması, ihale edilmesi inşası, işletilmesi ve bakımı ve su tüketiminin izlenmesi.
- iii) İller Bankası (İLBANK) Genel Müdürlüğü: Belediyelere içme suyu ve atıksu altyapı projeleri için finansman sağlamak, proje yönetimi desteği vermek ve teknik yardım (planlama, proje, ihale, yapım) sunmak.

Su ve atıksu projeleri, şehirlerin altyapısının temel bileşenleri arasında yer alır ve insan sağlığını, çevre korumayı ve sürdürülebilir kalkınmayı hedefler. Bu tür projelerin yönetimi, çeşitli süreçler içermekle birlikte planlama, tasarım, ihale, sözleşme, inşaat, işletmeye alma ve bakım gibi çeşitli aşamalardan oluşur. Su ve atıksu altyapı projelerinin yönetim süreçleri şu şekilde açıklanabilir (Alegre vd., 2013; Chong vd., 2016):

- i) Proje Tanımı ve Planlama: Yapılacak altyapı mahallinin mevcut durumu incelenir. Fizibilite ve çevre etki çalışmaları yapılır. Mevcut su kaynakları belirlenir ve müstakbel nüfus projeksiyonlarına göre su ihtiyacı tespit edilir.
- ii) Tasarım: Bu aşamada mühendislik hesaplamaları, hidrolik analizler, malzeme seçimi, projelendirme, şartnameler, maliyet hesapları ve çevresel etki değerlendirmeleri yapılır.
- iii) İhale ve Sözleşme: Kesin altyapı projesinin şartnamelere uygun bir şekilde tatbik edilmesi için tedarikçi firmalar seçilir ve sözleşme imzalanır.
- iv) İnşaat (Uygulama): Sözleşme sonrasında; iş programı, saha denetimi, işçi sağlığı ve iş güvenliği önlemleri, kalite ve bütçe kontrolü altında, kazı, boru döşeme, sanat yapıları ve tesislerin fiili inşa süreçlerini içerir.
- v) İşletme: İnşa süreci tamamlanan tesislerin, test edilmesi ve devreye alınma sürecidir. Tasarım aşamasında belirlenen kriterlere (standart, şartname) uygunluk kontrolü yapılır.
- vi) Bakım: Altyapılar uzun ömürlü olması için sıklıkla bakım ve onarımlardan geçirilmelidir. Scada sistemleriyle izlemelere yapılmakta, arıza ve sızmalar takip edilmektedir.

Kentsel alanlar içerisinde, altyapı sistemleri suyun önemi nedeniyle kıyılara, göllere veya nehirlerle yakın konumlanmıştır (Wilbanks ve Fernandes, 2018). Kentsel alanların benzersiz koşullara ve kırılganlıklara sahip olduğu dikkate alındığında iklim etkilerine karşı savunmasız olan altyapı türleri arasında çok sayıda bağımlılık bulunmaktadır. İklim etkileri, deniz seviyesi yükselmesi ve fırtına dalgaları gibi aynı coğrafi alanda bulunan tüm altyapıları birbirini tamamlayan etkilerle etkiler (Kirshen vd., 2008).

Altyapı hizmetlerinin sürekliliği ve güvenilirliği, modern toplumlar için kritik öneme sahiptir. İklim değişikliği, içme suyu ve atıksu altyapısının performansını ve dayanıklılığını etkileyerek, bu hizmetlerin sürekliliğine ve kalitesine doğrudan etkiler yapabilir. Sıcaklık artışları, değişen yağış rejimleri, ani hava olayları, deniz seviyelerindeki yükselmeler gibi etkiler ile aşırı kuraklık, taşkınlar, fırtınalar ve iklim göçleri, su kaynaklarının sürdürülebilirliği ve altyapı üzerinde ciddi bir risk konusudur. İklim değişikliğinin içmesuyu ve atıksu altyapıları üzerindeki muhtemel kırılganlıkları aşağıda sıralanan maddeler halinde açıklanabilir (Bates vd., 2008; Delpla vd., 2009; Nicholls ve Cazenave, 2010; Wilbanks ve Fernandes, 2018):

İçmesuyu altyapısında:

- i) İklim değişikliği neticesinde su kaynaklarının azalması, içmesuyunun arzında problem oluşturabilir bu durum da içmesuyu temininde güvensizlik ve altyapı üzerinde baskıyı arttırabilir. Su arzında yaşanılacak belirsizlikler, yönetim ve yatırım politikalarını doğrudan etkileyebilir.
- ii) Şiddetli yağışlar ve sel olayları neticesinde, yüzey sularının kirliliği artabilir. Bu durum da arıtma süreçlerini zorlaştırarak ilave bir maliyet oluşturabilir.
- iii) Özellikle kıyı şehirlerde, deniz seviyelerindeki yükselmeler, yeraltı ve yer üstü suların tuzlanmasına neden olabilecek olup bu durum da su kalitesinin bozulması yanında ilave bir arıtma maliyetlerine sebebiyet verebilir. Ayrıca kıyı şeritlerde bulunan yerleşim yerlerinin içmesuyu altyapısının korunması için ilave önlemler alınmasını gerekli kılar.
- iv) Su arzının aksamaması için bulunan yeni su kaynaklarının yerleşim yerlerine iletimi sırasında kullanılan enerji miktarları artması ilave enerji maliyetlerinin yanında enerji verimliliği kritik hale getirir.
- v) Susuzluk, kuraklık gibi nedenlerle göç eden nüfus, çoğunlukla büyük şehirlerde yoğunlaşır, bu da bu şehirlerdeki su altyapısı üzerinde yoğunluk ve büyük bir baskı yaratır. Özellikle plansız ve hızlı şehirleşme, su altyapısının hızla aşırı yüklenmesine ve hizmet kesintilerine yol açabileceğinden su temini altyapısının sürdürülebilirliğini tehdit eder.

Atıksu altyapısında:

- i) İklim değişikliği, ani ve yoğun yağışları tetikleyebileceğinden, atıksu altyapısının da taşma riskini arttırır. Bu durumda, atıksu arıtma tesislerinin kapasite aşımına ve atık suyun çevreye yayılmasına neden olabilir
- ii) Kuraklık dönemlerinde, atıksu tesislerine giren su azalması, tesisin veriminin azalmasına ve karmaşık hale gelmesine neden olabilir. Aynı şekilde deniz suyunun yükselmesi sonucu, tesise giren tuzlu su sistemi aksatabilir.
- iii) Özellikle su kıtlığı yaşanan yerlerde, atıksuların ileri derecede arıtma teknolojileriyle arıtılıp yeniden kullanıma sunma talebini arttırabilir.

Altyapı sistemlerinin iklim değişikliğine adaptasyonu, gelecekteki potansiyel etkileri en aza indirmek ve toplumların daha dayanıklı hale gelmesini sağlamak için önemlidir. İklim değişikliği ile mücadelede, altyapı sistemlerinin sürdürülebilir ve esnek hale getirilmesi için stratejik ve yenilikçi yaklaşımlar benimsenmelidir. Altyapı sistemlerinin iklim değişikliğine

adaptasyonu, potansiyel etkilere karşı dayanıklılığın artırılması ve hizmet sürekliliğinin sağlanması açısından büyük önem taşır. Adaptasyon stratejileri hem mevcut altyapıların güçlendirilmesini hem de yeni ve yenilikçi altyapı çözümlerinin geliştirilmesini içerir. İklim değişikliğiyle başa çıkmak için aşağıdaki stratejiler dikkate alınmalıdır (IPCC, 2014a; ASCE, 2015; Wilbanks ve Fernandes, 2018):

- İklim değişikliği risklerinin değerlendirilmesi ve bu risklere karşı alınacak önlemler, karar vericilerin daha bilinçli seçimler yapmasına olanak sağlayarak altyapı sistemlerinin dayanıklılığını artırmada kritik öneme sahiptir.
- Mevcut altyapıların iklim değişikliğine adaptasyonu için teknolojik ürünlerin kullanılması bu sürece yardımcı olabilir. Örneğin, sel taşkınına karşı geçirgen yüzeyler kullanmak, akıllı su şebekelerine geçişi.
- Altyapı yatırımlarının planlanması ve yönetilmesinde iklim değişikliği dikkate alınarak uygun politikalar ve düzenlemeler oluşturulması, adaptasyonu için önemlidir. Ayrıca adaptasyon sürecini destekleyen yasal düzenlemeler, altyapı projelerinin sürdürülebilirliğini artırabilir.
- Altyapı sistemlerinin adaptasyonu için yeterli finansman ve kaynak tahsisi bu süreç için kritik bir faktördür. İklim değişikliğine uyum sağlamak için yapılacak yatırımlar, uzun vadede büyük ekonomik ve sosyal faydalar sağlayabilir.
- Yerel toplulukların ve paydaşların ihtiyaçları ve beklentileri dikkate alınarak katılımı, adaptasyon sürecine önemli katkı yapabilir.

Bu uyum kapsamında, özellikle altyapı yatırımları için gerçekleştirilecek faaliyetlerin maliyet tahmini ve finansman ihtiyacı konusunda sağlıklı verilere ulaşmak, dünya genelinde gelişmiş ülkelerde bile oldukça sınırlı ve zorludur. Türkiye'de de ulusal ve bölgesel düzeyde sektörel bazda veri ve bilgiye erişim son derece kısıtlıdır. Günümüze kadar gerçekleştirilen çalışmaların sonuçlarına göre, mevcut yapıların iklim değişikliğine dirençli hale getirilmesi için alınacak güçlendirme önlemleri nispeten maliyetli bir seçenek olarak değerlendirilmektedir (Pehlivan, 2023).

1.7. Çok Ölçütlü Karar Verme (ÇÖKV) Yöntemleri

Karar verme, farklı faktörlerin ve karar alıcıların beklentilerinin dikkate alındığı, alternatiflerin oluşturulması ve değerlendirilerek en uygun çözümün belirlenmesi sürecidir. Bu süreç; mevcut bilgi, alternatif seçenekler, karar kriterleri ve bireysel-kurumsal değerlerin

bir araya geldiği bir karar ortamında gerçekleştirilir. Ancak, özellikle karmaşık problemlerde, alternatiflerin değerlendirilmesinde kullanılan kriterlerin çeşitliliği ve bu kriterler arasındaki potansiyel çatışmalar, karar verme sürecini zorlaştırmaktadır. Karmaşık durumların analiz edilmesi, daha gelişmiş yöntemlerin kullanımını zorunlu kılmaktadır (Korucuk, 2018). Bu bağlamda, Çok Ölçütlü Karar Verme (ÇÖKV) yöntemleri, birden fazla ve çoğu zaman birbiriyle çelişen kriterlerin eşzamanlı değerlendirilmesine olanak sağlayan analitik yaklaşımlar sunmaktadır. ÇÖKV yöntemleri, karar alıcıların ölçülebilen ve ölçülemeyen stratejik faktörleri bir arada ele alarak daha etkin ve bilinçli kararlar vermesini mümkün kılar (Majeed ve Breesam, 2021).

Örneğin, bireysel bir karar olarak yeni bir araç satın alma sürecinde fiyat, yakıt tüketimi, güvenlik özellikleri, marka itibarı, servis ağı ve ikinci el değeri gibi birden fazla kriter değerlendirilir. Farklı ölçütlerin aynı anda değerlendirilmesi, karar süreçlerinin daha bilinçli ilerlemesine olanak tanır. Kurumsal düzeyde bir yatırım kararı, finansal getiriler, riskler, maliyet etkinliği, pazar payı, likidite ve çevresel etkiler gibi çok boyutlu kriterleri içerebilir. Tek bir kritere dayalı analizlerin bu tür durumlarda yetersiz kalması nedeniyle ÇÖKV yöntemleri, alternatiflerin kapsamlı ve sistematik bir şekilde değerlendirilmesini sağlamaktadır. Analitik yaklaşımların sunduğu çözümler hem bireysel hem de kurumsal düzeyde etkili sonuçlar elde edilmesini sağlar (Zavadskas vd., 2018).

ÇÖKV sürecinde kullanılan yöntemlerden bazıları olan Analitik Hiyerarşi Süreci (AHP), Aşamalı Ağırlık Değerlendirme Oranı Analizi (SWARA), İdeal Çözüme Benzerlik ile Tercih Sıralaması Tekniği (TOPSIS) ve Gerçekliği İfade Eden Eleme ve Tercih Yöntemi (ELECTRE) gibi teknikler, karar problemlerine farklı yaklaşımlar sunmaktadır. Her yöntemin belirli bir probleme özgü avantajları, karar süreçlerini daha sistematik hale getirir. Bu yöntemlerin seçimi, karar probleminin yapısına, çözüm sürecinde yer alan kriterlerin doğasına ve karar alıcıların önceliklerine göre şekillenmektedir. Ayrıca, her yöntemin sağladığı çözüm sonuçlarının hassasiyeti, kullanılan verinin kalitesi ve miktarı ile doğrudan ilişkilidir.

Söz konusu yöntemler, mühendislik, yönetim, ekonomi ve sosyal bilimler gibi çeşitli disiplinlerde karmaşık karar problemlerine yönelik çözüm araçları olarak kullanılmaktadır. Çok boyutlu ve çok ölçütlü karar süreçlerinde ÇÖKV yöntemleri, karar alıcıların analitik ve sistematik yaklaşımlarla en uygun seçeneği belirlemelerine olanak tanımaktadır. Bu nedenle, her yöntemin varsayımlarını, hesaplama süreçlerini ve karar problemlerine uygunluğunu dikkate alarak doğru yöntemin seçimi, etkin karar verme süreçlerinin temel taşıdır.

1.7.1. SWARA Yöntemi


SWARA (Aşamalı Ağırlık Değerlendirme Oranı Analizi) yöntemi, çok kriterli karar verme süreçlerinde sıklıkla kullanılan, kriterlerin (parametrelerin) göreceli önemini adım adım belirleme yeteneğiyle öne çıkan etkili bir yöntemdir. 2010 yılında Kersulienė ve çalışma arkadaşları tarafından geliştirilen bu yöntem, özellikle hukuki, sosyal ve ekonomik konularda, çözüm alternatiflerinin değerlendirilmesi için tercih edilmektedir (Kersulienė vd., 2010). Yöntemin temel prensibi, karar problemlerinin çözümünde uzmanların görüşlerini değerlendirmesine dayanmaktadır. Yöntemin dikkat çeken özelliklerinden birisi de parametre ağırlıklarını belirleme sürecini, basit ve anlaşılır bir çerçevede sunmasıdır; bu yönüyle Analitik Hiyerarşi Süreci gibi geleneksel karar verme yöntemleriyle benzerlik gösterirken, basitlik ve hız açısından uygulayıcılara avantaj sağlamaktadır (Çakır ve Akar, 2019).

SWARA, aynı zamanda parametre önceliklerini belirlerken kurumların stratejilerine ve spesifik hedeflerine uyum sağlayarak, işletmelerin ihtiyaçlarına göre esneklik sunar (Korucuk, 2018). Bu özellik, yöntemin lojistik, mühendislik, sürdürülebilirlik değerlendirmeleri, risk yönetimi ve kaynak tahsisi gibi çok çeşitli alanlarda uygulanabilirliğini artırmaktadır.

SWARA yönteminin uygulama süreci, öncelikle ilgili parametrelerin sıralanmasıyla başlamakta ve uzmanların görüşlerine göre parametrelerin birbirine göre önem dereceleri belirlenmektedir. Daha sonra, parametrelerin ağırlıkları göreceli önem düzeyine göre hesaplanarak alternatiflerin değerlendirilmesi sağlanmaktadır. Alternatifler arasında en uygun seçenek, hesaplanan ağırlıklı skorlar üzerinden belirlenir ve karar vericilerin tercihlerini destekleyen bir sistematik yapı ortaya konur (Radovic ve Stevic, 2018).

Yöntemin başarısı, karar sürecine birden fazla alanında uzman ve karar vericinin katılımına bağlı olup bu da daha kapsayıcı ve rasyonel sonuçların elde edilmesine katkı sağlar. Bununla birlikte, yöntem uzman görüşlerine dayandığı için subjektif yargıların karar sonuçlarını etkileyebileceği eleştirisine açıktır. Özellikle parametre sayısının artması, hesaplamalarda karmaşıklığa ve hatalara yol açabileceği için dikkatli bir uygulama gerektirmektedir. Yöntemde, sıralama en önemli parametreyle başlar ve en az önemli olan parametre ise en sonudur (Zavadskas vd., 2018).

Parametre önceliklerinin SWARA yöntemiyle belirlenme süreci, Şekil 3'te detaylı olarak gösterilmektedir.



Şekil 3. SWARA yöntemi ile parametre önceliklerinin belirlenmesi (Çakır ve Akar, 2019)

Yukarıdaki şekilde SWARA yönteminin ilerleme süreci, adım adım olarak verilmiştir. Özellikle bu yöntemde uzman karar vericiler, değerlendirmelerde ve ağırlıkların hesaplanmasında önemli bir role sahiptir. Dolayısıyla her bir karar verici her bir parametrenin önem düzeyini seçmektedir. Daha sonra, her bir uzman karar verici kendi bilgisi ve deneyimlerini kullanarak belirlenen tüm parametreleri, ilkinden sonuncusuna kadar sıralar. Bu yöntemle göre en önemli parametre birinci sırada, en önemsiz parametre ise en son sırada olmak üzere sıralanır.

Bir karar verme sürecinde yer alan parametrelerin listesi tanımlanıp oluşturduktan sonra, SWARA yöntemi aşağıdaki adımlar yardımıyla analiz edilir (Kersuliene vd., 2010).

Adım 1: Belirlenen parametrelerin sıralanması:

Parametreler önem derecelerine göre sıralanmalıdır. Bu aşamada uzmanlar, tanımlanan parametreleri sahip oldukları önem düzeyine göre sıralarlar, örneğin en önemli olan birinci sırada, en önemsiz olan son sırada yer alır, aradaki geometrik oran farkı parametrelerin önem derecesine sahiptir.

Adım 2: Tüm parametreler için göreceli ortalama önem düzeyinin belirlenmesi:

İkinci sıradaki parametreden hareketle önem derecelerini belirler. j . parametrenin $(j+1)$. parametreden ne kadar önemli olduğu belirlenir. 2010 yılında Kersulienne tarafından geliştirilen (s_j) parametre, ortalama değerin karşılaştırmalı önemini değerlendirir.

Adım 3: k_j katsayısını aşağıdaki denklemde hesaplanarak belirlenmesi:

Tüm parametreler için k_j değeri, Eşitlik (1) kullanılarak hesaplanır.

$$k_j = \begin{cases} 1, & j = 1 \\ s_j + 1, & j > 1 \end{cases} \quad (1)$$

Adım 4: Belirlenen tüm parametreler için uyum ağırlıkları (q_j), değişken katsayısının denklemi eşitlik (2) kullanılarak hesaplanır.

$$k_j = \begin{cases} 1 & j = 1 \\ \frac{q_{j-1}}{k_j} & j > 1 \end{cases} \quad (2)$$

Adım 5: Toplamı bire eşit olan parametrelerin ağırlık değerlerini hesaplayarak parametrelerin önem ağırlıkları belirlenmesi:

Parametrelerin göreceli ağırlıkları denklem (3) ile hesaplanmakta olup (w_j) ise parametrelerin göreceli ağırlık değerini temsil eder.

$$w_j = \frac{q_j}{\sum_{k=1}^n q_k} \quad (3)$$

1.8. Temel Birleşen Analizi (Principal Component Analysis)

PCA, karmaşık ve yüksek hacimli veri setlerinin boyutunu indirgemek için kullanılan istatistiksel bir tekniktir. Bu teknik, en fazla bilgiyi içeren ana bileşenleri ayırt ederek önemsiz verileri veri setinden çıkarırken, önemli detayları da korur. PCA, bunu yaparken en


fazla varyansı temsil eden ana bileşenler oluşturarak hem veri setinin boyutunu azaltır hem de daha basit hale getirir (Jolliffe, 2016).

Bir veri setindeki değişken sayısını azaltmak, veri setindeki bazı detayları atlaması (nonlineerlik, ölçeklendirme) gibi hassasiyet düşürme durumları göz önünde bulundurulmalıdır. Boyut küçültmenin amacı, bazı verilerden yani hassasiyetten vazgeçilmesi demektir. Düşük boyutlu verileri incelemek daha kolay ve hızlı olduğundan, özellikle makine öğrenmesi algoritmaları bu verilerin analizini kolaylaştırmaktadır (Abdi ve Williams, 2010).

PCA, çok boyutlu veri setlerindeki değişkenlerin varyansını açıklamak için bu değişkenleri birkaç yeni bileşene indirger. Bu yeni bileşenler, orijinal veri setinin en yüksek varyansa sahip yönelimlerini temsil ederken veri setindeki en fazla bilgi korunmuş olunur. PCA'nın temel adımları şu şekildedir (Shlens, 2014):

1. Veri Normalizasyonu: Veriler farklı ölçekte olması durumunda, her değişkene eşit ağırlık verilmesi için genellikle standartlaştırma işlemine tabi tutulur.
2. Kovaryans Matrisi Hesaplama: Veri setindeki değişkenlerin birbirleriyle olan ilişkilerini ölçmek için kullanılır.
3. Özvektörler ve Özdeğerler: Kovaryans matrisinin özvektörleri ve özdeğerleri hesaplanır. Özvektörler, bileşenlerin doğrultusunu belirlerken, özdeğerler her bileşenin açıklayabileceği varyans miktarını gösterir.
4. Bileşenlerin Seçimi: En büyük özdeğerlere sahip bileşenler seçilir.
5. Ortogonallik: Bileşenlerin birbirine dik ve bağımsız biçimini ifade eder. Bu özellik, bileşenler arasında herhangi bir bilgi tekrarı olmadığını ve her bir bileşenin veri setindeki farklı bir varyans boyutunu temsil ettiğini garanti eder.
6. Yeni Veri Seti (Görselleştirme): Veriler, seçilen başlıca bileşenler kullanılarak yeni bir uzaya dönüştürülür.

PCA, veri setindeki toplam değişken sayısını sınırlandırırken mümkün olduğunca ayrıntıyı koruyacak şekilde tasarlanmıştır. Bu işlem uygulandıktan sonra değiştirilmiş yeni özellikler, ana bileşen (PC) olarak adlandırılır. PC sayısı, veri setindeki değişken sayısına eşit veya daha azdır. PC_1 'den PC_n 'ye kadar her bir bileşenin önemi azalmakta olup PC_1 en önemli, PC_n 'nin ise en az önemli olduğunu gösterir. Çok boyutlu ve karmaşık veri setlerini daha az sayıda bileşenle temsil edebilmek için varyans maksimizasyonu ve boyut indirmesi Şekil 4'te gösterilmektedir (Abdi ve Williams, 2010; Shlens, 2014).




Şekil 4. PCA veri boyut indirgeme şeması

Çoklu-doğrusallık, eksik sayılar, kategorize edilmiş veriler ve hassas olmayan metrikler gibi birçok durumu içeren veri setlerini analiz etmek için oldukça uyarlanabilir bir yaklaşım olan PCA, veriden temel detayları çıkarır ve bunları ana bileşenlerce kapsamlı olarak yansıtmaları neticesinde mühendislik uygulamalarında sıklıkla kullanılmaktadır. Veri boyutunu azaltma, gürültü (hata) filtreleme, özellik çıkarımı ve görselleştirme gibi özellikleri sayesinde, makine öğrenmesi algoritmaları veri analizi ve modelleme süreçlerinde önemli faydalar sağlamaktadır. Ancak bileşen analizlerinin lineer ilişkilerle sınırlı olduğu ve veri setinde bilgi kaybı yaşanma ihtimali göz önünde bulundurulmalıdır (Yan vd., 2007; Huang vd., 2014; Cai vd., 2018).

1.9. Yapay Zekâ

Yapay zekâ kavramı, tarihte ilk kez 1956 yılında bilgisayar bilimci John McCarthy tarafından “insan benzeri zeki makinelerin, zeki bilgisayar programı yapma bilimi” olarak ifade edilmiştir (Alpaydın, 2013).

İnsan zekasını taklit edebilen yapay zekâ; bilgisayarların anlama, öğrenme, karar verme, problem çözme gibi görevleri yerine getirilmesine yardımcı olarak algoritmalar geliştirmeye odaklanır. AI, kapsam olarak, makine öğrenmesi, derin öğrenme, yapay sinir ağları, bilişsel hesaplama, doğal dil işleme, bilgisayarla görme gibi alt dallarla ayrılır (Aylak vd., 2021). Bunlardan sıklıkla kullanılanları, makine öğrenmesi ve yapay sinir ağları olup aralarındaki ilişki Şekil 5’te gösterilmektedir.




Şekil 5. Yapay zekâ, makine öğrenmesi ve yapay sinir ağları ilişkisi (URL-4)

Şekil 5'ten de görüleceği üzere, yapay sinir ağları (YSA), makine öğrenmesinin bir alt kümesi olup, verilerden öğrenme yeteneğine sahip bir yöntemdir. YSA, makine öğrenmesinin diğer algoritmalarından, biyolojik sinir ağlarından ilham alarak geliştirilen katmanlı yapısıyla ayrılır. Bu yapı, giriş verilerini işleyerek karmaşık ilişkileri öğrenmeyi mümkün kılar.

Makine öğrenmesi (ML) ise, YSA gibi çeşitli algoritmalar kullanarak bilgisayarların karar alma ve tahmin süreçlerini gerçekleştirdiği geniş bir alandır. ML, insan müdahalesine gerek kalmadan verilerdeki örüntüleri keşfederek bu görevleri yerine getirir. Hem yapay sinir ağları (YSA) hem de diğer makine öğrenmesi teknikleri (SVR, KNN, XGBOOST, vs.), yapay zekânın (AI) bir alt dalını oluşturur ve algoritmalar geliştirerek öğrenme, tahmin ve problem çözme süreçlerini destekler (Bingöl vd., 2020).

Makine öğrenmesinin temel bileşenleri; veri, özellikler, model ve algoritmadır. Veriler, çalışmanın amacına uygun toplanabilen datalardır. Özellikler, verilerden elde edilen ve eğitim için gerekli özniteliklerdir. Model, veriler üzerinde, girdi ve çıktıya dayalı tahmin yapılacak fonksiyonu ifade etmektedir. Algoritma da modelin nasıl öğreneceğini belirleyen çalışma kümesidir (Murphy, 2012; Raschka ve Mirjalili, 2017; Geron, 2019).


Makine öğrenmesi, genellikle üç temel yaklaşım altında incelenmektedir. Sıklıkla kullanılan makine öğrenmesi türleri Şekil 6'da gösterilmektedir (Bishop, 2006; Murphy 2012, Aylak vd., 2021).



Şekil 6. Makine öğrenmesi türleri

Denetimli Öğrenme (Supervised Learning): Bu yaklaşımda, model, etiketli (niteliği bilinen) verilerle eğitilir, yani model hem giriş verisini (features) hem de bu girişlere karşılık gelen doğru çıkışı (labels) görür. Model, bu ilişkiyi öğrenerek yeni, etiketlenmemiş veriler üzerinde doğru tahminlerde bulunmayı öğrenir.

Denetimsiz Öğrenme (Unsupervised Learning): Bu türde, algoritmik model etiketlenmemiş veriler ile eğitilir. Bu verilerde sadece girdi bulunur ve istenen çıktı bilinmez. Algoritma, verilerdeki örüntüleri ve gizli ilişkileri keşfederek verileri kümeleme veya boyut azaltma gibi görevleri yerine getirir. Pekiştirmeli öğrenmede ise deneme-yanılma ile algoritma bir ortamla etkileşime girerek ve aldığı ödülleri veya cezaları gözlemleyerek öğrenir. Tüm bu bilgilere ilişkin, denetimli ve denetimsiz öğrenmenin şematik gösterimi Şekil 7’de gösterilmiştir.



Şekil 7. Denetimli ve denetimsiz öğrenme süreçleri


Sınıflandırma ve regresyon (tahmin) problemleri, denetimli öğrenmenin en yaygın uygulamaları arasındadır. Regresyon, sonsuz olasılığa sahiptir ve sonucu tahmin etmek için kullanılır. Sınıflandırma, çıkışın evet veya hayır olarak sınıflandırıldığı durumlarda kullanılır. Makine öğrenmesi süreci, veri setlerinin analizi ve bu verilerden model geliştirilmesi esasına dayanmaktadır. Bu süreç, temel olarak aşağıdaki süreçlerden oluşur (Domingos, 2012; Bergstra ve Bengio, 2012; Geron, 2019):

- i) Veri Toplama: ML sürecinin ilk adımı olarak uygun verilerin toplanmasıdır.
- ii) Veri Ön İşleme: Toplanan verilerin; gereksiz olanların ayıklanması, eksik veri varsa takviye yapılması, verilerin normalizasyonu ve özellik mühendisliği gibi değerlendirilme sürecini kapsar.
- iii) Model Eğitimi: Seçilen veriler bölümlere ayrılarak, model eğitilir. Kullanılacak algoritma verileri bu aşamada öğrenir.
- iv) Model Testi: Eğitim seti dışında bırakılan veriler ile model performansının değerlendirilmesi için test işlemine tabi tutulur
- v) Model Optimizasyonu: Gerekmesi durumda, modelde kullanılan algoritma başlangıç hiper parametre ayarlarının değiştirilerek modelin performansının iyileştirilmesi sürecini kapsamaktadır.
- vi) Genellenebilirlik: Eğitim, test ve optimizasyon aşamaları tamamlanan modelin, veri setinde hiç görmemiş olduğu verilerle sınanarak tahmin performansının ölçülmesini ifade etmektedir.

Optimizasyon (en iyileme), modelin performansını en üst düzeye çıkarmak için makine öğrenmesinde kullanılan önemli bir süreçtir. Bu süreç, modelin öğrenme yeteneğini geliştirmek, hataları en aza indirmek ve tahmin performansını arttırmak için çeşitli teknikler ve stratejiler içerir. Optimizasyonda, belirli bir durumu modelleyen matematik formülleri kullanılarak mümkün olan en iyi çözüm bulunmaya çalışılır. Model üzerinde mümkün olduğu kadar iyileştirme yapılır ve bu durum son aşamaya gelinceye kadar devam eder. Temel makine öğrenmesinde, hiper parametre, düzenleme (regülerizasyon), çapraz doğrulama (cross-validation) ve hata fonksiyon optimizasyonları bu süreçte sıklıkla kullanılmaktadır (Bishop, 2006; Sönmez, 2023; Karakuş, 2023).

Tez kapsamında, çalışmanın amacı ve verilerin niteliği göz önüne alındığında, modelleme ve tahmin çalışmalarında denetimli makine öğrenmesi algoritmaları kullanılacaktır. Literatürde onlarca makine öğrenmesi teknikleri (algoritma) bulunmaktadır. Her algoritmanın, veriyi anlama, yorumlama, düzenleme, eğitme ve tahmin süreçleri

birbirinden farklıdır. Bu tezde, çalışmaya dolaylı olarak da veri setimize uygun oldukları tespit edilen Ridge, Lasso, XGBoost ve Destek vektör algoritma (regresyon) modelleri tercih edilmiştir (Şekil 8).



Şekil 8. Denetimli öğrenme algoritmaları

Makine öğrenmesinde; En Küçük Kareler (EKK), en temel (doğrusal) regresyon problem çözüm yöntemidir. EKK, bağımsız değişkenler (x) ile bağımlı değişkeni (y) ilişkilendiren bir regresyon modelinin parametrelerini bulmak için kullanılmaktadır. Yöntemin amacı, tahmin edilen ($\hat{y}_i$) değerler ile gerçek değerler (y_i) arasındaki farkın kareler toplamını (hata kareleri toplamı) minimum yapan parametreleri belirlemektir (Weisberg, 2005). Hata kareleri toplamı minimum olan bir model, en iyi tahmini yapan model olarak görülür. Eşitlik 4 ve 5'te temel dereceli regresyon denklemi verilmektedir.

$$EKK = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2^2 + \beta_3 x_3^3 + \dots + \beta_n x_n^n + \epsilon \quad (5)$$

Denklemden, β_0 sabit (intercept), $\beta_{1,2,3,4,\dots,n}$ bağımsız değişkenin, bağımlı değişken üzerindeki etkisini ifade eden katsayılarıdır. ϵ ise modelde açıklanamayan yani bağımlı (y) değişkendeki değişikliği açıklayan hata terimidir (Draper ve Smith, 1998).

1.9.1. Ridge Regresyon

Ridge Regresyonu, istatistik ve makine öğrenme alanlarında kullanılan bir regresyon analizi yöntemi olup aynı zamanda "L2 tipli düzenleştirme" olarak bilinir. Ridge regresyonu, Hoerl ve Kennard tarafından 1970 yılında ortaya atılmış ve ilk makaleleri "Ridge Regresyon:

Ortogonal Olmayan Problemler İçin Sapmalı Tahmin" başlığıyla *Technometrics* dergisinde yayımlanmıştır (Hoerl ve Kennard, 1970). Bu metot, aşırı uyumu azaltmak, modelin daha genelleştirilebilir hale gelmesini sağlamak ve özellikler arasındaki çoklu doğrusal bağlantıyı ele almak amaçlarıyla geliştirilmiştir.

Özellik olarak lineer regresyonun bir çeşidi olan Ridge regresyonu, aşırı uyum (overfitting) sorununu önlemek için modele, alpha (α) olarak adlandırılan cezalandırma (penalizasyon) terimi ekler ve bu sayede hata kareler toplamı ile birlikte katsayıların karelerinin toplamını da minimize eder (Hastie vd., 2009). Ridge regresyonun temel denklemi Eşitlik 6'da sunulmaktadır.

$$\text{minimize} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{j=1}^p |\beta_j^2| \quad (6)$$

Alpha (α) cezalandırma parametresi, modelin daha iyi genelleştirme yapmasında kritik rol oynar. Alpha (α) değerinin sıfır olması, modeli lineer regresyona dönüştürür. Alpha (α) değeri arttıkça, modeldeki katsayılar daha fazla küçültülür ve modelin daha basit hale gelir. Ancak bu değer belli seviyenin üstünde olması durumunda, model aşırı basitleşir ve doğruluk yeteneğini kaybedebilir. Ridge regresyonu, çoklu veri setlerinde veriler arasında doğrusal bağıntıları iyi ele alır ve katsayıları küçülterek (asla sıfırlamaz) modelin güvenilirliğini artırmaya yardımcı olur. Genel olarak, Ridge regresyon, modelin karmaşıklığını kontrol ederek genelleme performansını artırmak için kullanılan bir regresyon yöntemi olup çoklu kolinearlılık gibi durumlarda faydalı olsa da tüm değişkenleri modelde tutmaktadır (Hoerl ve Kennard, 1970; Hastie vd., 2009).

1.9.2. Lasso Regresyon

Lasso (Least Absolute Shrinkage and Selection Operator), istatistik ve makine öğrenme alanlarında kullanılan bir regresyon analizi yöntemi olup aynı zamanda "L1 tipli düzenleştirme" olarak bilinir. 1996 yılında Robert Tibshirani tarafından tanıtılan Lasso, yüksek boyutlu veri kümelerinde değişken seçimi gerektiren durumlarda sıklıkla kullanılmaktadır (Tibshirani, 1996). Lineer ve Ridge regresyona alternatif olarak, hem modele cezalandırma terimi (penalizasyon) ekleyerek karmaşıklığı azaltabilmekte hem de değişken seçimi yapabilmektedir. Ridge uygulamasından farkı, modelde bazı katsayıları

sıfıra indirgeyerek değişken seçicinde etkili olabilmektedir (Montgomery vd., 2012).

Lasso regresyonu da aşırı uyum (overfitting) sorununu önlemek için modele, alpha (α) olarak adlandırılan cezalandırma (penalizasyon) terimi ekler ve bu sayede hata kareler toplamı ile birlikte katsayıların mutlak değerinin ya küçültür ya da sıfıra indirgeyerek modeli minimize eder (Hastie vd., 2009). Lasso regresyonun temel denklemi Eşitlik 7’de sunulmaktadır.


$$\text{minimize} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \sum_{j=1}^p |\beta_j| \quad (7)$$

Lasso algoritmasının katsayıların mutlak değerlerini düzenlemesi ve modeldeki bazı katsayıları tam olarak sıfıra çekmesi, özellikle yüksek boyutlu veri kümelerinde değişken seçiminde büyük kolaylık sağlamaktadır. Sıfıra çekilen yani gereksiz değişkenler, modelden çıkarılarak hem basit ve daha genellenebilir bir model oluştururken hem de etkileyici tahminler yapabilme imkânı sağlanmış olunur (Tibshirani, 1996; Montgomery vd., 2012).

1.9.3. XGBoost Regresyon

Washington Üniversitesinden Tianqi Chen ve Carlos Guestrin tarafından bir araştırma projesi olarak geliştirilen XGBoost (Extreme Gradient Boosting), algoritması, gradyan arttırma temelini kullanan, karar ağacı tabanlı ve karar ağacını güçlendiren bir ensemble (birleştirilmiş) makine öğrenme algoritmasıdır (Chen ve Guestrin, 2016). Günümüzde geliştirilmeye hala devam eden bu algoritma, makine öğreniminde kabul görmüş birçok Kaggle yarışmasını kazanmıştır (Kurt vd., 2020).

XGBoost, tahmin karar ağaçları oluşturmak için Classification and Regression Tree (CART) algoritmasını kullanır ve bu tahminleri de Gradient Boosting Machines (GBM) algoritmasının kayıp fonksiyonları (hataları) izleyerek iyileştirir. XGBoost, Şekil 9’da görüleceği üzere, Gradient Boosting Machines algoritmasının optimize edilmiş en kararlı hali olup kayıp fonksiyonun gradyanını takip ederek ardışık ağaçlar oluşturur ve böylece yüksek performans sağlar. Bu algoritma, özellikle büyük ve karmaşık veri setleri üzerinde daha kısa işlem süreleri ve daha düşük bellek kullanımı ile dikkat çekmektedir. Ayrıca, eksik veri yönetimi için entegre edilmiş düzenleme teknikleri sunmaktadır (Bayrakçı vd. 2021).



Şekil 9. XGBoost algoritmasının gelişim süreci (Kelle ve Yüce, 2022)

XGBoost algoritması, birkaç denklem ve fonksiyonun birleşmesiyle oluşmaktadır. Modelin karar ağaçları üzerindeki zayıf tahmini Eşitlik 8 ile, modelin performansını ölçen kayıp (hata) fonksiyonu Eşitlik 9 ile modelin aşırı uyum yapmasını engelleyen düzenleme fonksiyonu eşitlik 10 ile kayıp fonksiyonun optimizasyonunu hızlandırmak için kullanılan ikinci dereceli Taylor serisi fonksiyonu da Eşitlik 11 ile hesaplanmaktadır (Chen ve Guestrin, 2016).

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad , \quad f_k \in F \quad (8)$$

Burada, K kullanılan ağaç sayısını, $\hat{y}_i$ i numaralı örnek için yapılan tahmini, $f_k(x_i)$ k numaralı ağacın i numaralı örnek için yaptığı tahmini, F karar ağaçlarının bulunduğu uzayı ayrı ayrı ifade eder.

$$L(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (9)$$

Burada, n veri sayısını, $L(\theta)$ toplam kayıp fonksiyonunu, $l(y_i, \hat{y}_i)$ gerçek değer ile tahmin edilen değerler arasındaki hatayı, $\Omega(f_k)$ karmaşıklığa bağlı düzenleme terimini ifade eder.

$$\Omega(f) = \gamma T + \lambda \sum_{j=1}^T w_j^2 \quad (10)$$

Burada, T yaprağın sayısını, γ yaprak başına cezayı, λ ise yaprak ağırlıklarının normuna uygulanan düzenleme parametresini temsil etmektedir


$$L^{(t)} \approx \sum_i [g_i f_t(x_i) + h_i f_t^2(x_i)] + \Omega(f_t) \quad (11)$$

Burada, $L^{(t)}$ t adımdaki kayıp fonksiyonu, g_i gradyan-kayıp fonksiyonunun birinci türevini, h_i -hesian-kayıp fonksiyonunun ikinci türevini ifade eder.

Bu algoritma, ağacı oluştururken maksimum derinlik değerini kullanmak gibi hesaplama hızına ve düzenleme gibi model performansına odaklanan avantajlara sahiptir. Arttırma mantığı, birden fazla küçük ve zayıf modelin birleştirilerek daha güçlü bir model elde edilmesine dayanır. Arttırma, sıralı bir süreçtir; yani ağaçlar, daha önce eğitilmiş bir ağaçtan gelen bilgileri kullanarak birbiri ardına büyütülür. Bu süreç, verilerden yavaşça öğrenir ve sonraki iterasyonlarda tahminini geliştirmeye çalışır. Eğer oluşturulan ağaç aşağı yönde aşırı ilerleme gösterirse, aşırı öğrenmenin önüne geçebilmek için budama işlemi gerçekleştirilir (Saraswat, 2023; Kelle ve Yüce, 2022).

1.9.4. SVR Regresyonu

SVR (Support Vector Regression), destek vektör makinaları prensiplerine dayanan denetimli makine öğrenmesi regresyon türüdür. SVR'nin temeli, ilk olarak 1992 yılında Vladimir Vapnik tarafından geliştirilmiş olan SVM algoritmasına dayanmaktadır (Vapnik, 1995). SVR, özellikle yüksek boyutlu uzaylarda etkilidir ve farklı sınıflar arasında net bir ayırım marjine sahip problemler için uygundur. Destek vektörlerinin veri noktaları etrafında hiper düzlem genişliği oluşturması durumu Şekil 10'da gösterilmektedir.



Şekil 10. Destek Vektörlerin Düzlem Oluşturması (Calayır ve Kabak, 2021)

SVR, model üzerinde verileri en iyi şekilde temsil edebilmek için verileri epsilon (ϵ) denilen bir hata marjı içerisinde ele alır. Algoritma, hata marjını yani toleransı içerisindeki en iyi hatayı (marjin) bularak, bu hataları epsilon değerine kadar göz ardı eder. Küçük epsilon değerleri, modeli daha hassas ve duyarlı hale getirir (B bant genişliği) ancak bu durum da karmaşık bir model oluşmasına sebebiyet verebilmektedir. Modelin hata marjını, epsilonun yanında ceza parametresi (C) ile denetlenir. C değerinin büyük seçilmesi, modelin daha az hata yapmasını dolayısıyla da aşırım uyum problemini beraberinde getirebilir. Bu gibi olumsuz durumların oluşmaması için C ve epsilon parametreleri modelde optimizasyonla dikkatli seçilmelidir. Ayrıca SVR modellemelerinde optimizasyon, yalnızca epsilon (ϵ) dışındaki hatalar için yapılmaktadır (Vapnik, 2000; Smola ve Schölkopf, 2002).

SVR algoritmasının temel fonksiyonu Eşitlik 12 ve 13'te verilmektedir.

$$f(x) = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b \quad (12)$$

$$f(x) = w^T \phi(x) + b \quad (13)$$

W ağırlık vektörünü, b sabit terimi, $\phi(x)$ de risini yüksek boyutlu bir özellik uzayına dönüştüren fonksiyonu ifade etmektedir. SVR'de amaç hataları, epsilon (ϵ) sınırları içinde tutarak y gerçek değer olmak üzere, $f(x)$ doğrusal tahmin fonksiyonu bulmaktır. Bunun için de kayıp fonksiyon kullanılmakta olup Eşitlik 14'te verilmektedir.

$$L_\epsilon(y, F(x)) = \max(0, |y - f(x)| - \epsilon) \quad (14)$$

SVR algoritmasında, modelin tahmin performansını yüksek tutmak, hataları minimize etmek, modelin karmaşıklığını kontrol altında tutmak ve daha genellenebilir bir hale gelmesi için optimizasyon işlemi önemli rol oynamaktadır. Bunun için de w ağırlık vektörünün normunu minimize edilip aşırı uyumun önüne geçilmesi amaçlanır. İlaveten C parametresi ile Slack değişkenleri (ξ_i , ξ_i') minimize edilerek, modelin yalnızca epsilon (ϵ) dışındaki hatalar üzerinde eğitilmesini sağlar. SVR algoritmasının optimizasyon denklemi Eşitlik 15'te verilmektedir.

$$\min(w, b, \xi_i, \xi_i') = w^2 + c \sum_{i=1}^n (\xi_i, \xi_i') \quad (15)$$

Belirlenen kıstaslar altında eğitilen model, tahmin aşamasına gelmiş olur. SVR algoritmasının genel karar denklemi Eşitlik 16'da sunulmaktadır.

$$f(x) = \sum_{i=1}^n (\alpha_i) K(x_i, x) + b \quad (16)$$

SVR algoritması, doğrusal olmayan verileri açıklamaya çalışırken kernel $K(x_i, x)$ denilen çekirdek fonksiyonları kullanmaktadır. Bu sayede, verileri daha yüksek boyutlu bir uzaya taşıyarak, modelde doğrusal olmayan ilişkilerin ortaya konmasını kolaylaştırır. Temel olarak lineer, polinomsal, radyal ve sigmoid türde kerneller kullanılmaktadır (Drucker vd., 1997; Vapnik, 2000). Bu kerneller, modelin durumuna göre Eşitlik 16'daki ilgili yere Eşitlik 17-20 kernel denklemleri yazılmaktadır.

$$\text{Lineer Kernel, } K(x_i, x_j) = x_i^T x_j \quad (17)$$

$$\text{Polinomsal Kernel, } K(x_i, x_j) = (\gamma x_i^T x_j + r)^d \quad (18)$$

$$\text{Radyal Kernel, } K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (19)$$

$$\text{Sigmoid Kernel, } K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r) \quad (20)$$

Sonuç olarak; SVR, bu kernel fonksiyonları sayesinde doğrusal olmayan veriler üzerinde güçlü modeller oluşturmayı sağlar. Özellikle polinomsal fonksiyon derecesi arttıkça, modelde karmaşıklıkla birlikte aşırı uyum sorununa da dikkat edilmelidir. Radyal kernel ise veriyi çok yüksek (teorik olarak sonsuz) boyutlu bir uzaya taşıyarak, veriler arasındaki doğrusal olmayan ilişkileri daha iyi açıklayabilmektedir (Vapnik, 2000; Schölkopf ve Smola, 2002).

2. YAPILAN ÇALIŞMALAR

2.1. Giriş

Bu bölümde ilk olarak, “1.3. Araştırma Yöntemi” başlığı altında da verildiği üzere literatürde sıklıkla kullanılan 16 adet parametre başlangıçta belirlenmiştir. Parametrelerden dağıtım debisi, ilk aşamada; içmesuyu ve atıksu proje büyüklükleri ise ikinci aşamada, bağımlı (sonuç) değişken olarak seçilmiştir. Kalan 13 adet parametreye ise çok ölçütlü karar verme yöntemlerinden SWARA yöntemiyle altyapı konusunda uzman 30 kişilik bir grupta yapılan görüşmeler ve anketler sonucunda parametrelerin önceliklendirilmesi yapılmıştır. Sonrasında, iklimsel parametrelerin, kurulacak modelde daha iyi temsil edilebilmesi için literatürde Aydeniz İklim Sınıflandırma yöntemi olarak bilinen Aydeniz formülünün teorik özellikleri verilerek, iklimsel parametrelerin bütünleşik etkisi veri setine yansıtılmıştır. En sonunda da veri setinin boyutunun küçültülmesi ve en önemli parametrelerin modelde temsil edilebilmesi için Temel Bileşen Analiz yöntemi kullanılarak 5 farklı bileşen analizi yapılmış ve özellik (bağımsız değişken) seçimi yapılmıştır.

Bağımsız değişkenler belirlendikten sonra, denetimli makine öğrenme algoritmalarından Lasso, Ridge, XGBoost ve SVR algoritmaları kullanılarak tahmin modelleri kurulmuştur. Kurulan modellerde verilerin belirli bir standartta olması için normalizasyon işlemi yapılmış, sonrasında tahmini yapılan bağımlı değişkenlerin en verimli ve en hızlı şekilde yapılması ve modellerin veri setinde görmediği verilerle test edilmesi için k-katlı çapraz doğrulama (cross validation) ve hold out yöntemleri, algoritmalara uygun şekilde kullanılmıştır. Ayrıca makine öğrenme destekli algoritmalarla kurulan modellerin performans sonuçlarını değerlendirmek ve birbirleriyle karşılaştırmak için literatürde sıklıkla kullanılan; ortalama mutlak hata (MAE), ortalama hata kareleri toplamı kökü (RMSE), R^2 (Determinasyon Katsayısı) ve NSE (Nash Sutcliffe) verimlilik katsayısı kullanılmıştır.

Kurulan modellerde, kullanılan veri seti 2006-2023 yılları arası 18 yılı kapsamakla birlikte, modellerin eğitim ve test setleri ise 2006-2020 yıllarını kapsayan 15 yıldan oluşmaktadır. Modelleme çalışma sonrasında, Adana şehri merkez ilçelerinin 2021-2026 yılları arasındaki dağıtım debisi ve proje büyüklükleri, beklenmesi muhtemel gerçekçi senaryolara göre tahmin edilmiş olup 2021-2023 yılları arasında gerçek değerlerle

algoritmaların tahmin performansları sınanmıştır.

İki aşamalı olarak planlanan tahmin model çalışmalarında; ilk aşamada, denetimli makine öğrenmesi algoritmaları kullanılarak dağıtım debisi tahmin modelleri kurulmuştur. İkinci aşamada ise ilk aşamada dağıtım debisi modellemelerinde en iyi performansı gösteren makine öğrenmesi algoritmalarıyla içmesuyu ve atıksu altyapı proje büyüklüğü tahmin modelleri kurulmuştur. Tüm kurulan modeller, algoritmaların temel başlangıç parametrelili ve optimize edilmiş hiper parametrelili olmak üzere iki ayrı şekilde incelenmiştir. Analizleri yapılan tüm bu model çalışmaları, “3. Bulgular ve İrdeleme” başlığı altında ayrıntılı biçimde sunulmuştur. Elde edilen sonuçlar, Ridge ve SVR makine öğrenmesi algoritmalarının, literatürde kullanılan diğer algoritmalarla karşılaştırıldığında, içmesuyu ve atıksu altyapı proje büyüklüklerinin tahmini üzerinde etkinliğini net bir şekilde ortaya koymaktadır.

2.1.1. İklim Değişikliğinin Önemi

İklim değişikliği, günümüzde içmesuyu ve atıksu altyapıları üzerinde önemli ve giderek artan bir etki meydana getirmektedir. Artan sıcaklıklar, değişen yağış rejimleri, deniz seviyesindeki yükselme ve ekstrem hava olaylarının sıklığındaki artış, altyapı projelerini daha kırılgan hale getirmekte ve uzun vadeli planlama süreçlerinde önemli belirsizlikler oluşturmaktadır. Bu durum da altyapı tasarımı ve yönetimi süreçlerinde, iklim parametrelerinin önceden dikkate alınmasını zorunlu hale getirmektedir (ASCE, 2015).

Son yıllarda yapılan araştırmalar, altyapı projelerinde iklim değişikliğinden kaynaklanan risklerin değerlendirilmesinin ve bu risklere yönelik yenilikçi çözümler geliştirilmesinin daha yaygın hale geldiğini göstermektedir. Bu doğrultuda; iklim değişikliğine uyum sağlamak için ek maliyetleri ve yükleri önceden tahmin etmek, bu maliyetleri politikalarla entegre ederek yönetmek, büyük önem taşımaktadır. İklim değişikliğinin etkilerinin giderek yoğunlaştığı günümüzde, bu etkileri bilimsel verilerle anlamak ve erken harekete geçmek, altyapı projelerinin sürdürülebilirliği açısından kritik bir gereklilik olarak öne çıkmaktadır (Pehlivan, 2023).

Bu minvalde, iklim değişikliği ve sosyo-ekonomik değişkenlerin altyapı projelerinde oluşturduğu etkinin, maliyet bileşenleri üzerinde olası yansımalarının önceden belirlenmesi amacıyla bu tez çalışması yapılmış olup çalışma kapsamında, yapay zekâ destekli bilimsel modeller geliştirilerek geleceğe yönelik yol gösterici senaryolar ortaya konulmuştur.

2.2. Tahmin Modellerinde Kullanılacak Verilerin Belirlenmesi

Adana ilinde altyapı sürecine ait tahmin modelleri oluşturabilmek için öncelikle altyapı tahmini için literatürde sıklıkla kullanılan bağımlı ve bağımsız değişken parametreleri belirlenmiştir. Bu kapsamda belirlenen parametreler sosyo-ekonomik ve iklimsel (meteorolojik) olmak üzere iki grup altında aşağıda verilmektedir:

1. Sosyo-ekonomik parametreler:

- 1.1. İçme suyu proje büyüklüğü,
- 1.2. Atıksu proje büyüklüğü,
- 1.3. Dağıtım debisi,
- 1.4. Yerleşim nüfusu,
- 1.5. Gayri safi yurtiçi hasıla (GSYH),
- 1.6. Abone sayısı,
- 1.7. Yapı ruhsatı sayısı,
- 1.8. Yapı kullanım izin (iskân) sayısı,
- 1.9. Tarım alanı

2. İklimsel (meteorolojik) parametreler:

- 2.1. Sıcaklık,
- 2.2. Buharlaşma miktarı,
- 2.3. Yağış miktarı,
- 2.4. Güneşlenme süresi,
- 2.5. Nispi nem,
- 2.6. Rüzgâr hızı,
- 2.7. Atmosfer basıncı

Yukarıda verilen değişkenlere ait sayısal veriler 2006 yılından 2023 yılına kadar aylık ve yıllık dönemler şeklinde ilgili kamu kurum ve kuruluşlarına ait web sitelerinden (URL 5-13) temin edilmiştir. Bu kapsamda Adana iline ait altyapı tahmin modellerinde kullanılan sosyo-ekonomik veriler EK 1’de, iklim değişikliğine ait (meteorolojik) veriler ise EK 2’de verilmektedir. Altyapı proje sürecine ait tahmin modelleri kurabilmek için tez çalışması kapsamında belirlenen parametrelerin tahmin modelleme sürecinde nasıl kullanılabileceklerinin tespiti için çok ölçekli karar verme yöntemleri (ÇÖKV) incelenmiştir.

Tez kapsamında gerçekleştirilecek çalışma için 9 adet sosyo-ekonomik ve 7 adet iklimsel parametrenin modeldeki ağırlıklarını temsil etmek amacıyla, bu parametrelerin önceliklendirilmesi için bir yöntem belirlenmiştir. Bu bağlamda, uygulama ve açıklama yönünden basitliği ile literatürde yaygın olarak kullanılan subjektif karar verme yöntemlerinden biri olan SWARA yöntemi tercih edilmiştir.

2.2.1. SWARA Yönteminin Uygulanması

Tez çalışması kapsamında, tahmin modelinde kullanılacak bağımsız değişkenlerin önem düzeylerinin tespiti amacıyla, altyapı projelerinde bilgi ve tecrübe sahibi 30 kişilik uzman (anket karar verici, AKV) bir grup ile görüşmeler ve anket çalışması gerçekleştirilmiştir. Çalışmanın ilk aşamasında, katılımcılarla birebir görüşmeler yapılmış ve bağımsız değişkenlerin belirlenmesi sürecine katkı sağlanmıştır. Bu görüşmelerde, altyapı projelerindeki deneyim ve birikimleri doğrultusunda uzmanların geri bildirimleri alınmış ve bu geri bildirimler, anket formunun yapılandırılmasında rehberlik etmiştir. Görüşmelerden elde edilen bilgiler doğrultusunda hazırlanan anket, Ek 3'te sunulmakta olup aynı uzman grubu ile uygulanmış ve sonuçlar toplanmıştır.

Çalışma kapsamında, kamu ve özel sektörde altyapı projelerinin planlama, uygulama ve yönetim süreçlerinde aktif rol alan 30 kişilik bir uzman grubu ile anket çalışması gerçekleştirilmiştir. Katılımcıların 23'ü mühendis, 7'si ise idareci pozisyonundadır. Tüm mühendisler, altyapı projelerinde en az 5 yıllık deneyime sahiptir. İdareciler arasında 1 genel müdür yardımcısı, 2 daire başkanı ve 4 şube müdürü yer almakta olup tamamı mühendislik kökenlidir. İdarecilerin mesleki tecrübeleri ise 10 yılın üzerindedir. Katılımcıların tamamı inşaat mühendisidir; bunların 1'i doktora, 8'i yüksek lisans derecesine sahiptir. Cinsiyet dağılımına göre katılımcıların %83,3'ü erkek (25 kişi), %16,7'si kadın (5 kişi) olarak belirlenmiştir. Yaş grupları incelendiğinde, mühendislerin 30-35 yaş arasında 7, 36-45 yaş arasında 5, 46-60 yaş arasında 7 ve 60 yaş üstünde 4 kişiden oluştuğu tespit edilmiştir. İdareciler ise 35-40 yaş arasında 4, 41-45 yaş arasında 2 ve 46-50 yaş arasında 1 kişiden oluşmaktadır. Bu uzman grubunun deneyim ve nitelikleri, araştırmanın güvenilirlik ve temsiliyet düzeyini önemli ölçüde desteklemektedir.

Görüşme ve anket çalışmalarından elde edilen sonuçlar doğrultusunda, uzmanlar tarafından belirlenen kriterlerin (parametrelerin) önceliklendirilmesi gerçekleştirilmiş ve öncelik sıralamaları oluşturulmuştur. Bu süreçte belirlenen öncelik düzeyleri, karar verme


süreçlerinde parametrelerin görece önemini açık bir şekilde ortaya koymaktadır.

Uzman kişilere göre iklimsel ve sosyo-ekonomik parametreler suyun miktarını yani dağıtım debisini doğrudan etkileyen etmenler olarak ifade edilmiştir. Bunun yansıması olarak da altyapı proje büyüklüğünü; debinin doğrudan, parametrelerin de dolaylı yönden etkilediği savunulmuştur. Bu yaklaşım doğrultusunda, ana hedefimiz olan proje büyüklüğü ve dağıtım debisinin bağımlı değişken, diğer parametrelerin ise bağımsız değişken olarak belirlenmesinin uygun olacağı kanaatine varılmıştır. Bu sebeple içmesuyu proje büyüklüğü, atıksu proje büyüklüğü ve dağıtım debisi sosyo-ekonomik parametreleri anket çalışması kapsamından çıkarılmıştır.

Altyapı projeleri için 6 adet sosyo-ekonomik ve 7 adet iklimsel olmak üzere toplam 13 adet parametreyi içeren anket 30 uzman katılımcıya sunulmuştur. Belirlenen 13 parametrenin ağırlıkları SWARA yöntemi kullanılarak hesaplanmıştır. 30 uzman karar vericiden parametreleri kendi bilgi ve deneyimlerine göre önem sırasına göre 1'den 13'e kadar sıralamaları istenmiştir. Her AKV, kendileri için en önemli olan parametreye bir puan vermiş ve ardından bir sonraki parametre yüzde p değeri atamıştır. Atanan P değeri, sıralamada kendisinden sonra gelen parametreye kıyasla her bir parametrenin önem yüzdesini gösteren bir değerdir. Her bir parametre için atanan p_j değerlerine en önemli parametrenin puanı eklenerek bir katsayı (k_j) elde edilir. Daha sonra, her bir parametre için önem sırasına göre hesaplanan her bir k değeri normalize edilerek düzeltilmiş ağırlık (q) hesaplanır. En yüksek parametrenin düzeltilmiş ağırlık değerinin 1 olması amaçlanmaktadır. En sonunda, parametrelerin ağırlıkları (q), her bir parametre için nihai ağırlığı (w) belirlemek üzere parametre ağırlıklarının toplamına bölünerek, sıralanma işlemi tamamlanmıştır. Bu sayede, SWARA yönteminde, anket karar vericilerin (AKV) uzmanlıklarına dayalı subjektif görüşleri, sistematik bir şekilde nesnel skorlama sistemi ile birleştirilmiştir.

Her bir AKV'nin belirlemiş olduğu parametre ağırlıklarının aritmetik ortalaması alınmış olup altyapı projelendirme sürecinde %23,88 önem yüzdesi ile yerleşim yeri nüfusu birinci, %18,80 önem yüzdesi ile abone sayısı ikinci, %17,38 önem yüzdesi ile şehir gelişmişliği üçüncü önem parametre olarak tespit edilmiştir. SWARA yöntemiyle anket karar vericilerinden elde edilen parametrelerin önem sıralaması Şekil 11'de verilmektedir. SWARA yöntemiyle anket karar vericilerine göre parametrelerin ağırlık sonuçları ise Tablo 2'de verilmektedir. Şekil 11 ve Tablo 2 incelendiğinde yapı ruhsatı ve iskân belgesi sayılarının üst sıralamada olmamasının nedeni kaçak veya izinsiz inşaa faaliyetlerinden kaynaklandığı söylenebilir. Bu durumda planlama ve izin süreçlerinde zafiyetlerin, altyapı

projelerine olan etkisini ortaya koymakta olup kaçak yapılaşmanın ilgili kurumlarca daha fazla dikkate alınması gerektiğini göstermektedir.



Şekil 11. SWARA yönteminde AKV'lere göre parametrelerin ağırlıkları ve önem sırası

Tablo 2. SWARA yöntemiyle anket karar vericilerine (AKV) göre parametrelerin ağırlık sonuçları

Parametreler	Yerleşim Nüfusu	Abone Sayısı	Şehir Gelişmişliği	İnşaat Ruhsat Sayısı	Tarımsal Alan	Verilen İskân Belgesi Sayısı	Sıcaklık	Yağış Miktarı	Nem Miktarı	Buharlaştırma Miktarı	Güneşlenme Süresi	Rüzgar Hızı	Atmosfer Basıncı
AKV-1	0,2515	0,1612	0,1935	0,0729	0,0608	0,0948	0,0245	0,0405	0,0186	0,0368	0,0223	0,0143	0,0079
AKV-2	0,2374	0,1583	0,1318	0,0856	0,0659	0,0942	0,0319	0,0507	0,0422	0,0384	0,0207	0,0228	0,0197
AKV-3	0,2880	0,0887	0,1800	0,1154	0,0592	0,1385	0,0348	0,0249	0,0191	0,0159	0,0133	0,0101	0,0121
AKV-4	0,2675	0,1911	0,1365	0,0299	0,1049	0,0538	0,0192	0,0808	0,0249	0,0449	0,0132	0,0174	0,0158
AKV-5	0,3446	0,2027	0,1689	0,0521	0,0939	0,0626	0,0030	0,0326	0,0192	0,0106	0,0057	0,0022	0,0016
AKV-6	0,3995	0,2349	0,1566	0,0512	0,0269	0,0922	0,0037	0,0142	0,0078	0,0053	0,0029	0,0024	0,0022
AKV-7	0,2482	0,1364	0,1773	0,0757	0,1137	0,0631	0,0421	0,0383	0,0227	0,0273	0,0198	0,0171	0,0180
AKV-8	0,2677	0,1487	0,1785	0,1144	0,0677	0,0880	0,0089	0,0451	0,0301	0,0215	0,0134	0,0081	0,0077
AKV-9	0,2635	0,2026	0,18424	0,0452	0,0677	0,1084	0,0241	0,0301	0,0209	0,0190	0,0136	0,0082	0,0124
AKV-10	0,2714	0,2171	0,1888	0,1049	0,0699	0,0466	0,0259	0,0199	0,0153	0,0127	0,0089	0,0106	0,0077
AKV-11	0,1821	0,2914	0,1517	0,0556	0,0723	0,1012	0,0308	0,0463	0,0221	0,0157	0,0121	0,0101	0,0084
AKV-12	0,1593	0,3106	0,2389	0,0369	0,0885	0,0553	0,0124	0,0246	0,0214	0,0194	0,0162	0,0068	0,0096
AKV-13	0,1645	0,2353	0,2138	0,0586	0,0645	0,0967	0,0231	0,0451	0,0277	0,0361	0,0103	0,0085	0,0154
AKV-14	0,1975	0,2469	0,1580	0,1089	0,0405	0,0908	0,0270	0,0567	0,0180	0,0225	0,0107	0,0093	0,0129
AKV-15	0,1938	0,2519	0,16152	0,0769	0,0285	0,1154	0,0238	0,0427	0,0372	0,0216	0,0188	0,0145	0,0131
AKV-16	0,1605	0,1926	0,2312	0,0535	0,1003	0,0668	0,0329	0,0412	0,0273	0,0286	0,0237	0,0216	0,0196

Tablo 2'nin devamı

AKV-17	0,1643	0,1807	0,2169	0,0966	0,0464	0,0604	0,0366	0,0290	0,0422	0,0402	0,0348	0,0264	0,0251
AKV-18	0,1374	0,1581	0,2055	0,0634	0,0947	0,0824	0,0332	0,0528	0,0251	0,0348	0,0440	0,0383	0,0301
AKV-19	0,1833	0,1222	0,2291	0,0727	0,0606	0,1018	0,0459	0,0353	0,0280	0,0505	0,0336	0,0154	0,0216
AKV-20	0,2173	0,1672	0,3043	0,0696	0,0409	0,1115	0,0095	0,0227	0,0125	0,0163	0,0104	0,0090	0,0086
AKV-21	0,2480	0,1653	0,0908	0,0757	0,0485	0,1181	0,0334	0,0582	0,0422	0,0367	0,0303	0,0276	0,0251
AKV-22	0,2725	0,2096	0,0699	0,0873	0,0384	0,1310	0,0319	0,0499	0,0231	0,0305	0,0254	0,0177	0,0127
AKV-23	0,3497	0,0857	0,2057	0,0612	0,0314	0,1285	0,0242	0,0408	0,0201	0,0139	0,0122	0,0167	0,0097
AKV-24	0,2751	0,1048	0,1965	0,0806	0,0537	0,1572	0,0275	0,0358	0,0136	0,0176	0,0212	0,0065	0,0097
AKV-25	0,2489	0,1197	0,0736	0,0920	0,0491	0,1915	0,0337	0,0446	0,0425	0,0405	0,0307	0,0137	0,0192
AKV-26	0,3329	0,1849	0,0565	0,0154	0,0289	0,0193	0,0060	0,1233	0,1027	0,0376	0,0790	0,0097	0,0035
AKV-27	0,2452	0,1572	0,1886	0,0130	0,0223	0,01433	0,0312	0,09823	0,0561	0,0702	0,0488	0,0375	0,0172
AKV-28	0,1887	0,1510	0,2359	0,0117	0,0888	0,0176	0,0388	0,0592	0,0564	0,0427	0,0470	0,0337	0,02815
AKV-29	0,2010	0,2814	0,1340	0,0175	0,0355	0,02101	0,02731	0,0837	0,0533	0,0586	0,0644	0,0125	0,0096
AKV-30	0,2042	0,3063	0,1571	0,0063	0,0924	0,0094	0,0257	0,0577	0,0481	0,0401	0,0334	0,0151	0,0042
GEO. ORT.	0,2310	0,1790	0,1636	0,0520	0,0564	0,0688	0,0219	0,0427	0,0272	0,0264	0,0195	0,0127	0,0112
ART. ORT.	0,2388	0,1888	0,1738	0,0634	0,0619	0,0844	0,0258	0,0475	0,0314	0,0302	0,0247	0,0155	0,0136
SIRALAMA	1	2	3	5	6	4	10	7	8	9	11	12	13

2.2.2. Aydeniz Yöntemi

SWARA yönteminde iklim parametrelerinin veri setindeki, önceliklendirilmeleri (temsili ağırlık katsayıları) sosyo-ekonomik parametrelere göre düşük çıkmış ve sıralamada son sıralarda yer almıştır. Ancak iklim değişikliği, altyapı projeleri üzerinde uzun vadede kritik etkiler meydana getirebileceğinden, bu parametrelerin kurulacak modellerde doğru şekilde temsil edilmesi önemlidir. Bu bağlamda, iklim parametrelerinin model içerisindeki etkilerinin daha kapsamlı bir şekilde, temsil edilmesi ve değerlendirilmesi gerekmektedir.

Çalışmanın, inceleme konusunda yer alan iklim değişikliği olaylarının en kötü etkilerinden birisi de kuraklık senaryolarıdır. Yağış değerlerinin normal seviyelerin altına düşmesi sonucu bu olay vuku bulmaktadır. Kuraklık ve nemlilik birbirleriyle zıt kavramlardır. Literatürde, kuraklık ve nemliliğin ifade edildiği ve farklı iklim tiplerini birbirinden ayırmak için bazı matematiksel indeksler kullanılmaktadır. Bu indeksler aşağıda verilmektedir (MGM, 2016):

- Standart Yağış İndeksi (SPI); belli bir süre boyunca gözlemlenen yağış değerlerinden normal yağış değerlerinin çıkarılıp standart sapmaya bölünmesiyle elde edilmektedir.
- Palmer Kuraklık Şiddet İndeksi (PDSI); yağış değişimlerinin buharlaşma miktarına bölünmesiyle bulunmaktadır.
- Köppen İklim indeksi; yağış ve sıcaklık verileri kullanılarak beş ana indiste iklim sınıflandırması yapılmaktadır.

Yukarıda verilen indekslerin tanımından anlaşılacağı üzere mevcuttaki yöntemler kuraklık veya iklim sınıflandırmasını en fazla iki parametreyle yansıtmaktadır. Bu durumun yetersiz olduğunu gören ve gerçeğe yakın dönemsel mevsim değerlerinin elde edilmesi için nem-yağış ile sıcaklık-güneşlenme süresi ilişkilerini birlikte göz önüne alan, merhum Prof. Dr. Akgün Aydeniz tarafından 1973 yılında bir formül geliştirilmiştir. Literatürde; Aydeniz İklim Sınıflandırması olarak geçen bu formülde, yağışın yanında sıcaklık, nispi nem ve güneşlenme süresinin ortalamaları alınmaktadır. Eşitlik 21’de verilen bu formülle göre yapılan hesaplama neticesinde kuraklık katsayı (K_{ks}) ve nemlilik katsayı (N_{ks}) indisleri elde edilmektedir (MGM, 2016).

$$(N_{ks})_{y\text{ıllık}} = \frac{P \cdot RH}{T \cdot G_s + 15} \times N_p \quad ; \quad (K_{ks})_{y\text{ıllık}} = \frac{1}{N_{ks}} \quad (21)$$

Denklemden; K_{ks} : Aydeniz kuraklık katsayısını, N_{ks} : Aydeniz Nemlilik katsayısını, P aylık toplam yağış yüksekliğini (cm), RH aylık ortalama nispi nemi (%), T aylık ortalama sıcaklığı ($^{\circ}C$), G_s ise aylık güneşlenme süresini (%) göstermektedir. N_p , nemli periyot yüzdesi olup aylık hesaplamalarda bu değer yerine 12 yazılır. Yıllık N_{ks} değeri, tüm aylar için hesaplanan nemlilik katsayı değerlerinden; 0,40'tan az olan ayların sayısı, 12'den çıkarılarak hesaplanan değer, 12'ye tekrar bölünerek elde edilmektedir. Tablo 3'te Aydeniz Yöntemine göre indis değerleri, dönemsel sınıflandırmaya ayrılmıştır (MGM, 2016).

Tablo 3. Aydeniz Yöntemi indeks değerleri

İndis	K_{ks}	N_{ks}
Çöl	>2.50	<0.40
Çok Kurak	1.50-2.50	0.40-0.67
Kurak	1.00-1.50	0.67-1.00
Yarı Kurak	0.75-1.00	1.00-1.33
Yarı Nemli	0.50-0.75	1.333-2.00
Nemli	0.25-0.50	2.00-4.00
Islak	<0.25	>4.00

Tez kapsamında elde edilen veri setimizde her ay için bulunan toplam yağış miktarı, ortalama nispi nem, ortalama sıcaklık ve ortalama güneşlenme süresi bağımsız değişken verileri Eşitlik 21'deki denklemde yerine yazıldığında Tablo 4'te verilen iklim değişikliğini temsil eden yıllık kuraklık katsayısı (K_{ks}) değerleri bulunmuştur.

Tablo 4. Aydeniz Yöntemine göre hesaplanan yıllık (N_{ks}) ve (K_{ks}) değerleri

Yıl	N_{ks}	K_{ks}
2006	0.9463	1.0567
2007	0.9737	1.0270
2008	0.5498	1.8187
2009	1.4688	0.6808
2010	0.6590	1.5174
2011	0.8985	1.1130
2012	1.9448	0.5142
2013	0.5765	1.7348
2014	1.0554	0.9475
2015	0.8708	1.1484
2016	1.0706	0.9340
2017	0.6682	1.4965
2018	1.4760	0.6775
2019	1.4927	0.7537
2020	0.7408	1.3500
2021	0.8704	1.1489
2022	0.8066	1.2398
2023	0.8883	1.1257

2.2.3. Temel Bileşen Analizinin Uygulanması

SWARA yöntemiyle bağımsız değişkenlerin (parametrelerin) önem düzeyleri belirlenerek önceliklendirilmesinden sonra, modellemelerde kullanılacak parametre verilerinin sayısı ve temsil oranının tespit edilmesi çok önemli bir husustur. Çok değişkenli analizlerde, veri setinde bulunan değişkenlerin çok sayıda olması ve bunların birbirleriyle ilişkili olması, modelleme çalışmalarında sorunlar teşkil etmekte olup bu tür değişkenlerle çalışmak hem parametrelerin bağımsızlığını zedelemekte hem de uzun zamanlar alan ilave işlem yükünü beraberinde getirmektedir. Bu tür veri setlerindeki çok değişkenli yapının özetlenmesi ve yorumlanması amacıyla sıklıkla kullanılan yöntemlerin başında Temel Bileşen Analizi (PCA) gelmektedir.

PCA, veri analizi ve modelleme süreçlerinde veri setlerinin boyutunun azaltılması ve özellik seçimi yapılması konusunda, önemli avantajlar sunmaktadır. Veri setinde az sayıda parametreyle temsil güçlerinin açıklanmasında etkili rol oynayan PCA, modelin daha hızlı eğitilmesine, aşırı uyumun (overfitting) önlenmesine ve genel performansının artırılmasına katkıda bulunur.

Veri setimizdeki 6 tanesi sosyo-ekonomik, 7 tanesi de iklim değişikliği olmak üzere toplamda 13 bağımsız değişken için veri setini daha düşük boyutlu hale getirmek ve modelleme sürecini kolaylaştırmak için PCA uygulanmıştır.

Bu işlem sırasında, bağımsız değişkenlerin farklı ölçeklere sahip olmasının pozitif etkisini azaltmak için her bir değişkenin ortalamasının sıfır ve standart sapmasının bir olması sağlanarak veri setinin standartlaştırılması yapılır. Standarda bağlanan verilerle kovaryans matrisi oluşturularak bağımsız değişkenler arasındaki doğrusal ilişkiler kurulmaya başlanır. Oluşturulan matrizen özvektörler ve özdeğerler (eigenvalues) hesaplanır. Özvektörler, verinin ana bileşenlerini temsil ederken özdeğerler ise bu eksenlerin veri varyansını ne kadar iyi açıkladığını gösterir. Nihayetinde, bileşenler içerisinde veri setindeki en fazla bilgiyi (varyansı) açıklayan yani en yüksek özdeğere sahip ana bileşenler hesaplanarak modelleme projeksiyonu oluşturulur.

PCA uygulaması ile veri setindeki bilgiyi daha az sayıda bileşende yoğunlaştırarak analiz ve modellemede en önemli bileşenler belirlenmiştir. 13 adet bağımsız değişken için 13 tane bileşen analizi yapılmıştır. Tablo 4'te görüleceği üzere, toplam değerler, analizde özdeğerlerin her bir ana bileşenin önemini ve veri setindeki varyansın ne kadarını açıkladığı göstermektedir. Döndürülmüş Karesel Yükleri, her bir bileşenin daha dengeli ve


yorumlanabilir hale getirilmesini sağlamak için kullanılan bir dönüşümün sonucu olarak ifade edilmektedir.

Tablo 5’te verilen PCA karakteristik değer sonuçlarına göre, ilk birkaç ana bileşen veri setindeki varyansın büyük bir kısmını açıklamaktadır. İlk ana bileşen (PC1) 6,574 özdeğeriyle tek başına varyansın %47,20’sini açıklamakta ve bu da veri setindeki önemli bilgi miktarını yansıtmaktadır. İlk beş ana bileşen ise toplam varyansın %88,75’ini açıkladığı görülmekte olup bu ilk beş temel bileşen, 13 bağımsız değişkenli veri setini temsil etmede kullanılabileceğini göstermektedir. Analiz süreçlerinde çalışmaların, %80 veya daha yüksek güç (temsil) seviyelerine ulaşacak şekilde tasarlanması gerektiği, yaygın olarak kabul edilen bir kuraldır (Murphy ve Myers, 2009).

Tablo.5. Bağımsız değişkenlerin PCA karakteristik değerleri

Bileşen	Başlangıç Özdeğerlerin			Döndürülmüş Karesel Yüklerinin		
	Toplam	Varyans (%)	Kümülatif (%)	Toplam	Varyans (%)	Kümülatif (%)
PC1	6.574	47.195	47.195	4.562	35.093	35,093
PC2	2.195	15.757	62.952	2.196	16.893	51,987
PC3	1.535	11.017	73.969	2.063	15.871	67,858
PC4	1.126	8.081	82.049	1.844	14.191	82,049
PC5	0.933	6.699	88.748	0.871	6.699	88.748
PC6	0.651	4.677	93.425			
PC7	0.371	2.665	96.090			
PC8	0.275	1.977	98.067			
PC9	0.176	1.260	99.327			
PC10	0.069	0.496	99.823			
PC11	0.023	0.167	99.990			
PC12	0.001	0.009	99.999			
PC13	0.000	0.001	100.000			

PC1, veri setindeki en büyük varyansı açıklayan; PC2, PC3, PC4 ve PC5 de daha düşük varyans oranları içermesine rağmen anlamlı bilgiyi içermektedir. Şekil 12’de temel bileşenlerin varyansı ile olan ilişkisi grafiksel olarak gösterilmektedir. Grafikte, veri setindeki bağımsız değişkenlerin temsil denklemi olan bileşen sayısı arttıkça, özdeğerlerin de kümülatif varyans (temsil) değerini arttırdığı görülmektedir.



Şekil 12. Temel bileşen sayısı-toplam açıklanan varyans grafiği

Temel bileşen analiz değerleri, veri setindeki tüm bağımsız değişkenlerin doğrusal bir kombinasyonudur. PC değerleri, sadece bir parametre olarak değerlendirilmemelidir. PC1, bu doğrusal kombinasyonda, veri setindeki en büyük varyansı açıklayan yani veri setini en iyi temsil eden optimize bileşen değeridir. Bununla beraber her bir ana bileşen için ağırlıklar (yük, loads), ilgili bileşenin hangi oranda sabit değişkenlerle ilişkili olduğunu gösterir. Bu ağırlıklar, değişkenlerin ana bileşenler üzerindeki etkisini değerlendirmek için kullanılır.

Yapılan temel bileşen analizi sonucunda, veri setinin yani bağımsız değişkenlerin toplam %88,75 oranında açıklayan ilk beş ana bileşene ait katsayılar (ağırlıklar), Tablo 6'da gösterilmektedir. Tablo 6'da SWARA yöntemine göre de uzman kişilerce ilk üç sıralamasında yer alan nüfus, şehir gelişmişliği ve abone sayısı katsayısının (ağırlık) mutlak değerleri, bileşen-1 (PC1) üzerindeki önemli bir etkiye sahip olduğu görülmektedir. Benzer şekilde, Aydeniz kuraklık katsayısı (iklim değişikliği) denkleminin unsurlarından; nem yüzdesi ve sıcaklık parametresi, bileşen-3 (PC3) üzerinde; yağmur miktarı parametresi, bileşen-4 (PC4) üzerinde ve güneşlenme süresi parametresi de bileşen-5 (PC5) üzerinde ayrı ayrı önemli etkileri gözlemlenmektedir.

Tablo 6. Bağımsız değişkenlerin PCA bileşen ağırlıkları (katsayıları)

Değişken	Bileşen				
	PC1	PC2	PC3	PC4	PC5
Nüfus	-0.395	-0.035	-0.062	-0.014	0.115
Gelişmişlik	-0.384	0.001	-0.149	-0.095	0.108
Tarım	-0.332	0.019	-0.260	0.232	0.026
Ruhsat	-0.160	0.531	-0.055	0.131	-0.089
İskân	-0.307	-0.295	-0.037	-0.008	0.057
Abone	-0.377	-0.103	-0.181	-0.014	0.135
Sıcaklık	-0.278	-0.269	-0.282	0.310	-0.241
Yağış	0.283	-0.107	-0.209	0.520	-0.037
Buharlaşma	-0.072	-0.408	0.285	-0.409	0.282
Güneşlenme	0.167	0.082	-0.182	0.236	0.890
Nem	0.214	-0.267	-0.538	-0.310	-0.104
Rüzgâr	-0.263	0.033	0.536	0.267	0.024
Basınç	-0.136	0.538	-0.234	-0.403	0.048

2.2.4. Tahmin Modellerinde Kullanılacak Verilerin Seçimi

Tez çalışması kapsamında başlangıçta tespit edilen 16 adet parametreden 3 tanesi (içmesuyu proje büyüklüğü, atıksu proje büyüklüğü, dağıtım debisi) uzmanlarla gerçekleştirilen anket çalışması sonucunda, bağımlı değişken olarak değerlendirilmiş ve bu nedenle anket analizinden çıkarılmıştır.

Geriye kalan 13 parametre, bağımsız değişken adayı olarak SWARA Yöntemi, Aydeniz Yönetimi ve Temel Bileşen Analizi yöntemlerine tabi tutulmuştur. SWARA ile Temel Bileşen Analizi yöntemleri neticesinde, önceliklendirilmeleri (temsili ağırlık katsayıları) en yüksek çıkmış olan şehir gelişmişliği, yerleşim nüfusu ve kayıtlı abone sayısı parametrelerinin tahmin modelleri kapsamında, bağımsız değişken olarak kullanılması gerektiği tespit edilmiştir. Ayrıca, çalışmanın temel konusu olan iklim değişikliği etkilerinin kurulacak modellerde daha etkin ve verimli bir şekilde temsil edilebilmesi amacıyla, sıcaklık, güneşlenme süresi, yağış miktarı ve nem parametrelerinin birleşiminden oluşan Aydeniz Kuraklık İndeksinin de tahmin modelleri kapsamında bağımsız (girdi) değişken olarak kullanılması gerektiği sonucuna ulaşılmıştır.

Gerek uzman görüşleri (anket çalışması) gerekse de matematiksel analizlerdeki (SWARA Yöntemi, Aydeniz Yönetimi ve Temel Bileşen Analizi) değerlendirmeler ışığında, başlangıçta belirlenen 16 parametreden 4'ü (şehir gelişmişliği, yerleşim nüfusu, kayıtlı

abone sayısı ve Aydeniz Kuraklık İndeksi) bağımlı değişken (hedef değişken) olarak belirlenen su dağıtım debisini etkileyebilecek, temel parametreler olduğu tespit edilmiştir. Bu doğrultuda, söz konusu parametrelerin kurulacak yapay zekâ destekli tahmin modellerinde bağımsız değişken olarak kullanılması uygun bulunmuştur.

Ayrıca, yapı ruhsatı ve yapı kullanım izin belgesi sayısının değerlendirilme dışında tutulması; şehirdeki yüksek oranda kaçak-izinsiz yapılan inşaat faaliyetlerinden kaynaklanmaktadır. Özellikle 2018 yılında çıkarılan imar affıyla birlikte, gelen başvurular nedeniyle 2018 yılı ve sonrasındaki yıllarda veri sayısında artış ve dalgalanmalar olmuştur. Yine aynı şekilde, tarım alanı miktarında da bu durumdan bahsedilebilir. İklim parametrelerinden olan, buharlaşma miktarı, rüzgâr hızı ve atmosfer basıncının da tercih edilmeme sebebi olarak, Aydeniz indeksinin, bu parametrelere bağlı olmaması ve iklimsel durumu bu parametrelerden daha iyi temsil ettiği söylenebilir.

2.3. Tahmin Modeli Çalışmaları

İçme suyu proje büyüklüğü, atıksu proje büyüklüğü ve dağıtım debisi bağımlı değişkenlerini tahmin etme çalışmalarına başlarken bu değişkenleri en fazla etkileyebilecek bağımsız değişkenler, kullanılan yöntemler bölümünde belirlenmişti. Kurulacak olan modelde, birden fazla bağımlı değişken olması, bunların birbirleriyle yüksek derecede ilişkili (kollinearite) olması problemine sebebiyet vererek, modelin veriye aşırı uyum sağlamasına ve genelleme yeteneğinin azalmasına neden olabilmektedir. Bağlı değişkenin istenilen sayıdan fazla olması, bağımsız değişkenlerin, bağımlı değişken üzerindeki gerçek etkilerinin belirlenmesini zorlaştırarak, kurulacak modelin doğruluk ve güvenilirliğinin test edilmesini de karmaşık hale getirecektir. Bu gibi sorunların modelin etkinliğini olumsuz yönde etkilememesi için modeli oluştururken bağımlı değişkenlerin sayısını optimize etmek ve modelin performansını ve genelleme yeteneğini dikkate almak, son derece önemlidir. Kurulacak modelin; doğru anlaşılması ve yorumlanması, modelin tahmin performansını şüphesiz olumlu yönde etkileyecektir.

Bundan dolayı, kurulacak model sayısının iki aşamalı olarak belirlenmesi kararlaştırılmıştır. İlk aşamada, önceki parametre tespit çalışmalarında belirlediğimiz; gelişmişlik (GSYH ile ifade edilecek), nüfus, abone sayısı ve Aydeniz kuraklık indeksi (katsayısı) bağımsız değişken olarak seçilerek, bağımlı değişkenimiz olan su dağıtım debisinin belirleneceği birinci model kurulmuştur.

Birinci modelde, toplamda dört bağımsız değişkene karşılık bir bağımlı değişken kullanılarak modelleme çalışmalarına başlanmıştır. Modelleme çalışmalarında makine öğrenmesi teknikleriyle kurulacak modellerin doğruluklarının değerlendirilebilmesi için veri seti, eğitim, test ve tahmin (sınama) veri setlerine ayrılmıştır. Bu sayede eğitim setleri ile kurulan modellerin aşırı öğrenme (overfitting) probleminin önüne geçilmeye çalışılmış ve modellerin doğruluğu, test verisi kullanarak sınanabilmiştir.

Veri setimiz, oldukça uzun yıllar uğraş ve araştırmalar sonucu elde edilen 18 yıllık (2006-2023) veri setinden oluşmaktadır. Ülkemizin 2007 yılından sonra adım adım geçtiği dijital kayıt sistemleriyle yakın zamanlara ait veriler toplanabilmiştir. Veriler eğitim, test ve tahmin setlerine ayırma aşamasına tabi tutulmuş olup toplamda üç farklı senaryo denenmiştir. Kurulan esas modelin eğitim ve test setleri, 2006-2020 yılları arasını kapsayan 15 yılı barındırmaktadır. Geriye kalan son 3 yıl (2021-2023), modelin tahmin performansını test edebilmek için ayrılmıştır. Makine öğrenmesi algoritmalarının kullanıldığı modellerin performansı değerlendirilirken veri seti, algoritmalara uygun olacak şekilde hold out (eğitim ve test seti oranları) ve k katlı çapraz doğrulama (cross validation) yapılmıştır. Bundan dolayı eğitim ve test setleri farklı senaryolara tabi tutulmuş, en iyi performansı sergileyen bölünmeye göre model seçilmiştir. Yapılan analizler neticesinde de kabul edilebilir sonuçların olduğu görülmüştür.

Veri setindeki bazı parametrelerin pik değerlerde olduğu görülmüş olup toplanan veri sayılarının nicelik durumunun model performansını ciddi anlamda etkilememesinden dolayı, bu değerler kurulan modellerden çıkarılmamıştır. Veri setinde yapılan ön incelemede, verilerde sürekli artış trendi gözlemlenmektedir. Adana'da merkez ilçelerin nüfus yoğunluğu, tüm şehir nüfusunun ortalama %78-%80 civarlarındadır. Şehirleşmenin yoğunlaşmasıyla birlikte, nüfus ve bina (mesken, işyeri vs.) artışı yanında yeni altyapı ihtiyacını da beraberinde getirmektedir. 2023 yılında nüfus azalışının sebebinin, asrın felaketi olarak bilinen on bir şehri etkileyen deprem etkisi olduğu düşünülmektedir. GSYH tespit yöntemi alıcı (ürünlerin nihai fiyatlarının enflasyon, kur artışı, vergi vs. eklenmiş) fiyatlar üzerinden olduğu için gerçek piyasa koşullarını yansıtmaktadır. 2008 ve 2018 yıllarındaki ekonomik belirsizlik, kendinden sonraki yıllarda etkisini göstermiştir. İklim değişikliği parametreleri olan yıllık kuraklık katsayı, yıllar içinde büyük dalgalanmalar göstermiş, bazı yıllar diğerlerine göre çok daha kurak veya çok daha nemli geçmiştir. Verilerde belirli bir düzen veya trend gözlenmemekte olup yıllar arası kuraklık katsayıları, başta 2009, 2012 ve 2016 yılları olmak üzere oldukça değişkenlik göstermiştir. Günümüzde

ise kuraklık seviyesinin daha tutarlı ve yüksek olduğu görülmektedir. Adana şehrinin iklim yapısını ortaya koyan bu durumlar, kuraklık yönetimi ve su kaynakları planlamasının önemini ortaya koymaktadır.

Dağıtım debisi miktarındaki düzenli artış hem içmesuyu hem de atıksu projelerinin büyüklüğünün de sürekli artmasına neden olmuştur. Bu durum da artan nüfus ve büyüyen endüstriyel faaliyetlerin bir göstergesi olarak yorumlanabilir. 2010 yılından sonra, kaynak ve yatırımların artmasına bağlı olarak, büyüme oranlarındaki artış, altyapı projelerinde ciddi bir büyüme eğilimine dönüşmüş olup bu eğilim de artan su talebinin bir göstergesi durumundadır.


Tüm bu değerlendirmeler bir bütün olarak ele alındığında; tez çalışmamızın, sosyo-ekonomik ve iklimsel parametre verileri ile altyapı ihtiyacının tespitinde paralellik gösterdiği belirlenmiştir. Çalışma kapsamında yukarıda bahsedilen senaryolara ait bulgular tez kapsamından “3. Bulgular ve İrdelemeler” başlığı altında detaylıca verilmiştir. Bahse konu senaryo durumları için verilerin; eğitim, test ve tahmin verilerine nasıl ayrıldığı farklı vurgular ile Tablo 7’de sunulmuştur. Gri renk ile vurgu yapılanlar eğitim, turuncu renk tonlarında olanlar test, mavi renk tonunda olanlar ise tahmin setine dahil edilmiştir. İçmesuyu proje büyüklüğü, atıksu proje büyüklüğü ve dağıtım debisi bağımlı değişkenlerinin modelleme ve analizler sonucunda en optimum sonucu veren eğitim (a), test (b) ve tahmin (c) veri setlerine ait zaman serileri Şekil 13’te verilmiştir.

Tablo 7. Verilerin eğitim, test ve tahmin setlerine ayrılması (I. ve II. Aşama)

YIL	Bağımlı Değişkenler		Bağımsız Değişkenler				
	İçmesuyu Proje Büyüklüğü (m)	Atıksu Proje Büyüklüğü (m)	Debi (m ³)	Nüfus (kişi)	Gelişmişlik (GSYH) (Bin TL)	Abone Sayısı (adet)	Aydeniz Kuraklık Katsayısı
2006	5.189,42	2.185,46	53.802.809	1.515.815	19.912.360	404.444	1.057
2007	5.396,16	2.398,97	56.209.408	1.530.257	21.002.159	423.894	1.027
2008	5.613,00	2.582,00	59.771.582	1.549.102	20.987.416	451.064	1.819
2009	5.880,02	2.739,38	61.079.384	1.589.473	20.447.250	470.543	0.681
2010	6.028,25	2.873,48	66.144.791	1.614.072	22.285.205	483.581	1.517
2011	6.406,23	3.065,46	69.470.451	1.639.819	24.254.546	496.887	1.113
2012	6.638,39	3.232,79	74.290.092	1.659.055	25.634.711	502.628	0.514
2013	6.904,99	3.471,86	79.767.110	1.678.046	27.817.077	511.700	1.735
2014	6.961,08	3.672,56	82.228.600	1.695.699	28.523.910	547.791	0.948
2015	7.085,65	3.784,38	84.927.842	1.717.473	30.297.483	558.675	1.148
2016	7.180,69	3.818,45	90.254.595	1.736.564	31.782.405	571.005	0.934
2017	7.245,74	3.949,51	91.620.226	1.753.337	33.128.140	585.228	1.497

Tablo 7'nin devamı

2018	7.332,41	4.068,57	93.09.2517	1.747.567	32.892.440	602.480	0.678
2019	7.407,28	4.146,71	94.220.158	1.768.860	33.471.468	623.907	0.754
2020	7.548,84	4.213,33	100.592.340	1.788.876	35.712.507	659.135	1.350
2021	7.664,74	4.281,54	101.403.451	1.797.136	39.711.988	692.032	1.149
2022	7.772,72	4.321,08	105.412.862	1.810.646	42.633.165	722.716	1.240
2023	7.848,50	4.371,11	110.906.891	1.800.619	44.551.658	757.341	1.126



Şekil 13. Optimum modelde içmesuyu proje büyüklüğü, atıksu proje büyüklüğü, su dağıtım debisi değişkenleri eğitim (a), test (b) ve tahmin (c) veri setlerine ait zaman serileri

Veri setindeki, özniteliklerin diğerlerine göre daha fazla etkili (baskınlığın azaltılması) olmasını engellenmesi ve dataların daha etkili ve verimli bir şekilde işlenebilmesi için literatürde sıklıkla normalizasyon işlemi yapılmaktadır. Bu işlem sayesinde, modelin kararlılığını artır ve ağırlıkların optimize edilmesi kolaylaştırılarak modelin tahmin performansı arttırılmış olunur (Cabello vd., 2023). Güncel makina öğrenme algoritmaları, analizlerin daha doğru yapılabilmesi için normalizasyona ihtiyaç duymaktadır. Veri setindeki tüm datalar, X_n normalize değeri ifade etmek üzere Eşitlik 22 kullanılarak min-max yöntemiyle 0 ile 1 arasında normalize edilmiştir.

$$X_n = \frac{\text{Gerçek değer} - \text{En küçük değer}}{\text{En büyük değer} - \text{En küçük değer}} \quad (22)$$

Modelleme çalışmalarında kullanılan makine öğrenmesi algoritmalarının tahmin performans sonuçlarını değerlendirmek ve karşılaştırmak için literatürde bazı ölçüm kriterleri kullanılmaktadır. Bunlardan en sık kullanılanları; ortalama mutlak hata (MAE, Mean Absolute Error), ortalama hata kareleri toplamı kökü (RMSE, Root Mean Squared Error), R^2 (Determinasyon Katsayısı) ve NSE (Nash Sutcliffe Verimlilik) katsayısıdır. Tezimizde; her model için kullanılan bu performans ölçüm kriterleri, Eşitlik 23-25 kullanılarak hesaplanmıştır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - td_i| \quad (23)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - td_i)^2} \quad (24)$$


$$NSE = R^2 = 1 - \frac{\sum_{i=1}^n (t_i - td_i)^2}{\sum_{i=1}^n (t_i - \bar{t})^2} \quad (25)$$

Bu eşitliklerde n veri sayısını, t_i ifadesi i . gerçek değeri, td_i ifadesi i . tahmin değerini, $\bar{t}$ ifadesi gerçek değerlerin ortalamasını ifade etmektedir. MAE ve RMSE değerlerinin 0 değerine, R^2 ve NSE değerlerinin de 1 değerine yakın olması, model doğruluğunun arttığına işaret etmektedir (Babacan ve Saka, 2022). R^2 ve NSE değer formüllerinin aynı olduğu görülmektedir ancak R^2 değeri modelin (test, eğitim setinin) R^2 , açıklama gücünü (bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini) ölçer, NSE değeri ise model

tahminlerinin doğruluğunu ve güvenilirliğini değerlendirmektedir. Literatürde sıkça kabul gören oranlara göre R^2 değerinin 0.50-0.75 aralığında olması "orta düzeyde", 0.75 ve üzeri ise "güçlü" bir açıklamayı ifade etmektedir (Hair vd., 2011). Benzer şekilde, NSE değerleri için 0.5'in altında "yetersiz", 0.5-0.7 arası "kabul edilebilir", 0.7-0.9 arası "iyi" ve 0.9-1 arası "mükemmel" bir tahmin olarak tanımlanmaktadır (Başakın vd., 2019).

2.4. Denetimli Makine Öğrenmesi ile Tahmin Modeli

Denetimli öğrenme (supervised learning), makine öğrenimi alanında en yaygın kullanılan tekniklerden biridir. Bu yöntemde, giriş verileri etiketlenmiş veri setinden ibarettir. Her veri noktası, belirli özellikler ve bu özelliklere karşılık gelen bir etiketten oluşur. Giriş verisi, makine öğrenmesi algoritmasına beslenir ve model bu veriler üzerinde eğitilir. Eğitim aşamasının sonunda; makine öğrenme algoritması, giriş-etiket ilişkisini temsil eden bir model oluşturur. Eğitimi biten model, eğitim verisinden bağımsız olarak veri setinden ayrılmış olan test verisi üzerinde değerlendirilir. Test aşaması, modelin genel performansını ve genelleme kabiliyetini ölçüldüğü bölümdür. En sonunda çıktı aşamasına geçilerek, kurulan modelin test verisi üzerindeki tahminleri, modelin genel performansını değerlendirmek için kullanılır (Bishop, 2006; Murphy 2012, Aylak vd., 2021). Tüm bu aşamaları temsil eden diyagram Şekil 14'te verilmektedir.



Şekil 14. Makine öğrenmesi temel süreci (Gültepe, 2019)

Kurulan tahmin modellerindeki kodlama, yapay zekânın alt dalı olan makine öğrenmesi uygulamalarında oldukça başarılı ve kullanışlı olan PHYTON programlama diliyle yapılmıştır.

Çalışmamızda kullanılacak olan ve etiketli verilerle eğitilecek olan girdi ve çıktı değişkenleri aşağıda verilen algoritmalar ile ayrı ayrı çözümlenmiştir:

- Lasso (Least Absolute Shrinkage and Selection Operator) Algoritması
- Ridge Algoritması
- XGBoost (Extreme Gradient Boosting) Algoritması
- SVR (Support Vector Regression) Algoritması

İki aşamalı olarak planladığımız tahmin modelleme çalışmalarında; ilk aşamadaki dağıtım debisi tahmininde, temel parametrelili ve optimize hiper parametrelili olmak üzere iki farklı modellemekten en iyi tahmin performansını gösteren makine öğrenmesi algoritmaları ile ikinci aşamadaki proje büyüklüğü tahminini model performansı kapsamında iki farklı şekilde yapılmıştır. Tüm bu model analizlerine ilişkin “3. Bulgular ve İrdeleme” başlığı altında detaylıca verilmektedir.

Kurulacak modellerde; tahmin edilmesi amaçlanan bağımlı değişkenlerin, en verimli ve en hızlı şekilde yapılması için modelin veri setinde görmediği verilerle ile test edilmesi sağlanmıştır. Bunun için stratifike k-kat çapraz doğrulama ve eğitim-test split (hold-out) yöntemleri, algoritmalara uygun şekilde kullanılmıştır.

Çapraz doğrulamada, veri seti k eşit katmana bölünür. Her bir katman, sırasıyla bir kez test seti olarak kullanılırken, kalan k-1 katman eğitim seti olarak kullanılır. Bu işlem her bir katman test seti olarak kullanılacak şekilde k kez tekrarlanır. Modelin nihai performansı, test seti ölçütlerinin ortalaması alınarak tespit edilir (Raschka ve Mirjalili, 2017). Bu yöntemde her veri hem eğitim hem test için kullanıldığından, daha dengeli ve güvenli sonuçları verirken, veri setinde değişkenlerin fazla olması durumunda uzun zaman almakta olup tahmin sonuçlarında sapmalar yapabilmektedir (Bishop, 2006).

Hold out yönteminde model, eğitim ve test olmak üzere iki parçaya ayrılmakta, modelin performans sonucuna göre en uygun oran seçilmektedir. Hızlı ve basit olan bu yöntemde, modelin performansı veri setinin bölünme biçimine göre değişmektedir (Murphy, 2012; Raschka ve Mirjalili, 2017). Bağımsız değişkenlerin fazla olduğu çalışmanın ilk aşamasında bu yöntemin kullanılması tercih edilmiştir. Her makine öğrenme algoritması sırasıyla; %90 eğitim-%10 test, %80 eğitim-%20 test, %70 eğitim-%30 test, %60 eğitim-%40 test, %50 eğitim-%50 test olmak üzere beş farklı biçimde (örneğin, Ridge algoritması

için R-I, R-II, R-III, R-IV, R-V) modellenerek performans ölçütleri incelenmiştir.

2006-2020 yılları arasındaki verilerin işlenmesiyle kurulan yüksek performanslı algoritmik modeller neticesinde, Adana şehri merkez ilçelerinin 2021-2026 yılları arasındaki dağıtım debisi ve proje büyüklükleri aşağıdaki senaryoya göre tahmin edilmiştir.

Kurulan modellerin tahmin performansını ve doğruluğunu belirleyebilmek için tez yazım sırasında açıklanmış olan 2021-2023 dönemlerine (2023-GSYH hariç) ilişkin veriler kullanılacak olup bu yıllara ait gözlemlenen değerlerle tahmin edilen değerler arasında, gerçek anlamda bir karşılaştırma yapılmıştır.

Senaryolarda kullanılan; nüfus verileri TÜİK 2018-2080 yılları gelecek nüfus projeksiyonundan, GSYH verileri Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığınca hazırlanan 2024-2026 yılı Orta Vadeli Programa göre büyüme beklentisinden, kuraklık katsayısı, Meteoroloji Genel Müdürlüğü'nün 2020-2040 yılları arasında Adana başlıklı kuraklık projeksiyonundan, abone sayısı değişkenin de gerçek artış oranları dikkate alınarak Adana şehrine uyarlanmak suretiyle ele alınmıştır (TÜİK, 2016; SBB, 2023; MGM, 2021). Senaryolarda kullanılan veriler Tablo 8'de sunulmuştur.

Tablo 8. Tahmin senaryosunun veri seti (I. ve II. Aşama)

Yıl	İçmesuyu Proje Büyüklüğü (m)	Atıksu Proje Büyüklüğü (m)	Dağıtım Debisi (m ³)	Yerleşim Nüfusu (kişi)	Gelişmişlik (GSYH) (in TL)	Abone Sayısı (adet)	Aydeniz Kuraklık (Katsayısı)
2021	7.664,74	4.281,54	101.403.451	1.797.136	39.711.988	692.032	1,149
2022	7.772,72	4.321,08	105.412.862	1.810.646	42.633.165	722.716	1,241
2023	7.848,50	4.371,11	110.906.891	1.800.619	44.551.658	757.341	1,126
2024	---	---	---	1.817.534	46.333.724	791.421	1,408
2025	---	---	---	1.830.967	48.418.742	825.452	1,548
2026	---	---	---	1.844.106	50.839.679	859.296	1,703

Bu çalışma, Adana ilindeki altyapı projelerinin maliyet bileşenleri üzerinde, iklim değişikliği ve sosyo-ekonomik parametrelerin etkilerini inceleme amacıyla gerçekleştirilmiş olup bu yönüyle yapım yönetimi alanında önemli bir boşluğu doldurmayı hedeflemiştir.

Çalışmanın özgünlüğü hem nicel analizleri hem de uzman görüşlerini bir araya getirerek altyapı projelerinin tahmini için çok yönlü bir yaklaşım sunmasında yatmaktadır. Bu doğrultuda, altyapı projeleri konusunda deneyimli 30 uzmanla görüşmeler yapılmış, ardından gerçekleştirilen anket çalışmasıyla elde edilen veriler SWARA yöntemiyle

değerlendirilerek bağımsız değişkenlerin önceliklendirilmesi sağlanmıştır. Aynı zamanda, bağımsız değişkenlere temel bileşen analizi (PCA) uygulanarak özellik seçimi yapılmış ve modellemede yalnızca en etkili bağımsız değişkenlerin yer alması sağlanmıştır.

Çalışma sürecinde veri temini ve toplanılan verilerin analiz süreçlerinin planlanmasında bazı zorluklar yaşanmıştır. Altyapı projelerine esas veriler, ASKİ Genel Müdürlüğü ve İLBANK Adana Bölge Müdürlüğü gibi kurumlardan temin edilmiş olup, resmî kurumlardan veri temin etmenin getirdiği prosedürel süreçler zaman alıcı olmuştur. Ayrıca, elde edilen verilerin farklı formatlarda (ihale, sözleşme, hakediş, iş programı vs.) olması ve içmesuyu ile atıksu projelerine yönelik mekânsal ve yıllık bazda düzenlenmesi, veri işleme ve analiz süreçlerini daha titiz bir planlama gerektirir hale getirmiştir. İklim değişikliği parametrelerine ilişkin veriler de Meteoroloji Genel Müdürlüğü'nün MEVBİS sisteminden elde edilmiş, bu süreçte verilerin güvenilirliği, uygun formatta hazırlanıp ve kullanılması için dikkatli bir veri ön işleme gereksinim duyulmuştur.


Bu çalışmanın yenilikçi ve öncü yapısı, süreç boyunca uzmanlarla sürekli fikir alışverişi yapılmasını ve analizlerin titizlikle planlanmasını gerektirmiştir. Bağımsız değişkenlerin seçimi için uygulanan SWARA ve PCA yöntemleri, modelleme sürecinin doğruluğunu artırmış ve değişkenlerin etkin şekilde belirlenmesine olanak tanımıştır. Bu yöntemlerin uygulanması sırasında, veri setlerinin detaylı analizi ve modellere uyumlaştırılması, dikkat ve zaman gerektiren bir süreç olmuştur.

Verilerin modelleme sürecinde, Python programlama dili kullanılmıştır. Programlamada, kodlama işlemleri, “Anaconda” platformu üzerinden, geniş bir veri analizi ve modelleme desteği sunan “Jupyter Lab” ortamında gerçekleştirilmiştir. Python’un güçlü veri işleme, modelleme ve görselleştirme yeteneklerinden yararlanılarak hem veri ön işleme hem de tahmin modellerinin kurulması sağlanmıştır. Veri işleme, modelleme ve analiz süreçlerinde Python’un “scikit-learn” ve makine öğrenme algoritmalarının güçlü kütüphanelerinden faydalanılmıştır.


Kodlama sürecinde, en iyi tahmin sonuçlarına ulaşabilmek için Ridge, Lasso, XGBoost ve SVR makine öğrenmesi algoritma modelleri kullanılmıştır. Kurulan her bir modelin performansı, değerlendirme metrikleri ile ölçülerek karşılaştırılmış olup en yüksek performansı gösteren model seçilmiştir. Kodlama sırasında; veri işleme, matematiksel özellik seçimi ve hiper parametre ayarlaması (model tuning) gibi kritik adımlar detaylı bir şekilde ele alınmıştır.

Söz konusu süreçler hem literatürde yer alan yöntemlere hem de çalışmanın özgün ihtiyaçlarına uygun olarak gerçekleştirilmiş, iklim değişikliği ve sosyo-ekonomik değişkenlerin altyapı projeleri üzerindeki gelecekteki etkilerini anlamada ve tahmin etmede başarılı sonuçlar ortaya koymuştur. Geliştirilen bu yaklaşımlar ile hem model doğruluğu hem de uygulama kolaylığı açısından literatüre önemli katkı sağlanmaktadır.

Tez çalışması kapsamında, dağıtım debisi ve proje büyüklüklerinin tahminine yönelik kurulan yapay zekâ destekli makine öğrenmesi modellerinde, izlenen adımları gösteren akış diyagramları Şekil 15 ve 16’da sunulmaktadır.




Şekil 15. Dağıtım debisi tahminine (I. Aşama) yönelik akış diyagramı




Şekil 16. Proje büyüklükleri (II. Aşama) tahminine yönelik akış diyagramı

Kodlama sürecinde; dağıtım debisi, içmesuyu ve atıksu altyapı projelerine yönelik tahmin modellerinin geliştirilmesinde, Python programlama dili kullanılmış ve çeşitli makine öğrenmesi algoritmaları uygulanmıştır. Bu süreçte, veri işleme, özellik seçimi ve model performans değerlendirme gibi kritik adımlar sistematik bir yaklaşımla ele alınmıştır. Kodlama sürecine ait örnekler, uygulanan yöntemlerin detaylarını göstermek amacıyla Şekil 17, 18, 19 ve 20’de sunulmaktadır.




Şekil 17. Dağıtım debisi tahmin modelinin python koduna ait ekran alıntısı

(Ridge algoritmasıyla dağıtım debisi bağımlı değişkenini tahmin edebilmek için modelin kurulum, eğitim ve performans metrikleriyle doğrulanmasına ait kodlama örneğidir.)




Şekil 18. Dağıtım debisi model grafiklerinin python koduna ait ekran alıntısı

(Dağıtım debisi bağımlı değişkenini tahmin edebilmek için Lasso, Ridge, XGBoost ve SVR algoritmaları modellerin veri açıklamasını gösteren saçılım grafiğine ait kodlama örneğidir.)



Şekil 19. İçmesuyu proje büyüklüğü tahmin modelinin python koduna ait ekran alıntısı

(SVR algoritmasıyla içmesuyu proje büyüklüğü bağımlı değişkenini tahmin edebilmek için modelin kurulum, eğitim ve hiper parametre ayarlamasına ait kodlama örneğidir.)



Şekil 20. Atıksu proje büyüklüğü tahmin modelinin python koduna ait ekran alıntısı

(Ridge ve SVR algoritmaları atıksu proje büyüklüğü bağımlı değişkenini tahmin edebilmek için modelin matematiksel etkileşim terimleriyle kurulum, eğitim, doğrulama ve hiper parametre ayarlamasına (optimizasyon) ait kodlama örneğidir.)

3. BULGULAR VE İRDELEMELER

Bu başlık altındaki tahmin modellerine ilişkin bulgular, iki ana bölüme ayrılmıştır. İlk bölümde 4 adet bağımsız değişken (nüfus, gelişmişlik, abone sayısı, kuraklık katsayısı) ile dağıtım debisi bağımlı değişkeninin tahminine yönelik Lasso, Ridge, XGBoost ve SVR algoritmalarıyla geliştirilen modellere ait bulgular ve irdelenmeler yapılmıştır. İkinci bölümde ise dağıtım debisi bağımsız değişken seçilerek, içmesuyu ve atıksu proje büyüklüğü bağımlı değişkenine ait birinci aşamada en iyi sonucu veren algoritmalar ile modelleme ve tahmine ilişkin bulgular sunulularak irdelenmiştir. İki ana bölüm kendi içerisinde; tahmini yapılan bağımlı değişkenlerden olan dağıtım debisi, içmesuyu proje büyüklüğü ve atıksu proje büyüklüğü alt başlıkları altında ayrı ayrı incelenerek algoritmik model bulguları verilmiş ve irdelenmiştir.

Kullanılan veri seti için hangi algoritmanın başarılı ve doğru sonuçları vereceğini önceden tahmin etmek zor olduğundan, bu çalışmanın sonuçları incelendiğinde kullanılan algoritmalarından hangisinin yüksek doğruluk derecesiyle en iyi tahmin sonucunu yansıttığı tespit edilecektir. Her algoritma, başlangıç ve en küçük hata değerine sahip model ayarlamalı (model tuning, optimize hiper parametreli) olmak üzere iki farklı şekilde modellenip ve tahmin sonuçları irdelenmiştir.


3.1. Dağıtım Debisi Tahmin Modellerine İlişkin Bulgular

3.1.1. Ridge Algoritması ile Tahmin Modeli

Ridge regresyonu, lineer regresyon modellerinde aşırı uyumu (overfitting) önlemek için kullanılan bir düzenleme (regülerizasyon) tekniğidir. Ridge regresyonu, modelin katsayılarını küçülterek ve böylece bazı gereksiz katsayıları sıfıra yaklaştırarak aşırı uyumu azaltır. Ridge regresyonun temel prensibi, bağımsız değişkenlere L2 (Euclidean normu) düzenlemesi ile değişken ağırlıkların karelerinin toplamını ceza (penalty) olarak eklemeye dayanmaktadır. Uygulanan bu cezanın gücünü alpha (α) parametresi belirlemektedir. Alpha katsayısı, modelin karmaşıklığını kontrol ederek regresyon modelinin doğruluğunu artırmak ve aşırı uyum riskini azaltmak için düzenleme yapan çok önemli bir parametre olup dikkatlice seçilmesi gerekmektedir. Seçilen bu katsayının küçük olması (0,01-0,1)

model üzerinde düzenleme etkisinin küçük olmasına yani modelin veri setine daha fazla uyum sağlamasına (modelin veriye uyması; overfitting) neden olabilir. Büyük alpha (10-100) değerlerinde ise güçlü bir düzenleme (ağırlık küçültme) yaparak modelin daha basit hale gelmesine ve aşırı uyum riskinin azaltılmasına katkı sağlar.

Kurulan modellere ilişkin, alpha (α) katsayısının R^2 değeriyle değişimini gösteren model performans grafiği Şekil 21’de sunulmaktadır. Grafiğe göre başlangıç alpha (α) değeri 1 iken ayarlanmış (optimizasyonlu) modelde en ideal (α) katsayısı 0,1322 olmuştur. Logaritmik ölçek (-3,3,100) kullanılarak 0.001 ile 1000 arasında, 100 farklı alpha değeri ile geniş yelpazede en iyi en ideal alpha değeri (α) elde edilmiştir. Bu değerlere göre ilk durumda orta seviyeli ve dengeli bir model kurulmuşken, optimizasyon (model tuning) durumunda daha düşük düzenlemeli bir model benimsenmiştir. En ideal alphanın, başlangıç değerine göre küçük olmasında normalize edilmiş bağımsız değişkenlerin etkisi olduğu görülmektedir.



Şekil 21. Ridge algoritması alpha (α) değişim grafiği

Alpha (α) katsayısının tespitinden sonra, normalize edilen veri seti kullanılarak dağıtım debisi değişkenini tahmin etmek için kurulan Ridge algoritması modellerine ait eğitim, test ve tahmin veri setleri için elde edilen performans ölçüt istatistikleri Tablo 9 ve 10’da verilmiştir.

Tablo 9 ve Tablo 10 incelendiğinde eğitim veri seti için en düşük MAE ve RMSE, en yüksek R^2 değerlerinin her iki analizde de I. modelde olduğu ve V. modele doğru sürekli

arttığı görülmektedir. Test setinde ise hata değerleri için eğitim setindeki gibi I. modelde en düşük değerde olmasına rağmen R^2 değeri II. modelde en yüksek çıkmıştır. R^2 katsayısındaki bu fark, test setinde yeterli sınama işleminin yapılmasından kaynaklanmıştır. Optimize edilmiş modelde, R^2 sıralamanın değişmediği ancak bu farkının çok azaldığı görülmektedir.

Tablo 9. Dağıtım debisi değişkeni için Ridge modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç parametrelili ($\alpha:1$) performans ölçüt istatistikleri


Eğitim	R-I	R-II	R-III	R-IV	R-V
MAE	0.064273	0.070405	0.078764	0.084006	0.097454
RMSE	0.069811	0.076459	0.08643	0.091342	0.111172
R^2	0.953677	0.938231	0.923208	0.921387	0.851953
Test	R-I	R-II	R-III	R-IV	R-V
MAE	0.048489	0.071898	0.073982	0.069974	0.114874
RMSE	0.051167	0.080099	0.079926	0.075783	0.137896
R^2	0.488108	0.948269	0.939278	0.935041	0.820354
Eğitim/Test	R-I	R-II	R-III	R-IV	R-V
NSE	0.954515	0.940718	0.929285	0.927357	0.841757
Tahmin	R-I	R-II	R-III	R-IV	R-V
MAE	0.020044	0.029963	0.048988	0.055469	0.093436
RMSE	0.029082	0.039924	0.056540	0.062334	0.099495
NSE	0.877980	0.770046	0.538811	0.439442	-0.428131

Tablo 10. Dağıtım debisi değişkeni için Ridge modellerinin eğitim, test ve tahmin veri setlerine ait optimize parametrelili ($\alpha: 0.1322$) performans ölçüt istatistikleri

Eğitim	R-I	R-II	R-III	R-IV	R-V
MAE	0.018739	0.020187	0.018457	0.019518	0.023134
RMSE	0.021282	0.022591	0.021251	0.022365	0.027514
R^2	0.995695	0.994608	0.995357	0.995287	0.990932
Test	R-I	R-II	R-III	R-IV	R-V
MAE	0.009816	0.011290	0.020709	0.018212	0.030825
RMSE	0.009837	0.011589	0.022551	0.020144	0.036825
R^2	0.981081	0.998917	0.995166	0.995410	0.987189
Eğitim/Test	R-I	R-II	R-III	R-IV	R-V
NSE	0.995967	0.995672	0.995319	0.995400	0.989292
Tahmin	R-I	R-II	R-III	R-IV	R-V
MAE	0.126892	0.125562	0.128749	0.126936	0.120955
RMSE	0.128594	0.127263	0.130429	0.128640	0.122626
NSE	-1.385670	-1.336526	-1.454236	-1.387388	-1.169372

Tablo 9 ve Tablo 10'daki tahmin sonuçlarının değerlendirme katsayısı NSE'de ise I. modelin her iki durumda da daha yüksek tahmin performansı gösterdiği, II. modelden sonra da bu performansın azaldığı dikkat çekmektedir. İleride yapılacak 2021-2023 yılı tahminlerini içeren tahmin setinde ise hata değerlerinin eğitim ve test setindeki gibi olduğu, tahmin performans göstergesi NSE değerinde ise başlangıç modellerinde, I. modelde en yüksek değerde olduğu ve sonraki modellerde bu değerin azaldığı görülmüştür. Optimize edilmiş modellerde ise değerlerin negatif olduğu, dolayısıyla tahmin performansı açısından çok kötü sonuç göstereceği görülmektedir.


Söz konusu ölçüt istatistiklerin bir bütün olarak değerlendirilmesi sonucunda, I. model her ne kadar hata, R^2 ve NSE değerlerinde ön plana çıksa da test verileri üzerindeki açıklama değeri kabul edilebilir düzeyde değildir. Modelin, genelleme yeteneğinin daha yüksek olması aşırı uyum sorunundan en az etkilenmesi ve daha güvenilir sonuçlar sağlayabilmesi için II. modelin, bundan sonraki tahmin süreçlerinde değerlendirmeye alınması daha uygun bulunmuştur. Bu durumun daha net görülebilmesi için Şekil 22'de dağıtım debisi bağımlı değişkenine ait yıllara sâri zaman serileri grafiği sunulmuştur.




Şekil 22. Ridge algoritması dağıtım debisi değişkenine ait zaman serisi grafiği

Zaman serisinde, ilk bölüm eğitim veri setini, kesik çizgili ikinci bölüm ise test veri setini temsil etmektedir. Hiper parametrelili optimize edilmiş algoritmanın, başlangıç hiper parametrelili algoritmaya göre kurulan modele göre daha yüksek oranda açıklama yaptığı

görülmektedir. Tahmin modellerinden elde edilen dağıtım debisi bağımlı değişkenine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 23 ve 24'te gösterilmektedir.



Şekil 23. Ridge algoritması dağıtım debisi değişkenine ait eğitim veri seti saçılım grafikleri



Şekil 24. Ridge algoritması dağıtım debisi değişkenine ait test veri seti saçılım grafikleri

Hazırlanan saçılım grafikleri incelendiğinde, verilerin optimizasyonlu modelin köşegene daha fazla yakın olduğu görülmekte olup optimizasyon hiper parametrelili modelin başlangıç modele kıyasla, gerçek dağıtım debisine daha yakın sonuçlar sergilemiştir.

Ridge algoritmasıyla oluşturulan modelden elde edilen parametreler ve hiper parametre fonksiyonlarına tespitine ilişkin değerler ve dağıtım debisi bağımlı değişkeninin elde edildiği denklem Tablo 11’de verilmiştir. Ayrıca modellerin, denklemlerinde kullanılan bağımsız değişkenlerin göreceli önemleri de Tablo 12’de gösterilmektedir.

Tablo 11. Ridge algoritması modelinin fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem

Başlangıç Temel Fonksiyonları	
Random State: 42 (HP)	
Maksimum iterasyon (max_iter): 1000 (HP)	
Alpha (α): 1 (HP)	
İntercept (Sabit): 0.1245 (P)	
Coefficients (Ağırlık): 0.2586 [N], 0.2278 [A], 0.2902 [G], -0.0190 [İ] (P)	
D dağıtım debisi = 0.1245 + 0.2586*N + 0.2278*A + 0.2902*G - 0.0190*İ	
Optimizasyonlu Model Fonksiyonları	
Random State: 42 (HP)	
Maksimum iterasyon (max_iter): 1000 (HP)	
Best Alpha (α): 0.132194114846 (HP)	
İntercept (Sabit): 0.0104 (P)	
Coefficients (Ağırlık): 0.3403 [N], 0.2499 [A], 0.3896 [G], 0.0109 [İ] (P)	
D dağıtım debisi = 0.0104 + 0.3403*N + 0.2499*A + 0.3896*G + 0.0109*İ	

Tablo 12. Ridge algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri

Başlangıç Modeli			Optimizasyon Modeli		
N	32.50		N	34.40	
A	28.60		A	25.20	
G	36.50		G	39.30	
İ	-2.40		İ	1.10	

Bu tablolarda, N, A, G ve İ sırasıyla nüfus, abone sayısı, gelişmişlik (GSYH) ve iklim değişikliği (kuraklık) katsayısı değerlerini temsil etmektedir. Tablo 11 incelendiğinde Ridge algoritması modelinin her iki analizde de bağımsız değişkenlerin önem sıralamasının aynı olduğu görülmektedir. Gelişmişlik (GSYH) kurulan modellerde en önemli parametre olmuştur. Kuraklık katsayısı ise başlangıçta kurulan modelde, negatif etki yaptığı göze çarpmaktadır. Bu durumun olmasında, iklim parametresi olan kuraklık verilerinin dalgalı olmasının etkisi fazladır.


Ridge algoritmalı modellerin bağımsız değişken katsayıları ve denklemini elde edildikten sonra, Tablo 8’de verilen senaryoya göre dağıtım debisi tahmin işlemleri her iki

model için gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası dağıtım debisini tahmin edildiği değerler Tablo 13'te sunulmaktadır.

Tablo 13. Ridge algoritması tahmin modeli sonuçları

Yıl	Gerçek Dağıtım Debisi (m ³)	Başlangıç Model (%80 Eğitim - %20 Test)		Optimizasyonu Model (%80 Eğitim - %20 Test)	
		Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)	Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)
2021	101.403.451	100.707.720	99.31%	106.989.089	94.78%
2022	105.412.862	105.038.203	99.64%	112.591.123	93.62%
2023	110.906.891	107.769.008	97.17%	115.764.734	95.80%
2024	---	111.283.093	---	120.481.774	---
2025	---	114.998.228	---	125.287.433	---
2026	---	118.970.801	---	130.460.624	---

Tahmin sonuçları genel olarak incelendiğinde, Ridge algoritması başlangıç modelinin, optimizasyonlu modele göre ilk üç yıl için gerçeğe daha yakın sonuçlar verdiği görülmektedir. Başlangıç hiper parametrelili model, ilk üç yıl için oldukça yüksek bir tahmin doğruluğu göstermiştir. Ridge algoritması, aşırı uyumu azaltmak için kullanılan bir regresyon tekniğidir ve bu sonuçlar modelin iyi bir genel performans sergilediğini göstermektedir. Nitekim, elde edilen değerlerin, gerçek değerlerle birbirine yakın olması kurulan Ridge modelin güvenilirliğini ortaya koymuştur. Bu kıyaslamamanın daha iyi yapılabilmesi için Şekil 25'te zaman serileri grafiği sunulmaktadır.




Şekil 25. Ridge algoritması tahmin modeline ait zaman serisi grafiği

3.1.2. Lasso Algoritması ile Tahmin Modeli

Lasso modeli, Ridge regresyon modeli ile benzerlik gösterir ancak ondan farklı olarak bazı katsayıları sıfıra eşitler ve böylece modelin daha yalın ve yorumlanabilir olmasını sağlar. Regresyonun temel prensibi, bağımsız değişkenlere L1 (Manhattan normu) düzenlemesi ile ağırlıkların mutlak değerinin toplamını ceza (penalty) olarak eklemeye dayanmaktadır. Uygulanan bu cezanın gücünü Ridge algoritmasında olduğu gibi α parametresi belirlemektedir. α katsayısının etkisi, bu algoritmada da aynıdır.

Kurulan modellere ilişkin, α katsayısının R^2 değeriyle değişimini gösteren model performans grafiği Şekil 26'da sunulmaktadır. Logaritmik ölçek (-3,3,100) kullanılarak 0.001 ile 1000 arasında, 100 farklı α değeri ile geniş yelpazede en küçük hata oranına göre en iyi optimum α değeri (α) elde edilmiştir. Grafiğe göre başlangıç α değeri 1 iken optimize edilmiş (α) katsayısı 0,001 olmuştur. Bu durum gerçek değerlerin modelde etkin olduğunu, optimizasyonlu durum için daha düşük düzenleme yapıldığı görülmektedir.



Şekil 26. Lasso algoritması Alpha (α) değişim grafiği

Lasso algoritması modeldeki gerek görülmeyen değişkenlere ait katsayıları sıfır yaptığı için veri setindeki verilerin de normalizasyonuna ihtiyaç duymaz, bu doğrultuda α katsayısı tespit edildikten sonra, dağıtım debisi değişkenini tahmin etmek için kurulan Lasso algoritması modellerine ait eğitim, test ve tahmin veri setlerinin performans ölçüt istatistikleri Tablo 14 ve 15'te verilmiştir.

Tablo 14. Dağıtım debisi değişkeni için Lasso modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç parametrelili ($\alpha:1$) performans ölçüt istatistikleri


Eğitim	L-I	L-II	L-III	L-IV	L-V
MAE	2.690347	2.735926	2.725980	2.626091	2.682864
RMSE	3.193737	3.419691	3.461588	3.341431	3.014395
R ²	0.955716	0.943560	0.943734	0.951947	0.950282
Test	L-I	L-II	L-III	L-IV	L-V
MAE	1.057377	3.219566	2.773115	2.452720	4.422679
RMSE	1.091354	4.631065	3.758598	3.247736	5.958505
R ²	0.893627	0.921013	0.938663	0.945505	0.846788
Eğitim/Test	L-I	L-II	L-III	L-IV	L-V
NSE	0.959115	0.938006	0.942311	0.950394	0.894703
Tahmin	L-I	L-II	L-III	L-IV	L-V
MAE	8.651072	7.766031	8.052075	8.301371	6.480905
RMSE	8.760033	7.864563	8.152317	8.404890	6.559609
NSE	-4.05692	-3.07590	-3.37962	-3.65521	-1.83551

Tablo 15. Dağıtım debisi değişkeni için Lasso modellerinin eğitim, test ve tahmin veri setlerine ait optimize parametrelili ($\alpha: 0.001$) performans ölçüt istatistikleri

Eğitim	L-I	L-II	L-III	L-IV	L-V
MAE	0.481804	0.504218	0.262202	0.277996	0.078499
RMSE	0.601840	0.625648	0.340971	0.353904	0.108088
R ²	0.998427	0.998111	0.999454	0.999461	0.999936
Test	L-I	L-II	L-III	L-IV	L-V
MAE	1.840685	1.337928	1.438505	1.212293	2.515799
RMSE	1.886830	1.551695	1.617041	1.457072	3.204440
R ²	0.682046	0.991132	0.988647	0.989031	0.955688
Eğitim/Test	L-I	L-II	L-III	L-IV	L-V
NSE	0.996417	0.996389	0.995688	0.995800	0.975093
Tahmin	L-I	L-II	L-III	L-IV	L-V
MAE	6.173702	6.266820	6.080618	6.074857	11.811823
RMSE	6.317926	6.404877	6.238156	6.231346	11.915576
NSE	-1.63041	-1.70331	-1.56440	-1.55881	-8.35631


Tablo 14 ve Tablo 15 incelendiğinde eğitim ve test veri seti için en düşük MAE ve RMSE, en yüksek R² değerlerinin her iki analizde de I. modelden V. modele doğru dalgalanmaların olduğu görülmektedir. Test setinde yeteri düzeyde sına yapılamamasından I. modelde R² değerinde düşüklük göze çarpmaktadır. Başlangıç modelinde, test ve eğitim seti NSE değerlerinde dalgalanmaların olduğu, optimize setinde ise doğrusal oranda artış göze çarpmaktadır. Bu durum da optimize modelin, verilere aşırı

uyum yapma riskini taşımaktadır. Tahmin sonuçlarının değerlendirme katsayısı NSE’de ise her iki analizde negatif değerlerde olduğu, bu durumun da modelin tahmin performansının çok kötü olacağını göstermektedir. Algoritma modellerindeki hata ve R^2 ve NSE değerleri birlikte değerlendirildiğinde; diğer modellerde arasında pek çok performans farkı olmayan II. model tahmin süreçlerinde değerlendirmeye alınacak olup bu modelin dağıtım debisi bağımlı değişkenine ait yıllara sâri zaman serileri grafiği Şekil 27’de sunulmuştur.




Şekil 27. Lasso algoritması dağıtım debisi değişkenine ait zaman serisi grafiği

Hazırlanan zaman serisinde, ilk bölüm eğitim veri setini, ikinci bölüm test veri setini temsil etmektedir. Hiper parametrelili optimize edilmiş algoritmanın, başlangıç (Alpha: 1) algoritmaya göre kurulan modele daha yüksek oranda uyum sağladığı görülmektedir. Algoritmik modelden elde edilen dağıtım debisine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 28 ve 29’da gösterilmektedir.



Şekil 28. Lasso algoritması dağıtım debisi değişkenine ait eğitim veri setlerinin saçılım grafikleri



Şekil 29. Lasso algoritması dağıtım debisi değişkenine ait test veri setlerinin saçılım grafikleri

Hazırlanan saçılım grafikleri incelendiğinde, optimizasyonlu model verilerinin köşegene daha fazla yakın olduğu görülmekte olup modelde eğitim ve test verilerinin gerçek dağıtım debisi değişkeninin daha çok uyum sağlamıştır.

Lasso algoritmasıyla oluşturulan modelden elde edilen parametreler ve hiper

parametre fonksiyonlarına tespitine ilişkin değerler ve dağıtım debisi bağımlı değişkeninin elde edildiği denklem Tablo 16’de verilmiştir. Ayrıca modellerin, denklemlerinde kullanılan bağımsız değişkenlerin göreceli önem yüzdeleri de Tablo 17’de gösterilmektedir.

Tablo 16. Lasso algoritması fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem

Başlangıç Temel Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Alpha (α): 1 (HP)
İntercept (Sabit): 9.8459 (P)
Coefficients (Ağırlık): 0 [N], 0 [A], 23.8833 [G], 0 [İ] (P)
D_dağıtım debisi = 9.8459 + 23.8833*G
Optimizasyonlu Model Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Best Alpha (α): 0.0011253 (HP)
İntercept (Sabit): -95.1934 (P)
Coefficients (Ağırlık): 76.495 [N], 4.291 [A], 15.466 [G], 0.798[İ] (P)
D_dağıtım debisi = -95.1934+ 76.495*N + 4.291*A + 15.466 *G + 0.798*İ

Tablo 17. Lasso algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri

Başlangıç Modeli			Optimizasyonlu Model		
N	0		N	78.80	
A	0		A	4.40	
G	100		G	15.90	
İ	0		İ	0.80	

Lasso algoritması, modelde karmaşıklığı kontrol etmek ve aşırı uyum (overfitting) problemini azaltmak için bazı bağımsız değişkenlerin katsayılarını sıfır yaparak ilgili değişkenleri modelden tamamen çıkarabilmektedir. Bu durum başlangıç modelinde açıkça gözükmemekte olup en önemli parametre olarak gelişmişliği ön plana çıkarmıştır. Optimizasyonlu modelde ise nüfus bağımsız değişkeni, gelişmişlik değişkenine göre beş kat daha önemli etkiye sahip olmuştur.


Lasso algoritmalı modellerin bağımsız değişken katsayıları ve denklemini elde edildikten sonra, Tablo 8’de verilen senaryoya göre dağıtım debisi tahmini

gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası dağıtım debisini tahmin edildiği değerler Tablo 18’de sunulmaktadır.

Tablo 18. Lasso algoritması tahmin modeli sonuçları

Yıl	Gerçek Dağıtım Debisi (m ³)	Başlangıç Model (%80 Eğitim - %20 Test)		Optimizasyonlu Model (%80 Eğitim - %20 Test)	
		Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)	Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)
2021	101.403.451	107.495.319	94,33%	107.584.949	94.25%
2022	105.412.862	114.472.045	92,09%	113.340.632	93.01%
2023	110.906.891	119.054.029	93,16%	115.598.179	95.94%
2024	---	123.310.187	---	120.019.967	---
2025	---	128.289.890	---	124.530.066	---
2026	---	134.071.879	---	129.548.377	---

Tablo 18’de verilen tahmin sonuçları incelendiğinde, her iki modelin de istenilen seviyede tahmin performansı sergilemediği görülmektedir. Bu sonuçlar üzerinde, Lasso algoritmasının bazı değişkenlerin katsayılarını sıfıra indirmesi etkili olmuştur. Hiper parametre optimizasyonu ile en iyi performans gösteren parametrelerin seçimi ise tahmin performansını biraz iyileştirmiştir. Tahmin edilen değerlerin, gerçek değerlerle ilişkisinin daha iyi görülebilmesi için Şekil 30’da zaman serisi grafiği sunulmaktadır.




Şekil 30. Lasso algoritması tahmin modeline ait zaman serisi grafiği

3.1.3. XGBoost Algoritması ile Tahmin Modeli

XGBoost, karar ağaçlarını temel alarak ve tahmin modellerinin doğruluğunu artırmak için de gradyan artırma (gradient boosting) tekniğini kullanan çok popüler bir bütünleşik makine öğrenmesi yöntemidir. XGBoost algoritması, karar ağaçlarının eğitilerek hataların minimize yapma esasına dayanan gradyan artırmayı, optimize etmek suretiyle daha da geliştirmek üzerine kuruludur. Algoritmanın yapısı gereği, tahmin modellerine karmaşıklığı ve aşırı öğrenmeyi (overfitting) önlemek ve performansı arttırmak için L1 (Lasso, alpha) ve L2 (Ridge, lambda) tipi regülasyon tekniğini kullanmaktadır. Bu sayede modelde, gereksiz değişken var ise alpha ile modelden çıkarılmasına, katsayıların çok büyük olması istenmiyorsa da lambda ile birlikte modelin kararlılığı sağlanmış olur.

Birden fazla algoritmayı içeriğinde barındıran XGBoost algoritmanın başarısı, doğru hiper parametre ayarları ile daha da artırılabilmekte olup learning rate (öğrenme hızı), n_estimators (ağaç sayısı), max_depth (ağaçların maksimum derinliği) ve subsample (alt örnekleme oranı) hiper parametreleri model performansını ve genelleyici yeteneğini optimize edilmesinde önemli rol oynamaktadır. Özellikle, modeldeki verilerden oluşturulan karar ağaçlarının yapısının optimize edilerek ve daha iyi ayırımlar yapmak için ağaç yapılarının derinliği ve düğüm sayısının ayarlanması tahmin sürecini önemli oranda etkiler.

Kurulan modellere ilişkin, anılan hiper parametrelerin RMSE değeriyle değişimini gösteren model performans grafiği Şekil 31’de sunulmaktadır. Genel olarak grafiklere bakıldığında, optimize modelde hata değerlerinin artış eğiliminde olduğu görülmektedir. Bunun yanında hiper parametre bazında bakılacak olunursa, modelin öğrenme hızını etkileyen learning rate ve her iterasyonda kullanılacak veri setinin oranını belirleyen subsample hiper parametreleri değer artışlarında RMSE değerlerinin artmasına neden olmaktadır. Bunun yanında, her bir karar ağacının maksimum derinliğini belirleyen max depth ve eğitilecek toplam ağaç sayısına karar veren n_estimators hiper parametrelerindeki artışlardan RMSE değerinin pek etkilenmediği görülmektedir.



Şekil 31. XGBoost algoritması hiper parametre- RMSE- değişim grafiği

Hiper parametrelerin tespitinden sonra, dağıtım debisi değişkenini tahmin etmek için kurulan XGBoost algoritması modellerine ait eğitim, test ve tahmin veri setlerinin performans ölçüt istatistikleri Tablo 19 ve 20’de verilmiştir.

Tablo 19. Dağıtım debisi değişkeni için XGBoost modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç hiper parametrelili performans ölçüt istatistikleri


Eğitim	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.001924	0.001866	0.001986	0.001977	0.002196
RMSE	0.002747	0.002754	0.003193	0.002921	0.002954
R ²	0.999928	0.999920	0.999895	0.999920	0.999895
Test	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.054005	0.047597	0.055059	0.064822	0.069787
RMSE	0.059597	0.049530	0.057299	0.075506	0.086298
R ²	0.305542	0.980220	0.968792	0.935516	0.929642
Eğitim/Test	XG-I	XG -II	XG -III	XG -IV	XG -V
NSE	0.995224	0.995059	0.989047	0.977266	0.960452
Tahmin	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.120406	0.118945	0.120857	0.120017	0.120107
RMSE	0.146387	0.145204	0.146998	0.146082	0.146539
NSE	-2.09152	-2.04174	-2.11741	-2.07867	-2.09795

Tablo 20. Dağıtım debisi değişkeni için XGBoost modellerinin eğitim, test ve tahmin veri setlerine ait optimize hiper parametrelili performans ölçüt istatistikleri

Eğitim	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.000710	0.005082	0.000974	0.000710	0.015112
RMSE	0.000835	0.007605	0.001251	0.000924	0.023091
R ²	0.999993	0.999389	0.999984	0.999992	0.993613
Test	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.050261	0.063341	0.055846	0.068502	0.074316
RMSE	0.052768	0.070948	0.066018	0.077689	0.095242
R ²	0.455584	0.959415	0.958572	0.931733	0.914303
Eğitim/Test	XG-I	XG -II	XG -III	XG -IV	XG -V
NSE	0.998255	0.999880	0.99538	0.992125	0.991898
Tahmin	XG-I	XG -II	XG -III	XG -IV	XG -V
MAE	0.117445	0.117128	0.119783	0.118537	0.122080
RMSE	0.143995	0.143965	0.146358	0.145268	0.151280
NSE	-1.99134	-1.99008	-2.09029	-2.04445	-2.30166


Tablo 19 ve Tablo 20 incelendiğinde eğitim ve test veri seti için MAE, RMSE, NSE ve R² değerlerinde, her iki analiz sonucunda dalgalanmalar göze çarpmaktadır. Özellikle NSE ve R² değerlerindeki oranlar, modellerin veriler üzerinde overfitting yaptığına işaret etmektedir. Bu durum da XGBoost algoritmasının veri öğrenmesine aşırı duyarlı olduğunu gösterir niteliktedir. Tahmin sonuçlarının değerlendirme katsayısı NSE’de ise her iki analizde negatif değerlerde olduğu, bu durumun da modelin aşırı ezber yaptığını ve buna bağlı olarak da tahmin performansının kötü olacağını göstermektedir.

Algoritma modellerindeki hata, R² ve NSE değerleri birlikte değerlendirildiğinde; diğer modellerle arasında pek çok performans farkı olmayan II. model tahmin süreçlerinde değerlendirmeye alınacak olup bu modelin dağıtım debisi bağımlı değişkenine ait yıllara sâri zaman serileri grafiği Şekil 32’de sunulmuştur. Hazırlanan zaman serisinde, ilk bölüm eğitim veri setini, ikinci bölüm test veri setini temsil etmektedir. Grafikte hem başlangıç hem de optimum model, eğitim seti üzerindeki gerçek değerlere bire bir yakın tahminler üretmektedir. Modellerin, eğitim seti üzerindeki yüksek performansının yanı sıra, test seti üzerinde de oldukça yüksek bir doğruluk sunduğunu göstermektedir. Özellikle optimum modelin R² değerinin 1 olması, bu modelin eğitim seti üzerinde aşırı uyum riski taşıdığını göstermektedir.




Şekil 32. XGBoost algoritması dağıtım debisi değişkenine ait zaman serisi grafiği

Algoritmik modelden elde edilen dağıtım debisine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 33 ve 34'te gösterilmektedir.



Şekil 33. XGBoost algoritması dağıtım debisi değişkenine ait eğitim veri setlerinin saçılım grafikleri



Şekil 34. XGBoost algoritması dağıtım debisi değişkenine ait test veri setlerinin saçılım grafikleri

Hazırlanan saçılım grafikleri incelendiğinde, zaman serisi grafiğinde olduğu gibi modellerin eğitim seti verilerinin gerçek değerlerin temsil edildiği köşegen birebir yakın olduğu, test setinde ise verilerin köşegene biraz daha mesafeli olduğu görülmektedir.

XGBoost gibi karar ağacı tabanlı algoritmalar, karar ağaçlarını tek tek kullanarak bunların birleşimi olarak ifade edilen tahminlere dayandığından bu algoritmanın doğrusal bir denklemini elde etmek doğrudan mümkün değildir. XGBoost algoritmasıyla oluşturulan tahmin modellerinde kullanılan hiper parametre fonksiyonlarına tespitine ilişkin değerler Tablo 21’de verilmiştir. Ayrıca modellerin, tahmin süreçlerinde kullanılan bağımsız değişkenlerin göreceli önemleri de Tablo 22’de gösterilmektedir.

Tablo 21 incelendiğinde, algoritmik modelin genelleme yeteneğini arttırabilmek için başlangıç modelinde gelişmişlik ve kuraklık değişkenlerine L1 tipli düzenleme işlemi yaptığı görülmektedir. Başlangıç modelde en önemli değişkenin abone sayısı olduğu dikkat çekicidir. Optimizasyonlu modelde ise daha kararlı ve performanslı bir model ortaya konabilmesi için bağımsız değişkenler, hiper parametre ayarlamalarıyla birlikte daha dengeli biçime dönüştürülmüştür. Optimize modelde ise nüfus en önemli bağımsız değişken olmuştur.

XGBoost algoritmasıyla karar ağaçlarının birleşimleri tamamlandıktan sonra, Tablo 8’de verilen senaryoya göre dağıtım debisi tahmini gerçekleştirilmiştir. Adana ilinin 2021-2026 yılları arası dağıtım debisini tahmin edildiği değerler, Tablo 23’te sunulmaktadır.

Tablo 21. XGBoost algoritması modellerinin hiper parametre fonksiyonları

Başlangıç Temel Fonksiyonları	
Random State:	42
booster:	gbtree, colsample_bylevel: 1.0, colsample_bytree: 0.8, eta: 0.1,
eval_metric:	rmse, gamma: 0, max_depth: 6, min_child_weight: 1,
n_estimators:	100, nthread: None, objective: reg:squarederror,
reg_alpha:	0.0, reg_lambda: 1.0, silent: 0, subsample: 0.8
Optimizasyonlu Model Fonksiyonları	
Random State:	42 (HP)
booster:	gbtree, colsample_bylevel: 1.0, colsample_bytree: 0.6, eta: 0.1,
eval_metric:	rmse, gamma: 0, max_depth: 6, min_child_weight: 1,
n_estimators:	200, nthread: None, objective: reg:squarederror,
reg_alpha:	0.0, reg_lambda: 1.0, silent: 0, subsample: 0.6


Tablo 22. XGBoost algoritması dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri

Başlangıç Modeli			Optimizasyonlu Model		
N	40.23		N	41.06	
A	59.77		A	26.13	
G	0		G	32.81	
İ	0		İ	0.80	

Tablo 23. XGBoost algoritması tahmin modeli sonuçları

Yıl	Gerçek Dağıtım Debisi (m³)	Başlangıç Model (%80 Eğitim - %20 Test)		Optimizasyonlu Model (%80 Eğitim - %20 Test)	
		Tahmin Edilen Dağıtım Debisi (m³)	Tahmin Yüzdesi (%)	Tahmin Edilen Dağıtım Debisi (m³)	Tahmin Yüzdesi (%)
2021	101.403.451	100.332.208	98,94%	100.407.722	99,02%
2022	105.412.862	100.362.710	95,21%	100.505.207	95.34%
2023	110.906.891	100.332.208	90,47%	100.368.840	90.50%
2024	---	100.368.410	---	100.532.798	---
2025	---	100.368.410	---	100.542.344	---
2026	---	100.362.710	---	100.539.120	---

Tablo 23'teki tahmin sonuçları incelendiğinde, optimize modelin başlangıç modele göre biraz iyileştirme sağlandığı görülmüş olsa da tahmin sonuçları gerçek değerlere kıyasla kabul edilebilir doğrulukta değildir. Modeller, eğitim süresince veride çok iyi uyum göstermiş ama yeni veri üzerinde kötü performans sergilemiştir. Bunun sebepleri arasında yüksek varyansa bağlı overfitting gelmektedir. Bu kıyaslamamanın daha iyi görülebilmesi için Şekil 35'te zaman serileri grafiği sunulmaktadır.




Şekil 35. XGBoost algoritması tahmin modeline ait zaman serisi grafiği

3.1.4. SVR Algoritması ile Tahmin Modeli

SVR algoritması, karar sınırını belirlemede kritik rol oynayan destek vektörlerinin tahmin performansına dayanmaktadır. Bu algoritma, destek vektörlerini belirli bir hata toleransı içinde kullanarak veriler arasındaki ilişkiyi modelleyen bir fonksiyon oluşturur ve verileri en iyi şekilde temsil eder. Regresyon modelinin performansı; hata marjı genişliğini belirleyen epsilon (ϵ) ve hataların toleransını belirleyen C ceza parametrelerine bağlıdır. Bu katsayılardan, epsilon (ϵ) değerinin modelde düşük (0.01-0.1) olması, modeli daha hassas (fazla hatayı dikkate alması) ve karmaşık yaparken, yüksek (0.5-1) olması da modeli basit ve duyarlılığının azalmasına (ayrıntıları kaçırmayı) neden olabilmektedir. Aynı şekilde C cezalandırma değerinin modelde düşük (0.1-1) olması, hatalara karşı daha toleranslı ve basit yaparken, yüksek (10-100) yapması da modelin daha az hata yapmasına ve aşırı uyumlu olmasına sebep olabilmektedir.

Kurulan modellere ilişkin, C ve epsilon değerlerinin RMSE değeriyle değişimini gösteren ısı haritası grafiği Şekil 36'da sunulmaktadır. Şekle göre SVR algoritmasının başlangıç modeldeki C ve epsilon değerleri sırasıyla 1 ve 0.1 iken RMSE değeri 0.098747, optimizasyon durumunda ise en küçük RMSE değeri 0.058062 olmak üzere C ve epsilon değerleri 1 ve 0.01 seçilmiştir. Epsilon değerinin optimize modelde daha da küçük seçilmesi daha hassas ve karmaşık bir analiz yapılacağına göstergesidir.



Şekil 36. SVR algoritması C ve Epsilon (ϵ) değişim grafiği

C ve epsilon hiper parametrelerinin dikkatli bir şekilde ayarlanması, SVR modelinin performansını optimize edilmesine katkı sağlamakla birlikte, modelin genelleme yeteneği ve doğruluğunu doğrudan etkilemektedir.

Hiper parametreler tespit edildikten sonra, dağıtım debisi değişkenini tahmin etmek için kurulan SVR algoritması modellerine ait eğitim, test ve tahmin veri setlerinin performans ölçüt istatistikleri Tablo 24 ve 25'te verilmiştir.

Tablo 24. Dağıtım debisi değişkeni için SVR modellerinin eğitim, test ve tahmin veri setlerine ait başlangıç hiper parametrelili performans ölçüt istatistikleri

Eğitim	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.073179	0.070946	0.072522	0.075909	0.069901
RMSE	0.078224	0.076191	0.078489	0.081539	0.080922
R ²	0.941840	0.938663	0.936670	0.937355	0.921559
Test	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.046184	0.063670	0.063428	0.059864	0.082358
RMSE	0.047918	0.069435	0.067112	0.063624	0.094435
R ²	0.551051	0.961127	0.957187	0.954215	0.915748
Eğitim/Test	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
NSE	0.944206	0.944215	0.944215	0.944215	0.922295
Tahmin	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.026484	0.027756	0.027756	0.027756	0.026172
RMSE	0.037924	0.039158	0.039158	0.039158	0.038205
NSE	0.792512	0.778789	0.778789	0.778789	0.789422


Tablo 25. Dağıtım debisi değişkeni için SVR modellerinin eğitim, test ve tahmin veri setlerine ait optimize hiper parametrelili performans ölçüt istatistikleri

Eğitim	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.011964	0.012904	0.006526	0.006817	0.008621
RMSE	0.014246	0.014826	0.007579	0.007882	0.008974
R ²	0.998071	0.997677	0.999410	0.999415	0.999035
Test	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.031302	0.021098	0.030147	0.025775	0.023363
RMSE	0.031913	0.026060	0.034412	0.031454	0.026232
R ²	0.800878	0.994524	0.988744	0.988810	0.993499
Eğitim/Test	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
NSE	0.996900	0.996900	0.995693	0.995693	0.995976
Tahmin	SVR-I	SVR -II	SVR -III	SVR -IV	SVR -V
MAE	0.131330	0.131330	0.128226	0.128226	0.152529
RMSE	0.133939	0.133939	0.131110	0.131110	0.154205
NSE	-1.58811	-1.58811	-1.47991	-1.47991	-2.430563

Tablo 24 ve Tablo 25 incelendiğinde modellerin eğitim veri seti için en yüksek MAE, RMSE ve R² değerlerinin I. modelde olduğu ve V. modele doğru genelde azalma yönünde olduğu görülmektedir. NSE değerlerinin ise yüksek oranda olduğu görülmekte ancak optimize modelde 1.00'a yaklaşan değerlerin overfitting yapma riski bulunmaktadır.


Tahmin setinin hata değerlerinin iyi düzeyde olduğu ancak tahmin sonuçlarının değerlendirme katsayısı NSE'de ise başlangıç modelde iyi performans sergilediği, optimize modelde ise negatif değerde olduğu göze çarpmaktadır. Bu durum optimize modelin tahmin performansının iyi düzeyde olmayacağını göstermektedir.

Söz konusu ölçüt istatistiklerin bir bütün olarak değerlendirilmesi sonucunda, II. modelin genelleme yeteneğinin daha yüksek olması ve aşırı uyum (overfitting) sorunundan en az etkilenmesinden dolayı, tahmin setinde kullanılması uygun bulunmaktadır. Bu durumun daha net görülebilmesi için Şekil 37'de dağıtım debisi bağımlı değişkenine ait yıllara sâri zaman serileri grafiği sunulmuştur.



Şekil 37. SVR algoritması dağıtım debisi değişkenine ait zaman serisi grafiği

Şekil 37’de hiper parametrelili optimize edilmiş algoritmanın, başlangıç ($C=1$, $\epsilon=0.1$) algoritmaya göre kurulan tahmin modelinin daha yüksek oranda açıklama yaptığı görülmektedir. Tahmin modellerinden elde edilen dağıtım debisi bağımlı değişkenine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 38’de gösterilmektedir.



Şekil 38. SVR algoritması modelinin eğitim ve test veri setlerine ait saçılım grafikleri

Hazırlanan saçılım grafikleri incelendiğinde, optimizasyonlu modelin köşegene daha fazla yakın olduğu görülmektedir. Bu durum da optimizasyonlu modelin; başlangıç modele kıyasla, gerçek dağıtım debisine yakın sonuçlar verdiğini göstermekle birlikte overfitting sorununu da beraberinde getirdiği görülmektedir.

SVR algoritması modellerinin fonksiyonları ve dağıtım debisi bağımlı değişkeninin elde edildiği lineer kernel çözüm denklemi Tablo 26’da verilmiştir. Ayrıca modellerin, tahmin denklemlerinde kullanılan bağımsız değişkenlerin göreceli önemleri de Tablo 27’de gösterilmektedir.

Tablo 26. SVR algoritması modelinin fonksiyonları ve dağıtım debisi değişkeninin elde edildiği denklem

Başlangıç Temel Fonksiyonları
Random State: 42 (HP), Kernel: Lineer (HP)
Düzenleme (Ceza) Katsayısı: 1, Epsilon (ϵ): 0.1 (HP)
İntercept (Sabit): 0.0877 (P)
Coefficients (Ağırlık): 0.2713 [N], 0.2581 [A], 0.2641 [G], 0.0296 [İ] (P)
D_dağıtım debisi = 0.0877 + 0.2713*N + 0.2581*A + 0.2641*G + 0.0296*İ
Optimizasyonlu Model Fonksiyonları
Random State: 42 (HP), Kernel: Lineer (HP)
Düzenleme (Ceza) Katsayısı: 1, Epsilon (ϵ): 0.01
İntercept (Sabit): -0.0102 (P)
Coefficients (Ağırlık): 0.4358 [N], 0.1330 [A], 0.4367 [G], 0.0230 [İ] (P)
D_dağıtım debisi = -0.0102 + 0.4358*N + 0.1330 *A + 0.4367 *G + 0.0230 *İ

Tablo 27. SVR algoritması modelinin dağıtım debisi değişkeninin tahmini için kullanılan bağımsız değişkenlerin göreceli önemleri

Başlangıç Modeli			Optimizasyonlu Model		
N	32.95		N	42.37	
A	31.35		A	12.93	
G	32.09		G	42.46	
İ	3.61		İ	2.24	


Tablo 26. incelendiğinde başlangıç modelinde nüfus, abone sayısı ve gelişmişlik bağımsız değişkenlerin eş değer önemde olduğu, optimize modelde ise nüfus ve gelişmişlik bağımsız değişkenlerinin göreceli önemleri oldukça yüksek olduğu görülmektedir.

SVR algoritmali modelin değişken katsayıları ve model denklemi elde edildikten sonra, Tablo 8’de verilen senaryoya göre dağıtım debisi tahmin işlemleri her iki durum için gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası dağıtım debisini tahmin edildiği değerler Tablo 28’de sunulmaktadır.

Tablo 28. SVR algoritması tahmin modeli sonuçları

Yıl	Gerçek Dağıtım Debisi (m ³)	Başlangıç Model (%80 Eğitim - %20 Test)		Optimizasyonlu Model (%80 Eğitim - %20 Test)	
		Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)	Tahmin Edilen Dağıtım Debisi (m ³)	Tahmin Yüzdesi (%)
2021	101.403.451	100.780.904	99.39%	107.483.456	94.34%
2022	105.412.862	105.246.664	99.84%	113.096.678	93.21%
2023	110.906.891	107.799.571	97.20%	115.577.685	95.96%
2024	---	111.895.622	---	120.210.351	---
2025	---	115.913.143	---	124.856.330	---
2026	---	120.186.668	---	129.922.443	---

Tahmin sonuçları incelendiğinde, SVR algoritması başlangıç modelinin optimizasyonlu modele kıyasla 2021-2023 yılları için gerçeğe çok yakın sonuçlar verdiği görülmektedir. Bu durum da modelin doğru ve iyi bir performans sergilediğini göstermektedir. Gerçek değerle tahmin edilen değerlerin birbirine yakın sonuçlar göstermesi, modelin güvenilirliğinin yüksek olduğunu göstermektedir. Optimize model eğitim süresince veri üzerinde çok iyi uyum göstermiş, yeni tahmin verisi üzerinde kötü performans göstermesi ise yüksek varyansa bağlı aşırı uyum sorunundan kaynaklanmaktadır. Bu farkın daha iyi görülebilmesi için Şekil 39'da zaman serileri grafiği çizilmiştir.



Şekil 39. SVR algoritması tahmin modeline ait zaman serisi grafiği

3.1.5. Dağıtım Debisi Tahmin Modellerinin Karşılaştırılması

Dağıtım debisi bağımlı değişkenini tahmin etmek için kurulan ve kendi içerisinde en iyi performans sergileyen makine öğrenmesi tabanlı Ridge, Lasso, XGBoost ve SVR algoritmalarının eğitim, test ve tahmin setlerinden elde edilen karşılaştırmalı performans ölçüt istatistikleri, Tablo 29’da sunulmaktadır.


Tablo 29. Dağıtım debisi bağımlı değişkeni modellerinin performans istatistiklerinin karşılaştırılması

Eğitim	Ridge ($\alpha:1$)	Lasso ($\alpha:0.001$)	XGBoost Optimize	SVR (C=1, $\epsilon=0.1$)	
	I. Model	II. Model	II. Model	I. Model	
MAE	0.0704	0.5042	0.0051	0.0709	
RMSE	0.0765	0.6256	0.0076	0.0762	
R ²	0.9382	0.9981	0.9994	0.9387	
Eğitim	Ridge ($\alpha:1$)	Lasso ($\alpha:0.001$)	XGBoost Optimize	SVR (C=1, $\epsilon=0.1$)	
	I. Model	II. Model	II. Model	I. Model	
MAE	0.0719	1.3379	0.0633	0.0637	
RMSE	0.0801	1.5517	0.0709	0.0694	
R ²	0.9483	0.9911	0.9594	0.9611	
Eğitim/Test	Ridge ($\alpha:1$)	Lasso ($\alpha:0.001$)	XGBoost Optimize	SVR (C=1, $\epsilon=0.1$)	
	I. Model	II. Model	II. Model	I. Model	
NSE	0.9407	0.9964	0.9999	0.9442	
Tahmin	Ridge ($\alpha:1$)	Lasso ($\alpha:0.001$)	XGBoost Optimize	SVR (C=1, $\epsilon=0.1$)	
	I. Model	II. Model	II. Model	I. Model	
MAE	0.0307	6.2668	0.1171	0.0278	
RMSE	0.0409	6.4049	0.1440	0.0392	
NSE	0.7587	-1.7033	-1.9901	0.7788	
Ortalama	Ridge ($\alpha:1$)	Lasso ($\alpha:0.001$)	XGBoost Optimize	SVR (C=1, $\epsilon=0.1$)	Ridge-SVR Fark (%)
	I. Model	II. Model	II. Model	I. Model	
MAE	0.0577	2.7030	0.0619	0.0541	6.13
RMSE	0.0658	2.8607	0.0742	0.0616	6.41
NSE	0.8497	-0.3535	-0.4951	0.8615	1.39

Tablo 29 incelendiğinde Lasso ve XGBoost algoritmalarının eğitim ve test süreçlerinde oldukça iyi skorlar vermesine rağmen, tahmin performansları son derece yetersiz kalmıştır. Bu yetersizlik, algoritmaların verilere aşırı uyum sağlamasından


kaynaklandığı görülmektedir. Diğer yandan Ridge ve SVR algoritmaları hem eğitim hem test hem de tahmin aşamalarında oldukça başarılı performans sergilemiştir. SVR algoritması MAE ve RMSE hata metriklerinde %6,13 ve %6,41, NSE tahmin katsayısında ise %1.39 olmak üzere, Ridge algoritmasından daha fazla performans sergilemiştir. Her iki modelde de uygun hiper parametrelerle verileri işleme ve sınırlandırma etkileri dikkat çekici olup genel olarak tahmin performansı çok iyi seviyelerdedir.

Gerçek dağıtım debileri ile tahmin edilen dağıtım debilerine ait eğitim, test ve tahmin setleri için en iyi modellemelere ait saçılım grafiği Şekil 40'da ayrı ayrı çizilerek karşılaştırılmıştır.



Şekil 40. Dağıtım debisi değişkeni modellerinin karşılaştırmalı saçılım grafiği

Grafikte yuvarlaklardan içi noktalı olanlar test setini, dışı çarpı şeklinde olanlar ise tahmin setini göstermektedir. Yukarıda ifade edildiği üzere, test ve eğitim aşamasında, Lasso ve XGBoost algoritmaları çok iyi performans göstermesine karşın modellerin genellenebilirlikleri düşük çıkmıştır. Ridge ve SVR algoritmaları ise daha kararlı ve genellenebilir performans sergilemiş olup tahmin aşamasında köşegene daha fazla yakın olduğu görülmektedir. Algoritmik modellerin daha net görülebilmesi için Şekil 41'de yıllara sâri zaman serileri grafiği çizilmiştir.



Şekil 41. Dağıtım debisi değişkeni modellerinin karşılaştırmalı zaman serisi grafiği

Şekil 41 incelendiğinde, Ridge ve SVR algoritmaları modeller, gerçek dağıtım debisi değerlerine 2021-2023 yılları arasında daha yakın sonuçlar sergilemektedir. SVR algoritmasının tahmin başarısı, Ridge algoritmasından ortalama %0.01 daha fazla olduğu görülmektedir. Bir sonraki aşamada irdelenmesi yapılacak olan altyapı proje büyüklükleri tahmin modellerinde, dağıtım debisi tahmininde en iyi performansı gösteren Ridge ve SVR algoritmaları kullanılacaktır.

4 adet bağımsız değişken (nüfus, gelişmişlik, abone sayısı, Aydeniz kuraklık katsayısı) ile dağıtım debisi bağımlı değişkeninin tahminine yönelik Lasso, Ridge, XGBoost ve SVR algoritmalarıyla yapılan modellemeler sonucunda bulunan tahmin değerleri Tablo 30'da sunulmaktadır. 2021-2026 yılları arasında altyapı proje büyüklüğü tahmininde, bağımsız değişken olarak Ridge ve SVR algoritma modellerince tahmini yapılan dağıtım debisine ait kendi değerleri kullanılmıştır.

Tablo 30. Makine öğrenmesi algoritma modellerinin dağıtım debisine ait tahmin sonuçları

En Uygun Model	Gerçek Değerler (Bin-m ³)			Tahmin Değerleri (Bin-m ³)								
	2021	2022	2023	2021	Tahmin Oranı	2022	Tahmin Oranı	2023	Tahmin Oranı	2024	2025	2026
Ridge (I)	101.403	105.412	110.906	100.707	99,31%	105.038	99,65%	107.769	97,17%	111.283	114.998	118.97
Lasso (I)	101.403	105.412	110.906	107.495	94,33%	114.472	92,09%	119.054	93,16%	123.310	128.289	134.071
XGBoost (II)	101.403	105.412	110.906	100.407	99,02%	100.505	95,34%	100.368	90,50%	100.532	100.542	100.539
SVR (I)	101.403	105.412	110.906	100.780	99,39%	105.246	99,84%	107.799	97,20%	111.895	115.913	120.186

3.2. Ridge Algoritması Proje Büyüklüğü Tahmin Modellerine İlişkin Bulgular

Bu aşamada, Ridge algoritmasıyla önceden tahmin edilen dağıtım debisi değişkenine ait değerler ile altyapı proje büyüklükleri arasında regresyon hesaplamaları yapılmıştır. Kurulan modellerde, proje büyüklüğü bağımlı değişken, dağıtım debisi ise bağımsız değişken olarak seçilmiştir.

Modellemelerde kullanılacak olan veri seti 2006-2020 yılları arasında 15 adet veriyi içermesinden dolayı, modelin doğruluğunu ve genellenebilirliğini değerlendirmek için k katlı çapraz doğrulama (cross-validation) kullanılmıştır. Bu sayede, farklı veri bölümleri üzerinde model eğitilerek az ve aşırı uyumun (underfitting, overfitting) azalmasına, daha güvenilir ve modelin görülmemiş yeni veriler üzerinde sağlam bir tahmin (genelleme) performansı sergilenmesine olanak sağlanmıştır.

Mevcut veri setinin durumu göz önüne alındığında, bu verilerin birbirleriyle olan ilişkisinin net olarak ortaya konabilmesi için k katlı çapraz doğrulamanın yanında polinom regresyonlar da kullanılmıştır. Ridge algoritmasının polinom regresyon ile birlikte kullanılmasıyla birlikte, optimize edilmiş daha esnek, karmaşık ve genellenebilir modeller oluşturulmuştur. Modelde, bağımsız değişkenlerle bağımlı değişken arasındaki ilişkiyi ifade eden karmaşıklık, Ridge algoritmasının ceza terimleriyle birlikte sınırlandırılarak aşırı uyum, kontrol altında tutulmaktadır. Polinom derecesini artırılması suretiyle, modelin veriye daha iyi uyum sağlamasına katkı sağlanmıştır.

Tüm bu kullanılan yöntemlerin yanında, modelin karmaşık ve doğrusal olmayan ilişkileri yakalayarak daha esnek bir modeller oluşturulabilmesi için özellik mühendisliğinden de yararlanılmıştır. Özellik mühendisliği, mevcut veri setinden kurulacak modellerin daha iyi performans göstermesini sağlamak için ek kullanışlı özelliklerin oluşturulduğu süreçtir. Ridge algoritmasıyla polinom fonksiyonlarının yetersiz kaldığı durumlarda; verilerin dağılımının sıkılaştırılması, lineer olmayan karmaşık ilişkilerin yakalanması, küçük verilerin de modelde etkisinin arttırılması gibi amaçlarla karesel, logaritmik, karekök ve ters dönüşüm (inverse) etkileşim dönüşümleri modellemelere dâhil edilmiştir.

Etkileşim terimleri sayesinde, birden fazla bağımsız değişkenin birlikte bağımlı değişken üzerinde nasıl etki ettiği belirlenerek karmaşık ilişkiler yakalanmış ve modellerin performansı optimize edilmiştir.

3.2.1. Ridge Algoritması ile İçmesuyu Proje Büyüklüğü Tahmin Modeli

Veri setinin, normalize edilmemiş halinin tahminler karşısında genel performansı önceden değerlendirebilmek için k katlı çapraz doğrulama işlemi yapılmıştır. Çapraz doğrulama sonrası kurulan başlangıç modelinde alpha (α) değeri 1 olarak alınmıştır. Optimize edilmiş modelde ise (-4, 4, 50) sınırlamalı logaritmik ölçek kullanılarak 0.0001 ile 10000 arasında, 50 farklı alpha değeri ile geniş yelpazede en iyi optimum alpha değeri (α) 100 tespit edilmiştir. Bu değere göre model, güçlü bir ağırlık küçültme yapılarak basit hale getirilmiş ve aşırı uyum riskinin önüne geçilmeye çalışılmıştır. Bu tespitlerden sonra, tahmini yapılacak olan içmesuyu proje büyüklüğünü Ridge algoritması modellerinin performans ölçüt istatistikleri Tablo 31’de verilmektedir.

Tablo 31. Ridge modellerinin ($\alpha:1$; $\alpha:100$) çapraz doğrulama performans ölçütleri

k (fold)	Başlangıç Model ($\alpha:1$)			Optimize Model ($\alpha:100$)		
	MAE	RMSE	R ²	MAE	RMSE	R ²
2	170.666	206.155	0.9258	206.010	170.659	0.9260
3	135.039	157.710	0.9566	166.544	138.031	0.9516
4	137.343	160.564	0.9550	163.259	135.626	0.9535
5	138.620	163.112	0.9536	168.731	138.437	0.9503
6	142.724	165.151	0.9524	169.752	141.572	0.9497
7	138.960	161.374	0.9546	162.706	134.741	0.9538
8	144.731	169.528	0.9499	174.789	144.146	0.9467
9	144.577	169.453	0.9499	174.765	144.062	0.9467
10	146.021	170.233	0.9494	175.251	145.410	0.9464
11	146.263	170.249	0.9494	175.298	145.588	0.9464
12	140.818	164.819	0.9526	167.576	139.105	0.9510
13	139.332	163.272	0.9535	166.048	137.629	0.9519
14	140.694	163.724	0.9532	166.007	137.974	0.9519
15	142.024	164.423	0.9528	166.485	139.217	0.9516

Çapraz doğrulama (cv) sonucunda, en düşük hata değerleri yönünden doğrulama foldları, başlangıç modelinde k=3, optimize modelde ise k=7 olarak bulunmuştur. K değerinin 3 olması, veri setini 3 farklı alt kümeye bölünüp, her bir alt kümeyi test verisi ve diğer iki kümenin eğitim verisi olarak kullanılması demektir. Anılan bu işlem 3 defa tekrarlanması sonucu bulunan değerler, performans ölçütleridir. Bulunan bu ölçütlerin, tek dereceli lineer denklem türünde olması, sadece doğrusal ilişkileri modelleyeceğinden; modelin veri setindeki düzensizlikleri ve doğrusal olmayan ilişkileri daha net bir şekilde ortaya konabilmesi için polinom (dereceli) regresyonun kullanılması gerekmektedir. Ridge

polinom regresyonunun ölçüt istatistikleri Tablo 32 ve Tablo 33’te verilmiştir.

Tablo 32. Ridge polinom regresyon başlangıç (k-cv=3) modelinin performans ölçütleri

Derece ($\alpha:1$) (Eğitim-Test)	2°	3°	4°	5°	6°
MAE	72.270	82.053	69.278	73.025	84.897
RMSE	79.883	94.852	82.791	91.693	113.456
R ²	0.985	0.979	0.984	0.981	0.969
Derece (Tahmin)	2°	3°	4°	5°	6°
MAE	143.561	236.619	119.845	46.977	101.906
RMSE	148.112	246.601	121.371	53.721	103.668
NSE	-2.858	-9.696	-1.591	0.283	-0.890

Tablo 33. Ridge polinom regresyonu optimize (k-cv=7) modelinin performans ölçütleri

Derece ($\alpha:100$) (Eğitim-Test)	2°	3°	4°	5°	6°	7°
MAE	101.2792	68.8159	55.952	70.134	106.474	132.956
RMSE	71.099	68.2850	64.180	68.189	138.973	202.990
R ²	0.9912	0.9919	0.9928	0.9919	0.9663	0.9281
Derece (Tahmin)	2°	3°	4°	5°	6°	7°
MAE	221.842	122.801	79.910	40.171	36.377	112.090
RMSE	227.827	124.054	81.118	49.692	48.651	115.346
NSE	-8.129	-1.707	-0.157	0.347	0.362	-1.340

Tablo 32 ve Tablo 33 incelendiğinde, başlangıç ve tuning (optimize) modelin eğitim-test seti için R² ve hata değerlerinde, derecelere göre genel bir dalgalanma görülmektedir. Buna ilaveten, NSE değerleri genel olarak negatif ağırlıkta çıkmış olup pozitif olanların ise 0.50’nin altında olması nedeniyle tahmin performansları yetersiz düzeydedir. Söz konusu durumu iyileştirebilmek için makine öğrenmesi literatüründe, özellik mühendisliği olarak bilinen logaritmik ve karekök etkileşim terimlerinden yararlanılmıştır.

Logaritmik (log_veri) dönüşümle büyük veriler sıkıştırma ve küçük verileri ise yayma suretiyle verilerin daha dengeli bir dağılıma sahip olmasına katkı sağlar. Karekök dönüşümle (sqrt_veri) de geniş aralıkta yayılan verileri sıkıştırarak doğrusal olmayan ilişkileri yakalamaya yardımcı olur. Etkileşim terimleri (log_D, sqrt_D) ve polinom özelliklerinin (D², D³, ...) birlikte harmanlanmasıyla (enhanced), model karmaşık yani doğrusal olmayan ilişkileri daha iyi tanıyacak hale gelmiştir. Yapılan bu işlemlerle birlikte, çapraz doğrulama işlemi yapılmış ve model eğitimi gerçekleştirilmiş olup bulunan performans ölçüt değerleri Tablo 34’te sunulmuştur.

Tablo 34. Ridge regresyon enhanced başlangıç (k-cv=3) modelinin performans ölçütleri


Derece ($\alpha:1$) (Eğitim-Test)	2°	3°	4°	5°	6°
MAE	0.042	0.038	0.039	0.043	0.042
RMSE	0.048	0.043	0.045	0.048	0.047
R ²	0.971	0.976	0.974	0.972	0.971
Derece (Tahmin)	2°	3°	4°	5°	6°
MAE	0.009	0.057	0.099	0.101	0.072
RMSE	0.010	0.058	0.095	0.097	0.071
NSE	0.889	-2.328	-8.619	-8.970	-3.976

Tablo 34'e göre eğitim-test işlemleri sonucunda polinom dereceleri değişmesine rağmen hata ve R² değerleri birbirine yakın sonuçlar vermiştir. Ancak tahmin setinde; ikinci derece geliştirilmiş modelin, diğer modellere göre çok üstün olduğu ve daha iyi performans sergilediği görülmektedir. Etkileşim terimlerinin başlangıç ($\alpha:1$) modeline etkisinden sonra, optimizasyon durumunda performansının değerlendirilebilmesi için (-6, 6, 100) logaritmik ölçekte, minimum hatayı veren en iyi alpha hiper parametresi 0.0057 bulunmuştur. Optimize durumda, modelin ölçütleri Tablo 35'te sunulmaktadır.

Tablo 35. Ridge regresyon enhanced optimizasyon (k-cv=7) modelinin performans ölçütleri


Derece ($\alpha_{best}:0.0057$) (Eğitim-Test)	2°	3°	4°	5°	6°
MAE	0.028	0.027	0.024	0.026	0.027
RMSE	0.032	0.031	0.028	0.030	0.031
R ²	0.876	0.886	0.909	0.892	0.906
Derece (Tahmin)	2°	3°	4°	5°	6°
MAE	0.069	0.053	0.022	0.027	0.036
RMSE	0.071	0.053	0.029	0.033	0.042
NSE	-3.996	-1.765	0.517	0.134	-0.711

Optimize modelde de benzer bir durum söz konusudur. Optimize modelin eğitim ve test performans ölçütleri birbirine yakın ve dalgalanmalıdır. Tahmin setinde ise NSE değeri dördüncü ve beşinci dereceli fonksiyonlar haricinde negatiftir. Diğerlerine kıyasla NSE değeri kabul edilebilir düzeyde olan dördüncü dereceli fonksiyon, tahmin setinde tercih edilmiştir. Bu durumun daha net görülebilmesi için Şekil 42'de içmesuyu proje büyüklüğü bağımlı değişkenine ait yıllara sâri zaman serileri grafiği çizilmiştir.



Şekil 42. Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait zaman serisi grafiği

Zaman serisi, k katlı çapraz doğrulama modeli ile genel veri setini (eğitim-test) temsil etmektedir. Optimize modelin (Alpha: 0.0057) biraz daha fazla olmak üzere, gerçek değerlere yakın açıklama yaptığı görülmektedir. Tahmin modellerinden elde edilen içmesuyu proje büyüklüğü değişkenine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 43'te gösterilmektedir.



Şekil 43. Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafikleri

Şekil 43 incelendiğinde, eğitim-test verilerinin zaman serisi grafiğinde olduğu gibi hiper parametre ayarlı (optimizasyonlu) model verilerinin köşegene daha yakın olduğu görülmekte ve gerçek proje büyüklüklerine yakın sonuçlar sergilemektedir.

Ridge algoritmasıyla oluşturulan modelden elde edilen parametreler, hiper parametre fonksiyonları tespitine ilişkin değerler ve içmesuyu proje büyüklüğü bağımlı değişkeninin elde edildiği denklem Tablo 36’da verilmiştir. Ayrıca modellerin, denklemlerinde kullanılan bağımsız değişkenlerin göreceli önemleri de Tablo 36’da gösterilmektedir. Tablo 36 ve Tablo 37’de D, dağıtım debisi değerlerini temsil etmektedir.

Tablo 37 incelendiğinde, etkileşim terimlerinin model üzerindeki temsil etkisi göze çarpmaktadır. Başlangıç modelin yaklaşık %63’lük kısmının lineer derecede, %37’lik kısmının da ikinci derecede açıklandığı görülmektedir. Optimize edilen modelde ise daha fazla veri ve etkileşim terimlerinin kombinasyonu ile model derecesinin arttığı ve daha fazla açıklama (temsil) yapıldığı görülmektedir.

Tablo 36. Ridge algoritması modelinin fonksiyonları ve içmesuyu proje büyüklüğü değişkeninin elde edildiği denklem

Başlangıç Temel Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Alpha (α): 1 (HP)
İntercept (Sabit): 0.592711856 (P) ; D-dağıtım debisi
İ_proje büyüklüğü = 0.592711856 + (0.0571 * D) + (0.0841 * log_D) + (0.1023 * sqrt_D) + (-0.0274 * D ²) + (-0.0105 * D log_D) + (0.0109 * D sqrt_D) + (0.0085 * log_D ²) + (0.0325 * log_D sqrt_D) + (0.0571 * sqrt_D ²)
Optimizasyonlu Model Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Best Alpha (α): 0.0057 (HP)
İntercept (Sabit): 0.592711856 (P); D-dağıtım debisi
İ_proje büyüklüğü = 0.592711856 + (0.0929 * D) + (0.1244 * log_D) + (0.0296 * sqrt_D) + (-0.0001 * D ²) + (0.0136 * D log_D) + (0.0462 * D sqrt_D) + (0.0376 * log_D ²) + (0.0756 * log_D sqrt_D) + (0.0929 * sqrt_D ²) + (-0.0076 * D ³) + (-0.0275 * D ² log_D) + (-0.0195 * D ² sqrt_D) + (-0.0409 * D log_D ²) + (-0.0239 * D log_D sqrt_D) + (-0.0001 * D sqrt_D ²) + (-0.0464 * log_D ³) + (-0.0192 * log_D ² sqrt_D) + (0.0136 * log_D sqrt_D ²) + (0.0462 * sqrt_D ³) + (0.0876 * D ⁴) + (0.0514 * D ³ log_D) + (0.0310 * D ³ sqrt_D) + (0.0161 * D ² log_D ²) + (0.0003 * D ² log_D sqrt_D) + (-0.0076 * D ² sqrt_D ²) + (-0.0172 * D log_D ³) + (-0.0268 * D log_D ² sqrt_D) + (-0.0275 * D log_D sqrt_D ²) + (-0.0195 * D sqrt_D ³) + (-0.0470 * log_D ⁴) + (-0.0489 * log_D ³ sqrt_D) + (-0.0409 * log_D ² sqrt_D ²) + (-0.0239 * log_D sqrt_D ³) + (-0.0001 * sqrt_D ⁴)

Tablo 37. Ridge algoritması içmesuyu proje büyüklüğü değişkeninin tahmini için kullanılan değişkenlerin göreceli önemleri


Optimize Model (k=7-cv, α :0.0057)			Başlangıç Model (k=3-cv, α :1)		
Değişken	Katsayı	Göreceli Önem	Değişken	Katsayı	Göreceli Önem
D	0.0929	7.7192%	D	0.0571	14.6177%
log_D	0.1244	10.3376%	log_D	0.0841	21.5429%
sqrt_D	0.0296	2.4565%	sqrt_D	0.1023	26.2180%
D ²	-0.0001	0.0065%	D ²	-0.0274	7.0193%
D log_D	0.0136	1.1318%	D log_D	-0.0105	2.6947%
D sqrt_D	0.0462	3.8360%	D sqrt_D	0.0109	2.7900%
log_D ²	0.0376	3.1265%	log_D ²	0.0085	2.1679%
log_D sqrt_D	0.0756	6.2797%	log_D sqrt_D	0.0325	8.3317%
sqrt_D ²	0.0929	7.7192%	sqrt_D ²	0.0571	14.6177%
D ³	-0.0076	0.6341%			
D ² log_D	-0.0275	2.2821%			
D ² sqrt_D	-0.0195	1.6230%			
D log_D ²	-0.0409	3.3991%			
D log_D sqrt_D	-0.0239	1.9826%			
D sqrt_D ²	-0.0001	0.0065%			
log_D ³	-0.0464	3.8539%			
log_D ² sqrt_D	-0.0192	1.5983%			
log_D sqrt_D ²	0.0136	1.1318%			
sqrt_D ³	0.0462	3.8360%			
D ⁴	0.0876	7.2767%			
D ³ log_D	0.0514	4.2709%			
D ³ sqrt_D	0.0310	2.5714%			
D ² log_D ²	0.0161	1.3347%			
D ² log_D sqrt_D	0.0003	0.0271%			
D ² sqrt_D ²	-0.0076	0.6341%			
D log_D ³	-0.0172	1.4303%			
D log_D ² sqrt_D	-0.0268	2.2265%			
D log_D sqrt_D ²	-0.0275	2.2821%			
D sqrt_D ³	-0.0195	1.6230%			
log_D ⁴	-0.0470	3.9085%			
log_D ³ sqrt_D	-0.0489	4.0660%			
log_D ² sqrt_D ²	-0.0409	3.3991%			
log_D sqrt_D ³	-0.0239	1.9826%			
sqrt_D ⁴	-0.0001	0.0065%			

Ridge algoritmali modellerin bağımsız değişken katsayıları ve denklemini elde edildikten sonra, Tablo 8 ve 13'te verilen senaryoya göre içmesuyu proje büyüklüğünün tahmin işlemleri her iki model için gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün Ridge algoritması ile tahmin edildiği değerler Tablo 38'de sunulmaktadır.

Tablo 38. Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin sonuçları

Yıl	Gerçek İçmesuyu Proje Büyüklüğü (m)	Başlangıç Model (k=3,cv)		Optimizasyonlu Model (k=7,cv)	
		Tahmin Edilen İçmesuyu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)	Tahmin Edilen İçmesuyu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)
2021	7.664,74	7629.96	99.55%	7552.36	98.53%
2022	7.772,72	7781.39	99.89%	7717.05	99.28%
2023	7.848,50	7873.46	99.68%	7845.82	99,97%
2024	---	7988.01		8050.50	
2025	---	8104.56		8328.39	
2026	---	8224.17		8713.89	

Tablo 38’de bulunan tahmin sonuçları incelendiğinde, her iki modelin de 2021-2023 yılları arasında gerçeğe yakın sonuçlar vermiştir. Özellikle başlangıç modelin, ilk üç yıl içindeki tahmin performansı ve doğruluğunun yüksek olduğu görülmektedir. Ridge algoritmasına eklenen (enhanced edilen) polinom özellikleri ve etkileşim terimleri, modelin karmaşık veri ilişkilerini iyi açıkladığı görülmektedir. Model performansının daha iyi gözlemlenebilmesi için Şekil 44’te zaman serileri grafiği sunulmaktadır.



Şekil 44. Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin modeline ait zaman serisi grafiği

3.2.2. Ridge Algoritması ile Atıksu Proje Büyüklüğü Tahmin Modeli

Bu aşamada, içmesuyu proje büyüklüğünün tahmin edilme sürecinde yapılan işlemlerin atıksu veri setinden teşkil edilen modellerde de olumlu sonuçlar gösterdiği görülmüştür. Veri setinin normalize olmamış halinin genel performansını değerlendirebilmek için k katlı çapraz doğrulama işlemi yapılmış, en iyi alfa değerleri tespit edilmiştir. Çapraz doğrulamada, başlangıç alpha (α) değeri 1, optimize edilmiş modelde ise (-4, 4, 50) sınırlamalı logaritmik ölçekte en iyi optimum alpha değeri (α) de 100 olarak tespit edilmiştir. Hiper parametre tespitinden sonra, tahmini yapılacak olan atıksu proje büyüklüğü Ridge algoritması modellerinin performans ölçüt istatistikleri Tablo 39’da verilmektedir.

Tablo 39. Ridge modellerinin ($\alpha:1$; $\alpha:100$) çapraz doğrulama performans ölçütleri

k (fold)	Başlangıç Model ($\alpha:1$)			Optimize Model ($\alpha:100$)		
	MAE	RMSE	R ²	MAE	RMSE	R ²
2	128.333	102.341	0.9610	128.264	102.304	0.9610
3	92.853	69.364	0.9796	91.270	69.017	0.9803
4	107.134	80.995	0.9728	107.783	84.923	0.9725
5	96.262	72.895	0.9780	102.432	77.414	0.9751
6	95.846	72.389	0.9782	101.659	76.253	0.9755
7	93.650	70.138	0.9792	98.848	75.374	0.9768
8	97.369	75.360	0.9775	105.675	82.927	0.9735
9	97.431	75.479	0.9775	105.735	83.021	0.9735
10	97.507	76.106	0.9775	105.839	83.569	0.9734
11	97.478	75.929	0.9775	106.348	84.009	0.9732
12	97.192	74.882	0.9776	105.144	81.946	0.9738
13	96.587	74.154	0.9779	104.648	81.229	0.9740
14	95.146	72.932	0.9785	102.674	79.823	0.9750
15	95.485	73.885	0.9784	102.636	79.943	0.9750

Çapraz doğrulama (cv) sonucunda, en düşük hata değerleri yönünden fold değerleri her iki model için de k=3 olarak bulunmuştur. Veri setindeki düzensizliklerin azaltılması, doğrusal olmayan ilişkilerin net olarak ortaya konabilmesi ve modellerin açıklama yüzdelerinin daha fazla artırılması için kurulacak modellere, polinom (dereceli) regresyon ve içmesuyu proje büyüklüğünün hesaplanmasında kullanılan logaritmik ve karekök dönüşümlü etkileşim terimleri ilave edilmiştir. Yapılan bu ilaveler sonucunda Ridge polinom regresyonunun ölçüt istatistikleri, Tablo 40 ve Tablo 41’de verilmiştir.

Tablo 40. Ridge polinom regresyon başlangıç ($k\text{-cv}=3$) modelinin performans ölçütleri

Derece ($\alpha:1$) (Eğitim-Test)	2°	3°	4°	5°	6°
MAE	0.035	0.037	0.037	0.037	0.037
RMSE	0.040	0.043	0.044	0.045	0.045
R ²	0.983	0.979	0.977	0.977	0.976
Derece (Tahmin)	2°	3°	4°	5°	6°
MAE	0.072	0.041	0.008	0.031	0.046
RMSE	0.082	0.049	0.009	0.033	0.050
NSE	-19.554	-6.509	-0.694	-.2337	-6.676

Tablo 41. Ridge polinom regresyonu optimize ($k\text{-cv}=3$) modelinin performans ölçütleri

Derece ($\alpha_{\text{best}}:0.1$) (Eğitim-Test)	2°	3°	4°	5°	6°
MAE	0.029	0.028	0.030	0.031	0.033
RMSE	0.035	0.034	0.036	0.037	0.038
R ²	0.984	0.984	0.983	0.983	0.982
Derece (Tahmin)	2°	3°	4°	5°	6°
MAE	0.024	0.026	0.033	0.031	0.060
RMSE	0.026	0.028	0.036	0.034	0.069
NSE	-1.089	-1.332	-2.967	-2.474	-13.477

Tablo 40 ve Tablo 41 incelendiğinde, başlangıç ve optimize edilen modelde, çapraz doğrulama eğitim-test seti için yüksek açıklama oranı olmasına karşın R² ve hata değerlerinde genel bir dalgalanma görülmektedir. Buna ilaveten, tahmin setinde NSE'lerin tamamının negatif değerde çıkmış olması nedeniyle tahmin performanslarının yetersiz düzeyde kaldığı ve modelin verilere tam olarak uyum sağlayamadığı görülmektedir. Bu durum, mevcut veri kümesinin küçük olması, alfa değerlerinin eksik hesaplanmasından veya etkileşim terimlerinin yetersizliğinden kaynaklanabilmektedir.

Yüksek tahmin performansına sahip bir model elde edebilmek için alfa değerlerinin daha geniş yelpazede değişimleri gridsearch ve hold out yöntemleriyle incelenmiştir. Logaritmik (log_veri) ve karekök (sqrt_veri) dönüşümü içeren polinom Ridge regresyon ölçütleri, alpha değerinin küçük oynamalarıyla değiştiği görülmektedir. Belirtilen kıstaslarda yapılan modelleme çalışmaları neticesinde, en uygun alpha değeri 0.042 olarak tespit edilmiş olup modelin performans ölçüt değerleri Tablo 42'de sunulmuştur.

Tablo 42. Ridge regresyon enhanced ($\alpha:0.042$) modelinin performans ölçütleri

Derece ($\alpha_{best}:0.042$) (Eğitim-Test)	2°	3°	4°	5°
MAE	0.034	0.034	0.032	0.031
RMSE	0.042	0.040	0.038	0.039
R ²	0.983	0.984	0.985	0.986
Derece (Tahmin)	2°	3°	4°	5°
MAE	0.018	0.007	0.011	0.018
RMSE	0.031	0.010	0.016	0.028
NSE	0.399	0.933	0.821	0.911


Modelleme yapılırken, polinom derecesi artarken hata ve NSE değerlerinin de artma eğiliminde olduğu görülmüştür. Tabloda, modellerin, eğitim ve test performanslarının yüksek olduğu, ancak tahmin setinde üçüncü dereceli çözümden sonra da hata değerleri artış eğilimindedir. NSE değerleri bakımından üçüncü dereceli model, en yüksek doğrulukta olduğu göze çarpmaktadır. Burada dikkat çekici olan şey, üçüncü dereceden sonra modelin derecesi artarken, polinom grafiğinin son yıllara doğru azalma eğilimine girmesidir. Bu durum da tahmin aşamasında, tahmin sonuçlarının olağan dışı azalmasına neden olmaktadır. 0.042 alpha değeri için üçüncü derece ve etkileşim terimli modelde, bu durum son limitte kalmış olup tahmin sürecinde kullanılmasında engel bulunmamaktadır.

Yukarıda seçilen modele alternatif olmak üzere, daha esnek ve performanslı bir model oluşturabilmek için logaritma ve karekök ($\log_D$, $\sqrt{D}$) etkileşimlerinin yanına karesel ($D_squared$) ve ters değişken ($inverse_D$) terimleri eklenmiştir. Burada karesel terim, değişkenler arasında doğrusal olmayan ilişkileri, ters değişken terimi ise küçük değerlerin model üzerinde etkisinin daha fazla ve net olarak ortaya konmasına yardımcı olmaktadır. Etkileşim terimleri ($\log_D$, $\sqrt{D}$, $D_squared$, $inverse_D$) ve polinom özelliklerinin (D^2 , D^3 , ...) birlikte enhanced edilmesiyle, model doğrusal olmayan ilişkileri daha iyi tanıyacak hale getirilmiştir. Modellerin performansının değerlendirilebilmesi için (-5, 1, 100) logaritmik ölçekte, minimum hatayı veren en iyi alpha hiper parametresi 0.020 bulunmuştur. Hold out yöntemiyle yapılan bu işlemlerle birlikte, model eğitimi gerçekleştirilmiş olup bulunan performans ölçüt değerleri Tablo 43'te sunulmuştur.

Tablo 43. Ridge regresyon enhanced ($\alpha:0.002$) modelinin performans ölçütleri

Derece ($\alpha_{\text{best}}:0.0020$) (Eğitim-Test)	2°	3°	4°	5°
MAE	0.073	0.075	0.071	0.071
RMSE	0.111	0.117	0.109	0.107
R ²	0.885	0.872	0.889	0.894
Derece (Tahmin)	2°	3°	4°	5°
MAE	0.002	0.016	0.040	0.037
RMSE	0.003	0.027	0.066	0.064
NSE	0.937	-3.422	-25.832	-24.067


Tablo 43'e göre eğitim-test işlemleri sonucunda polinom dereceleri değişmesine rağmen hata ve R² değerleri birbirine yakın sonuçlar sergilemektedir. Ancak tahmin setinde; pozitif ve en yüksek NSE oranında olan ikinci derece etkileşim terimli modelin, diğer modellere çok üstün olduğu ve yüksek doğruluk sergilediği görülmektedir. Söz konusu durumun daha net görülebilmesi için Şekil 45'de atıksu proje büyüklüğü bağımlı değişkenine ait yıllara sâri zaman serileri grafiği çizilmiştir.



Şekil 45. Ridge algoritması atıksu proje büyüklüğü değişkenine ait zaman serisi grafiği

Zaman serisi, iki model ile genel veri setini (eğitim-test) temsil etmektedir. Grafikte, birinci ve ikinci modelin arasında pek fark olmamakla birlikte, modellerin gerçek değerleri

ilk yıllarda yüksek varyans ile açıkladığı, sonraki yıllarda ise bu varyansın düştüğü görülmektedir. Tahmin modellerinden elde edilen atıksu proje büyüklüğü değişkenine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 46’da gösterilmektedir.



Şekil 46. Ridge algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafikleri

Hazırlanan saçılım grafikleri incelendiğinde, eğitim-test verilerinin zaman serisi grafiğinde olduğu gibi her iki model verilerinin köşegene daha yakın olduğu görülmekte ve gerçek proje büyüklüklerine yakın sonuçlar sergilemektedir.

Ridge algoritmasıyla oluşturulan modelden elde edilen parametre/hiper parametre fonksiyonlarına tespitine ilişkin değerler ve atıksu proje büyüklüğü bağımlı değişkeninin elde edildiği denklem Tablo 44’te verilmiştir. Ayrıca modellerin, denklemlerinde kullanılan bağımsız değişkenlerin göreceli önemleri de Tablo 45’te gösterilmektedir. Tablo 44 ve Tablo 45’te D, dağıtım debisi değerlerini temsil etmektedir.

Tablo 44 incelendiğinde, etkileşim terimlerinin model üzerindeki yüksek açıklama oranı dikkat çekicidir. İlk modelde %12’lik kısım lineer ve ikinci derecede açıklama yaptığı, II. modelde ise bu oranın %19 mertebelerinde olduğu görülmektedir. Etkileşim terimleri en fazla açıklamayı ilk modelde yapmıştır.

Ridge algoritmalı modellerin bağımsız değişken katsayıları ve denklemini elde edildikten sonra, Tablo 8 ve 13’te verilen senaryoya göre içmesuyu proje büyüklüğünün tahmin işlemleri her iki model için gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin edildiği değerler Tablo 46’da sunulmaktadır.

Tablo 44. Ridge algoritması modelinin fonksiyonları ve atıksu proje büyüklüğü değişkeninin elde edildiği denklem

1. Model Temel Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Alpha (α): 0.002009233 (HP)
İntercept (Sabit): 0.5727 (P) ; D-dağıtım debisi
A_proje büyüklüğü = $0.5727 + (0.0132 * D) + (0.0132 * \log_D) + (0.0352 * \text{sqrt_D}) + (-0.0156 * D_squared) + (0.0252 * \text{inverse_D}) + (0.0571 * D^2) + (0.0402 * D \log_D) + (-0.0014 * D \text{sqrt_D}) + (0.0144 * D D_squared) + (0.0478 * D \text{inverse_D}) + (0.0252 * \log_D^2) + (0.0125 * \log_D \text{sqrt_D}) + (-0.0397 * \log_D D_squared) + (0.0393 * \log_D \text{inverse_D}) + (-0.0783 * \text{sqrt_D}^2) + (0.0252 * \text{sqrt_D} D_squared) + (-0.0193 * \text{sqrt_D} \text{inverse_D}) + (-0.0156 * D_squared^2) + (0.0156 * D_squared \text{inverse_D}) + (0.0352 * \text{inverse_D}^2)$
2. Model Temel Fonksiyonları
Random State: 42 (HP)
Maksimum iterasyon (max_iter): 1000 (HP)
Best Alpha (α): 0.0420 (HP)
İntercept (Sabit): 0.5727 (P); D-dağıtım debisi
A_proje büyüklüğü = $0.5727 + (0.0366 * D) + (0.0416 * \log_D) + (0.1046 * \text{sqrt_D}) + (0.0091 * D^2) + (0.0214 * D \log_D) + (0.0217 * D \text{sqrt_D}) + (0.0290 * \log_D^2) + (0.0265 * \log_D \text{sqrt_D}) + (0.0366 * \text{sqrt_D}^2) + (-0.0548 * D^3) + (-0.0284 * D^2 \log_D) + (-0.0160 * D^2 \text{sqrt_D}) + (-0.0044 * D \log_D^2) + (0.0043 * D \log_D \text{sqrt_D}) + (0.0091 * D \text{sqrt_D}^2) + (0.0167 * \log_D^3) + (0.0209 * \log_D^2 \text{sqrt_D}) + (0.0214 * \log_D \text{sqrt_D}^2) + (0.0217 * \text{sqrt_D}^3)$


Tablo 45. Ridge algoritması atıksu proje büyüklüğü değişkeninin tahmini için kullanılan değişkenlerin göreceli önemleri

1. Model (Alpha: 0.0020)			2. Model (Alpha: 0.0420)		
Değişken	Katsayı	Göreceli Önem	Değişken	Katsayı	Göreceli Önem
D	0.0132	0.0231	D	0.0366	0.0697
log_D	0.0132	0.0232	log_D	0.0416	0.0793
sqrt_D	0.0352	0.0619	sqrt_D	0.1046	0.1994
D_squared	-0.0156	0.0273	D^2	0.0091	0.0173
inverse_D	0.0252	0.0443	D log_D	0.0214	0.0407
D^2	0.0571	0.1003	D sqrt_D	0.0217	0.0414
D log_D	0.0402	0.0706	log_D^2	0.0290	0.0553
D sqrt_D	-0.0014	0.0025	log_D sqrt_D	0.0265	0.0505
D D_squared	0.0144	0.0254	sqrt_D^2	0.0366	0.0697
D inverse_D	0.0478	0.0840	D^3	-0.0548	0.1045
log_D^2	0.0252	0.0443	D^2 log_D	-0.0284	0.0541
log_D sqrt_D	0.0125	0.0220	D^2 sqrt_D	-0.0160	0.0304
log_D D_squared	-0.0397	0.0698	D log_D^2	-0.0044	0.0083
log_D inverse_D	0.0393	0.0691	D log_D sqrt_D	0.0043	0.0081
sqrt_D^2	-0.0783	0.1375	D sqrt_D^2	0.0091	0.0173
sqrt_D D_squared	0.0252	0.0443	log_D^3	0.0167	0.0318
sqrt_D inverse_D	-0.0193	0.0339	log_D^2 sqrt_D	0.0209	0.0399
D_squared^2	-0.0156	0.0273	log_D sqrt_D^2	0.0214	0.0407
D_squared inverse_D	0.0156	0.0273	sqrt_D^3	0.0217	0.0414
inverse_D^2	0.0352	0.0619			

Tablo 46. Ridge algoritması ile Adana şehir merkezinin 2021-2026 yılları arası atıksu proje büyüklüğü tahmin sonuçları

Yıl	Gerçek Atıksu Proje Büyüklüğü (m)	1. Model (α : 0.0020) (%60 Eğitim - %40 Test)		2. Model (α : 0.0420) (%60 Eğitim - %40 Test)	
		Tahmin Edilen Atıksu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)	Tahmin Edilen Atıksu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)
2021	4281.54	4274.86	99.84%	4249.51	98.25%
2022	4321.08	4320.98	99.97%	4347.13	99.43%
2023	4371.11	4356.64	99.67%	4396.25	99,41%
2024	---	4408.39		4443.94	
2025	---	4468.99		4474.05	
2026	---	4539.08		4481.39	

Tablo 46’da verilen tahmin sonuçları incelendiğinde, her iki modelin de 2021-2023 yılları arasında gerçeğe çok yakın sonuçlar vermiştir. Özellikle I. modelin üç yıllık tahmin performansı çok yüksektir. Modellere eklenen etkileşim terimleri ve polinom özelliklerinin, veri setindeki doğrusal olmayan karmaşık işlemleri iyi açıkladığı görülmektedir. Model performansının daha iyi irdelenebilmesi için Şekil 47’de zaman serileri grafiği çizilmiştir.



Şekil 47. Ridge algoritması atıksu proje büyüklüğü tahminine ait zaman serisi grafiği

3.3. SVR Algoritması Proje Büyüklüğü Tahmin Modellerine İlişkin Bulgular

Bu aşamada, Ridge algoritmasında olduğu gibi dağıtım debisi bağımsız değişkeni ile altyapı proje büyüklüğü bağımlı değişkeni arasında modeller kurulmuştur. Modellerde kullanılacak veri sayısının sınırlı olması nedeniyle, tüm verilerin eğitim aşamasında yer alarak dolayısıyla da genellenebilirliğinin artırılması, uygun hiper parametrelerin seçilmesi, veriler arasında aşırı uyumun azaltılması ve daha kararlı bir model elde edilebilmesi için k katlı çapraz doğrulama tercih edilmiştir.

C ve epsilon parametrelerinin hata toleransı ile model karmaşıklığını dengeleyen bir optimizasyon aracı olan SVR algoritması, veriler arasındaki ilişkiyi modellerken kernel denilen çekirdek fonksiyonlardan yararlanmaktadır. Bu kerneller, lineer, sigmoid, polinomsal, radyal türdedir. Çalışmada kullanılan verilerin doğrusal olmayan ilişkileri daha iyi yansıtabilmesi için modeller polinomsal ve radyal fonksiyonlar ile optimizasyon işlemine tabi tutulmuştur. Polinomsal kernel ile veriler, belirli bir dereceye kadar dönüştürülerek, doğrusal olmayan ilişkileri modellenmiştir. Radyal kernel ile de verilere sonsuz bir uzaya yansıtılarak, çok daha karmaşık ve doğrusal olmayan karar sınırları oluşturulmasına imkân sağlanmıştır.

Radyal fonksiyonun (RBF) temelini oluşturan gamma (γ) parametresi, fonksiyonun genişliğini ve ölçeğini belirleyen kritik öğrenme parametredir. Grid search ve k katlı çapraz doğrulama ile tespit edilen bu değer, az olması underfittinge, fazla olması da overfittinge neden olacağından, veri setindeki verilerin varyans değerleri göz önüne alınarak seçilmiştir. Ayrıca radyal fonksiyon verileri sonsuz boyutlu bir uzaya yansıtması sonucu oluşturduğundan, tahmin sonucuna göre denklem elde edilememektedir. Bundan dolayı radyal fonksiyonların denklemi, lineer türe çevrilmiş olup bu şekilde ifade edilmiştir.

3.3.1. SVR Algoritması ile İçmesuyu Proje Büyüklüğü Tahmin Modeli

SVR algoritması normalize edilmemiş veri seti matrislerinde negatif sonuç verdiği için, veri seti öncelikle normalize edilmiştir. Modelleme işlemine başlanılmadan önce, normalize veri setinin genel performansını değerlendirebilmek için k katlı çapraz doğrulama işlemi yapılmıştır. Modeldeki, C ve epsilon değerleri sırasıyla 1 ve 0.1 başlangıç değerleri alınarak veri seti çapraz doğrulamaya tabi tutulmuş olup modelin

performans ölçüt istatistikleri Tablo 47’de verilmektedir.

K katlı çapraz doğrulama sonucunda, en düşük hata değerleri ve yüksek açıklama kriterleri altında $k=4$ değeri en iyi kat (fold) olarak bulunmuştur. SVR algoritması, ağırlıklı olarak lineer çekirdek fonksiyonu ürününü kullandığından, veri setindeki doğrusal olmayan ilişkileri daha iyi sergilenebilmesi için polinom ve radyal kernel (çekirdek fonksiyonu) değerlendirmeye alınmıştır. Yapılan genel modelleme sonucu bulunan ölçüt istatistikleri, Tablo 48’de verilmiştir.

Tablo 47. SVR modelinin ($C:1$; $\epsilon:0.1$) çapraz doğrulama performans ölçütleri

k (fold)	MAE	RMSE	R ²
2	0.179	0.134	0.6900
3	0.105	0.086	0.8926
4	0.103	0.085	0.8975
5	0.107	0.088	0.8896
6	0.107	0.088	0.8891
7	0.106	0.088	0.8909
8	0.104	0.086	0.8945
9	0.104	0.086	0.8945
10	0.104	0.086	0.8941
11	0.105	0.086	0.8933
12	0.105	0.086	0.8933
13	0.104	0.086	0.8941
14	0.104	0.086	0.8944
15	0.104	0.086	0.8943


Tablo 48. SVR regresyon ($k\text{-cv}=4$, $C:1$; $\epsilon:0.1$) genel modelinin performans ölçütleri

Derece (Eğitim-Test)	1°	2°	3°	4°	5°
MAE	0.084	0.116	0.162	0.190	0.214
RMSE	0.096	0.148	0.188	0.223	0.251
R ²	0.878	0.715	0.537	0.346	0.158
Derece (Tahmin)	1°	2°	3°	4°	5°
MAE	0.033	0.186	0.243	0.284	0.325
RMSE	0.035	0.205	0.275	0.326	0.378
NSE	-2.712	-127.23	-229.65	-324.71	-436.09

Tablo 48 incelendiğinde, modelin derecesi arttıkça, hata değerleri de artmış ve verilerin modeli açıklanma yüzdeleri düşmüştür. Ayrıca NSE değerlerinin tamamının negatif ağırlıkta çıkmış olması nedeniyle, modelin tahmin performansı da çok kötü

olmuştur. SVR algoritmasının polinom kerneli, modelde nitelikli özellik dönüşümü yapamamış, dolayısıyla da aşırı uyum problemi göstermiştir. İlavenen, aynı parametrelere radyal kernel dönüşümü de uygulanmış, benzer nitelikte sonuçlar elde edilmiştir.

Bahse konu durumu iyileştirmek ve yüksek performanslı bir model elde edebilmek için ilk olarak SVR'nin C ve epsilon hiper parametrelerinde detaylı analiz yapılmış, bunların kolektif olarak RMSE değeriyle değişimlerini gösteren ısı haritası Şekil 48'de çıkarılmıştır.



Şekil 48. SVR algoritması C-ε ve RMSE ısı haritası

Şekil 49'a göre en az hatanın olduğu değerler, mor renkle işaretli yerlerin kesişim yerleridir. Yüzeysel olarak incelenildiğinde; en iyi model oluşturulabilmesi için, C değerinin net olmamakla birlikte 1 ile 100 arasında, epsilon değerinin ise kesin olarak 0.01 mertebesinde olması gerekmektedir.


Phyton programa diliyle beraber, optimum hata oranı ve tahmin performansı en yüksek düzeyde olacak şekilde, hiper parametre ve kernel seçim optimizasyonu yapılmıştır. Yapılan optimizasyon işlemi neticesinde, C ve epsilon değerlerinin sırasıyla 100 ve 0.01 olduğu 2. dereceli radyal kernel fonksiyonu en iyi model olarak seçilmiştir. Seçilen modeldeki değerler, hassas ve karmaşık bir analiz yapılacağına işaret etmektedir. Ayrıca grid search analizinde k katlı çapraz doğrulama da yapılmış olup k=8 değerinden sonraki modellerin kabul edilebilir performans sergilediği, kernel fonksiyon derecelerinin

ise çapraz doğrulama sonucu modelde herhangi bir etkisinin olmadığı görülmüştür. Yapılan tüm bu işlemlerle birlikte modeller kurulmuş olup bulunan performans ölçüt değerleri Tablo 49’da sunulmuştur.

Optimize modelde, k=8 katlı doğrulamadan sonra hata değerleri ve performansta önemli bir artışın olmadığı göze çarpmaktadır. Tahmin setinde ise NSE değerleri %50’nin üzerinde olması nedeniyle nispeten kabul edilebilir düzeydedir. Bu şartlar altında, k=10 çapraz doğrulamalı model tercih edilmiş olup içmesuyu proje büyüklüğü bağımlı değişkeninin zaman serileri grafiği Şekil 49’da çizilmiştir.


Tablo 49. SVR regresyon özel modelinin performans ölçütleri

Fold (cv) (Eğitim-Test)	k=7	k=8	k=9	k=10
MAE	0.024	0.023	0.024	0.024
RMSE	0.029	0.027	0.026	0.026
R2	0.893	0.911	0.913	0.914
Fold (cv) (Tahmin)	k=7	k=8	k=9	k=10
MAE	0.043	0.017	0.016	0.016
RMSE	0.044	0.022	0.022	0.022
NSE	-0.885	0.547	0.548	0.548



Şekil 49. SVR algoritması içmesuyu proje büyüklüğü değişkenine ait zaman serisi grafiği

Eğitim-test setinin k=10 katlı çapraz doğrulama sonucu oluşturulan modelin zaman serisinde, tahmin edilen değerler gerçek değerlere paralel açıklama yaptığı göstermektedir. Tahmin modelinden edilen içmesuyu proje büyüklüğü değişkenine ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 50’de gösterilmektedir.



Şekil 50. SVR algoritması içmesuyu proje büyüklüğü değişkenine ait saçılım grafiği

Hazırlanan saçılım grafikleri incelendiğinde, k=10 katlı çapraz doğrulamalı modelin eğitim-test tahmin değerlerinin köşegene daha yakın olduğu görülmekte ve gerçek proje büyüklüklerine yakın sonuçlar sergilemektedir.

SVR algoritmasında doğrusal olmayan kernel fonksiyonların, model denklemi ve değişkenlerin göreceli önemi doğrudan çıkarılamamaktadır. Ancak algoritmanın doğrusal forma dönüştürülmesiyle birinci dereceden lineer denklem elde edilebilmektedir. SVR algoritmasıyla oluşturulan modelden elde edilen parametreler-hiper parametre fonksiyonlarına tespitine ilişkin değerler ve içmesuyu proje büyüklüğü bağımlı değişkeninin lineer dönüşüm denklemi Tablo 50’de verilmiştir.

Tablo 50. SVR algoritması modelinin fonksiyonları ve içmesuyu proje büyüklüğü değişkeninin elde edildiği denklem

Başlangıç Temel Fonksiyonları

Random State: 42 (HP)

('C': 100, 'degree': 2, 'epsilon': 0.01, 'gamma': 'auto', 'kernel': 'rbf') (HP)

İntercept (Sabit): 0.98319386 (P) ; D-dağıtım debisi


İ proje büyüklüğü = 0.98319386 + 0.09142896*D

Çapraz doğrulama ile eğitilen modelimiz, ardından tüm veri setiyle tekrar eğitildikten sonra yeni verilerle tahmin aşamasına geçilmiş olup Tablo 8 ve 28’de verilen senaryoya göre içmesuyu proje büyüklüğünün tahmin işlemleri gerçekleştirilmiştir. Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin edildiği değerler Tablo 51’de sunulmaktadır.

Tablo 51. SVR algoritması ile Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğü tahmin modeli sonuçları

Yıl	Gerçek İçmesuyu Proje Büyüklüğü (m)	SVR Model (k=10,cv)	
		Tahmin Edilen İçmesuyu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)
2021	7.664,74	7.579,99	98.89%
2022	7.772,72	7.758,12	99.81%
2023	7.848,50	7.866,18	99.78%
2024	---	8.043,38	
2025	---	8.212,31	
2026	---	8.373,93	

Tablo 51’de verilen tahmin sonuçları incelendiğinde, kurulan modelin 2021-2023 yılları arasında gerçeğe yakın sonuçlar vermiştir. Modelin, ilk üç yıl içindeki tahmin performansı ve doğruluğunun yüksek olduğu görülmektedir. Model performansının daha iyi gözlemlenebilmesi için Şekil 51’de zaman serileri grafiği çizilmiştir.



Şekil 51. SVR algoritması tahmin modeline ait zaman serisi grafiği

3.3.2. SVR Algoritması ile Atıksu Proje Büyüklüğü Tahmin Modeli

Min-max normalizasyonu yapılan SVR algoritması, tüm verileri etkin kullanabilmek için k katlı çapraz doğrulama yapılmıştır. 1 ve 0.1 başlangıç C ve epsilon değerleri altında

model, çapraz doğrulama ile eğitim ve test işlemlerine tabi tutulmuş olup modelin performans ölçüt istatistikleri Tablo 52’de verilmektedir.

K katlı çapraz doğrulama sonucunda, en düşük hata değerleri ve yüksek açıklama kriterleri altında $k=7$ değeri en iyi fold olarak bulunmuştur. SVR algoritması, ağırlıklı olarak lineer çekirdek fonksiyonu ürünü kullandığından, veri setindeki doğrusal olmayan ilişkileri daha iyi sergileyebilmesi için polinom kernel (çekirdek fonksiyonu) değerlendirmeye alınmıştır. Yapılan genel modelleme sonucu bulunan ölçüt istatistikleri, Tablo 53’te verilmiştir.

Tablo 52. SVR modelinin ($C:1$; $\epsilon:0.1$) çapraz doğrulama performans ölçütleri

k (fold)	MAE	RMSE	R ²
2	0.1012	0.1403	0.7001
3	0.0701	0.0903	0.8758
4	0.0696	0.0899	0.8769
5	0.0709	0.0898	0.8772
6	0.0710	0.0898	0.8770
7	0.0710	0.0893	0.8784
8	0.0711	0.0898	0.8771
9	0.0712	0.0899	0.8770
10	0.0712	0.0899	0.8770
11	0.0717	0.0902	0.8762
12	0.0720	0.0902	0.8761
13	0.0717	0.0901	0.8764
14	0.0713	0.0897	0.8776
15	0.0714	0.0897	0.8775


Tablo 53. SVR regresyon ($k\text{-cv}=7$, $C:1$; $\epsilon:0.1$) genel modelinin performans ölçütleri

Derece (Eğitim-Test)	1°	2°	3°	4°	5°
MAE	0.052	0.065	0.116	0.143	0.162
RMSE	0.058	0.079	0.129	0.157	0.176
R ²	0.701	0.813	0.337	-0.066	-0.328
Derece (Tahmin)	1°	2°	3°	4°	5°
MAE	0.026	0.174	0.223	0.270	0.395
RMSE	0.036	0.189	0.248	0.304	0.442
NSE	-5.023	-168.98	-293.59	-442.01	-935.14

Hem eğitim-test seti hem de tahmin seti sonuçlarına göre, modelin polinom derecesi arttıkça, aşırı uyum ve karmaşıklığa bağlı olarak modelin genel ve tahmin performansı ciddi derecede kötüleşmektedir. Küçük dereceli kernel fonksiyonları, eğitim-test aşamasında iyi performans sergilemesine karşın tahmin seti üzerindeki NSE değerleri

negatif yani başarısız çıkmıştır. Polinom kernel fonksiyona ek olarak radyal kernel de veri seti üzerinde denenmiş olumlu bir sonuç gözlemlenememiştir.

SVR modelinin yüksek performanslı bir hale getirebilmek, hiper parametreler üzerinde daha detaylı analiz yapılmasına bağlıdır. Modeldeki olumsuz durumları düzeltmek ve iyi bir tahmin performansı elde edebilmek için öncelikle C ve epsilon hiper parametrelerinde birlikte uyumu ve RMSE değerleriyle değişimi gözlenmesi gerekmektedir. Bunun için de SVR regresyonunda anılan parametrelerin hata değerleriyle değişimini gösteren ısı haritası Şekil 52’de çıkarılmıştır.



Şekil 52. SVR algoritması C-ε değerleri ısı haritası

Şekil 52’de mor bölgeler, hatanın minimum olduğu yerlerdir. Düşük hatalı ve yüksek performanslı bir model geliştirebilmek için hata marjı olan epsilon değerinin 0.01 mutlak olmakla birlikte, C değerinin 1 ile 100 arasında olması gerekmektedir. Bunun için de SVR algoritmasının kernel fonksiyonları ve hiper parametre seçim optimizasyonu yapılmıştır.


Yapılan optimizasyon işlemi neticesinde, C ve epsilon değerlerinin 1 ve 0.01 olduğu dereceli radyal kernel fonksiyon ile C ve epsilon değerlerinin 30 ve 0.01 olduğu ikinci dereceli radyal kernel fonksiyonlar en iyi modeller olarak bulunmuştur. İkinci dereceli modelin, lineer modelden yaklaşık %10 daha fazla tahmin performans skoru (NSE) sergilediği görülmüştür. Seçilen bu model üzerinde grid search destekli k katlı çapraz doğrulama yapılmış, en iyi fold değerinin 6’dan başladığı görülmüştür. Ayrıca model

üzerinde radyal çekirdek fonksiyon derecelerinin çapraz doğrulama etkisi altında pek değişmediği tespit edilmiştir. Yapılan parametre optimizasyonu sonucu elde edilen örnek modellere ait performans ölçüt değerleri Tablo 54'te sunulmuştur.

Tablo 54. SVR regresyon örnek modellerin performans ölçütleri

Fold (cv) (Eğitim-Test)	k=6	k=7	k=8	k=9
MAE	0.025	0.023	0.026	0.029
RMSE	0.029	0.026	0.027	0.031
R2	0.862	0.881	0.902	0.922
Fold (cv) (Tahmin)	k=6	k=7	k=8	k=9
MAE	0.009	0.009	0.007	0.006
RMSE	0.011	0.013	0.009	0.008
NSE	0.384	0.384	0.579	0.623


Optimize edilmiş modelde, k fold değeri arttıkça hataların azaldığı dolayısıyla da performansın arttığı görülmektedir. 8. ve 9. fold tahmin performansları yeterli görülmekle beraber k=9 çapraz doğrulamalı model foldu tercih edilmiş olup atıksu proje büyüklüğü bağımlı değişkeninin zaman serileri grafiği Şekil 53'te çizilmiştir.



Şekil 53. SVR algoritması atıksu proje büyüklüğü değişkenine ait zaman serisi grafiği

K=9 katlı çapraz doğrulama sonucu eğitim-test seti verilerinin, aşırı uyum sorunu göstermediği, gerçek değerlere paralel olduğu görülmektedir. Özellikle 4, 11 ve 15. verilerde bu durum dikkat çekicidir. Optimize modelin atıksu proje büyüklüğü değişkenine

ait eğitim ve test veri setlerinin saçılım grafikleri Şekil 54'te gösterilmektedir.



Şekil 54. SVR algoritması atıksu proje büyüklüğü değişkenine ait saçılım grafiği

Şekil 54 incelendiğinde, k=9 katlı çapraz doğrulamalı modelin eğitim-test tahmin değerlerinin köşegene yakınsak olduğu görülmektedir. Bu da modelin, genel olarak iyi tahminlerde bulunduğunu göstermekle birlikte, bazı noktalarda tahminler, referans çizgisinde sapmalar yapmıştır. SVR algoritmasıyla oluşturulan modelden elde edilen parametre-hiper parametre fonksiyonlarının tespitine ilişkin değerler ve atıksu proje büyüklüğü bağımlı değişkeninin lineer dönüşüm denklemi Tablo 55'te verilmiştir.

Tablo 55. SVR algoritması modelinin fonksiyonları ve atıksu proje büyüklüğü değişkeninin elde edildiği denklem


Başlangıç Temel Fonksiyonları
Random State: 42 (HP)
('C': 30, 'degree': 2, 'epsilon': 0.01, 'gamma': 'auto', 'kernel': 'rbf') (HP)
İntercept (Sabit): 1.00714194 (P) ; D-dağıtım debisi
İ proje büyüklüğü = 1.00714194 + 0.06019892*D

Optimizasyon parametreleriyle yeniden şekillendirilip çapraz doğrulamayla da eğitilen model, Tablo 8 ve 28'de verilen senaryoya göre atıksu proje büyüklüğünün tahmin işlemleri yapılmıştır. Adana şehir merkezinin 2021-2026 yılları arası içmesuyu proje büyüklüğünün tahmin edildiği değerler Tablo 56'da sunulmaktadır.

Tablo 56. SVR algoritması ile Adana şehir merkezinin 2021-2026 yılları arası atıksu proje büyüklüğü tahmin modeli sonuçları

Yıl	Gerçek Atıksu Proje Büyüklüğü (m)	SVR Model (k=9,cv)	
		Tahmin Edilen Atıksu Proje Büyüklüğü (m)	Tahmin Yüzdesi (%)
2021	4.281,54	4.251,10	99.29%
2022	4.321,08	4.350,97	99.31%
2023	4.371,11	4.398,88	99.37%
2024	---	4.460,98	
2025	---	4.503,57	
2026	---	4.528,41	

Tablo 56’da verilen tahmin sonuçları incelendiğinde, kurulan model, gerçeğe oldukça yakın sonuçlar vermiş olup ilk üç yıl içindeki modelin tahmin performansı ve doğruluğunun da yüksek olduğu görülmektedir. Model performansının daha iyi gözlemlenebilmesi için Şekil 55’te zaman serileri grafiği sunulmaktadır.



Şekil 55. SVR algoritması tahmin modeline ait zaman serisi grafiği

3.4. Proje Büyüklüğü Tahmin Modellerinin Karşılaştırılması

İçmesuyu ve atıksu proje büyüklüğü değişkenlerini tahmin etmek için kurulan ve kendi içerisinde en iyi performans sergileyen makine öğrenmesi tabanlı Ridge ve SVR algoritmalarının eğitim-test ve tahmin setlerinden elde edilen karşılaştırmalı performans ölçüt istatistikleri, Tablo 57 ve Tablo 58’de sunulmaktadır.

Tablo 57. İçmesuyu proje büyüklüğü bağımlı değişken modeli performans istatistiklerinin karşılaştırılması

Eğitim-Test	Ridge ($\alpha:1$) Modeli	SVR (C:100; $\epsilon:0.01$) Modeli	
MAE	0.042	0.024	
RMSE	0.048	0.026	
R ²	0.971	0.914	
Tahmin	Ridge ($\alpha:1$) Modeli	SVR (C:100; $\epsilon:0.01$) Modeli	
MAE	0.009	0.016	
RMSE	0.010	0.022	
NSE	0.889	0.548	
Ortalama	Ridge ($\alpha:1$) Modeli	SVR (C:100; $\epsilon:0.01$) Modeli	Fark (%)
MAE	0.026	0.020	21.6
RMSE	0.029	0.024	17.2
R ² =NSE	0.930	0.731	21.4

Tablo 58. Atıksu proje büyüklüğü bağımlı değişken modeli performans istatistiklerinin karşılaştırılması


Eğitim-Test	Ridge ($\alpha: 0.002$) Modeli	SVR (C:30, $\epsilon:0.01$) Modeli	
MAE	0.073	0.029	
RMSE	0.111	0.031	
R ²	0.885	0.922	
Tahmin	Ridge ($\alpha: 0.002$) Modeli	SVR (C:30, $\epsilon:0.01$) Modeli	
MAE	0.002	0.006	
RMSE	0.003	0.008	
NSE	0.937	0.623	
Ortalama	Ridge ($\alpha: 0.002$) Modeli	SVR (C:30, $\epsilon:0.01$) Modeli	Fark (%)
MAE	0.038	0.018	53.3
RMSE	0.057	0.020	65.8
R ² =NSE	0.911	0.773	15.2

Tablo 57 ve 58 incelendiğinde, içmesuyu proje büyüklüğü için yapılan modellemelerde, SVR algoritması MAE ve RMSE hata metriklerinin %21.6 ve %17.2 daha iyi performans göstermesine karşın, NSE katsayısında Ridge algoritmasına göre %21.4 daha az performans sergilemiştir. Yine aynı şekilde, atıksu proje büyüklüğü için yapılan modellemelerde, SVR algoritması MAE ve RMSE hata metriklerinin %53.3 ve %65.8 daha iyi performans göstermesine karşın, NSE katsayısında Ridge algoritmasına göre %15.2 daha az performans sergilemiştir.


SVR algoritması, genelde daha karmaşık ve esnek bir model olduğundan, özellikle verilerin karmaşıklığını yakalamada Ridge modeline göre daha yetenekli olabileceğinden, hata metriklerinin düşük çıkması beklenen bir durumdur. Ancak bu esneklik, NSE değerlerinden anlaşıldığı üzere, model üzerinde aşırı uyuma (overfitting) daha da yatkınlık

sağlamıştır. Dolayısıyla da aşırı uyum sorunuyla daha iyi baş ederek, veriyi açıklama ve modelin stabilitesi yönünden, Ridge algoritması modellerinin genel tahmin performansı çok iyi seviyede olmuştur.

Gerçek proje büyüklükleri ile tahmin edilen proje büyüklüklerine ait eğitim-test ve tahmin setleri için en iyi modellemelere ait saçılım grafiği içmesuyu için Şekil 56'da ve atıksu için Şekil 57'de çizilerek karşılaştırılmıştır.



Şekil 56. İçmesuyu proje büyüklüğü değişkeni modellerinin karşılaştırmalı saçılım grafiği



Şekil 57. Atıksu proje büyüklüğü değişkeni modellerinin karşılaştırmalı saçılım grafiği

Şekil 57 ve 58 incelendiğinde, yukarıda detayları bahsedildiği üzere, test-eğitim aşamasında, daha çok uyum sergileyen SVR algoritmali modellerin; tahmin aşamasında ise Ridge algoritmali modellerin köşegene daha fazla yakın olduğu görülmektedir. Modeller, tahmin performansı açısından değerlendirilecek olunursa; Ridge algoritmali modellerin, gerçek içmesuyu proje büyüklüğü değerlerine daha yakın sonuçlar sergilemektedir.

3.5. Proje Büyüklüğü Tahmin Değerleri


Adana iline ait toplam içmesuyu ve atıksu altyapı proje büyüklüklerine ilişkin, ASKİ Genel Müdürlüğü ve İLBANK Adana Bölge Müdürlüğünden temin edilen mevcut veriler ile çalışma kapsamında elde edilen tahmini değerler Tablo 59’da karşılaştırmalı olarak verilmektedir. Ayrıca, geleceğe yönelik tahmin senaryoları içmesuyu için Şekil 58’de ve atıksu için Şekil 59’da dairesel grafik formatında görselleştirilerek sunulmaktadır.

Tablo 59. Adana ili merkez ilçelerine ait toplam içmesuyu ve atıksu altyapı proje büyüklüklerine ilişkin geçmiş ve tahmin değerleri


	Yıl	İçmesuyu	Atıksu
		Proje Büyüklüğü (km)	Proje Büyüklüğü (km)
Mevcut Altyapı Değerleri	2006	5189.42	2185.46
	2007	5396.16	2398.97
	2008	5613.00	2582.00
	2009	5880.02	2739.38
	2010	6028.25	2873.48
	2011	6406.23	3065.46
	2012	6638.39	3232.79
	2013	6904.99	3471.86
	2014	6961.08	3672.56
	2015	7085.65	3784.38
	2016	7180.69	3818.45
	2017	7245.74	3949.51
	2018	7332.41	4068.57
	2019	7407.28	4146.71
	2020	7548.84	4213.33
	2021	7664.74	4281.54
	2022	7772.72	4321.08
	2023	7848.5	4371.11

Tablo 59'un devamı

Tahmin Modeli Değerleri	Ridge	2021	7629.96	4274.86
		2022	7781.39	4320.98
		2023	7873.46	4356.64
		2024	7988.01	4408.39
		2025	8104.56	4468.99
		2026	8224.17	4539.08
	SVR	2021	7579.99	4251.1
		2022	7758.12	4350.97
		2023	7866.18	4398.88
		2024	8043.38	4460.98
		2025	8212.31	4503.57
		2026	8373.93	4528.41



Şekil 58. Adana ili içmesuyu proje büyüklüklerine ilişkin tahmin senaryoları



Şekil 59. Adana ili atıksu proje büyüklüklerine ilişkin tahmin senaryoları

4. TARTIŞMALAR

Bu çalışma, altyapı projelerinin uzun vadeli sürdürülebilirliğini sağlamak amacıyla, iklim değişikliği ve sosyo-ekonomik parametrelerin etkilerini bütüncül bir yaklaşımla ele alarak literatüre önemli bir katkı sunmaktadır. Benzer çalışmalardan farklı olarak, çok boyutlu bir veri analiziyle geliştirilen gerçekçi tahmin modelleri, planlama süreçlerine entegre edilebilir hale getirilmiştir. Seçilen yenilikçi yöntemler sayesinde, altyapı projelerinin çevresel ve ekonomik etkileri daha öngörülebilir hale getirilmiş ve karar alma süreçlerine yenilikçi bir perspektif kazandırılmıştır. Çalışmada, geleneksel tahmin yöntemlerinin ötesinde, dinamik ve çok yönlü bir model sunulmuş; böylece altyapı projelerinin iklimsel ve sosyal değişimlere karşı dayanıklılığını artırmaya yönelik önemli bir katkı sağlanmıştır.

Çalışmanın birinci aşamasında, modellerde kullanılan parametrelerin seçiminde SWARA ve PCA yöntemleri uygulanmıştır. Bu yöntemler, özellikle şehir gelişmişliği, yerleşim nüfusu ve abone sayısı gibi sosyo-ekonomik parametrelerin etkisinin önemli olduğunu ortaya koymuştur. Dağıtım debisinin tahmini için Ridge, Lasso, XGBoost ve SVR algoritmaları kullanılarak modeller geliştirilmiştir. İkinci aşamada ise, birinci aşamada en yüksek performansı gösteren Ridge ve SVR algoritmalarına dayalı modeller kullanılarak, dağıtım debisi tahmin sonuçları üzerinden içmesuyu ve atıksu proje büyüklükleri tahmin edilmiştir.

Dağıtım debisi tahmin sürecinde (birinci aşama), Ridge algoritması, genellenebilirliği yüksek sonuçlar sağlamış, SVR ise özellikle hata metriklerinde daha düşük değerler sunarak model başarısını ortaya koymuştur. Ridge algoritmasının performansı, L2 normuna dayalı düzenlemenin model karmaşıklığını kontrol altında tutarak aşırı uyumu engelleme kabiliyetine bağlanabilir. Benzer şekilde, SVR algoritmasının esnek çekirdek (kernel) fonksiyonları, karmaşık ve doğrusal olmayan ilişkileri yakalamada etkili olmuştur. Bu aşamada, SVR algoritması, altyapı projeleri modellemesinde iklim değişikliğinin etkisinin %3,61 olduğunu, buna karşılık sosyo-ekonomik parametrelerin etkisinin %96,39 gibi belirleyici bir oranda olduğunu ortaya koymuştur.

Diğer yandan, Lasso ve XGBoost algoritmalarında gözlemlenen veriye aşırı uyum, tahmin süreçlerindeki düşük performansın ana sebebi olarak değerlendirilmiştir. Özellikle, Lasso algoritmasında, bazı değişkenlerin katsayılarının sıfıra indirgenmesi nedeniyle modelin önemli özellikleri göz ardı etmesi, düşük performansa katkı sağlamıştır.

Çalışmanın ikinci aşamasında ise Ridge ve SVR algoritmaları kullanılarak içmesuyu ve atıksu altyapı projelerinin büyüklükleri başarıyla tahmin edilmiştir. Özellikle Ridge algoritmasının polinomsal ve etkileşim terimleriyle desteklenmesi, karmaşık ilişkilerin daha iyi modellenmesine olanak sağlamış ve genellenebilir sonuçlar üretmiştir. SVR algoritması ise hata toleranslarını polinomsal ve kernel fonksiyonlarıyla birleştirerek içmesuyu ve atıksu proje büyüklükleri tahmininde etkili sonuçlar elde etmiştir. Ancak, NSE değerlerinin Ridge algoritmasından düşük olması, SVR algoritmasının genelleme kabiliyetinde bazı eksikliklere işaret etmektedir. Bu bulgular, literatürde sıklıkla vurgulanan ve makine öğrenmesi algoritmalarının etkinliğini artırmada kritik bir rol oynayan model optimizasyonunun (tuning) tahmin başarısı üzerindeki belirleyici etkisini açıkça ortaya koymaktadır. Özellikle, algoritma performansını iyileştirmek için uygun hiperparametre seçimlerinin yapılmasının, analiz edilen veri setleri bağlamında, sonuçları önemli ölçüde iyileştirdiği görülmüştür.

Veri seti boyutunun sınırlı olması, algoritmaların genelleme performansını doğrudan etkilemiş ve bazı modellerde aşırı uyuma yol açmıştır. Bu bağlamda, k-kat çapraz doğrulama gibi yöntemlerin kullanılması önemli bir avantaj sağlasa da daha geniş veri setleri ile doğrulama yapılması önerilmektedir. Gelecek çalışmalar, veri setinin artırılmasının yanı sıra, Ridge ve SVR algoritmalarına dayalı hibrit modellerin geliştirilmesine odaklanabilir. Ayrıca, hiperparametre optimizasyonunda daha gelişmiş yöntemler (örneğin, genetik algoritmalar veya bayesiyan optimizasyon vs.) kullanılarak tahmin doğruluğu daha da artırılabilir.

Çalışmada, Ridge ve SVR algoritmalarının altyapı proje büyüklüklerinin tahmininde kullanımına odaklanması, literatürdeki güçlü temeller üzerine inşa edilmiş anılan algoritmaların gerçek koşullara yönelik potansiyelini ortaya koymuştur. Özellikle, Ridge algoritmasının polinomsal ve etkileşim terimleriyle desteklenmesi, karmaşık veri ilişkilerinin modellenmesinde etkili bir yöntem olarak literatüre katkı sunmaktadır. Ridge algoritmasının bu tür genişletilmiş yaklaşımlar ile kullanımı literatürde sınırlı olduğundan, bu çalışma bu alandaki önemli bir boşluğu doldurmaktadır. Elde edilen sonuçlar, Şahinarslan (2019) ve Bayrakçı vd. (2021) gibi önceki çalışmalarla paralellik göstererek literatüre anlamlı bir katkı sağlamaktadır.

Modelleme çalışmalarında kullanılan SVR algoritması, literatürde tahmin doğruluğu yüksek modeller arasında sıklıkla tercih edilmektedir. Özellikle karmaşık ve doğrusal olmayan veri yapılarını modellemede üstün bir performans sergileyerek hata oranlarını düşürdüğü (MAE: 0,05, RMSE: 0,06) ve NSE değeri açısından güçlü bir sonuç ortaya koyduğu (0,86) görülmüştür. Bu bulgular, İbrahim vd. (2020) ve Yurtsever ve Emeç (2023)

gibi çalışmalarda sunulan sonuçlarla uyum içerisindedir. Bahsi geçen çalışmalarda, SVR algoritmasının içmesuyu kalite ve talep tahmininde sırasıyla %99,4 ve %92 doğruluk oranları elde ettiği ve genellenebilirlik açısından üstün performans gösterdiği vurgulanmıştır.

XGBoost algoritması, MAE ve RMSE değerleri açısından iyi sonuçlar sunmasına rağmen, aşırı uyum sorunları nedeniyle tahmin performansı sınırlı kalmıştır. Modelleme çalışmalarından elde edilen bulgular, Feng vd. (2023) tarafından su kalitesi kontrolü ve Nie vd. (2022) tarafından elektrik talep tahminlerinde belirtilen yüksek genelleme başarısının aksine, düşük genellenebilirlik ortaya koymuştur. Bu durum, XGBoost algoritmasının karmaşık veri setlerinde yüksek doğruluk sağlamasına karşın, bazı veri setlerinde aşırı uyum nedeniyle genelleme kapasitesinde yaşanan düşüşle ilişkilendirilmektedir.

SWARA yöntemi ile önceliklendirilen ve PCA ile boyutları küçültülen parametreler, tahmin modellerinin doğruluğunu artırmada önemli bir rol oynamıştır. Bu bağlamda, Aydeniz İklim Katsayısı ve sosyo-ekonomik parametrelerin (şehir gelişmişliği, yerleşim nüfusu, abone sayısı) modelleme sürecine entegre edilmesi, altyapı projelerinin tahmin performansını iyileştirmiştir. Benzer şekilde, Zhou vd. (2014), Shenyang vilayetinin su talebi tahmininde Temel Bileşen Analizi (PCA) yöntemini kullanarak parametre sayısını azaltmış ve model doğruluğunu artırmayı başarmıştır.

Altyapı projelerinde iklim değişikliği parametrelerinin dikkate alınması, literatürdeki diğer çalışmalarla uyumlu bir yaklaşım sergilemektedir. Örneğin, Sooji vd. (2017), iklim değişikliği senaryolarına uyum sağlamak amacıyla altyapı projelerinde uzun vadeli projeksiyonların önemini vurgulamıştır. Benzer şekilde, Oslakovic vd. (2012), iklim değişikliğinin altyapı performansı üzerindeki etkilerini incelemiş ve dayanıklılık ile sürdürülebilirlik açısından kritik bir rol oynadığını ifade etmiştir. Zhang vd. (2023) ise altyapı projelerinin sürdürülebilirliğini sağlamak için iklim değişikliği parametrelerinin entegrasyonunun önemini ortaya koymuştur. Bu bağlamda, çalışmada kullanılan Aydeniz İklim Sınıflandırması, bölgesel iklim değişikliklerinin altyapı projelerine olan etkilerini değerlendirmek için güçlü bir temel sunmakta ve mevcut literatüre değerli bir katkı sağlamaktadır.

Çalışmada, Ridge ve SVR algoritmalarının altyapı proje büyüklüklerinin tahmininde kullanımına odaklanması, literatürdeki bu güçlü temeller üzerine inşa edilmiş ve algoritmaların gerçek koşullara yönelik potansiyelini ortaya koymuştur. Özellikle Ridge algoritmasının polinomsal ve etkileşim terimleriyle desteklenmesi, karmaşık veri ilişkilerinin modellenmesinde etkili bir yöntem olarak literatüre katkı sunmaktadır. Ridge algoritmasının

bu tür genişletilmiş yaklaşımlar ile kullanımı literatürde sınırlı olduğundan, bu çalışma bu alandaki önemli bir boşluğu doldurmaktadır. Bununla birlikte, elde edilen sonuçlar, Şahinarslan (2019) ve Bayrakçı vd. (2021) gibi önceki çalışmalarla paralellik göstererek literatüre anlamlı bir katkı sağlamaktadır.

Modelleme çalışmalarında kullanılan SVR algoritması, literatürde tahmin doğruluğu yüksek modeller arasında sıklıkla tercih edilmektedir. Özellikle karmaşık ve doğrusal olmayan veri yapılarını modellemede üstün bir performans sergileyerek hata oranlarını düşürdüğü (MAE: 0,05, RMSE: 0,06) ve NSE değeri açısından güçlü bir sonuç ortaya koyduğu (0,86) görülmüştür. Bu bulgular, İbrahim vd. (2020) ve Yurtsever ve Emeç (2023) gibi çalışmalarda sunulan sonuçlarla uyum içerisindedir. Bahsi geçen çalışmalarda, SVR algoritmasının içmesuyu kalite ve talep tahmininde sırasıyla %99,4 ve %92 doğruluk oranları elde ettiği ve genellenebilirlik açısından üstün performans gösterdiği vurgulanmıştır.

XGBoost algoritması, MAE ve RMSE değerleri açısından iyi sonuçlar sunmasına rağmen, aşırı uyum sorunları nedeniyle tahmin performansı sınırlı kalmıştır. Modelleme çalışmalarından elde edilen bulgular, Feng vd. (2023) tarafından su kalitesi kontrolü ve Nie vd. (2022) tarafından elektrik talep tahminlerinde belirtilen yüksek genelleme (tahmin performansı) başarısının aksine, düşük genellenebilirlik ortaya koymuştur. Bu durum, XGBoost algoritmasının karmaşık veri setlerinde yüksek doğruluk sağlamasına karşın, bazı veri setlerinde aşırı uyum nedeniyle genelleme kapasitesinde yaşanan düşüşle ilişkilendirilmektedir.

SWARA yöntemi ile önceliklendirilen ve PCA ile boyutları küçültülen parametreler, tahmin modellerinin doğruluğunu artırmada önemli bir rol oynamıştır. Bu bağlamda, Aydeniz İklim Katsayısı ve sosyo-ekonomik parametrelerin (şehir gelişmişliği, yerleşim nüfusu, abone sayısı) modelleme sürecine entegre edilmesi, altyapı projelerinin tahmin performansını iyileştirmiştir. Benzer şekilde, Zhou vd. (2014), Shenyang vilayetinin su talebi tahmininde Temel Bileşen Analizi (PCA) yöntemini kullanarak parametre sayısını azaltmış ve model doğruluğunu artırmayı başarmıştır.

Altyapı projelerinde iklim değişikliği parametrelerinin dikkate alınması, literatürdeki diğer çalışmalarla uyumlu bir yaklaşım sergilemektedir. Örneğin, Sooji vd. (2017), iklim değişikliği senaryolarına uyum sağlamak amacıyla altyapı projelerinde uzun vadeli projeksiyonların önemini vurgulamıştır. Benzer şekilde, Oslakovic vd. (2012), iklim değişikliğinin altyapı performansı üzerindeki etkilerini incelemiş ve dayanıklılık ile sürdürülebilirlik açısından kritik bir rol oynadığını ifade etmiştir. Zhang vd. (2023) ise,

altyapı projelerinin sürdürülebilirliğini sağlamak için iklim değişikliği parametrelerinin entegrasyonunun önemini ortaya koymuştur. Bu bağlamda, çalışmada kullanılan Aydeniz İklim Sınıflandırması, bölgesel iklim değişikliklerinin altyapı projelerine olan etkilerini değerlendirmek için güçlü bir temel sunmakta ve mevcut literatüre değerli bir katkı sağlamaktadır.

Sonuç olarak, bu tez çalışması, Ridge ve SVR algoritmalarının altyapı projelerinin planlanmasında güvenilir tahmin modelleri oluşturulabileceğini göstererek, bu alandaki mevcut literatürü önemli ölçüde genişletmiştir. Modelleme sürecinde kullanılan SWARA, PCA ve özellik mühendisliği gibi çok boyutlu analiz yöntemlerinin entegrasyonu, tahmin modellerinin doğruluğunu artırırken, altyapı projelerinin uzun vadeli sürdürülebilirliğini sağlamaya yönelik önemli bir çerçeve sunmuştur. Çalışmada, iklimsel ve sosyo-ekonomik parametrelerin çeşitliliği, modellerin genellenebilirliğini artırmış ve altyapı projelerinin iklim değişikliği ve sosyal dinamiklere karşı dayanıklılığını değerlendirme imkânı sağlamıştır. Özellikle içmesuyu ve atıksu altyapıları için geliştirilen bu dinamik modeller, mühendislik uygulamaları ve karar destek sistemleri açısından değerli bir katkı sunmaktadır. Çalışma, altyapı projelerinin gelecekteki planlama süreçlerinde daha dayanıklı ve sürdürülebilir kararlar alınmasına ışık tutacak yenilikçi bir yaklaşım ortaya koymaktadır.

5. SONUÇLAR

Altyapı projelerinin başarılı bir şekilde hayata geçirilmesi, yapım yönetimi disiplininin merkezinde yer alan etkili planlama, koordinasyon ve kontrol süreçlerine dayanır. Yapım yönetimi, bu tür projelerin her aşamasında kritik bir öneme sahip olmakla birlikte, altyapı projelerinin çevresel ve sosyal etkilerini en aza indirerek, sürdürülebilir hedeflere ulaşma amacını taşır. Bu projelerin başlangıcında belirlenen kapsam, maliyet ve zaman yönetimi gibi temel unsurlar, başarıya ulaşmanın temel taşlarını oluşturur. Kalite kontrol süreçleri, kaynakların verimli kullanımı ve mevzuata uyum, altyapı projelerinin zamanında ve bütçe sınırları içinde tamamlanmasını güvence altına almaktadır.

İçme suyu ve atıksu altyapılarının nüfus artışı ve iklim değişikliği etkileri karşısındaki esnekliği ve dayanıklılığı, modern toplumların sürdürülebilirliğini sağlamada kritik bir öneme sahiptir. Söz konusu bu etkiler, altyapıların hizmet sunumunda aksamalara neden olabilecek risk taşımaktadır. Özellikle, nüfus artışı, iklim göçleri, kuraklık, aşırı yağış ve taşkınlar, altyapı sistemleri üzerinde baskı oluşturarak, su temininin aksamasına ve mevcut kapasitelerin zorlanarak altyapıların arızalara yatkın hale gelmesine yol açmaktadır. Bu nedenle sosyal ve iklimsel etkiler karşısında adaptasyonunun sağlanması, içmesuyu ve atıksu altyapılarının uzun vadeli performans ve sürdürülebilirliği açısından oldukça önemli hale getirmektedir.

Yukarıda belirtilen hususlar dikkate alınarak, bu tez çalışmasında, tasarım ve planlama aşamalarında söz konusu adaptasyona katkı sağlamak için gelecek yıllara ait içmesuyu ve atıksu altyapı projelerinin dağıtım debisi ve proje büyüklüklerinin (metraj) tahmin modellerinin geliştirilmesi amaçlanmıştır. Modelleme sürecinde, yapay zekâ destekli Ridge, Lasso, XGBoost ve SVR denetimli makine öğrenmesi algoritmaları kullanılmıştır.

Modellemelerde kullanılan parametreler, literatürdeki çalışmalar gözetilerek belirlenmiştir. Çalışmanın başlangıcında, 16 adet parametre belirlenmiş ve bu parametreler, çok ölçütlü karar verme yöntemlerinden SWARA yöntemi kullanılarak önceliklendirilmiştir. Bu süreçte, altyapı projeleri konusunda uzman 30 kişi ile görüşmeler gerçekleştirilmiş ve görüşmelerin ardından yapılan anketler aracılığıyla her bir parametrenin göreceli önemi belirlenerek sıralanmıştır. Sıralanan parametrelere de boyut küçültmesi ve özellik seçimi yapılabilmesi için Temel Bileşen Analizi (PCA) yöntemi kullanılarak 5 farklı bileşen analizi yapılmıştır. İklim değişikliği parametrelerinin kurulan modellerde etkin ve verimli

kullanabilmesi için de Aydeniz İklim Sınıflandırma yöntemi kullanılmıştır. Yapılan tüm bu işlemler neticesinde, 3 adet sosyo-ekonomik parametre (şehir gelişmişliği (GSYH), yerleşim nüfusu ve kayıtlı abone sayısı) ile iklimsel parametre Aydeniz Kuraklık İndeksi (Sıcaklık, güneşlenme süresi, yağış miktarı ve nem parametrelerinin birleşimi) olmak üzere toplam 4 adet bağımsız değişken seçilmiştir.

Kurulan modellerde kullanılan veriler ilgili kamu kurum ve kuruluşlarından toplanmış olup, veri seti 2006-2023 yılları arası 18 yılı kapsamakla birlikte, modellerin eğitim ve test setleri ise 2006-2020 yıllarını kapsayan 15 yıldan oluşmaktadır. Modelleme çalışmaları neticesinde, Adana şehri merkez ilçelerinin 2021-2026 yılları arasındaki dağıtım debisi ve içmesuyu ve atıksu altyapı proje büyüklükleri, resmi ve gerçekçi senaryolara göre tahmin edilmiş olup 2021-2023 yılları arasındaki gerçek değerlerle de kullanılan algoritmaların tahmin performansları MAE, RMSE, R^2 ve NSE ölçütleriyle sınanmıştır.

Veri setindeki parametrelerin birbirleriyle olan ilişkisi ve proje büyüklüğü tahminlerinin, dağıtım debisi üzerinden daha iyi bir şekilde tahmin edilebilmesi için tez çalışması iki aşamalı olarak yürütülmüştür. İlk aşamada belirlenen 4 adet bağımsız değişken ile dağıtım debisi bağımlı değişkenin tahminine ilişkin Ridge, Lasso, XGBoost ve SVR makine öğrenme algoritmaları modeller kurulmuştur. Tüm kurulan modeller, algoritmaların temel başlangıç parametrelili ve optimize edilmiş hiper parametrelili olmak üzere iki ayrı şekilde incelenmiştir. Yapılan dağıtım debisi tahmin modellemeleri neticesinde,

- ❖ Lasso Algoritması, ($\alpha:0.001$) optimize değerli II. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 2.70, RMSE:2.86, NSE:-0.35 olarak bulunmuştur. Modelin veriyi açıklama değerleri ve hata metriklerinin iyi sonuç vermesine rağmen, NSE değerinin negatif çıkması, modelin veriye aşırı uyum göstermesinin (overfitting) etkili olduğu görülmüştür.
- ❖ Ridge Algoritması, ($\alpha:1$) başlangıç değerli I. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.05, RMSE:0.06, NSE:0.84 olarak bulunmuştur. Modelin, hata metriklerinin minimum ve NSE tahmin değerinin çok iyi olması genellenebilir ve yüksek performanslı olduğu görülmüştür.
- ❖ XGBoost Algoritması, optimizasyonlu II. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.06, RMSE:0.07, NSE:-0.49 olarak bulunmuştur. Modelin veriyi açıklama değerleri ve hata metriklerinin çok iyi sonuç vermesine rağmen, NSE değerinin negatif çıkması, modelin veriye aşırı uyum göstermesinin (overfitting) etkili olduğu görülmüştür.

- ❖ SVR Algoritması, ($C=1, \epsilon=0.1$) başlangıç değerli I. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE:0.05, RMSE:0.06, NSE: 0.86 olarak bulunmuştur. Modelin, hata metriklerinin minimum ve NSE tahmin değerinin çok iyi olması genellenebilir ve yüksek performanslı olduğu görülmüştür.

Yukarıda verilen sonuçlara göre Lasso ve XGBoost algoritmaları veri seti üzerinde aşırı uyum sorununa bağlı olarak yüksek performanslı ve kabul edilebilir tahmin modelleri oluşturamamıştır. Diğer yandan Ridge ve SVR algoritmaları hem eğitim hem test hem de tahmin aşamalarında oldukça başarılı performans sergilemiş olup SVR algoritması, oransal olarak MAE ve RMSE hata metriklerinde %6.13 ve %6.41, NSE değerinde ise %1.39 olmak üzere Ridge algoritmasından daha fazla performans sergilemiştir. Kurulan her iki model de uygun hiper parametre değerleriyle verileri işleme ve sınırlandırma özellikleri çok iyi olmuş, genellenebilir dağıtım debisi tahmin sonuçları üretmiştir.

İkinci aşamada ise tahmini yapılan dağıtım debisi modellemelerinde en iyi performansı gösteren Ridge ve SVR makine öğrenmesi algoritmalarıyla içmesuyu ve atıksu altyapı proje büyüklüğü tahmin modelleri kurulmuştur. Kurulan modellerin doğruluğunu ve genellenebilirliğini arttırmak için k katlı çapraz doğrulama (cross-validation) kullanılmıştır. Bu sayede, az sayıdaki verilerin tamamı eğitim işleminde kullanılarak, az ve aşırı uyumun (underfitting, overfitting) önüne geçilmiştir.

Ridge algoritması proje büyüklükleri tahmin modellerinde, karmaşık ve doğrusal olmayan ilişkileri ortaya koymak ve daha esnek bir modeller oluşturabilmek için polinomsal ($D^2, D^3, \dots$) ve etkileşim terimlerinden ($\log_D$, $\sqrt{D}$, $D_squared$, $inverse_D$) yararlanılmıştır. Yapılan proje büyüklüğü tahmin modellemeleri neticesinde,

- ❖ İçmesuyu proje büyüklüğü, ($\alpha:1$) başlangıç değerli I. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.02, RMSE:0.03, NSE: 0.93 olarak bulunmuştur Modelin, hata metriklerinin minimum ve NSE tahmin değerinin çok iyi olması genellenebilir ve yüksek performanslı olduğu görülmüştür.
- ❖ Atıksu proje büyüklüğü, ($\alpha:0.002$) başlangıç değerli I. model en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.03, RMSE:0.05, NSE: 0.91 olarak elde edilmiştir. Bu sonuçlar, kurulan tahmin modelinin yüksek performanslı ve güvenilirliğinin yüksek olduğunu ortaya koymaktadır.

SVR algoritması proje büyüklükleri tahmin modellerinde, karmaşık ve doğrusal olmayan ilişkileri ortaya konabilmesi için hata toleransları dâhilinde polinomsal ($D^2, D^3, \dots$) ve kernel fonksiyonlarından yararlanılmıştır. Yapılan proje büyüklüğü tahmin modellemeleri

neticesinde,

- ❖ İçmesuyu proje büyüklüğü, (C:100; ϵ :0.01) hiper parametreleri ile en iyi performansı göstermiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.02, RMSE:0.02, NSE: 0.73 olarak bulunmuştur Modelin, hata metriklerinin az olması ve NSE tahmin değerinin iyi olması modelin kabul edilebilir düzeyde olmuştur.
- ❖ Atıksu proje büyüklüğü, (C:30; ϵ :0.01) hiper parametreleri ile en iyi performansı sergilemiştir. Kurulan modelin ortalama ölçüt istatistikleri ise MAE: 0.01, RMSE:0.02, NSE: 0.77 olarak bulunmuştur. Bu sonuçlar, kurulan tahmin modelinin tahmin performansının ve güvenilir olduğunu ortaya koymaktadır.

Ridge ve SVR algoritmaları eğitim-test ve tahmin süreçlerinde oldukça başarılı performans sergilemiş olup SVR algoritması, içmesuyu proje büyüklüğü tahminlerinde oransal olarak MAE ve RMSE hata ölçütlerinde %21,6 ve %17,2 daha iyi performans göstermesine karşın, NSE katsayısında Ridge algoritmasına göre %21,4 daha az performans sergilemiştir. Benzer şekilde, atıksu proje büyüklüğü tahmin modellemelerinde, SVR algoritması MAE ve RMSE hata ölçütlerinde %53,3 ve %65,8 daha iyi performans göstermesine karşın, NSE katsayısında Ridge algoritmasına göre %15,2 daha az performans sergilemiştir.

Makine öğrenmesi algoritmalarına dayalı olarak gerçekleştirilen bu çalışmada, Adana ilinin içmesuyu ve atıksu altyapı proje büyüklükleri için geleceğe yönelik tahmin senaryoları oluşturulmuştur. Ridge ve SVR algoritmalarının karşılaştırmalı analizleri sonucunda, içmesuyu ve atıksu projeksiyonları yıllar bazında detaylı olarak belirlenmiş ve iklim değişikliği ile sosyo-ekonomik değişkenlerin etkisi altında, altyapı proje büyüklüklerinde öngörülen artışlar tespit edilmiştir. Ridge algoritması ile yapılan analizlerde; içmesuyu proje büyüklükleri 2024, 2025 ve 2026 yılları için sırasıyla 7988,01 km, 8104,56 km ve 8224,17 km; atıksu proje büyüklükleri ise aynı yıllar için 4408,39 km, 4468,99 km ve 4539,08 km olarak hesaplanmıştır. SVR algoritması ile yapılan tahminler ise içmesuyu için 8043,38 km, 8212,31 km ve 8373,93 km; atıksu için ise 4460,98 km, 4503,57 km ve 4528,41 km olarak belirlenmiştir.

Sonuç olarak, bu çalışmada kullanılan algoritmik modeller, yapım yönetimi süreçlerinde giderek artan bir öneme sahip olmakta ve iklim değişikliği ile sosyo-ekonomik dinamiklerin altyapı projelerinin planlanması ve uygulanmasındaki etkilerini anlamada önemli bir destek sağlamaktadır Özellikle, bu faktörlerin maliyet bileşenlerine etkisi, projelerin sürdürülebilirliği ve fizibilitesini doğrudan şekillendirmektedir. Bu çalışmada, söz

konusu dinamiklerin maliyet bileşenleri üzerindeki etkilerinin önceden öngörülmesi ve bu etkilerin planlama süreçlerine entegre edilmesi amacıyla yapay zekâ destekli modeller kullanılmış ve ileriye dönük senaryolar oluşturulmuştur. Bu bilimsel yaklaşımlar, altyapı projelerinin daha dayanıklı, verimli ve ekonomik açıdan uygulanabilir hale gelmesini sağlayarak gelecekteki uygulamalara yönelik önemli katkılar sunmaktadır.



6. ÖNERİLER

Bu araştırma, makine öğrenmesi algoritmalarının faydaları, içmesuyu ve atıksu altyapı projelerinde önemli gelişmeler sağlamış olsa da tezin gelecekteki uzantıları için şu ek iyileştirmeler önerilmektedir:

- ❖ Bu çalışmada kullanılan denetimli makine öğrenmesi algoritmaları, elektrik, doğalgaz ve yol gibi farklı altyapı türlerine uyarlanarak çeşitli amaçlara yönelik modellerin geliştirilmesinde kullanılabilir. Bu uyarlamalar, algoritmaların performanslarının farklı koşullarda gözlemlenmesini ve karşılaştırılmasını mümkün kılacaktır.
- ❖ İçme suyu ve atıksu altyapılarının sosyo-ekonomik ve iklim değişikliği gibi etkilerle başa çıkabilmesi için çeşitli adaptasyon stratejileri geliştirilebilir. Dirençli ve esnek altyapılar oluşturmak için söz konusu etkilerin tasarım ve planlama süreçlerinde öncelikli olarak değerlendirilmesi önemlidir.
- ❖ Proje büyüklüklerine bağlı olarak öngörülen ilave maliyetlerin dikkate alınması, gerekli altyapı projeleri için bütçe tahminlerinin doğru bir şekilde oluşturulmasını sağlar. Bu yaklaşım, kaynakların etkin yönetimi ve sürdürülebilir projelerin geliştirilmesi açısından kritik bir öneme sahiptir. Ayrıca, yeni altyapı projelerinin hayata geçirilmesi sürecinde yerel yönetimlerin, yurt içi ve yurt dışındaki düşük faizli ve uzun vadeli kredi imkanlarından yararlanarak ilgili kurum, kuruluş veya ajanslardan finansman anlaşmaları yapması önerilmektedir.
- ❖ İklim değişikliğinin altyapılar üzerindeki etkilerini azaltmaya yönelik önleyici politikalar geliştirilmesi büyük önem taşımaktadır. Bu kapsamda, toplum temelli yaklaşımların benimsenmesi, erken müdahale stratejilerinin (proaktif planlama) hayata geçirilerek teşvik edilmesi için yasal mevzuatların güçlendirilmesi gereklidir.
- ❖ Ülkemizin 2030 yılında, nüfusunun 100 milyona ulaşması ve kişi başına düşen kullanılabilir su miktarının yaklaşık 1120 m³/yıl olması öngörülmektedir. Kişi başına düşen su miktarının 1000 m³'ün altına düşmesi durumunda su kıtlığı riskiyle karşılaşılacağından, bu riskin etkilerini en aza indirmek büyük önem taşımaktadır. Bu doğrultuda, yerel yönetimlerin altyapılarında su verimliliği ve sürdürülebilirliği artırmak amacıyla gelişmiş akıllı su izleme ve yönetim teknolojilerinin kullanılması teşvik edilmelidir.
- ❖ Bu modelleme çalışması, Adana ili özelinde gerçekleştirilmiş olup dinamik ve esnek

bir yapıya sahiptir. Model, farklı veri setleri ve parametreler kullanılarak revize edilebilir ve bu sayede diğer iller veya bölgeler için de uygulanabilir. Bu yaklaşım, yerel koşullara özgü ihtiyaçların karşılanması ve altyapı planlamasının daha etkin bir şekilde yapılmasına olanak tanır.



7. KAYNAKÇA

- Abdi, H., & Williams, L. J. (2010). *Principal component analysis*. Self-Published.
- Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO2 emissions in Turkey with different machine learning algorithms. *Sustainable Production and Consumption*, 29, 141–157.
- Ajbar, A., Hamid; A., & Emadadeen M. (2015). Prediction of municipal water production in touristic Mecca City in Saudi Arabia using neural networks. *Journal of King Saud University - Engineering Sciences*, 27(1), 83–91.
- Alpaydın, E. (2013). *Yapay Öğrenme*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Ansari, A.T, Nigar, N, Faisal, H.M., & Shahzad, M.K. (2024). AI for clean water: efficient water quality prediction leveraging machine learning. *Water Practice and Technology*, 19(5), 1986–1996.
- Antoniou, F., & Aretoulis, G. N. (2018). Comparative analysis of multi-criteria decision making methods in choosing contract type for highway construction in Greece. *International Journal of Management and Decision Making*, 17(1), 1–20.
- ASCE. (2015). American Society of Civil Engineers, *Climate-Resilient Infrastructure: Adaptive Design and Risk Management*. ASCE Publications.
- Aylak, B.L., Oral, O., & Yazıcı, K. (2021). Yapay Zekâ ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı. *El-Cezerî Fen ve Mühendislik Dergisi*, 8 (1), 74-93.
- Ayyub, B.M. (2018). Climate-Resilient Infrastructure Adaptive Design and Risk Management, *ASCE Manuals and Reports on Engineering Practice*, No. 140.
- Babacan, H. T., & Saka, F. (2022). Makine Öğrenmesi ile Aksu Deresi'nde Akış Tahmin Modeli Geliştirilmesi. *Türk Hidrolik Dergisi*, 6(1), 1-11.
- Basheer, M., Nechifor, V., & Calzadilla, A. (2023). Cooperative adaptive management of the Nile River with climate and socio-economic uncertainties. *Nat. Clim. Chang.* 13, 48–57.
- Başakın, E.E., Ekmekçioğlu, Ö., & Özger, M. (2019). Makine öğrenmesi yöntemleri ile kuraklık analizi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 25(8), 985-991.
- Bates, B. C., Kundzewicz, Z. W., Wu, S., & Palutikof, J. P. (2008). Climate Change and Water (IPCC Technical Paper VI). *Intergovernmental Panel on Climate Change*.
- Baumli, K., & Jamasb. T. (2020). Assessing Private Investment in African Renewable Energy Infrastructure: A Multi-Criteria Decision Analysis Approach. *Sustainability*, 12(22), 9425.
- Bayrakçı, H. C., Çiçekdemir, R. S., & Özkahraman, M. (2021). Tarım Arazilerinde Harcanan Su Miktarını Yapay Zekâ Teknikleri Kullanarak Belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(6), 237-250.

- Bayram, S., & Çıtakoğlu, H. (2023). Modeling monthly reference evapotranspiration process in Turkey: Application of machine learning methods. *Environmental Monitoring and Assessment*, Vol.195, No.1.
- Belay, S., Goedert, J., Woldeesenbet, A., & Rokooei, S. (2022). AHP based multi criteria decision analysis of success factors to enhance decision making in infrastructure construction projects. *Cogent Engineering*, 9(1), 2043996.
- Belayneh A., & Adamowski, J. (2013). Drought forecasting using new machine learning methods. *Journal Of Water And Land Development*, 18, 3-12.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2), 281-305.
- Bingöl, K., Akan, A., Örmecioglu, H. T., & Er, A. (2020). Depreme dayanıklı mimari tasarımda yapay zekâ uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 2197-2210.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer..
- Cabello-Solorzano, K., Ortigosa de Araujo, I., Peña, M., Correia, L., & Tallón-Ballesteros, A. J. (2023). The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis. In P. García Bringas et al. (Eds.), *18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023)*, (pp. 344–353).
- Cai, J., Nie, F., Huang, H., & Yin, Y. (2018). Feature selection and machine learning for fault diagnosis of rotating machinery using wireless sensor networks. *IEEE Transactions on Industrial Electronics*, 65(5), 4.
- Calayır, G. N., & Kabak, M. (2021). Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama. *Journal of Turkish Operations Management*, 5(1), 662-675.
- Cengiz, A. E., Aytekin, O., Ozdemir, I., Kusan, H., & Cabuk, A. (2017). A Multi-criteria Decision Model for Construction Material Supplier Selection. *Procedia Engineering*, 196, 294-301.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794).
- Chine, W-H., Wang, T-S., Chen, L., & Kou, C-H. (2009). Artificial Neural Networks for Water Quality Prediction in a Reservoir, *Second International Workshop on Computer Science and Engineering, Qingdao*, 516-519.
- Chinowsky, P. S., Schweikert, A. E., & Strzepek, N. L. (2015). Infrastructure and climate change: a study of impacts and adaptations in Malawi, Mozambique, and Zambia. *Climatic Change* 130, 49–62.

- Çakır, E. & Akar, G. S. (2019). Bütünleşik SWARA–TOPSIS yöntemi ile makine seçimi: Bir üretim işletmesinde uygulama. *Journal of Academic Value Studies*, 3(13), 206-216.
- Daniel, J.E., Elena, C.L., Jorge, R.H., & Juan Carlos, C. J. (2014). A review of application of multi-criteria decision making methods in construction. *Automation in Construction*, 45(2), 151–162.
- Delpla, I., Jung, A. V., Baures, E., Clement, M., & Thomas O. (2009). Impacts of climate change on surface water quality in relation to drinking water production. *Environ Int.* 35(8):1225.
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87.
- Draper, N. R., & Smith, H. (1998). *Applied Regression Analysis*. John Wiley & Sons.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *In Advances in Neural Information Processing Systems*, 155-161.
- DSİ. (2023), *Yıllık Faaliyet Raporu*. Ankara: <https://www.dsi.gov.tr> adresinden alınmıştır.
- Feng, F., Zhang, Y., Chen, Z., Ni, J., Feng, Y., & Xie., Y. (2024). Machine Learning to Access and Ensure Safe Drinking Water Supply: A Systematic Review, ChemRxiv.
- Ellis, J., Fisher, D., Longstaff, T., Pesante, L., & Pethia, R. D. (1997). Report to the President's Commission on critical infrastructure protection. *White House White House Press*, 3-4.
- Elshaboury, N., & Marzouk, M. (2020). Comparing machine learning models for predicting water pipelines condition. *2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)*. IEEE, Giza.
- Elzbieta, B., & Karolina. O, (2020). Multi-criteria analysis of transport infrastructure projects. *Transportation Research Part D: Transport and Environment*, 83(1), 102351.
- Erdoğan, B., (2016). Aydeniz İklim Sınıflandırmasına Göre Türkiye İklimi, T.C. Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü, *Araştırma Dairesi Başkanlığı Klimatoloji Şube Müdürlüğü*, Ankara.
- Frimpong, A.I., Agyekum, A.K., & Amoakwa, A.B. (2023). Toward the attainment of climate-smart PPP infrastructure projects: a critical review and recommendations. *Environment, Development and Sustainability*, 10668.
- Geron, A., (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.
- Guo, W. Y., Liu, T., Dai, F., & P. Xu. (2019). An improved whale optimization algorithm for forecasting water resources demand. *Applied Soft Computing Journal* 86 (Jan): 105925.
- Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *European Journal of Science and Technology*, 8-15.

- Gündüz, M., & Saleh, R. T. (2020). Assessment of delay factors in construction of sport facilities through multi criteria decision making, *Production Planning & Control*, 31:15, 1291-1302.
- Haghighi, A., & Bakhshipour, A. (2015). Deterministic integrated optimization model for sewage collection networks using tabu search. *Journal of Water Resources Planning and Management*, 141 (1), 04014045.
- Hair, J., Ringle, C., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *The Journal of Marketing Theory and Practice*. 19. 139-151.
- Hashad, K., Gu. J., Yang. B., Rong, M., Chen, E., Ma, X., & Zhang, K. (2021). Designing roadside green infrastructure to mitigate traffic-related air pollution using machine learning. *Science of The Total Environment*. 773. 144760.
- Hassan, A., & Tarek, Z. (2008). Infrastructure Management: Integrated AHP/ANN Model to Evaluate Municipal Water Mains Performance. *Journal of Infrastructure Systems*, 14(4), 305–318.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: *Data Mining, Inference, and Prediction*. Springer.
- Henry, A.D., Cabrales, S., Santos, R., & Saldarriaga, J. (2019). A New Multi-Criteria Decision Analysis Methodology for the Selection of New Water Supply Infrastructure. *Water*, 11(4), 805.
- Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
- Hong, Y., QunRen, L., Song, J., Hu, X., Li, X., Zhang, G., Lin, T., & Xue, X. (2017). The role of climate, construction quality, microclimate, and socio-economic conditions on carbon emissions from office buildings in China. *Journal of Cleaner Production*, S0959652617323922.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q. N., & Liu, H. P. (2014). The empirical mode decomposition and the Hilbert transform in signal processing. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 469(2150), 20120203.
- Huntingford, C., Jeffers, E. S., Bonsall, M. B., Christensen, H. M., Lees, T., & Yang, H. (2019). Machine learning and artificial intelligence to aid climate change research and preparedness. *Environmental Research Letters*, 14(12), 124007.
- IPCC. (2014a). *Climate change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and sectoral aspects*, Cambridge, UK: Cambridge Univ. Press.
- IPCC. (2014b). *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Geneva, Switzerland, 151 pp.

- İbrahim, T. Y., & Maghraby, F. A. (2020). Water Demand Forecasting Using Machine Learning and Time Series Algorithms, *International Conference on Emerging Smart Computing and Informatics (ESCI)*, 325-329.
- Jeuland, M. (2010). Economic implications of climate change for infrastructure planning in transboundary water systems: An example from the Blue Nile. *Water Resources Research*, 46(11).
- Jithish, J., & Sankaran, S. (2017). A neuro-fuzzy approach for domestic water usage prediction, *IEEE Region 10 Symposium (TENSYP)*, pp. 1-5.
- Jolliffe, I. T. (2016). *Principal component analysis*. John Wiley & Sons.
- Junqueira, A., Fernández, L.A., Miquel, T., Paul, H., Nasak, J., Daniel, B., Sara, F., Cabeza, M., & Victoria, R.G. (2021). Interactions between Climate Change and Infrastructure Projects in Changing Water Resources: An Ethnobiological Perspective from the Daasanach, Kenya. *Journal of Ethnobiology*. 41. 331-348.
- Karakuş, C. (2023, Temmuz 27). Yapay Zekâ: <https://ckk.com.tr/doc.html> adresinden alınmıştır.
- Kelle, A. C., & Yüce, H. (2022). MQTT Trafikinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması. *Journal of Materials and Mechatronics*, 3(1), 50-62.
- Keršulienė, V., Zavadskas, E. K., & Turskis, Z. (2010). Selection of rational dispute resolution method by applying new step-wise weight assessment ratio analysis (Swara). *Journal of Business Economics and Management*, 11(2), 243–258.
- Kıran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T. (2012). A novel hybrid approach based on particle swarm optimization and ant colony algorithm to forecast energy demand of Turkey. *Energy Conversion Management*, 53:75-83.
- Kirshen, P., Knee K., & Ruth, M. (2008). Climate change and coastal flooding in Metro Boston: Impacts and adaptation strategies, *Climatic Change*, 90: 453–473.
- Korucuk, S. (2018). ÇKKV yöntemleri ile imalat işletmelerinde TZY Performans faktörlerinin önem derecelerinin belirlenmesi ve en ideal rekabet stratejisi seçimi: Ordu ili örneği. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 33(2), 569-593.
- Koçar, H. (2023). Sürdürülebilir Kalkınma Çerçevesinde İklim Değişikliğinin Kırsal Kalkınmaya Etkisi. *Fiscaeconomia*, 7(3), 2250-2272.
- Köseoğlu, B. (2018). *Altyapıyla İlgili Kalkınma Projelerinde İller Bankasının Rolü*, Uzmanlık Tezi, İller Bankası Anonim Şirketi, Ankara.
- Kurt, A., Buldu, B., & Cedimoğlu, I.H. (2020). Xgboost ve rastgele orman algoritmalarının ağ tabanlı saldırı tespitine yönelik performanslarının karşılaştırılması, *International Marmara Sciences Congress Proceedings Book*, c.3, 730-736.

- Kyeongseok, K., Sooji, H., & Hyoungkwan, K. (2017). Using real options for urban infrastructure adaptation under climate change. *Journal of Cleaner Production*, 143(7), 40–50.
- Li, J., Song, S. B., Kang, Y., Wang, H. J., & Wang, X. J. (2021). Prediction of urban domestic water consumption considering uncertainty. *Journal of Water Resources Planning and Management*, 147 (3), 14.
- Li, B., Liu, L., Ma, R., Guo, L., Jiang, J., Li, K., & Li, X. (2024). Deployment of interpretable machine learning in a water treatment device - feasibility exploration of performance enhancement. *Journal of Water Process Engineering*, 104567.
- Mabdeh, A.N., Ajin, R.S., Razavi-Termeh, S.V., Ahmadi, M., & Al-Fugara, A. (2024) Enhancing the Performance of Machine Learning and Deep Learning-Based Flood Susceptibility Models by Integrating Grey Wolf Optimizer (GWO) Algorithm. *Remote Sens.*16, 2595.
- Majeed, R. A., & Breesam, H. K., (2021). Application of SWARA technique to find criteria weights for selecting landfill site in Baghdad governorate. In *IOP Conference Series: Materials Science and Engineering*, 1090, No.1, p. 012045.
- Manyeruke, C., Hamauswa, S., & Mhandara, L. (2013). The effects of climate change and variability on food security in Zimbabwe: A socio-economic and political analysis. *International Journal of Humanities and Social Science*, 3(6), 270–286.
- Metin, H. H., & Kaçtıoğlu, S. (2018). Power Consumption Estimation Using Artificial Neural Networks: The Case of Turkey, *Journal of international trade. logistic and law*, 4(1).
- MGM. (2016). *Aydeniz İklim Sınıflandırmasına göre Türkiye İklimi*, Meteoroloji Genel Müdürlüğü, Ankara.
- MGM. (2021). *Yeni Senaryolarla Türkiye İçin İklim Değişikliği Projeksiyonları*, Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü Araştırma Dairesi Başkanlığı Klimatoloji Şube Müdürlüğü, Ankara.
- Mirzaei, K., Arashpour, M., Asadi, E., Masoumi, H., Bai, Y., & Behnood, A. (2022). 3D point cloud data processing with machine learning for construction and infrastructure applications: a comprehensive review. *Advanced Engineering Informatics*, 51, 101501.
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to Linear Regression Analysis*, John Wiley & Sons.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*, MIT Press.
- Murphy, K., Myors B. (2009) *Statistical power analysis: a simple and general model for traditional and modern hypothesis tests*, 3rd edn.
- Nacar, S. (2014). *Farklı Yapay Zeka Yöntemleriyle Günlük Akarsu Akım Değerlerinin Tahmini-Haldizen Deresi Örneği*, Aksaray Üniversitesi Fen bilimleri Enstitüsü, Aksaray.

- Nicholls, R. J., & Cazenave, A. (2010). Sea-level rise and its impact on coastal zones. *Science*, 328(5985).
- Nie, R.X., Tian, Z.P., Long, R.Y., & Dong, W. (2022). Forecasting household electricity demand with hybrid machine learning-based methods: Effects of residents' psychological preferences and calendar variables. *Expert System with Application*, 206, 117854.
- NSIDC. (2012). *Arctic climatology and meteorology glossary*. National Snow and Ice Data Center.
- Oslakovic, I. S., Maat, H., Hartmann, A., & Dewulf, G. (2012). Climate Change and Infrastructure Performance: Should We Worry About. *Procedia - Social and Behavioral Sciences*, 48(1), 1775–1784.
- Pacchin, E., Alvisi, S., & Franchini, M. (2017). A Short-Term Water Demand Forecasting Model Using a Moving Window on Previously Observed data, *Water*, MDPI.
- Pehlivan, Ö. (2023). *İklim Değişikliğine Uyum Önlemlerinin Maliyetlerinin Tahmini, Türkiye’de İklim Değişikliğine Uyum Eyleminin Güçlendirilmesi Projesi*. Ankara.
- Pidgeon, A., & Dawood, N. (2021). Bridging the gap between theory and practice for adopting meaningful collaborative BIM processes in infrastructure projects, utilising multi-criteria decision making (MCDM), *Established and Emerging Digital Technologies within the Construction Industry*, 783-811.
- Porthin, M., Rosqvist, T., & Perrels, A. (2013). Multi-criteria decision analysis in adaptation decision-making: a flood case study in Finland. *Regulation environmental changes*, 13, 1171–1180.
- Radovic, D., & Stevic, Z. (2018). Evaluation and selection of KPI in transport using SWARA method. *Transport & Logistics: The International Journal*, 8(44), 60-68.
- Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning*. Packt Publishing Ltd.
- Sabir, M., Torre, A., & Magsi, H. (2017). Land-use conflict and socio-economic impacts of infrastructure projects: the case of Diamer Bhasha Dam in Pakistan. *Area Development and Policy*, 2(1), 40–54.
- Safavi, H., & Mohammad A. G. (2017). Optimization of sewer networks using the mixed-integer linear programming, *Urban Water Journal*, 14:5, 452-459.
- Saraswat, M. (2023, 10 Temmuz). Beginners Tutorial on XGBoost and Parameter Tuning R <https://www.hackerearth.com/blog/developers/beginners-tutorial-on-xgboost-parameter-tuning-r>. adresinden alınmıştır.
- SBB. (2023). Strateji ve Bütçe Başkanlığı, *Orta Vadeli Plan (2024-2026)*, Ankara,
- Schölkopf, B., & Smola, A. J. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. MIT press.

- Sevim, A.S. (2018). *Su Kanalizasyon Altyapı Hizmetlerinde Dünya'da Uygulanan Regülasyonların İncelenmesi, Türkiye'de İller Bankasının Denetleyeceği ve Düzenleyeceği Kuruluş Boyutları İle Değerlendirilmesi*, İller Bankası A.Ş., Uzmanlık Tezi, Ankara.
- Shams, M.Y., Elshewey, A.M., & El-kenawy, S.M. (2024). Water quality prediction using machine learning models based on grid search method. *Multimed Tools Appl*, 35307–35334.
- Shevnina, E., Kourzeneva, E., Kovalenko, V., & Vihma, T. (2017). Assessment of extreme flood events in a changing climate for a long-term planning of socio-economic infrastructure in the Russian Arctic, *Hydrology Earth System Science*, 21, 2559–2578,
- Shiklomanov, N. I., Dmitry A., Streletskiy, B., & Swales, A. (2017). Climate Change and Stability of Urban Infrastructure in Russian Permafrost Regions: Prognostic Assessment based on GCM Climate Projections, *Geographical Review*, 107:1, 125-142.
- Shlens, J. (2014). *Tutorial on Principal Component Analysis*, Google Research Mountain View.
- Sooji, Ha., Hongjo, K., Kyeongseok K., Lee, H., & Hyoungkwan K. (2017). Algorithm for Economic Assessment of Infrastructure Adaptation to Climate Change. *Natural Hazards Review*, 18(4), 04017007.
- Sönmez, A.C. (2023, Kasım 27). Yapay Zeka: https://web.itu.edu.tr/~sonmez/lisans/ai/yapay_zeka_problem_cozme.pdf#:~:text=Problem%20çözme%20çoğunlukla%20düşünen%20varlıkların,çözüm%20ararken%20yapılan%20zihin%20aktivitesidir adresinden alınmıştır.
- Şahinarslan, F.V. (2019). *Makine öğrenmesi algoritmaları ile nüfus tahmini: Türkiye örneği*, Yüksek Lisans tezi, İşletme Lisansüstü Programı, Sosyal Bilimler Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.
- TBMM. (2021). *Küresel İklim Değişikliğinin Etkilerinin En Aza İndirilmesi, Kuraklıkla Mücadele ve Su Kaynaklarının Verimli Kullanılması İçin Alınması Gereken Tedbirlerin Belirlenmesi Amacıyla Kurulan Meclis Araştırması Komisyonu Raporu*, Türkiye Büyük Millet Meclisi, Sıra Sayısı: 300.
- Ter-Akopov, A.A., & Bezverbny, V.A. (2019). Development of Transport Systems in Siberia and the Far East of Russia: SocioEconomic and Natural-Climatic Factors. *Journal of Environmental Management and Tourism*, 5(37): 1074 -1083.
- Tibshirani, R. (1996). Regression shrinkage and selection via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267-288.
- Tiwari, M. K., Adamowski, A., & Damowski, K. (2016). Water demand forecasting using extreme learning Machines. *Journal of water and land development*, 28 (3): 37–52.
- Tsyganov, V. (2020). *Infrastructure Development Management Platform in Extreme Climate*. 13th International Conference Management of large-scale system development.

- Turgut, A., Temir, A., Aksoy, A., & Özsoy, K. (2020). Yapay zekâ yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması, *International Journal of 3D Printing Technologies and Digital Industry*, c.3, s3, 244-253.
- TÜİK. (2016, Ocak 13). <https://data.tuik.gov.tr/Bulten/Index?p=Nufus-Projeksiyonlari-2018-2080-30567> adresinden alınmıştır.
- UNFCCC. (1992). *Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi United Nations Framework Convention on Climate Change*, md.2.
- URL-1. (2022, Ocak 8). İnternet: Etymonline. Definition of Infrastructure. <http://www.webcitation.org/query?url=https%3A%2F%2Fwww.etymonline.com%2Fword%2Finfrastructure&date=2018-03-01> adresinden alınmıştır.
- URL-2. (2022, Ocak 8). İnternet: The American Heritage Dictionary. Definition of Infrastructure.: <http://www.webcitation.org/query?url=https%3A%2F%2Fahdictionary.com%2Fword%2Fsearch.html%3Fq%3Dinfrastructure&date=2018-03-01> adresinden alınmıştır.
- URL-3. (2022, Ocak 8). İnternet: United Nations. Sustainable Development Goals.: <https://www.webcitation.org/query?url=http%3A%2F%2Fwww.jgjhjg%2Fsustainabledevelopmentgoalsdevelsopmense%2F%2F12%2FF43521&date=2018-03-01> adresinden alınmıştır.
- URL-4. (2022, Ocak 8). İnternet: Görüntü İşlemede Yapay Zekâ Endüstride Geleceği Şekillendiren Teknoloji.: <https://pulsar.com.tr/robotik/goruntu-islemede-yapay-zeka-endustride-gelecegi-sekillendiren-teknoloji/> adresinden alınmıştır.
- URL-5. (2021, Ekim 8). <https://www.adana-aski.gov.tr/images/2020faaliyet.pdf> adresinden alınmıştır.
- URL-6. (2021, Ekim 8). <https://www.ilbank.gov.tr/storage/uploads/reports/ilbank-2020-fr.pdf> adresinden alınmıştır.
- URL-7. (2021, Ekim 8). <https://ekap.kik.gov.tr/EKAP/Ortak/IhaleArama/index.html> adresinden alınmıştır.
- URL-8. (2021, Ekim 8). <https://ekap.kik.gov.tr/ekap/ortak/ksp/kspihalearama.aspx> adresinden alınmıştır.
- URL-9. (2021, Ekim 8). <https://mevbis.mgm.gov.tr/mevbis/ui/index.html> adresinden alınmıştır.
- URL-10. (2021, Ekim 8). <https://data.tuik.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuclari-2020> adresinden alınmıştır.
- URL-11. (2021, Ekim 8). <https://data.tuik.gov.tr/Bulten/Index?p=Il-Bazinda-Gayrisafi-Yurt-Ici-Hasila-2020-37188> adresinden alınmıştır.

- URL-12. (2021, Ekim 8). <https://data.tuik.gov.tr/Bulten/Index?p=Yapi-Izin-Istatistikleri-Ocak-Aralik,-2020-37460> adresinden alınmıştır.
- URL-13. (2021, Ekim 8). <https://data.tuik.gov.tr/Kategori/GetKategori?p=Tarim-111> adresinden alınmıştır.
- Uzlu, E., Kankal, M., Akpınar, A., & Dede, T. (2014). Estimates of energy consumption in Turkey using neural networks with the teaching–learning-based optimization algorithm, *Energy, Elsevier*, 75, 295-303.
- Vapnik, V. (1996). *The Nature of Statistical Learning Theory*, Second Ed., 1, New York.
- Vapnik, V. (2000). *The Nature of Statistical Learning Theory*, Second Ed., 1, New York.
- Wang, M., Liu, M., Zhang, D-Q., Zhang, Y., Su, J., Zhou, S., & Bakhshipour, A. (2023). Assessing hydrological performance for optimized integrated grey-green infrastructure in response to climate change based on shared socio-economic pathways. *Sustainable Cities and Society*, 91. 104436.
- Weber, B., Alfen, H. W., & Staub-Bisang, M. (2016). *Infrastructure as an asset class: Investment strategy, sustainability, project finance and PPP*. John wiley & sons. (11-12).
- Weisberg, S. (2005). *Applied Linear Regression*. John Wiley & Sons.
- Wilbanks, T.J., & Fernandes, S. J. (2018). Climate Change and infrastruCture, urban systems, and Vulnerabilities, Technical Report for the U S Department of Energy in Support of the National Climate Assessment, *Island Press*, United States of America.
- World Bank. (2022). *Türkiye CCDD Background Note 3: Agriculture, Fisheries, and Water*.
- Xia, Li., Guojin, L., & Xinhua, Z. (2011). *State Estimation of Municipal Water Supply Network Based on BP Neural Network and Genetic Algorithm*, IEEE information Services (ICICIS)-Hong Kong 2011 International Conference on Internet Computing and Information Services, 403–406.
- Yan, R., Peng, X., & Li, Z. (2007). Vibration signal monitoring and fault diagnosis of a rotor system based on PCA and KPCA. *Mechanical Systems and Signal Processing*, 21(2), 795-804.
- Yılmaz, E., & Çiçek, İ., (2016). Türkiye Thornthwaite İklim Sınıflandırması, *Journal of Human Science*, C.10, s. 3.
- Yun, J., Ryu, K. & Ham, Suyun. (2022). Spatial analysis leveraging machine learning and GIS of socio-geographic factors affecting cost overrun occurrence in roadway projects. *Automation in Construction*, 133. 104007.
- Yurtsever, M., & Emeç, M. (2023). Potable Water Quality Prediction Using Artificial Intelligence and Machine Learning Algorithms for Better Sustainability. *Ege Academic Review*, 23(2), 265-278.

- Zavadskas, E. K., Stević, Ž., Tanackov, I., & Prentkovskis, O. (2018). A Novel Multicriteria Approach–Rough Step-Wise Weight Assessment Ratio Analysis Method (R-SWARA) and its application in logistics. *Studies in Informatics and Control*, 27(1), 97-106.
- Zhang, Y., Chouinard L., Power G.J., Conciatori D., Sasai, K. & Abdoul S. B. (2023). Multi-objective optimization for the sustainability of infrastructure projects under the influence of climate change, *Sustainable and Resilient Infrastructure*, 8:5, 492-513.
- Zhou, X., Zhang, S. X., Xie, M., Yang, Y. B., & Li, L. (2014). Application of BP Neutral Networks to Water Demand Prediction of Shenyang City Based on Principle Component Analysis, *2014 7th International Conference on Intelligent Computation Technology and Automation*, 912-915.



8. EKLER

EK-1. Adana iline ait altyapı tahmin modellerinde kullanılan sosyo-ekonomik veriler

[illegible]

EK-2. Adana iline ait altyapı tahmin modellerinde kullanılan iklimsel (meteorolojik) veriler

YIL - Ay	ORTALAMA SICAKLIK (°C)	TOPLAM BUHARLAŞMA (mm)	TOPLAM YAĞIŞ (mm=kg/m ²)	TOPLAM GÜNEŞLENME SÜRESİ (Saat)	ORTALAMA NISPI NEM (%)	ORTALAMA RÜZGÂR HIZI (m/sn)	ORTALAMA ATMOSFER BASINCI (hPa)
2006-1	9,1	37,8	36,3	136	62,9	1,6	1015,1
2006-2	10,7	37,6	131,6	95,6	72,9	1,4	1012,9
2006-3	14,1	67,1	46,2	157,3	76,3	1,3	1011
2006-4	18,4	94,9	9,3	128,5	71,2	1,2	1008,1
2006-5	22,1	179,3	19,8	321,3	69	1,1	1009,1
2006-6	25,7	212,9	4,5	318,6	73,2	1,2	1006,8
2006-7	27,9	212,4	41,3	311,5	78,8	1,3	1002,9
2006-8	29,1	225,9	0	295,8	79	1,1	1002,8
2006-9	26,1	178,6	37,4	262,6	67,6	1	1007,3
2006-10	21,6	101,4	156,3	207,6	70,8	0,9	1010,1
2006-11	13,8	56	91,5	194,8	65,1	0,9	1016,3
2006-12	9,6	55,7	0	215,5	57,9	1,2	1021,1
2007-1	9	47,2	34,1	191,2	62,7	1,1	1020,9
2007-2	11,2	48,1	127	139,4	72	1,2	1012,9
2007-3	14,1	90,9	75,7	199	69,8	1,2	1011,3
2007-4	16,5	131,6	115,4	229,8	63,4	1,3	1008,9
2007-5	23,4	172,6	32	244,3	69,8	1,1	1006,3
2007-6	26,5	227,2	24,8	293	69,1	1	1003,3
2007-7	29,6	258,5	1,2	350,9	68,1	1,3	1001,2
2007-8	29,5	223,4	0	297,9	72,1	1,1	1001,9
2007-9	26,5	167,7	0,5	276,6	65,8	0,9	1006,2
2007-10	23,3	131,3	18,2	214,6	61,8	1	1011,5
2007-11	15,6	63,6	83	153,8	68,3	0,9	1013,1
2007-12	10,3	50,8	125,4	154,1	69,7	1,3	1016,5
2008-1	7,4	51,1	32,2	186,3	58,5	1,5	1016,9
2008-2	9,6	65,5	55,1	191,8	61,3	1,4	1018,5
2008-3	16,3	107,2	25,6	166,1	66,1	1,1	1009,6
2008-4	19,2	140,8	18,5	193,9	67,7	1	1009,3
2008-5	21	182	19,2	271,2	71,9	1	0
2008-6	26,6	273,9	4,8	335,1	72,9	1,1	1004
2008-7	29	289	0	349,3	79,9	1,1	1001,1
2008-8	30	258,5	9,6	269,1	78,4	0,9	1000,6
2008-9	26,7	187,4	16,8	227,9	71,3	0,9	1005,2
2008-10	22,3	132,8	31,5	226	65,8	0,7	1011,3
2008-11	16,8	80,4	45,3	163,5	68,2	0,8	1014,4
2008-12	9,8	54,2	58,2	163,2	67	1,1	1016,7
2009-1	9,3	54,9	145,7	114,3	71,1	1,3	1017
2009-2	10,7	44	130,1	100,8	79,7	1	1010,4
2009-3	12,6	88,1	135,5	175,2	71,1	1,2	1010,4
2009-4	17,1	131	34,3	235,6	68,8	0,9	1008,8
2009-5	21,9	199,4	28,7	309,1	64,2	1,2	1009,4
2009-6	26,9	238,4	0	325	69	1,2	1006,5
2009-7	28,3	264,5	22,7	330,6	79,4	1,2	1001,4
2009-8	29,1	257,5	0	321,2	72,9	1,1	1003,2
2009-9	25,3	189,8	33,5	261,6	66,6	1,2	1007,1
2009-10	23,5	161,5	15,2	234,4	56,3	1,2	1010,4
2009-11	15,1	83,4	130,1	157,2	71,6	1,1	1014
2009-12	12,7	47,3	131,8	70	74,9	1,3	1013,2
2010-1	11,20	42,6	113,90	87,2	72,20	1,9	1013,8
2010-2	12,3	72,6	67,6	87,6	67,3	2	1010,9
2010-3	15,6	108,4	14,8	164,8	64	1,8	1012,1
2010-4	18,4	146,2	89,3	245,1	63,5	1,7	1010
2010-5	22,2	179,4	56,6	280,2	67	1,5	1007,2
2010-6	25,9	217	1,4	323,2	64,9	1,8	1003,5
2010-7	28,5	211,4	0,7	312,1	67,4	1,9	1001,8
2010-8	30,8	244,8	0	317,2	63,5	1,7	1001,4

EK-2'nin devamı

2010-9	28	200,7	1,7	301,7	62,5	1,6	1004,6
2010-10	22,4	107,3	30,8	217,1	60,9	1,5	1009,8
2010-11	18,4	101,2	0	212,2	56,2	1,3	1015
2010-12	13	64,7	194,5	18,3	70,6	1,7	1013,8
2011-1	10,4	54,8	76,5	153,7	64,6	1,7	1014,4
2011-2	11,3	58,9	92,4	180,8	61,4	1,8	1010,7
2011-3	13,5	78,4	107	239,1	65,5	1,5	1014,6
2011-4	16,6	92,9	78,3	195,2	67,4	1,8	1007,4
2011-5	21	148	105,6	283,6	66,5	1,6	1008,9
2011-6	25,4	207,9	49,4	308,8	67,6	1,8	1004,9
2011-7	28,5	231,3	0	313,7	67,7	1,7	1002,4
2011-8	29,3	219,6	0	331,1	63,9	1,8	1002,2
2011-9	27	154,3	4,1	296,7	62,1	1,6	1005,6
2011-10	21,4	126,5	5,8	259,7	48,1	1,7	1011,4
2011-11	12,9	68,8	44,1	177,4	54,3	1,5	1015
2011-12	10,1	37,3	156,4	171,6	67,9	1,4	1017,7
2012-1	8,5	26,6	262	118,7	73,3	1,8	1013,2
2012-2	9,1	54,2	122,9	158,2	57,7	1,7	1012,7
2012-3	11,3	99,3	57,9	121,1	54	1,8	1014,4
2012-4	18,7	109	21,4	196,2	64,6	1,6	1009,5
2012-5	21,6	141,5	79,9	214	68,9	1,6	1008,2
2012-6	27	210,5	17,1	224,4	62,8	1,6	1004,9
2012-7	29,2	242,8	14	183,7	61,2	1,8	1001,5
2012-8	29,8	248	0,1	267,4	58,7	1,7	1002,7
2012-9	27,6	176,6	0	260,5	60,4	1,5	1006,8
2012-10	22,5	97,9	63,4	168	61,5	1,3	1010,8
2012-11	17	46,6	128,3	155	68,3	1,2	1013,1
2012-12	11,1	25,1	298,4	94,2	77,1	1,5	1013,2
2013-1	9,8	29,6	46,2	100,7	66,7	1,6	1013,5
2013-2	12,5	49,2	55,7	130,3	71,8	1,6	1013,6
2013-3	14,8	92,7	54,3	183,7	56,7	1,9	1010,7
2013-4	18,6	92,5	54	180,8	67	1,4	1009,5
2013-5	23,6	156,8	61,5	251,9	65,7	1,5	1007,5
2013-6	26,1	202,8	0,9	289,8	61,3	1,8	1005,1
2013-7	28,6	237	0	307,3	64,3	1,8	1002,2
2013-8	29,2	207,2	19,8	313,3	67,9	1,7	1002,8
2013-9	25,9	152,7	31,9	227,3	61,8	1,5	1006,7
2013-10	19,9	118,1	40,1	232,7	50,4	1,5	1012,4
2013-11	17,7	64,1	6,1	151,9	62,7	1,2	1013
2013-12	10,6	64,8	21,5	113,6	47,9	1,8	1017,6
2014-1	11,6	41	35,7	133,9	70,5	1,2	1016,5
2014-2	12,3	57,4	36,5	174,1	63,3	1,4	1015,7
2014-3	15,6	100,1	47,7	193,3	63,2	1,7	1010,8
2014-4	19	137,3	22,1	217	65,5	1,7	1010,6
2014-5	21,9	157	34,9	196,5	67,8	1,5	1009,3
2014-6	25,6	178,8	89,8	275,1	68	1,7	1006,3
2014-7	28,4	219,7	3,5	264	70,6	1,9	1003,6
2014-8	29,3	199,4	0,2	248,4	71,3	1,7	1003,4
2014-9	26,3	145,1	95,4	230,4	64,5	1,7	1006,6
2014-10	21,3	104,3	54,9	203,6	65	1,4	1011,7
2014-11	15,1	58	66,5	163,8	60,2	1,2	1015
2014-12	13,4	32,3	106,4	121,5	73,7	1,4	1016,9
2015-1	9,4	37,9	107,5	123,5	69,2	1,5	1016
2015-2	11,2	35,5	122	53,9	72	1,7	1011
2015-3	14,6	80	135,1	182,9	64,9	1,7	1013,4
2015-4	16,9	106,5	21,5	191,1	61,2	1,7	1010,9
2015-5	22,5	148,9	65,7	240,7	65	1,5	1008,9
2015-6	25	171,4	4,8	250,4	69,6	1,8	1006,3
2015-7	28,4	206,7	0,4	291,4	69,8	1,7	1004,1
2015-8	30	204,9	10,9	288,8	63,4	1,6	1004,9

EK-2'nin devamı

2015-9	28,4	167,1	130	246,1	64,8	1,3	1007,8
2015-10	23,5	99	32,1	208,2	63,8	1,2	1010,7
2015-11	17,5	77,4	10,5	188,4	50,1	1,2	1014,8
2015-12	11,8	55	0,6	159,4	53,1	1,4	1020
2016-1	8,7	33,9	138,4	107,6	61,8	1,6	1016,2
2016-2	14	62,8	83,1	173,6	68,4	1,3	1016,6
2016-3	15,7	91,9	67,1	190,8	61,5	1,6	1010,5
2016-4	20,5	142,7	36,6	237,9	59,2	1,4	1009,6
2016-5	21,6	141,9	87,9	220	69,3	1,6	1008,3
2016-6	27,1	195,4	45,6	294,5	66,1	1,6	1005,6
2016-7	29,5	231,8	0,2	310,5	67,5	1,8	1002,6
2016-8	29,9	205,3	8,2	272,8	69	1,7	1004,4
2016-9	26,3	148,5	39,8	257,6	61,8	1,5	1008,1
2016-10	23,1	112,7	0	229,2	56,4	1,2	1011,3
2016-11	15,6	77,9	11,9	183,6	52,2	1,4	1016,6
2016-12	9	32,6	216,3	99,2	64,8	1,6	1016,7
2017-1	8,7	32,7	52	123,3	62,1	1,6	1016,6
2017-2	10,7	61,5	0,8	193,3	50,7	1,6	1018,8
2017-3	15,2	82,3	65,4	170,2	62,8	1,4	1010,8
2017-4	18,5	128,5	65,9	228,3	60,7	1,6	1011,9
2017-5	21,8	143,7	45,9	219,6	68,8	1,5	1008,8
2017-6	26,2	175,2	17,3	295,7	69,1	1,6	1006,5
2017-7	30,4	246,3	0	336,4	64,4	1,7	1002,5
2017-8	29,9	205,6	0	268,1	67,5	1,6	1003,8
2017-9	27,8	164,6	11,2	258,3	66,1	1,3	1007,7
2017-10	22,2	111	44,3	230,2	54,1	1,2	1010,8
2017-11	15,9	67,6	122,7	162,5	66,3	1,3	1014,3
2017-12	12,6	39,5	33	157	74,4	1,2	1017,2
2018-1	10,5	31,6	324,3	107,9	76,2	1,3	1014,1
2018-2	13,5	46,5	64,8	126,7	71,3	1,3	1012,3
2018-3	16,8	75,8	40,1	179,4	71,6	1,3	1010,2
2018-4	20,1	109,8	35	237,9	61,2	1,2	1009,7
2018-5	24,4	154,9	29,5	231,3	62,8	1,4	1006,9
2018-6	26,4	176,7	25,6	250	70,2	1,5	1005
2018-7	29,1	231,8	0	290,7	69,8	1,8	1002,1
2018-8	29,6	190,1	0	286,1	68,8	1,6	1003,5
2018-9	27,9	165,2	1,3	259,9	63,6	1,3	1007,5
2018-10	22,9	103,2	73,7	198,7	58,6	1,3	1011,7
2018-11	16,9	64,2	22,5	136,6	64,1	1,1	1014,4
2018-12	12,2	42,7	308	81,4	75,3	1,3	1013,8
2019-1	9,8	49,1	249	141,6	71	1,5	1012,5
2019-2	11,8	51,3	88,6	152,4	72,1	1,4	1014,6
2019-3	13,8	87,5	96,5	191,6	69	1,4	1011,4
2019-4	17	101,4	71,1	221,9	67	1,4	1010,7
2019-5	24,1	185,4	2,6	310,2	57,6	1,6	1008,9
2019-6	27,1	190,9	21,3	298,2	68,7	1,6	1005,9
2019-7	28,4	196,7	30,9	319,3	68,8	1,7	1002,6
2019-8	29,6	211,4	0	306,4	68	1,6	1003,5
2019-9	27,3	156,2	4	306,1	62,1	1,5	1007
2019-10	24,2	115,5	21,1	245,1	61,6	1,4	1010,9
2019-11	18,1	78,8	22,7	201,5	56,7	1,4	1014,4
2020-1	12,2	36,9	150,2	125,9	67,9	1,3	1013,5
2020-2	9,9	46,3	98,4	131,4	67,2	1,5	1016
2020-3	10,4	42,1	52,3	126,5	69,1	1,5	1015,5
2020-4	15,3	81,5	24,3	168,5	70,2	1,5	1010,1
2020-5	18,3	116	73,6	208,2	61	1,4	1009,5
2020-6	23,3	168,3	43,5	275,9	70,9	1,6	1009,1
2020-7	25	171,3	0	266,3	74,3	1,6	1005,8
2020-8	29,4	213,3	2	302,1	65,9	1,7	1001,9
2020-9	29,7	206,5	0	126,4	68,3	1,6	1001,6

EK-2'nin devamı

2020-10	29,4	164,8	0	271,2	68	1,3	1006,6
2020-11	25,1	117,1	52,6	243,2	59,5	1,3	1011,6
2020-12	17	59,2	31	162,1	63,9	1,3	1014
2021-1	11,7	49,8	131,4	122,8	63,7	1,2	1011,4
2021-2	13	73,9	23,9	185,5	61,4	1,2	1010,7
2021-4	18,3	82,4	44	209,6	68,7	1,2	1013,5
2021-5	23,9	107,8	4,1	288,4	64,9	1,6	1008,9
2021-6	25,9	154,9	0,4	289,8	67,2	1,8	1006,3
2021-7	30	211,2	15,8	278,1	68	1,7	1003,3
2021-8	30,6	237,9	1,2	271,4	64,4	1,5	1016,6
2021-9	27,3	227,7	9,9	252,5	58,8	1,3	1016,7
2021-10	22,6	183,2	2,3	1,1	49,2	1,2	1016,6
2021-11	17,4	152,7	50,4	15,7	66,5	1,5	1010
2021-12	11,9	108,2	226	116,9	66,7	1,3	1007,2
2022-1	8,9	78,1	239	102,1	66,2	1,2	1003,5
2022-2	12,4	33,8	89,2	116,1	71,8	1,6	1001,8
2022-3	10,9	49,1	106,7	1,6	58,5	1,4	1001,4
2022-4	20	93,2	4	228,3	57,2	1,3	1016,6
2022-5	22,8	111,3	9	255,9	61,8	1,2	1016,7
2022-6	26,6	151,1	31,9	241,9	72,8	1,6	1016,6
2022-7	29,4	190,9	0	318	65,9	1,6	1018,8
2022-8	29,5	226,6	1,2	256	71,4	1,4	1010,8
2022-9	27,3	214,9	2,3	279,5	64,2	1,6	1011,9
2022-10	23,4	160,4	11,3	207,5	58,4	1,6	1008,8
2022-11	17,8	104,8	118,5	164,3	68	1,2	1016,7
2022-12	13,9	61,5	38	160,1	73,3	1,2	1016,3
2023-2	10,2	36,8	59,9	210,9	55,6	1,2	1007,3
2023-3	15,8	53,7	86,5	193,5	71,3	1,6	1010,1
2023-4	17,9	75,9	128,4	202,8	68,6	1,8	1016,3
2023-5	22,7	112,8	46,8	280,6	62,3	1,7	1002,8
2023-6	25,9	148,4	23,2	288	70,8	1,5	1007,3
2023-7	30,2	181,3	0	337,7	62	1,3	1010,1
2023-8	30,6	215,6	9,2	312,9	72,8	1,2	1016,3
2023-9	27,8	205,1	3,5	295,8	66,3	1,5	1021,1
2023-10	23,7	168,2	57,4	252,6	63,9	1,5	1016,7
2023-11	18,5	121,4	90,3	196,7	64,80	1,3	1011,6
2023-12	14	81,1	52,8	163	77,20	1,2	1016,3

EK-3. Anket Formu

KTÜ
İnşaat Mühendisliği Bölümü

**Sayın Katılımcı;**

Bu anket, Karadeniz Teknik Üniversitesi Fen Bilimler Enstitüsü İnşaat Mühendisliği Anabilim Dalı “Yapay Zekâ Kullanarak İklim Değişikliği ve Sosyo-Ekonomik Parametrelerin Altyapı Projeleri Üzerindeki Etkisinin İncelenmesi: Adana Şehir Örneği” konulu doktora tezine veri toplama amacıyla düzenlenmiştir. Elde edilen veriler sadece bilimsel amaçlı olarak kullanılacak olup üçüncü şahıslarla asla paylaşılmayacaktır.

Anketin doğru ve samimi cevaplanması, araştırmanın geçerliliği ve doğru sonuçlara ulaşılması açısından önem taşımaktadır. Değerli zamanınızı ayırdığınız için şimdiden teşekkür eder çalışmalarınızda başarılar dileriz.

Not: Altyapı projesine esas debi tahmini hesaplamalarında etkili olan aşağıda verilen 13 parametreyi SWARA analizi kapsamında değerlendirilmek üzere kendinize göre önem sıralamasına koyunuz. Ayrıca, yaptığınız sıralamadaki her bir parametrenin (ilk parametre hariç) kendinden bir sonraki parametreden % kaç daha fazla önemli olduğunu belirtiniz.

Tez Danışmanı	Tez Öğrencisi
Prof. Dr. Tayfun DEDE	Yük. İnş. Müh. Yusuf BALTACI

Altyapı Karar Vericisi			
	Parametreler (Şehir Bazında)	Önem Sırası	Kendinden sonraki parametreden % kaç daha fazla önemli
1	Abone Sayısı		
2	Atmosfer Basıncı		
3	Buharlaşma Miktarı		
4	Güneşlenme Süresi		
5	Nem Miktarı		
6	Rüzgâr Hızı		
7	Sıcaklık		
8	Şehrin Gelişmişliği		
9	Tarımsal Alan		
10	Verilen İnşaat Ruhsat Sayısı		
11	Verilen İskân Belgesi Sayısı		
12	Yağış Miktarı		
13	Yerleşim Nüfusu		

ÖZGEÇMİŞ

Yusuf BALTACI, ilköğrenimini Hayrat Merkez İlköğretim Okulunda tamamladıktan sonra, 2008 yılında Affan Kitapçıoğlu Lisesinden mezun olmuştur. 2009 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümünde lisans eğitimine başlamış ve 2013 yılında mezun olmuştur. Aynı yıl, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yapım Yönetimi kürsüsünde tezli yüksek lisans eğitimine başlamış, 2015 yılında tezini başarıyla tamamlayarak mezun olmuştur. Akademik kariyerine 2018 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yapım Yönetimi kürsüsünde doktora programıyla devam etmiştir. Mesleki kariyerine, 2015 yılında T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı-İller Bankası Adana Bölge Müdürlüğünde teknik uzman yardımcısı olarak göreve başlamış, 2019 yılında uzmanlık tezi ve sınavını başarıyla tamamlayarak teknik uzman pozisyonuna atanmıştır. Halen bu görevi sürdürmektedir.