

T.C.
ADİYAMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

ERZURUM AZİZİYE İLÇESİ PM₁₀ KONSANTRASYONLARININ
YAPAY SİNİR AĞLARI İLE MODELLENMESİ

YÜKSEK LİSANS TEZİ

HİKMET POLAT

DANIŞMAN
DOÇ. DR. FATİH TUFANER

ADİYAMAN, 2025

ÖZET

ERZURUM AZİZİYE İLÇESİ PM₁₀ KONSANTRASYONLARININ YAPAY SİNİR AĞLARI İLE MODELLENMESİ

Hikmet POLAT

Çevre Mühendisliği Anabilim Dalı

Adıyaman Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ekim/2025, Sayfa:68

Danışman: Doç. Dr. Fatih TUFANER

Bu çalışmada, 2024 yılına ait hava kalitesi ve meteorolojik veriler kullanılarak Erzurum ili Aziziye ilçesinde PM₁₀ konsantrasyonunun modellenmesi amaçlanmıştır. Veriler, Aziziye Hava Kalitesi İzleme ve Erzurum Meteoroloji İstasyonlarından günlük ortalamalar şeklinde alınmıştır. Çalışmanın temel hedefi, doğrudan ölçülmesi özel cihaz ve altyapı gerektiren PM₁₀ değerlerinin, meteorolojik ve gaz kirletici parametreler aracılığıyla yüksek doğrulukla tahmin edilebilmesidir. Bu kapsamda, Yapay Sinir Ağı (YSA) algoritmaları ve DataFit yazılımı kullanılarak doğrusal ve doğrusal olmayan regresyon modelleri oluşturulmuş; yöntemlerin tahmin performansları istatistiksel ölçütlerle karşılaştırılmıştır. Parametre seçiminde t-ratio, Pearson korelasyon katsayısı ve Temel Bileşen Analizi (TBA) yöntemlerinden yararlanılmış; nihai değişkenler çevresel bilgi, literatür ve modelleme deneyimiyle belirlenmiştir. YSA modelleri eğitim, doğrulama ve test kümeleri üzerinden değerlendirilmiş; en başarılı modelde test verisi için $R^2 = 0.9607$ ve $MSE = 0.00117$ elde edilmiştir. DataFit ile geliştirilen çoklu doğrusal regresyon modelinde ise $R^2 = 0.89$ bulunmuştur. Sonuçlar, her iki modelin de yüksek doğruluk ve istatistiksel güvenilirlik gösterdiğini ortaya koymuştur. Ayrıca, geliştirilen model yapılarının uygun şekilde uyarlanması hâlinde, bölgesel hava kalitesi yönetim süreçlerine destek sağlayabilecek potansiyele sahip olduğu değerlendirilmektedir. Bu yönüyle çalışma, yalnızca PM₁₀ tahmini için değil, benzer çevresel modelleme araştırmaları açısından da yöntemsel ve bölgesel düzeyde anlamlı bir katkı sunmaktadır.

Anahtar Kelimeler: PM₁₀ konsantrasyonu; Yapay sinir ağı (YSA); DataFit; Hava kalitesi modelleme; Tahmin doğruluğu.

ABSTRACT

MODELING OF PM₁₀ CONCENTRATIONS IN ERZURUM'S AZIZIYE DISTRICT USING ARTIFICIAL NEURAL NETWORKS

Hikmet POLAT

Department of Environmental Engineering

Adiyaman University, Graduate Education Institute, October/2025, Page:68

Supervisor: Assoc. Prof. Dr. Fatih TUFANER

In this study, it was aimed to model the PM₁₀ concentration in the Aziziye district of Erzurum province using air quality and meteorological data from the year 2024. The data were obtained as daily averages from the Aziziye Air Quality Monitoring and Erzurum Meteorology Stations. The main objective of the study is to develop highly accurate models that can estimate PM₁₀ concentrations, which require specialized instruments and infrastructure for direct measurement, through meteorological and gaseous pollutant parameters. In this context, Artificial Neural Network (ANN) algorithms and DataFit software were used to construct linear and nonlinear regression models, and the predictive performances of both methods were compared using statistical indicators. During the parameter selection process, t-ratio analysis, Pearson correlation coefficient, and Principal Component Analysis (PCA) methods were utilized; final variables were determined based on environmental knowledge, literature, and modeling experience. ANN models were evaluated through training, validation, and testing datasets, and the best-performing model yielded $R^2 = 0.9607$ and $MSE = 0.00117$ for the test data. The multiple linear regression model developed with DataFit achieved an R^2 value of 0.89. The results demonstrated that both models provided high accuracy and statistical reliability. Furthermore, it was evaluated that the developed model structures have the potential to support regional air quality management processes when appropriately adapted. In this respect, the study provides not only a reliable PM₁₀ prediction approach but also a methodological and regional contribution to similar environmental modeling research.

Keywords: PM₁₀ concentration; Artificial neural network (ANN); DataFit; air quality modeling; Prediction accuracy

TEŞEKKÜR

Tüm akademik sürecim ve tez çalışmam boyunca bilgi ve deneyimleriyle gelişimime katkı sağlayan, yönlendirmeleriyle çalışmamın şekillenmesinde önemli rol oynayan değerli danışmanım Doç. Dr. Fatih TUFANER'e teşekkür ederim. Sağladığı yapıcı katkılar ve akademik rehberliği, sadece bu tez çalışmasının değil, tüm akademik donanımımın gelişmesinde de etkili olmuştur.

Akademik eğitimim süresince bilgi ve deneyiminden faydalandığım Prof. Dr. Yavuz DEMİRCİ'ye; tüm hocalarıma tez savunma sürecinde yapıcı değerlendirmeleriyle çalışmamın gelişimine değerli katkılar sunan Doç. Dr. İsmail DABANLI'ya teşekkür ederim.

Ayrıca, bu süreçte gösterdikleri anlayış ve manevi destekle her zaman yanımda olan aileme içten teşekkürlerimi sunarım.

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Adıyaman Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

(İmza)

Hikmet POLAT

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI.....	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR.....	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	vi
İÇİNDEKİLER.....	vii
TABLolar DİZİNİ.....	xii
ŞEKİLLER DİZİNİ.....	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ.....	1
2. HAVA KİRLİLİĞİ VE KİRLETİCİLER.....	6
2.1.Hava Kirliliği ve Kirleticiler	6
2.2.Hava Kirliliği Tanımı.....	6
2.3.Kirletici Türleri.....	6
2.3.1.Aerosol türleri ve PM ₁₀ bağlamında tanecik büyüklükleri.....	7
2.4.Başlıca Gaz Kirleticiler	8
2.5.Erzurum’da Hava Kirliliği	8
2.6.Meteorolojik Faktörlerin Etkisi.....	9
2.7.Yapay Sinir Ağları.....	9
2.7.1.Tanım, tarihçe ve gelişim süreci	9
2.7.2.Yapay sinir ağlarının özellikleri	10
2.7.3.Yapay sinir ağlarının avantaj ve dezavantajları.....	10
2.8.Biyolojik Nöron ve Yapay Nöron Modelleri	11
2.8.1.Ağırlıklar ($W_1, W_2, \dots, W_n$)	13
2.8.3.Transfer fonksiyonu (Aktivasyon fonksiyonu)	13
2.8.4.Sigmoid fonksiyon	14

2.8.5.Hiperbolik fanjant (Tanh) fonksiyonu.....	14
2.8.6.Doğrusal fonksiyon (Linear).....	14
2.8.7.Sinüzoidal fonksiyon (Sine)	15
2.9.Çıktı.....	15
2.10.Değerlendirme.....	16
2.11.Çıktı ve Öğrenme Döngüsü	17
2.12.Yapay Sinir Ağlarının Yapısı.....	17
2.12.1.Giriş katmanı	17
2.12.2. Gizli katman(lar)	17
2.12.3. Çıkış katmanı.....	19
2.13. YSA Sınıflandırması	19
2.14. YSA'nın Çevre Mühendisliğinde Kullanım Alanları.....	19
2.14.1. Hava kalitesi modelleme ve tahmini	19
3. LİTERATÜR TARAMASI	21
3.1. Kullanılan Giriş Parametreleri.....	21
3.2. Model Türleri ve Yaklaşımlar	22
3.3.Yöntemlerin Karşılaştırmalı Tablosu.....	23
3.4. Literatürdeki Eksiklikler ve Geleceğe Yönelik Öneriler.....	24
4. MATERYAL VE YÖNTEM.....	26
4.1. Çalışma Alanı ve Veri Kaynakları.....	26
4.2. Yazılım ve Donanım Özellikleri	26
4.2.1. Kullanılan yazılımlar	26
4.2.2.Donanım özellikleri	26
4.3.Verİ Önİşleme Aşamaları.....	27
4.4. Parametre Seçimi ve Önceliklendirme.....	27
4.4.1. Pearson korelasyon katsayısı.....	27
4.4.2. t-ratio ve p-değeri (prob(t)) analizi	27

4.4.3. Temel bileşenler analizi (PCA)	27
4.5. Yapay Sinir Ağı Modelleme Süreci	28
4.6. Eğitim, Doğrulama ve Test Süreci	29
4.7. Performans Değerlendirme Kriterleri	29
4.8. Lineer ve Non-Lineer Regresyon Analizi ve YSA ile Karşılaştırma.....	30
4.8.1. Doğrusal regresyon analizi (MLR)	30
4.8.2. Doğrusal olmayan regresyon analizi.....	31
4.8.3. DataFit ile doğrusal olmayan regresyon.....	31
4.8.4. YSA ile doğrusal olmayan regresyon:.....	31
5. BULGULAR VE TARTIŞMA	33
5.1. Parametre Seçimi Sonuçlarının Değerlendirilmesi.....	33
5.2. YSA Modelleme Sonuçlarının Değerlendirilmesi	34
5.3. Geri Yayılım Algoritmalarının Karşılaştırmalı Analizi.....	35
5.4. Eğitim Performansı ve Erken Durdurma Mekanizması.....	36
5.5. YSA Yapısının Uygunluğu	37
5.6. Model Performansının Görsel Analizi	38
5.6.1. Regresyon grafikleri.....	38
5.6.2. Hata dağılımının analizi.....	40
5.6.3. Performans eğrisi (MSE karşılaştırması).....	41
5.6.4.Eğitim performansı grafiği (Performance plot)	41
5.6.5. Eğitim sürecine ait durum grafikleri (Training state)	43
5.7. PM ₁₀ Tahmininde Yapay Sinir Ağı Yaklaşımları	44
5.7.1. Parametre seçimi açısından karşılaştırmalar	44
5.7.2. Model performansı açısından literatürle uyum.....	45
5.8. Modelin Güçlü ve Sınırlı Yönleri.....	45
5.8.1. Modelin güçlü yönleri	45
5.8.2. Modelin sınırlı yönleri.....	46

5.9. Genel Değerlendirme.....	47
5.10. PM ₁₀ Tahmini İçin Lineer ve Doğrusal Olmayan Yaklaşımlar	47
5.11. Hata İstatistikleri ve Regresyon Sonuçlarının Yorumu.....	52
5.11.1 Hata toleransı ($Y_a - Y_p$ - $Y_a - Y_p$)	52
5.11.2. Ortalama hata	52
5.11.3. Hataların toplamı (SSE).....	52
5.11.4. Tahmindeki standart hata.....	52
5.11.5. Genel değerlendirme	53
5.12. Tahmin Sonuçlarının İstatistiksel Değerlendirmesi.....	53
5.12.1. PM ₁₀ tahmin sonuçlarının istatistiksel incelemesi.....	53
5.12.1.1. Determinasyon katsayısı (R^2).....	56
5.12.1.2. Korelasyon katsayısı (R).....	56
5.12.1.3. Ortalama mutlak hata (MAE)	56
5.12.1.4. Ortalama karesel hata (RMSE) ve ortalama kare hata (MSE)	56
5.12.1.5. Sistemik (RMSES) ve sistemik olmayan hata (RMSEU)..	57
5.12.1.6. Sistemik hata oranı (PSE).....	57
5.12.1.7. Uyum indeksi (IA).....	57
5.12.1.8. İki faktörü (FA2) ve fraksiyonel varyans (FV).....	57
5.12.1.9. Genel değerlendirme.....	57
5.13. Lineer ve Doğrusal Olmayan Modelleme Karşılaştırması.....	58
5.14. Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması	59
5.14.1. PM ₁₀ konsantrasyonu tahmini	59
6. SONUÇ VE ÖNERİLER	61
6.1. Genel Değerlendirme ve Elde Edilen Bulgular	61
6.2. Literatüre Katkı ve Modelin Güçlü Yönleri.....	62
6.3. Öneriler.....	63

6.4.Bölgesel ve Coğrafi Faktörlere Dayalı Öneriler.....	64
6.5. Genel Sonuç	64
KAYNAKÇA.....	66
EKLER	
ÖZ GEÇMİŞ	



TABLÖLAR DİZİNİ

Sayfa

Tablo 5.1. <i>Farklı geri yayılım algoritmalarının YSA performans karşılaştırması.....</i>	35
Tablo 5.2. <i>Eğitim ayarları.....</i>	37
Tablo 5.3. <i>PM₁₀ Konsantrasyonunun tahminine yönelik datafit yazılımı ile geliştirilen çoklu regresyon modelleri ve</i>	48
Tablo 5.4. <i>PM₁₀ konsantrasyonu tahmininde deneysel verilerle en yüksek uyum gösteren çoklu regresyon modeli (Çoklu doğrusal regresyon model).....</i>	50
Tablo 5.5. <i>Modelin bakiyeye dayalı hata istatistikleri</i>	51
Tablo 5.6. <i>PM₁₀ tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu</i>	55

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1.Aerosol türlerinin tanecik boyutu aralıkları	7
Şekil 2.2.Yapay nöron yapısı ve bilgi akışı	12
Şekil 2.3.Yapay nöronun genel yapısı	12
Şekil 2.4.Yapay nöronun detaylı işleyiş süreci.....	16
Şekil 2.5.Gizli tabakası tek katmanlı YSA	18
Şekil 2.6.Gizli tabakası çok katmanlı YSA	18
Şekil 5.1.YSA modeline ait eğitim süreci sonunda elde edilen performans göstergeleri ..	36
Şekil 5.2.Regresyon grafiği.....	39
Şekil 5.3.Eğitim, doğrulama ve test verilerine ait hata histogramı	40
Şekil 5.4.Eğitim, doğrulama ve test aşamalarına ait ortalama karesel hata (mse) eğrilerinin analizi.....	42
Şekil 5.5.Eğitim sürecine ait gradient, mu ve validation kontrolleri grafikleri.....	43
Şekil 5.6.PM10 konsantrasyonu tahmininde YSA simülasyonları (eğitim (a), doğrulama (b) ve test (c)) ile deneysel veriler arasındaki karşılık gelen görsel uyumlar ve korelasyonlar	60

SİMGELER VE KISALTMALAR DİZİNİ

R_2	: Determinasyon Katsayısı
R_{a2}	: Ayarlanmış Çoklu Determinasyon Katsayısı
R	: Korelasyon Katsayısı
MAE	: Ortalama Mutlak Hata
RMSE	: Ortalama Karesel Hata Karekökü
RMSEs	: Sistemik RMSE
RMSEU	: Sistemik Olmayan RMSE
MSE	: Ortalama Karesel Hata
IA	: Uyum İndeksi
FA2	: İki Faktörü
FV	: Fraksiyonel Varyans
PSE	: Sistemik Hata Oranı
SEE	: Tahmindeki Standart Hata
SR	: Hataların Toplamı
AR	: Ortalama Bakiye Hata
RSS	: Hataların Kareleri Toplamı
NNI	: Uygulanan Non- Lineer İterasyon Sayısı
Y_a	: Deneysel Veri
Y_p	: Tahmin Değeri
n	: Gözlem Sayısı
p	: Çoklu Regresyon Modelindeki Değişken Sayısı
$^{\circ}C$	: Celcius Sıcaklık Birimi
YSA	: Yapay Sinir Ağları
BP-ANN	: Back-Propagation Artificial Neural Network (Geri Beslemeli Yapay Sinir Ağları)
GRNN	: General Regression Neural Network (Genel Regresyon Sinir Ağı)
MLP	: Çok Katmanlı Algılayıcı (Multilayer Perceptron)
TBA	: Temel Bileşen Analizi (PCA, Principal Component Analysis)
BP	: Geri Yayılım Algoritması
PM ₁₀	: Partikül Madde 10 Mikron (çapı 10 μm 'den küçük partiküller)

t-ratio	: t-İstatistiği Oranı (parametre anlamlılığı için)
MLR	: Multiple Linear Regression (Çoklu Doğrusal Regresyon)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
BiLSTM	: Bidirectional LSTM (Çift Yönlü Uzun Kısa Süreli Bellek)



1.GİRİŞ

Türkiye’de hava kalitesi verileri, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından düzenli olarak yayımlanmakta olup kamuoyunun erişimine açık ve şeffaf bir biçimde sunulmaktadır. Hava kirliliği, yalnızca insan sağlığını değil; aynı zamanda hayvan yaşamını, doğal ekosistemleri ve genel çevre bütünlüğünü tehdit eden küresel ölçekte önemli bir çevresel sorundur. Özellikle solunabilir partikül maddeler aracılığıyla, atmosferdeki kirlilik iklim dengesizliklerine neden olarak ekosistemlerin işleyişinde geri dönüşü zor tahribatlar oluşturabilmektedir.

Solunabilir partikül maddelerden biri olan PM₁₀ (çapı ≤ 10 mikrometre olan partiküller), çevresel sağlık risklerinin değerlendirilmesinde temel göstergelerden biridir. Dünya Sağlık Örgütü (World Health Organization, WHO), 2021 yılında yayımladığı hava kalitesi kılavuzunda, PM₁₀ için 24 saatlik ortalama sınır değerini $45 \mu\text{g}/\text{m}^3$ olarak önermiştir (WHO, 2021). Avrupa Birliği, 2024 yılında yürürlüğe giren yeni mevzuatla (Directive (EU) 2024/2881), bu değeri yasal sınır olarak benimseyerek 2030 itibarıyla $45 \mu\text{g}/\text{m}^3$ ’ün yılda en fazla 18 gün aşılmasına izin verileceğini hükme bağlamıştır. Ayrıca PM₁₀’un yıllık ortalama konsantrasyonu için sınır değer de $20 \mu\text{g}/\text{m}^3$ olarak güncellenmiştir (European Commission, 2024).

Türkiye’de ise halen yürürlükte olan “Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği”ne göre, PM₁₀ için 24 saatlik sınır değeri $50 \mu\text{g}/\text{m}^3$, yıllık ortalama sınır değeri ise $40 \mu\text{g}/\text{m}^3$ olarak belirlenmiş olup, günlük sınırın yılda en fazla 35 kez aşılmasına izin verilmektedir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2008). Bu sınırların aşılması durumunda, halk sağlığını korumaya yönelik olarak yerel ve ulusal düzeyde önleyici müdahale stratejilerinin devreye sokulması gereklidir.

Dünya Sağlık Örgütü’nün 2024 yılına ait güncel verilerine göre, dünya genelinde her yıl yaklaşık 6,7 milyon insan; hem dış ortam hem de kapalı alan hava kirliliğine bağlı gelişen hastalıklar nedeniyle hayatını kaybetmektedir (World Health Organization, 2024). Bu durum, hava kirliliğinin yalnızca çevresel bir mesele değil, aynı zamanda ciddi bir halk sağlığı problemi olduğunu açıkça ortaya koymaktadır. Özellikle solunum ve dolaşım sistemlerini etkileyen rahatsızlıkların bu olumsuz koşullarla doğrudan bağlantılı olduğu vurgulanmaktadır.

Partikül madde (PM) kirliliği, özellikle çapı 10 mikrometreden (PM_{10}) ve 2,5 mikrometreden ($PM_{2.5}$) küçük olan tanecikler açısından sağlık üzerinde ciddi riskler oluşturmaktadır. Bu tür küçük partiküller solunum sistemine derinlemesine ulaşabilmekte ve dolaşım sistemine karışarak başta iskemik kalp hastalıkları, inme ve çeşitli solunum yolu rahatsızlıkları olmak üzere çok sayıda sağlık sorununu tetikleyebilmektedir. Gerek kısa süreli gerekse uzun süreli maruziyet durumlarında bu kirleticilerin, kalp-damar ve solunum sistemine bağlı hastalıklardan kaynaklanan hastalık yükünü ve erken ölüm oranlarını artırdığı bilimsel verilerle ortaya konmuştur (WHO, 2021).

Son yıllarda hava kirliliği modellemelerinde dikkat çekici bir ilerleme yaşanmıştır. Başlangıçta daha çok klasik istatistiksel yöntemlerle yapılan tahminler, zamanla yerini daha gelişmiş ve esnek yapay zekâ tekniklerine bırakmıştır. Bu geçişin temel nedeni, çevresel verilerin çok boyutlu ve karmaşık yapısının daha dinamik yaklaşımlar gerektirmesidir.

Yapay Sinir Ağları (YSA), bu noktada öne çıkan modeller arasında yer almakta; çevresel değişkenler ile PM_{10} seviyeleri arasındaki karmaşık ilişkileri öğrenebilme yeteneğiyle dikkat çekmektedir. Bunun yanı sıra, çeşitli yapay öğrenme algoritmaları da farklı yaklaşımlar sunarak bu alanda çeşitliliği artırmıştır. Son dönemde, özellikle zaman serisi verilerinde derin öğrenme yöntemlerinin kullanımı yaygınlaşmış ve daha başarılı sonuçlar elde edilmiştir.

Tahmin başarısını yalnızca kullanılan model değil, aynı zamanda veri işleme süreci de belirlemektedir. Özellikle gereksiz verilerin elenmesi, önemli değişkenlerin seçimi ve veri gürültüsünün azaltılması gibi ön işlemler, sonuçların güvenilirliğini artırmaktadır.

Türkiye özelinde bakıldığında, bu tür çalışmalar genellikle büyük şehirlerde yoğunlaşmakta, veri erişimi ve istasyon altyapısı gibi nedenlerle bazı bölgelerde sınırlı kalmaktadır. Ancak genel anlamda, bu alandaki gelişmelerin sürdüğü ve daha uygulanabilir, bütünleşik modellerin ön plana çıktığı bir dönüşüm yaşandığı söylenebilir.

PM_{10} kirliliğinin sağlık üzerindeki etkileri, özellikle ince partiküller ($PM_{2.5}$) düzeyinde belirginleşmektedir. Dockery ve Pope (1994), ince partikül kirliliğinin kardiyovasküler ve solunum hastalıklarına katkıda bulunduğunu ve bunun erken ölümlere neden olabileceğini vurgulamaktadır. Bu bulgular, hava kirliliğinin yalnızca çevresel bir sorun değil, aynı zamanda halk sağlığı açısından da ciddi sonuçlar doğurabilecek bir tehdit olduğunu ortaya koymaktadır.

Bu tez çalışmasının temel amacı, Erzurum ili Aziziye ilçesine ait 2024 yılına ilişkin günlük meteorolojik ve hava kalitesi verileri kullanılarak, PM_{10} konsantrasyonlarının

öngörülmesine yönelik güvenilir model yapıları geliştirmektir. Bu hedef doğrultusunda, bir yandan YSA gibi yapay zekâ temelli yaklaşımlar; diğer yandan ise kullanım kolaylığı ve hızlı hesaplama avantajlarına sahip doğrusal olmayan regresyon yöntemleri incelenmiş, modellerin performansları çeşitli istatistiksel değerlendirme kriterleri ile karşılaştırılmıştır.

Modelin doğruluk düzeyini artırmak amacıyla, çevresel değişkenler arasından en etkili olanların belirlenmesi hedeflenmiştir. Bu kapsamda, literatürde yaygın biçimde kullanılan Pearson korelasyon katsayısı ve Temel Bileşen Analizi (TBA) (Principal Component Analysis (PCA)) gibi yöntemlerden faydalanılmıştır (Taheri Shahraiyi ve Sodoudi, 2016). Gardner ve Dorling (2000), yapay sinir ağı ve regresyon modellerinde farklı değişkenlerin kullanılmasını, model başarımı açısından karşılaştırmalı olarak ele almışlardır. Ancak nihai değişken seçimi yalnızca istatistiksel analizlerle sınırlandırılmamış; çevresel bilgi birikimi, literatür desteği ve modelleme deneyimi de dikkate alınarak sekiz parametre belirlenmiştir.

Çok değişkenli modelleme uygulamalarında, bağımsız değişkenlerin hedef değişken üzerindeki etkilerinin düzeyini belirlemek; hem modelin doğruluğu hem de farklı veri setlerine uygulanabilirliği açısından temel bir adımdır.

Bu çalışma, söz konusu eksiklikleri gidermeye yönelik olarak Erzurum ili Aziziye ilçesinde gerçekleştirilmiş; farklı modelleme yaklaşımlarının kıyaslanarak değerlendirilmesini amaçlamış ve yerel ölçekte uygulanabilir, geçerli PM₁₀ tahmin modelleri geliştirmeyi hedeflemiştir.

Günümüzde hava kirliliği, kentleşme, nüfus artışı ve sanayileşme gibi etkenlerle birlikte çevresel ve toplumsal boyutta ciddi etkiler yaratan bir sorun haline gelmiştir. Bu sorunun önemli bileşenlerinden biri olan PM₁₀, solunabilir özellikteki parçacıklar sayesinde doğrudan insan sağlığını tehdit etmekte; özellikle solunum yolu ve kardiyovasküler hastalıkların oluşumunda kritik rol oynamaktadır.

PM₁₀ düzeylerinin izlenmesi, çevre politikalarının geliştirilmesi ve halk sağlığının korunması açısından büyük önem taşısa da, bu tür kirleticilerin doğrudan ölçülmesi hem maliyetli hem de teknik açıdan zahmetli bir süreçtir. Özellikle geniş coğrafi alanlarda, sürekli izleme yapılması gereken bölgelerde bu durum önemli bir kısıt oluşturmaktadır.

Bu bağlamda, çalışmanın önemi; PM₁₀ konsantrasyonlarını doğrudan ölçüm yapmadan, meteorolojik ve çevresel değişkenler yardımıyla tahmin edebilme potansiyelini taşımasından kaynaklanmaktadır. Özellikle çok sayıda parametre içinden en anlamlı

olanların seçilerek, daha az veriyle yüksek doğruluk sağlayan modellerin geliştirilmesi, hem ekonomik açıdan sürdürülebilir hem de uygulama açısından pratik bir çözüm sunmaktadır.

Çalışmada kullanılan modelleme yaklaşımları, hem hesaplama kolaylığı sağlayan regresyon yöntemleri hem de doğrusal olmayan karmaşık ilişkileri ortaya çıkarabilen yapay zekâ temelli yapılarla desteklenerek, farklı analiz ihtiyaçlarına cevap verebilecek esnek ve güvenilir tahmin sistemlerinin oluşturulmasına imkân tanımaktadır.

Bu tezde gerçekleştirilen modelleme çalışmaları, PM_{10} konsantrasyonunu tahmin etme başarısının, tercih edilen yöntemler ve model yapılarına bağlı olarak farklılık gösterdiğini ortaya koymuştur. YSA yaklaşımı, çok sayıda değişken içeren ve doğrusal olmayan yapılar sergileyen veri kümelerinde, yüksek düzeyde öngörü başarısı sağlamasıyla öne çıkmıştır. Belirli transfer fonksiyonları ile eğitim algoritmalarının birlikte kullanıldığı senaryolarda R^2 değerlerinin %90'ı aştığı gözlemlenmiştir; aynı zamanda modelin test başarımı, öğrenme sürecinde ezberleme (overfitting) gibi sorunlarla karşılaşmadığını göstermiştir.

Daha yalın bir yapıya sahip olan doğrusal olmayan regresyon modelleri, bazı değişken kombinasyonlarında başarılı sonuçlar üretmiş ve belirli durumlarda etkili bir alternatif olarak değerlendirilmiştir. DataFit yazılımıyla oluşturulan bu modeller, hızlı analiz imkânı ve kolay uygulanabilirlik gibi pratik avantajlar sunarken, esneklik bakımından YSA modellerine kıyasla daha sınırlı kalmıştır.

Elde edilen veriler, Erzurum Aziziye gibi karasal iklime ve yüksek rakıma sahip bölgelerde PM_{10} seviyelerini etkileyen faktörlerin, büyükşehirlerdeki koşullardan farklı bir yapıya sahip olduğunu ortaya koymuştur. Özellikle güneşlenme süresi, rüzgar hızı ve buhar basıncı gibi meteorolojik unsurların baskın hale gelmesi, bu bölgeye özgü atmosferik yapıların model çıktıları üzerinde doğrudan belirleyici olduğunu göstermektedir.

Elde edilen sonuçlar, geliştirilen modellerin hem bilimsel geçerlilik hem de uygulamaya dönük kullanım potansiyeli açısından olumlu performans sergilediğini göstermektedir. Uygulanan farklı modelleme stratejilerinin kıyaslanması, yöntem seçimi açısından rehber niteliği taşıırken; yerel düzeyde hava kalitesi yönetimini destekleyebilecek karar verme mekanizmalarının temellerini de güçlendirmiştir.

Bu tez çalışması yedi ana bölümden oluşmaktadır:

Bölüm 1: Hava kirliliği kavramı, bu çalışmanın amacı ve önemi açıklanmış; ayrıca çalışmanın kapsamı, varsayımlar ve sınırlılıklar ile birlikte genel yapısı sunulmuştur.

Bölüm 2: Partikül madde (PM₁₀) kirliliği, kirletici kaynaklar ve meteorolojik etkenler hakkında genel bilgiler verilmiş; özellikle Erzurum ili Aziziye ilçesi özelinde mevcut durum değerlendirilmiştir.

Bölüm 3: Yapay sinir ağları teorisi, yapısı, avantajları ve çevre mühendisliğinde kullanım alanları detaylı olarak ele alınmıştır.

Bölüm 4: Çalışmada kullanılan veri setleri, veri kaynakları, ön işleme adımları ve istatistiksel analiz yöntemleri (t-ratio, pearson korelasyon, PCA) açıklanmıştır.

Bölüm 5: YSA modeli mimarisi, eğitim algoritması seçimi, model parametreleri ve optimizasyon süreci anlatılmıştır.

Bölüm 6: Modelleme sonuçları; regresyon grafikleri, hata dağılımı, performans eğrileri gibi görsel analizlerle birlikte değerlendirilmiş; YSA ve DataFit modellerinin karşılaştırmalı analizi yapılmıştır.

Bölüm 7: Elde edilen bulgular özetlenmiş, modelin güçlü yönleri ortaya konmuş ve gelecekte yapılabilecek çalışmalar için öneriler sunulmuştur.



2.HAVA KİRLİLİĞİ VE KİRLETİCİLER

2.1.Hava Kirliliği ve Kirleticiler

Atmosfer, yaşamı sürdürebilmek için gerekli olan gazları içeren ve Dünya'yı çevreleyen bir gaz tabakasıdır. Bu tabaka, sıcaklık profiline bağlı olarak troposfer, stratosfer, mezosfer ve termosfer olmak üzere dört ana katmana ayrılmaktadır. Hava kirliliği çalışmaları, büyük ölçüde insanların yaşadığı ve kirletici maddelerin yoğunlaştığı en alt katman olan troposfer üzerinde yoğunlaşmaktadır (Seinfeld ve Pandis, 2016).

Hava kalitesini belirleyen temel unsur, atmosferin alt katmanlarında biriken kirletici maddelerin yoğunluğudur. Dünya Sağlık Örgütü'nün 2021 yılında yayımladığı Hava Kalitesi Kılavuzu'nda; PM₁₀, PM_{2.5}, NO₂, O₃, SO₂ ve CO gibi maddeler insan sağlığı açısından temel kirleticiler olarak tanımlanmıştır (WHO, 2021).

2.2. Hava Kirliliği Tanımı

Hava kirliliği, insan sağlığına, çevreye ve eşyaya zarar verebilecek gaz, partikül veya buhar hâlindeki kirleticilerin atmosferde zarar verebilecek düzeyde (Anbarcı ve Toros, 2018) ve uzun süre boyunca (Olçay, 2023) bulunması durumudur.

Bu tanım çerçevesinde hava kirliliğinin oluşabilmesi için, kirletici maddenin atmosferde yalnızca bulunması yeterli değildir; aynı zamanda bu maddelerin belirli bir yoğunluğun (konsantrasyonun) üzerinde ve belirli bir süre boyunca havada kalması gerekmektedir. Bu iki koşul bir araya geldiğinde, kirleticiler canlı sağlığını ve çevresel dengeyi tehdit eden boyutlara ulaşır. Dolayısıyla, hava kirliliği değerlendirmelerinde hem konsantrasyon düzeyleri hem de maruziyet süresi birlikte ele alınmalı, sınır değerler bu çifte etkene göre tanımlanmalıdır.

2.3. Kirletici Türleri

Hava kirleticileri genel olarak kaynaklarına göre sınıflandırıldığında iki gruba ayrılmaktadır. Doğrudan atmosfere salınan kirleticiler “birincil”, atmosferdeki kimyasal reaksiyonlar sonucu oluşanlar ise “ikincil” kirleticiler olarak tanımlanmaktadır. SO₂, NO_x, CO ve partikül maddeler birincil; ozon ve fotokimyasal sis ise ikincil kirleticilere örnek verilebilir (Anbarcı ve Toros, 2018).

2.3.1. Aerosol türleri ve PM₁₀ bağlamında tanecik büyüklükleri

Atmosferde bulunan ve gaz ortamında askıda kalan katı ya da sıvı tanecikler, kaynakları ve fiziksel özelliklerine göre farklı gruplara ayrılır. Bu parçacıklar, çevre sağlığı ve hava kalitesi açısından önem taşır ve genel olarak aerosol olarak adlandırılır. Taneciklerin çapları mikrometre (μm) ölçeğinde değişmekte olup, özellikle 10 mikrometreden küçük çaplı partiküller (PM₁₀) insan sağlığı açısından risk oluşturabilecek boyutlardadır.

Aerosoller fiziksel yapılarına göre şu şekilde sınıflandırılabilir:

- Toz:** Mekanik aşınma, inşaat faaliyetleri veya endüstriyel işlemler sonucu oluşan, genellikle 1–1000 μm aralığında katı partiküllerdir. PM₁₀'un önemli bir bileşenidir.


- Buhar:** Kimyasal veya fiziksel süreçlerle oluşan gaz halindeki maddelerin yoğunlaşmasıyla meydana gelir; 0.01–1 μm aralığındadır.

- Sis:** Yoğuşma sonucu oluşan ve mikrometre ölçeğinde sıvı damlacıklardan oluşan aerosollerdir; PM₁₀ içinde yer alabilir.

- Duman:** Özellikle karbon içeren maddelerin eksik yanmasıyla ortaya çıkan ince katı parçacıklardır. Genellikle 0.1–1 μm çapındadır ve PM_{2.5} ile çakışır.

- Sprey:** Sıvıların gazla birlikte püskürtülmesi sonucu oluşan ve 1–100 μm arasında değişen sıvı taneciklerdir.

Tanecik çapı küçüldükçe atmosferde kalma süresi artmakta ve solunum sistemine nüfuz etme potansiyeli yükselmektedir. Bu nedenle PM₁₀ ($\leq 10 \mu\text{m}$) boyutundaki parçacıklar, özellikle çevre ve insan sağlığı açısından önem taşır ve birçok aerosol türü bu boyut aralığında yer alır.



Şekil 2.1. Aerosol türlerinin tanecik boyutu aralıkları (*Kaynak:* Müezzinoğlu, 2000'den uyarlanmıştır)

Farklı aerosol türleri, atmosferdeki askıda kalma süreleri ve sağlık etkileri bakımından tanecik çaplarına göre sınıflandırılmaktadır. Şekil 2.1'de bu türlerin yaklaşık boyut aralıkları gösterilmekte olup, 10 mikrometrenin altındaki partiküller (PM_{10}) özellikle solunum sistemine nüfuz edebilme özellikleri nedeniyle önem arz etmektedir.

2.4. Başlıca Gaz Kirleticiler

Kükürt dioksit (SO_2), kömür ve petrol gibi fosil yakıtların yanması sırasında oluşan bir gazdır. Atmosferde su buharıyla etkileşime girerek asidik bileşiklere dönüşebilir; bu da asit yağmurlarına zemin hazırlar. Solunduğunda ise, özellikle hassas bireylerde solunum yollarında tahrişe yol açabilir.

Azot oksitler (NO_x), başta araç egzozları ve enerji üretim tesislerinden olmak üzere birçok yanma sürecinden kaynaklanır. Bu bileşikler, atmosferde ozon (O_3) oluşumunu tetikler ve fotokimyasal duman gibi hava kirliliği olaylarında önemli rol oynar.

Karbon monoksit (CO), yakıtların tam olarak yanmaması sonucu ortaya çıkar. Kana karıştığında hemoglobinin oksijen taşıma kapasitesini düşürerek, başta kalp ve sinir sistemi olmak üzere vücutta ciddi etkiler oluşturabilir.

Uçucu organik bileşikler (VOC'ler), başta boya ve temizlik malzemeleri gibi ürünlerden ve bazı sanayi süreçlerinden atmosfere salınır. Bu maddeler, güneş ışığıyla reaksiyona girerek yer seviyesinde ozon üretimine katkıda bulunur.

Bazı VOC türleri toksik hatta kanserojen özellik gösterebilir. Fotokimyasal sis, özellikle NO_x ve VOC'lerin güneş ışığıyla etkileşimi sonucunda oluşur. Bu olay troposferik ozon seviyelerini yükselterek insan sağlığını tehdit edebilir; özellikle astım gibi solunum yolu hastalıklarını tetikleyebilir (Toros, 2018).

2.5. Erzurum'da Hava Kirliliği

Erzurum, Türkiye'nin kuzeydoğusunda yer alan en büyük ve gelişmiş şehirlerden biridir. Sanayileşmenin düşük olduğu bu yüksek rakımlı şehirde, kış aylarında sıcaklıklar $-40^{\circ}C$ 'ye kadar düşebilmektedir. Şehrin kuzey ve güney yönlerinde 2000 ila 3000 metre yüksekliğinde dağlarla çevrili olması ve bu coğrafi yapı nedeniyle rüzgarsız günlerde hava sirkülasyonunun sınırlı olması, hava kirliliği açısından ciddi sağlık riskleri oluşturmaktadır.

Özellikle kış aylarında yakıt tüketimindeki artışla birlikte, hava kirliliğinde belirgin yükselişler yaşanmakta; en yüksek PM_{10} ve SO_2 konsantrasyonları ocak ayında

kaydedilmektedir. Önceki çalışmalar da benzer şekilde, Erzurum’da endüstriyel kaynaklı bir kirlenmenin bulunmadığını ve hava kirliliğinin büyük ölçüde kış koşullarına bağlı olarak ortaya çıktığını ortaya koymuştur (Koşan vd., 2018).

2.6. Meteorolojik Faktörlerin Etkisi

Hava kirliliğinin düzeyi yalnızca kirleticiler kaynakların yoğunluğuna değil, aynı zamanda ortamın meteorolojik özelliklerine de bağlıdır. PM₁₀ konsantrasyonlarını etkileyen başlıca çevresel faktörler arasında sıcaklık, bağıl nem, rüzgâr hızı ve yönü gibi meteorolojik parametreler yer almaktadır (Birim vd., 2023).

2.7.Yapay Sinir Ağları

2.7.1.Tanım, tarihçe ve gelişim süreci

YSA, insan beyninin öğrenme ve problem çözme yeteneklerinden ilham alınarak geliştirilmiş yapay zeka sistemleridir. Bu sistemler, veriler arasındaki karmaşık ilişkileri tanımlayarak öğrenebilme, genelleme yapabilme ve tahminlerde bulunma yeteneğine sahiptir. YSA'lar, verilerin matematiksel yapısını öğrenerek daha önce karşılaşılmamış örnekler üzerinde de anlamlı sonuçlar üretmeleriyle öne çıkar. Bu özellik, onları sınıflandırma, regresyon ve optimizasyon gibi görevlerde güçlü bir araç haline getirir.

McCulloch ve Pitts (1943), nöronların davranışlarını “ya hep ya hiç” yasasına dayandırarak mantıksal ifadelerle modellenebileceğini öne sürmüş ve böylece yapay sinir ağlarının ilk kuramsal temellerini atmışlardır.

Rosenblatt (1958), insan beynindeki bilgi işleme süreçlerinden esinlenerek geliştirdiği perceptron modelini, öğrenebilen ilk sinir ağı sistemi olarak tanımlamıştır. Bu model, giriş verilerine karşılık olarak uyarılara tepki verebilen ve zamanla bu tepkileri güncelleyebilen yapay bir sistem olarak kurgulanmıştır.

Rumelhart, Hinton ve Williams (1986), geri yayılım (backpropagation) algoritmasını tanıtarak gizli katman içeren yapay sinir ağlarının etkin biçimde eğitilmesini mümkün kılmış ve böylece bu yöntemi, YSA alanında en etkili öğrenme mekanizmalarından biri hâline getirmiştir (Rumelhart vd., 1986). Bu gelişmeyle birlikte yapay sinir ağları, doğrusal olmayan sistemlerin modellenmesinde etkin biçimde kullanılmaya başlanmış ve zamanla farklı mimariler (ör. geri beslemeli ağlar, konvolüsyonel ve tekrarlayan sinir ağları) geliştirilerek çok çeşitli alanlarda uygulama bulmuştur.

2.7.2.Yapay sinir ağlarının özellikleri

YSA, öğrenme yetenekleri sayesinde karmaşık ve doğrusal olmayan ilişkileri çözümleyebilme kapasitesine sahiptir. Veriler arasında istatistiksel olarak açıkça belirgin olmayan örüntüleri tanıyabilir ve bu örüntülerden genelleme yaparak yeni veriler üzerinde de etkili tahminlerde bulunabilir.

YSA'ların en önemli özelliklerinden biri paralel bilgi işleme yetenekleridir. Bu özellik, büyük ve çok değişkenli veri setlerinde hesaplamaların eş zamanlı gerçekleştirilmesine olanak tanıyarak, geleneksel yöntemlere kıyasla daha verimli bir modelleme sağlar. Ayrıca, ağın bazı nöronlarında veya bağlantılarında sorun yaşansa bile sistemin genel işleyişi sürdürülebilir; bu da YSA'lara hata toleransı ve esneklik kazandırır.

YSA'ların öğrenme süreci sonunda elde ettikleri bilgi, sadece eğitildikleri veri ile sınırlı kalmayıp yeni verilere de genelleme yapabilmelerine olanak sağlar. Bu özellik, yapay sinir ağlarının esnek ve uyarlanabilir yapısını ortaya koyar (Ersoy ve Karal, 2012).

2.7.3.Yapay sinir ağlarının avantaj ve dezavantajları

YSA, biyolojik sinir sisteminden esinlenerek geliştirilmiş sistemlerdir ve geleneksel istatistiksel yöntemlere kıyasla birçok avantaj sunmaktadır. Bu ağlar, öğrenme, genelleme, bellek ve örüntü tanıma gibi özellikleriyle karmaşık problemlerin çözümünde yaygın olarak kullanılmaktadır (Ersoy ve Karal, 2012; Öztemel, 2003).

Avantajları:

- Öğrenme Yeteneği:** YSA'lar, girdi-çıktı örneklerinden öğrenme yeteneğine sahiptir. Bu özellik, insan beyninin deneyim yoluyla öğrendiği süreçlere benzetilebilir (Ersoy ve Karal, 2012).
- Hata Toleransı:** Eğitim sırasında elde edilen bilgiler, nöronlar arasındaki bağlantı ağırlıklarına dağıtılarak saklandığı için sistemin bazı bileşenleri bozulsa bile ağ genel olarak çalışmaya devam edebilir (Ersoy ve Karal, 2012).
- Dağıtık Bellek Yapısı:** Bilgiler, YSA içinde tek bir noktada değil; birçok nöron bağlantısı boyunca paralel olarak saklanır. Bu yapı, bellek kaybına karşı sistemin dayanıklılığını artırır (Ersoy ve Karal, 2012).
- Karmaşık İlişkileri Öğrenebilme:** Özellikle doğrusal olmayan ve çok boyutlu ilişkiler içeren veri setlerinde, yapay sinir ağlarının örüntü tanıma ve öğrenme kabiliyeti sayesinde

geleneksel yöntemlere kıyasla daha esnek modeller sunduğu belirtilmektedir (Öztemel, 2003).

Dezavantajları:

- “Kara Kutu” Sorunu:** YSA’ların karar verme süreçleri, modelin içsel yapısı nedeniyle çoğu zaman açıklanabilirlik açısından sınırlıdır. Bu durum, özellikle karmaşık ağlarda modelin nasıl karar verdiğini yorumlamayı zorlaştırmaktadır (Haykin, 2009).

- Aşırı Öğrenme (Overfitting):** YSA, eğitim verilerine aşırı uyum sağladığında genelleme yeteneğini kaybedebilir. Bu durum, yeni veri üzerinde düşük performansa yol açar (Haykin, 2009).


- Yüksek Hesaplama Maliyeti:** Geri yayılım algoritmasının eğitimi sırasında, ağ yapısının karmaşıklığına bağlı olarak ağırlıkların güncellenmesi uzun sürebilir ve çok sayıda yineleme (iterasyon) gerekebilir. Ayrıca ağın katman sayısı arttıkça öğrenme süresi uzamakta ve bazı durumlarda yakınsaması mümkün olmamaktadır (Öztemel, 2003).

- Parametre Seçimi Zorluğu:** Yapay sinir ağı tasarımı katman sayısı, nöron sayısı ve öğrenme oranı gibi hiperparametrelerin belirlenmesi genellikle deneysel yöntemlere dayanır ve bu süreç zaman alıcı olabilir (Haykin, 2009).


2.8.Biyolojik Nöron ve Yapay Nöron Modelleri

Yapay sinir ağlarının temel yapı taşı olan yapay nöronlar, biyolojik nöronların yapısından ilham alınarak modellenmiştir. Biyolojik bir nöron; dendritler aracılığıyla uyarıları alır, hücre gövdesinde bu sinyalleri işler ve akson aracılığıyla diğer nöronlara iletir. Bu doğal işleyiş, yapay nöronların tasarımına temel teşkil etmiştir.

Yapay sinir ağlarında, her bir giriş sinaptik ağırlıklarla çarpılarak ağırlıklı toplam elde edilir. Bu toplam, doğrusal olmayan bir aktivasyon fonksiyonundan geçirilerek nöronun çıktısı üretilir (Haykin, 2009).



Şekil 2.2. Yapay nöron yapısı ve bilgi akışı (Kaynak: Öztemel, 2003'ten uyarlanmıştır).



Şekil 2.3. Yapay nöronun genel yapısı (Kaynak: Yurtoğlu, 2005).

Yapay sinir ağlarının temel yapı taşı olan yapay nöronlar, biyolojik nöronların yapısından ilham alınarak modellenmiştir. Biyolojik bir nöron; dendritler aracılığıyla uyarıları alır, hücre gövdesinde bu sinyalleri işler ve akson aracılığıyla diğer nöronlara iletir. Bu doğal işleyiş, yapay nöronların tasarımına temel teşkil etmiştir.

Yapay sinir ağlarında, her bir giriş sinaptik ağırlıklarla çarpılarak ağırlıklı toplam elde edilir. Bu toplam, doğrusal olmayan bir aktivasyon fonksiyonundan geçirilerek nöronun çıktısı üretilir (Haykin, 2009).

Bu süreçte kullanılan temel bileşenler aşağıda özetlenmiştir:

2.8.1.Ağırlıklar ($W_1, W_2, ..., W_n$)

Her bir girdinin çıktı üzerindeki etkisini belirler. Her giriş, belirli bir ağırlık katsayısı ($W_0, W_1, ..., W_n$) ile çarpılır. Bu katsayılar, ağırlık öğrenme sürecinde ayarlanır ve her girdinin çıktıya katkı düzeyini belirler. Ağırlıkların güncellenmesini sağlayan algoritmik yapı burada temsil edilir. Öğrenme programı, girdilerle beklenen çıktılar arasındaki farklara göre ağırlıkları yeniden düzenler.

2.8.2.Toplama fonksiyonu ($\sum W_i X_i$)

Ağırlıklı girişlerin toplamını hesaplar.

2.8.3.Transfer fonksiyonu (Aktivasyon fonksiyonu)

Toplam değeri işleyerek çıktı üretir. Doğrusal ya da doğrusal olmayan dönüşümler uygulanabilir. Toplama fonksiyonu sonucu, aktivasyon (transfer) fonksiyonu yardımıyla doğrusal veya doğrusal olmayan bir biçime dönüştürülür. Bu dönüşüm, modelin sınıflandırma veya tahmin gibi görevleri yerine getirmesini sağlar. En sık kullanılan transfer fonksiyonları şunlardır:

- Sigmoid
- Hiperbolik Tanjant (tanh)
- Doğrusal (Linear)
- Sine (Sinüzoidal)

Bu fonksiyonlar modelin karmaşık örüntüleri tanımasını sağlar.

Yapay sinir ağlarında her bir nöron, kendisine gelen girişlerin ağırlıklı toplamını hesaplar ve bu değeri bir aktivasyon fonksiyonu aracılığıyla işleyerek modele doğrusal olmayanlık kazandırır. Bu yapı, ağırlık karmaşık örüntüleri öğrenebilmesini sağlar ve çıktının genliği üzerinde kontrol sunar (Haykin, 2009).

Ağ yapısında doğrusal olmayanlık kazandırılması, özellikle karmaşık veri örüntülerinin tanınmasında kritik öneme sahiptir. Aktivasyon fonksiyonu kullanılmadan oluşturulan ağlar yalnızca doğrusal ilişkileri öğrenebilir ve bu da birçok gerçek dünya uygulaması için yetersiz kalır.

2.8.4.Sigmoid fonksiyon

Sigmoid fonksiyonu, doğrusal olmayan, sürekli ve türevlenebilir bir fonksiyon olup genellikle ikili sınıflandırma problemlerinde tercih edilmektedir. Matematiksel olarak (2.1) numaralı denklemdeki gibi tanımlanır:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

Yapay sinir ağlarında yaygın olarak kullanılan sigmoid gibi aktivasyon fonksiyonları, giriş değerlerini 0 ile 1 arasında bir aralığa sıkıştırarak olasılıksal yorumlara olanak tanır. Ancak bu tür fonksiyonlar, özellikle büyük pozitif veya negatif giriş değerlerinde türevlerinin çok küçük olması nedeniyle gradyanların sifıra yakınsadığı durumlara yol açabilir. Bu durum, ağır öğrenme sürecini yavaşlatarak eğitimi olumsuz etkileyebilir ve literatürde “gradyan sönmesi” (vanishing gradient) problemi olarak tanımlanır (Haykin, 2009).

2.8.5.Hiperbolik fanjant (Tanh) fonksiyonu

Hiperbolik tanjant fonksiyonu da sigmoid fonksiyona benzer şekilde doğrusal olmayan bir yapıya sahiptir; ancak çıktısı -1 ile +1 aralığındadır. Bu sayede, ortalamaya yakın sıfır merkezli değerler üretir ve bazı durumlarda öğrenme sürecinde avantaj sağlayabilir. Bununla birlikte, tanh fonksiyonu da büyük giriş değerlerinde türevlerinin küçülmesi nedeniyle gradyan sönmesi problemine neden olabilir (Haykin, 2009). Hiperbolik tanjant fonksiyonunun matematiksel ifadesi Denklem (2.2)’de verilmiştir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

2.8.6.Doğrusal fonksiyon (Linear)

Doğrusal aktivasyon fonksiyonu genellikle regresyon türü problemler için kullanılmakta olup, (2.3) numaralı denklemdeki gibi ifade edilir:

$$f(x) = ax + b \quad (2.3)$$

Çok katmanlı yapay sinir ağlarında doğrusal aktivasyon fonksiyonlarının tercih edilmesi, her katmanın yalnızca girişlerin ağırlıklı toplamını işlemesiyle sonuçlanır. Bu yapı, ardışık katmanların birleştirilerek tek bir doğrusal dönüşüme indirgenmesine yol açar. Sonuç olarak, ağın derinliği ne olursa olsun, doğrusal yapılar karmaşık örüntüleri öğrenmekte yetersiz kalabilir (Hagan vd., 2014).

2.8.7.Sinüzoidal fonksiyon (Sine)

Sinüs fonksiyonu, özellikle zaman serisi verileri, döngüsel olaylar veya periyodik sistemlerin modellenmesinde kullanılmaktadır:

$$f(x) = \sin(x) \quad (2.4)$$

Hiperbolik tanjant (tanh) fonksiyonu, çıktı değerlerini -1 ile +1 aralığında sınırlayan doğrusal olmayan bir aktivasyon fonksiyonudur. Bu özelliği sayesinde bazı durumlarda simetrik veri işleme açısından avantaj sağlar. Ancak uç değerlerde türevlerinin çok küçük olması, geri yayılım algoritmasında gradyanların sönmesine neden olabilir. Bu durum, öğrenme sürecinin yavaşlamasına yol açabileceğinden, tanh fonksiyonu derin ağ yapılarında dikkatli kullanılmalıdır (Haykin, 2009).


2.9.Çıktı

Bir sonraki katmana iletilen ya da doğrudan tahmin değeri olarak kullanılan sinyaldir. Bu yapı, Şekil 2.3’de kavramsal olarak sunulmuştur.

Aktivasyon (transfer) fonksiyonları, nöronların verdiği tepkiyi şekillendirerek ağın genel öğrenme davranışını belirler. Log-sigmoid ve tanh gibi doğrusal olmayan, diferansiyellenebilir fonksiyonlar çok katmanlı ağlarda yaygın olarak kullanılmakta olup; doğrusal (linear) fonksiyonlar genellikle çıkış katmanlarında tercih edilir. Seçilen fonksiyon, modelin öğrenme performansını ve doğrusal olmayan ilişkileri yakalama kapasitesini doğrudan etkiler (Hagan vd., 2014,).

Transfer fonksiyonları, nöronların dışarıya verdiği çıktının biçimini belirleyerek ağın genel davranışını doğrudan etkiler. Logsig, tansig ve purelin gibi fonksiyonlar, özellikle feedforward yapay sinir ağlarında, karmaşık ve doğrusal olmayan veri yapılarının başarıyla modellenmesini mümkün kılar (Hagan vd., 2014).

Sonuç olarak, yapay nöronlar; girdileri alıp işleyen, öğrenme sürecinde ağırlıklarını güncelleyen ve karmaşık veri örüntülerini tanıyan temel bilgi işleme birimleridir. Bu yapı, yapay sinir ağlarının güçlü bir tahmin ve modelleme aracı olmasını sağlar.



Şekil 2.4. *Yapay nöronun detaylı işleyiş süreci (Kaynak: Yurtoğlu, 2005).*

Bu şekil, yapay sinir ağlarında bir nöronun veri işleme sürecini çok adımlı olarak tanımlayan kavramsal bir modeli göstermektedir. Yapay sinir ağlarının temel birimi olan bu yapı, girdi verilerini alır, ağırlıklandırır, matematiksel işlemden geçirir ve çıktı üretir. Şema, bu sürecin bileşenlerini ve etkileşimlerini açıkça görselleştirerek, yapay nöronun öğrenme döngüsüyle nasıl entegre olduğunu göstermektedir.

2.10.Değerlendirme

Transfer fonksiyonları, yapay sinir ağlarının öğrenme dinamiklerinde ve karar mekanizmalarında merkezi bir role sahiptir. Doğrusal olmayan transfer fonksiyonlarının kullanımı, ağın çok katmanlı yapısıyla birleşerek yüksek dereceli karar sınırları oluşturmaya olanak tanır. Fonksiyon seçiminde modelin karmaşıklığı, verinin ölçeği ve hedef çıktının doğası göz önünde bulundurulmalı; gerektiğinde hibrit yaklaşımlar benimsenmelidir.

2.11.Çıktı ve Öğrenme Döngüsü

Çıktı (Output)

Transfer fonksiyonu sonrası elde edilen sonuç, ağın ürettiği çıktıyı oluşturur. Bu çıktı ya doğrudan bir tahmin değeridir ya da bir sonraki ağ katmanına aktarılır.

Öğrenme Döngüsü (Learning Cycle):

Modelin öğrenmesini sağlayan geribildirim döngüsünü temsil eder. Çıktılar ve hedefler karşılaştırılır, hata varsa bu hata geriye doğru yayılır ve ağırlıklar buna göre güncellenir.

2.12.Yapay Sinir Ağlarının Yapısı

YSA, biyolojik sinir sistemlerinin çalışma prensiplerinden esinlenilerek geliştirilen, çok sayıda yapay nöronun birbirine bağlanmasıyla oluşturulan bilgi işleme sistemleridir (Haykin, 2009). Bu ağlar, özellikle doğrusal olmayan ve karmaşık veri yapılarını öğrenebilme ve genelleyeabilme yetenekleri sayesinde, sınıflandırma, tahmin, optimizasyon gibi birçok problemde başarıyla kullanılmaktadır (Zhang vd., 1998). YSA'lar üç temel katmandan oluşur: giriş katmanı, gizli (ara) katman(lar) ve çıkış katmanı. Bu yapılar, verinin işleme sürecine göre organize edilmiş olup Şekil 2.4'de şematize edilmiştir.

2.12.1.Giriş katmanı


Yapay sinir ağlarında giriş katmanı, modelin dış ortamdan aldığı bilgileri iç yapısına aktardığı ilk katmandır. Bu katmanda yer alan her bir yapay nöron, veri setindeki bir değişkeni temsil eder. Giriş katmanı, bu bilgileri doğrudan işlem yapmadan bir sonraki gizli katmana iletir. Böylece ağın öğrenme süreci başlatılmış olur (Hagan vd., 2014). Giriş katmanı, öğrenme sürecinde doğrudan işlem yapmamakla birlikte modelin temel bilgi akışını başlatması açısından kritik bir öneme sahiptir.

2.12.2. Gizli katman(lar)


Gizli katmanlar, giriş katmanından gelen bilgilerin çeşitli ağırlıklar ve aktivasyon fonksiyonları aracılığıyla işlendiği bölümlerdir. Bu katmanlar, ağın öğrenme sürecinde temel rol oynar ve yüksek seviyeli örüntülerin çıkarılmasında etkilidir. Bir yapay sinir ağı, problemi çözme karmaşıklığına bağlı olarak birden fazla gizli katman içerebilir (Haykin,

2009). Her bir gizli katmandaki nöronlar, kendilerine ulaşan girdileri ağırlıklandırarak toplar, bir aktivasyon fonksiyonu aracılığıyla dönüştürür ve çıktıyı bir sonraki katmana aktarır.

Gizli katman sayısı ve bu katmanlardaki nöron sayısı arttıkça, ağın öğrenme kapasitesi artmakla birlikte hesaplama maliyeti ve aşırı öğrenme (overfitting) riski de artmaktadır (Zhang vd., 1998). Bu nedenle uygun ağ mimarisinin belirlenmesi, YSA modellemesinde temel adımlardan biridir. Şekil 2.5 ve Şekil 2.6’da sırasıyla tek katmanlı ve çok katmanlı gizli yapılar örneklenmiştir.



Şekil 2.5. Gizli tabakası tek katmanlı YSA (Kaynak: Kakıcı, 2009).



Şekil 2.6. Gizli tabakası çok katmanlı YSA (Kaynak: Yurtoğlu, 2005).

2.12.3. Çıkış katmanı

Yapay sinir ağlarında çıkış katmanı, modelin öğrenme süreci sonunda ürettiği tahmin değerini dış dünyaya aktaran son katmandır. Bu katmandaki nöron sayısı, genellikle problemin çıktı sayısına göre belirlenir. Örneğin, tek bir hedef değişkenin öngörüldüğü regresyon problemlerinde yalnızca bir nöron yeterli olurken; çok sınıflı sınıflandırma problemlerinde, her bir sınıfa karşılık gelecek şekilde birden fazla çıkış nöronu kullanılabilir (Hagan vd., 2014).

Çıkış katmanında üretilen sonuçlar, hem doğrudan kullanıcıya sunulabilir hem de geri beslemeli sistemlerde hata geri yayılım algoritması (backpropagation) ile ağırlıkların güncellenmesinde kullanılabilir. Bu süreç, ağıın öğrenmesini ve hata oranının azaltılmasını sağlar.

Yapay sinir ağları, esnek mimarileri ve doğrusal olmayan karmaşık sistemleri modelleyebilme yetenekleri sayesinde mühendislik uygulamalarında, özellikle çevresel verilerin işlenmesinde yaygın şekilde kullanılmaktadır (Haykin, 2009; Zhang vd., 1998).

2.13. YSA Sınıflandırması

Yapay sinir ağları, mimari yapılarına göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) olarak sınıflandırılırken; öğrenme yaklaşımları danışmanlı, danışmansız ve takviyeli öğrenme olarak üç ana grupta değerlendirilmektedir. Besleme yönüne dayalı bu mimari sınıflandırma (statik/dinamik), Zhang vd. (1998) tarafından tanımlanan yapılarla uyumludur.

2.14. YSA'nın Çevre Mühendisliğinde Kullanım Alanları

Çevre mühendisliği uygulamalarında yapay zekâ temelli modelleme yöntemlerinin özellikle su, hava ve atık yönetimi gibi alanlarda önemli katkılar sağladığı ifade edilmektedir (Yetilmezsoy vd., 2011).

2.14.1. Hava kalitesi modelleme ve tahmini

YSA, hava kirliliğine neden olan partikül maddelerin (örneğin PM_{10} , $PM_{2.5}$) ve gaz kirleticilerin (örneğin NO_x , CO) konsantrasyonlarının tahmini amacıyla, meteorolojik değişkenlerle birlikte entegre bir şekilde kullanılmaktadır. Bu uygulamalarda sıcaklık, bağıl

nem, rüzgar hızı gibi meteorolojik parametreler modelin giriş verileri olarak değerlendirilirken, hedef değişken olarak kirletici madde seviyeleri öngörülmektedir. YSA modelleri, doğrusal olmayan ve karmaşık ilişkileri temsil etme yetenekleri sayesinde, geleneksel istatistiksel yöntemlere kıyasla daha yüksek doğruluk oranları sunmakta ve özellikle şehir içi hava kalitesi tahmininde etkili bir alternatif olarak öne çıkmaktadır (Taheri Shahraini ve Sodoudi, 2016).

3. LİTERATÜR TARAMASI

Hava kirliliği, özellikle PM_{10} gibi solunabilir partikül maddeler üzerinden değerlendirildiğinde, çevre mühendisliği ve atmosfer bilimi alanlarında son yıllarda yoğun biçimde ele alınan bir konudur. PM_{10} tahmini için kullanılan yöntemlerin çeşitliliği, bu alanda yapılmış çok sayıda çalışmayı beraberinde getirmiştir. Bu bölümde, 2000–2025 yılları arasında yayımlanmış belirli örnek çalışmalar incelenmiş; yöntem türleri ve uygulama örnekleri çerçevesinde genel hatlarıyla değerlendirilmiştir.

3.1. Kullanılan Giriş Parametreleri

PM_{10} konsantrasyonlarının tahmini için kullanılan model girdi parametreleri, çalışmanın yapıldığı bölgenin çevresel özelliklerine, veri erişimine ve model türüne göre önemli çeşitlilik göstermektedir. Bu parametreler genellikle üç ana grupta toplanmaktadır: meteorolojik değişkenler, gaz kirleticiler ve trafik ya da demografik değişkenler.

Pek çok çalışmada olduğu gibi, PM_{10} konsantrasyonlarının modellenmesinde meteorolojik değişkenler önemli giriş parametreleri arasında yer almaktadır. Gündoğdu (2020) tarafından gerçekleştirilen bir araştırmada, Türkiye’de sanayi faaliyetlerinin yoğun olduğu bir bölgede, PM_{10} ve SO_2 düzeylerinin tahminine yönelik yapay sinir ağı modelleri uygulanmıştır. Bu kapsamda, hava sıcaklığı, bağıl nem, rüzgâr hızı gibi meteorolojik değişkenlerin yanı sıra PM_{10} ve SO_2 ölçüm verileri, modelin giriş değişkenleri olarak kullanılmıştır. Çalışmada hem statik yapıya sahip Çok Katmanlı Algılayıcı (MLP) modeli hem de zamana bağlı değişimleri dikkate alan dinamik NARX (Nonlinear Autoregressive with Exogenous Input) ağ mimarisi test edilmiştir. Elde edilen sonuçlar, kullanılan parametrelerin hava kirliliği tahmininde anlamlı katkılar sunduğunu ve dinamik ağ yapıların, özellikle zaman serisi tabanlı hava kalitesi tahminlerinde güçlü bir alternatif olduğunu ortaya koymuştur (Gündoğdu, 2020).

Çakır ve Sita (2020) tarafından yürütülen çalışmada, Lefkoşa’daki hava kalitesine ilişkin modellemelerde giriş değişkenleri olarak bir önceki güne ait kirletici konsantrasyonları ile birlikte atmosfer basıncı, rüzgâr hızı, bağıl nem ve sıcaklık verileri kullanılmıştır. Bu yaklaşım, yalnızca meteorolojik faktörleri değil, aynı zamanda kirletici seviyelerinin zamansal devamlılığını da göz önünde bulundurarak daha güvenilir tahminler yapılmasını mümkün kılmıştır.

Taşpınar (2015) tarafından yürütülen çalışmada, 2007–2014 yılları arasında elde edilen günlük ortalama PM_{10} , sıcaklık, bağıl nem ve rüzgâr hızı gibi meteorolojik veriler esas alınarak hava kalitesi tahmin modeli geliştirilmiştir. Bununla birlikte, PM_{10} 'un geçmiş günlere ait ölçüm değerleri de model girişleri arasında değerlendirilmiştir. Girdi parametrelerinin boyutunu azaltmak ve model başarımını iyileştirmek amacıyla Temel Bileşenler Analizi (PCA) yöntemi kullanılmış ve böylece değişkenler arasındaki çoklu bağlantılar sadeleştirilmiştir.

Şahin vd., (2020) tarafından yürütülen Iğdır çalışmasında da hem meteorolojik hem de kimyasal kirletici veriler birlikte değerlendirilmiştir. Girdi seti; sıcaklık, bağıl nem, rüzgâr hızı ve yönü, NO_2 , SO_2 , O_3 , CO gibi değişkenlerden oluşturulmuştur.

Bunun yanı sıra bazı araştırmalar, geleneksel meteorolojik ve hava kalitesi değişkenlerinin ötesine geçerek farklı veri türlerini de modellemeye dâhil etmiştir. Örneğin, Antanasijević ve çalışma arkadaşları (2013), 23 Avrupa ülkesini kapsayan analizlerinde PM_{10} maruziyetini öngörmek amacıyla yalnızca çevresel verilerle yetinmeyip; sürdürülebilir kalkınma göstergeleri, sanayi yapısı ve ekonomik büyüklük gibi sosyoekonomik faktörleri de modele entegre etmişlerdir.

Zhang vd., (2013) ise Çin'in Taiyuan kentindeki çalışmada meteorolojik verilere ek olarak nüfus yoğunluğu, kentleşme düzeyi gibi demografik göstergeleri de modele entegre ederek mekânsal PM_{10} dağılımını tahmin etmiştir.

3.2. Model Türleri ve Yaklaşımlar

PM_{10} tahminine yönelik gerçekleştirilen araştırmalar, geleneksel istatistiksel analiz yöntemlerinin yanı sıra yapay zekâ tabanlı güncel modelleme tekniklerini de içerecek şekilde geniş bir yelpazede yürütülmektedir. Bu çalışmalar içinde en çok öne çıkan yöntemler arasında çoklu doğrusal regresyon (MLR), YSA ve regresyon ağaçları (CART) yer almaktadır. Bazı araştırmalar bu yöntemleri karşılaştırmalı olarak uygulayarak hangi yöntemlerin hangi durumlarda üstünlük sağladığını da ortaya koymuştur.

Yapay sinir ağı modelleri çoğu çalışmada ya tek başına uygulanmış ya da başka modellerle karşılaştırılmıştır. Örneğin Gündoğdu (2020), Türkiye'deki bir endüstriyel tesis verilerini kullanarak hem statik (MLP) hem de dinamik NARX ağ yapısını karşılaştırmıştır. NARX modeli, zaman gecikmeli verilerle çalıştığı için özellikle dinamik hava kirliliği süreçlerinde avantaj sağlamaktadır.

Abdullah ve diğerkleri (2019), Malezya'daki PM₁₀ tahmini alıřmalarında Radyal Baz Fonksiyonu (RBF), (MLP) ve (MLR) modellerini karřılařtırmıřtır. Yazarlar, doğrusal ve doğrusal olmayan modellerin aynı veri seti üzerindeki başarı düzeylerini ölçerek, RBF'nin yüksek esneklik kabiliyetine sahip olduğunu ortaya koymuřtur.

Lefkořa kentinde gerekleřtirilen bir arařtırmada akır ve Sita (2020), PM₁₀ seviyelerinin tahmini iin yalnızca geri yayılımlı YSA modelini uygulamıřlardır. Söz konusu model, hata payını en aza indirme amacına yönelik olarak geri yayılım algoritmasıyla eğitilmiřtir. alıřmada farklı yöntemlerle bir karřılařtırma yapılmamıř, yalnızca bu YSA yapısının öngörü yeteneđi deđerlendirilmiřtir.

Yapay sinir ađlarının geleneksel yöntemlerle karřılařtırıldıđı ilk dönem alıřmalardan biri olan Chaloulakou ve diğerkleri (2003), MLR ile YSA modellerini karřılařtırmıř ve sinir ađlarının özellikle yaz aylarında daha iyi performans gösterdiđini belirtmiřtir. Bu durum, YSA'nın doğrusal olmayan iliřkileri daha iyi yakalayabildiđini göstermektedir.

Alam ve McNabola (2015), klasik MLR yöntemine ek olarak, doğrusal olmayan polinom regresyon ve YSA modellerini de ieren bir karřılařtırmalı analiz gerekleřtirmiřtir. alıřma kapsamında, Viyana ve Dublin gibi büyükřehirlerde PM₁₀ konsantrasyonlarının zamansal ve mekânsal deđiřimlerini öngörme amacıyla bu modelleme tekniklerinin performansları deđerlendirilmiřtir. Arazi kullanım verilerinin modele entegre edilmesi, özellikle YSA'nın öğrenme kapasitesini artırmıřtır.

Bu alıřmalar göstermektedir ki, PM₁₀ tahmininde kullanılabilecek modeller arasında tek bir ideal yaklařım bulunmamakta; her modelin avantajları alıřmanın amacına, veri yapısına ve çevresel kořullara göre deđiřmektedir. Bununla birlikte, doğrusal olmayan iliřkileri öğrenebilen ve gemiř deđerleri dikkate alan YSA ve türevi modellerin, genel olarak daha esnek ve başarılı olduđu öne ıkmaktadır.

3.3.Yöntemlerin Karřılařtırmalı Tablosu

Son yıllarda geliřtirilen yapay zekâ tabanlı yöntemler, özellikle YSA, hava kalitesi tahmininde önemli bir yer edinmiřtir. Bununla birlikte,MLR gibi klasik yöntemler de hâlâ yaygın olarak kullanılmaktadır. Literatürde, yapay sinir ađları ile MLR yöntemlerini karřılařtıran ok sayıda alıřma bulunmaktadır. Bu alıřmalar, modelleme performansı, doğruluk katsayıları ve uygulama kolaylıđı açısından yöntemler arasında farklılıklar ortaya koymaktadır. Örneđin, Kocaeli ilinde yapılan bir alıřmada YSA modellerinin MLR'ye göre

daha yüksek R^2 deęerleri ve daha dūşük hata oranları sunduęu gōsterilmiřtir (Özdemir ve Taner, 2014). Benzer řekilde, Sakarya ili üzerine geręekleřtirilen bir dięer alıřmada da YSA modellerinin, MLR'ye kıyasla PM_{10} tahmininde daha isabetli sonular verdięi rapor edilmiřtir (Ceylan ve Bulkan, 2018).

PM_{10} tahmininde yapay sinir aęları ile regresyon yōntemlerinin birlikte deęerlendirildięi alıřmalardan biri Chaloulakou vd., (2003) tarafından Atina'da yūrūtūlmūřtur. Bu alıřmada, YSA modellerinin gūnlūk ortalama PM_{10} konsantrasyonlarını tahmin etmede oklu doęrusal regresyona kıyasla daha bařarılı olduęu saptanmıřtır.

Benzer řekilde, Özdemir (2014), meteorolojik faktōrleri temel alarak hem YSA hem de MLR yōntemlerini PM_{10} üzerinde test etmiř; YSA modellerinin tahmin doęruluęunun MLR modellerinden daha yūksek olduęunu belirtmiřtir. Bu bulgu, ۆzellikle deęiřken iliřkilerin doęrusal olmayan yapılar gōsterdięi durumlarda YSA'nın avantajlı olduęunu gōstermektedir (Özdemir, U. ve Taner, S. (2014)).

Pérez ve Reyes (2002), řili'nin Santiago kentinde 24 saatlik ortalama PM_{10} konsantrasyonlarını 30 saat önceden tahmin etmeye yōnelik bir model geliřtirmiřtir. Bu kapsamda, MLR ve YSA yōntemleri karřılařtırılmıř; ayrıca farklı veri ön iřleme tekniklerinin ve model yapılandırılmalarının tahmin performansına etkileri incelenmiřtir. alıřma bulgularına gōre, ۆzellikle yūksek konsantrasyon seviyelerinin gōzlendięi gūnlerde YSA modelleri, MLR'ye kıyasla daha yūksek doęruluk oranları sunmuřtur (Pérez ve Reyes, 2002).

3.4. Literatūrdeki Eksiklikler ve Geleceęe Yōnelik Őneriler

PM_{10} modellemeleriyle ilgili literatūr olduka geniř olmakla birlikte bazı yōnlerden sınırlılıklar da iermektedir. Őzellikle İstanbul, Ankara ve İzmir gibi būyūķřehirlerde yoęunlařan arařtırmalar, bu bōlgelerdeki istasyon altyapısının daha gūlū ve veriye eriřimin daha kolay olmasıyla iliřkilidir. Buna karřın, Doęu ve Gūneydoęu Anadolu bōlgelerinde hem izleme istasyonu sayısının dūřuk olması hem de bazı istasyonların yıllık veri būtūnlūęūnū saęlayamaması nedeniyle bilimsel alıřmalar sınırlı kalmaktadır. Zeydan (2021), 176 hava kalitesi izleme istasyonunu deęerlendirdięi alıřmasında, veri yetersizlięi nedeniyle 10 istasyonun analiz dıřı bırakıldıęını ve bu istasyonların būyūk kısmının Doęu–Gūneydoęu Anadolu'da yer aldıęını aıka belirtmiřtir (Zeydan, 2021).

Gelecekte yapılacak çalışmalarda, bölgesel veri eşitsizliğinin giderilmesi, hava kalitesi izleme istasyonlarının sayısının artırılması ve açık veri paylaşımı gibi konular kritik rol oynayacaktır. Ayrıca, PM_{10} dışındaki diğer partikül madde türleri (örneğin $PM_{2.5}$, ultrafine particles) ile ilgili bütünleşik modelleme çalışmalarının yapılması da önem arz etmektedir. Sonuç olarak, bu literatür taraması göstermektedir ki PM_{10} modelleme alanı gelişmeye açık bir alandır ve doğru yöntem seçimi, veri ön işleme kalitesi ve çok parametrelili analiz yaklaşımları ile daha başarılı ve uygulanabilir modeller geliştirilebilecektir.

4. MATERİYAL VE YÖNTEM

4.1. Çalışma Alanı ve Veri Kaynakları

Bu tez çalışmasında, Erzurum ili, Aziziye ilçesinde yer alan hava kalitesi ve meteorolojik parametrelerin 2024 yılına ait günlük ortalama değerleri kullanılmıştır. Hava kalitesi ile ilgili veriler, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın Hava Kalitesi İzleme Ağı kapsamında faaliyet gösteren Erzurum Aziziye ölçüm istasyonundan sağlanmıştır. Meteorolojik parametreler ise, T.C. Meteoroloji Genel Müdürlüğü'ne bağlı 17095 numaralı Erzurum Meteoroloji Gözlem İstasyonu'ndan alınmıştır. Eksik gözlemler ayıklandıktan sonra toplam 263 ortalama günlük veri seti elde edilmiştir. Bu veriler, analiz sürecinden önce Excel platformunda birleştirilmiş ve ön işleme aşamasından geçirilerek hem DataFit hem de MATLAB yazılımlarına uyumlu hale getirilmiştir.

4.2. Yazılım ve Donanım Özellikleri

Bu tez kapsamında gerçekleştirilen yapay sinir ağı modellemeleri, regresyon analizleri ve istatistiksel değerlendirmeler aşağıdaki yazılım ve donanım bileşenleri kullanılarak yürütülmüştür:

4.2.1. Kullanılan yazılımlar

- MATLAB R2017a: Yapay sinir ağı modellemesi, veri ön işleme, normalizasyon, performans analizi ve grafik üretimi için kullanılmıştır. fitnet, train, plotregression ve perform gibi yerleşik fonksiyonlar aracılığıyla eğitim ve doğrulama süreçleri yürütülmüştür.

- DataFit version 8.1.69: Lineer ve non-lineer regresyon analizleri ile t-ratio ve prob(t) istatistiklerinin hesaplanması için tercih edilmiştir.

- Microsoft Excel 2019: Ham veri birleştirme, eksik veri kontrolü, görselleştirme ve ilk analizler için kullanılmıştır.

4.2.2. Donanım özellikleri

- İşlemci: Intel Core i5 (2.71 GHz)
- RAM: 8 GB DDR4
- İşletim Sistemi: Microsoft Windows 10 (64-bit)
- Sabit Disk: 224 GB SSD

4.3. Veri Önışleme Aşamaları

Veri önışleme aşamasında řu adımlar takip edilmiştir:

- 263 veri seti excel dosyasında birleştirilmiş, DATAFİT ve MATLAB ortamına aktarılmıştır.
- Normalizasyon, min-max ölçekleme yöntemiyle -1,1 aralığına indirilerek yapılmıştır.
- Eğitim ve test süreçleri için veri %70 eğitim, %15 doğrulama ve %15 test olacak şekilde bölünmüştür.

4.4. Parametre Seçimi ve Önceliklendirme

Modelin performansını artırmak amacıyla anlamlı ve etkili değişkenlerin belirlenmesinde üç temel yöntem kullanılmıştır. Bu yöntemler sonucunda sekiz parametre nihai modele dâhil edilmiştir.

4.4.1. Pearson korelasyon katsayısı

Pearson korelasyon katsayıları, değişkenler arasındaki doğrusal ilişkinin yönü ve gücünü değerlendirmek amacıyla kullanılmıştır. Belirli bir eşik değeri belirlenmemiş, bunun yerine korelasyon katsayıları karşılaştırmalı olarak değerlendirilmiş ve görece yüksek ilişki gösteren değişkenler parametre seçim sürecinde öncelikli olarak ele alınmıştır.

4.4.2. t-ratio ve p-değeri (prob(t)) analizi

DataFit yazılımı kullanılarak yapılan non-linear regresyon sonucunda her bir bağımsız değişkenin PM₁₀ tahmini üzerindeki katkısı t-ratio değeriyle analiz edilmiş; $p < 0.05$ olan değişkenler anlamlı sayılmıştır.

4.4.3. Temel bileşenler analizi (PCA)

MATLAB çevresinde PCA yöntemi uygulanarak veriler bileşenler bazında ayrıştırılmış ve çoklu bağlantı (multicollinearity) sorunları azaltılmıştır. Elde edilen yük değerlerine göre katkısı düşük olan parametreler elenmiştir.

4.5. Yapay Sinir Ağı Modelleme Süreci

Bu çalışmada PM_{10} konsantrasyonunun tahmini amacıyla geliştirilen YSA modeli, MATLAB R2017a ortamında fitnet fonksiyonu kullanılarak gerçekleştirilmiştir. Modelleme sürecinde, önce tek gizli katmanlı yapılarla başlanmış, ardından çok katmanlı mimarilere geçilerek daha yüksek doğruluk aranmıştır. Deneysel olarak, gizli katmandaki nöron sayısı 5 ile 35 arasında değişecek şekilde farklı kombinasyonlar denenmiştir.

Her bir model kombinasyonunda, giriş katmanı sayısı seçilen parametre sayısı kadar belirlenmiştir. Giriş verileri (p_n) ve hedef veriler (t_n), mapminmax fonksiyonu ile -1,1 aralığında normalize edilerek modele verilmiştir. Ağın öğrenme performansını etkileyen farklı transfer fonksiyonlarını test etmek amacıyla, logsig, tansig ve purelin fonksiyonları alternatif olarak değerlendirilmiştir. Her transfer fonksiyonu, hem gizli katmanda hem de çıkış katmanında farklı şekillerde test edilmiştir.

Ağ yapısı aşağıda genel biçimiyle özetlenmiştir:

- Girdi Katmanı: Seçilen parametre sayısı kadar nöron
- Gizli Katman(lar): 1 ila 3 katman, her biri için farklı nöron sayısı denenmiştir
- Çıkış Katmanı: Tek nöron (PM_{10} tahmini)
- Transfer Fonksiyonları: logsig, tansig, purelin
- Öğrenme Algoritmaları: trainlm (Levenberg-Marquardt), trainbr (Bayesian Regularization), trainscg (Scaled Conjugate Gradient), trainrp (Resilient Backpropagation)

Her model eğitiminde eğitim başarımını ölçmek için ortalama karesel hata (MSE) temel performans metriği olarak kullanılmıştır. Eğitim süreci sırasında net.trainParam.goal ile hata limiti, net.trainParam.epochs ile maksimum yineleme sayısı tanımlanmıştır.

Bu modelleme yaklaşımı, literatürde geniş kabul görmüş olup, çok değişkenli ve doğrusal olmayan çevresel modelleme problemlerinde yaygın biçimde kullanılmaktadır (Yetilmezsoy ve Sapçlı-Zengin, 2009).

Bu modelleme yaklaşımı, çok değişkenli ve doğrusal olmayan çevresel sorunların çözümünde yaygın olarak tercih edilen, uygulama alanı oldukça geniş bir yöntemdir.

Özellikle karmaşık veri yapılarının analizinde ve öngörü modellerinin geliştirilmesinde etkinliği kanıtlanmış yöntemlerden biri olarak kabul edilmektedir.

4.6. Eğitim, Doğrulama ve Test Süreci

Geliştirilen YSA modelinin genelleme kabiliyeti ve öğrenme performansını değerlendirmek için, veri seti rastgele olacak şekilde üç gruba ayrılmıştır:

- %70 Eğitim Verisi (training)
- %15 Doğrulama Verisi (validation)
- %15 Test Verisi (testing)

Verilerin eğitim, doğrulama ve test kümelerine ayrılması işlemi, MATLAB yazılımında yer alan dividerand fonksiyonu aracılığıyla rastlantısal olarak gerçekleştirilmiştir. Eğitim sürecinde, ağ parametreleri sadece eğitim verileri üzerinden öğrenilirken, doğrulama verileri ile aşırı öğrenme (overfitting) riski kontrol altına alınmıştır. Test verileri ise tamamen eğitimden bağımsız olarak değerlendirme amacıyla kullanılmıştır.

Ayrıca eğitim süreci sonunda elde edilen model çıktıları ile hedef değerler karşılaştırılarak dört farklı regresyon grafiği (plotregression) oluşturulmuştur. Bu grafikler; eğitim, doğrulama, test ve tüm veri seti için ayrı ayrı gösterilmiştir. Böylece modelin farklı bölümlerdeki uyumu görsel olarak da incelenmiştir.

4.7. Performans Değerlendirme Kriterleri

YSA modeli ile yapılan tahminlerin doğruluğunu ve güvenilirliğini belirlemek için aşağıdaki istatistiksel performans göstergeleri kullanılmıştır:

- R^2 (Determinasyon Katsayısı)

Gerçek ve tahmin değerler arasındaki uyumu gösterir; 1'e yaklaştıkça uyum artar.

- R (Korelasyon Katsayısı)

Lineer ilişki gücünü ölçer; ± 1 aralığında değer alır.

- MAE (Ortalama Mutlak Hata)

Gerçek ve tahmin değerler arasındaki ortalama sapma.

- MSE (Ortalama Karesel Hata)

Tahmin hatalarının karelerinin ortalaması.

- RMSE (Karekök Ortalama Hata)

Hataların karekökü; birim olarak tahmin değişkeniyle aynı ölçektir.

- IA (Uyum İndeksi)

Model tahminleri ile gerçek veriler arasındaki benzerliği değerlendiren 0 ile 1 arasında değişen bir ölçüttür. Değer 1'e yaklaştıkça, modelin öngörü gücünün yüksek olduğu kabul edilir.

- FA2 (İki Faktörü – Factor of Two)

Gerçek ve tahmin değerlerin 0.5–2 aralığında olup olmadığını yüzdesel olarak gösterir.

- FV (Fraksiyonel Varyans)

Modelin tahmin doğruluğunu değerlendirmek amacıyla kullanılan basit bir ölçüttür. Gerçek ve tahmin değerleri arasındaki varyans farkına dayanır; değer in sıfıra yaklaşması, model başarısının arttığını gösterir. Bu tür kriterler, farklı YSA senaryoları arasında karşılaştırma yaparak en uygun modeli belirlemek için kullanılmıştır.

4.8. Lineer ve Non-Lineer Regresyon Analizi ve YSA ile Karşılaştırma

Yapay sinir ağı modelinin başarımını değerlendirebilmek amacıyla, aynı veri seti üzerinde çoklu doğrusal (MLR) ve doğrusal olmayan (non-lineer) regresyon analizleri de uygulanmıştır. Bu analizler, DataFit yazılımı kullanılarak gerçekleştirilmiştir. Her iki model türü, bağımlı değişken olan PM₁₀ konsantrasyonunun çoklu bağımsız meteorolojik ve atmosferik parametrelerle tahmin edilmesine yönelik olarak oluşturulmuştur.

Bu bölümde, YSA modeli ile elde edilen tahmin sonuçlarının başarımı, aynı veri seti üzerinde DataFit yazılımı kullanılarak oluşturulan çoklu doğrusal (MLR) ve doğrusal olmayan regresyon modelleriyle karşılaştırılmıştır. Her üç modelin hedefi, PM₁₀ konsantrasyonunun meteorolojik ve atmosferik parametrelerle açıklanması ve tahmin edilmesidir.

4.8.1. Doğrusal regresyon analizi (MLR)

Birden fazla bağımsız değişkenin, tek bir bağımlı değişken üzerindeki etkisini açıklamak amacıyla kullanılan çoklu doğrusal regresyon modeli, genel olarak (4.1) numaralı yapıda formüle edilmektedir:

$$PM_{10} = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_n \cdot X_n + \varepsilon \quad (4.1)$$

Burada;

PM₁₀: Bağımlı değişken (tahmin edilen değer),

X₁, X₂, ..., X_n: Bağımsız değişkenler (girdiler),

β_0 : Sabit terim (intercept),
 $\beta_1, \beta_2, \dots, \beta_n$: Regresyon katsayıları,
 ε : Hata terimi.

Model kurulduktan sonra, parametrelerin anlamlılığı t-ratio ve prob(t) değerleri ile test edilmiştir. 0.05 anlamlılık düzeyi altında $p < 0.05$ çıkan değişkenler, PM_{10} üzerindeki etkileri bakımından istatistiksel olarak anlamlı kabul edilmiştir. Elde edilen bulgular, çoklu doğrusal regresyon modellerinin her durumda veriyi etkili biçimde temsil edemediğini ortaya koymuştur. Özellikle değişkenler arasında doğrusal olmayan ilişkilerin bulunduğu durumlarda, modelin açıklayıcılığında belirgin bir azalma gözlenmiştir.

4.8.2. Doğrusal olmayan regresyon analizi

Bu bölümde, doğrusal olmayan (non-linear) regresyon yaklaşımları hem DataFit yazılımı hem de YSA modelleri ile ayrı ayrı ele alınmıştır. Her iki yöntem de, PM_{10} konsantrasyonunun meteorolojik ve atmosferik değişkenlerle tahmininde doğrusal ilişkilerin yetersiz kaldığı durumlar için kullanılmıştır.

4.8.3. DataFit ile doğrusal olmayan regresyon

DataFit yazılımının “nonlinear regression” modülü kullanılarak, Gauss, logaritmik, sigmoidal gibi çeşitli eğri uydurma fonksiyonları test edilmiştir. Modeller, en düşük hata ve en yüksek determinasyon katsayısı (R^2) esas alınarak değerlendirilmiş; parametreler iteratif yöntemlerle belirlenmiştir. Bu analizlerde kullanılan algoritmalar, doğrusal olmayan fonksiyonel ilişkilerin belirlenmesinde etkili olmuştur.

4.8.4. YSA ile doğrusal olmayan regresyon

Yapay sinir ağı modeli, doğrusal olmayan ilişkileri tanımlamada güçlü bir alternatif olarak değerlendirilmiştir. Çok katmanlı yapısı sayesinde, girdi ve çıktı değişkenleri arasındaki karmaşık ilişkileri öğrenme ve genelleme yeteneğine sahiptir. Bu çalışmada, ağın eğitimi sırasında hatayı minimize etmeye yönelik etkili bir algoritma kullanılmış; böylece model, düşük hata oranları ile yüksek doğrulukta sonuçlar üretmiştir. Bu yönüyle yapay sinir ağı, doğrusal regresyon yöntemlerine kıyasla daha esnek ve başarılı bir yapı sunmuştur.

Sonu olarak, hem DataFit hem de YSA uygulamaları, doğrusal olmayan regresyon analizi kapsamında değeriendirilmiř; ancak yöntemlerin matematiksel alt yapıları ve modelleme yaklaşımları birbirinden farklıdır.

5. BULGULAR VE TARTIŞMA

5.1. Parametre Seçimi Sonuçlarının Değerlendirilmesi

Bu çalışmada PM₁₀ konsantrasyonunun modellenmesinde çok değişkenli atmosferik ve çevresel etkenler birlikte değerlendirilmiştir. Başlangıçta 15 parametre üzerinden yapılan analizlerde t-istatistiği (t-ratio), Pearson korelasyon katsayısı ve Temel Bileşenler Analizi (PCA) yöntemleri kullanılmış; değişkenlerin istatistiksel anlamlılığı ve modele katkı potansiyeli çok yönlü olarak incelenmiştir.

Üç yöntemden en az ikisinde anlamlı bulunan altı parametre doğrudan modele seçilmiştir. Ancak nihai değişken seti yalnızca istatistiksel bulgulara dayandırılmamış; çevresel bilgi birikimi, literatür desteği ve modelleme deneyimi de dikkate alınmıştır. Bu nedenle tekil analizlerde sınırlı katkı göstermesine rağmen çevresel açıdan önemli görülen buhar basıncı ve rüzgâr hızı da eklenerek toplam sekiz parametre belirlenmiştir.

Seçilen sekiz parametre şunlardır:

- Buhar basıncı (hPa)
- Rüzgâr hızı (m/s)
- Yağış miktarı (mm)
- Nispi nem (%)
- SO₂ konsantrasyonu (µg/m³)
- CO konsantrasyonu (mg/m³)
- NO_x konsantrasyonu (µg/m³)
- Güneşlenme süresi (saat)

Buhar basıncı, tekil istatistiksel analizlerde PM₁₀ ile düşük ilişki göstermiş olsa da, ikincil partikül oluşumunda belirleyici rolü nedeniyle modele dahil edilmiştir. Gaz fazındaki organik bileşiklerin partikül fazına geçişinde doymuş buhar basıncının kritik öneme sahip olduğu, dolayısıyla PM₁₀ seviyelerine dolaylı katkı sunduğu literatürde vurgulanmaktadır (Seinfeld ve Pandis, 2016; Cappa vd., 2016).

Benzer şekilde rüzgâr hızı da tekil istatistiksel testlerde zayıf görünse de, kirleticilerin taşınımı ve seyrelmesi açısından fiziksel olarak vazgeçilmezdir (Seinfeld ve Pandis, 2016).

Yapay Sinir Ağları gibi çok değişkenli, doğrusal olmayan modeller, tek başına anlamlı olmayan değişkenlerin diğer parametrelerle etkileşimleri sayesinde tahmin gücünü artırabileceğini göstermektedir (Haykin, 2009). Bu nedenle yalnızca korelasyon ya da t-ratio

değerlerine değil, değişkenler arası etkileşim ve modelin genel performansına odaklanılmıştır.

Nitekim 15 parametreyle kurulan model ile 8 parametrelilik nihai model karşılaştırıldığında R^2 ve MSE gibi performans göstergelerinde anlamlı bir fark görülmemiştir. Bu sonuç, modelin daha az parametreyle de yüksek başarı sağladığını; dolayısıyla yalın ve yorumlanabilir bir yapının tercih edilmesinin uygun olduğunu ortaya koymaktadır.

Sonuç olarak, seçilen sekiz parametre hem istatistiksel hem de çevresel açıdan modelleme için uygun bulunmuş; bu yaklaşım model çıktıların güvenilirliğini artırmış ve parametre seçiminin doğruluğunu teyit etmiştir.

5.2. YSA Modelleme Sonuçlarının Değerlendirilmesi

Bu çalışmada PM_{10} kirliliğini tahmin etmek amacıyla geliştirilen YSA modeli, çevresel verilerin doğrusal olmayan ve çok değişkenli yapısını öğrenebilecek şekilde yapılandırılmıştır. Model, ileri beslemeli çok katmanlı yapıya sahiptir ve MATLAB ortamında kullanıcı tanımlı komutlarla geliştirilmiştir. Eğitim sürecinde Levenberg–Marquardt (trainlm) algoritması kullanılmıştır. Bu algoritma, küçük ve orta büyüklükteki veri setlerinde yüksek doğrulukla ve kısa sürede yakınsama sağlamasıyla öne çıkmaktadır.

Modelin giriş katmanında çevresel ve meteorolojik sekiz parametre yer almakta, çıkış katmanında ise tahmin edilen PM_{10} değeri bulunmaktadır. Gizli katmanlar üç seviyelidir ve sırasıyla 5, 10 ve 20 nörondan oluşmaktadır. Bu yapı, farklı mimari kombinasyonlar üzerinde yapılan denemeler sonucunda belirlenmiştir. Katman ve nöron sayılarının seçimi, öğrenme başarısı ile genelleme kabiliyeti arasında denge kurmak amacıyla optimize edilmiştir. Literatürde de belirtildiği gibi (Haykin, 2009; Hagan vd., 2014), bu tür çok katmanlı yapılar, çevresel sistemlerin modellenmesinde hem düşük frekanslı eğilimleri hem de yüksek frekanslı detayları yakalamada etkilidir.

Modelin eğitimi sonucunda düşük hata değerleri ve yüksek korelasyon katsayıları elde edilmiş; bu da hem veri işleme sürecinin etkinliğini hem de modelin genel başarımını göstermektedir. Bu bağlamda, modelin yapısal özelliklerine dayalı olarak elde edilen performans çıktıları hem sayısal hem de grafiksel olarak aşağıda detaylandırılmıştır.

5.3. Geri Yayılım Algoritmalarının Karşılaştırmalı Analizi

PM₁₀ konsantrasyonunun tahmini için oluşturulan YSA modelinde, farklı geri yayılım algoritmalarının performansları karşılaştırmalı olarak değerlendirilmiştir. Tüm algoritmalar sabit bir model mimarisi (5-10-20 nöronlu üç gizli katman) ile test edilmiş; korelasyon katsayısı (R), ortalama karesel hata (MSE) ve iterasyon sayısı gibi metriklerle analiz edilmiştir.

Toplam 11 algoritma karşılaştırılmış ve sonuçlar Tablo 5.1'de özetlenmiştir. Levenberg–Marquardt (trainlm) algoritması, genel R değeri (0.98046), düşük MSE (0.00117) ve sadece 69 iterasyonla en kısa sürede yakınsama sağlaması gibi avantajlarla en başarılı yöntem olmuştur. Eğitimde yüksek başarı elde edip test setinde düşük performans gösteren trainoss (test R: 0.44) gibi algoritmalar, aşırı öğrenme eğilimleri nedeniyle tercih edilmemiştir. Benzer şekilde, traingd ve traingdm gibi klasik algoritmalar da düşük R değerleri (0.80 ve 0.87) ve yüksek MSE değerleriyle yetersiz kalmıştır.


Bu kapsamlı analiz sonucunda, trainlm algoritması, PM₁₀ tahmini için en uygun eğitim yöntemi olarak belirlenmiştir.

Tablo 5.1. Farklı geri yayılım algoritmalarının YSA performans karşılaştırması.

Algoritma	R (Eğitim)	R (Validasyon)	R (Test)	R (Genel)	MSE	İterasyon
trainlm	0.987	0.978	0.961	0.980	0.00117	69
trainbfg	0.958	0.958	0.970	0.959	0.00765	96
trainrp	0.973	0.953	0.817	0.954	0.00386	1000
traingcf	0.958	0.852	0.970	0.956	0.00514	1000
traingcp	0.918	0.932	0.864	0.910	0.00249	1000
traingcb	0.921	0.894	0.513	0.908	0.0171	59
trainseg	0.915	0.883	0.950	0.915	0.00279	1000
trainoss	0.988	0.715	0.441	0.939	0.00241	1000
traingd	0.789	0.843	0.864	0.805	0.0400	1000
traingdx	0.889	0.935	0.959	0.912	0.0116	1000
traingdm	0.858	0.901	0.907	0.870	0.247	1000

5.4. Eğitim Performansı ve Erken Durdurma Mekanizması

Bu bölümde, YSA modelinin eğitim performansı ve doğrulama sürecinde devreye giren erken durdurma mekanizması ele alınmaktadır. Modelin eğitimi süresince elde edilen istatistiksel performans değerleri Şekil 5.1’te sunulmuştur.



Şekil 5.1. YSA modeline ait eğitim süreci sonunda elde edilen performans göstergeleri
(Kaynak: nntraintool arayüzü – MATLAB R2017a)

Model eğitimi, toplam 69 epoch sonunda 0.00117 ortalama karesel hata (MSE) değeri ile başarıyla tamamlanmıştır. Eğitim sürecinde doğrulama setine ait hata izlenmiş; en iyi doğrulama performansının ardından üst üste 50 epoch boyunca iyileşme gözlenmemesi nedeniyle eğitim işlemi erken durdurma (early stopping) mekanizmasıyla sonlandırılmıştır.

Bu durum, modelin aşırı öğrenme (overfitting) eğiliminden başarıyla korunduğunu göstermektedir.

Model, hızlı yakınsama sağlayan ve küçük-orta boyutlu veri setleri için önerilen Levenberg-Marquardt (trainlm) algoritmasıyla eğitilmiştir (Haykin, 2009). Eğitim öncesi tüm giriş verileri, mapminmax fonksiyonu ile $[-1, 1]$ aralığına normalize edilmiştir. Bu işlem, öğrenme sürecinde ağına daha kararlı ve hızlı eğitilmesini sağlamıştır. Modelin eğitimine ilişkin temel parametreler ve ayarlar Tablo 5.2’de verilmiştir.

Tablo 5.2. Eğitim ayarları

Parametre	Değer
Eğitim Algoritması	Levenberg-Marquardt (trainlm)
Performans Fonksiyonu	Ortalama Karesel Hata (MSE)
Veri Bölme Yöntemi	Rastgele bölme (dividerand)
Eğitim/Doğrulama/Test Oranları	%70 / %15 / %15 (263 veri seti)
Maksimum Epoch Sayısı	1000 (net.trainParam.epochs)
Erken Durdurma	50 ardışık doğrulama hatası artışı
Gerçekleşen Epoch	69
Eğitim MSE	0.00117

Sonuç olarak, eğitim işlemi 69. epochta sonlandırılmış ve modelin genel başarımı korunmuştur. Bu yaklaşım, erken durdurma mekanizmasının hem eğitim hem de doğrulama verisi üzerinde dengeli bir öğrenme sunduğunu göstermektedir.

1. Başarım Göstergeleri

Modelin performansı aşağıdaki göstergelerle değerlendirilmiştir. Bu değerler yalnızca eğitim setine değil, genel öğrenme başarımını yansıtan istatistiksel ölçütlerdir:

- MSE (Mean Squared Error): 0.00117 – Düşük hata oranı.
- Gradyan (Gradient): 0.000464 – Kararlı öğrenme süreci.
- Mu (Adaptasyon Katsayısı): $1.00e-5$ – Güncellemelerde denge.
- Validation Checks: 50 – En iyi doğrulama başarısından sonra geçen 50 başarısız epoch sonrasında erken durdurma mekanizması devreye girmiştir.

5.5. YSA Yapısının Uygunluğu

Üç katmanlı sinir ağı yapısı, PM_{10} gibi çevresel verilerde sıkça karşılaşılan doğrusal olmayan ilişkileri temsil etmek için etkili bir çözüm sunmuştur. Nöron sayılarının katmanlar arasında artan şekilde dağıtılması, modelin daha geniş bir örüntü tanıma kabiliyeti

kazanmasını sağlamıştır. Seçilen transfer fonksiyonları (logsig, tansig, purelin) ve eğitim algoritmaları tahmin performansını desteklemiş; eğitim süresinin yalnızca 1 saniye sürmesi, donanım ve veri hazırlık sürecinin başarılı olduğunu göstermektedir.

Sonuç olarak, geliştirilen YSA modeli; önceki bölümde açıklanan düşük hata oranı, kararlı öğrenme yapısı ve erken durdurma mekanizması gibi unsurlarla başarılı bir eğitim süreci geçirmiştir. Bu bulgular, modelin hem eğitim verisine yüksek uyum sağladığını hem de aşırı öğrenmeye düşmeden genelleme kapasitesini koruyabildiğini göstermektedir. Performans değerlendirmeleri, ilerleyen bölümlerde regresyon grafikleri ve hata histogramları ile desteklenecektir.

5.6. Model Performansının Görsel Analizi

Modelin başarı düzeyini yalnızca sayısal performans göstergeleri ile değil, aynı zamanda görsel analiz araçları ile desteklemek, tahmin kabiliyetinin daha anlaşılır hale getirilmesini sağlar. Bu amaçla eğitim, doğrulama, test ve genel veri seti için oluşturulan regresyon grafiklerinin yanı sıra hata histogramı ve modelin genel başarımını yansıtan performans eğrileri değerlendirmeye alınmıştır.

Grafiklerle desteklenen model çıktıları, YSA yapısının yalnızca istatistiksel metriklerle değil, aynı zamanda görsel doğrulama ile de güçlü bir tahmin yeteneğine sahip olduğunu ortaya koymaktadır. Özellikle eğitim, doğrulama ve test setlerinde benzer doğruluk düzeylerinin elde edilmesi, modelin genelleme kapasitesini somut biçimde göstermekte ve sahada uygulanabilirliğini artırmaktadır.

5.6.1. Regresyon grafikleri

Eğitim süreci tamamlandıktan sonra modelin tahmin sonuçları ile gerçek değerler karşılaştırılarak, eğitim, doğrulama, test ve tüm veri setleri için dört ayrı regresyon grafiği oluşturulmuştur (Şekil 5.2).


- Eğitim Regresyonu (Training): Modelin öğrenme sürecindeki doğruluğunu yansıtan bu grafikte, tahmin edilen PM_{10} değerleri ile gözlenen değerler arasındaki ilişkinin korelasyon katsayısı 0.98709'dur. Bu yüksek değer, güçlü bir doğrusal uyuma işaret etmektedir.

- Doğrulama Regresyonu (Validation): Aşırı öğrenmenin olup olmadığını anlamak için kullanılan bu veri seti üzerinde modelin korelasyon katsayısı 0.97754 olarak

bulunmuştur. Bu sonuç, doğrulama verilerinde de yüksek doğruluk elde edildiğini göstermektedir.

- Test Regresyonu (Test): Modelin daha önce görmediği veriler üzerindeki başarımını değerlendirmek adına oluşturulan bu grafik için R değeri 0.96139 civarındadır. Tahmin sonuçları ve gerçek ölçümler arasındaki uyum, modelin güvenilirliğini desteklemektedir.

- Genel Regresyon (All): Tüm veri seti göz önüne alındığında, modelin genel korelasyon katsayısı 0.98046'dır. Bu analiz, modelin genel doğruluk düzeyinin oldukça yüksek olduğunu ortaya koymaktadır



Şekil 5.2. Regresyon grafiği

Modelin tüm veri setlerinde elde ettiği yüksek korelasyon katsayıları ve regresyon grafiklerinde gözlenen uyumlu dağılım, yapay sinir ağı modelinin hem öğrenme sürecinde hem de daha önce karşılaşmadığı veriler üzerinde başarılı tahminler yapabildiğini


göstermektedir. Bu durum, modelin yalnızca ezberleme (memorization) değil, genelleme (generalization) yeteneğine sahip olduğunu ortaya koymaktadır. Özellikle test verisi üzerinde elde edilen $R = 0.9614$ değeri, çevresel veri yapısının karmaşıklığına rağmen modelin pratik uygulamalarda da geçerli sonuçlar verebileceğini göstermektedir.

Kullanılan Levenberg–Marquardt (trainlm) algoritması, bu başarıda belirleyici olmuştur. Literatürde de bu algoritmanın küçük-orta boyutlu veri setlerinde hızlı öğrenme sağlaması ve minimum hata ile sonuç üretmesi nedeniyle tercih edildiği belirtilmektedir (Hagan vd., 2014). Bu çalışmada elde edilen sonuçlar da bu görüşü desteklemektedir.

Sonuç olarak, Şekil 5.2'deki grafikler, modelin tahmin gücünü yalnızca sayısal metriklerle değil, grafiksel olarak da güçlü biçimde ortaya koymakta; böylece hem bilimsel hem de uygulamalı anlamda güvenilir bir yapay zeka yaklaşımı sunduğunu göstermektedir.

5.6.2. Hata dağılımının analizi

Modelin tahmin performansını daha ayrıntılı analiz etmek amacıyla, eğitim, doğrulama ve test veri kümeleri için hata dağılımı incelenmiştir. Şekil 5.3'de gösterilen histogram, her bir veri setinde elde edilen hataların frekanslarını sunmakta ve hataların sıfıra yakın bir dağılım gösterip göstermediğini görselleştirmektedir.



Şekil 5.3. Eğitim, doğrulama ve test verilerine ait hata histogramı

Histogramın yatay ekseninde hata değerleri (Hedef – Tahmin), dikey ekseninde ise bu hataların gözlenme sıklığı (frekansı) yer almaktadır.

“Mavi Çubuklar” Eğitim verisine ait mavi çubukların, genellikle sıfıra yakın hata değerleri etrafında yoğunlaştığı gözlemlenmiştir. Bu, modelin eğitim verilerinde oldukça iyi öğrendiğini göstermektedir.

Yeşil (doğrulama) ve kırmızı (test) verilerinde de dağılım simetriktir ve sıfırın etrafında kümelenmiştir. Bu durum, sistematik sapma olmadığını, yani modelin belirli bir yönde sürekli yanılmadığını (bias taşımadığını) ortaya koyar.

Hataların büyük çoğunluğunun -0.025 ile $+0.025$ arasında yoğunlaştığı görülmektedir. Bu da tahminlerin büyük kısmının hedefe oldukça yakın olduğunu ifade eder.


Bu histogram, YSA modelinin tüm veri kümelerinde tutarlı ve düşük hatalı tahminler ürettiğini destekleyen önemli bir görsel bulgudur. Modelin yalnızca eğitim verisinde değil, doğrulama ve test setlerinde de dengeli hata dağılımı göstermesi, genelleme başarısının yüksek olduğunu göstermektedir.

5.6.3. Performans eğrisi (MSE karşılaştırması)

Eğitim, doğrulama ve test aşamalarına ait ortalama karesel hata (MSE) değerlerinin iterasyonlara göre değişimini gösteren performans eğrisi, modelin öğrenme dinamiklerini ve genel uyum sürecini değerlendirmek açısından önemli bilgiler sunmaktadır. Bu grafikte doğrulama hatası, belirli bir iterasyonda minimuma ulaşmakta ve ardından sabitlenmektedir. Bu da erken durdurma mekanizmasının doğru noktada devreye girdiğini ve aşırı öğrenmenin önlendiğini göstermektedir.

5.6.4. Eğitim performansı grafiği (Performance plot)

Yapay sinir ağı modeli eğitilirken, her bir epoch sonunda eğitim, doğrulama ve test veri kümeleri için hesaplanan ortalama karesel hata (MSE) değerleri izlenmiş ve eğitim süreci boyunca nasıl değiştiği Şekil 5.4’te sunulmuştur.



Şekil 5.4. Eğitim, doğrulama ve test aşamalarına ait ortalama karesel hata (MSE) eğrilerinin analizi

Yorum:

•Eğitim hatası (mavi çizgi):

Eğitim boyunca sürekli azalmış, bu da modelin öğrenme sürecinde başarılı olduğunu göstermektedir.

•Doğrulama hatası (yeşil çizgi):

19. epoch'ta minimuma ulaşmış ve bu noktadan sonra artmaya başlamıştır. Bu bulgu, erken durdurma (early stopping) yönteminin uygun zamanda devreye girerek modelin aşırı öğrenme (overfitting) eğilimine girmesini başarılı şekilde engellediğini ortaya koymaktadır.

•Test hatası (kırmızı çizgi):


Eğitim sonrası yükselme eğilimine girmiş, ancak validasyonla benzer eğilim sergilemiştir. Bu durum, modelin genelleme kabiliyeti açısından dengeli bir davranış gösterdiğini düşündürmektedir.

Bu grafik, modelin hem öğrenme kapasitesini hem de genelleme yeteneğini aynı anda değerlendirmeye olanak sağlar. Doğrulama hatası 19. epoch'ta minimum değere ulaşmış ($MSE = 0.0049832$) ve ardından yükselmeye başlamıştır. Bu durum modelin optimum

öğrenmeyi sağladığı, fakat daha fazla eğitimle ezberleme riskine gireceğini açıkça göstermektedir.

5.6.5. Eğitim sürecine ait durum grafikleri (Training state)

Yapay sinir ağı modelinin eğitimi sırasında, ağırlıkların güncellenmesi, hata fonksiyonunun takibi ve erken durdurma kriterlerinin işleyişi, MATLAB ortamında elde edilen eğitim durumu grafikleri ile izlenmiştir. Şekil 5.5'te bu grafiklere ait bilgiler sunulmuştur.



Şekil 5.5. Eğitim sürecine ait gradient, mu ve validation kontrolleri grafikleri

Yorum:

1. Gradient (∇E):

Model eğitimi boyunca azalmış ve 69. epoch'ta 0.00046 seviyesine ulaşmıştır.

Bu, ağırlıklarının istikrarlı şekilde optimize edildiğini ve hata fonksiyonunun minimum seviyelere indirildiğini gösterir.

2. Mu (Levenberg-Marquardt parametresi):

Eğitim boyunca $1e-5$ düzeyinde sabit kalmıştır.

Algoritmanın dengeli çalıştığını ve ani sapmalara uğramadığını göstermektedir.

3. Validation Checks:

Validasyon hatası belirli bir süre iyileşme göstermeyince 50 tekrar sonra eğitim durmuştur.

Bu durum erken durdurma (early stopping) mekanizmasının düzgün çalıştığını ve aşırı öğrenmenin önüne geçildiğini kanıtlar.

Bu grafikler, geliştirilen YSA modelinin hem istikrarlı hem de kontrol edilebilir bir şekilde eğitildiğini ortaya koymaktadır. Eğitim sürecinin erken durdurulması, modelin sadece eğitim verisine değil, genelleme kapasitesine göre optimize edildiğini desteklemektedir. Böylece model, hem güvenilir hem de etkili sonuçlar elde edebilme yeteneği kazanmıştır.

5.7. PM₁₀ Tahmininde Yapay Sinir Ağı Yaklaşımları

Akkoyunlu vd. (2010) çalışmasında, YSA tabanlı SO₂ tahmin modelinde genel veri seti için IA değeri 0.922 olarak hesaplanmıştır. Bu sonuç, modelin gözlenen verilerle uyum düzeyinin yüksek olduğunu göstermektedir. Bununla birlikte, aynı model için R² değerinin 0.751 olması, modelin açıklayıcılığının orta düzeyde olduğunu ve tahmin performansının sınırlı da olsa tutarlı olduğunu göstermektedir.

Benzer şekilde, Almasri ve Kaluarachchi (2005), yer altı sularındaki nitrat dağılımını tahmin etmek amacıyla çok katmanlı YSA modelleri kurmuş ve modelin doğruluk düzeyinin, gizli katman sayısı ile bu katmanlardaki nöron sayısına bağlı olarak değiştiğini belirtmişlerdir. Ayrıca, farklı ağ yapılarının test edildiği çalışmada, aşırı öğrenme (overfitting) riskini azaltmak üzere en uygun yapının seçildiği vurgulanmıştır. Bu tez kapsamında da benzer bir yaklaşım izlenmiş; üç katmanlı yapı ve çeşitli transfer fonksiyonu kombinasyonları denenerek, düşük hata ile en iyi sonuç veren yapı tercih edilmiş ve aşırı öğrenme eğilimi azaltılmıştır.

5.7.1. Parametre seçimi açısından karşılaştırmalar

Bu çalışmada, modelde kullanılacak parametrelerin seçiminde çok değişkenli istatistiksel analiz sonuçları dikkate alınmıştır. Parametrelerin anlamlılık düzeyleri ve modele katkı potansiyelleri; t-istatistiği, korelasyon katsayısı ve temel bileşen analizi (PCA) gibi yöntemlerle değerlendirilmiştir. Bununla birlikte, bazı parametreler istatistiksel olarak

anlamalı olmasa da, literatürde sıklıkla kullanılması, fiziksel anlamlılığı veya deneysel olarak model performansına katkı sağlaması nedeniyle modelde tutulmuştur

5.7.2. Model performansı açısından literatürle uyum

MathWorks'un (2017) teknik belgelerine göre, Levenberg–Marquardt algoritması, özellikle küçük ve orta ölçekli veri kümelerinde hem yüksek doğruluk hem de hızlı öğrenme süresi açısından avantaj sağlamaktadır. Bu çalışma kapsamında kullanılan veri setinin boyutu ve algoritmanın performansı bu bilgiyle tutarlıdır. Model yalnızca 1 saniyede eğitilmiş ve çok düşük MSE ile sonuçlanmıştır, bu durum da literatürdeki önerileri desteklemektedir

Sonuç olarak, bu çalışmada elde edilen bulgular, hem tahmin başarımı hem de kullanılan yöntemlerin doğruluğu açısından literatürdeki benzer çalışmalarla paralellik göstermektedir. Modelin elde ettiği düşük hata oranları ve yüksek korelasyon katsayısı, uygulanan yapay sinir ağı mimarisinin çevresel tahminleme problemleri için uygun bir yaklaşım olduğunu doğrulamaktadır.

5.8. Modelin Güçlü ve Sınırlı Yönleri

Bu tez kapsamında geliştirilen YSA tabanlı PM_{10} tahmin modeli, hem modelleme tekniği hem de kullanılan parametrelerin analizi açısından güçlü yönleri sahiptir. Bununla birlikte, veri setinin özellikleri ve bazı yöntemsel sınırlamalar dikkate alındığında modelin çeşitli kısıtları da mevcuttur. Aşağıda bu yönler detaylı şekilde değerlendirilmektedir.

5.8.1. Modelin güçlü yönleri

- Yüksek Tahmin Başarısı: Eğitim ve test sonuçlarına göre modelin R^2 değeri 0.90 üzerinde, MSE değeri ise 0.00117 gibi oldukça düşük bir seviyede kalmıştır. Bu da modelin PM_{10} konsantrasyonlarını yüksek doğrulukla tahmin edebildiğini göstermektedir.

- Optimum Parametre Seçimi: T-ratio, Pearson korelasyon katsayısı ve Temel Bileşenler Analizi (PCA) gibi farklı istatistiksel yöntemler birlikte kullanılarak, modele anlamlı katkı sunan parametreler bilimsel olarak belirlenmiştir. Bu yaklaşım, modelin genelleme yeteneğini artırmıştır.

- Aşırı öğrenme riskini azaltmak amacıyla eğitim sürecinde erken durdurma (early stopping) yöntemi uygulanmış; doğrulama setinde 50 ardışık iterasyon boyunca performans

iyileşmesi gözlenmemesi durumunda eğitim işlemi otomatik olarak sonlandırılmıştır. Bu da modelin yalnızca öğrenilen veriyle değil, benzer fakat farklı verilerle de başarılı tahminler yapmasını sağlamıştır.

- Zaman ve Donanım Etkinliği: Eğitim süresi yalnızca 1 saniyede tamamlanmış ve bu durum sistem kaynaklarının verimli kullanıldığını göstermiştir. Eğitim süresi açısından hızlı olması, modelin gelecekte gerçek zamanlı sistemlerde de uygulanabilirliğini artırmaktadır.

5.8.2. Modelin sınırlı yönleri

- Modelin yüksek doğrulukta tahminler üretmesine rağmen bazı sınırlılıkları da bulunmaktadır. Bu sınırlılıklar hem veri yapısından hem de kullanılan yöntemsel yaklaşımlardan kaynaklanmaktadır.

- Tek Lokasyon Verisi Kullanımı: Bu çalışma yalnızca Erzurum Aziziye ilçesine ait 2024 yılına özgü verilerle sınırlıdır. Farklı coğrafi bölgelerdeki farklı topoğrafik, meteorolojik ve emisyon özellikleri dikkate alınmadığı için modelin genellenebilirliği sınırlı kalmaktadır. Daha geniş coğrafi veri kümeleri ile yapılacak karşılaştırmalı analizler modelin dış geçerliliğini artıracaktır.

- Zaman Serisi Yapısının Göz Ardı Edilmesi: Bu çalışmada 2024 yılına ait günlük veriler kullanılmış; her günün çevresel parametreleri, aynı günün PM₁₀ değerini tahmin etmek amacıyla model girişlerine aktarılmıştır. Zaman gecikmeli girişler (lagged variables) değerlendirmeye alınmamıştır. Bu durum, özellikle ardışık günlerdeki birikim etkilerinin modele yansıtılmasını sınırlayabilir.

- Parametre Kapsamının Sınırlılığı: Modele çevresel ve meteorolojik yalnızca sekiz değişken dâhil edilmiş olsa da, atmosferik basınç, kar örtüsü, topografya gibi bölgeye özgü diğer potansiyel etkileyiciler göz ardı edilmiştir. Bu durum modelin açıklayıcılık gücünü sınırlandırabilir.

- Alternatif Yöntemlerin Değerlendirilmemesi: Bu çalışmada yalnızca YSA yaklaşımı kullanılmıştır. Oysa destek vektör makineleri (SVM), gradyan artırma algoritmaları (GBM) veya fuzzy logic gibi yöntemlerin de karşılaştırmalı olarak modellenmesi, yönteme özgü avantaj ve dezavantajların belirlenmesi açısından faydalı olabilirdi.

5.9. Genel Değerlendirme

Bu çalışma, sınırlı kaynaklara rağmen PM_{10} tahmini için oldukça etkili ve uygulanabilir bir model ortaya koymuştur. Modelin başarısı, hem seçilen yapay sinir ağı yapısına hem de verilerin özenle hazırlanmasına dayanmaktadır. Ancak bu modelin daha geniş çapta geçerlilik kazanabilmesi için coğrafi ve zamansal çeşitlilik açısından genişletilmiş yeni çalışmalarla desteklenmesi gerekmektedir.

5.10. PM_{10} Tahmini İçin Lineer ve Doğrusal Olmayan Yaklaşımlar

DataFit yazılımı kullanılarak PM_{10} konsantrasyonunun tahmini amacıyla yapılan analizler sonucunda, modelleme sürecinde biri üssel (eksponansiyel) ve ikisi doğrusal (lineer) olmak üzere toplam üç farklı denklem önerilmiştir. Çalışma kapsamında elde edilen bu modelleme çıktıları Tablo 5.3’de detaylı olarak sunulmaktadır.

Tabloda yer alan modellerin karşılaştırılmasında özellikle determinasyon katsayısı (R^2) ile düzeltilmiş (R_a^2) değerleri öncelikli değerlendirme ölçütleri olarak dikkate alınmıştır. Bu iki istatistiksel ölçüt, modelin açıklayıcılık düzeyi hakkında önemli bilgiler sunmakta; aynı zamanda veri setinin büyüklüğünün yeterliliğine dair ipuçları vermektedir. R^2 ve R_a^2 değerlerinin birbirine yakın olması, modelin güvenilirliğinin yanı sıra veri sayısının da parametrik doğrulama için uygun seviyede olduğunu göstermektedir.

Tablo 6.3’de verilen sonuçlar incelendiğinde, bu iki katsayının oldukça benzer değerlere sahip olduğu görülmektedir. Bu durum, kullanılan veri setinin modelleme açısından yeterli dağılım ve hacme sahip olduğunu desteklemektedir. Sonuç olarak, elde edilen doğrusal ve doğrusal olmayan modellerin PM_{10} tahmininde geçerli bir referans teşkil ettiği söylenebilir.

Tablo 5.3. *PM₁₀ Konsantrasyonunun tahminine yönelik datafit yazılımı ile geliştirilen çoklu regresyon modelleri ve ilgili istatistiksel performans göstergeler*

Sıra	Model	SEE	SR	AR	RSS	R ²	R _a ²	NNI
1	$a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8 + i$	10.56	6.46×10^{-8}	2.46×10^{-10}	28285.10	0.893	0.890	1
2	$a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8$	10.634	34.83	0.13	28723.04	0.891	0.889	4
3	$\exp(a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8 + i)$	10.856	-80.77	-0.31	29938.50	0,890	0,883	6

SEE : Tahmindeki standart hata

SR : Hataların toplamı

AR : Ortalama bakiye hata

RSS : Hataların kareleri toplamı

R2 : Determinasyon katsayısı

Ra2 : Ayarlanmış çoklu determinasyon katsayısı

NNI : Uygulanan non-lineer iterasyon sayısı

Özet :

•NNI = 1 → Model tamamen doğrusal

- $NNI > 1 \rightarrow$ Model doğrusal olmayan öğeler içeriyor
- $NNI \geq 5-7 \rightarrow$ Karmaşık, dönüşümlü veya üstel fonksiyon içeriyor demektir

DataFit modeli sonuçlarının değerlendirilmesi kapsamında, en yüksek korelasyon katsayısına sahip olan çoklu doğrusal regresyon denkleme ait bulgular Tablo 6.4’de detaylı biçimde sunulmuştur. Bu tabloda, modelin regresyon katsayıları ile birlikte çeşitli istatistiksel performans ölçütlerine de yer verilmiştir.

Model doğrulama sürecinde dikkate alınan temel istatistiksel göstergelerden biri t oranı (t-ratio), diğeri ise anlamlılık düzeyini belirleyen p değeridir. t istatistiği değerinin yüksek, p değerinin ise düşük çıkması, ilgili değişkenin modele katkısının istatistiksel açıdan anlamlı olduğunu göstermektedir. Tablo 6.4 incelendiğinde, birçok parametrenin bu koşulları karşıladığı ve bu nedenle modelde anlamlı rol oynadığı görülmektedir.

Bunun yanı sıra, önceden sunulmuş olan Tablo 6.3’deki ön analiz sonuçları ile bu modelin bulguları kıyaslandığında, seçilen değişkenlerin uygunluğunun ve modelin genel geçerliliğinin doğrulandığı anlaşılmaktadır. Bu kapsamda, çoklu doğrusal regresyon modelin PM_{10} tahmininde deneysel verilerle güçlü bir uyum sergilediği ifade edilebilir.

Tablo 5.4. *PM₁₀ konsantrasyonu tahmininde deneysel verilerle en yüksek uyum gösteren çoklu regresyon modeli (Çoklu doğrusal regresyon model)*

Katsayı	Girdi Değişkeni	Standart Hata	t oranı	p değeri
A	x_1 = Günlük ort. buhar basıncı (hPa)	0,28	5,19	0,0
B	x_2 = Günlük güneşlenme süresi (saat)	0,27	-2,12	0,03
C	x_3 = SO ₂ konsantrasyonu (µg/m ³)	2,01	1,86	0,06
D	x_4 = Günlük ort. rüzgar hızı (m/s)	0,98	1,95	0,05
E	x_5 = Toplam yağış (mm)	0,18	-0,54	0,59
F	x_6 = Ortalama nispi nem (%)	0,09	0,09	0,93
G	x_7 = CO konsantrasyonu (µg/m ³)	7,41E-03	-5,21	0,0
H	x_8 = NO _x konsantrasyonu (µg/m ³)	6,64E-02	17,49	0,0
I	Sabit terim	6,34	1,98	0,05

Bu çalışmada gerçekleştirilen doğrusal regresyon analizleri sonucunda elde edilen çoklu doğrusal regresyon modellere ilişkin bulgular, Tablo 5.4 ve Tablo 5.7’de sunulmuştur. Bu tablolarda yer alan regresyon değişkenlerine ait t oranı (t-ratio) değerlerinin hem pozitif hem de negatif olduğu gözlemlenmiştir. t oranı, her bir değişkenin modele olan etkisinin, ilgili değişkenin standart hatasına oranı olarak hesaplanan sayısal bir ölçüttür.

Pozitif t oranı, ilgili değişkenin modele sinerjistik (destekleyici) katkı sunduğunu, negatif t oranı ise antagonistik (azaltıcı/negatif) bir etkisi olduğunu göstermektedir. Ancak bu etkiler, kullanılan modelin matematiksel yapısına doğrudan bağlıdır; yani aynı değişken farklı bir modelde farklı yönde etki gösterebilir. Bu nedenle, t oranlarının yorumlanmasında model türü ve yapısı mutlaka dikkate alınmalıdır.

Diğer yandan, regresyon modelinde yer alan değişkenlerin hedef değişken (örneğin PM₁₀) üzerindeki göreceli etkilerini daha güvenilir şekilde değerlendirmek için ANOVA (Varyans Analizi) sonuçlarına dayanan kareler toplamı değerleri incelenebilir. Bu yöntem,

değişkenlerin tahmin performansına olan yüzdesel katkılarını daha net ortaya koyabilmektedir.

Tablo 5.5'te ise PM₁₀ tahmininde en başarılı uyumu sağlayan çoklu regresyon modeline ilişkin tanımlayıcı bakiye (residual) hata istatistikleri sunulmuştur. Bu istatistikler, modelin tahmin hatalarının dağılımına dair bilgi vererek model doğruluğu hakkında ek değerlendirme yapılmasına olanak sağlamaktadır.

Tablo 5.5. Modelin bakiyeye dayalı hata istatistikleri

Bakiye hata istatistiği	Hesaplama	Regresyon sonuçları
Hata toleransı	$Y_a - Y_p$	
Hataların toplamı	$\sum_{i=1}^n Y_a - Y_p$	6.46×10^{-8}
Ortalama hata	$\frac{\sum_{i=1}^n Y_a - Y_p}{n}$	2.46×10^{-10}
Hataların toplamı (Mutlak)	$SSE = \sum_{i=1}^n Y_a - Y_p^2$	28285.10
Tahmindeki standart hata	$\sqrt{\frac{\sum_{i=1}^n Y_a - Y_p^2}{n - p}} = \sqrt{\frac{SSE}{n - p}}$	10.53

Açıklamalar:

- Y_a : Gözlenen (gerçek) değer
- Y_p : Modelin tahmin ettiği değer
- n : Gözlem sayısı (263)
- p : Modeldeki parametre sayısı (8)

5.11. Hata İstatistikleri ve Regresyon Sonuçlarının Yorumu

Tabloda verilen hata toleransı, hata toplamı, ortalama hata, hataların toplamı (SSE) ve tahmindeki standart hata değerleri, modelin tahmin performansını kapsamlı şekilde değerlendirmeye olanak sağlamaktadır.

5.11.1 Hata toleransı ($Y_a - Y_p$)

Bu, her bir gözlem için gerçek değerler ile model tahminleri arasındaki farktır. Tabloda hata toleranslarının toplamı yaklaşık 6.46×10^{-8} olarak verilmiştir ki bu, model hatalarının pozitif ve negatif değerlerinin birbirini neredeyse tamamen dengelediğini gösterir. Bu durum, modelin genel olarak tahminlerinde belirgin bir yönlü sapma olmadığını ortaya koyar.

5.11.2. Ortalama hata

Ortalama hata 2.46×10^{-10} gibi neredeyse sıfıra eşit bir değer olarak hesaplanmıştır. Bu çok küçük değer, model tahminlerinin genel olarak gerçek verilere çok yakın olduğunu ve hata sapmasının pratikte ihmal edilebilir düzeyde olduğunu gösterir.

5.11.3. Hataların toplamı (SSE)

Hataların toplamı, yani hata karelerinin toplamı 28285.10 olarak hesaplanmıştır. Bu değer, hataların büyüklüğünün toplamını gösterir ve modelin tahminlerinde bazı gözlemler için belirgin sapmalar olduğunu, ancak genel olarak kabul edilebilir düzeyde bir tahmin başarısı sergilediğini göstermektedir.

Bu değer, modelin tüm veri seti üzerindeki toplam hata miktarını göstermekte olup, sayısal büyüklüğü tek başına yorumlanmamalıdır. 263 gözlem dikkate alındığında, SSE değeri modelin bazı gözlemlerde belirgin sapmalar ürettiğini, ancak genel olarak kabul edilebilir düzeyde bir tahmin başarısı sergilediğini göstermektedir.

5.11.4. Tahmindeki standart hata

Tahmindeki standart hata 10.53 olarak bulunmuştur. Bu değer, modelin tahminlerinin gerçek değerlerden ortalama ne kadar sapabileceğini, yani hata dağılımının standart sapmasını ifade eder.

Yaklaşık 10.53 standart sapma, çevresel modeller için kabul edilebilir bir hata seviyesi olarak değerlendirilebilir.

5.11.5. Genel değerlendirme

Tablodaki sonuçlar, modelin hem ortalama hem de toplam hata açısından başarılı performans gösterdiğini ortaya koymaktadır.

Hata toleransı ve ortalama hata değerlerinin sıfıra çok yakın olması, modelin tahminlerinde belirgin bir yönlü sapma olmadığını gösterirken, SSE ve tahmindeki standart hata, bazı gözlemler için daha büyük sapmaların varlığını göstermektedir.

Bu sonuçlar ışığında, model tahminlerinin genel olarak güvenilir olduğu, ancak iyileştirme için bazı gözlemler üzerinde odaklanılabileceği söylenebilir.

5.12. Tahmin Sonuçlarının İstatistiksel Değerlendirmesi

Bu bölümde, YSA ve DataFit yazılımı ile gerçekleştirilen modelleme çalışmalarına ait veri setlerinin istatistiksel yönden analizleri sunulmaktadır. PM_{10} konsantrasyonu için elde edilen tahmin sonuçları, test veri kümeleri temel alınarak karşılaştırmalı olarak değerlendirilmiştir.

Analizler kapsamında, tahmin performanslarını değerlendirmek amacıyla çeşitli istatistiksel ölçütler kullanılmış ve her iki yöntemin başarımları düzeyleri detaylı olarak irdelenmiştir. Alt başlıklarda, hem PM_{10} konsantrasyonu tahminine yönelik oluşturulan modellerin test sonuçlarına dayalı istatistiksel performanslarının ayrıntılı bir şekilde karşılaştırılması yapılacaktır.

5.12.1. PM_{10} tahmin sonuçlarının istatistiksel incelemesi

Bu alt bölümde, PM_{10} tahmini amacıyla oluşturulan YSA modeli ile DataFit yazılımı aracılığıyla elde edilen modellerin istatistiksel performans karşılaştırması yapılmıştır. Karşılaştırmaya ilişkin bulgular Tablo 5.6’da özetlenmektedir.

Tablodan elde edilen bulgular incelendiğinde, YSA ile oluşturulan modelin hem determinasyon katsayısı (R^2) hem de korelasyon katsayısı (R) bakımından, DataFit ile elde edilen modele kıyasla daha yüksek değerlere ulaştığı görülmektedir. Bu durum, YSA’nın mevcut veri seti için daha güçlü bir öngörü kapasitesine sahip olduğunu göstermektedir.

Buna ek olarak, ortalama mutlak hata (MAE), kök ortalama karesel hata (RMSE), sistematik hata (RMSEs), sistematik olmayan hata (RMSEu) ve görelî sistematik hata oranı (PSE) gibi hata ölçütleri incelendiğinde, yapay sinir ağı modelinin daha düşük hata değerleri üretmesi, bu modelin DataFit tabanlı modele kıyasla daha yüksek tahmin başarısına sahip olduğunu göstermektedir.

Ayrıca, model doğruluğunu değerlendirmede kullanılan uyumluluk indeksi (IA) ve 2 kat doğruluk faktörü (FA2) gibi performans göstergeleri de analiz kapsamına alınmıştır. Bu iki parametre, modellerin genel doğruluğunu yansıtmakla birlikte, diğer hata ölçütleri kadar belirleyici olmayabilir. Ancak, her iki yöntemde de bu değerlerin 1'e oldukça yakın olması, tahminlerin genel anlamda yüksek doğrulukla yapıldığını göstermektedir. Yine de YSA modeli, bu kriterlerde de DataFit modeline kıyasla bir miktar üstünlük sağlamıştır.



Tablo 5.6. *PM10 tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu*

İstatistiksel Performans Göstergeler	Matematiksel gösterim	ANNs Model	Çoklu Doğrusal Regresyon Model
Determinasyon katsayısı (R ²):	$R^2 = \frac{(\sum_{i=1}^n (O_i - O_m)(P_i - P_m))^2}{\frac{1}{n} \sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}$	0.96	0.89
Korelasyon katsayısı (R):	$R = \frac{\sum_{i=1}^n (O_i - O_m)(P_i - P_m)}{(n-1)(\sigma_o - \sigma_p)}$	0.98	0.95
Ortalama karesel hatanın karekökü (RMSE):	$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}}$	6.33	10.37
Sistemik RMSE (RMSE _s):	$RMSE_s = \sqrt{\frac{\sum_{i=1}^n (O_i - P_{reg})^2}{n}}$	1.05	3.39
Sistemik olmayan RMSE (RMSE _u):	$RMSE_u = \sqrt{\frac{\sum_{i=1}^n (P_i - P_{reg})^2}{n}}$	6.25	9.80
Sistemik hata oranı (PSE):	$PSE = \frac{(RMSE_s)^2}{(RMSE_u)^2}$	0.03	0.12
Ortalama Mutlak Hata (MAE):	$MAE = \frac{\sum_{i=1}^n O_i - P_i }{n}$	4.49	7.26
Uyumluluk indeksi (IA):	$IA = 1 - \left[\frac{\sum_{i=1}^n (P_i - O_i)}{\sum_{i=1}^n (P_i - O_m + O_i - O_m)} \right]$	0.99	0.97
Fraksiyonel Varyans (FV):	$FV = \frac{2 \times (\sigma_o - \sigma_p)}{(\sigma_o + \sigma_p)}$	-0.0006	0.06
2'nin Faktörü (FA2):	$FA2 = \frac{\sum_{i=1}^n \frac{O_i}{P_i}}{n}$	0.99	0.95

PM10 Tahmin Modellerinin Performans Analizi ve Gösterge Yorumları

• Bu bölümde, PM₁₀ konsantrasyonunun tahmini amacıyla geliştirilen iki farklı modelin performansları değerlendirilmiştir: YSA modeli ve çoklu doğrusal regresyon modeli. Modeller, çeşitli istatistiksel performans göstergeleri kullanılarak karşılaştırılmış ve elde edilen bulgular detaylı olarak analiz edilmiştir.

- Tablo 5.6’da yer alan performans göstergeleri; determinasyon katsayısı (R^2), korelasyon katsayısı (R), ortalama mutlak hata (MAE), ortalama karesel hatanın karekökü (RMSE), uyum indeksi (IA), sistematik ve sistematik olmayan hatalar (RMSES, RMSEU), iki faktörü (FA2), fraksiyonel varyans (FV) ve sistematik hata oranı (PSE) gibi ölçütleri içermektedir. Aşağıda bu göstergeler açıklanmakta ve yorumlanmaktadır.

5.12.1.1. Determinasyon katsayısı (R^2)

• R^2 , bağımsız değişkenlerin bağımlı değişken üzerinde açıklayabildiği varyans oranını ifade eder ve 0 ile 1 arasında değer alır. YSA modelinde $R^2 = 0.96$ olarak bulunmuştur; bu, modelin verideki değişimin %96.13’ünü açıkladığını gösterir. Regresyon modelinde ise bu oran %89,3’tür ($R^2 = 0.89$). Bu sonuçlar, YSA modelinin daha yüksek bir açıklayıcılığa sahip olduğunu ortaya koymaktadır.

5.12.1.2. Korelasyon katsayısı (R)

•Korelasyon katsayısı, gözlenen ve tahmin edilen değerler arasındaki doğrusal ilişkiyi ölçer. YSA modeli için $R = 0.98$, regresyon modeli için $R = 0.95$ olarak hesaplanmıştır. YSA modeli, veriler arasındaki ilişkiyi daha iyi yansıtmaktadır.

5.12.1.3. Ortalama mutlak hata (MAE)

•MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını temsil eder. YSA modeli için $MAE = 4.49 \mu\text{g}/\text{m}^3$, regresyon modeli için ise $7.26 \mu\text{g}/\text{m}^3$ olarak bulunmuştur. Bu değerler, YSA modelinin daha düşük sapmalarla tahmin yaptığını göstermektedir.

5.12.1.4. Ortalama karesel hata (RMSE) ve ortalama kare hata (MSE)

•RMSE, tahmin hatalarının karelerinin ortalamasının kareköküdür. MSE ise bu karelerin ortalamasıdır. YSA modelinde $RMSE = 6.33 \mu\text{g}/\text{m}^3$, regresyon modelinde ise $10.37 \mu\text{g}/\text{m}^3$ ’tür. Bu sonuç, YSA modelinin daha dengeli ve düşük hatalı tahminler yaptığını göstermektedir.

5.12.1.5. Sistematik (RMSES) ve sistematik olmayan hata (RMSEU)

•Toplam hata iki bileşene ayrılarak incelenmiştir. RMSES modelin yapısal sapma düzeyini, RMSEU ise rastgele hataları ifade eder. YSA için $RMSES = 1.05$, $RMSEU = 6.25$; regresyon için $RMSES = 3.39$, $RMSEU = 9.80$ 'dir. Bu değerler, YSA modelinin hem sistematik hem de rastgele hata bileşenlerinde daha başarılı olduğunu göstermektedir.

5.12.1.6. Sistematik hata oranı (PSE)

•PSE, sistematik hataların toplam hatalara oranını gösterir. YSA modeli için bu oran 0.03, regresyon modeli için 0.12'dur. YSA modeli sistematik hata oranını daha iyi yönetmektedir.

5.12.1.7. Uyum indeksi (IA)

•IA, tahmin edilen ve gözlenen değerler arasındaki yapısal uyumu değerlendirir. 1'e ne kadar yakınsa modelin uyumu o kadar güçlüdür. YSA modeli için $IA = 0.990$, regresyon modeli için $IA = 0.97$ olarak hesaplanmıştır.

5.12.1.8. İki faktörü (FA2) ve fraksiyonel varyans (FV)

•FA2, tahmin değerlerinin gözlenen değerlerin %50 ila 2 katı arasında kalan oranını verir. YSA için $FA2 = 0.99$, regresyon modeli için 1.084'tür. FV ise varyans benzerliğini gösterir. YSA için $FV = -0.00055$, regresyon için 0.06'dır. YSA modeli varyans açısından daha dengeli tahminler yapmaktadır.

5.12.1.9. Genel değerlendirme

• Elde edilen tüm metrikler değerlendirildiğinde, YSA modelinin PM_{10} tahmini konusunda daha yüksek doğruluk ve uyum sunduğu görülmektedir. Özellikle düşük hata değerleri (MAE, RMSE, MSE), yüksek korelasyon ve uyum katsayıları (R , R^2 , IA) ile YSA modeli, veri setindeki karmaşık yapıyı daha iyi öğrenebilmekte ve genelleyebilmektedir. Regresyon modeli daha basit ve anlaşılır yapısıyla kabul edilebilir tahminler sunsa da, YSA'nın sunduğu performansa ulaşamamıştır. Bu nedenle, PM_{10} tahmininde YSA modelinin tercih edilmesi önerilmektedir.

5.13. Lineer ve Doğrusal Olmayan Modelleme Karşılaştırması

Bu bölümde, YSA ile modellenmiş veri seti, DataFit yazılımı aracılığıyla yeniden analiz edilerek iki yöntem arasında karşılaştırmalı bir değerlendirme yapılması amaçlanmıştır. DataFit, tıpkı YSA gibi yüksek düzeyde korelasyon sağlayabilen bir araç olmakla birlikte, uygulama mantığı ve yapısı itibarıyla bazı farklılıklar barındırmaktadır.

YSA ile elde edilen başarılı modelin tahmin kapasitesini doğrulamak amacıyla aynı veri seti, DataFit ortamında hem lineer hem de doğrusal olmayan (non-lineer) analizlere tabi tutulmuştur. Böylece, yapay sinir ağı ile elde edilen tahmin sonuçları, geleneksel regresyon yöntemlerinin çıktılarıyla karşılaştırmalı olarak değerlendirilmiştir.

Bununla birlikte, literatürde genel kabul gören bir görüş olarak, geleneksel regresyon modellerinin tahmin başarımının YSA gibi esnek ve çok katmanlı öğrenme yapılarından daha yüksek olması beklenmemektedir. YSA'nın adaptif öğrenme kapasitesi sayesinde yeni verilere hızla uyum sağlayabilmesi önemli bir avantajdır. Buna karşılık DataFit'te modelin güncellenmesi için genellikle yeni bir denklemin oluşturulması gerekmektedir. Bu özellik, yapay sinir ağlarını hem esnek yapısı hem de uygulama kolaylığı bakımından avantajlı bir yöntem olarak öne çıkarmaktadır.

Ayrıca, DataFit programının sunduğu karmaşık matematiksel modellerin, uygulamada doğrudan kullanılabilirliği sınırlı olabilir. Bu nedenle, her ne kadar korelasyon katsayıları tatmin edici olsa da, pratikte YSA tabanlı modeller daha avantajlı bir alternatif olarak öne çıkmaktadır.

Bir sonraki bölümde, DataFit kullanılarak PM10 verileri üzerinden yapılan analizlerin sonuçları ve elde edilen denklemler detaylı biçimde sunulmaktadır.

YSA'ların çevresel sistemlerdeki karmaşık ve doğrusal olmayan ilişkileri modellemede geleneksel yöntemlere kıyasla daha esnek ve etkili olduğunu belirtmiştir (Gardner vd., 1998).

Ayrıca YSA modelleri, zaman içinde değişen çevresel dinamiklere uyum sağlama potansiyeline sahiptir. Adaptif öğrenme mekanizmaları sayesinde yeni verilerle kolayca yeniden eğitilerek güncel tahmin performansını sürdürebilirler. Buna karşılık regresyon modelleri, yeni koşullara uyum sağlayabilmek için baştan modellenmeyi gerektirir. Bu yönüyle YSA, özellikle çevresel veri analizinde dinamik sistemlerin modellenmesinde daha esnek ve güçlü bir alternatif sunmaktadır.

Sonuç olarak, yalnızca korelasyon katsayısı ya da MSE gibi performans göstergeleri değil, aynı zamanda yapısal esneklik, adaptif kapasite ve çok değişkenli sistemleri temsil edebilme yeteneği açısından da YSA tabanlı modeller, çevre mühendisliği uygulamaları için daha uygun ve sürdürülebilir bir modelleme yaklaşımı olarak değerlendirilmektedir.

Tablo 5.7. Performans göstergeleri


Performans Göstergesi	YSA Modeli	Çoklu Doğrusal Regresyon Model
R²	0.96	0.89
R	0.98	0.95
MAE	4.49	7.26
RMSE	6.33	10.37
RMSE_s	1.05	3.39
RMSE_u	6.25	9.80
PSE	0.03	0.12
IA	0.99	0.971
FV	-0.00055	0.06
FA2	0.994	0.95

5.14. Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması

Bu bölümde, YSA modeli tarafından tahmin edilen PM₁₀ değerleri ile gözlemlenen gerçek değerler karşılaştırılmıştır. Elde edilen regresyon grafikleri, modelin doğruluk düzeyinin hem görsel hem de istatistiksel olarak değerlendirilmesini sağlamaktadır.

5.14.1. PM₁₀ Konsantrasyonu Tahmini

Bu çalışmanın bu bölümünde, MATLAB ortamında geliştirilen YSA modeli, 2024 yılına ait Erzurum ili Aziziye ilçesi için seçilen meteorolojik ve hava kirliliği parametreleri kullanılarak PM₁₀ konsantrasyonunun tahmin edilmesinde uygulanmıştır. Şekil 5.6'da deneysel (ölçülen) PM₁₀ konsantrasyonu ile YSA modeli tarafından simüle edilen PM₁₀ konsantrasyonu (eğitim, doğrulama ve test) arasındaki görsel uyumu ve korelasyonu göstermektedir.



Şekil 5.6. *PM10 Konsantrasyonu tahmininde YSA simülasyonları (eğitim (a), doğrulama (b) ve test (c)) ile deneyisel veriler arasındaki karşılık gelen görsel uyumlar ve korelasyonlar.*

Şekil 5.6'ten görüldüğü üzere, önerilen YSA modeli yüksek ve tatmin edici bir tahmin performansı sergilemiştir. Bu başarı, atmosferik kirleticilerin oluşumu ve dağılımı gibi oldukça karmaşık bir sistemde, meteorolojik ve hava kirliliği atfedilebilir.

6. SONUÇ VE ÖNERİLER

6.1. Genel Değerlendirme ve Elde Edilen Bulgular

Bu tez çalışmasında, 2024 yılına ait Erzurum ili Aziziye ilçesine ait günlük hava kalitesi ve meteorolojik veriler kullanılarak PM_{10} konsantrasyonunun tahmini amaçlanmıştır. Modelleme sürecinde hem geleneksel istatistiksel yöntemler hem de yapay zekâ temelli yaklaşımlar bir arada değerlendirilmiş; özellikle YSA algoritmaları MATLAB yazılımı ile uygulanmış, DataFit yazılımı ile oluşturulan doğrusal olmayan regresyon modelleriyle karşılaştırmalı olarak analiz edilmiştir.

Girdi değişkenlerinin PM_{10} üzerindeki etkilerini değerlendirmek amacıyla t-ratio, Pearson korelasyon katsayısı ve Temel Bileşenler Analizi (PCA) yöntemleri birlikte kullanılmış; Ancak nihai değişkenler çevresel bilgi, literatür ve modelleme deneyimi ışığında (buhar basıncı, güneşlenme süresi, rüzgar hızı, toplam yağış, nispi nem, SO_2 , CO ve NO_x) nihai modellemede dikkate alınmıştır.

YSA modelleri MATLAB ortamında Levenberg-Marquardt algoritması (trainlm) ile eğitilmiş; eğitim, doğrulama ve test kümelerine %70-%15-%15 oranlarıyla ayrılmıştır. Modelin en iyi performans gösterdiği yapı, $MSE \approx 0.00117$ değeri ile erken durdurma mekanizmasıyla belirlenmiş, doğrulama verisinde optimum başarıya 19. iterasyonda ulaşılmıştır. Elde edilen determinasyon katsayısı ($R^2 \approx 0.96$), yüksek korelasyon ve düşük hata metrikleri (MAE, RMSE, IA) modelin güvenilirliğini desteklemiştir. Özellikle IA değerinin 0.90'ın üzerinde olması, modelin başarılı bir şekilde tahmin yeteneğine sahip olduğunu göstermektedir. Benzer şekilde, Akkoyunlu vd. (2010) çalışmasında da YSA tabanlı SO_2 tahmin modelinde IA değeri 0.92 olarak hesaplanmış ve modelin hem doğruluk hem de gözlenen verilerle yüksek uyum düzeyine sahip olduğu belirtilmiştir.

Buna karşılık, DataFit ile gerçekleştirilen non-lineer regresyon analizlerinde elde edilen en yüksek korelasyon katsayısı 0.95 olup, üç farklı formülasyondan çoklu doğrusal regresyon model öne çıkmıştır. Ancak bu modelin yeniden eğitim gerektirmesi, güncel verilerle esnek şekilde çalışamaması ve düşük genelleme kapasitesi nedeniyle, uygulama açısından YSA modeline göre daha az avantajlı olduğu sonucuna ulaşılmıştır.

6.2. Literatüre Katkı ve Modelin Güçlü Yönleri

Bu çalışmanın özgün yönü, PM_{10} konsantrasyon tahmininde hem istatistiksel hem de yapay zekâ temelli yaklaşımların birlikte uygulanması; parametre seçiminin çok kriterli yöntemlerle yapılması ve bu sürecin detaylı grafik analizleriyle desteklenmesidir. Özellikle YSA modellerinin, geleneksel regresyon yöntemleriyle karşılaştırılarak değerlendirilmesi ve güncel veri ile yerel bağlamda uygulanması, çalışmayı literatürdeki benzerlerinden ayırmaktadır.

Bu çalışmanın öne çıkan yönlerinden biri de, çok kriterli parametre seçimi yöntemlerinin birlikte uygulanarak çevresel bir probleme yönelik optimize edilmiş bir YSA modeli geliştirilmesidir. Literatürde çoğunlukla tek yöntemle yapılan parametre seçimlerine kıyasla bu yaklaşım daha kapsamlı bir analiz imkânı sunmaktadır.

Yapay Sinir Ağı modelinin güçlü yönleri şunlardır:

- Anlamlı ve çevresel temsiliyeti yüksek değişkenlerin çok kriterli yöntemlerle belirlenmesi,
- Aşırı öğrenmenin erken durdurma mekanizmasıyla başarılı şekilde önlenmesi,
- Eğitim, doğrulama ve test verilerinin dengeli oranlarda ayrılması sayesinde genelleme yetisinin korunması,
- Farklı nöron sayıları ve aktivasyon fonksiyonlarının denenebilmesi sayesinde sistemin kararlılığı ve tahmin doğruluğunun artırılması,
- Yeni verilerle güncellenebilir olması sayesinde modelin sürdürülebilirliğinin sağlanması,
- Çok katmanlı yapısının sağladığı derin öğrenme kabiliyeti sayesinde yüksek genelleme başarısının elde edilmesi.

Ayrıca, modelin performans değerlendirmesinde çok sayıda hata metriklerinin (MSE, RMSE, MAE, IA, FA2 vb.) birlikte kullanılması, analizlerin sadece tek bir kritere bağlı kalmaksızın çok yönlü değerlendirilmesini sağlamıştır (Yetilmezsoy ve Sapçı-Zengin, 2009).

Bu çalışmada kullanılan bir diğer yöntem olan DataFit yazılımı ile gerçekleştirilen doğrusal olmayan regresyon analizleri de, modelleme sürecine karşılaştırmalı bir bakış kazandırmıştır. Özellikle çoklu doğrusal regresyon formülasyonunun öne çıktığı bu yöntemle elde edilen korelasyon katsayısı 0,95 olarak bulunmuştur.

DataFit'in parametrik yapısı ve grafiksel ara yüzü sayesinde hızlı ve kullanıcı dostu bir analiz süreci sağlanmıştır. Ancak, yeniden eğitim gerektirmesi, esnek güncellenebilirlikten yoksun oluşu ve düşük genelleme kapasitesi gibi sınırlılıklar nedeniyle, özellikle çevresel değişkenlerin dinamik yapısını modellemede Yapay Sinir Ağı yaklaşımına kıyasla daha az avantajlı bulunmuştur. Bu karşılaştırma, çalışmada uygulanan farklı modelleme tekniklerinin güçlü ve zayıf yönlerini ortaya koyarak literatüre katkı sağlamaktadır.

6.3. Öneriler

Bu tez çalışmasından elde edilen bulgular ışığında aşağıdaki öneriler geliştirilmiştir:

1. Veri Çeşitliliği Artırılmalıdır: Model yalnızca 2024 yılı Erzurum Aziziye verilerine dayanmakta olup, farklı yıllar ve bölgelerden elde edilecek veri setleriyle test edilerek genelleme kabiliyeti artırılabilir.

2. Farklı Yapay Zekâ Algoritmalarıyla Karşılaştırma Yapılmalıdır: YSA dışında SVM, Karar Ağaçları (DT), Rastgele Ormanlar (RF) gibi yöntemlerin uygulanması, YSA'nın avantajlarını daha net ortaya koyabilir.

3. Mevsimsel Etkiler Modellenmelidir: PM_{10} konsantrasyonlarındaki mevsimsel değişimlerin modele entegre edilmesi, doğruluk düzeyini yükseltebilir.

4. Modelin Güncellenebilirliği Sağlanmalıdır: Literatürde vurgulandığı üzere, YSA modellerinin çevresel koşullardaki değişime adaptasyon kabiliyeti nedeniyle periyodik yeniden eğitim önerilmektedir (Almasri ve Kaluarachchi, 2005).

5. Parametre Optimizasyonu Geliştirilebilir: Değişken sayısının azaltılmasıyla model sadeleştirilebilir; ancak bu yapılırken temsiliyet gücünün zayıflamamasına dikkat edilmelidir.

6. DataFit ile Karşılaştırmalar Derinleştirilebilir: Bu çalışmada geliştirilen YSA modelleri ile DataFit tabanlı non-lineer regresyon modelleri karşılaştırılmıştır. Elde edilen sonuçlara göre, DataFit ile belirlenen çoklu doğrusal regresyon formülasyonunun korelasyon katsayısı 0.95 olup güçlü bir yapı sunmasına rağmen; yeniden modelleme gerekliliği ve sınırlı esneklik nedeniyle YSA'nın daha dinamik ve uygulamaya uygun bir yöntem olduğu görülmüştür.

7. Aktivasyon Fonksiyonları Çeşitlendirilebilir: Bu çalışmada kullanılan tansig fonksiyonu yerine log-sigmoid, ReLU gibi alternatif aktivasyonlar da denenerek performans analizleri yapılabilir.

8. YSA Tabanlı Hibrit Modeller Geliştirilebilir: Neuro-fuzzy sistemler, genetik algoritmalarla desteklenmiş YSA gibi hibrit yaklaşımların geliştirilmesiyle model performansı daha ileri taşınabilir.

9. Tersine Tahmin Uygulamaları (Inverse Modeling): PM_{10} yerine diğer çevresel parametrelerin de tahmini hedeflenerek yeni YSA modelleri oluşturulabilir.

10. Gerçek Zamanlı Sistemlere Entegrasyon Sağlanmalıdır: Elde edilen model, yerel yönetimler tarafından erken uyarı mekanizmalarına entegre edilerek halk sağlığı için etkin bir karar destek aracı olarak kullanılabilir.

6.4. Bölgesel ve Coğrafi Faktörlere Dayalı Öneriler

Erzurum'un çanak şeklindeki topoğrafyası ve düşük hava sirkülasyonu, PM_{10} kirleticisinin atmosferde birikmesini artıran önemli bir etkidir. Bu nedenle, ileride yapılacak çalışmalarda meteorolojik parametrelerle birlikte topoğrafik verilerin (rakım, eğim, vadi yönü vb.) de modele dâhil edilmesi önerilmektedir. Ayrıca yalnızca Aziziye istasyonu değil, Erzurum merkezdeki tüm istasyon verilerinin birlikte değerlendirilmesi, bölgesel taşınımın ve yerel kirlenme dinamiklerinin daha doğru biçimde belirlenmesine katkı sağlayacaktır.

Doğu ve Güneydoğu Anadolu Bölgeleri'nde yer alan hava kalitesi izleme istasyonlarının sayısı genel olarak yeterli görünse de, istasyonlar arasında ölçülen kirletici parametre türleri bakımından farklılıklar bulunmaktadır. Bazı istasyonlarda sınırlı sayıda kirletici ölçülürken, bazı istasyonlar daha kapsamlı veri sağlamaktadır. Bu durum, bölgesel ölçekte yapılan modelleme çalışmalarında veri setlerinin karşılaştırılabilirliğini, bütünlüğünü ve genellenebilirliğini kısıtlayan önemli bir unsurdur.

Ayrıca, bu tez çalışmasında kullanılan veri setinin yalnızca tek bir istasyona (Aziziye) ve tek bir yıla (2024) ait olması, modelin uzun dönemli eğilimleri ve farklı mekânsal koşulları temsil etmesini kısıtlamaktadır. Veri sayısının azlığı, elde edilen sonuçların genellenebilirliğini ve bölgesel ölçekte karşılaştırılabilirliğini sınırlandıran başlıca unsurlardan biridir.

6.5. Genel Sonuç

Bu tez kapsamında gerçekleştirilen analizler, PM_{10} gibi çevresel kirleticilerin öngörülmesinde Yapay Sinir Ağı tabanlı modellerin yüksek doğruluk ve esneklik sunduğunu

ortaya koymuřtur. zellikle YSA'nın doęrusal olmayan iliřkileri modelleme yeteneęi, ok deęiřkenli veri setleriyle uyumu ve yeni verilerle kolayca gncellenebilmesi, bu yntemi evresel tahmin uygulamaları aısından srdrlebilir bir zm haline getirmiřtir. İleriye dnk olarak, geliřtirilen modelin daha geniř ve eřitlendirilmiř veri setleriyle test edilmesi, gerek zamanlı karar destek sistemlerine entegrasyon aısından nemli frsatlar sunmaktadır.



KAYNAKÇA

- Abdullah, S., Ismail, M., Ahmed, A. N., & Abdullah, A. M. (2019). "Forecasting particulate matter concentration using linear and non-linear approaches for air quality decision support." *Atmosphere*, 10(11), 667.
- Akkoyunlu, A., Yetilmezsoy, K., Erturk, F., & Oztemel, E. (2010). "A neural network-based approach for the prediction of urban SO₂ concentrations in the Istanbul metropolitan area." *International Journal of Environment and Pollution*, 40(40), 301–321.
- Alam, M. S., & McNabola, A. (2015). "Exploring the modeling of spatiotemporal variations in ambient air pollution within the land use regression framework: Estimation of PM₁₀ concentrations on a daily basis." *Journal of the Air & Waste Management Association*, 65(7), 628–640.
- Almasri, M. N., & Kaluarachchi, J. J. (2005). "Modular neural networks to predict the nitrate distribution in groundwater using the on-ground nitrogen loading and recharge data." *Environmental Modelling & Software*, 20(7), 851–871.
- Antanasijević, D. Z., Ristić, M. Đ., Perić-Grujić, A. A., & Pocajt, V. V. (2013). "Forecasting human exposure to PM₁₀ at the national level using an artificial neural network approach." *Journal of Chemometrics*, 27(5), 153–159.
- Birim, N. G., Turhan, C., Atalay, A. S., & Gokcen Akkurt, G. (2023). "The influence of meteorological parameters on PM₁₀: A statistical analysis of an urban and rural environment in Izmir/Türkiye." *Atmosphere*, 14(3), 421.
- Cappa, C. D., Jathar, S. H., Kleeman, M. J., Docherty, K. S., Jimenez, J. L., Seinfeld, J. H., & Wexler, A. S. (2016). "Simulating secondary organic aerosol in a regional air quality model using the statistical oxidation model–Part 2: Assessing the influence of vapor wall losses." *Atmospheric Chemistry and Physics*, 16(5), 3041–3059.
- Ceylan, Z., & Bulkan, S. (2018). "Forecasting PM₁₀ levels using ANN and MLR: A case study for Sakarya City." *Global NEST Journal*, 20(2), 281–290.
- Chaloulakou, A., Grivas, G., & Spyrellis, N. (2003). "Neural network and multiple regression models for PM₁₀ prediction in Athens: A comparative assessment." *Journal of the Air & Waste Management Association*, 53(3), 325–334.
- Çakır, S., & Sita, M. (2020). "Evaluating the performance of ANN in predicting the concentrations of ambient air pollutants in Nicosia." *Atmospheric Pollution Research*, 11(12), 2327–2334.
- Dockery, D. W., & Pope, C. A. (1994). "Acute respiratory effects of particulate air pollution." *Annual Review of Public Health*, 15(1), 107–132.
- Ersoy, M., & Karal, Y. (2012). Yapay sinir ağları ve insan beyni. Akademik Bilişim 2012 – XIV. Akademik Bilişim Konferansı Bildirileri, 1–6. Uşak Üniversitesi.

European Commission. (2024). Directive (EU) 2024/2881 of the European Parliament and of the Council of 13 May 2024 on ambient air quality and cleaner air for Europe. Official Journal of the European Union.

Gardner, M. W., & Dorling, S. R. (1998). "Artificial neural networks (the multilayer perceptron)—A review of applications in the atmospheric sciences." *Atmospheric Environment*, 32(14–15), 2627–2636.

Gardner, M. W., & Dorling, S. R. (2000). "Statistical surface ozone models: An improved methodology to account for non-linear behavior." *Atmospheric Environment*, 34(1), 21–34.

Gündoğdu, S. (2020). "Comparison of static MLP and dynamic NARX neural networks for forecasting of atmospheric PM10 and SO2 concentrations in an industrial site of Turkey." *Environmental Forensics*, 21(3), 245–258.

Hagan, M. T., Demuth, H. B., Beale, M. H., and De Jesús, O. (2014). *Neural network design* (2nd ed.). Martin Hagan and Howard Demuth.

Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.

Kakıcı, A. (2009). *Yapay Sinir Ağlarına Giriş*. Erişim: Wayback Machine.

Koşan, Z., Kavuncuoğlu, D., Çalıkoğlu, E. O., & Yerli, E. B. (2018). "Evaluation of air pollution by PM10 and SO2 levels in Erzurum province, Turkey: Descriptive study." *Journal of Surgery and Medicine*, 2(3), 265–268.

McCulloch, W. S., & Pitts, W. (1943). "A logical calculus of the ideas immanent in nervous activity." *The Bulletin of Mathematical Biophysics*, 5, 115–133.

Müezzinoğlu, A., 2000. *Hava Kirliliği ve Kontrolü Esasları*. Dokuz Eylül Yayınları, İzmir.

Olçay, S. (2023). Kirleticiler. In H. Toros (Ed.), *Hava Kirliliği, İklim Krizi ve Sağlık Etkileri* (s. 100). İstanbul: Türkiye Solunum Araştırmaları Derneği Yayınları.

Özdemir, U., & Taner, S. (2014). "Impacts of meteorological factors on PM₁₀: Artificial Neural Networks (ANN) and Multiple Linear Regression (MLR) approaches." *Environmental Forensics*, 15(4), 329–336.

Öztemel, E. (2003). *Yapay zeka: Kavramlar, uygulamalar ve yöntemler*. Papatya Yayıncılık.

Pérez, P., & Reyes, J. Á. (2002). "Prediction of maximum of 24-h average of PM₁₀ concentrations 30 h in advance in Santiago, Chile." *Atmospheric Environment*, 36(28), 4555–4561.

Rosenblatt, F. (1958). "The perceptron: A probabilistic model for information storage and organization in the brain." *Psychological Review*, 65(6), 386–408.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). "Learning representations by back-propagating errors." *Nature*, 323(6088), 533–536.

Seinfeld, J. H., & Pandis, S. N. (2016). *Atmospheric chemistry and physics: From air pollution to climate change* (3rd ed.). John Wiley & Sons.

Şahin, F., Işık, G., Şahin, G., & Kara, M. K. (2020). “Estimation of PM₁₀ levels using feed forward neural networks in Iğdır, Turkey.” *Urban Climate*, 34, 100721.

Taheri Shahraiyini, H., & Sodoudi, S. (2016). “Statistical modeling approaches for PM10 prediction in urban areas: A review.” *Atmosphere*, 7(2), 15.

Taşpınar, F. (2015). “Improving artificial neural network model predictions of daily average PM₁₀ concentrations by applying PCA and implementing seasonal models.” *Journal of the Air & Waste Management Association*, 65(7), 800–809.

Toros, H. (2018). Hava kirliliğine dirençli kentler. ResearchGate.

T.C. Çevre ve Şehircilik Bakanlığı. (2008). Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği. Resmî Gazete (06.06.2008, Sayı: 26898).

World Health Organization. (2021). WHO global air quality guidelines: Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. Geneva: WHO.

World Health Organization. (2024). Air pollution.

Yetilmezsoy, K., & Sapci-Zengin, Z. (2009). “Stochastic modeling applications for the prediction of COD removal efficiency of UASB reactors treating diluted real cotton textile wastewater.” *Stochastic Environmental Research and Risk Assessment*, 23, 13–26.

Yetilmezsoy, K., Özkaya, B. & Çakmakçı, M., (2011). ‘Artificial Intelligence- Based Prediction Models For Enviromental Engineering’, *Neural Network World*, 193-218.

Yurtoğlu, H. (2005). *Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*. Uzmanlık Tezi, Devlet Planlama Teşkilatı, Ankara.

Zeydan, Ö. (2021). “2019 Yılında Türkiye’deki Partikül Madde (PM10) Kirliliğinin Değerlendirilmesi.” *Journal of the Institute of Science and Technology*, 11(1), 106–118.

Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (1998).” Forecasting with artificial neural networks: The state of the art.” *International Journal of Forecasting*, 14(1), 35–62.

Zhang, H., Liu, Y., Shi, R., & Yao, Q. (2013). “Evaluation of PM₁₀ forecasting based on the artificial neural network model and intake fraction in an urban area: A case study in Taiyuan City, China.” *Journal of the Air & Waste Management Association*, 63(7), 755–763.

EKLER

EK-1 Giriş Veri Seti

17095_günlük _buhar_basın cı_hpa	17095_günlük_ güneşlenme_sü resi_saat	aziziye_so 2_ugm3	17095_günlük_ ortalama_rüzg ar_hızı_m_sn	17095_günl ük_toplam_ yağış_mm_ kg_m²	aziziye_co_ ugm3	17095_günlü k_ortalama_ nispi_nem_y uzde	aziziye_n ox_ugm3	aziziye_ pm10_u gm3
2,1	2,8	17,86	0,5	0	1643,43	75,1	167,57	147,88
4,3	2,8	5,59	5,4	0	294,59	73,7	20,16	7,47
4,3	8,2	5,53	2,6	0	356,88	65	26,47	11,78
4,5	6,5	6,96	2,5	0	653,93	75,5	38,8	20,64
4,9	4,8	4,14	2,6	0	482,16	70,1	26,16	11,21
5,1	5,3	7,28	1,2	0	827,24	77,1	48,06	25,61
4,5	8,5	13,45	0,5	0	1085,81	74,6	64,36	45,65
4,3	5,4	13,52	0,5	0	1003,52	72,7	71,06	58,96
4,3	3,1	9,49	0,6	0	674,23	61,4	39,56	39,43
5,1	0,7	7,76	2,1	0	426,69	70,2	19,15	27,37
4,8	7,6	8,68	0,7	0	912,39	70,9	58,48	38
4,9	2,9	3,88	1	0	434,52	76	22,31	27,89
4,2	0,3	8,08	0,7	0,4	576,19	68,7	32,28	25,15

3,6	4,3	6,23	0,6	0	620,86	64,5	40,65	35,32
4,5	2,3	6,54	0,6	0,1	620,64	73,4	40,58	25,83
4	4,4	6,14	1,2	0	589,33	65,4	32,32	33,26
4,4	1,1	4	1,2	0	600,95	72,4	34,33	24,3
4,8	5,7	2,71	1,3	4,7	533,22	78,8	31,34	13,26
3,3	9,4	10,54	0,6	0,1	945,09	64	62,47	45,27
2,9	9,4	9,27	1,8	0	645,27	57,8	36,17	46,49
2	9,4	3,61	1,8	0	343,13	42,9	15,12	15,82
1,7	9,4	3,14	1,7	0	363,81	38,7	15,03	17,62
1,8	9,4	11,51	0,6	0	1049,39	39,7	83,26	51,49
2,3	9,1	20,06	0,5	0	1434,99	42,5	110,95	96,45
2,7	8,8	12,03	1,4	0	968,72	43,4	71,66	62,97
2,4	9,1	18,08	1,1	0	785,79	39,2	50,63	40,72
3,1	8,8	14,09	0,5	0	917,39	51,1	65,78	61,71
4,8	0	4,89	1,5	0	688,22	65,8	29,05	30,39
4,4	0,4	9,62	0,7	0	721,79	82,5	53,38	31,73
4,4	3,5	6,37	1,2	2,7	287,81	73,6	13,45	12,21
3,3	9,9	5,79	2	0	335,26	55,3	16,32	13,81

3	9,7	7,61	1	0	742,3	51,1	35,55	21,51
3,6	7,4	10,71	1,4	0	720,12	53	43,21	39,17
4,1	1,5	13,9	0,8	0	633,99	53,5	36,54	39,17
4,8	0,5	12,76	1,2	0	789,47	69,4	42,47	55,72
5,5	8,9	5,87	1,9	10,8	512,15	83,4	23,79	11,05
4,7	3,7	6,93	2	0,5	646,18	73,3	26,12	22,8
5,9	0	5,73	1,5	4,6	601,95	90	27,19	14,28
5,8	1,1	5,34	1,4	5,9	484,71	85,8	16,59	5,73
5,7	0,4	5,28	0,7	1,3	539,95	84,8	19,95	6,48
5,6	1,1	7,23	0,9	0,4	678,46	82,9	29,75	18,24
5,6	2,2	5,3	1,2	6,2	573,04	89,7	22,74	7,07
4,9	0	5,44	1	15,7	494,5	88	15,2	7,98
4,8	8,4	7,81	1,9	0	540,24	62,8	38,6	37,47
5,9	7,6	10,26	1	0	733,2	69	42,98	76,14
5,3	10	5,8	1,4	0	435,17	54,4	24,77	35,1
3,8	9,8	12,12	1,3	0	960,84	40	62,51	47,55
6,7	2,3	5,5	0,8	3,7	433,94	71,5	20,61	11,76
6,6	3,7	5,2	2,7	1,7	345,04	72,5	10,77	12,84

6,6	3,4	4,98	2,5	8,5	358,53	75,4	11,62	8,97
7,1	6,4	4,96	2,6	0	386,92	70,8	11,97	9,97
6,7	3,9	5,19	1,5	1	400,85	66,5	13,9	9,3
6	8,7	5,36	1,4	0,9	417,57	61,2	19,04	8,08
5	11,1	5,61	1,6	0	489,9	47,7	23,88	17,88
6,6	8,3	5,77	2,1	0	416,62	52,3	16,64	17,03
7,8	0,2	5,82	1,8	0,5	448,61	62	19,79	24,42
9	3,2	5,12	1	3,7	497,37	86,2	18,56	16,29
7,9	1,1	4,97	0,8	23,5	450,57	88	18,06	8,69
6,8	2,8	4,82	1,5	10,1	380,35	78,8	11,79	4,67
6,5	9,9	5,54	3,1	1,5	457,43	69,9	20,58	10,6
7	2	5,57	1,8	0	482,57	78,3	23,13	15,01
5,3	10,6	4,94	2,3	7	344,85	60,4	11,67	5,34
4,7	12,5	4,97	2,1	0,2	321,93	47,8	14,17	6,9
6,8	7	5,21	1,5	0	428,11	54,7	17,71	17,56
6,2	11,9	5,46	1,1	0	390,69	51	18,87	17,39
7,2	9,8	5,32	1,8	0	410,75	54	16,88	18,79
7,9	11,7	5,08	1,7	0	357,44	53,8	11,22	11,07

7,7	7	5,06	1,5	0	383,91	56,4	16,52	25,81
9,8	5,9	5,15	2,1	2,5	439,33	78,4	18,69	20,53
8,5	0,9	4,96	2	0	383,1	62,3	13,67	15,01
9,3	2,4	5,09	0,6	8,8	470,2	84,9	22,62	9,09
9,7	7,5	5,29	1,1	4,3	523,85	78	27,49	17,54
9,6	6,8	5,74	1,9	4	454,21	67,5	20,89	25,38
7,7	9,1	5,64	1,4	0	461,44	46	25,06	43,62
9,4	10,2	5,35	1,7	0	438,25	51,4	18,29	38,52
8,7	12,7	5,46	2,2	0	382,87	43,7	14,88	26,82
8,6	7,1	4,88	1,4	0	379,39	54,6	15,44	17,76
6,2	12,7	5,04	0,7	0	362,42	44,5	21,64	12,4
6,8	12,5	5,09	1,2	0	405,17	40,6	26,01	13,7
7,9	12,1	5,05	1,9	0	382,07	44,1	19,02	12,21
9,1	11,1	5,01	1	0	416,74	44,8	21,79	14,3
9,4	12,5	4,95	1,1	0	438,4	45,5	28,52	16,66
11	8	4,49	1,1	0	440,6	52,6	24,63	36,26
11,4	3,3	4,31	1,6	7,2	451,22	72,5	21,34	18,95
10,3	8	4,2	2	2	349,79	62,3	10,78	15,02

10,7	7,8	4,28	0,7	0	350,01	65,6	10,77	14,2
9,9	11,9	4,24	0,8	0	364,38	57,9	13,58	14,82
8,3	12,3	4,52	1	0	374,61	41,6	22,03	47,63
7,9	12,7	4,41	0,9	0	370,76	41,8	25,01	41,39
9,2	10,4	4,62	1,1	0	443,3	45,6	24,84	34,94
11,1	11,9	4,6	1,5	3,1	399,65	54,3	16,01	27,29
9,3	10	4,62	0,9	0	407,18	43,2	23,55	30,52
8,8	10,5	4,87	1,6	0	398,18	37,8	17,61	30,11
9,2	11,8	4,56	1,2	0,8	370,49	39	12,12	17,69
9,4	11	4,64	1,8	0	402,49	37,8	13,97	21,85
10	12,7	4,39	1,3	0	430,23	49,3	16,23	17,08
8,9	12,7	4,23	1,3	0,3	366,31	46,4	9,65	10,23
7,9	12,7	4,33	1,7	0,8	341,91	36,6	9,1	9,94
8,6	12,7	4,54	1,1	0,8	397,61	36,5	13,27	19,71
7,7	12	4,43	0,8	0	410,73	31,9	15,34	21,63
9	9,2	4,32	1,2	0	416,66	48,6	11,45	29,09
6,5	12,7	4,29	0,9	0	387,25	44,3	9,98	8,98
7,9	12,7	4,4	0,9	1,3	415,76	45	17,42	14,5

9	10,4	4,39	1,7	0,9	401,91	50,5	15,07	12,86
10,6	8,8	4,39	2	2,1	393,26	61,1	12,03	11,88
11,2	1,5	4,22	1,8	12,4	441,43	79,3	19,08	8,2
10,4	9,8	4,24	1	5,7	451,69	72,7	18,67	15,19
11,4	10,2	4,25	1,3	42,7	444,23	71,4	17,73	10,03
10,3	11,2	4,41	1,1	0,3	444,93	54	19,13	23,97
8,7	12,6	4,46	1,5	0	406,83	41,8	22,02	30,33
9,9	9,1	4,45	2,5	0	314,15	39,8	15,13	33,75
11,2	7,5	4,31	2,9	1	339,6	55,1	11,97	13,43
12,5	4,1	4,29	1,9	1,8	378,86	69,5	14,33	12,47
13,1	3,7	4,31	2,2	13,2	393,68	75,1	15,06	15,02
13,9	7,6	4,28	0,9	6,9	439,11	75	19,78	16,17
12,4	11,9	4,55	1	3,3	508,74	62,1	21,84	20,02
11,3	9,9	4,67	1	0	436,25	47,3	24,79	26,56
12,4	11,2	4,41	1,2	0	360,02	52,3	13,82	15,98
13,8	6,1	4,22	2,1	0	400,37	62,9	13,37	14,96
14	4,8	4,37	2	3,7	437,72	70,1	16,37	17,28
14,7	7,3	4,32	1,2	3,8	464,8	69,1	17,86	22,03

14,3	7,6	4,42	1,3	5	488,38	66	19,14	27,48
14	9,3	4,05	2	10,7	426,39	72,2	15,83	15,09
13,4	12	4,03	1,6	7,1	411,16	71,1	13,29	10,35
14,4	5,2	3,99	0,9	10,3	433,95	77	15,77	8,27
13,1	12,6	4,43	0,8	2,7	419,14	68,3	17,34	9,13
12,4	12,3	4,57	0,8	0	440,81	56,3	20,41	16,59
11,9	12,2	4,37	1	0	430,96	52,5	20,74	29,81
11,1	10,2	4,18	0,8	0,5	387,73	53,2	15,57	22,31
10,6	12,8	4,08	1,3	0	381,47	50,7	13,56	12,81
12,1	8,6	4,17	1,5	0	418,23	51,8	17,26	22,19
13	7,3	4,07	0,9	2,3	424,7	66,5	14,69	17,89
12,1	9,3	4,07	0,9	8,5	411,94	66,7	12,47	9,09
10,6	12,8	4,1	2	0	374,47	59,3	13,09	9
12	12,7	4,45	1,1	0	415,14	57,7	14,13	25,38
12,2	13	4,57	1	0	412,21	53,8	14,55	22,82
12,3	12,9	4,58	1,2	0	444,28	55,4	18,18	26,51
10	12,6	4,63	0,8	0	434,98	44,7	21,81	24,85
11,6	8,5	4,76	0,9	0	511,09	50,4	22,87	33,83

10,4	12,9	4,48	0,9	0	500,54	48,5	18,79	28,68
11,2	12,9	4,52	0,8	0	541,87	48,7	24,23	29,04
9,9	12,7	4,73	1,1	0	504,61	41,3	20,18	27,4
12,1	12,8	4,3	1,4	0	505,04	58,7	11,82	13,53
10,7	12,6	3,67	1,3	0	390,24	49	16,6	10,22
9,9	12,6	3,73	1,1	0,1	419,38	46,5	25,59	21,83
8,3	12,6	3,91	0,9	0,3	384,64	41,2	24,9	17,21
9,2	12,1	3,85	1,2	0	382,65	45	16,22	17,02
7,6	11,5	3,78	3,6	0,1	332,05	36,7	8,42	18,17
10,6	11	4,19	2,1	0,2	412,08	46,3	10,45	21,07
10,8	11,1	4,05	1,1	0	459,05	45,1	17,57	24,57
10,4	8,2	4,44	0,8	0	446,61	42,6	18,67	20,86
10,2	9,3	4,33	1,1	0	570,99	39,8	28,57	31,01
9,4	10,6	5,17	2	0	600,41	36,3	33,11	37,28
7,4	10,8	4,6	1,7	0	453,55	30,2	25,77	28,45
8,9	8,4	4,16	2,8	0	440,58	36,7	14,62	25,79
10	9,5	4,26	2,5	0,5	460,23	48,5	18,52	20,23
9,1	9,6	4,76	0,8	0,1	495,94	43,3	27,57	20,95

10,2	10	4,18	2,4	0,6	433,64	50,3	13,02	21,1
9,7	9,2	4,45	3,5	0,4	431,04	39,5	9,8	35,97
10,1	7,2	4,66	2,9	0	461,95	41,9	11,65	35,61
10,9	8,4	4,99	1,6	0,7	515,73	51,2	26,9	25,93
10,6	9,3	5,34	2,2	0,9	464,97	45,7	18,25	38,57
8	11,4	4,92	1,7	0,4	441,2	35,4	27,08	31
7	10,5	4,94	0,7	0,1	457,28	34,7	30,63	25,07
10,1	10,7	4,35	1	0,6	467,06	50,8	21,72	29,99
10,5	8,7	3,97	0,8	0,1	459,91	52	16,12	16,67
11,5	4,6	3,84	1,1	0,7	478,16	63	13,8	14,26
12,1	5,5	3,68	1,8	1,5	510,56	76,8	15,39	12,44
11,2	9	3,81	1,7	7,9	519,66	65,5	17,91	13,99
9,8	7,7	4,01	1,7	0	583,72	52,8	32,52	22,89
11,2	9,5	4,58	1,8	0	569,58	57,2	24,68	26,14
7,6	10,6	4,41	0,8	0	594,88	38,9	40,66	31,51
8,2	10,6	4,16	0,9	0	553,75	40,5	28,52	28,13
10	8,4	3,94	1,4	0,1	516,72	47,6	11,88	21,31
9,4	9,5	4,04	1,5	0,3	526,2	50,3	14,28	17,38

8,7	8,8	4,37	2	0,1	510,91	41,3	11,77	41,71
10,3	4,8	3,9	0,9	0,4	514,11	64	22,93	19,77
9,5	8,3	3,86	0,9	13,6	444,8	70,6	25,82	12,68
9,7	6,6	3,85	1,2	0,2	415,04	66,8	16,22	11,39
10,6	5,3	3,84	0,8	4,3	442,7	75,5	19,63	12,87
9,6	2,4	3,89	0,7	0,3	474,43	75,6	25,84	14,16
10,6	2,2	3,82	0,8	0,7	473,49	83,6	21,2	9,65
9,1	7,3	3,82	1,6	5,3	440,69	71,6	18,29	9,33
8,4	5,7	4,09	1	0,4	489,59	65,5	27,5	11,96
7,4	10	4,37	0,5	0	598,49	61,1	49,72	19,13
7,3	10	4,25	0,9	0	487,99	56,3	31,5	19,11
8,4	9,7	4,15	1,8	0	425,78	54,8	12,79	15,32
7,7	9,9	4,02	2,6	0,1	420,53	53,9	13,19	15,23
7,1	9,8	4,05	2,9	0	385,56	49,4	10,25	15,62
6	7,1	4,5	1	0	461,55	41,7	24,04	27,81
8,2	2,2	5,61	1,8	1,3	506,95	58,8	24,04	31,76
8,7	2	4,4	1	19,2	496,27	84,7	24,07	8,15
7	9,5	5,53	0,5	3,8	720,91	69,4	45,29	40,63

6,9	9,4	5,72	0,8	0	732,01	61,9	58,04	24,55
6,9	9,5	5,72	0,5	0	770,78	57,9	59,5	26,7
6,6	9,6	6,04	0,8	0	714,4	52,3	53,54	31,56
6,3	9	5,66	0,9	0	637,44	43	53,76	29,5
7,4	2	7,23	1,2	0	789,46	52	64,99	43,31
6,6	9,3	6,98	1,3	0	784,15	54,9	67,6	36,19
6	7,4	6,33	1,8	0	662,92	41,2	48,51	37,05
7,3	0,1	9,62	0,6	0	773,91	48,2	63,47	50,19
7,2	8	7,42	1,1	0	691,63	51,2	42,15	48,02
9,1	6	5,04	0,7	0	738,57	69,9	32,16	31,25
8,6	4,3	5,25	0,8	0	814,21	69,8	42,91	34,24
4,3	5,2	4,05	2	0	582,89	65,7	19,95	8,47
3,8	3,6	4,41	1,9	0	622,41	59,3	22,23	9,82
4,3	3,4	4,63	2,7	0	592,77	64,6	19,18	8,72
4,3	4,9	6,22	0,8	0	713,79	65,6	27,41	12,01
3,9	8,6	9,06	1,2	0	805,83	59	36,3	21,52
4,5	8,3	7,73	0,6	0	1161,32	62,3	56,92	35,83
5	6,8	8,37	1,1	0	967,16	66,1	53,61	15,2

4,7	6,7	5,69	2,6	0	678,28	58,8	24,8	16,92
4,3	8,4	14,83	0,5	0	970,62	60,4	50,25	28,4
3,7	8	28,68	0,4	0	1390,63	55,9	90,45	67,13
3,7	8	25,23	0,4	0	1419,09	48,4	86,89	68,37
4,2	7,9	16,36	0,6	0	1345,32	51,1	82,68	58,86
4,2	7,8	25,59	0,5	0	1569,61	55,4	91,34	65,73
4	7,7	26,69	0,4	0	1432,45	51,1	80,51	70,47
4	7,8	16,68	1,1	0	1201,44	51,1	64,19	59,88
4,5	3,7	11,27	0,9	0	1094,56	51,6	45,12	46,37
4,7	3,2	6,49	1,3	0	763,23	61,8	21,77	14,38
3,4	3	5,1	3,4	0	689,1	51	16,97	19,27
2,9	7,6	22,51	0,5	0	1193,47	55,9	63,26	34,79
5,5	3,4	5,89	2	0	1052,98	71,3	40,65	21,23
6,1	1,9	7,86	1,2	0,1	1212,64	74,6	51,22	27,64
6,2	1,4	7,89	0,9	0	1268,01	75,4	46,98	31,07
6,3	1,2	2,96	1,5	0,1	949,47	66,7	15,4	18,47
4,1	0	3,13	0,8	16,8	978,83	90,5	23,68	9,16
3,2	0	3,87	0,3	6,9	1160,17	88,8	41,57	31,12

3,4	0	5,6	1,7	5,9	1047,13	85,3	30,46	23,11
2,9	7	10,98	1,1	1,8	1181,39	75	43,45	9,98
1,7	7,2	19,3	0,5	0	3173,62	77,4	200,77	179,94
1,8	7,2	14,06	0,5	0	3209,73	74,5	190,84	187,63
2,6	6,8	20,59	0,7	0	1945,12	83,1	119,41	72,05
1,8	7	17,45	0,4	0	2795,54	78	177,74	114,56
1,6	6,8	17,55	0,5	0	2667,64	74,6	177,34	157,42
3	5,3	44,34	0,4	0	3131,12	78,1	233,78	208,18
3,7	5,7	36,88	0,4	0	2140,38	79	167,28	185,12
3,1	5,8	22,72	0,4	0	1688,49	85	200,08	118,94
4,1	0,9	17,27	0,4	0	1152,06	86,3	136,29	83,54
5,3	0	7,98	0,4	0,9	673,74	96,8	53,57	50,89
4,3	0	3,36	0,6	0	830,02	95,5	46,19	30
3,8	0,1	4,55	0,4	0	1300,91	93,9	68,63	48,62

4,1	0,1	8,03	1,9	0,3	2066,43	91,3	123	71,55
3,5	4,5	3,97	3,5	5,8	771,28	72,5	21,72	4,13
1,8	7,2	7,87	2,3	0,2	912,92	61,8	30,86	10,1
1,4	6	21,42	0,6	0	1992,13	71,3	108,01	71,26
2,3	0,7	17,59	0,5	0	2270,63	76,3	116,89	98,13
3,1	7,1	9,18	2	0,9	1339,82	77	52,77	29,44
3,7	2,5	7,99	4,7	0	1080,18	75	30,37	20,76
3,8	4,8	18,92	2	0	1236,13	67,6	44,17	22,62
2,9	7,1	27,13	0,5	0	2824,94	81,7	165,71	104,52
2,4	7,1	26,15	0,4	0	3427,96	78,9	202,18	162,46
2,8	1,3	19,8	0,5	0	3887,41	82,8	207,84	172,03
4,2	0,1	17,5	0,6	0,9	1843,37	81,8	74,92	52,53
5,3	1	13,94	0,9	0,1	1782,15	82,5	63,32	33,8
5	4,8	16,16	0,6	0,1	1733,77	73,2	50,96	32,91
4,1	1,7	16,51	0,5	0	2301,79	75,8	100,03	42,89
4,9	0	7,13	2,4	0,1	1575,7	88,4	28,13	23,41
5	0,2	4,77	1,9	7	1547,83	85,9	24,03	6,85
4,2	0,3	11,45	0,4	0,4	2046,56	85,5	57,75	29,06

3,6	2,6	12,28	0,6	0	2137,76	76,3	67,14	38,78
3,1	6,6	13,63	0,4	0	2456,82	78,8	87,36	55,7