

**T.C.
BALIKESİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI**



HAVA KALİTESİ ÜZERİNE YAPAY ZEKA UYGULAMALARI

AHMAD TAMİM NOORİ

YÜKSEK LİSANS TEZİ

**Jüri Üyeleri : Doç. Dr. Atilla MUTLU (Tez Danışmanı)
Prof. Dr. Umut OKKAN
Doç. Dr. Aşkın BİRGÜL**

BALIKESİR, OCAK - 2026

ETİK BEYAN

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan “**Hava Kalitesi Üzerine Yapay Zeka Uygulamaları**” başlıklı tezde;

- Tüm bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Kullanılan veriler ve sonuçlarda herhangi bir değişiklik yapmadığımı,
- Tüm bilgi ve sonuçları bilimsel araştırma ve etik ilkelere uygun şekilde sunduğumu,
- Yararlandığım eserlere atıfta bulunarak kaynak gösterdiğimi,

beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ederim.

Ahmad Tamim NOORI

ÖZET

**HAVA KALİTESİ ÜZERİNE YAPAY ZEKA UYGULAMALARI
YÜKSEK LİSANS TEZİ
AHMAD TAMİM NOORİ
BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DOÇ. DR. ATILLA MUTLU)
BALIKESİR, OCAK - 2026**

Bu çalışmada yapay zekâ tabanlı yöntemler kullanılarak hava kirliliği parametrelerinden PM_{10} ve SO_2 konsantrasyonlarının tahmini amaçlanmıştır. Bu kapsamda Yapay Sinir Ağları (Artificial Neural Networks, ANN) ve Radyal Tabanlı Fonksiyon (Radial Basis Function, RBF) modelleri Bursa, Çanakkale ve Balıkesir illerine ait ölçüm verileri üzerinde uygulanmıştır. Modellerin performansları Nash-Sutcliffe (NS), Hata Kareler Ortalamasının Karekökü (RMSE), Standart Sapma Oranı (RSR) ve Yüzde Sapma (Pbias) istatistikleri ile değerlendirilmiştir.

Elde edilen sonuçlar, PM_{10} tahminlerinde ANN ve RBF yöntemleri birbirine yakın performanslar sergilemiş, özellikle Çanakkale verilerinde her iki yöntemde de yüksek uyum değerleri elde edilmiştir. Balıkesir verilerinde ise her iki yöntem de görece daha düşük performans göstermiştir. SO_2 tahmininde ise RBF modelinin ANN'ye kıyasla daha yüksek doğruluk sağladığını ortaya koymuştur. Özellikle Bursa verilerinde RBF modeli eğitim aşamasında 0.97 gibi oldukça yüksek bir NS değerine ulaşmıştır. ANN modelinde ise bazı durumlarda test aşamasında negatif NS değerleri gözlenmiş, bu da modelin genelleme yeteneğinin sınırlı olduğunu göstermiştir. Genel olarak, yapay zekâ tabanlı yöntemlerin hava kirliliği parametrelerinin tahmininde etkili araçlar olduğu, ancak model performanslarının bölgesel verilerin özelliklerine bağlı olarak değişkenlik gösterebildiği sonucuna varılmıştır. Gelecek çalışmalarda hibrit yaklaşımların kullanılması, meteorolojik parametrelerin modele entegre edilmesi ve daha kapsamlı veri setlerinin değerlendirilmesi ile tahmin performanslarının artırılacağı öngörülmektedir. RBF ağlarının hava kalitesi çalışmalarında uygulanabilirliğini göstermesi bakımından literatüre özgün bir katkı sunmaktadır.

ANAHTAR KELİMELER: Hava kirliliği, PM_{10} , radyal tabanlı fonksiyon (RBF), SO_2 , yapay sinir ağları (ANN), yapay zekâ.

ABSTRACT

ARTIFICIAL INTELLIGENCE APPLICATIONS ON AIR QUALITY
MSC THESIS
AHMAD TAMIM NOORI
BALIKESIR UNIVERSITY INSTITUTE OF SCIENCE
ENVIRONMENTAL ENGINEERING
(SUPERVISOR: ASSOC. PROF. DR. ATILA MUTLU)
BALIKESİR, JANUARY - 2026

In this study, artificial intelligence-based methods were employed to predict the concentrations of two major air pollution parameters, PM₁₀ and SO₂. Artificial Neural Networks (ANN) and Radial Basis Function (RBF) models were applied using measurement data obtained from the provinces of Bursa, Çanakkale, and Balıkesir. The performances of the models were evaluated using statistical indicators including Nash-Sutcliffe Efficiency (NS), Root Mean Square Error (RMSE), Ratio of Standard Deviation (RSR), and Percent Bias (PBIAS).

The results showed that the ANN and RBF methods exhibited similar performance in predicting PM₁₀ concentrations, with both models achieving high NS values for the Çanakkale dataset. However, for the Balıkesir dataset, both methods yielded comparatively lower performance. In the estimation of SO₂ concentrations, the RBF model outperformed ANN, providing higher prediction accuracy. Notably, the RBF model achieved a very high NS value of 0.97 during the training phase for the Bursa dataset. In contrast, the ANN model produced negative NS values in some test cases, indicating limitations in its generalization capability. Overall, the findings indicate that artificial intelligence-based approaches can serve as effective tools for predicting air pollution parameters; however, model performance may vary depending on the characteristics of regional datasets. Future studies are recommended to incorporate hybrid modeling approaches, integrate meteorological variables into the models, and utilize more extensive datasets to enhance prediction accuracy. It makes an original contribution to the literature by demonstrating the applicability and potential of RBF networks in air quality modeling and assessment.

KEYWORDS: Air pollution, PM₁₀, radial basis function (RBF), SO₂, artificial neural networks (ANN), artificial intelligence

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	iv
TABLO LİSTESİ	v
ÖNSÖZ	vi
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM	10
2.1 Uygulama Alanı	10
2.2 Bölgesel Konum ve Genel Özellikler	11
2.2.1 Hava kalitesi izleme altyapısı	11
2.2.2 Bursa.....	12
2.2.3 Çanakkale	12
2.2.4 Balıkesir	13
2.3 Veri Analizi	13
2.4 Hava Kalitesinin İzlenmesi ve Modellenmesi	17
2.4.1 Partikül Madde 10 (PM ₁₀)	17
2.4.2 Kükürt Dioksit (SO ₂).....	18
2.5 Yapay Zekâ Tabanlı Tahmin Modelleri	19
2.5.1 Yapay Sinir Ağları (ANN).....	20
2.5.2 Radyal Tabanlı Yapay Sinir Ağları (RBF)	23
2.6 Model Performans Kriterleri Hakkında Genel Bilgi	24
3. BULGULAR	28
4. SONUÇLAR VE TARTIŞMA	43
5. KAYNAKLAR	46
ÖZGEÇMİŞ	52

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Çalışmada PM ₁₀ ve SO ₂ analizleri için kullanılan çalışma alanının konumları (Arcgis).	10
Şekil 2.1: Çanakkale, Bursa ve Balıkesir illerindeki hava kalitesi izleme istasyonlarının konumu.	11
Şekil 2.2: 2013–2018 yılları arasında Bursa, Çanakkale ve Balıkesir illeri için ölçülen PM ₁₀ (üstte) ve SO ₂ (altta) konsantrasyonlarının zamansal değişimleri.	14
Şekil 2.3: Yapay sinir ağı yapısı (Saplıoğlu, 2010).	21
Şekil 2.4: RBF'nın yapısı (Okkan ve Dalkılıç, 2012).	23
Şekil 3.1: Bursa ili için PM ₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	31
Şekil 3.2: Bursa ili için PM ₁₀ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	31
Şekil 3.3: Çanakkale ili için PM ₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	32
Şekil 3.4: Çanakkale ili için PM ₁₀ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	32
Şekil 3.5: Balıkesir ili için PM ₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	33
Şekil 3.6: Balıkesir ili için PM ₁₀ konsantrasyonlarının RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	33
Şekil 3.7: Bursa ili için SO ₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	35
Şekil 3.8: Bursa ili için SO ₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	35
Şekil 3.9: Çanakkale ili için SO ₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	36
Şekil 3.10: Çanakkale ili için SO ₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	36
Şekil 3.11: Balıkesir ili için SO ₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	37
Şekil 3.12: Balıkesir ili için SO ₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.	37

TABLO LİSTESİ

Sayfa

Tablo 2.1: Çalışma alanındaki hava kalitesi izleme istasyonlarının koordinatları.	11
Tablo 2.2: Bursa, Çanakkale ve Balıkesir illerine ait PM10 ve SO2 konsantrasyonlarının temel istatistikleri.	16
Tablo 2.3: Model Performans Kriterleri ve Sınıflandırma Tablosu.....	27
Tablo 3.1: Bursa, Çanakkale ve Balıkesir için ANN ve RBF Modellerinin PM ₁₀ Konsantrasyonu Tahmin Performansları.	38
Tablo 3.2: Bursa, Çanakkale ve Balıkesir için ANN ve RBF Modellerinin SO ₂ Konsantrasyonu Tahmin Performansları.	40

ÖNSÖZ

Bu tez çalışması, yapay zekâ tabanlı yöntemlerin hava kirliliği parametrelerinin tahmininde uygulanabilirliğini arařtırmak amacıyla hazırlanmıřtır. Günümüzde artan sanayileřme ve nüfus yoğunluęu, hava kalitesi sorunlarını önemli bir çevresel risk hâline getirmiřtir. Bu bağlamda, hava kirleticilerinin doğru řekilde tahmin edilmesi; çevre planlaması, halk saęlığı ve sürdürülebilir kalkınma açısından büyük önem taşımaktadır. Çalışmada Yapay zeka modelleri kullanılarak PM₁₀ ve SO₂ konsantrasyonlarının tahmini gerçekleştirilmiř, elde edilen sonuçlar farklı bölgeler için karşılaştırılmıřtır, ve bu süreçte yalnızca teknik bilgi deęil, aynı zamanda bilimsel düşünme, veri analizi ve yorumlama konularında da önemli deneyimler kazanılmıřtır.

Ders dönemim ve tez çalışmam süresince bilgi ve yönlendirmeleriyle bana destek olan deęerli danıřmanım Doç. Dr. Atilla MUTLU'ya teřekkür ederim. TÜBİTAK projesi kapsamında saęladığı destek ve yönlendirmeler için Prof. Dr. Umut OKKAN'a teřekkür ederim. Yaşamım boyunca maddi ve manevi desteklerini esirgemeyen aileme ve desteęini her zaman hissettiğim arkadařım Arař. Gör. Zeynep Beril ERSOY'a sonsuz teřekkür ederim

Balıkesir, 2026

Ahmad Tamim Noori

1. GİRİŞ

İnsanların yaşam kalitesini doğrudan etkileyen en temel çevresel unsurlardan biri hava kalitesidir. İnsan sağlığının yanı sıra ekosistemler, şehir planlaması ve kamu politikaları da atmosferdeki gaz ve partikül madde miktarından etkilenmektedir. Trafik, sanayi faaliyetleri, nüfus yoğunluğu ve iklim değişikliği gibi faktörler nedeniyle hava kalitesi şu anda özellikle büyük şehirlerde ciddi şekilde düşüyor. Bunun ışığında, hava kalitesini takip etmek ve gelecekteki durumunu tahmin etmek artık halk sağlığının korunması açısından büyük önem taşıyor. Bu gereksinime güçlü ve uyarlanabilir yanıtlar sağlayan yapay zeka uygulamalarının ortaya çıkmasıyla hava kalitesi modellemesinde yeni bir dönem başlamıştır (WHO, 2016).

Hava kirliliğiyle ve kalitesiyle ilgili ilk gözlemler dünya üzerinde 1200'lü yıllara kadar uzanmakta olup, özellikle Sanayi Devrimi ile birlikte bu durum en ciddi sağlık problemlerinden biri haline gelmiştir. 1948-1952 yılları arasında ABD'nin Pensilvanya eyaletinde ve İngiltere'nin başkenti Londra'da yaşanan akut hava kirliliği, pek çok insanın hastalanmasına yol açmış ve binlerce kişinin hayatını kaybetmesine neden olmuştur (Vallero, 2023).

Sıcaklık, nem, rüzgar hızı ve yönü ve karışım yüksekliği (atmosferdeki dikey karışım yüksekliği) gibi etyolojik değişkenler, zaman ve mekanda birden fazla ölçekte hava kalitesi modellerinin belirlenmesinde önemli roller oynar. Bu bağlantılar, hava kirliliği emisyonlarındaki değişiklikler, taşınım, seyreltme, kimyasal dönüşüm ve hava kirlleticilerinin nihai birikimi yoluyla işleyebilir. Hava kalitesini ve insan sağlığını iyileştirmeye yönelik politikalar, kirlilik emisyonlarının ne zaman, nerede ve nasıl kontrol edileceğini belirlerken meteorolojik değişkenleri hesaba katar ve genellikle geçmişte gözlemlenen hava durumunun, kontrol politikaları tam olarak uygulandığında gelecekte meydana gelecek hava durumu için iyi bir gösterge olduğunu varsayar (Kinney, 2008).

Kötü hava kalitesi, yalnızca insanların yaşamlarını ve işlerini etkilemekle kalmaz, ekonomik gelişmeyi de engeller ve iklim değişikliğine yol açar (Kampa, 2020). Dünya Sağlık Örgütü'nün (WHO) raporuna göre, dış mekandaki hava kirliliği içindeki küçük parçacıklar, daha önce düşünüldüğünden çok daha zararlıdır (Aayush, 2020). WHO'ya göre, hava kirliliği her yıl yaklaşık 7 milyon insanın ölümüne sebep olmaktadır. 2016

yılında, dış mekan hava kirliliği (özellikle Partikül Madde) dünya genelinde hem kentsel hem de kırsal alanlarda 5,2 milyon erken ölüme yol açmıştır. Hava kirliliği ve bu konuda yaşanan tehlikelerin yol açtığı ölümler, Güney ve Doğu Asya'da en yüksek oranlarda (%15) tespit edilmiştir. Hindistan gibi gelişmekte olan ülkelerde hava kirliliğine bağlı ölümlerde bir azalma olsa da, 1990 ile 2017 arasında ölüm oranlarının %14 arttığı görülmüştür (Mannucci and Franchini, 2017). İnsan sağlığı ve yaşam kalitesi, çevresel, psikososyal, fiziksel, biyolojik ve sosyal faktörler tarafından belirlenmektedir (Asha, 2022). İklim değişiklikleri, hava koşullarında ve sıcaklık düzeninde değişimlere neden olur.

Hava kirliliğiyle ilgili sorunlar, hem gelişmekte olan hem de gelişmiş ülkelerde hava kalitesi konusunda kamuoyunun farkındalığının artmasına neden olmuştur. Çevrecilerin, sivil toplum kuruluşlarının ve kamuoyunun baskısı, birçok ülkede hükümetleri düzenleyici adımlar atmaya zorlamıştır. Avrupa Çevre Ajansı (AÇA) ve Çevre Koruma Ajansı (EPA) gibi ulusal ve uluslararası çevre kuruluşları, hava kirliliğiyle ilgili gerekli yönergeleri ve yasal zemini oluşturmak üzere kurulmuştur. Hava kirleticilerinin kabul edilebilir seviyeleri genellikle bu kuruluşlar tarafından belirlenir. Bu kuruluşlar tarafından belirlenen hava kalitesi yönergeleri, hava kirliliğine ilişkin verilerin üretimi, azaltılması, kontrolü, ölçümü ve dağıtımındaki standartları ayrıntılı olarak açıklamaktadır. Kirli havada karbon monoksit (CO), partikül madde (PM₁₀), ozon (O₃), azot dioksit (NO₂) vb. gibi insan sağlığını olumsuz etkileyen birçok hava kirleticisi bulunmaktadır. Kükürt dioksit (SO₂) bunlar arasında önemli bir kirleticidir (Karaca, Alagha ve Ertürk, 2005; Karaca, Nikov ve Alagha, 2006). Bu kirleticilerin yüksek konsantrasyonları yaşamı tehdit edebilir, nefes almada zorluk, baş ağrısı ve baş dönmesine neden olabilir. Hatta kalp krizlerine bile yol açabilirler (Künzli et al., 2000). Bu nedenle yetkililer, havadaki kirleticilerin izlenmesi ve tahmin edilmesi için kriterler önermektedir.

Hava kirliliği ve kalitesi, günümüzde insan sağlığına en büyük tehlikeleri oluşturan çevre sorunlarından biri olarak öne çıkmaktadır. Özellikle, solunabilir partikül maddeler (PM₁₀) ve kükürt dioksit (SO₂) solunum yolu hastalıkları, kalp ve damar problemleri ile erken ölümlerle doğrudan bağlantılıdır (WHO, 2021). Bu kirleticilerin durumu üzerine yapılan değerlendirmeler ve gelecek tahminleri, çevresel önlemler alındıkça halk sağlığını tehdit eden risklerin azalmasında hayati bir rol üstlenmektedir.

Kurt ve Oktay (2010) tarafından İstanbul şehir için yapılan bir çalışmada, PM₁₀ tahmini için geliştirilen ANN modelinin geleneksel regresyon yöntemlerine göre daha yüksek korelasyon ve daha düşük hata değerleri verdiği belirtilmiştir. Benzer şekilde, Grivas and Chaloulakou (2006), Yunanistan'da PM₁₀ seviyelerini tahmin etmek için kullandıkları ANN modellerinin, özellikle kış aylarında oldukça başarılı sonuçlar verdiğini bildirmiştir. Yapay zekâ, bir bilgisayar veya bilgisayar kontrollü bir makinenin, genellikle insanlara özgü olarak kabul edilen akıl yürütme, anlam çıkarma, genelleme ve geçmiş deneyimlerden öğrenme gibi karmaşık zihinsel görevleri gerçekleştirebilme yeteneği olarak tanımlanabilir (Nabiyev, 2005). Yapay zekâ araştırmaları, bilgisayar teknolojisinin ilk ortaya çıktığı 1940'lı yıllara kadar gitmektedir.

Bazı bilim insanları, insan beynindeki sinir ağı sisteminin matematiksel bir modelini geliştirmişlerdir. Bu yapılar, Yapay Sinir Ağları (Artificial Neural Networks) olarak adlandırılmaktadır. McCulloch and Pitts (1943) yılında, yayımladıkları bir çalışmada basit bir ikili nöron türünün davranışlarını ve özelliklerini incelemişlerdir. Söz konusu araştırmacıların geliştirdiği bilgisayar modeli, yapay sinir hücrelerini, önermeli mantığı, fizyolojiyi ve Turing'in hesaplama kuramını temel almaktadır.

Sivas ili için hava kalitesinin yapay sinir ağları (YSA) yöntemiyle modellenmesi amaçlanmıştır. Araştırmada SO₂, CO₂ NO_x ve PM₁₀ gibi çeşitli kirletici parametrelerden elde edilen veriler kullanılarak bir YSA modeli geliştirilmiştir. Bu model aracılığıyla bölgedeki hava kalitesinin geleceğe yönelik eğilimleri tahmin edilmeye çalışılmıştır. Elde edilen bulgular, YSA yaklaşımının hava kirliliği öngörülerinde güvenilir ve etkili bir yöntem olduğunu ortaya koymuştur. Çalışma ayrıca, çevresel planlama ve yönetim süreçlerinde karar vericilere bilimsel destek sağlayabilecek nitelikte sonuçlar sunmaktadır (Yüksek vd., 2007).

Balıkesir şehir merkezinde son beş yıl boyunca ölçülen PM₁₀ ve SO₂ hava kirleticilerinin meteorolojik koşullarla ilişkisi incelenmiştir. Sonuçlara göre PM₁₀'un ortalama değeri 47,3 µg/m³, SO₂'nin ortalaması ise 7,75 µg/m³ bulunmuştur. Her iki kirleticinin özellikle kış aylarında arttığı, bunun da ısınma faaliyetleri ve atmosferik inversiyonlarla ilişkili olduğu belirlenmiştir. Analizler, PM₁₀ seviyelerinin rüzgâr hızı ve sıcaklık ile ters yönlü ilişkili olduğunu, SO₂ seviyelerinde ise en etkili parametrenin yine sıcaklık olduğunu göstermektedir (Mutlu, 2019).

Gültepe (2019) yılında, Kastamonu ilinde çeşitli makine öğrenmesi algoritmaları (YSA, Karar Ağaçları, Rastgele Orman vb.) kullanarak hava kirliliği tahmini yapmıştır. En başarılı modeller %99 doğrulukla Karar Ağaçları ve Rastgele Orman olurken, Lineer Regresyon en düşük performansı göstermiştir. Çalışma, farklı algoritmaların performansını istatistiksel ölçütlerle kıyaslamıştır.

Kunt (2014) yılında, Doktora tez çalışmasında, Konya şehir merkezindeki hava kirliliği verileri kullanılarak iki farklı yapay zekâ yaklaşımı olan Bulanık Mantık ve Yapay Sinir Ağları (YSA) yöntemleriyle modelleme yapılmıştır. Amaç, hava kirliliği parametrelerinin zaman içindeki değişimini tahmin etmek ve bu tahminlerde hangi yöntemin daha etkili olduğunu belirlemektir. Modelleme sürecinde: 1: Meteorolojik veriler ve hava kirletici değerleri giriş olarak kullanılmıştır. 2: Bulanık mantık sistemi belirsizlikleri yönetmede avantaj sağlarken, 3: YSA, karmaşık ilişkileri öğrenerek tahmin doğruluğunu artırmıştır. Sonuç olarak, her iki yöntem de hava kalitesinin modellenmesinde başarılı sonuçlar vermiş, ancak YSA'nın daha yüksek doğruluk oranları sunduğu ifade edilmiştir.

Bu çalışmada, akıllı sistemlerle çevre modellemesinin etkinliğini ortaya koymaktadır. Hava kalitesi parametrelerinin hem zaman içinde tahmini hem de coğrafi (mekânsal) dağılımının belirlenmesi amacıyla makine öğrenmesi yöntemleri kullanılmıştır. Hava kirliliğine neden olan parametreler (örneğin PM₁₀, NO₂, vb.) ile birlikte meteorolojik veriler analiz edilmiştir. Kullanılan modeller sayesinde: 1: Farklı bölgelerdeki hava kalitesi tahmin edilebilmiş. 2: Elde edilen sonuçlar mekânsal haritalar üzerinde görselleştirilmiştir. Hassas ve bölgesel bazda etkili tahminler ile çevresel önlemler için güçlü bir karar destek aracı oluşturmaktır. Makine öğrenmesi yöntemleri, özellikle geleneksel istatistiksel yöntemlere kıyasla daha esnek ve doğru tahminler sunmuştur (Dokuz, Bozdağ ve Gökçek, 2020).

Hava kirliliğinin yapay zekâ yöntemleriyle (özellikle bulanık mantık) modellenmesi amaçlanmıştır. SO₂, NO_x, PM₁₀ ve CO gibi kirletici gazların konsantrasyonları kullanılarak bir hava kirliliği indeksi tahmin modeli geliştirilmiştir. Girdi-çıkı ilişkileri üzerine kurulu model, EPA (Environmental Protection Agency) standartlarına dayalı olarak oluşturulmuştur. Yapay zekâ teknikleri, kirletici verilerin yorumlanmasında ve karmaşık çevresel süreçlerin değerlendirilmesinde etkili ve hassas tahminler sağlamıştır.

Çalışma, geleneksel ölçüm sistemlerine alternatif olarak akıllı tahmin sistemlerinin geliştirilmesine katkı sağlamaktadır (Bıyık, 2010).

Türkiye geneli 32 ildeki veriler kullanılarak hava kirliliği (özellikle partikül madde: PM) seviyeleri hem Yapay Sinir Ağı (YSA) hem de regresyon modelleri ile tahmin edilmiştir. 2009–2017 dönemine ait verilerle model kurulmuş, 2018 yılına dair tahminler yapılmıştır. Doğruluk karşılaştırması için MAPE (Ortalama Mutlak Yüzde Hata) değeri kullanılmıştır. Sonuçlara göre: 1: Regresyon yöntemi, YSA'ya göre daha düşük hata oranıyla daha iyi uyum göstermiştir. 2: 2019 yılı PM tahminleri yalnızca regresyon modeliyle yapılmıştır. Bu çalışma, hava kirliliği tahmininde klasik istatistiksel yöntemlerin bazı durumlarda yapay zekâ modellerinden daha etkili olabileceğini ortaya koymuştur (Akbulut ve Özcan, 2020).

Şehirlerin hava kalitesinin tahmin edilmesi amacıyla çeşitli makine öğrenmesi yöntemleri kullanılarak gerçekleştirilmiştir. Avrupa standartlarına dayalı Hava Kalite Endeksi (AQI) verileri, şehirlerin nüfusu, yapı yoğunluğu, yeşil alan miktarı ve ulaşım araç oranları gibi çeşitli şehirselle parametrelerle birlikte analiz edilmiştir. Sonuç olarak, makine öğrenmesi yöntemlerinin hava kalitesi sınıflandırmasında başarılı ve uygulanabilir bir yaklaşım sunduğu ortaya konmuştur (Öklü ve Canbay, 2023).

Yüksek (2007) yılında, yüksek lisans çalışmasında hava kirliliğinin tahmini amacıyla iki farklı yaklaşım karşılaştırılmıştır: 1: Çoklu Regresyon Analizi (CRA). 2: Yapay Sinir Ağları (YSA). Araştırmada çeşitli hava kirliliği parametreleri girdi olarak kullanılarak her iki model geliştirilmiş ve performansları ölçülmüştür. Sonuçlara göre, YSA modeli, doğrusal olmayan ilişkileri daha başarılı şekilde öğrenerek daha yüksek tahmin doğruluğu sağlamıştır. Buna karşın, CRA yöntemi, daha basit yapısıyla yorumlanabilirlik avantajı sunmuştur. Ayrıca YSA'nın hava kalitesi gibi karmaşık çevresel veriler üzerinde daha etkili bir yöntem olduğunu göstermektedir.

Maleki et al. (2019) çalışması, İran'ın hava kirliliği açısından en yoğun şehirlerinden biri olan Ahvaz'da yapay sinir ağlarının (YSA) hava kirliliği tahmininde kullanımı üzerine odaklanmaktadır. Çalışmada bir yıllık süre boyunca toplanan meteorolojik veriler ve hava kirlileti konsantrasyonları değerlendirilmiştir. YSA modeli, meteorolojik değişkenler ve geçmiş hava kirliliği değerlerini kullanarak O₃, NO₂, PM₁₀, PM_{2.5}, SO₂ ve CO gibi

kirleticilerin tahmininde uygulanmıştır. Sonuçlar, YSA'nın kısa vadeli hava kirliliği tahminlerinde başarılı performans sergilediğini göstermektedir. Araştırma, belediyeler ve karar vericiler için hava kalitesi yönetimi, erken uyarı sistemleri ve halk sağlığı planlamasında kullanılabilecek pratik bir yaklaşım önermektedir.

Alberini and Krupnick (1998) çalışmasında, PM₁₀ seviyelerinin akut solunum hastalığı başlangıçlarını önemli ölçüde etkilediğini; fakat epizod süresini etkilemediğini; ayrıca Tayvan'daki bireylerin hastalıktan kaçınmaya yönelik ekonomik değerlerinin (WTP) ABD'den basitçe aktarılması gerektiğini göstermektedir. Bu bulgular, yerel epidemiyolojik veriye dayanan politika-değerlendirme çalışmalarının önemini vurgular.

Qingxin et al. (2009) çalışmasında, Çin'in Harbin şehrinde PM₁₀ konsantrasyonlarını tahmin etmek amacıyla gri tahmin (grey prediction) modelini uygulamışlardır. Çalışma sonucunda, gri tahmin modellerinin kısa vadeli hava kalitesi öngörülerinde güvenilir bir araç olduğu ortaya konulmuştur. Bu çalışma, istatistiksel temelli yöntemlerin özellikle hızlı ve kısa dönemli projeksiyonlarda kullanılabilirliğine örnek teşkil etmektedir.

Cengiz vd. (2013) yılında, Samsun bölgesindeki hava kirliliği ile sağlık arasındaki ilişkiyi incelemiş, geliştirilmiş tahmin denklemleri metodunu kullanarak hava kirliliğinin bölgedeki hastalıklarla olan bağlantısını modellemiştir. Çalışma, hava kirliliği parametrelerinin yalnızca çevresel değil aynı zamanda halk sağlığı üzerinde de doğrudan etkili olduğunu vurgulamaktadır.

Endüstriyel kaynakların etkisini ele alan Arabacı vd. (2010) yılında, tuğla ve kiremit fabrikalarının hava kirliliğine olan katkılarını yapay sinir ağları (YSA) yöntemi ile modellemiştir. Bu çalışma, belirli sanayi tesislerinin lokal ölçekte hava kalitesi üzerinde ne kadar etkili olduğunu göstermesi bakımından önemlidir. Ayrıca YSA'nın, doğrusal olmayan ve çok değişkenli yapıları başarıyla modelleyebilmesi, hava kirliliği çalışmalarında esnek bir yaklaşım sunduğunu kanıtlamaktadır.

Tahmin performansını artırmaya yönelik bir diğer çalışma, Raimondo et al. (2007) tarafından yapılmıştır. Araştırmacılar, PM₁₀ konsantrasyonlarını öngörmek için yapay sinir ağları ve destek vektör makineleri (SVM) yöntemlerini karşılaştırmış ve veri güdümlü

yaklaşımların hava kirliliği tahmininde güçlü ve güvenilir araçlar olduğunu göstermiştir. Sonuçlar, makine öğrenmesi tabanlı yöntemlerin klasik istatistiksel yöntemlere kıyasla daha yüksek doğruluk sağlayabileceğini ortaya koymuştur.

Daha kapsamlı parametrelerin kullanıldığı bir diğer çalışma (Haiming and Xiaoxiao, 2013) tarafından yürütülmüştür. Bu çalışmada, PM_{2.5} konsantrasyonu tahmini için SO₂, PM₁₀, sıcaklık, basınç, nem, NO₂, rüzgâr hızı ve rüzgâr yönü gibi birçok değişken giriş verisi olarak kullanılmıştır. Araştırmacılar, tahminlerde RBF tabanlı yapay sinir ağlarını uygulamış ve modelin yüksek doğruluk sağladığını tespit etmiştir. Bu bulgu, meteorolojik ve kirlenici parametrelerin birlikte ele alınmasının model başarısını önemli ölçüde artırdığını göstermektedir.

Erbaşlar ve Taşdemir (2007) yılında, kentsel atmosferlerdeki hava kirlenicilerini meteorolojik parametrelerle ilişkilendirmişlerdir. Regresyon modelleri aracılığıyla SO₂, PM ve CO gibi kirlenicilerin sıcaklık, basınç, nem ve rüzgâr hızı ile ilişkilerini incelemişlerdir. Sonuçlar, meteorolojik faktörlerin hava kirliliği üzerinde doğrudan ve güçlü etkilerinin bulunduğunu ortaya koymuştur.

Çıldır ve Mutlu (2022) çalışmasında, 2017–2019 yılları arasında Balıkesir şehir merkezinde PM₁₀ ve SO₂ kirlilik seviyelerinin meteorolojik koşullarla ilişkisini incelemiştir. Sonuçlar, özellikle sonbahar sonu ve kış aylarında kirliliğin arttığını göstermiştir. Rüzgâr hızı ve sıcaklık en etkili faktörler olup, artışları kirlenici seviyelerini azaltmıştır. Ayrıca 100 µg/m³'ün üzerinde dört epizot dönemi tespit edilmiş, bunların hem yerel kaynaklardan hem de bölgesel taşınımlardan etkilendiği belirlenmiştir.

Alimissis et al. (2018) çalışması, Yunanistan'ın Atina metropol bölgesinde hava kirlenicilerin mekânsal dağılımını tahmin etmek amacıyla yapay sinir ağları (YSA) ve çoklu doğrusal regresyon (ÇDR) yöntemlerini karşılaştırmıştır. Araştırmada NO₂, NO, O₃, CO ve SO₂ gibi beş temel kirleniciye ait hava kalitesi izleme ağı verileri kullanılmıştır. Sonuçlar, YSA modellerinin özellikle ölçüm istasyonu yoğunluğunun düşük olduğu bölgelerde ÇDR'ye kıyasla daha yüksek doğruluk sağladığını ortaya koymuştur. Çalışma, YSA'nın mekânsal hava kirliliği modellemesinde güçlü bir araç olduğunu ve karar vericiler için daha güvenilir tahminler sunabileceğini göstermektedir.

Grivas and Chaloulakou (2006) yılında, Atina'da PM₁₀ partikül maddesinin saatlik seviyelerini tahmin etmek amacıyla yapay sinir ağı (ANN) modelleri geliştirmiştir. Çalışmada ANN, yüksek doğruluk oranları ile hem sabit hava durumu koşullarında hem de ani değişimlerde PM₁₀ tahmininde başarılı olmuştur. Ayrıca model, kısa vadeli hava kalitesi tahmini ve uyarı sistemleri için güvenilir bir araç olarak önerilmiştir.

Johnson and Perumalsamy (2024) tarafından Hindistan'ın sanayi bölgelerinde yapılan bir çalışmada, PM₁₀ ve SO₂ gibi kirleticilerin Ensemble-SMOTE tekniğiyle modellenmesi sayesinde çevre sağlığına yönelik risklerin daha doğru tahmin edilebildiği gösterilmiştir.

Monteiro Martins et al. (2025), PM₁₀ ve SO₂ gibi çevresel değişkenleri kullanarak hastane başvurularını tahmin etmeye yönelik bir sistematik derleme sunmuştur. Yapay sinir ağları ve regresyon modelleri ile gerçekleştirilen tahminlerde, hava kirliliği ile sağlık hizmetleri arasındaki güçlü ilişkiler ortaya konmuştur.

Sonuç itibarıyla, yapay zeka tabanlı ANN ve RBF modelleri, hava kalitesi bileşenlerini tahmin etme ve sağlık etkilerini modelleme konusunda şehire göre etkili sonuçlar sunmaktadır. Yapılan araştırmalar, bu tekniklerin karar destek sistemlerinde, erken uyarı yöntemlerinde ve şehir planlama süreçlerinde sıkça kullanılabileceğini ortaya koymaktadır. Yakın gelecekte, bu modellerin derin öğrenme ve karma yapay zeka sistemleri ile bir araya getirilmesi, daha detaylı ve doğru tahminlerin elde edilmesine olanak tanıyacaktır.

Bu tez çalışmada, Güney Marmara bölgesinde bulunan 3 şehrin Bursa, Çanakkale, ve Balıkesir illerine ait uzun aylık hava kirleticilerinin (PM₁₀ ve SO₂) incelenmiştir.

Çalışmasının temel amacı, hava kirliliği verilerinin yapay zekâ yöntemleriyle analiz edilerek çevresel etkilerinin daha doğru, güvenilir ve öngörülebilir biçimde ortaya konulmasını sağlamaktır. Literatürde son yıllarda özellikle Yapay Sinir Ağları (Artificial Neural Networks – ANN) kullanılarak hava kalitesi tahmini üzerine çok sayıda çalışma yapılmış olmakla birlikte, Radyal Tabanlı Fonksiyon (Radial Basis Function – RBF) ağlarının bu alandaki uygulamalarına sınırlı sayıda rastlanmaktadır. Bu durum, RBF tabanlı modellerin hava kirliliği verilerinin modellenmesi ve tahmin edilmesindeki potansiyelinin yeterince araştırılmadığını ve literatürde önemli bir boşluk bulunduğunu göstermektedir.

Bu tez kapsamında ANN ve RBF modellerinin karşılaştırmalı olarak ele alınmasıyla, farklı yapay zekâ yaklaşımlarının hava kirleticilerin zamansal değişimini modelleme ve tahmin etme performansları değerlendirilmekte; RBF modelinin alternatif ve tamamlayıcı bir yöntem olarak literatüre kazandırılması hedeflenmektedir. Çalışmadan elde edilecek bulguların, hava kalitesi tahminlerinde daha güvenilir ve yüksek doğruluğa sahip modellerin geliştirilmesine katkı sunacağı ve çevre yönetimi ile politika geliştirme süreçlerinde bilimsel temelli karar alma mekanizmalarını destekleyeceği düşünülmektedir. Bu yönüyle çalışma, mevcut literatüre katkı sağlamanın yanı sıra, ilerleyen dönemlerde yapılacak yapay zekâ tabanlı çevre ve hava kalitesi modelleme çalışmalarına metodolojik bir altyapı oluşturmayı amaçlamaktadır.

2. MATERYAL VE YÖNTEM

2.1 Uygulama Alanı

Bu tez çalışması, Şekil 2.1'de gösterildiği üzere Türkiye'nin Güney Marmara Bölgesi içerisinde yer alan Bursa Çanakkale ve Balıkesir illeri için gerçekleştirilmiştir. Seçilen çalışma alanları; sanayi faaliyetlerinin yoğunluğu, artan nüfus, ulaşım trafiği, tarımsal üretim ve ısınma kaynaklı emisyonlar gibi çeşitli antropojenik etkenlerin yanı sıra bölgenin meteorolojik koşulları ve coğrafi yapısı nedeniyle hava kirliliği açısından dikkat çeken iller arasında yer almaktadır. Güney Marmara Bölgesi, sanayi, kentsel ve kırsal alanları bir arada barındırması nedeniyle hava kirleticilerin mekânsal ve zamansal değişiminin incelenmesi için uygun bir çalışma alanı sunmaktadır. Bu çalışmada temel hava kirleticiler olarak PM₁₀ (10 mikrometreden küçük partikül madde) ve SO₂ (Kükürt Dioksit) ele alınmıştır. Bu kirleticiler, yanma ve endüstriyel faaliyetlerle doğrudan ilişkili olmaları, ölçüm istasyonlarında düzenli olarak izlenmeleri ve hava kalitesi değerlendirmelerinde yaygın şekilde kullanılmalrı nedeniyle tercih edilmiştir. Elde edilen veriler, yapay zekâ tabanlı modellerin performansını değerlendirmek ve hava kalitesi tahminlerinin doğruluğunu artırmak amacıyla analiz edilmiştir.



Şekil 2.1: Çalışmada PM₁₀ ve SO₂ analizleri için kullanılan çalışma alanının konumları (Arcgis).

2.2 Bölgesel Konum ve Genel Özellikler

Marmara Bölgesi, Türkiye'nin en yoğun nüfuslu ve ekonomik açıdan en gelişmiş bölgelerinden biridir. Bölge, karasal ve denizel iklim geçiş özellikleri gösteren karma bir iklim yapısına sahiptir. Özellikle Marmara Denizi, Çanakkale ve İstanbul Boğazları aracılığıyla deniz trafiğinin yoğunluğu, bölge genelinde hava kalitesini etkileyen ek bir faktördür. Seçilen üç il, hem birbirine komşu konumları hem de farklı emisyon profillerine sahip olmaları nedeniyle karşılaştırmalı analizler için uygundur.

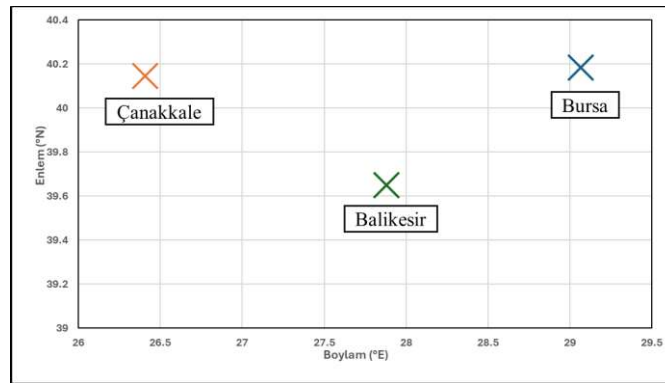
2.2.1 Hava kalitesi izleme altyapısı

Çalışmada kullanılan veriler, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Ulusal Hava Kalitesi İzleme Ağı kapsamında faaliyet gösteren istasyonlardan temin edilmiştir. İstasyonlar, otomatik ölçüm cihazları ile saatlik PM₁₀ ve SO₂ verilerini kaydetmektedir. Fakat bu çalışmada veriler, daha iyi sonuç ve detaylı analiz için verileri aylık olarak yapay zeka modellerinin eğitim, doğrulama ve test aşamalarında girdi olarak kullanılmıştır.

Tablo 2.1: Çalışma alanındaki hava kalitesi izleme istasyonlarının koordinatları.

İstasyon Adı	Enlem (°N)	Boylam (°E)
Bursa	40.1826	29.0669
Çanakkale	40.1467	26.4086
Balıkesir	39.6484	27.8826

Bu dağılım, bölgedeki hava kalitesinin hem kıyı hem iç kesimlerde, hem de sanayi yoğunluğu yüksek hem de görece düşük alanlarda karşılaştırmalı olarak değerlendirilmesine olanak sağlamaktadır.



Şekil 2.1: Çanakkale, Bursa ve Balıkesir illerindeki hava kalitesi izleme istasyonlarının konumu.

2.2.2 Bursa

Bursa, Türkiye'nin en önemli sanayi merkezlerinden biri olup ülke ekonomisinde stratejik bir konuma sahiptir. 40°11' kuzey enlemleri ve 29°04' doğu boylamları arasında yer alan kent, coğrafi konumu ve topoğrafik özellikleri bakımından dikkat çekmektedir. Özellikle otomotiv, tekstil, gıda ve metal işleme sanayilerinin yoğun faaliyet gösterdiği şehirde, bu endüstriyel üretim süreçleri sürekli emisyon kaynağı oluşturmaktadır. Yüksek nüfus yoğunluğu ve artan ulaşım talebi de kentsel hava kirliliğini artıran ek faktörler arasında yer almaktadır.

Bursa'nın Uludağ'ın kuzey eteklerinde konumlanması, topografik yapısı nedeniyle hava dolaşımını kısıtlamaktadır. Özellikle kapalı ve durağan meteorolojik koşullarda yeterli hava sirkülasyonunun sağlanamaması, kirletici gazların ve partikül maddelerin atmosferde birikmesine yol açmaktadır. Kış aylarında bu durum daha da belirginleşmekte, atmosferik inversiyon olaylarının sık görülmesi kirleticilerin üst atmosfer tabakalarına dağılmasını engelleyerek kent merkezinde yoğunlukların artmasına neden olmaktadır.

Sonuç olarak, Bursa'da sanayi kaynaklı emisyonların, ulaşım faaliyetlerinin ve topoğrafik-meteorolojik özelliklerin birleşimi, hava kirliliğini ciddi bir çevresel sorun haline getirmektedir. Bu durum, yalnızca çevresel açıdan değil, aynı zamanda halk sağlığı ve yaşam kalitesi bakımından da önemli riskler taşımaktadır.

2.2.3 Çanakkale

Çanakkale ili, yaklaşık 40.15°K enlemi ve 26.41°D boylamı üzerinde konumlanmakta olup, Çanakkale Boğazı kıyısındaki stratejik yeri nedeniyle hem ulaşım hem de çevresel faktörler açısından dikkat çekmektedir. Bölgedeki başlıca emisyon kaynakları; deniz taşımacılığı, kentsel ulaşım, ısınma faaliyetleri ve enerji üretim tesisleridir. Özellikle Çan ve Biga ilçelerinde faaliyet gösteren termik santraller, kış aylarında artan kömür tüketimi sonucunda PM₁₀ ve SO₂ düzeylerinde belirgin yükselişlere yol açmaktadır. Ayrıca, yoğun gemi trafiğinin gerçekleştiği Çanakkale Boğazı'nda deniz taşımacılığında kaynaklanan emisyonlar da hava kalitesini olumsuz etkilemektedir.

Meteorolojik koşullar da bölgedeki hava kirliliği üzerinde önemli rol oynamaktadır. Yaz mevsiminde etkili olan kuzey ve kuzeybatı yönlü rüzgârlar, zaman zaman Balkanlar ve Trakya üzerinden taşınan kirleticilerin bölgeye ulaşmasına neden olmaktadır. Kış aylarında

ise atmosferin durağanlaştığı ve sıcaklık terselmesi (inversiyon) olaylarının sıklaştığı dönemlerde, kirleticilerin dikey ve yatay taşınımı sınırlanmakta; bu durum, özellikle yerleşim alanlarında hava kirliliği seviyelerinin artmasına sebebiyet vermektedir.

2.2.4 Balıkesir


Balıkesir ili, Marmara Bölgesi'nin önemli yerleşim alanlarından biri olup, sanayi ve tarımsal üretimin birlikte yoğunlaştığı bir konuma sahiptir. Özellikle Bandırma ilçesi, gübre ve kimya sanayi kuruluşlarının yanı sıra termik enerji üretim tesislerinin varlığı ile dikkat çekmektedir. Bu tür faaliyetlerin, literatürde de belirtildiği üzere (örn. enerji üretimi ve kimya sanayi kaynaklı emisyonlar), hava kalitesini olumsuz yönde etkileyebilecek potansiyel kirletici unsurlar arasında yer aldığı ifade edilmektedir. Kent merkezinde ise özellikle kış aylarında artan katı yakıt kullanımı, PM₁₀ ve SO₂ gibi kirletici konsantrasyonlarının yükselmesine yol açmaktadır.

Coğrafi konumu itibariyle Balıkesir, yaklaşık 39.65°K enlemi ve 27.89°D boylamında bulunmakta ve bölgesel ölçekte hava kirliliği etkileşim alanında yer almaktadır. Nitekim, ilin Çanakkale ve Bursa gibi komşu illerden kirletici taşınımına açık olması, hava kalitesi üzerinde yalnızca yerel değil, aynı zamanda bölgesel kaynaklı etkilerin de rol oynadığını göstermektedir. Bu durum, Balıkesir'in hava kirliliği çalışmalarında hem yerel emisyonların hem de bölgesel taşınım süreçlerinin birlikte değerlendirilmesi gereken bir örnek teşkil ettiğini ortaya koymaktadır.

2.3 Veri Analizi

Bursa, Çanakkale ve Balıkesir illerine ait PM₁₀ ve SO₂ zaman serisi Şekil2.3'teki grafikleri incelendiğinde, iller arasında belirgin farklılıklar olduğu görülmektedir. PM₁₀ açısından Bursa ili diğer iki ile kıyasla oldukça yüksek konsantrasyon değerlerine ulaşmış, özellikle belirli dönemlerde (örneğin 20–25, 30–35 ve 55–65. gözlem aralıklarında) 5000 µg/m³'ün üzerine çıkan pikler dikkat çekmiştir. Bu durum, Bursa'da hava kalitesi açısından ciddi riskler barındıran kısa süreli ancak yoğun kirlilik olaylarının yaşandığını göstermektedir. Balıkesir'de PM₁₀ değerleri zaman zaman 1000–2000 µg/m³ seviyelerine yükselmiş olsa da Bursa kadar aşırı değerlere ulaşmamış; Çanakkale ise daha düşük ve stabil seviyelerde seyretmiştir. Bu bulgu, Bursa'da partikül madde kirliliğinin hem sıklık hem de yoğunluk bakımından daha ciddi bir sorun olduğunu ortaya koymaktadır.

SO₂ konsantrasyonları değerlendirildiğinde, Balıkesir’de ani ve yüksek zirveler dikkat çekmektedir. Özellikle 20–25, 35 ve 60 civarındaki gözlemlerde 600–700 µg/m³ seviyelerine ulaşan değerler, kirliliğin düzensiz fakat etkili bir şekilde ortaya çıktığını göstermektedir. Çanakkale’de ise başlangıçta oldukça yüksek bir SO₂ pikine rastlanmış, sonrasında dalgalanmalar daha orta düzeyde devam etmiştir. Bursa’da SO₂ değerleri diğer iki ile kıyasla daha istikrarlı olmakla birlikte, zaman zaman orta şiddette artışlar gözlenmiştir.



Sekil 2.2: 2013–2018 yılları arasında Bursa, Çanakkale ve Balıkesir illeri için ölçülen PM₁₀ (üstte) ve SO₂ (altta) konsantrasyonlarının zamansal değişimleri.

Genel olarak, PM₁₀ açısından en sorunlu ilin Bursa olduğu, SO₂ açısından ise Balıkesir’in daha düzensiz ve yüksek piklere sahip olduğu sonucuna ulaşılmıştır. Çanakkale her iki kirleticide de daha düşük konsantrasyonlara sahip olmakla birlikte, zaman zaman kısa süreli artışlar gösterebilmektedir. Bu farklılıklar, illerin sanayi yapısı, enerji kullanımı, meteorolojik koşulları ve topografik özellikleri ile ilişkili olabilir. Özellikle PM₁₀ ve SO₂’nin bazı dönemlerde eşzamanlı artış göstermesi, ortak kaynaklı kirlilik olaylarını (örneğin kömürle ısınma veya sanayi faaliyetleri) işaret etmektedir.

Tablo 2.2'den elde edilen istatistiksel veriler ayrıntılı olarak incelendiğinde, hem PM₁₀ hem de SO₂ değerlerinin şehirler arasında oldukça farklılık gösterdiği ve hava kalitesi açısından dikkat çekici sonuçlar ortaya koyduğu görülmektedir.

PM₁₀ değerleri üzerinden bakıldığında, Bursa istasyonu açık bir şekilde en yüksek kirlilik düzeyine sahiptir. Ortalama PM₁₀ konsantrasyonu 2275,70 µg/m³ olup bu değer hem ulusal hem de uluslararası hava kalitesi standartlarının çok üzerindedir. Medyan değer (1981,56 µg/m³) ortalamadan daha düşük olması ve pozitif çarpıklık (0,69) dağılımın sağa çarpık olduğunu göstermektedir. Bu durum, ölçümlerin büyük bir kısmının ortalamanın altında yoğunlaştığını, fakat zaman zaman ortaya çıkan çok yüksek değerlerin ortalamayı yukarı çektiğini düşündürmektedir. Standart sapmanın oldukça yüksek olması (1190,15 µg/m³) ve değişim katsayısının %52'yi aşması, Bursa'da PM₁₀ konsantrasyonlarının oldukça dalgalı olduğunu ortaya koymaktadır. Maksimum değer 5867,24 µg/m³ gibi son derece yüksek bir seviyeye ulaşmış olup, bu tür zirve değerler özellikle kısa vadeli sağlık etkileri açısından ciddi risk teşkil etmektedir. Çanakkale'de ise ortalama PM₁₀ değeri 552,58 µg/m³ ile Bursa'ya göre oldukça düşüktür, ancak yine de normal kabul edilebilecek seviyelerin üstündedir. Medyan ile ortalamanın birbirine yakın olması (530,56 – 552,58 µg/m³) dağılımın daha dengeli olduğunu gösterirken, pozitif çarpıklık (0,52) ve kurtosis (1,16) değerleri uç örneklerin varlığını ortaya koymaktadır. Balıkesir'deki ortalama PM₁₀ değeri 967,27 µg/m³ olup, Çanakkale'den yüksek fakat Bursa'dan oldukça düşüktür. Standart sapma (460,71) ve değişim katsayısı (%47,63) burada da önemli bir dalgalanma olduğunu göstermektedir. Pozitif çarpıklık (0,54) yüksek değerlerin varlığını işaret ederken, basıklığın -0,08 olması uç değerlerin dağılımının daha sınırlı olduğunu düşündürmektedir. Genel olarak üç şehirde de PM₁₀ konsantrasyonlarının çok yüksek olduğu, özellikle Bursa'da ölçülen değerlerin insan sağlığı üzerinde ciddi olumsuz etkilere yol açabilecek seviyelere ulaştığı ifade edilebilir.

Tablo 2.2: Bursa, Çanakkale ve Balıkesir illerine ait PM10 ve SO2 konsantrasyonlarının temel istatistikleri.

Variable	Mean	StDev	CoefVar	Minimum	Median	Maximum	Skewness	Kurtosis
PM ₁₀ _Bursa($\mu\text{g}/\text{m}^3$)	2275.70	1190.15	52.30	77.60	1981.56	5867.24	0.69	0.22
PM ₁₀ _Çanakkale($\mu\text{g}/\text{m}^3$)	552.58	248.68	45.00	29.48	530.56	1434.08	0.52	1.16
PM ₁₀ _Balıkesir($\mu\text{g}/\text{m}^3$)	967.27	460.71	47.63	36.82	878.60	2189.63	0.54	-0.08

Variable	Mean	StDev	CoefVar	Minimum	Median	Maximum	Skewness	Kurtosis
SO ₂ _Bursa($\mu\text{g}/\text{m}^3$)	135.96	101.28	74.50	1.32	102.96	377.24	0.84	-0.23
SO ₂ _Çanakkale($\mu\text{g}/\text{m}^3$)	181.19	122.62	67.68	6.46	153.29	568.61	1.03	0.68
SO ₂ _Balıkesir($\mu\text{g}/\text{m}^3$)	164.06	147.25	89.75	1.78	112.57	691.47	1.38	1.74

SO₂ değerleri açısından bakıldığında, şehirler arası farklılık PM10 kadar belirgin olmamakla birlikte, yine dikkat çekici sonuçlar elde edilmiştir. Bursa'da ortalama SO₂ konsantrasyonu 135,96 $\mu\text{g}/\text{m}^3$ 'tür. Medyan (102,96 $\mu\text{g}/\text{m}^3$) ortalamadan daha düşük olup, sağa çarpıklık (0,84) dağılımın dengesiz olduğunu göstermektedir. Değişim katsayısının %74,50 gibi oldukça yüksek bir değerde olması, SO₂ konsantrasyonlarının zaman içinde büyük dalgalanmalar gösterdiğini işaret etmektedir. Çanakkale'de ortalama SO₂ değeri 181,19 $\mu\text{g}/\text{m}^3$ olup, Bursa'dan daha yüksek bir düzeydedir. Medyan (153,29 $\mu\text{g}/\text{m}^3$) ortalamadan düşük, sağa çarpıklık (1,03) ise belirgin biçimde pozitif yönlüdür. Bu durum Çanakkale'de de nadiren çok yüksek değerlerin gözlemlendiğini ortaya koymaktadır. Kurtosis değerinin 0,68 olması, dağılımın normal dağılıma göre daha sivri uçlu olduğunu ve aşırı değerlerin daha sık görüldüğünü göstermektedir. Balıkesir'de ise ortalama SO₂ değeri 164,06 $\mu\text{g}/\text{m}^3$ olup, Çanakkale ile benzer, Bursa'dan ise daha yüksektir. Ancak Balıkesir'i diğerlerinden ayıran özellik, dağılımın aşırı dengesizliğidir. Standart sapma (147,25 $\mu\text{g}/\text{m}^3$) ve değişim katsayısı (%89,75) en yüksek değerlerdir. Çarpıklık katsayısının 1,38 ve kurtosis değerinin 1,74 olması, Balıkesir'de SO₂ dağılımının ağır kuyruklu olduğunu, yani nadir fakat son derece yüksek zirve değerlerin mevcut olduğunu göstermektedir. Bu tür uç değerler özellikle kısa süreli maruziyetlerde ciddi sağlık riskleri doğurabilir.

Tüm bu bulgular birlikte değerlendirildiğinde, PM₁₀ kirliliği açısından en sorunlu bölge Bursa iken, SO₂ açısından en istikrarsız ve uç değerlere en yatkın bölge Balıkesir olarak öne çıkmaktadır. Çanakkale ise her iki kirlenici bakımından orta seviyelerde bulunmakta, fakat zaman zaman yüksek konsantrasyonların görüldüğü anlaşılmaktadır. Bu durum, sadece ortalama değerlerin değil, aynı zamanda dağılımın şeklinin (çarpıklık ve basıklık) ve değişkenliğin (standart sapma ve CV) de dikkate alınmasının önemini ortaya

koymaktadır. Özellikle yüksek çarpıklık ve kurtosis değerleri, belirli dönemlerde çok yüksek değerlerin görülebildiğini, bu nedenle ortalama değerlerin tek başına durumu yansıtmada yetersiz kalabileceğini göstermektedir.

Sonuç olarak, çalışmada elde edilen istatistikler bölgedeki hava kirliliğinin hem düzey hem de süreklilik açısından ciddi bir problem olduğunu ortaya koymaktadır. Elde edilen yüksek ortalamalar uzun vadeli kronik etkilerin, nadir fakat çok yüksek pikler ise kısa vadeli akut etkilerin göz ardı edilmemesi gerektiğini göstermektedir. Dolayısıyla, politika yapıcılarının yalnızca ortalama değerleri değil, aynı zamanda maksimum değerleri, sınır aşım sıklıklarını ve uç değerlerin dağılımını da göz önünde bulundurmaları önem arz etmektedir.

2.4 Hava Kalitesinin İzlenmesi ve Modellenmesi

Hava kalitesi, atmosferde bulunan kirleticilerin yoğunluğu ve dağılımı ile tanımlanan bir çevresel sağlık göstergesidir. Türkiye genelinde PM₁₀, SO₂ ile birlikte 1980'lerden beri tüm il merkezlerinde ölçülmektedir. Havanın kalitesini değerlendirmek için çeşitli parametreler (kirleticiler) izlenir. Bu parametreler hem insan sağlığı hem de ekosistem üzerindeki etkiler açısından büyük öneme sahiptir. Bu çalışmada Partikül Madde 10 (PM₁₀) ve Kükürt Dioksit (SO₂) parametreleri incelenmektedir.

2.4.1 Partikül Madde 10 (PM₁₀)

Havadaki çapı 10 mikrometreden (μm) küçük olan partiküller PM₁₀ grubuna girmektedir. İçerdikleri benzopiren, furan, dioksin ve ağır metaller gibi toksik maddeler nedeniyle kanser riski taşımakta ve ciddi sağlık tehditleri oluşturmaktadır. Dünya Sağlık Örgütü (WHO), PM₁₀ için ortalama günlük sınır değerini 50 $\mu\text{g}/\text{m}^3$, yıllık sınır değerini ise 20 $\mu\text{g}/\text{m}^3$ olarak belirlemiştir.

Bununla birlikte, birçok ülkede resmi uyarılar yalnızca günlük PM₁₀ konsantrasyonunun 200 $\mu\text{g}/\text{m}^3$ seviyesine ulaştığında yapılmaktadır. Bu durum, genellikle yanlış bir güvenlik algısına neden olur; çünkü hava kalitesi, alarm eşiğine gelmeden çok önce insan sağlığı için tehlikeli hale gelebilmektedir (Merkezi, 2015; Avşar, 2015).

Partikül maddeler, aerodinamik çapları temel alınarak sınıflandırılır. Hava kalitesi izleme çalışmalarında kullanılan temel parametrelerden PM₁₀, 10 μm 'den küçük; PM_{2.5} ise 2.5 μm 'den küçük partikülleri ifade eder. Bu partiküller hem insan kaynaklı (antropojenik)

hem de doğal süreçler sonucu atmosfere karışır. Antropojenik kaynaklar arasında sanayi tesisleri, enerji üretim merkezleri, yakma sistemleri ve inşaat faaliyetleri yer alırken; orman yangınları ve uzun mesafeli toz taşınımı doğal kaynaklar arasında değerlendirilmektedir. Günlük yaşamda karşılaşılan partikül maddeler yalnızca toz, sis ve duman formunda değil, aynı zamanda bakteri, mantar ve alg gibi biyolojik partiküller şeklinde de bulunabilir (Peavy et al., 1985; Godish, 2004). Ayrıca evsel ısınma, endüstriyel süreçler ve trafik de partikül madde oluşumuna katkı sağlayan önemli faktörlerdir..

Partiküler maddelerin kimyasal bileşimi ve özellikleri oldukça değişkendir. Bu maddeler genel olarak organik ve inorganik bileşenler olarak ikiye ayrılır. İnorganik bileşenler arasında sülfat, nitrat, kurşun, demir, mangan, çinko ve vanadyum yer alırken; organik bileşenler hidrokarbonlar, fenoller, organik asitler ve alkoller içermektedir. Ayrıca bazı partiküller, mikroorganizmalar olarak bilinen biyolojik kökenli yapılar olabilir.

PM₁₀'un insan sağlığı üzerindeki etkileri özellikle solunum sistemi üzerinde yoğunlaşmaktadır. Yüksek düzeyde PM₁₀ maruziyeti, öksürük nöbetleri, hırıltılı solunum ve astım ile bronşit gibi hastalıkların şiddetlenmesine yol açabilir. Uzun süreli maruziyet ise kalp krizi (miyokard enfarktüsü) ve felç gibi kardiyovasküler hastalık risklerini artırmaktadır. PM₁₀ içinde bulunan benzopiren gibi kimyasallar ise yüksek kanserojen potansiyele sahiptir.

2.4.2 Kükürt Dioksit (SO₂)

Boğucu, keskin kokulu ve renksiz bir gaz olan kükürt dioksit (SO₂), kükürt oksitleri arasında en yaygın olanıdır. Enerji üretimi ve endüstriyel faaliyetler sırasında yakılan kömür, linyit ve petrol türevleri, bu gazın başlıca kaynaklarını oluşturmaktadır (WHO, 1980: 97). Bunun yanı sıra, aktif volkanlar ve jeotermal kaynaklar gibi doğal süreçler de atmosfere belirli miktarda SO₂ salınımına neden olmaktadır. Havada bulunan nem ile kimyasal tepkimeye girdiğinde asit yağmurları oluşumuna yol açan bu gaz, yalnızca insanlar için değil, bitkiler ve ekosistemler açısından da zararlı etkiler göstermektedir (Nations, 2010).

SO₂, oda sıcaklığında kararlı bir gaz olup yanıcı değildir (Fan et al., 2017). Atmosfere salındıktan sonra birkaç gün boyunca havada kalabilir ve rüzgâr, sıcaklık gibi meteorolojik faktörlerin etkisiyle yüzlerce kilometre uzağa taşınabilir (Barbulescu and Barbes, 2017).

Bu kirleticinin etkilerini azaltmak için yenilenebilir enerji kaynaklarının yaygınlaştırılması ve fosil yakıtlara alternatif çevreci yakıtların tercih edilmesi önem taşımaktadır (Peavy et al., 1985).

Hava kirletici madde konsantrasyonlarındaki artışın büyük oranda insan faaliyetlerinden kaynaklandığı bilinmektedir. Özellikle Covid-19 pandemisi döneminde uygulanan kısıtlamalar, nüfus hareketliliğini azaltmış ve bu süreçte hava kirliliği düzeylerinde ölçülebilir değişikliklerin meydana gelip gelmediğini araştıran çok sayıda çalışma yapılmıştır.

SO₂'nin insan sağlığı üzerindeki etkileri özellikle solunum sistemi ile ilgilidir. Bu gazın yüksek konsantrasyonlara ulaşması, akciğer hastalıkları ve kronik solunum yetmezliği olan bireylerde ölümcül sonuçlara yol açabilmektedir. Ayrıca SO_x grubu gazlar, metal yüzeylerde korozyon, boya ve yapı malzemelerinde bozulma gibi etkilerle de tanınmaktadır. En ciddi çevresel etkileri ise, asit yağmurlarına neden olarak bitki örtüsünü ve orman ekosistemlerini tahrip etmesidir. Asit yağmurları, yalnızca SO_x gazlarından değil, aynı zamanda NO_x (azot oksit) bileşiklerinden de kaynaklanmaktadır. Bu kirleticiler, atmosferdeki su buharı ile birleşerek sülfürik ve nitrik asit gibi güçlü asitlere dönüşür. Ortaya çıkan asitli damlalar, yağmur yoluyla yeryüzüne inerek toprak, su kaynakları ve bitki örtüsü üzerinde yıkıcı etkiler oluşturur.

Asidik yağışların iki temel dolaylı zararı vardır. İlk olarak, yüzeysel akış yoluyla su kaynaklarının kimyasal dengesini bozar. İkinci olarak, toprakta bulunan besin maddelerinin çözünmesini artırarak bu besinlerin kaybına neden olur. Bu süreç, bitkilerin gelişimini olumsuz etkiler ve ekosistemin üretkenliğini azaltır. Ayrıca, asit yağmurları tarihî ve kültürel yapıların da bozulmasına yol açar; özellikle mermer ve kireç taşı gibi malzemelerden yapılmış antik eserler ciddi biçimde zarar görmektedir.

2.5 Yapay Zekâ Tabanlı Tahmin Modelleri

Son yıllarda, veri miktarının hızla artması ve sistemlerin karmaşıklığının çoğalmasıyla birlikte, geleneksel istatistiksel yöntemler bazı durumlarda yetersiz kalmaktadır. Özellikle çok değişkenli ve doğrusal olmayan ilişkilerin bulunduğu alanlarda, klasik regresyon veya korelasyon teknikleri, veri içindeki gizli örüntüleri ve karmaşık etkileşimleri yeterince yakalayamaz. Bu noktada yapay zekâ (YZ) tabanlı yöntemler, veriler arasındaki karmaşık

ilişkileri modelleme ve geleceğe dönük tahminler yapma konusunda önemli avantajlar sunar.

Yapay zekâ, temel olarak insan bilişsel süreçlerini taklit edebilen bilgisayar sistemlerini ifade eder. Bu sistemler; öğrenme, genelleme, karar verme ve problem çözme yeteneklerine sahiptir. Girdi olarak sağlanan verilerden örüntü ve ilişki çıkarma kapasitesi, YZ yöntemlerini özellikle çevre mühendisliği, enerji yönetimi, finans, sağlık ve ulaşım gibi alanlarda vazgeçilmez kılar.

Hava kirliliği tahmini, YZ yöntemlerinin yoğun olarak uygulandığı bir alan olarak öne çıkar. Hava kirleticiler ile meteorolojik değişkenler (sıcaklık, nem, rüzgâr hızı, basınç vb.) arasındaki etkileşimler genellikle doğrusal olmayan ve değişkenlere bağlıdır. Bu nedenle, yapay sinir ağları (ANN) ve radial basis function (RBF) ağları gibi yöntemler, klasik yöntemlerden daha yüksek doğrulukla tahminler yapabilmektedir. Bu modeller, geçmiş verilerden öğrenme, gizli ilişkileri keşfetme ve bilinmeyen koşullarda tahmin yapabilme gibi özellikleri sayesinde hava kalitesi yönetiminde kritik bir araç olarak kullanılmaktadır. (Yadav et al., 2024), ANN tekniklerinin hava kirleticilerini geleneksel yöntemlere göre daha hassas bir şekilde tahmin ettiğini belirtmişlerdir. (Sun et al., 2008), RBF ağlarının, Iowa'daki domuz yetiştirme tesislerinde günlük hava kalitesi tahminlerinde yüksek doğruluk sağladığını göstermişlerdir. Bu çalışmada, hava kirleticilerin tahmininde ANN ve RBF modellerinin uygulanabilirliği araştırılacaktır. Bu iki yöntem, hem doğrusal olmayan ilişkileri yakalama hem de veri setindeki gürültü ve belirsizliklere karşı esnek olma özellikleri nedeniyle tercih edilmiştir. Takip eden bölümlerde, önce ANN'nin temel yapısı ve çalışma prensipleri, ardından RBF modelinin işleyişi detaylı olarak açıklanacaktır.

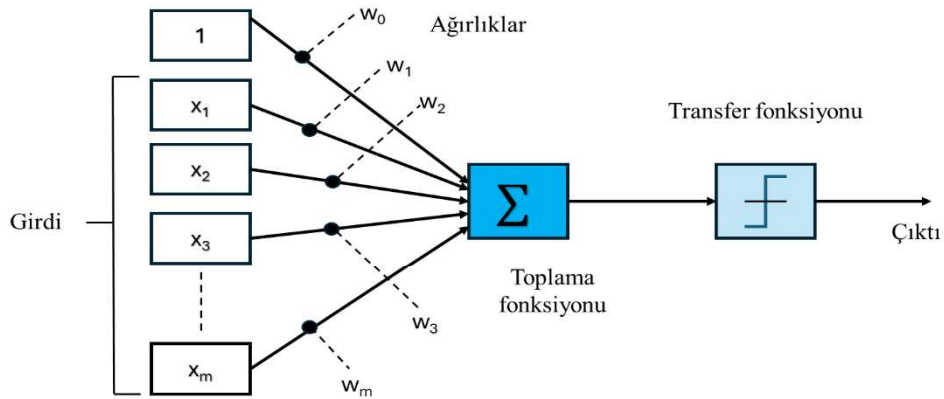
2.5.1 Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları (Artificial Neural Networks- ANN), insan beyninin bilgi işleme biçimini taklit ederek öğrenme ve genelleme yeteneği sağlayan, çok katmanlı ve paralel yapıya sahip hesaplama modelleridir. İlk olarak 1943 yılında McCulloch ve Pitts tarafından önerilen bu modeller, 1980'lerden itibaren artan işlem gücü ve veri miktarının etkisiyle çeşitli mühendislik ve bilimsel alanlarda yaygın olarak kullanılmaya başlanmıştır (McCulloch and Pitts, 1943).

YSA, bir matematiksel modelleme sistemidir. Bu model, birbirine bağılı nöronlardan oluşu n katmanlar içermektedir (Tosunoğlu ve Benli, 2012: 542; Benli ve Yıldız, 2014: 216). YSA'nın kullanımı, istatistiksel modelleme ve tahmin çalışmalarında, bir eğitim veri kümesine dayalı olarak o verileri üreten istatistiksel süreci temsil edip yeni verilerle en doğru tahmini gerçekleştirmek adına düzenlenmiştir. Yapay Sinir Hücresi (YSH) ya da yapay nöron, YSA'nın temel bileşeni veya işlem birimidir (Aygören vd., 2012: 78).

Sinir hücreleri belirli görevler üstlense de, tek başlarına çoğunlukla anlamlı bir sonuç ortaya koymazlar. Hücrelerin bir arada bulunması ve aralarındaki uyum, problemlerin çözümünde belirleyici rol oynar. Ancak yalnızca bu hücrelerin varlığı, insanın bazı şeyleri algılaması için yeterli değildir. İçgüdüsel davranışların ötesindeki öğrenme ve uygulamalar, tekrar süreçleri sonucunda gelişir. Bir durumun defalarca yaşanması, beynin buna karşı verdiği cevabın doğruluk ihtimalini yükseltir. Yapay sinir ağları da aynı prensiple çalışır; kullanılan nöron sayısı, eğitim sürecinde yapılan tekrarların miktarı ve verilerin çeşitliliği, modelin başarısını doğrudan etkiler.

Şekil 2.3'te verilen yapay sinir ağı modeli, biyolojik sinir sistemini andıran dört ana bileşene sahiptir. İlk adımda sisteme giriş verileri sağlanır. Bu veriler, ağırlıklarla çarpılarak toplama işlemine dahil edilir. Elde edilen sonuç, transfer fonksiyonuna gönderilir ve burada işlenir. İşlenen bilgiler tekrar toplama fonksiyonuna aktarılır ve bu döngü, öğrenme süreci tamamlanıncaya kadar devam eder. Eğitim süreci sona erdiğinde modelden çıktı alınabilir (Anderson and McNeill, 1992).



Şekil 2.3: Yapay sinir ağı yapısı (Saplioğlu, 2010).

Girdiler: Nöronların işleyişi için giriş verileri temel bir unsur olarak kabul edilir. Bir olayı etkileyen parametrelerin düzenli bir şekilde modele aktarılması gerekmektedir. Bu sebeple, nöronlar üzerinden oluşturulacak bir modelde kullanılan verilerin olayın tamamını yansıtacak kapsamda olması kritik öneme sahiptir. Eğer veriler yalnızca olayın belirli bir bölümünü temsil ediyor veya olayla ilgisiz özellikler içeriyorsa, insan beyninde olduğu gibi yapay sinir ağı hücreleri de problemi tam anlamıyla kavrayamaz ve doğru çıktılar üretilemez.

Ağırlıklar: Bir olay birden fazla parametreden etkileniyorsa, bu parametrelerin her birinin olayı aynı düzeyde temsil edeceği varsayımı doğru değildir. Bu nedenle her parametreye bir ağırlık değeri atanmalı ve modele bu ölçüde katkı sağlaması sağlanmalıdır. Yapay sinir ağlarında model kurulurken, sisteme girilen parametreler arasındaki ilişkiler karşılaştırılır ve en uygun ağırlıkların atanması hedeflenir. Bu yaklaşım, elde edilen sonuçların doğruluğunu artırır. Ayrıca, modele dahil edilen parametre sayısının fazla olması, nöronların bu ağırlıkları daha doğruya yakın şekilde belirleyebilmesi bakımından kritik bir rol oynamaktadır.

Toplama işlemi: Nöronlarda kullanılan toplama işlevi, her girişin ait olduğu ağırlıkla çarpılmasının ardından elde edilen değerlerin toplanması ve bu sonuca eşik değerlerinin eklenmesiyle tanımlanır (Denklem 2.1). Bununla birlikte, problemin karakterine göre bu işlevin farklı biçimlerde uygulanması mümkündür. Örneğin, toplama işleminin yerine minimum, maksimum, çarpım veya rastgele normalizasyon temelli fonksiyonlar kullanılabilir (Elmas, 2003).

$$V_i = \sum_{i=1}^n w_{ij} x_i + \theta_j \quad (2.1)$$

İfade edilen formülde V_i , toplama fonksiyonunu; w_{ij} , girişlere ait ağırlıkları; x_i , kullanılan girdileri ve θ_j ise toplama sonucuna eklenen eşik değerini tanımlamaktadır.

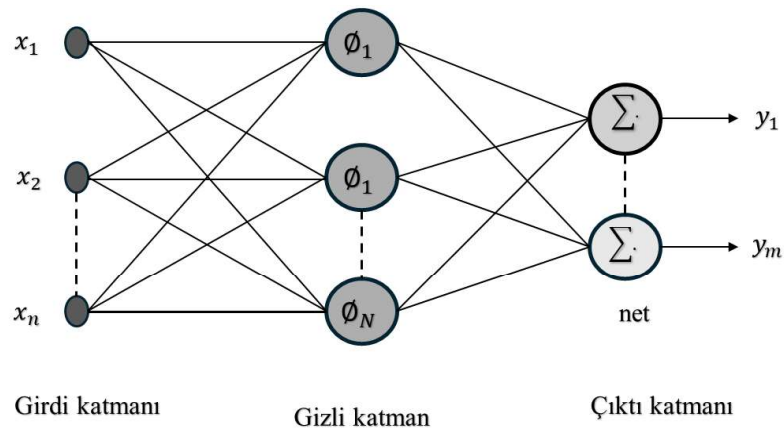
Transfer fonksiyonu: Bir nöronun toplama sonucundan çıkan değer, transfer fonksiyonundan geçirilerek çıkış katmanına gönderilir. Bu aşamada önceden belirlenmiş bir eşik değeri dikkate alınır. Fonksiyon çıktısı eşikten büyükse eğitim tekrarlanır ve yeni

değerler üretilir; küçükse döngü sonlandırılarak model geliştirilmiş olur. Bununla birlikte, eşik değer aşılmış olsa bile kimi durumlarda kullanıcının kararıyla öğrenme süreci sonlandırılarak doğrudan sonuçlara ulaşmak da mümkündür.

Çıkış Fonksiyonu: Transfer fonksiyonu, nöronun ürettiği çıktıyı dışarıya ya da diğer nöronlara iletir. Bir nöronun tek bir çıkışı vardır ve bu çıkış, biyolojik sinirlerde olduğu gibi önce hücre içinde işlenip sonrasında başka nöronlara aktarılabilir.

2.5.2 Radyal Tabanlı Yapay Sinir Ağları (RBF)

Radyal Tabanlı Yapay Sinir Ağları (RBF), 1988’de geliştirilen ve biyolojik sinir hücrelerindeki uyarı–tepki prensibinden ilham alan özel bir ağ türüdür (Broomhead and Lowe, 1988). İlk kez filtreleme uygulamalarında kullanılarak yapay sinir ağları literatürüne girmiştir. Bu yöntemin öğrenme süreci, çok boyutlu bir uzayda verilerle en iyi uyumu sağlayacak yüzeyin oluşturulması şeklinde düşünülebilir (Ham and Kostanic, 2000). Dolayısıyla eğitim, temelde bir interpolasyon problemine karşılık gelmektedir. RBF’nın yapısı, klasik sinir ağı modellerinde olduğu gibi giriş, gizli ve çıkış katmanlarından oluşsa da (Şekil 2.4), farklılık gizli katmana geçişte ortaya çıkar. Burada radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan kümeleme yöntemleri kullanılır. Çıkış katmanı ise diğer sinir ağı türlerinde olduğu gibi modelin asıl öğrenme işlemlerinin gerçekleştiği bölümdür.



Şekil 2.4: RBF’nın yapısı (Okkan ve Dalkılıç, 2012).

RBF modellerinde ağ tarafından üretilen çıktı (y), Denklem 2.2 kullanılarak hesaplanmaktadır.

$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c_k) = \sum_{k=1}^n w_{ik} \phi_k(\|x - c_k\|_2), \quad i = 1, 2, \dots, m \quad (2.2)$$

Modelde kullanılan gösterimler şu şekildedir: $x \in \mathbb{R}^{n \times 1}$ giriş vektörünü, $\phi_k(\cdot) \in \mathbb{R}^+$ Radyal tabanlı aktivasyon fonksiyonunu, $c_k \in \mathbb{R}^{n \times 1}$ giriş uzayından seçilmiş merkez vektörlerini tanımlar. Girdi ile merkez arasındaki mesafe, $\|\cdot\|_2$ normu yardımıyla hesaplanmaktadır, Çıkış katmanında yer alan bağlantı ağırlıkları w_{ik} ile, gizli katmandaki nöronların sayısı ise N ile ifade edilmektedir.

RBF yapılarında belirleyici unsurlar; hücrelerin merkezleri, çıkış katmanındaki ağırlık değerleri ve tercih edilen aktivasyon fonksiyonunun yapısıdır. Ayrıca bu modellerde çeşitli aktivasyon fonksiyonları kullanılma imkânı vardır. Çeşitli aktivasyon fonksiyonları arasında doğrusal, kübik, Gauss, multi-kuadratik ve ters multi-kuadratik fonksiyonlar yer almaktadır. Bu araştırmada Gauss fonksiyonu seçilmiş ve ilgili matematiksel formülasyon Denklem 2.3'de verilmiştir.

$$\phi_k(x) = \exp(-(\|x - c_k\|_2)^2 / 2\sigma^2) \quad (2.3)$$

Bu ifadede x giriş vektörünü, c_k merkezleri göstermektedir. σ ise merkezleri temsil etmektedir. σ değeri standart sapmayı göstermekte olup, yapay sinir ağları literatüründe RBF modelinin başarımını doğrudan etkileyen yayılım (spread) parametresi olarak da tanımlanmaktadır (Ham and Kostanic, (2000).

2.6 Model Performans Kriterleri Hakkında Genel Bilgi

Hidrolojik ve çevresel modelleme çalışmalarında, kurulan modellerin güvenilirliğini ve doğruluğunu değerlendirmek için çeşitli istatistiksel performans ölçütleri kullanılmaktadır. Bu ölçütler, model çıktıları ile gözlenen veriler arasındaki uyum derecesini ortaya koyarak modelin gerçek sistemi ne ölçüde temsil ettiğini gösterir. Yaygın olarak kullanılan kriterler arasında Nash–Sutcliffe Etkinlik Katsayısı (NSE), Kök Ortalama Hata Oranı (RSR), Yüzdellik Sapma (PBIAS) yer almaktadır.

y_i : i'nci zaman adımıdaki gözlenen (ölçülen) değer, $y\gamma_i$: i'nci zaman adımıdaki model tarafından simüle edilen (tahmin edilen) değer, ve y : gözlenen değerlerin ortalaması, n :toplam veri sayısı.

Bu analizin Avantajlar ve Dezavantajlar vardır.

❖ NSE Katasisının avantajları

- PEC'in geliştirilmesine elverişli nicel bir ölçüdür;
- Sürekli uzun vadeli simülasyonlarda kullanıma uygundur ve modelin ilgili çıktı tepkisi eğilimlerini ne kadar iyi simüle ettiğini belirlemek için kullanılabilir;
- Sağlamdır ve çeşitli çıktı tepkileri ve zamansal ölçekler için model performansını değerlendirmek için kullanılabilir; ve
- yaygın olarak kullanılır, yani bildirilen değerler hakkında karşılaştırma amacıyla kullanılabilir kapsamlı bilgi vardır. Ayrıca, ölçüm belirsizliğini de içerebilir. (Harmel and Smith, 2007; Harmel et al., 2010).

❖ NSE, NSE Katasisının dezavantajları:

- Model yanlılığını belirlemeye yardımcı olamaz ve tepe akışlarının zamanlaması ve büyüklüğü ile durgunluk eğrilerinin şeklindeki farklılıkları belirlemek için kullanılamaz;
- Başka bir deyişle, tek olaylı simülasyonlar için kullanılamaz.

Note; kare farklar nedeniyle uç değerlere duyarlıdır (Krause vd., 2005). Uç değer durumlarının üstesinden gelmek ve daha düşük ölçülen ve simüle edilen değerlere duyarlılığı artırmak için Krause vd. (2005), NSE ve d'nin logaritmik ve bağıl türev formlarının kullanılmasını önermiştir ve bu katsayıyı Denklem (2.4) ile hesaplanmaktadır. Ölçülen verilerin aynı çalışma alanında yüksek ve düşük dağılımlara sahip iki modlu olduğu durumlarda, örneğin Cho ve Olivera (2009) tarafından ölçülen akışlarda, daha düşük değerlerin simülasyonuna doğru bir eğilimden kaçınmak için iki veri kategorisinin ayrılması önerilir.

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - y\gamma_i)^2}{\sum_{i=1}^n (y_i - y)^2} \quad (2.4)$$

RSR için: RSR, hata endeksi istatistiklerinin avantajlarını bünyesinde barındırır ve bir ölçekleme/normalleştirme faktörü içerir, böylece elde edilen istatistikler ve raporlanan değerler çeşitli çıktı yanıtlarına uygulanabilir. Dezavantajları: RSR, paydadaki kare fark değerleri nedeniyle yüksek değerlerdeki hatalar genellikle düşük değerlerdeki hatalardan mutlak değer olarak daha büyük olduğundan, düşük değerlere kıyasla yüksek değerlere daha fazla ağırlık verir. Notlar: RSR, nispeten yeni bir istatistiksel performans ölçüsü olduğundan, H/WQ modelleme literatüründe yaygın olarak kullanılmamıştır. (denklem.2.5).

$$RSR = 1 - \frac{\sqrt{\sum_{i=1}^n (y_i - y_i)^2}}{\sqrt{\sum_{i=1}^n (y_i - y)^2}} \quad (2.5)$$

❖ PBIAS avantajlar:

- Modelin, ilgili çıktı tepkisi için ortalama büyüklükleri ne kadar iyi simüle ettiğini belirlemek için kullanılabilir;
- Sürekli uzun vadeli simülasyonlar için faydalıdır;
- Sağlamdır ve yaygın olarak kullanılır, yani bildirilen değerler hakkında kapsamlı bilgi vardır;
- Ortalama model simülasyon yanlılığını (aşırı tahmin veya düşük tahmin) belirlemeye yardımcı olabilir; ve
- Ölçüm belirsizliğini içerebilir (Harmel et al., 2010).

❖ PBIAS Dezavantajları:

- Tepe akışlarının zamanlaması ve büyüklüğündeki farklılıkları ve durgunluk eğrilerinin şeklini belirlemek için tek olaylı simülasyonlarda veya
- Modelin ilgili çıktı tepkisi için kalıntı değişimlerini ve/veya eğilimleri ne kadar iyi simüle ettiğini belirlemek için kullanılamaz.

Notlar: Model, düşük tahmin ettiği kadar yüksek tahmin de yapıyorsa, PBIAS model performansına yanıltıcı bir puan verebilir. Bu durumda, model simülasyonu zayıf olsa bile PBIAS sifıra yakın olacaktır. Bu nedenle, model performansını belirlemek için PBIAS'ın diğer istatistiksel ve grafiksel PM'lerle birlikte kullanılması önerilir. (Denklem.2.6)

$$PBIAS = \frac{\sum_{i=1}^n (y_i - y_i)}{\sum_{i=1}^n y_i} \times 100 \quad (2.6)$$

Tez çalışmada elde ettiğimiz sonuçları Tablo2.3'ye göre değerlendireceğiz, model performansının değerlendirilmesinde kullanılan NSE, RSR, PBIAS gibi istatistiksel göstergeler için literatürde kabul görmüş sınıflandırmalar mevcuttur. Bu sınıflandırmalar, model çıktılarının gözlemlerle ne derece uyumlu olduğunu objektif olarak değerlendirme imkânı sağlar. Özellikle Moriasi et al. (2007) tarafından önerilen kriterler, hidrolojik modelleme çalışmalarında en yaygın başvuru kaynağı olarak kullanılmaktadır.

Tablo 2.3: Model Performans Kriterleri ve Sınıflandırma Tablosu

Performans Derecesi	NSE	RSR	PBIAS (%)
Çok İyi	$0.75 < NSE \leq 1.00$	$0.00 < RSR \leq 0.50$	$PBIAS < \pm 10$
İyi	$0.65 < NSE \leq 0.75$	$0.50 < RSR \leq 0.60$	$\pm 10 \leq PBIAS < \pm 15$
Tatmin Edici	$0.50 < NSE \leq 0.65$	$0.60 < RSR \leq 0.70$	$\pm 15 \leq PBIAS < \pm 25$
Tatmin Edici Değil	$NSE \leq 0.50$	$RSR > 0.70$	$PBIAS \geq \pm 25$

3. BULGULAR

Çalışmanın ilk aşamasında 2013–2018 yılları arasındaki saatlik meteorolojik veriler (sıcaklık farkı $dT(^{\circ}C)$) rüzgâr hızı $w(m/sn)$, yükseklik $h(m)$ ve inversiyon kalınlığı $t(m)$) girdi değişkenleri olarak kullanılmış, hava kirlenici parametrelerden PM_{10} ve SO_2 ise çıktı değişkenleri olarak seçilmiştir. Bu veriler, yapay zekâ tabanlı tahmin yöntemlerinden Yapay Sinir Ağları (YSA) ve Radyal Tabanlı Fonksiyon (RBF) ağ modelleri ile analiz edilmiştir. Ancak saatlik bazda gerçekleştirilen bu ilk modelleme çalışmaları, veri setinde bulunan eksiklikler, yüksek değişkenlik ve düzensizlik nedeniyle tatmin edici düzeyde anlamlı sonuçlar vermemiştir. İncelenen saatlik verilerde bazı günlerde yalnızca gece saat 00:00 ölçümlerinin mevcut olduğu, buna karşılık gündüz saatlerine ait ölçümlerin bulunmadığı; bazı günlerde ise herhangi bir ölçümün hiç yapılmadığı tespit edilmiştir. Bu durum, veri sürekliliğini bozarak kısa zaman aralıklarında ani ve düzensiz dalgalanmaların oluşmasına neden olmuş ve modellerin öğrenme sürecini olumsuz etkilemiştir. Özellikle bu eksiklikler, yapay zekâ modellerinin genelleme kabiliyetini sınırlandırmış ve tahmin performansını düşürmüştür. Bu nedenlerle, saatlik verilerden elde edilen sonuçların güvenilirliğini artırmak amacıyla aynı veri seti aylık verilere dönüştürülmüş ve modelleme çalışmaları bu yeni veri yapısı üzerinden yeniden gerçekleştirilmiştir. Aylık verilere geçilmesiyle birlikte, veri setindeki düzensizlikler azaltılmış ve modellerin daha istikrarlı ve anlamlı sonuçlar üretmesi sağlanmıştır.

Zaman ölçeğinin saatlikten aylağa çıkarılmasıyla birlikte, veriler'deki gürültü azalmış ve daha dengeli bir dağılım elde edilmiştir. Böylece makine öğrenme algoritmalarının ilişkileri daha sağlıklı bir şekilde yakalayabildiği görülmüştür. Bu yöntem değişikliği sonucunda, hem YSA hem de RBF modellerinden elde edilen tahminlerin önceki denemelere kıyasla daha mantıklı, istatistiksel açıdan daha anlamlı ve yorumlanabilir çıktılar sunduğu belirlenmiştir.

Bu bulgular, hava kirliliği modellemelerinde veri çözünürlüğünün (zaman ölçeği) önemli bir rol oynadığını ve özellikle yüksek dalgalanmaların bulunduğu durumlarda daha uzun dönemli ortalamaların kullanılmasının, model başarımını artırabileceğini göstermektedir. Model performansı Tablo2.3'ye göre, NS ve RSR değerleri esas alınarak derecelendirilmiştir. Modellerin “Çok İyi”, “İyi”, “Tatmin Edici” veya “Yetersiz”

kategorilerinde sınıflandırılması, tahmin başarımının istatistiksel olarak karşılaştırılmasına olanak tanımaktadır.

Çalışmada kullanılan veri seti, makine öğrenmesi modellerinin başarısını daha iyi şekilde test edebilmek amacıyla %80 eğitim dönemi ve %20 test dönemi olarak ikiye ayrılmıştır. Eğitim döneminde model parametreleri öğrenilirken, test döneminde elde edilen sonuçlar performans ölçütleriyle değerlendirilmiş ve tabloda verilen sınıflandırmaya göre yorumlanmıştır. Bu yöntem, modellerin yalnızca öğrenilen verilere değil, daha önce görmediği yeni verilere karşı da güvenilirlik düzeyini göstermektedir.

Aşağıda, eğitim ve test dönemlerine ait sonuçlar ile bu sonuçların dağılımını gösteren saçılım diyagramları sunulmuştur.


Bursa ili için şekil 3.1’de PM_{10} konsantrasyonlarının tahmininde kullanılan yapay sinir ağları (ANN) ve radyal tabanlı fonksiyon (RBF) modelleri karşılaştırıldığında her iki modelin de gözlenen(observed) değerlerin genel eğilimini başarıyla yansıttığı görülmektedir. ANN modeli, özellikle yüksek konsantrasyon dönemlerinde gözlenen dalgalanmaları takip edebilmiş, ancak aşırı uçlarda beklenen değerlerden sapmalar göstermiştir. Saçılım diyagramı incelendiğinde, verilerin doğrusal bir eğilim izlediği fakat belirli bir saçılımın da bulunduğu, dolayısıyla modelin orta düzeyde bir uyum sağladığı anlaşılmaktadır. Ayrıca şekil 3.2’de RBF modeli ise ANN modeline benzer şekilde gözlenen eğilimleri yansıtmış, fakat özellikle orta düzey PM_{10} değerlerinde daha dengeli ve tutarlı sonuçlar üretmiştir. Yüksek konsantrasyon dönemlerinde bazı sapmalar görülmekle birlikte, saçılım diyagramında noktaların regresyon doğrusuna ANN’e kıyasla daha yakın dağıldığı dikkat çekmektedir. Bu durum, RBF modelinin gözlenen ve tahmin edilen değerler arasındaki ilişkiyi daha güçlü şekilde yakaladığını göstermektedir.

Çanakkale şehir için şekil 3.3’te yapay sinir ağı (ANN) ile yapılan modelleme sonuçlarında, kalibrasyon döneminde gözlenen değerlerle modellenen(modelled) değerler genel olarak birbirine yakın seyretmektedir. Model özellikle orta seviyelerdeki PM_{10} değerlerini başarıyla tahmin edebilmiş, ancak yüksek ve ani değişim gösteren pik değerleri yakalamakta zorlanmıştır. Test döneminde ise modelin performansı belirgin şekilde düşmüş, gözlemlenen değerlerin dalgalanmaları ve tepe noktaları modellenen seride daha sönük ve düşük yansımıştır. Bu durum, ANN modelinin öğrenilen örüntüyü test verisine


genellemede yetersiz kaldığını göstermektedir. Ayrıca şekil 3.4'te RBF modeli ise hem kalibrasyon hem de test döneminde gözlemlerle daha uyumlu bir eğilim göstermektedir. Kalibrasyon aşamasında gözlenen ve modellenen değerler arasındaki uyum daha güçlü olup, dalgalanmalar ve pik değerler ANN modeline göre daha başarılı şekilde yakalanmıştır. Test döneminde de modelin performansı korunmuş, gözlenen değerlerin artış ve azalış eğilimleri modele daha iyi yansımıştır. Özellikle yüksek değerlerin modellenmesinde ANN'e kıyasla daha yakın sonuçlar elde edilmiştir.

Balıkesir ili için Şekil 3.5'te PM₁₀ tahmininde kullanılan iki yöntem olan Yapay Sinir Ağı (ANN) ve (RBF) modelleri karşılaştırıldığında, genel olarak RBF modelinin daha iyi ve tutarlı bir performans sergilediği görülmektedir. ANN modeli kalibrasyon döneminde orta düzeyde bir başarı göstermesine rağmen, test döneminde önemli sapmalar yapmış ve gözlenen PM₁₀ değerlerinin büyük bir kısmını yeterince temsil edememiştir. Bu durum, ANN modelinin eğitim verisine aşırı uyum sağladığını (aşırı öğrenme) ve bu nedenle yeni ve bağımsız veriler üzerinde zayıf bir genelleme yeteneğine sahip olduğunu göstermektedir. Buna karşılık, Şekil 3.6'da sunulan RBF modeli hem kalibrasyon hem de test dönemlerinde daha dengeli ve istikrarlı sonuçlar üretmiştir. RBF modelinin özellikle test döneminde gözlenen değerlere daha yakın tahminler yapması, modelin doğrusal olmayan ilişkileri daha etkin bir şekilde yakalayabildiğini ve PM₁₀ konsantrasyonlarındaki değişimleri daha iyi temsil ettiğini ortaya koymaktadır. Bu başarının temel nedenlerinden biri, RBF modelinin yerel öğrenme yaklaşımı sayesinde verideki karmaşık ve bölgesel desenleri daha hassas biçimde modelleyebilmesidir. Ayrıca RMSE, Pbias ve Nash–Sutcliffe Verimlilik Katsayısı (NS) gibi performans kriterleri incelendiğinde, RBF modelinin ANN'ye kıyasla daha düşük hata değerleri ve daha yüksek doğruluk seviyeleri sunduğu açıkça görülmektedir. Özellikle düşük RMSE ve Pbias değerleri, RBF modelinin hem hata payının az olduğunu hem de sistematik sapmalar üretmediğini göstermektedir. NS değerlerinin yüksek olması ise modelin gözlenen verileri başarılı bir şekilde temsil ettiğini ve tahmin gücünün yüksek olduğunu doğrulamaktadır.


Sonuç olarak, Balıkesir ili için PM₁₀ konsantrasyonlarının modellenmesinde RBF yöntemi, ANN modeline kıyasla daha güvenilir, daha kararlı ve genelleme yeteneği daha yüksek bir yaklaşım olarak öne çıkmaktadır. Bu nedenle, PM₁₀ tahmin çalışmalarında RBF modelinin tercih edilmesi daha uygun ve başarılı sonuçlar sağlayacaktır.




Şekil 3.1: Bursa ili için PM₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.




Sekil 3.2: Bursa ili için PM₁₀ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.




Şekil 3.3: Çanakkale ili için PM₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.4: Çanakkale ili için PM₁₀ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.5: Balıkesir ili için PM₁₀ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.6: Balıkesir ili için PM₁₀ konsantrasyonlarının RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.


SO₂ için grafiklere baktığımızda Şekil 3.7’de Bursa SO₂ – ANN model kalibrasyon döneminde gözlenen ve modellenen değerler arasında genel bir uyum olsa da özellikle pik değerlerde sapmalar olduğu görülmektedir. Model, eğilimi takip etse de yüksek değerleri doğru yansıtmakta zorlanmaktadır. Test döneminde ise bu uyum belirgin biçimde bozulmakta, model gözlenen değerlerden ciddi şekilde uzaklaşmaktadır. Bazı noktalarda model değerleri aşırı düşük ya da yüksek tahmin etmiştir. Bu durum, modelin kalibrasyon

verisine aşırı uyum sağladığını ancak yeni veriler üzerinde iyi performans gösteremediğini, yani genelleme yeteneğinin zayıf olduğunu göstermektedir. Saçılım grafiğinde de görüldüğü üzere, gözlenen ve tahmin edilen değerler arasında güçlü bir doğrusal ilişki bulunmamaktadır. Ayrıca Şekil 3.8’de Bursa SO₂ – RBF modeli kalibrasyon döneminde gözlenen ve modellenen değerler oldukça uyumlu olup, model pik değerleri dahi başarılı bir şekilde yakalayabilmiştir. Bu durum, RBF modelinin kalibrasyonda güçlü bir performans gösterdiğini ortaya koymaktadır. Test döneminde de ANN’ye kıyasla daha iyi sonuçlar vermektedir. Her ne kadar düşük değerlerde bazı farklılıklar bulunsa da genel eğilim gözlenen değerlere daha yakındır. Saçılım grafikleri incelendiğinde ANN modeline göre daha düzenli bir ilişki olduğu görülmektedir.


Şekil 3.9’de Çanakkale ili için SO₂ yapay sinir ağı (ANN) ile yapılan modellemede, kalibrasyon döneminde gözlenen ve tahmin edilen değerler arasında genel olarak benzerlik olduğu, modelin bu dönemde eğilimleri yakalayabildiği görülmektedir. Ancak test döneminde model performansı belirgin şekilde düşmüş, gözlenen değerlerle tahmin edilen değerler arasında ciddi farklılıklar oluşmuştur. Bu durum ANN’in eğitim verisine uyum sağlarken, test verisinde genelleme kabiliyetinin zayıf olduğunu göstermektedir. Ayrıca Şekil 3.10’de Radyal Tabanlı Fonksiyon (RBF) yöntemi ile yapılan modellemede, kalibrasyon döneminde gözlenen ve tahmin edilen değerler oldukça uyumlu çıkmış, model genel eğilimleri başarılı şekilde yansıtmıştır. Test döneminde performans düşmekle birlikte, ANN’e göre daha dengeli sonuçlar elde edilmiştir. Özellikle eğilimleri takip etmede ve gözlenen değerlerle paralellik göstermede RBF yönteminin daha kararlı olduğu anlaşılmaktadır.

Şekil 3.11’de Balıkesir ili için SO₂ Yapay Sinir Ağı (ANN) modeliyle yapılan çalışmada, kalibrasyon döneminde modelin gözlenen değerlerle genel olarak uyumlu sonuçlar ürettiği, özellikle eğilimleri yakalama konusunda başarılı olduğu görülmektedir. Ancak test dönemine geçildiğinde modelin performansı belirgin şekilde düşmüş, gözlenen değerlerdeki dalgalanmalara karşılık veremediği ve tahminlerin oldukça yetersiz kaldığı dikkat çekmektedir. Bu durum, ANN modelinin eğitim verisine fazla uyum sağladığını ancak yeni veriler üzerinde genelleme yeteneğinin zayıf olduğunu göstermektedir. Ayrıca Şekil 3.12’de Radyal Tabanlı Fonksiyon (RBF) yöntemiyle yapılan modellemede, kalibrasyon döneminde modelin gözlenen değerlerle büyük ölçüde uyumlu tahminler yaptığı ve genel eğilimleri başarılı şekilde takip edebildiği görülmektedir. Test döneminde


performansta bir miktar düşüş yaşanmakla birlikte, RBF modelinin ANN'ye kıyasla daha dengeli sonuçlar verdiği, gözlenen değerlerle daha iyi örtüştüğü anlaşılmaktadır. Bu durum, RBF yönteminin genelleme yeteneğinin daha güçlü ve yeni veriler karşısında daha kararlı olduğunu ortaya koymaktadır.




Şekil 3.7: Bursa ili için SO₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.




Şekil 3.8: Bursa ili için SO₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.




Şekil 3.9: Çanakkale ili için SO₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.10: Çanakkale ili için SO₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.11: Balıkesir ili için SO₂ konsantrasyonunun ANN modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.



Şekil 3.12: Balıkesir ili için SO₂ konsantrasyonunun RBF modeliyle tahmini: (a) eğitim dönemi gözlenen ve tahmin edilen değerler, (b) test dönemi gözlenen ve tahmin edilen değerler.

En son elde ettiğimiz model performans değerlerini tablo haline getirerek analizlerini aşağıda yapmıştır. Yapay Sinir Ağları (ANN) modeli Bursa istasyonu için eğitim aşamasında tatmin edici düzeyde performans göstermiştir (NS=0.59, RSR=0.64). RMSE değerinin yüksek çıkması modelin gözlemlerden sapmalarının fazla olduğunu ortaya koymaktadır. Ancak PBIAS değerinin (-0.15) olması, modelin sistematik bir yanlılık taşımadığını göstermektedir. Test aşamasında ise ANN modelinin performansı bir miktar iyileşmiş, NS değeri 0.64'e yükselmiş, RSR 0.58'e düşerek "iyi" sınıfa yaklaşmıştır. PBIAS (-9.50) değeri de ± 10 sınırları içinde kaldığı için modelin sistematik sapmasının kabul edilebilir düzeyde olduğu görülmektedir. Bu sonuçlar, ANN modelinin Bursa için güvenilir ancak hata düzeyi yüksek tahminler sunduğunu göstermektedir. RBF modeli ise Bursa istasyonu için eğitim aşamasında ANN ile benzer bir performans sergilemiştir (NS=0.55, RSR=0.67). Bununla birlikte RMSE değerinin daha yüksek olması, ANN'e kıyasla eğitim sürecinde daha fazla hata yaptığını göstermektedir. Ancak test aşamasında RBF modelinin performansı belirgin şekilde iyileşmiştir. NS değeri 0.69'a çıkmış, RSR 0.53'e düşerek iyi performans düzeyine ulaşmıştır. Ayrıca RMSE değeri ANN modeline göre daha düşük bulunmuştur (628.55). PBIAS (-9.00) değeri de ± 10 sınırları içinde yer alarak modelin sistematik tahmin sapmasının oldukça düşük olduğunu ortaya koymaktadır.

Tablo 3.1: Bursa, Çanakkale ve Balıkesir için ANN ve RBF Modellerinin PM₁₀ Konsantrasyonu Tahmin Performansları.

		Train				Test				
		NS	RMSE	RSR	Pbias	NS	RMSE	RSR	Pbias	
PM ₁₀	ANN	Bur	0.59	755.19	0.64	-0.15	0.64	682.53	0.58	-9.508
		Çan	0.75	105.08	0.50	0.01	0.50	258.95	0.68	24.048
		Bal	0.47	324.02	0.72	-0.61	0.29	406.16	0.81	-18.060
	RBF	Bur	0.55	791.15	0.67	2.17E-12	0.69	628.55	0.53	-9.005
		Çan	0.81	91.72	0.44	-4.92E-06	0.74	185.01	0.49	16.665
		Bal	0.37	352.81	0.79	-6.94E-12	0.52	334.89	0.66	-8.969

ANN modeli, Çanakkale istasyonu için eğitim aşamasında oldukça güçlü bir performans göstermiştir. NS değeri 0.75 olup bu sonuç modelin gözlemlerle yüksek uyum sağladığını ortaya koymaktadır. RSR değeri 0.50 ile "iyi" performans sınırında, RMSE değeri 105.08 ise diğer istasyonlara kıyasla oldukça düşük bulunmuştur. Ayrıca PBIAS değeri 0.01 olup sifıra yakın bir değer elde edilmiştir; bu da modelin sistematik bir yanlılık taşımadığını ve tahminlerinin gözlem değerleriyle neredeyse aynı olduğunu göstermektedir. Ancak test aşamasında modelin performansı düşmüştür. NS değeri 0.50'ye gerileyerek tatmin edici

sınırdaki kalmış, RSR değeri 0.68'e yükselmiş ve hata oranı artmıştır. Ayrıca PBIAS değeri 24.04 olarak bulunmuş ve bu durum modelin gözlemleri belirgin şekilde düşük tahmin ettiğini göstermektedir. Bu sonuçlara göre, ANN modeli eğitim verilerinde oldukça başarılı iken test verilerinde doğruluğunu kaybetmiş, genelleme kabiliyetinin sınırlı olduğu ortaya çıkmıştır. RBF modeli ise Çanakkale için daha istikrarlı bir performans sergilemiştir. Eğitim aşamasında NS değeri 0.81 ile "çok iyi" düzeyde bulunmuş, RSR değeri 0.44 ile oldukça düşük hata oranı göstermiştir. RMSE değeri 91.72 olup ANN modeline göre daha düşük bir hata değeri elde edilmiştir. PBIAS değeri sıfıra çok yakın (-4.92E-06) olduğundan modelin sistematik önyargısı bulunmamaktadır. Test aşamasında da performans kabul edilebilir düzeydedir. NS değeri 0.74 ile ANN'e kıyasla belirgin şekilde daha yüksek bulunmuş, RSR değeri 0.49 ile "iyi" sınıfta yer almıştır. Ancak PBIAS değeri 16.66 olması, modelin gözlemleri hafifçe düşük tahmin etme eğiliminde olduğunu göstermektedir.

ANN modeli Balıkesir için eğitim aşamasında güçlü bir performans göstermiştir. NS değeri 0.78 olup modelin gözlemlerle yüksek uyum sağladığını göstermektedir. RSR değeri 0.47 ile düşük hata oranı yakalanmış, RMSE değeri 103.31 olarak hesaplanmıştır. Ayrıca PBIAS değeri 0.02 olup sıfıra çok yakın bir değer elde edilmiştir; bu da modelin sistematik önyargı taşımadığını ve gözlem değerlerine oldukça yakın tahminler ürettiğini göstermektedir. Ancak test aşamasında ANN'in performansı belirgin şekilde düşmüştür. NS değeri 0.46'ya gerileyerek kabul edilebilir sınırdaki kalmış, RSR değeri 0.73'e yükselmiş ve hata oranı artmıştır. Bununla birlikte PBIAS değeri -31.18 olarak bulunmuş, bu da modelin gözlem değerlerini belirgin şekilde yüksek tahmin etme eğiliminde olduğunu göstermektedir. Dolayısıyla ANN modeli eğitimde çok başarılı olsa da test aşamasında genelleme kabiliyeti zayıf kalmıştır. Ayrıca RBF modeli ise daha kararlı sonuçlar sunmuştur. Eğitim aşamasında NS değeri 0.80 ile "çok iyi" düzeyde bulunmuş, RSR değeri 0.45 ile düşük hata oranı göstermiştir. RMSE değeri 98.85 olup ANN'e göre daha düşük bir hata değeri elde edilmiştir. Ayrıca PBIAS değeri 0.03 olması, modelin tahminlerinde sistematik bir yanlılık taşımadığını ortaya koymaktadır. Test aşamasında ise RBF modeli ANN'e göre çok daha başarılı sonuç vermiştir. NS değeri 0.71 ile güçlü bir performans göstermiş, RSR değeri 0.53 ile "iyi" seviyede kalmıştır. Ancak PBIAS değeri -32.07 olması, modelin gözlem değerlerini genel olarak daha yüksek tahmin etme eğiliminde olduğunu ortaya koymaktadır.

Genel sonuçlar incelendiğinde, PM₁₀ tahmininde yapay sinir ağı (ANN) ve radyal tabanlı fonksiyon (RBF) modellerinin performansları istasyonlara göre farklılık göstermektedir. Çanakkale istasyonu en başarılı sonuçların elde edildiği nokta olurken, Bursa orta seviyede, Balıkesir ise en düşük doğrulukla modellenmiştir. ANN modeli eğitim verilerinde güçlü sonuçlar verse de test aşamasında başarısı düşmüş, bu da fazla öğrenmeye eğilimli olduğunu göstermiştir. RBF modeli ise test verilerinde daha kararlı ve güvenilir sonuçlar sunmuş, özellikle Balıkesir’de ANN’e göre daha başarılı olmuştur. Genel olarak, RBF modeli PM₁₀ tahminlerinde ANN’e kıyasla daha güvenilir bir yöntem olarak öne çıkmaktadır.

Tablo 3.2’de SO₂ sonuçlarına bakıldığında Bursa için ANN modeli eğitim (train) verisinde orta düzeyde bir uyum göstermiştir. NS değeri 0.48 ile kabul edilebilir seviyede, fakat RMSE (73.80) ve RSR (0.72) yüksek hata değerleri içermektedir. Pbias ise 0.02 ile neredeyse hatasız, yani sistematik bir sapma bulunmamaktadır. Ancak test verisinde modelin başarısı düşmektedir. NS değeri -2.03 olup negatif çıktığı için modelin test performansı başarısızdır. RMSE 81.51 ve RSR 1.67 değerleri de yüksek hata oranına işaret etmektedir. Ayrıca Pbias -30.68 ile modelin SO₂ değerlerini ciddi şekilde düşük tahmin ettiğini göstermektedir. RBF modeli ise eğitim aşamasında çok güçlü bir performans sergilemiştir. NS değeri 0.97 olup mükemmel uyuma işaret etmektedir. RMSE (17.70) ve RSR (0.17) çok düşük hata değerleridir. Pbias değeri sıfıra yakın çıkmış ve herhangi bir sapma göstermemiştir. Test verisinde ise modelin performansı düşmüştür. NS 0.15 ile düşük bir uyum göstermekte, RMSE 43.25 ve RSR 0.89 ile orta düzeyde hata bulunmaktadır. Pbias 8.58 değeri, modelin test aşamasında SO₂ değerlerini bir miktar yüksek tahmin ettiğini göstermektedir.

Tablo 3.2: Bursa, Çanakkale ve Balıkesir için ANN ve RBF Modellerinin SO₂ Konsantrasyonu Tahmin Performansları.

		Train				Test				
		NS	RMSE	RSR	Pbias	NS	RMSE	RSR	Pbias	
SO ₂	ANN	Bur	0.48	73.80	0.72	0.02	-2.03	81.51	1.67	-30.681
		Çan	<u>0.72</u>	64.38	0.52	1.05	-6.19	134.23	2.57	-133.001
		Bal	0.57	95.77	0.65	0.43	<u>0.02</u>	143.85	0.95	22.320
	RBF	Bur	<u>0.97</u>	17.70	0.17	-2.63E-13	0.15	43.25	0.89	8.584
		Çan	0.87	44.49	0.36	-2.17E-14	-0.52	61.71	1.18	3.672
		Bal	0.44	109.63	0.74	-1.08E-14	<u>0.33</u>	119.15	0.78	11.683

Çanakkale için ANN modeli eğitim (train) verisinde orta seviyede bir performans göstermiştir. NS değeri 0.72 olup kabul edilebilir düzeydedir. RMSE 64.38 ve RSR 0.52 değerleri orta seviyede hata olduğunu göstermektedir. Pbias 1.05 ile modelin az da olsa yüksek tahmin eğilimi vardır. Ancak test verisine bakıldığında modelin başarısı ciddi şekilde düşmektedir. NS değeri -6.19 olup negatif çıkmıştır, bu da modelin test aşamasında başarısız olduğunu gösterir. RMSE 134.23 ve RSR 2.57 çok yüksek hata seviyelerine işaret etmektedir. Pbias ise -133 gibi oldukça büyük bir değere sahiptir ve modelin testte SO₂ değerlerini çok ciddi biçimde düşük tahmin ettiğini göstermektedir. RBF modeli ise eğitim verisinde başarılı sonuçlar üretmiştir. NS 0.87 olup yüksek uyum göstermektedir. RMSE 44.49 ve RSR 0.36 hata değerlerinin düşük olduğunu ortaya koymaktadır. Pbias değeri sıfıra yakın (-2.17E-14) çıkmış ve modelin eğitimde sistematik bir sapma yapmadığını göstermektedir. Test verisinde ise modelin performansı düşmüştür. NS -0.52 ile negatif çıkmış, bu da başarısızlık göstergesidir. RMSE 61.71 ve RSR 1.18 değerleri yüksek hata olduğunu göstermektedir. Pbias ise 3.67 ile modelin test aşamasında SO₂ değerlerini az miktarda yüksek tahmin ettiğini ortaya koymaktadır.

Balıkesir için ANN modeli eğitim (train) verisinde orta seviyede bir performans sergilemiştir. NS değeri 0.57 olup kabul edilebilir bir uyum sağlamaktadır. RMSE 95.77 ve RSR 0.65 hata oranlarının yüksek olduğunu göstermektedir. Pbias 0.43 değeri ise modelin eğitim sırasında çok az bir yüksek tahmin eğilimi taşıdığını gösterir. Test verisine bakıldığında, NS 0.02 ile sıfıra yakın çıkmıştır, yani modelin test performansı çok zayıftır. RMSE 143.85 ve RSR 0.95 hata seviyelerinin yüksek olduğunu göstermektedir. Pbias 22.32 değeri ise modelin test aşamasında SO₂ değerlerini belirgin şekilde yüksek tahmin ettiğini göstermektedir. RBF modeli ise eğitim verisinde zayıf bir performans sergilemiştir. NS değeri 0.44 olup düşük uyuma işaret etmektedir. RMSE 109.63 ve RSR 0.74 hata seviyelerinin yüksek olduğunu göstermektedir. Pbias neredeyse sıfırdır, yani sistematik sapma yoktur. Test verisinde ise sonuçlar biraz daha iyileşmiştir. NS 0.33 olup düşük de olsa pozitif uyum vardır. RMSE 119.15 ve RSR 0.78 değerleri hata payının yüksek olduğunu gösterir. Pbias 11.68 ile modelin SO₂ değerlerini yüksek tahmin ettiği anlaşılmaktadır.

Genel olarak bakılırsa, ANN modeli üç şehirde de eğitimde kabul edilebilir düzeyde sonuçlar vermesine rağmen test aşamasında başarısız olmuş, özellikle Çanakkale ve Balıkesir’de yüksek hata ve ciddi sapmalar üretmiştir. RBF modeli ise eğitimde çok

başarılı, testte ise orta düzeyde performans göstermiştir. ANN'e göre daha güvenilir ve dengeli sonuçlar verse de her iki modelin de test verilerinde yüksek doğruluk sağlamadığı görülmektedir.

Son yıllarda hava kirliliği parametrelerinin tahmin edilmesinde yapay zekâ temelli yöntemler yaygın biçimde kullanılmaktadır. Literatürde özellikle yapay sinir ağları (Artificial Neural Networks, ANN) ve radyal tabanlı fonksiyon (Radial Basis Function, RBF) ağlarının, doğrusal regresyon gibi klasik yöntemlere kıyasla daha başarılı sonuçlar verdiği sıklıkla rapor edilmektedir. Bu yöntemler, doğrusal olmayan ilişkileri modelleme yeteneği sayesinde hava kalitesi tahmininde önemli avantajlar sağlamaktadır.

PM₁₀ sonuçlarında ANN ve RBF yöntemleri daha yakın performanslar sergilemektedir. Çanakkale için her iki yöntemin de hem eğitim hem test aşamasında görece daha yüksek NS değerleri elde ettiği görülmektedir (örneğin RBF testte 0.74, ANN testte 0.50). Balıkesir'de ise modellerin genel performansı daha düşük bulunmuştur. Bu durum, veri setlerinin özellikleri, yerel emisyon kaynakları ve meteorolojik faktörlerle açıklanabilir.

SO₂ sonuçlarında ise değerlendirildiğinde, eğitim (train) aşamasında RBF yöntemi genellikle daha yüksek Nash-Sutcliffe (NS) değerleri ve daha düşük hata oranları ile öne çıkmaktadır. Örneğin Bursa için RBF modeli eğitimde 0.97 NS değeriyle oldukça yüksek bir performans göstermiştir. Test aşamasında ise ANN modelinde bazı durumlarda negatif NS değerleri gözlenmiş, bu da test verisinde yetersiz performans anlamına gelmektedir. Buna karşılık RBF yöntemi test setinde daha istikrarlı sonuçlar üretmiştir.

Genel olarak sonuçlar, RBF yönteminin özellikle SO₂ tahminlerinde daha kararlı ve başarılı olduğunu, ANN yönteminin ise bazı durumlarda aşırı uyumlu eğilimi gösterdiğini ortaya koymaktadır. Literatürdeki benzer çalışmalar da RBF'nin daha esnek yapısı nedeniyle zamansal değişkenliği yüksek olan kirleticiler için daha uygun olabileceğini desteklemektedir. Ancak PM₁₀ için iki yöntemin performansları birbirine daha yakın olup, bölgesel farklılıkların öne çıktığı görülmektedir. Sonuç olarak, yapay zekâ yöntemleri hava kalitesi tahmininde etkili araçlardır; fakat model seçimi, veri kalitesi ve bölgesel koşullar dikkate alındığında sonuçlar değişkenlik göstermektedir. Bu nedenle ilerleyen çalışmalarda hibrit yöntemlerin ve daha geniş veri setlerinin kullanılmasıyla performansın artırılacağı öngörülmektedir.

4. SONUÇLAR VE TARTIŞMA

Bu çalışmada, yapay zekâ tabanlı modelleme tekniklerinden Yapay Sinir Ağları (ANN) ve Radyal Tabanlı Fonksiyon (RBF) yöntemleri kullanılarak, Bursa, Çanakkale ve Balıkesir illerinde hava kalitesi göstergeleri olan SO₂ ve PM₁₀ kirleticilerinin kısa vadeli tahmini gerçekleştirilmiştir. Çalışmanın temel amacı, farklı bölgelerdeki verilerin yapısal özelliklerini dikkate alarak bu iki yöntemin performanslarını kıyaslamak ve yapay zekâ tabanlı modellerin hava kirliliği öngörülerindeki potansiyelini ortaya koymaktır.

Elde edilen bulgular göstermektedir ki, her iki kirletici için model performansları hem yonteme hem de bölgesel verilere bağılı olarak deęişkenlik göstermektedir. Bu durum, yapay zekâ modellerinin performansını deęerlendirirken yalnızca algoritmanın yapısına odaklanmanın yeterli olmadığını, aynı zamanda veri kalitesi, ölçüm güvenilirliği ve bölgesel emisyon dinamiklerinin de dikkate alınması gerektiğini ortaya koymaktadır.

PM₁₀ için elde edilen sonuçlar, genel olarak daha dengeli bulunmuştur. Özellikle Çanakkale ili verilerinde hem ANN hem de RBF yöntemleri yüksek Nash–Sutcliffe (NS) katsayıları ile tatmin edici sonuçlar üretmiştir (örneğin RBF test aşamasında NS=0.74). Bu sonuç, Çanakkale’de ölçüm verilerinin düzenli, meteorolojik deęişkenlerin daha öngörülebilir ve emisyon kaynaklarının daha sınırlı olabileceğini düşündürmektedir. Buna karşın, Balıkesir ili için elde edilen sonuçlar beklenenden düşük kalmıştır. Her iki yöntemde de model doğruluklarının görece zayıf olması; bölgede farklı kaynaklardan gelen emisyonların çeşitlilięi, ölçüm istasyonlarının konumu ve hassasiyeti ya da meteorolojik deęişkenlerin ani dalgalanmaları ile ilişkili olabilir. Bu durum, model performansının yalnızca kullanılan yöntemden deęil, aynı zamanda veri setinin homojenliğinden ve bölgesel özelliklerden güçlü şekilde etkilendiğini açıkça ortaya koymaktadır.

SO₂ kirleticisinin tahmininde ise yöntemler arasında daha belirgin farklılıklar gözlenmiştir. RBF yöntemi, özellikle eğitim aşamasında oldukça yüksek uyum sağlamış ve Bursa verilerinde NS deęerinin 0.97’ye kadar ulaşması, bu modelin doğrusal olmayan ve ani deęişim gösteren veri setlerine uyum kabiliyetini açıkça ortaya koymuştur. Test aşamasında da RBF modelinin görece istikrarlı sonuçlar ürettięi, özellikle Bursa ve Çanakkale illerinde hata oranlarının düşük seviyede kaldığı görülmüştür. Bu bulgu,

literatürde de sıkça ifade edildiği gibi, RBF modellerinin kısa süreli ve dalgalı SO₂ konsantrasyonlarını öngörmede avantajlı olduğunu desteklemektedir.

Buna karşılık, ANN modelleri özellikle test aşamasında tatmin edici sonuçlar verememiştir. Negatif NS değerleri, modelin eğitim verisine fazla uyum sağladığını (overfitting) ve test verisine genelleme yapmada yetersiz kaldığını göstermektedir. Bu durum, ANN'nin yapısal karmaşıklığının kontrol edilmediği senaryolarda model performansını olumsuz yönde etkileyebileceğini ve daha dikkatli parametre optimizasyonu yapılması gerektiğini ortaya koymaktadır.

Genel olarak, çalışma bulguları şu sonuçlara işaret etmektedir:

- ✓ RBF yöntemi, SO₂ tahmininde daha başarılı ve güvenilir sonuçlar vermiştir. Özellikle ani değişkenliklerin yüksek olduğu bölgelerde RBF'nin avantajı daha net ortaya çıkmaktadır.
- ✓ PM₁₀ tahminlerinde ANN ve RBF birbirine yakın performanslar sergilemiştir. Bu durum, partikül madde konsantrasyonlarının bölgesel olarak daha dengeli dağılım göstermesiyle ilişkilendirilebilir.
- ✓ ANN modellerinde zaman zaman aşırı uyum eğilimi gözlenmiş, bu da test performanslarını olumsuz etkilemiştir.
- ✓ Model performansları yalnızca kullanılan yöntemden değil, aynı zamanda bölgesel özelliklerden, veri setinin kapsamından ve meteorolojik faktörlerden etkilenmiştir.

Gelecek Çalışmalar İçin Öneriler: Bu çalışmanın ortaya koyduğu bulgular, yapay zekâ tabanlı yöntemlerin hava kalitesi tahmininde güçlü bir potansiyel sunduğunu göstermektedir. Bununla birlikte, performansın bölgeden bölgeye değişkenlik göstermesi, daha kapsamlı ve hibrit yaklaşımların gerekliliğine işaret etmektedir. Bu bağlamda, gelecek çalışmalarda:

- ✎ Hibrit modelleme yaklaşımlarının uygulanması,
- ✎ Daha uzun süreli ve geniş kapsamlı veri setlerinin kullanılması,
- ✎ Meteorolojik parametrelerin (sıcaklık, rüzgâr hızı, nem, basınç vb.) modele entegrasyonu,
- ✎ Bölgesel emisyon envanterlerinin ve kentsel faaliyetlerin dikkate alınması,
- ✎ Farklı ölçeklerde (kentsel, bölgesel, ulusal) tahminlerin yapılması, model performanslarını daha da iyileştirebilecektir.

Sonuç olarak, bu çalışma yapay zekâ tabanlı modellerin hava kalitesi tahmininde etkili ve umut verici araçlar olduğunu, ancak her kirletici ve her bölge için tek bir modelin her zaman en iyi sonucu vermediğini ortaya koymuştur. En uygun yöntemin seçimi, veri setinin yapısına, kirleticinin doğasına ve bölgesel koşullara bağlı olarak yapılmalıdır. Daha kapsamlı veri setleri ve hibrit yöntemlerle desteklenen gelecek çalışmalar sayesinde, hava kalitesi tahminlerinde doğruluk ve güvenilirliğin daha da artırılacağı öngörülmektedir.

Model performansları incelendiğinde, bazı şehirler için elde edilen Nash–Sutcliffe Verimlilik (NS) katsayılarının görece düşük olduğu görülmüştür. Bu durumun, ilgili şehirlerin coğrafi konumu, topoğrafik yapısı, hâkim rüzgâr yönü ve rüzgâr hızı gibi meteorolojik faktörlerden kaynaklandığı düşünülmektedir. Özellikle denizel etkiye açık alanlar, ani meteorolojik değişimler ve kirleticilerin atmosferde taşınımını etkileyen rüzgâr rejimleri, hava kirliliği değerlerinde düzensiz dalgalanmalara neden olmuş ve modellerin tahmin başarısını sınırlamıştır. Buna rağmen, genel sonuçlar ANN ve RBF modellerinin hava kirliliği tahmininde uygulanabilir ve anlamlı sonuçlar üretebildiğini göstermektedir. RBF modelinin bazı şehirlerde alternatif ve tamamlayıcı bir yöntem olarak öne çıkması, ilerleyen çalışmalarda farklı meteorolojik parametrelerin ve daha uzun veri setlerinin modele dâhil edilmesiyle tahmin performansının artırılacağına işaret etmektedir. Bu yönüyle çalışma, gelecekte yapılacak yapay zekâ tabanlı hava kalitesi modelleme araştırmaları için önemli bir metodolojik altyapı sunmaktadır

5. KAYNAKLAR

- Aayush, K., Vishal, D., Hammad, N., and Manu, K. S.** (2020). Application of artificial intelligence in curbing air pollution: The case of India. *Asian Journal of Management*, 11(3), 285-290.
- Akbulut, İ., ve Özcan, B.** (2020). Hava kirliliği tahmini: yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 3(1), 12-22.
- Alberini, A. and Krupnick, A.** (1998). Air Quality and Episodes of Acute Respiratory Illness in Taiwan Cities: Evidence from Survey Data. *Journal of Urban Economics*, 44 (1), 68-92.
- Alimissis, A., Philippopoulos, K., Tzani, C. G., and Deligiorgi, D.** (2018). Spatial estimation of urban air pollution with the use of artificial neural network models. *Atmospheric environment*, 191, 205-213
- Anderson, D., and McNeill, G.** (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258(6), 1-83.
- Arabacı, M., Bayram, M., Yüceer, M., ve Karadurmuş, E.** (2010). Tuğla ve kiremit fabrikalarının hava kirliliğine katkılarının yapay sinir ağı modellemesi ile araştırılması. 9. *Ulusal Kimya Mühendisliği Kongresi*, 727-728.
- Asha, P., Natrayan, L. B. T. J. R. R. G. S., Geetha, B. T., Beulah, J. R., Sumathy, R., Varalakshmi, G., and Neelakandan, S.** (2022). IoT enabled environmental toxicology for air pollution monitoring using AI techniques. *Environmental research*, 205, 112574.
- Avşar, E.** (2015). Balıkesir ili burhaniye ilçesi (iskele mahallesi) hava kalitesinin değerlendirilmesi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 4(1), 68-82.
- Aygören, H., Sarıtaş, H., ve Morah, T.** (2012). İMKB 100 endeksinin yapay sinir ağları ve newton nümerik arama modelleri ile tahmini. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 73-88.
- Barbulescu, A., and Barbes, L.** (2017). Mathematical modeling of sulfur dioxide concentration in the western part of Romania. *Journal of environmental management*, 204, 825-830.
- Benli, Y. K., ve Yıldız, A.** (2015). Altın fiyatının zaman serisi yöntemleri ve yapay sinir ağları ile öngörüsü. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (42).

KAYNAKLAR DİZİNİ (devam)

- Bıyık, İ.** (2010). Hava kirliliğinin yapay zeka teknikleri ile belirlenmesi (Doctoral dissertation, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü).
- Broomhead, D., and Lowe, D.** (1988). Multivariable functional interpolation and adaptive networks, complex systems, vol. 2. *Complex Systems*, 2.
- Cengiz, M. A., Şenel, T., Terzi, E., Savaş, N., ve Terzi, Y.** (2013). Samsun bölgesindeki hava kirliliğinin neden olduğu hastalıkların istatistiksel modellenmesi. *Karadeniz Fen Bilimleri Dergisi*, 3(8), 27-36.
- Cho, J., and Olivera, F.** (2009). Effect of the streamflow observation network on the calibration of watershed models. *Journal of Hydrologic Engineering*, 14(4), 380–389. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2009\)14:4\(380\)](https://doi.org/10.1061/(ASCE)1084-0699(2009)14:4(380)).
- Çıldır, İ., ve Mutlu, A.** (2022). Balıkesir şehir merkezinde hava kirliliği seviyelerinin zamansal ve mekansal analizleri. *Journal of Advanced Research in Natural and Applied Sciences*, 8(2), 246-266.
- Dokuz, Y., Bozdağ, A., ve Gökçek, B.** (2020). Hava Kalitesi Parametrelerinin Tahmini ve Mekansal Dağılımı İçin Makine Öğrenmesi Yöntemlerinin Kullanılması. *Niğde ömer halisdemir üniversitesi mühendislik bilimleri dergisi*, 9(1), 37-47.
- Elmas Ç.** (2003). Yapay Sinir Ağları. Seçkin Yayıncılık, Ankara.
- Erbaşlar, T., ve Taşdemir, Y.** (2007). Bursa atmosferinde ölçülen klasik hava kirleticilerin birbirleri ile olan ilişkileri. *Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 12(2), 9-19.
- Fan, Q., Li, Y., and Ren, N.** (2009, June). Application of grey prediction model to forecast the main air contaminant PM10 in Harbin City. In *2009 3rd International Conference on Bioinformatics and Biomedical Engineering* (pp. 1-4). IEEE.
- Godish, T.** “Air Quality 4 Edition”, Lewis Publishers, A CRC Press Company, p 32-185,2004.
- Grivas, G., and Chaloulakou, A.** (2006). Artificial neural network models for prediction of PM10 hourly concentrations, in the Greater Area of Athens, Greece. *Atmospheric environment*, 40(7), 1216-1229.
- Gültepe, Y.** (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.

KAYNAKLAR DİZİNİ (devam)

- Haiming, Z., and Xiaoxiao, S.** (2013, June). Study on prediction of atmospheric PM_{2.5} based on RBF neural network. In *2013 Fourth International Conference on Digital Manufacturing & Automation* (pp. 1287-1289). IEEE.
- Ham, F. M., and Kostanic, I.** (2000). *Principles of neurocomputing for science and engineering*. McGraw-Hill Higher Education.
- Harmel, R. D., and Smith, P. K.** (2007). Consideration of measurement uncertainty in the evaluation of goodness-of-fit in hydrologic and water quality modeling. *Journal of Hydrology*, 337(3-4), 326-336.
- Harmel, R. D., Smith, P. K., and Migliaccio, K. W.** (2010). Modifying goodness-of-fit indicators to incorporate both measurement and model uncertainty in model calibration and validation. *Transactions of the ASABE*, 53(1), 55-63.
- Johnson, S., and Perumalsamy, D.** (2024). Ensemble-SMOTE Model to Evaluate Air Quality in the Industrial Area in Chavara. *Metallurgical and Materials Engineering*, 30(4), 143-162.
- Kampa, M., and Castanas, E.** (2008). Human health effects of air pollution. *Environmental pollution*, 151(2), 362-367.
- Karaca, F., Alagha, O., and Ertürk, F.** (2005). Application of inductive learning: Air pollution forecast in Istanbul City. *Intelligent Automation and Soft Computing*, 11(4), 207–216.
- Karaca, F., Nikov, A., and Alagha, A.** (2006). NN-AirPol: A neural-networks-based method for air pollution evaluation and control. *International Journal of Environment and Pollution*, 28(3/4), 310–325.
- Kinney, P. L.** (2008). Climate change, air quality, and human health. *American journal of preventive medicine*, 35(5), 459-467.)
- Krause, P., Boyle, D. P., and Båse, F.** (2005). Comparison of different efficiency criteria for hydrological model assessment. *Advances in geosciences*, 5, 89-97.
- Kunt, F.** (2014). Bulanık mantık ve yapay sinir ağları yöntemleri kullanılarak Konya il merkezi hava kirliliği modellenmesi. *Selçuk Üniversitesi Fen Bilimleri Enstitüsü Basılmamış Doktora Tezi, Konya*.
- Kunt, F. ve Dursun, Ş.** (2018). *Konya Merkezinde Hava Kirliliğine Bazı Meteorolojik Faktörlerin Etkisi. Ulusal Çevre Bilimleri Araştırma Dergisi*, 1(1).

KAYNAKLAR DİZİNİ (devam)

- Künzli, N., Kaiser, R., Medina, S., Studnicka, M., Chanel, O., Filliger, P., et al.** (2000). Public-health impact of outdoor and traffic-related air pollution: A European assessment. *The Lancet*, 356(2932), 795–801.
- Kurt, A., and Oktay, A. B.** (2010). Forecasting air pollutant indicator levels with geographic models 3 days in advance using neural networks. *Expert Systems with Applications*, 37(12), 7986-7992.
- Maleki, H., Sorooshian, A., Goudarzi, G., Baboli, Z., Tahmasebi Birgani, Y., and Rahmati, M.** (2019). Air pollution prediction by using an artificial neural network model. *Clean technologies and environmental policy*, 21(6), 1341-1352.
- Mannucci, P. M., and Franchini, M.** (2017). Health effects of ambient air pollution in developing countries. *International journal of environmental research and public health*, 14(9), 1048.
- McCulloch, W. S., and Pitts, W.** (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Merkezi, R. S. H.** (2015). *Hava Kirliliğine Genel Bakış*.
- Monteiro Martins, L., Coz, E., Maucort-Boulch, D., and Hacid, M. S.** (2025). Machine learning with environmental predictors to forecast hospital visits and admissions: a systematic review. *Environmental Systems Research*, 14(1), 12.
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., and Veith, T. L.** (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Mutlu, A.** (2019). Hava kalitesi ve meteoroloji: korelasyon, trend ve epizot analizleri. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 9(4), 724-741.
- Nations, U.** (2010). Natural hazards, unnatural disasters: the economics of effective prevention. *The World Bank Group*.
- Nabiyev, V. V.** (2005). *Yapay zeka: problemler-yöntemler-algoritmalar*. Seçkin Yayıncılık.
- Okkan, U., ve yıldırım Dalkılıç, H.** (2012). Radyal tabanlı yapay sinir ağları ile Kemer Barajı aylık akımlarının modellenmesi. *Teknik Dergi*, 23(112), 5957-5966.

Öklü, M., ve Canbay, P. (2023). Makine öğrenmesi yöntemleri ile şehirlerin hava kalitesi tahmini. *International Journal of Advances in Engineering and Pure Sciences*, 35(1), 39-53.

KAYNAKLAR DİZİNİ (devam)

Peavy, H. S., Rowe, D. R., and Tchobanoglous, G. (1985). Wastewater treatment and disposal. *Environmental Engineering. McGraw Hill Education Pvt. Ltd.*

Qingxin, F., Ying, L., and Nanqi, R. (2009). Application of grey prediction model to forecast the main air contaminant PM₁₀ in Harbin City, IEEE.

Raimondo, G., Montuori, A., Moniaci, W., Pasero, E., and Almkvist, E. (2007). September). An application of machine learning methods to PM₁₀ level medium-term prediction. In *International Conference on Knowledge-Based and Intelligent Information and Engineering Systems* (pp. 259-266). Berlin, Heidelberg: Springer Berlin Heidelberg.

Saplıoğlu, K. (2010). Parametrik havza modellemesi ile akım tahmini: Köprüçay Nehri havzası.

Sun, G., Hoff, S. J., Zelle, B. C., and Nelson, M. A. (2008). Forecasting daily source air quality using multivariate statistical analysis and radial basis function networks. *Journal of the Air & Waste Management Association*, 58(12), 1571-1578.

Taşdemir, Y., ve Erbaşlar, T. (2007). Kentsel bir atmosferdeki bazı hava kirleticilerin meteorolojik parametrelerle ilişkilendirilmesi. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 12(2).

Tosunoglu, N. G., ve Benli, Y. K. (2012). Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü/Forecasting of Morgan Stanley Capital International Turkey Index with Artificial Neural Networks. *Ege Akademik Bakis*, 12(4), 541.

Vallero, D., A. Fundamentals of air pollution, USA: Academic press, 2008.

World Health Organization. (2016). Ambient air pollution: A global assessment of exposure and burden of disease. *World Health Organization*.
<https://www.cleanairjournal.org.za/article/download/7001/8376>

Yadav, V., Yadav, A. K., Singh, V., and Singh, T. (2024). Artificial neural network an innovative approach in air pollutant prediction for environmental applications: A review. *Results in Engineering*, 22, 102305.

- Yüksek, A. G.** (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. *Sivas Cumhuriyet Üniversitesi, Yayınlanmamış Doktora Tezi, Sosyal Bilimler Enstitüsü, Sivas.*
- Yüksek, A. G., Bircan, H., Zontul, M., ve Kaynar, O.** (2007). Sivas ilinde yapay sinir ağları ile hava kalitesi modelinin oluşturulması üzerine bir uygulama. *CÜ İktisadi ve İdari Bilimler Dergisi, 8(1), 97-112.*

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Ahmad Tamim NOORI

Doğum tarihi ve yeri :

e-posta :

Öğrenim Bilgileri

	Okul/Program	Yıl
Y. Lisans	Balıkesir Üniversitesi/Çevre Mühendisliği	2026
Y. Lisans	Balıkesir Üniversitesi/İnşaat Mühendisliği	2023
Lisans	Balıkesir Üniversitesi/İnşaat Mühendisliği	2019

Yayın Listesi

Noori, A. T. (2023). *Hazne işletme optimizasyonu için parametrik bir simülasyon modelinin geliştirilmesi* (Master's thesis, Balıkesir University (Turkey)).

Okkan, U., Fistikoglu, O., Ersoy, Z. B., and Noori, A. T. (2023). Investigating adaptive hedging policies for reservoir operation under climate change impacts. *Journal of Hydrology*, 619, 129286.

Okkan, U., Fistikoglu, O., Ersoy, Z. B., and Noori, A. T. (2024). Analyzing the uncertainty of potential evapotranspiration models in drought projections derived for a semi-arid watershed. *Theoretical and Applied Climatology*, 155(3), 2329-2346.