

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**METEOROLOJİK PARAMETRELERİN HAVA
KİRLİLİĞİNE ETKİLERİNİN YAPAY SİNİR AĞLARI
MODELİ İLE İNCELENMESİ**

Çevre Mühendisi Mehmet Erkan GÜNDOĞDU

FBE Çevre Mühendisliği Anabilim Dalında
Hazırlanan

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Yrd. Doç. Dr. Arslan SARAL

İSTANBUL, 2006

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ	iv
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ	ix
ÖNSÖZ.....	x
ÖZET	xi
ABSTRACT	xii
1 GİRİŞ.....	1
1.1 Kirleticilerin Atmosferdeki Hareketleri.....	2
1.2 Kirleticiler Kaynakları	4
1.3 Kirleticilerin İnsan Sağlığına Etkileri	6
1.4 Metod: Yapay Sinir Ağları	7
1.4.1 Yapay Sinir Ağının Yapısı	8
1.4.2 YSA ağ tipleri.....	9
1.4.3 Eşik fonksiyonları.....	9
1.4.4 Ağırlık uzayı	11
1.4.5 Yapay Sinir Ağlarında Eğitim	12
1.4.5.1 Eğitim algoritmaları	12
1.4.5.2 Öğrenme Kuralları	12
1.4.6 Çok katmanlı perceptron (Multi-layer perceptron)	12
1.4.7 Hatanın geriye yayılması algoritması ve genelleştirilmiş delta kuralı.....	13
1.4.7.1 Bağlantı ağırlıklarının atanması.....	18
1.4.7.2 Öğrenme katsayısı	19
1.4.7.3 Momentum katsayısı.....	19
1.4.8 Verilerin Normalizasyonu	20
1.5 Neural Connection.....	20
1.6 Hava Kirliliği Modellemesinde Yapay Sinir Ağları Uygulamaları ile İlgili Önceki Çalışmalar	21
2 MATERYAL VE METODLAR	25
2.1 Çalışma Bölgesi Ve Veri Tabanı	25
2.1.1 Çalışma Bölgesi	25
2.1.1.1 Çalışma Bölgesinin Topografik Durumu	25
2.1.2 Veri Tabanı	27

2.1.2.1	Hava kirliliği verileri	27
2.1.3	Meteoroloji verileri	28
2.1.4	Verilerin Analizi Ve Model İçin Girdi Seti Hazırlanması.....	34
2.1.5	Meteorolojik Faktörlerin Kirliletiçi Konsantrasyonları İle Değişimleri	35
2.1.5.1	SO ₂ – Meteorolojik Parametrelerin Değişimleri	35
2.1.5.2	PM – Meteorolojik Parametrelerin Değişimleri	39
2.1.5.3	NO _x – Meteorolojik Parametrelerin Değişimleri	42
2.1.5.4	CO – Meteorolojik Parametrelerin Değişimleri	46
2.2	Metodoloji	50
2.2.1	Modellenebilirlik	52
2.2.2	Meteorolojik Faktörlerin Kirliliğe Etkilerinin Modellenmesi	54
3	SONUÇLAR VE DEĞERLENDİRMELER.....	55
3.1	Modeli Etkileyen Parametreler	55
3.1.1	Doğrulamalı Eğitim İle Denenen Çeşitli Modellerin Performansları	56
3.1.2	Verilerde Sınıf Eşitlemesinin Model Performansı Üzerindeki Etkileri.....	57
3.2	Model Tahmin Sonuçları	57
3.2.1	SO ₂ Tahmin Sonuçları	58
3.2.2	PM ₁₀ Tahmin Sonuçları	61
3.2.3	CO Tahmin Sonuçları	64
3.2.4	NO _x Tahmin Sonuçları	67
3.3	Meteorolojik Faktörlerin Kirlilik Parametrelerine Etkilerinin YSA İle Belirlenmesi	70
3.3.1	SO ₂ – Meteorolojik Faktörlerin Etkileşimleri	70
3.3.2	PM ₁₀ Meteorolojik Faktörlerin Etkileşimleri	74
3.3.3	CO Meteorolojik Faktörlerin Etkileşimleri	77
3.3.4	NO _x Meteorolojik Faktörlerin Etkileşimleri	81
3.4	Meteorolojik Parametrelerin Çıktı Üzerindeki Etkileri	84
4	ÖNERİLER	92
	KAYNAKLAR.....	93
	ÖZGEÇMİŞ.....	96

SİMGE LİSTESİ

SO ₂	Kükürt dioksit
PM ₁₀	Partiküler madde
CO	Karbon monoksit
NO _x	Azot oksit bileşikleri
SO _x	Kükürt oksit bileşikleri
HC	Hidrokarbonlar
NO ₂	Azot dioksit

KISALTMA LİSTESİ

YSA	Yapay sinir ağıları
EPA	Environmental Protection Agency
MLP	Multi Layer Perceptron
ANN	Artificial Neural Networks

ŞEKİL LİSTESİ

Şekil 1.1	Kuzey yarım kürede bir siklonda yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri.....	3
Şekil 1.2	Kuzey yarım kürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri.	3
Şekil 1.3	YSA'nın blok diyagramı	8
Şekil 1.4	Yapay Sinir Ağları Sınıflandırıcıları.	9
Şekil 1.5	Çok kullanılan eşik fonksiyonları.....	10
Şekil 1.6	Üç boyutlu uzayda ağırlık vektörünün değişimi.....	11
Şekil 1.7	Çok katmanlı perceptron	13
Şekil 1.8	Hatanın geriye yayılması algoritmasının blok akış diyagramı	14
Şekil 1.9	Gizli katmanı olmayan ağırlık hata fonksiyonu	16
Şekil 1.10	Gizli katmana ait ağırlık hata fonksiyonu	16
Şekil 2.1	İstanbul ili şehir haritası	25
Şekil 2.2	İstanbul ili topografik haritası.....	27
Şekil 2.3	Hava kirliliği ölçüm noktaları.....	28
Şekil 2.4	Günlük ortalama sıcaklığın 2003-2005 yılları arasında değişimi.....	29
Şekil 2.5	Günlük ortalama deniz seviyesi basıncının 2003-2005 yılları arasında değişimi .	29
Şekil 2.6	Günlük gözlemlenen bulutluluk seviyesinin 2003-2005 yılları arasında değişimi	30
Şekil 2.7	Günlük ortalama nem oranının 2003-2005 yılları arasında değişimi	31
Şekil 2.8	Günlük ortalama çığ noktasının 2003-2005 yılları arasında değişimi.....	31
Şekil 2.9	Hakim rüzgar yönlerinin YSA modeli için girdi sayısal değerlerine dönüştürülmesi.....	32
Şekil 2.10	Günlük rüzgar yönünün 2003 – 2005 yılları arasında değişimi	33
Şekil 2.11	Günlük ortalama rüzgar hızının 2003 – 2005 yılları arasında değişimi	33
Şekil 2.12	Nem oranının ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	35
Şekil 2.13	Sıcaklığın ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	36
Şekil 2.14	Rüzgar yönünün ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	36
Şekil 2.15	Rüzgar hızının ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	37
Şekil 2.16	Bulutluluk seviyesinin ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	37
Şekil 2.17	Deniz seviyesi basıncının ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	38
Şekil 2.18	Çığ noktasının ve SO ₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	38
Şekil 2.19	Sıcaklığın ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	39
Şekil 2.20	Rüzgar hızının ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	40
Şekil 2.21	Rüzgar yönünün ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	40
Şekil 2.22	Nem oranının ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	41
Şekil 2.23	Bulutluluk seviyesinin ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	41
Şekil 2.24	Deniz seviyesi basıncının ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	42
Şekil 2.25	Çığ noktasının ve PM ₁₀ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	42

Şekil 2.26	Sıcaklığın ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	43
Şekil 2.27	Rüzgar hızının ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	44
Şekil 2.28	Rüzgar yönünün ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	44
Şekil 2.29	Nem oranının ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	45
Şekil 2.30	Çiğ noktasının ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	45
Şekil 2.31	Deniz seviyesi basıncının ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	46
Şekil 2.32	Bulutluluk seviyesinin ve NO _x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	46
Şekil 2.33	Sıcaklığın ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi .	47
Şekil 2.34	Rüzgar hızının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	48
Şekil 2.35	Rüzgar yönünün ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	48
Şekil 2.36	Nem oranı ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.	49
Şekil 2.37	Bulutluluk seviyesinin ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	49
Şekil 2.38	Deniz seviyesi basıncının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi	50
Şekil 2.39	Çiğ noktasının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi.....	50
Şekil 2.40	Kullanılan YSA modelinin topolojik yapısı	51
Şekil 2.41	Günlük ortalama SO ₂ konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi	52
Şekil 2.42	Günlük ortalama PM ₁₀ konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi.....	53
Şekil 2.43	Günlük ortalama CO konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi.....	53
Şekil 2.44	Günlük ortalama NO _x konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi.....	54
Şekil 3.1	Doğrulamalı eğitimde en iyi model noktası.....	56
Şekil 3.2	Ölçülen SO ₂ konsantrasyonunun ve en iyi model tahmininin dağılım diagramı ..	58
Şekil 3.3	Ölçülen SO ₂ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması	59
Şekil 3.4	Ölçülen SO ₂ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması	60
Şekil 3.5	Ölçülen PM ₁₀ konsantrasyonunun ve en iyi model tahmininin dağılım diagramı.	61
Şekil 3.6	Ölçülen PM ₁₀ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması ..	62
Şekil 3.7	Ölçülen PM ₁₀ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması ..	63
Şekil 3.8	Ölçülen CO konsantrasyonunun ve en iyi model tahmininin dağılım diagramı ...	64
Şekil 3.9	Ölçülen CO konsantrasyonunun ve en iyi model tahmininin karşılaştırılması	65
Şekil 3.9	Ölçülen CO konsantrasyonunun ve en iyi model tahmininin karşılaştırılması	66
Şekil 3.11	Ölçülen NO _x konsantrasyonunun ve en iyi model tahmininin dağılım diagramı..	67
Şekil 3.12	Ölçülen NO _x konsantrasyonunun ve en iyi model tahmininin karşılaştırılması....	68
Şekil 3.13	Ölçülen NO _x konsantrasyonunun ve en iyi model tahmininin karşılaştırılması....	69
Şekil 3.14	SO ₂ konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi ...	71
Şekil 3.15	SO ₂ konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi	71
Şekil 3.16	SO ₂ konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi	72
Şekil 3.17	SO ₂ konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi	72
Şekil 3.17	SO ₂ konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi.....	73

Şekil 3.18	SO ₂ konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi.....	73
Şekil 3.19	SO ₂ konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi.....	74
Şekil 3.20	PM ₁₀ konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi .	74
Şekil 3.21	PM ₁₀ konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi.....	75
Şekil 3.22	PM ₁₀ konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi.....	75
Şekil 3.23	PM ₁₀ konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi.....	76
Şekil 3.24	PM ₁₀ konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi.....	76
Şekil 3.25	PM ₁₀ konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi.....	77
Şekil 3.26	PM ₁₀ konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi.....	77
Şekil 3.26	CO konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi	78
Şekil 3.27	CO konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi	78
Şekil 3.28	CO konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi	79
Şekil 3.29	CO konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi.....	79
Şekil 3.30	CO konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi.	80
Şekil 3.31	CO konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi.....	80
Şekil 3.32	CO konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi.....	81
Şekil 3.33	NO _x konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi...	81
Şekil 3.34	NO _x konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi	82
Şekil 3.35	NO _x konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi	82
Şekil 3.36	NO _x konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi.....	83
Şekil 3.37	NO _x konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi.....	83
Şekil 3.38	NO _x konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi.....	84
Şekil 3.39	NO _x konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi.....	84
Şekil 3.40	Meteorolojik parametrelerin SO ₂ konsantrasyonu ile değişim oranı.....	86
Şekil 3.41	Meteorolojik parametrelerin PM ₁₀ konsantrasyonu ile değişim oranı.....	87
Şekil 3.42	Meteorolojik parametrelerin CO konsantrasyonu ile değişim oranı.....	88
Şekil 3.43	Meteorolojik parametrelerin NO _x konsantrasyonu ile değişim oranı.....	89

ÇİZELGE LİSTESİ

Çizelge 1.1	İstanbul'da 1999 yılındaki kirletici emisyonlarının dağılımı	5
Çizelge 1.2	Amerika'da 1987 yılı için kirletici emisyonları	6
Çizelge 1.3	Bazı hava kirliliği olayları ve sonuçları	6
Çizelge 2.1	Modelde kullanılan parametreler ve bunların 2003 – 2005 yılları arasındaki ortalama değerleri	34
Çizelge 3.1	Modelde kullanılan meteorolojik faktörlerin ortalama değerleri	70
Çizelge 3.2	Meteorolojik parametrelerin SO ₂ konsantrasyonuna etkisi.....	85
Çizelge 3.4	Meteorolojik parametrelerin PM ₁₀ konsantrasyonuna etkisi.....	86
Çizelge 3.6	Meteorolojik parametrelerin CO konsantrasyonuna etkisi.....	87
Çizelge 3.5	Meteorolojik parametrelerin NO _x konsantrasyonuna etkisi	88
Çizelge 3.6	En iyi model verileri.....	90

ÖNSÖZ

Hava kirliliğinin modellenmesi ve önceden tahmini insan sağlığı açısından önem teşkil etmektedir. Kirlilik seviyesinin arttığı kış aylarında, meteorolojik koşullara bağlı olarak hava kirliliğinin önceden bilinmesi, zamanında önlemler alınmasına ve hava kirliliğinden en az ölçüde etkilenmeye katkıda bulunacaktır. İstanbul ili için yapılan bu çalışmada, düzenli olarak ölçülen meteorolojik parametreler kullanılarak atmosfer uygulamalarında kullanımı giderek yaygınlaşan ve klasik istatistiksel metotlara kıyasla oldukça başarılı sonuçlar ortaya koyan yapay sinir ağıları modelleri kullanılarak SO₂, NO_x, PM₁₀ ve CO kirlilik parametreleri tahmin edilmiştir.

Katkılarından dolayı Sayın hocam Yrd. Doç. Dr. Arslan Saral'a, Arş. Gör. Kamil Varınca'ya, Arş. Gör. Fatih İlhan'a ve Çevre Müh. Faruk Özdemir'e teşekkürü bir borç bilirim.

Mehmet Erkan Gündoğdu

İstanbul, 2006

ÖZET

Hava kirliliği özellikle büyük şehirler için kış aylarında önemli bir sorun olarak kendisini göstermektedir. Kirleticilerin atmosfere bırakılma miktarı yanında olumsuz atmosferik şartlar büyük şehirlerde hava kirliliğinin insan sağlığı için olumsuz konsantrasyon değerlerine ulaşmasına neden olmaktadır. İstanbul ilinin geçmişi göz önüne alındığında bu tür olumsuzluklar özellikle kış aylarında sıkça gözlemlenmiştir. Hava kirliliği modellemesi ile kirletici konsantrasyonların doğru bir şekilde tahmininin yapılması kirliliğin olumsuz etkilerinin azaltılmasında ya da gerekli önlemlerin alınmasında etkili olacaktır.

Bu çalışmada İstanbul ili ele alınarak, hava kirliliği konularında giderek daha yaygın uygulama olanağı bulan ve başarılı sonuçlar veren Yapay Sinir Ağları (YSA) modelleri kullanılarak hava kirliliğinin çeşitli meteorolojik parametreler bazında modellenmesi ve hava kirliliğinin tahmini yapılmıştır. SO_2 , NO_x , PM_{10} ve CO kirletici parametreleri için uygun modeller oluşturulmuş ve bu modeller yardımı ile meteorolojik parametrelerdeki değişimin kirletici konsantrasyonlarına olan etkileri incelenmiştir. Kullanılan meteorolojik parametreler kuru termometre sıcaklığı, deniz seviyesi basıncı, bağıl nem, bulutluluk seviyesi, hakim rüzgar yönü ve rüzgar hızıdır. Bu bağımsız parametrelerle, SO_2 , NO_x , PM_{10} ve CO konsantrasyonları modellenen ve tahmin edilen hava kirliliği parametreleri olarak kullanılmıştır.

Veri tabanı olarak 2003 – 2005 yılları arasındaki veriler zaman sıralı olarak kullanılmış ve bu veri seti ile en uygun modeller oluşturulmuştur. Yeterli sayıda gizli katman nöron sayısı olmayan modellerin verileri genelleyemediği, diğer yandan fazla sayıda gizli katman nöron içeren modellerin eğitime setini ezberlediği ve genelleme yapabilme kabiliyetinin azaldığı gözlemlenmiştir.

Model sonuçları incelendiğinde SO_2 , NO_x , PM_{10} ve CO'nın kış aylarındaki yüksek değerlerden ilkbahar ve yaz aylarına doğru düşüş eğilimi ve yine kış aylarına doğru yükseliş eğilimi YSA modeli ile oldukça iyi temsil edilebilmektedir. Herbir kirletici için en iyi model kullanılarak meteorolojik parametrelerdeki değişimin kirletici konsantrasyonu üzerindeki etkileri incelendiğinde modellerin genel olarak başarılı tahminler yapabildiği görülmüştür.

Anahtar kelimeler: Hava kirliliği, yapay sinir ağları, MLP, modelleme, meteorolojik faktörler

ABSTRACT

Air pollution shows itself as a serious problem in big cities especially for winter seasons. Beside the amount of pollution emission into the atmosphere, stable atmospheric conditions cause the air pollution episodes in big cities. As in the case of İstanbul, there were frequently occurring air pollution episodes in the previous years. When considering this point of view, it is obvious that air pollution modelling and prediction in advance have great importance in preventing the occurrence of air pollution episodes or will provide sufficient time to take the necessary precautions.

In this study, İstanbul metropolitan city was taken as the study area, and Artificial Neural Networks (ANN), was used in modelling and predicting air pollution on the basis of various meteorological parameters. Best models are constructed to predict the concentrations of SO₂, NO_x, PM₁₀ and CO pollutants and their variation through the meteorological parameters. The meteorological parameters used in this study are dry bulb temperature, sea level pressure, relative humidity, cloudness, wind speed, wind direction and dew point.

The data between the years 2003 and 2005 were used in time series form as data base in this study. ANN models without enough hidden layer neurons can not generalize the data. On the other hand, the models having too many hidden layer neurons tend to memorize the training set and again missing the generalization ability.

Test results show that the trend of pollutants from seasonal variations can be correctly represented by the neural networks. And the effects of the meteorological parameters on the pollutant concentrations were generally correctly represented by the neural networks models.

Keywords: Air pollution, artificial neural networks, MLP, modelling, meteorological factors

1 GİRİŞ

Teknolojideki gelişmeler doğrultusunda giderek daha hızlı bir şekilde oluşan hava kirliliği insanlar için çok önemli bir sorun olmuştur. Bu kirlilik insan sağlığı üzerinde doğrudan ve dolaylı birçok istenmeyen durumlara yol açmaktadır. Hava kirliliğinin birincil kaynağı yanma reaksiyonlarıdır. Bunların başlıca kaynakları fabrikalar, motorlu araçlar, ısınma, enerji üretimi olarak sayılabilir. Teorik olarak yanma gerçekleştiğinde yakıt içindeki hidrojen ve karbon havanın oksijeni ile birleşerek ısı, ışık, karbondioksit ve su buharı açığa çıkar. Bununla beraber yakıttaki safsızlıklar, uygun olmayan hava/yakıt oranı ve ya çok yüksek ya da çok düşük yanma sıcaklıkları karbonmonoksit, kükürt oksitleri, azot oksitleri, uçucu kül ve yanmayan hidrokarbonlar gibi hepsi hava kirleticileri olan maddelerin açığa çıkmasına sebep olabilir. En önemli hava kirleticilerinden SO_2 , PM, CO ve NO_x öncelikli olarak benzin yanması, araç emisyonları, fosil yakıtların fabrikalarda, termik santrallerde rafinerilerde, ofis binalarında evlerde ve yakma tesislerinde yakılması sonucu ortaya çıkmaktadır.

Düşük kalitede fosil yakıtların ısınma amaçlı kullanımı ve endüstriyel faaliyetler sonucunda havadaki kirletici konsantrasyonları giderek artış göstermektedir. Diğer büyük şehirlerde olduğu gibi İstanbul'da da bu kirlilik önemli bir sorun teşkil etmektedir. Özellikle kış aylarında bu kirlilik seviyesinde gözle görünür bir artış göstermektedir. Kararlı atmosferik koşullar büyük şehirlerde kirliliğin oluşmasında en önemli etkenlerden biridir. Meteorolojik faktörler havadaki bölgesel karışım için belirleyici faktörlerdir.

Hava kirliliği atmosferde bulunan kirleticilerin insan sağlığı, bitki, yapı ve malzemelerde zararlı etkiler meydana getirecek konsantrasyon ve sürede bulunması" şeklindedir (Wark ve diğerleri, 1981). Bu nedenle hava kirliliğini oluşmadan tahmin edebilmek ve önceden önlemler almak giderek daha önemli olmaktadır. Bu doğrultuda tahmin yapabilmek için istatistiksel ve deterministik modeller oluşturulmuştur. Gauss modelleri kirleticinin bir yöndeki dağılımı bilindiğinde kullanılabilir fakat değişen rüzgar yönlerinde yeterli verim elde edilememektedir. (Collet ve Oluyemi, 1997) Ayrıca kirletici ve diğer parametreler ile ilgili yeterli veri bulunamadığından istatistiksel modeller giderek daha yaygın olarak kullanılmaktadır. (Ziomass ve diğerleri 1995.) Kirleticiler arasındaki kompleks ve doğrusal olmayan ilişkilerin geleneksel istatistiksel metodların büyük veri setini algılamakta yetersiz kalması nedeniyle ifadesi zordur. (Bakshi ve diğerleri, 1999) Yapay sinir ağları doğrusal olmayan sistemleri modelleyebilmekte ve başarılı sonuçlar elde edilebilmektedir. (Boznar ve diğerleri, 1993 ; Comrie, 1997)

1.1 Kirleticilerin Atmosferdeki Hareketleri


Çeşitli kaynaklardan yayılan bütün hava kirleticileri, meteorolojik şartlara bağlı olarak taşınır, yayılır veya bir bölgede toplanır. Taşınma sırasında kirletici seyrelir ya da fotokimyasal reaksiyonlara uğrar.(Myer, 1999) Çevrim, kirleticilerin yağmur ile atmosferden yıkanması vasıtasıyla, sonuçta bitkiler, yüzey suları, toprak ve diğer malzemeler üzerine çökmesi ile ya da bazı faktörler etkisi ile ortamdan uzaklaşması ile tamamlanır. Bazı durumlarda kirleticiler rüzgar sebebiyle tekrar atmosfere girebilirler. Kirleticilerin atmosferdeki hareketleri dikey ve yatay yönde hareketler olmak üzere iki şekildedir.

Dikey hareketler

Kirleticilerin atmosferde dikey taşınımalarını sağlayan ve ya engelleyen atmosferik hareketler, meteorolojik ölçeklerine bakılmaksızın, atmosfer kararlılığı, alçak ve yüksek basınç durumlar, atmosferik durgunluk olarak önemli başlıklar altında sıralanabilir.


Atmosfere bırakılan kirleticilerin dağılma derecesini tahmin edebilmek için atmosferin kararlılık durumunun bilinmesi gerekmektedir. Atmosferin kararlılığı, dikey karışım ve ya hareket yapma derecesinin ölçüsüdür. Atmosfer kararlı ise, yani yeterince dikey karışım ve ya hareket göstermiyorsa, kaynaktan bırakılan kirleticiler yer yüzeyine yakın bölgede kalır ve dağılmazlar. Atmosferin kararlılığı doğrudan düşey sıcaklık profiline bağlıdır. Sıcaklığın yükseklikle değişme oranı kararlılığı belirleyen parametredir. Bu sıcaklık profiline bağlı olarak atmosferin kararlılığı genel olarak kararsız, nötr, kararlı ve enversiyon olmak üzere dört tiptir.

Alçak basınç (Siklon hareketi) : Bir sıcak hava kütesinin soğuk hava kütlesi altına girmesi ile oluşur. Oluşan sıcaklık farkı dolayısıyla altta kalan sıcak hava kütlesi yükselme eğilimi gösterir. Sıcak hava kütlesi yükselirken düşük irtifalarda yerini çevresinden gelen hava doldurur. Oluşan bu içeri doğru hareket, yakınsayan siklonik bir harekettir ve spiral şeklinde yukarı doğru oluşur (Şekil 1.1). Bu spiralin yönü kuzey yarım kürede saat yönünün tersinde, güney yarım kürede ise saat yönünde oluşur. Oluşan bu yukarı doğru hareket alt atmosferdeki kirleticileri de yukarı doğru taşıyarak dağıtır. Bu bakımdan alçak basınç sistemi kirleticilerin dağıtılması açısından istenen bir durumdur.



Şekil 1.1 Kuzey yarım kürede bir siklonda yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri. Havanın düşey doğrultudaki hareketi sağdaki şekilde gösterilmiştir.

Yüksek basınç (Antisiklon hareketi) : Yüksek basınç durumu da alçak basınç durumunun tersine bir soğuk hava kütesinin bir sıcak hava kütlesi üzerine çıkması ile oluşur. Yukarıda kalan soğuk hava kütlesi aşağı doğru hareket etme eğilimi gösterir. Aşağı inerken yerini çevresinden gelen hava doldurur. Bu durumda oluşan aşağı doğru hareket dışarı doğru bir spiral şeklini alır (Şekil 1.2). Bu hava hareketine antisiklon hareketi de denilmektedir. Hareket aşağı doğru olduğu için böyle bir basınç sisteminin bulunduğu bölgede atmosfere bırakılan kirleticiler yukarı doğru yükselemez. Bunun için hava kirliliği açısından istenmeyen bir durumdur.



Şekil 1.2 Kuzey yarım kürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri. Havanın düşey doğrultudaki çökme hareketi sağdaki şekilde gösterilmiştir.

Atmosferik durgunluk (blocking) : Avrupa ve ABD'nin doğusundaki en ciddi hava kirliliği olayları bir antisiklonun doğuya doğru hareketini geçici bir süre için durdurması ve birkaç gün süreyle durgunluk oluşturması ile olmuştur. Durgunluk oluşturan antisiklonlara müsait topografik yapıları bölgeler, hava kirliliği için ciddi potansiyel taşımaktadır.

Yatay yöndeki hareketler (rüzgarlar)

Kirleticilerin atmosferde yatay yayılmaları, emisyon kaynağı yüksekliğindeki ortalama rüzgar hızına büyük ölçüde bağlı bir fonksiyondur. Bölgenin topografik yapısı, ağaçların yoğunluğu ve yerleşimi, göllerin, nehirlerin, tepelerin ve yapıların yerleşimi ve boyutları dikey yönde farklı rüzgar hızı profillerini oluşturmaktadır.

1.2 Kirletici Kaynakları

Hava kirliliği doğal veya insan kökenli kaynaklardan gaz, toz veya sıvı halde atmosfere atılan maddelerin doğrudan veya dolaylı olarak diğer maddelerle reaksiyona girmesiyle olmaktadır.

Doğal yollar; volkanlar, tozlar, orman yangınlar, su yüzeyinden olan atımlardır. İnsan kaynaklı hava kirliliği oluşum sebepleri genel olarak üç grupta toplanmaktadır.

Alansal Kaynaklar

Bu grupta en önemli kaynak konutların ısıtılmasıdır. İstanbul'da son yıllarda doğalgaz kullanımı hızla artmakta ve kükürt değeri az, kalori değeri yüksek olan tamamen ithal veya ithal yerli kömür karışımı yakıt kullanılmaktadır. Isıtmada kullanılan diğer yakıt cinsleri de fuel-oil, motorin, kerosin, gaz ve odundur. Konut ısıtılmasında ve enerji temininde kullanılan fosil yakıtlar içerisinde en büyük pay kömür ve petrole aittir. Kullanılan yakıtın kalitesi bu tür kaynaklardan gelen hava kirliliği üzerine çok fazla etki yapmaktadır.

Çizgisel Kaynaklar

Bu tür hava kirliliği ulaştırma kaynaklıdır. Yolcu ve yük taşıyan araçların getirdiği kirlilik başlıcalarıdır. Bunlar benzinli, mazotlu ve gaz tribünlü içten yanmalı motorla çalışmaktadırlar. Bu kaynaklardan yanma sonucu karbon monoksit (CO), azot oksitler (NO_x), kükürt oksitler (SO_x), hidrokarbonlar (HC) ve partiküller madde (PM) kirletici olarak atmosfere yayılmaktadır (Şen, 1996). Karbon monoksit, hidrokarbon ve azot oksitler bakımından en yüksek emisyonlar araçlar tarafından oluşturulmaktadır.

Noktasal Kaynaklar

Bu gruptaki kaynaklar fabrikalar, sanayi ve enerji santralleridir. Bu işletmelerde üretim yapmak için gerekli olan enerjiyi sağlamak için kullanılan yakıttan atmosfere kirletici çıkmaktadır. Ayrıca noktasal olarak katı atıkların fırınlarda ve açık arazide yanması sonucu kirlenme oluşmaktadır. Yine benzin, boya maddeleri ve kuru temizleme çözeltileri gibi organik maddelerin buharlaşmasından noktasal olarak kirlilik meydana gelmektedir.

İstanbul'da hava kirliliğinin en önemli kaynaklarını, ev ve apartmanlarda kış aylarında ısınma maksadıyla kullanılan yakıtların yakılmasından ileri gelen ve alan kaynak olarak sınıflandırılan kaynaklar teşkil etmektedir. Bunların yanında, hareketli kaynaklar olarak sınıflandırılan motorlu taşıtlar ve nokta kaynaklar kategorisine giren endüstriyel kaynaklar da bölgesel olarak hava kirlenmesine yol açmaktadır. Isıtma ve endüstriyel kaynaklardaki emisyonları sabit kaynaklarda yakıt yanması olarak belirlemek mümkündür.

Bu yakıtların yakılması neticesinde atmosfere verilen belli başlı kirleticiler arasında, partiküler madde (PM), kükürtdioksit (SO_2), azot oksitler (NO_x), karbonmonoksit (CO), hidrokarbonlar (HC) bulunmaktadır. Bunlardan son üçünün önemli bir kaynağını motorlu taşıtlar oluşturmaktadır. İstanbul'da sabit kaynaklar ve taşıtlardan meydana gelen kirletici miktarları, emisyon faktörleri kullanılarak hesaplandığında bu emisyonların relatif dağılımları bulunabilir. 1990 yılı için bu faktörler kullanılarak tahmin edilen kirletici emisyonlarının dağılımı Çizelge 1.1'de gösterilmiştir.

Çizelge 1.1 İstanbul'da 1999 yılındaki kirletici emisyonlarının dağılımı

Kirletici	Toplam Emisyon İçindeki Payı (%)	Kaynak Payları (%)	
		Sabit Kaynaklar	Taşıtlar
PM	10.8	4.9	5.9
SO_2	4.8	2.6	2.2
CO	57.1	0.1	57
NO_x	15.6	1.7	13.9
HC	11.7	0.1	11.6
TOPLAM	100	≈ 10	≈ 90

Çizelge 1.1'den görüldüğü gibi, İstanbul'da hava kirlenmesine büyük ölçüde taşıtlar için kullanılan yakıtlar sebep olmaktadır. Sabit kaynakların hava kirliliğindeki payı ise %10 mertebesindedir. Çizelge 1.2'de bazı kirleticilerin Amerika'da toplam emisyon içindeki payları ve kaynakları verilmektedir.

Çizelge 1.2 Amerika’da 1987 yılı için kirletici emisyonları EPA (1989)

Kirletici	Taşıma (10 ⁶ ton/yıl)	Yakıt emisyonu (10 ⁶ ton/yıl)	Endüstriyel faaliyetler (10 ⁶ ton/yıl)	Toplam (10 ⁶ ton/yıl)
Partiküller	1,4	1,8	3,8	7,0
SO ₂	0,9	16,4	3,1	20,4
CO	40,7	7,2	13,5	61,4
NO _x	8,4	10,3	0,8	19,5
Organik oksitler	6,0	2,3	11,3	19,6
Kurşun	3,0	0,5	4,6	8,1
Toplam Emisyon	60,4	38,5	37,1	136,0

1.3 Kirleticilerin İnsan Sağlığına Etkileri

Pek çok kentimizde özellikle kış aylarında yoğun olarak karşılaştığımız hava kirliliği insan sağlığı açısından önemli problemler yaratmakta ve hatta bazı durumlarda ölümlere neden olabilmektedir. Örnek olarak geçmiş yıllarda dünya üzerinde toplu ölümlere neden olmuş bazı hava kirliliği olayları Çizelge 1.3’de görülmektedir.

Çizelge 1.3 Bazı hava kirliliği olayları ve sonuçları EPA (1989)

Yeri	Tarihi	Ölü sayısı
Aralık 1930	Meuse Valley, Belçika	63
Ekim 1948	Donora, Pensilvanya	17
26 Kasım – 1 Aralık 1948	Londra, İngiltere	700 – 800
5 – 9 Aralık 1952	Londra, İngiltere	4000
3 – 6 Ocak 1956	Londra, İngiltere	1000
2 – 5 Aralık 1967	Londra, İngiltere	700 – 800
26 – 31 Ocak 1959	Londra, İngiltere	200 – 250
5 – 10 Aralık 1967	Londra, İngiltere	700
7 – 22 Ocak 1963	Londra, İngiltere	700
9 ocak – 12 Şubat 1963	New York, Amerika	200 – 400

SO₂ yüksek konsantrasyonlarda öldürücü etkileri olan bir gazdır. 1952’de Londra’da binlerce insan hava kirliliği nedeniyle yaşamlarını yitirmişlerdir. SO₂’nin insan sağlığına diğer etkileri bağışık sistemi zayıflığı ve ciğerlerde patolojik değişiklikler olarak sıralanabilir.

NO_x da SO₂ gibi yüksek konsantrasyonlarda ölüme yol açabilir. Yüksek konsantrasyon seviyelerinde gözlerde tahriş, bronşit ve pneumonya NO_x kirleticisinin diğer etkilerindendir.

CO akciğerlerde kendisini hemoglobine bağlamaktadır. Bu kandaki oksijen miktarının

azalmasına neden olmaktadır.

PM solunum sistemine girerek buralarda depolabilir. Bazı partiküller yüksek toksisite değerleri yüzünden tehlikeli olabilmektedirler. Yüksek toz konsantrasyonlarının solunması bronşite neden olabilir. (Eagleman, 1991)

1.4 Metod: Yapay Sinir Ağları

Yapay sinir ağları, geniş bir alana yayılmış bilimsel ve mühendislik problemlerinin çözümü için uygulanan bir teknolojidir. Yapay sinir ağlarının matematiği, biyolojik sistemlerin yararlı özellikleri kullanılarak elde edilmiştir. Biyolojik sinir sistemlerinde olduğu gibi, yapay sinir ağları da kendi çözüm tarzlarını bulmak için eğitilebilirler.

Yapay Sinir Ağları (YSA); insan beyninin çalışma sisteminin yapay olarak taklit edilmesi sonucu ortaya çıkmıştır. YSA, insan beynindeki nöronlara karşılık gelen yapay basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanmasından oluşan karmaşık bir sistemdir. Bugün YSA; fizik, matematik, elektrik ve bilgisayar mühendisliği gibi çok farklı bilim dallarında araştırma konusu haline gelmiştir. Yapay sinir ağlarının uygulamada kullanım alanı, değişik yapıda ve formlarda bulunabilen verileri hızlı bir şekilde sınıflandırma, tanımlama ve algılama üzerinedir. YSA, klasik tekniklerle çözümü zor problemler için mühendislik uygulamalarında etkin bir alternatiftir

YSA'lar, önceden tahmin, örnek değerlendirme ve gruplama işlemlerinde etkilidir. Aynı işlemleri klasik bir bilgisayar programı ile yapmak da mümkündür. YSA'lar, açıkça kuralları bulunmayan ve ya anında optimizasyon kısıtlamaları koyan uygulamalar için idealdir. YSA için endüstriyel kontrol işlemleri oldukça yaygın uygulama alanlarıdır. Burada kurallar çok sık değişmez ve üstelik iyi bir tarafı da öteki çalışma koşullarına ait verilerin bol oluşudur.

YSA'ların uygulamadaki dezavantajlarını sıralayacak olursak;

- Bir problemin çözümünde çok uygun bir çözüm bulamayabilirler ve çözümde hata yapabilirler. Buna sebep ise eğitilecek bir fonksiyonun bulunamamasıdır. Fonksiyon bulunsa bile yeterli veri sağlanamayabilir.
- Sonuç almak yüzlerce giriş örneğinin hesaplanmasına bağlı olabilir. Ayrıca hangi ağırlığın sonucu nasıl etkileyeceğini tahmin etmek zordur.
- YSA'larla bir dizi işlem yapmak, bunları eğitmek yavaş ve pahalı olabilir. Maliyeti arttıran sebeplerden ilki eğitme verilerinin toplanması ve değerlendirilmesidir. Doğru


değerleri bulmak için deneyler yapmak gerekebilir.

- Bir YSA'nın kalitesi ve kapasitesi uygulamadaki hızı ile orantılıdır. Öyleki düğüm sayısındaki az bir artış bile yürütme zamanında çok daha fazla artışa sebep olur. Örneğin 100 düğümde 10 000 bağlantı var ise, standart bir mikroişlemci bunu 10 000 000 çarpma, saklama işlemi yaparak hesaplanır. Böylece ağdan saniyede 1000 geçiş olur. Eğer 300 düğüm var ise aynı işlemci ancak 100 kere geçiş yapmayı sağlayabilir. Kısacası düğüm sayısı 3 kat arttığında cevap süresi 10 kat azalır.

YSA'ların diğer çözümlerden daha doğru çözümler ürettikleri de bir gerçektir. Çünkü bu sakıncalı durumlar teorik olarak söz konusudur.

1.4.1 Yapay Sinir Ağının Yapısı


YSA paralel dağılmış bir bilgi işleme sistemidir. YSA'nın temelinde, zeka gerektiren işlemlerden oluşan bilgi işleme işlevi vardır. Bu sistem, tek yönlü işaret kanalları (bağlantılar) ile birbirine bağlanan işlem elemanlarından oluşur. Çıkış işareti bir tane olup isteğe göre çoğaltılabilir. YSA yaklaşımının temel düşüncesiyle, insan beyninin fonksiyonları arasında benzerlik vardır. Bu yüzden YSA sistemine insan beyninin modeli denilebilir. YSA çevre şartlarına göre davranışlarını şekillileyebilir. Girişler ve istenen çıkışların sisteme verilmesi ile kendisini farklı cevaplar verebilecek şekilde ayarlayabilir. Ancak son derece karmaşık bir içyapısı vardır. Bu sebeple bugüne kadar gerçekleştirilen YSA; biyolojik fonksiyonların temel nöronlarını örnek alarak yerine getiren kompoze elemanlardır. Yapay sinir ağının genel blok diyagramı Şekil 1.3'de görülmektedir.



Şekil 1.3 YSA'nın blok diyagramı

Bir işlem elemanına gelen girişler matematiksel tiplerine göre etiketlenilerek sınıflandırılır. YSA, giriş veri tiplerine göre ikili giriş (0,1) ve sürekli değerli giriş olmak üzere aşağıdaki

gibi sınıflandırılır.



Şekil 1.4 Yapay Sinir Ağları Sınıflandırıcıları.

1.4.2 YSA ağ tipleri

YSA'nın üç çeşit ağ tipi vardır; İleri beslemeli ağ: Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir, Kaskat bağlantılı ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir, Geri beslemeli ağ: En az bir hücre sonraki katmanlardaki hücrelerce de beslenir.

1.4.3 Eşik fonksiyonları

Transfer ve ya işaret fonksiyonları olarak da adlandırılan eşik fonksiyonları; muhtemel sonsuz domen girişli işlem elemanlarını, önceden belirlenmiş sınırdan çıkış olarak düzenler. Dört tane yaygın eşik fonksiyonu vardır. Bunlar lineer, rampa, basamak ve sigmoid fonksiyonlarıdır. Şekil 1.5'de bu fonksiyonlar gösterilmiştir.

Şekil 1.5.a'da gösterilen lineer fonksiyonun denklemi aşağıdaki gibidir:


$$f(x) = \alpha x \quad (1.1)$$

Formülde α , işlem elemanının x aktivitesini ayarlayan reel değerli bir sabittir. Lineer fonksiyon $[-\tau, +\tau]$ sınırları arasında kısıtlandığında (b)'deki rampa eşik fonksiyonu olur ve denklemi;

$$f(x) = \begin{cases} \tau: & \text{eger } x \geq \tau \\ x: & \text{eger } |x| < \tau \text{ şeklini alır.} \\ -\tau: & \text{eger } x \leq -\tau \end{cases} \quad (1.2)$$

$+\tau$ ($-\tau$) işlem elemanının maksimumu (minimumu), çoğu zaman doyma seviyesi olarak adlandırılan çıkış değeridir. Eğer eşik fonksiyonu bir giriş işaretine bağlı ise yaydığı $+\tau$ giriş toplamı pozitif, bağlı değilse eşik basamak fonksiyonu $[-\delta]$ olarak adlandırılır. Şekil 1.5.c, basamak eşik fonksiyonunu gösterir ve denklemini;

$$f(x) = \begin{cases} \tau & \text{eger } x > 0 \\ -\delta & \text{diger durumlar} \end{cases} \text{ şeklindedir.} \quad (1.3)$$



Şekil 1.5 Çok kullanılan eşik fonksiyonları

Çok kullanılan eşik fonksiyonu sigmoid fonksiyonudur. Şekil 1.5.d'de gösterilen sigmoid fonksiyonu; seviyeli, lineer olmayan çıkış veren, sınırlı, monoton artan fonksiyondur. Denklemi (Comrie, 1997);

$$f(x) = \frac{1}{1 + e^{-x}} \text{ biçimindedir.} \quad (1.4)$$

Her işlem elemanı kendisine verilen yerel veriye göre, kendisini ayarlayacak bütün YSA'nın enformasyon bölgesinin öğrenmesini sağlar. (Enformasyon bölgesi olasılık-yoğunluk fonksiyonu ile de tanımlanabilir). Enformasyon bölgesi birçok uygulamada, gerçek değer

"0" ile "1" arasında normalize edilmesi gerekir. Normalizasyon aynı anda bütün girişlere uygulanabilir.

1.4.4 Ağırlık uzayı

Bir çok YSA öğrenme işlemi, işlem elemanlarının ağırlığı değiştirilerek sağlanır. Böylece tanımlanan ağırlık değiştirilerek öğrenmede iyi bir model kullanıp, ağırlıkların bu modele göre değiştirilmesi esastır. Basit bir matematiksel model olarak her bir işlem elemanının "n" adet gerçek ağırlığı olduğu düşünülerek ve N adet işlem elemanı göz önüne alınırsa;


$$w = (w_{11}, w_{12}, \dots, w_{1n}, w_{21}, w_{22}, \dots, w_{2n}, \dots, w_{N2}, w_{N2}, \dots, w_{Nn})^T \quad (1.5)$$

$$w = (w_1^T, w_2^T, w_3^T, \dots, w_N^T) \quad (1.6)$$

Burada; $w_1, w_2, \dots, w_N$: işlem elemanlarının ağırlık vektörleridir.

$$w_1 = \begin{bmatrix} w_{11} \\ w_{12} \\ \vdots \\ w_{1n} \end{bmatrix}, \dots, w_N = \begin{bmatrix} w_{N1} \\ w_{N2} \\ \vdots \\ w_{Nn} \end{bmatrix} \quad (1.7)$$

YSA ağırlık vektörü N, n boyutlu orkit uzayında yayılır. YSA'nın enformasyon işleme performansı, ağırlık vektörünün belirli bir değeri ile bulunacaktır. Aşağıda Şekil 1.6' da ağırlıkların düzeltiminin vektörel çizimi verilmiştir.



Şekil 1.6 Üç boyutlu uzayda ağırlık vektörünün değişimi.

1.4.5 Yapay Sinir Ağlarında Eğitim

1.4.5.1 Eğitim algoritmaları

Eğitim algoritmaları yapay sinir ağlarının (YSA) ayrılmaz bir parçasıdır. Eğitim algoritması eldeki problemin özelliğine göre öğrenme kuralını YSA'na nasıl adapte edeceğimizi belirtir. Üç çeşit eğitim algoritması yaygın olarak kullanılmaktadır.

- 1- Öğreticili eğitim (supervised training).
- 2- Skor ile eğitim (graded training).
- 3- Kendini düzenleme ile eğitim (self-organization training)

Öğreticili eğitimde, elde doğru örnekler vardır. Yani $(x_1, x_2, \dots, x_n)$ şeklindeki giriş vektörünün, $(y_1, y_2, \dots, y_n)$ şeklindeki çıkış vektörü, tam ve doğru olarak bilinmektedir. Herbir $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ çifti için ağ doğru sonuçları verecek şekilde seçilen bir öğrenme kuralı ile beraber eğitilir.

Skor ile eğitimde giriş işaretlerine karşılık gelen çıkış işaretleri tam olarak bilinmemektedir. Çıkış işareti yerine skor verilir ve ağın değerlendirilmesi yapılır. Özellikle kontrol uygulamaları için idealdir. Çeşitli maliyet (cost) fonksiyonları kullanılır.

1.4.5.2 Öğrenme Kuralları


Bilginin kurallar şeklinde açıklandığı klasik uzman sistemlerin tersine, YSA gösterilen örnekten öğrenerek kendi kurallarını oluşturur. Öğrenme; giriş örneklerine ve ya (tercihen) bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren ve ya ayarlayan öğrenme kuralı ile gerçekleştirilir.

1.4.6 Çok katmanlı perceptron (Multi-layer perceptron)

Çok katmanlı perceptron giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı YSA sistemleridir. Gizli katman (hidden layer) olarak isimlendirilen bu katmanlarda, düğümleri aracısız giriş alamayan ve aracısız çıkış veremeyen üniteler vardır. Şekil 1.7 'de çok katmanlı perceptronun genel yapısı verilmiştir.

İki katmanlı ağlarda veriler giriş katmanı tarafından kabul edilirler. Ağ içinde yapılan işlemler sonucunda çıkış katmanında oluşan sonuç değer işlenen cevap ile karşılaştırılır. Bulunan cevap ile istenen cevap arasındaki herhangi bir fark varsa ağırlıklar bu farkı azaltacak şekilde

yeniden düzenlenir. Girişteki değer, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkışlar istenilen cevaplarla karşılaştırılarak sonuçta gerekirse hata işaret belirtilir. Hata işareti gizli birimlerden çıkış birimine olan ağırlıkları değiştirmekte kullanılır. Ama bunu yaparken giriş katmanından gizli katmana gelenin değiştirilip değiştirilemediğini düşünmek gerekir. Gizli birimlerden ne tür bir çıkış istendiği bilinmeyeceği için gizli birimlerin çıkışında hata işareti verilmesi kolay bir şey değildir. Bunun yerine her bir birimin, çıkış biriminin hatalarına olan etkisi bilinmelidir. Bu hatalı birim için gizli birime bağlı olan çıkış birimlerinin hata işaretlerinin ağırlıkları toplamı alınarak yapılır. Çok sayıda gizli katmana sahip sistemlerde her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde, giriş seviyesine varana kadar devam eder. Sonuçta sistem hatalar yapar, ama bu hatalardan bir şeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yöntem "hatanın geriye yayılması algoritması" (Error back-propagation algorithm) denir.



Şekil 1.7 Çok katmanlı perceptron

1.4.7 Hatanın geriye yayılması algoritması ve genelleştirilmiş delta kuralı

Hatanın geriye yayılması algoritması, karesi alınmış hata fonksiyonunu minimize eden kodlu bir algoritma olup, genelleştirilmiş delta kuralını eğitime için kullanılır. Şekil 1.8'de blok akış diyagramı gösterilen algoritma, ana hatlarıyla şöyledir:

Her bir j biriminin çıkışı o_j şu şekilde tanımlanır;

$$o_j = f(net_j) = f(x) \quad \text{ise} \quad net_j = \sum_i^j w_{ji} o_i + \theta_j \quad (1.8)$$


Burada: o_i ; i. biriminin çıkışı

w_{ji} ; i biriminden j birimine bağlantının ağırlığı,

θ_j ; j biriminin kutbu (bias)

net_j ; çıkışı j birimine akan her i biriminin toplamıdır.

$f(x)$; bir monoton artan ve türevi alınabilen fonksiyondur. Pratikte bir lojistik aktivasyon fonksiyonu olarak (1.5) numaralı eşitlikte verilen sigmoid fonksiyonu daha çok kullanılır.



Şekil 1.8 Hatanın geriye yayılması algoritmasının blok akış diyagramı

m-boyutlu giriş örüntüleri set edildiğinde $\{ i_p = (i_{p1}, i_{p2}, \dots, i_{pm}) ; p \in P \}$ 'dir. Benzer şekilde istenilen n- boyutlu çıkış örüntüleri $\{ t_p = (t_{p1}, t_{p2}, \dots, t_{pn}) ; p \in P \}$ belirtir. Burada; P:YSA uygulanan işaret şekilsel v.b. örüntüleri verir.

Bir örüntü için karesel hata (MSE) fonksiyonu E_p şu şekilde tanımlanır:

$$E_p = \frac{1}{2} \sum (t_{pj} - o_{pj})^2 \quad ; j \in \text{çıkış katmanı} \quad (1.9)$$

Amaç uygun w_{ji} ve q_j seçimiyle, $E = \sum_p E_p$ toplam hatayı yeterince küçük yapmaktır. Bu amacı gerçekleştirmek için, bir $p \in P$ örüntüsü ard arda ve rasgele biçimde seçilir. Daha sonra w_{ji} ve q_j şöyle değiştirilir;

i_{pi} : Giriş işaretinin i bileşeni;

t_{pj} : Çıkış vektörünün j bileşeni;

o_{pj} : YSA uygulanan P örüntü setinin ürettiği çıkış olmak üzere;

$$\delta_{pj} = (t_{pj} - o_{pj}) \quad (1.10)$$

$$\Delta_p w_{ji} = -\varepsilon \left(\frac{\partial E_p}{\partial w_{ji}} \right) \quad (1.11)$$

$$\Delta_p \theta_j = -\varepsilon \left(\frac{\partial E_p}{\partial \theta_j} \right) \quad (1.12)$$

Burada ε : öğrenme oranı adı verilen küçük bir pozitif sabit sayılır. Şayet gizli katman yok ise; (1.14) ve (1.15)'in sağ tarafı hesaplanır, o zaman;

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial w_{ji}} \quad (1.13)$$

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj}) = -\delta_{pj} \quad (1.14)$$


$$o_p = \sum_i w_{ji} i_{pi} \text{ ise;} \quad (1.15)$$

$$\frac{\partial o_{pj}}{\partial w_{ji}} = i_{pi} \quad (1.16)$$

elde edilir. Bu ifadeler (1.15)'de yerine konulursa;


$$-\frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} i_{pi} \quad (1.17)$$

olur. Hata fonksiyonu Şekil 1.9'da gösterildiği gibidir.



Şekil 1.9 Gizli katmanı olmayan ağına ait hata fonksiyonu

Gizli katman bulunan yapay sinir ağlarında ; hata düzeyi Şekil 1.46'da olduğunun aksine bir minimumdan daha fazladır. Şekil 1.10'daki gibi çeşitli minimumlar oluşur. Öğrenmede en küçük minimuma ulaşılmak istenir.



Şekil 1.10 Gizli katmana ait ağına ait hata fonksiyonu

Bu durumda j. düğümün lineer olmayan çıkışı;

$$o_{pj} = f_j(netp_j) \Rightarrow netp_j = \sum_i w_{ji} o_{pi} \quad (1.18)$$

şeklindedir. Bu durumda;

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial netp_j} \frac{\partial netp_j}{\partial w_{ji}} \Leftrightarrow \frac{\partial netp_j}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \sum_k w_{jk} o_{pk} = o_{pi} \quad (1.19)$$

$$\delta_{pj} = -\frac{\partial E_p}{\partial netp_j} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial netp_j} = -\frac{\partial E_p}{\partial o_{pj}} f'_j(netp_j) \quad (1.20)$$

İki durum söz konusudur:

1- o_{pj} YSA'nın çıkışı ise; (1.16) ifadesini (1.22)'de yerine koyarsak,

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(netp_j) \quad (1.21)$$

bulunur.

2- Eğer gizli katmanların çıkış işaretinden bahsediliyorsa yani eleman çıkış elemanı değilse;

$$\sum_k \frac{\partial E_p}{\partial netp_k} \frac{\partial netp_k}{\partial p_j} \quad \text{şeklinde ise,} \quad (1.22)$$

$$\sum_k \frac{\partial E_p}{\partial netp_k} \frac{\partial}{\partial o_{pj}} \sum_i w_{ki} o_{pi} = - \sum_k \delta_{pk} w_{kj} \quad (1.23)$$

olur. Bulunan sonuç (2.22)'de yerine konulursa;

$$\delta_{pj} = f'(net_{pj}) \sum_k \delta_{pk} w_{kj} \quad (1.24)$$

elde edilir. (1.25) denklemindeki (-) işareti, ağırlıkların ters yönde değiştiğini belirtir.

Bütün yapılan işlemler kısaca özetlenecek olursa;

1. Genelleştirilmiş Δ (delta) kuralı:

$$\Delta_p w_{ji} = \varepsilon \delta_{pj} i_{pi}$$

2. Çıkış katmanı elemanları için;

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(net_{pj})$$

3. Gizli katman elemanları için;

$$\delta_{pj} = f'_j(net_{pj}) \sum_k \delta_{pk} w_{kj}$$

olur. İşlem elemanında, transfer (eşik) fonksiyonu olarak "sigmoid" fonksiyonu kullanılırsa;

$$o_{pj} = \frac{1}{1 + e^{-\left(\sum_i w_{ji} o_{pi} + \theta_j\right)}} \quad (1.25)$$

$net_{pj} = \sum_i w_{ji} o_{pi} + \theta_j$ ifadesinin türevi alınır ve gerekli kısaltmalar yapılırsa;

$$\frac{\partial o_{pj}}{\partial net_{pj}} = o_{pj} (1 - o_{pj}) \quad (1.26)$$

bulunur. Bu (1.23) de yerine konulursa, çıkış elemanı için;

$$\delta_{pj} = (t_{pj} - o_{pj})o_{pj}(1 - o_{pj}) \quad (1.27)$$

elde edilir. (1.28); (1.26) da yerine konulursa, gizli katman elemanı için;

$$\delta_{pj} = o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (1.28)$$

bulunur. Yukarıda toplam içerisinde gösterilen k'nın, j çıkış birimine akan her birim k olduğuna dikkat edilmelidir. Hesaplamayı hızlandırmak için momentum terimleri (α) eklenirse, en genel halde çıkış ve gizli katman ifadeleri şu şekilde olur:

$$\Delta_p w_{ji}(t+1) = \varepsilon \delta_{pj} o_{pi} + \alpha \Delta_p w_{ji}(t) \quad (1.29)$$

$$\Delta_p \theta_j(t+1) = \varepsilon \delta_{pj} + \alpha \Delta_p \theta_j(t) \quad (1.30)$$

Burada; t: öğrenme devirlerinin sayısını gösterir. (α) küçük pozitif bir sayıdır.

Genelde hatanın geriye yayılması (BP) algoritmasında öğrenme yavaştır (Lippman, 1987). Bu, tipik olarak hata yüzeyinin karakteristiği sebebiyledir.

Hatanın geriye yayılması algoritmasını geliştirme amacıyla pek çok öneri ortaya atılmıştır. Bunların çoğu deneyime dayalı düzenlemeler olup, bazıları sistemin hızını artırmaya yönelik, bazıları yerel minimuma takılıp kalmayı önlemeye yönelik; bazıları da sistemin genelleme yeteneğini arttırmaya yöneliktir.

1.4.7.1 Bağlantı ağırlıklarının atanması

Hatanın geriye yayılması algoritması; algoritmanın gradyan azalma tabanlı olması sebebiyle, ilk şartlara çok duyarlıdır. Eğer ilk atanan ağırlık vektörü, hata yüzeyinin minimumuna çok yakın ve eğimli bir bölgede ise YSA'nın öğrenmesi çok çabuk olacaktır. Eğer ilk atanan ağırlık vektörü, hata yüzeyinin minimumuna uzak ve eğimsiz bir bölgede ise bu durumda sonuca ulaşmak çok zaman alabileceği gibi ulaşlamaya bilir de.

Uygulamada, ağırlıkların ilk atanmaları sıfıra yakın keyfi değerler şeklinde olur. Ağırlıkların büyük seçilmesi nöronların erken doymaya ulaşmalarına ve kendilerini öğrenme işlemine duyarsız hale getirmelerine sebep olur. Bu sakıncayı önlemek amacıyla; f_i , i. nörona bağlı girişlerin sayısı olmak üzere, ağırlıkların ilk değerlerini $1/\sqrt{f_i}$ seviyesinde atamak düşünülebilir.

1.4.7.2 Öğrenme katsayısı

Hatanın geriye yayılması algoritmasında çözüme ulaşma hızı ile öğrenme katsayısının değeri doğrudan alakalıdır. Eğer öğrenme katsayısı küçük seçilirse YSA' nın takip edeceği araştırma yolu gradyan yola çok yakın olacaktır. Bu durumda yerel minimuma ulaşmak için alınacak adım sayısı artacağından çözüme ulaşmak uzun zaman alacaktır. Diğer yandan, öğrenme katsayısı çok büyük seçilirse başlangıçta YSA çözüme kolay yaklaşacak fakat çözüm civarında osilasyon yaparak çözümü bulamayacaktır. Genelde minimumdan uzak bölgelerde büyük adım kat etmek ve minimum civarında küçük adımlar kullanmak en uygun çözümdür.

Öğrenme katsayısını otomatik olarak ayarlama amacıyla pek çok yöntem bulunmaktadır; t iterasyon sayısı olmak üzere $\nabla E(t)$ ve $\nabla E(t-1)$ gradyen vektörleri arasındaki açının kosinüsüne dayalı öğrenme katsayısı yanı sıra; $\frac{\partial E}{\partial w_i}$ kısmi türevinin işaret değiştirme sayısına bağlı olarak her ağırlık için öğrenme katsayısını artırılıp azaltılması da söz konusudur.

1.4.7.3 Momentum katsayısı

Hatanın geriye yayılması algoritmasının hızının arttırılmasında diğer bir metod ağırlıkları değiştirme formülüne momentum katsayısının dahil edilmesidir. Bununla $\frac{\partial E}{\partial w_i}$ kısmi türevinin işaret değiştirmesini takip etmek yerine; her Δw_i ağırlık değişmesine, değişimi azalma doğrultusunda hızlandıracak bir momentum verilmiş olur. Momentumun eklenmesiyle ağırlık değişme eşitliği şu şekilde olur:

$$\Delta w_i(t) = -\rho \frac{\partial E}{\partial w_i(t)} + \alpha \Delta w_i(t-1) \quad (1.31)$$

Burada; ρ , öğrenme katsayısı ve α momentum katsayısıdır. α normalde 0 ile 1 arasında değişen bir sayıdır. Momentum katsayısı :

$$\alpha(t) = \frac{\frac{\partial E}{\partial w_i(t)}}{\frac{\partial E}{\partial w_i(t-1)} - \frac{\partial E}{\partial w_i(t)}} \text{ şeklindedir.} \quad (1.32)$$

(1.34) eşitliğini; (1.33) de yerine koymakla elde edilen ağırlık değişim formülü; dinamik olarak değişen öğrenme katsayısı kullanımıyla “steepest gradient-descent-based” adaptasyon algoritmasına dönüşmüş olur. (1.33) eşitliğinde olduğu gibi hata gradyanı bilgisinin ard arda

iki zaman adımında kullanılması, Newton'un ikinci dereceden araştırma metoduna benzetilebilir.

Momentum katsayısını değiştirmede diğer bir metod “conjugate gradient method” dur. Bumetotla ağırlıkların değiştirilmesine ait eşitlik:

$$\Delta w(t) = -\rho \nabla E(t) + \frac{[\nabla E(t) - \nabla E(t-1)]^T \nabla E(t)}{\|\nabla E(t-1)\|^2} \Delta w(t-1) \text{ dir.} \quad (1.33)$$

1.4.8 Verilerin Normalizasyonu

Verilerin normalizasyonu girdi setindeki her bir parametrenin modelin tahmin işlemine eşit ölçüde katkıda bulunmasını sağlar. Eğer girdi parametreleri normalize edilmezse sayısal olarak düşük aralıklarda değişen bir parametrenin etkisi yine sayısal olarak daha geniş aralıklarda değişen bir başka girdi parametresine göre daha önemsiz kalacaktır. Mesela basıncın kendi değişim aralığında ortalama değere göre azami değişim yüzdesi ile sıcaklığın kendi değişim aralığında ortalama değere göre azami değişim yüzdesi büyük farklılıklar göstermektedir. Bu farklılıkları ortadan kaldırmak ve her bir parametrenin modele eşit katkıda bulunmasını sağlamak için veri setindeki bütün parametreler kendi değişim aralıklarında normalize edilir. Denklem (1.1) tipik bir normalizasyon denklemidir (Gardner et.al. 1999).

$$x_{\text{norm}} = 2 \left(\frac{(x - x_{\min})}{x_{\max} - x_{\min}} \right) - 1 \quad (1.34)$$

Burada

x_{norm} : x verisinin normalize edilmiş hali

$x_{\max}$: x verisinin maksimum değeri

$x_{\min}$: x verisinin minimum değeri

Model çıktısı veriler Denklem (1.2) ile orijinal durumlarına dönüştürülür.

$$x = \left(\frac{(x_{\text{norm}} + 1) \times (x_{\max} - x_{\min})}{2} \right) + x_{\min} \quad (1.35)$$

1.5 Neural Connection

Bu çalışmada Neural Connection 2.1 ticari yapay sinir ağları programı kullanılmıştır. Neural

Connection problemleri çözmeye sinir ağı ve diğer teknikleri kullanan, kompleks uygulamalar kullanılmasına olanak sağlayan bir yazılım sistemidir.

1.6 Hava Kirliliği Modellemesinde Yapay Sinir Ağları Uygulamaları ile İlgili Önceki Çalışmalar

Yapay sinir ağı (YSA) modellerinin hava kirliliğine, veya daha genel bir ifadeyle atmosfer ortamına, uygulanması 1990'lı yılların öncesine gitmemektedir. YSA modelleri ile başarılı sonuçlar elde edilebilmesi sayesinde hava kirliliği konusunda giderek daha yaygın ve çeşitli kullanım alanları bulmuştur. Aşağıda sıralanan çalışmalar yapay sinir ağlarının hava kirliliği modellemesine uygulanması konusunda literatürden örnek olarak alınmış çalışmalardır. Bunlar dışında literatürde daha birçok benzer çalışmaya ulaşmak mümkündür.

Reich ve diğerleri (1999) emisyon kaynaklarını belirlemek için YSA kullanmışlardır. Saatlik meteorolojik veriler ve ölçülen konsantrasyonlar kullanılarak bilinmeyen emisyonlar çıktı olarak alınmıştır. Ayrıca YSA ile 24 saatlik SO₂ tahmini de başarı ile yapılmıştır.

Gardner ve diğerleri (1998) Londra için yaptıkları çalışmada YSA ile NO_x ve NO₂ modellemesinde Multi layer perceptron (MLP) ağlarının regresyon tabanlı modellere göre daha iyi sonuçlar ortaya koyduğunu belirtmişlerdir. Oluşturdukları değişik MLP setlerinde 0.47 – 0.92 aralığında korelasyon katsayıları bulmuşlardır.

Mok ve diğerleri (1998) yaptıkları çalışmada Çin Macau Adasında 3 katmanlı ileri beslemeli yapay sinir ağı kullanarak SO₂ tahminleri yapmışlardır. Sadece bir ay öncesinin verilerini kullanarak yapılan tahminle iki veri setinde 14,45% ve 13,71% hata oranı elde edilebilmiştir.

Benvenuto ve diğerleri (2000) İtalya'da yaptıkları çalışmada YSA ile veri kalitesi kontrolü için zaman serilerini ve eksik verilerin yapılandırılmasını incelemişlerdir. YSA kısa ve orta zamanlı tahminler, günlük maksimum sıcaklığın interpolasyonu ve ekstrapolasyonu ve zaman dağılımının değiştirilmesi üzerine uygulanmış ve başarılı sonuçlar elde edilmiştir. Sonuç ANN'nin klasik modellere göre daha gelişmiş ve zaman serilerinin onarımı için uygun olduğunu göstermiştir.

Jiang ve diğerleri (2000) tarafından yapılan çalışmada Şangay'da hava kalitesi indeksinin YSA modeli kullanılarak geliştirilmesi amaçlanmıştır. MLP ağına girdi olarak maksimum ve ortalama yüzey sıcaklığı, yüzey basıncı, yüzey nemi, bulutluluk ve günlük yağış kullanılmıştır. Sonuç olarak korelasyon katsayıları PM₁₀, SO₂; ve NO₂ için sırasıyla 0.6056, 0.6993 ve 0.63 bulunmuştur.

Chelani ve diğerleri (2000) Delhi için yaptıkları SO₂ tahmin çalışmasında YSA modeli ile rüzgar hızı, bağıl nem, sıcaklık rüzgar yönü indeksi veri seti ile sanayi, ticari, ve evsel kaynaklı SO₂ konsantrasyonu model tahminlerinde korelasyon katsayılarını 0.71, 0.79 ve 0.91 olarak bulmuşlardır.

Kolehmainen ve diğerleri (2000) partiküler kirleticiler üzerine yaptıkları çalışmada veri kümeleri oluşturmuşlar, ve verileri herbiri bir kirlilik olayı içeren birçok MLP modelinde uygulamışlardır. Böylece MLP modellerinin kombinasyonu ile kirleticinin gerçek durumunu ortaya koymuşlardır. Model sonuçları incelendiğinde gaz kirleticilerin partiküler kirleticilere oranla daha iyi sonuçlar vermiştir. Perez ve diğerleri (2001) Şili’de yaptıkları saatlik PM_{2.5} tahmininde gizli katman olmadan (lineer) daha başarılı sonuçlar elde etmişler. 6 saatlik tahminlerde hata oranının uzun dönemli tahminlere göre daha iyi olduğunu belirtmişlerdir.

Viotti ve diğerleri (2002) yaptıkları çalışmada İtalya’da SO₂, NO_x, PM₁₀, Benzen, Ozon için yatay rüzgar hızı, nem, basınç, sıcaklık, toplam güneş ışıması, yağmur ve trafik verileri ile YSA kullanarak başarılı sonuçlar elde etmişlerdir.

Lu ve diğerleri (2003) Hong Kong’da, NO_x, NO₂ kirleticileri için birincil bileşen analiz tekniği ve radial basis fonksiyonu birleşiminden oluşan geliştirilmiş bir YSA kullanmışlar ve elde edilen sonuçlar doğrultusunda geliştirilmiş modellerin standart sinir ağı modellerinin yerine kullanılabileceğini belirtmişlerdir.

Nunnari ve diğerleri (2003) İngiltere’de günlük ortalama, günlük maksimum ve saatlik ortalama olmak üzere 3 değişik SO₂ veri seti ile birçok YSA modelini karşılaştırmışlardır.

Marra ve diğerleri (2003) Avrupa’dan Sicilya Adasına araba ve kamyonlar ile tek bağlantı olan Messina Boğazında CO ve hidrokarbonların oluşturduğu 1 – 10 saat arası kirlilik tahmininde L. Cao tarafından geliştirilen bir metod ile ileri beslemeli yapay sinir ağıları modeli kullanılmış ve 90% ye varan doğru tahminler yapılabilmektedir.

Kukkonen ve diğerleri (2003) Helsinki’de saatlik NO_x, NO₂ ve PM₁₀ konsantrasyon verilerini göz önüne alarak ölçüm yapılan üç istasyon ile hava kalitesi yapmak için çalışmışlardır. Çalışmada ölçülen ve ya ön işlemden geçirilmiş meteoroloji verileri kullanılmıştır. Deterministik ve istatistiksel (MLP ile yapay sinir ağıları) model karşılaştırılması yapılmış deterministik modelin önceki konsantrasyon verilerinden yeteri kadar yararlanamadığı belirtilmiştir.

Hashemi (2004) Güney Kaliforniya’da araç emisyonları üzerine yaptığı çalışmada 34 nolu mazot ile çalışan 6 araç incelenmiş ve araç özellikleri modelde girdi verileri olarak kullanılmıştır. YSA ile CO₂ için 0.97, NO_x için 0.89, CO için 0.70 ve HC için 0.48 korelasyon katsayıları elde etmiştir.

Jensen ve diğerleri (2004) yanma gazlarından kaynaklanan civa konsantrasyonlarının tahmini için yaptıkları çalışmada civa türü, kömür karakteristiği ve kazan türü arasındaki non-lineer bağlantıyı modelleyebilmesi nedeniyle MLP kullanmışlardır. Çalışmada korelasyon katsayısını 0,9750 elde etmişler ve non-lineer ve kompleks yapılarda standart regresyon analizlerinin başarılı olamadığını, yapay sinir ağları ile iyi sonuçlar elde edilebildiğini göstermişlerdir.

Chelani ve diğerleri (2005) Hindistan’da düzensiz zaman serilerini belirlemek için yapay sinir ağlarını kullanmışlardır. NO₂ konsantrasyonu, meteorolojik faktörler modelde kullanılmış ve düzensiz zaman serileri tahmini yapılmıştır. Model zaman serisini gerçeğe yakın olarak tahmin edebilmiştir.

Eğrioğlu ve diğerleri (2005) yaptıkları çalışmada, melez bir yaklaşımla YSA ile Ankara ili için hava kirliliği tahminleri yapmışlar ve sonuçları diğer model tahminleri ile karşılaştırmışlardır. Ankara hava kirliliği verisi için melez yaklaşımın uygulandığı iki modelin, Box-Jenkins yaklaşımının uygulandığı modele göre daha iyi öngörü sonuçları verdiği görülmüştür. Melez yaklaşımın uygulandığı modellerin, sadece yapay sinir ağı yönteminin kullanıldığı modelden de daha iyi öngörü sonuçları verdiği görülmektedir. Ancak en iyi öngörü sonucu girdi birimlerinden çıktı birimine doğrudan bağlantının bulunmadığı yapay sinir ağı modeli ile elde edilmiştir.

Grivas ve diğerleri (2006) Atina’da sıcaklık, bağıl nem, rüzgar hızı ve rüzgar yönü, basınç, yağmur miktarı, güneş ışıması verilerini kullanarak YSA modeli, çok katmanlı perceptron (MLP) ağı ile PM₁₀ konsantrasyonu tahmininde başarılı sonuçlar elde etmişlerdir.

Nagendra ve diğerleri (2006) YSA kullanarak Delhi’de egzost emisyonlarından kaynaklanan NO₂ konsantrasyonlarının tahmini üzerine çalışma yapmışlardır. Modelde 10 meteorolojik veri ve 6 trafik karakteristik verisi kullanılmıştır. Modelde eğitim amaçlı olarak 2 senelik veri seti kullanılmıştır.

Wesolowski ve diğerleri (2006) Polonya’da ısınma (kış) sezonunda ve yaz sezonunda oluşabilecek bir modelin yapay sinir ağları ile belirlenmesini araştırmışlardır. Bu kapsamda 13 kirlletici parametre MLP ağında girdi veri seti olarak kullanılmıştır.

Pfeiffer (2006) Kıbrıs'da yaptığı çalışmada NO_2 emisyonları tahmininde ihtiyacı karşılayabilecek üç farklı metod üzerinde çalışmışlardır. Bu metodlardan ilki olan regression modelinde non-lineer korelasyonlarda istenen verim sağlanamamıştır. İkinci model olan interpolasyon yöntemi ile gerçek dağılım sağlanamamıştır. Üçüncü yöntem olan YSA ile en iyi sonuçlar elde edilmiştir. Birçok denemeden sonra YSA ile Pearson korelasyon katsayısı 0,75 olarak bulunmuştur.

Yildirim ve diğerleri (2006) Zonguldak İli için yaptıkları çalışmada SO_2 ve toplam askıda partiküler madde değişimin incelenmiştir. Neuro-Fuzzy tabanlı yapay sinir ağları modellemesi “MATLAB Fuzzy Toolbox ile yapılmıştır. Modelde girdi olarak bağıl nem, sıcaklık, basınç, rüzgar hızı ve yağış verileri kullanılmıştır. Bu parametrelere ek olarak bir gün öncesinin SO_2 ve toplam askıda partiküler madde konsantrasyonları kullanılmıştır. Oluşturulan model ler %90'a kadar başarılı tahminler yapabilmektedir.

Videnova ve diğerleri (2006) NO_2 , CO, H_2S kirleticileri için yaptıkları tahmin çalışmasında girdi olarak rüzgar hızı, rüzgar yönü, bağıl nem ve sıcaklık parametrelerini kullanmışlar ve YSA modeli kullanarak %3 hata oranı ile başarılı sonuçlar elde etmişlerdir.

2 MATERYAL VE METODLAR

2.1 Çalışma Bölgesi Ve Veri Tabanı

2.1.1 Çalışma Bölgesi

İstanbul, yaklaşık 5712 km² yüzölçümüne ve 2000 yılı nüfus sayımına göre 10018735 (Devlet İstatistik Enstitüsü, 2000) nüfusa sahip bir büyükşehirdir. İstanbul genelde birçok vadi ile birbirinden ayrılmış tepelerden oluşmaktadır. Bugün yerleşim son derece büyük bir alana yayılmıştır. Çalışma bölgesi Şekil 2.1’de görülmektedir.



Şekil 2.1 İstanbul ili şehir haritası

2.1.1.1 Çalışma Bölgesinin Topografik Durumu

İstanbul'un topografyası 4 ana bölümden oluşmaktadır:

Batı Bölgesi: Kumburgaz'dan Bakırköy'e kadar uzanan 35 km uzunluğundaki Batı Bölgesinde, Büyükçekmece, Küçükçekmece ve Marmara Denizi'ne ulaşan başlıca üç vadi bulunmaktadır. Bu üç vadi sularını Büyükçekmece'ye, Küçükçekmece'ye ve doğrudan

Marmara Denizi'ne vermektedir. Vadiler Marmara Denizi'nden kuzeye doğru uzanan alçak tepelerle sınırlanmıştır. Topografik bakımdan Kuzey Marmara sahilleri karakteristiğindedir. Bu bölgede arazi kotları 0-200 m arasında değişmektedir.

Merkezi Bölge: Bakırköy'den Boğaz'daki Ortaköy'e kadar uzanan ve Haliç'i de içine alan Merkezi Bölge, kuzey-batı yönünde uzanan vadilerden oluşmakta, arazi yüksekliği deniz seviyesinden 120 m'ye kadar değişmektedir. Arazi meyili, Boğaz sahillerinde Marmara sahillerine nazaran daha diktir. Bu bölgede üç havza tariflemek mümkündür. Bunlar sularını Marmara Denizi'ne, Haliç'e ve Boğaz'a veren alanlardır. Sularını Marmara'ya veren bölgede Çırpıcı Deresi, Haliç'e veren bölgede ise Alibeyköy ve Kağıthane Dereleri yer almaktadır. Bu bölgede, hava kirliliği açısından en kritik kesim, Eminönü'nden Şişli'ye kadar uzanan ve Eyüp, Alibeyköy, Gaziosmanpaşa, Bayrampaşa, Kağıthane, ve Kasımpaşa'yı da içine alan Haliç koridorudur.

Boğaziçi Bölgesi: Asya ve Avrupa kıtalarını ayıran ve toplam uzunluğu 27 km olan İstanbul Boğazı'nı içine alan Boğaziçi Bölgesi, boğaza dik olarak gelen vadilerden oluşmaktadır. Boğaz'ın Avrupa kıyısı, Ortaköy'e kadar düzgün olarak giden yükseklikleri yaklaşık 130 m'yi bulan tepelerle 5 km genişliğindeki şerit halinde Haliç drenaj sahasından ayrılır. Ortaköy'den Rumeli Kavağı'na kadar olan kısımda bulunan tepelerin rakımları 150 m'ye kadar çıkar. Boğaz'ın Anadolu tarafında ise, Avrupa yakasına göre daha engebeli ve daha yüksek tepelerden oluşan bir topografya mevcuttur. Bu kesimde, 200 m'ye kadar çıkan Kısıklı ve 250 m'ye kadar çıkan Büyük ve Küçük Çamlıca tepesi, en yüksek rakımları teşkil etmektedir. Anadolu Kavağı'na kadar devam eden bölgede 16 adet küçük vadi vardır.

Pendik-Kadıköy Bölgesi: İstanbul'un topografik olarak dördüncü önemli bölümünü Kadıköy ile Pendik arasında uzanan, kuzeyde Kayışdağı ve Yakacık tepeleri ile sınırlanan ve deniz seviyesinden yaklaşık 50 m yüksekliğe kadar değişen araziler teşkil etmektedir. Bölge genel olarak fazla yüksek olmayan tepe ve platolardan oluşmuştur. Topografik yönden bölgeyi iki bölüme ayırabiliriz. Bunlar sularını Marmara Denizi'ne ve Boğaz'a veren sahalardır. Bölge içinde zaman zaman kuruyan derelerin de bulunduğu dört vadi mevcuttur. Bunlardan Kurbağalıdere, Bostancı Deresi ve İbrahimağa Deresi Marmara Denizi'ne, Beylerbeyi Deresi ise Boğaza dökülmektedir. İstanbul ili topografik haritası Şekil 2.2'de verilmiştir.



Şekil 2.2 İstanbul ili topografik haritası

2.1.2 Veri Tabanı

İstanbul'un hava kirliliğinin yapay sinir ağları ile modellenmesinde, model hedef girdisi olarak günlük ortalama SO_2 , CO , PM_{10} ve NO_x parametreleri kullanılmıştır. Bu parametrelerin tahmininde aynı günün meteorolojik parametreleri model için girdi parametreleri olarak kullanılmıştır. Modelde kullanılan girdi parametreleri, temin edildikleri merkezler, ölçüm birimleri ve hava kirliliğine olan muhtemel etkileri aşağıda belirtilmiştir.

2.1.2.1 Hava kirliliği verileri

Bu çalışmada kullanılan kirlilik verileri İstanbul Büyükşehir Belediyesi'nden temin edilmiştir. SO_2 , NO_x , PM_{10} , ve CO konsantrasyonları İstanbul'da Büyükşehir Belediyesi'nin ölçüm istasyonlarında ölçülmüş ve $\mu g/m^3$ birimi ile ifade edilmiştir. Bu ölçüm istasyonların yerleri Şekil 2.3'de gösterilmektedir.

Bu istasyonlardan toplanan 2003 – 2005 yılları arasındaki kirlilik verilerinin aritmetik ortalamaları alınarak model için hedef parametreleri oluşturulmuştur.



Şekil 2.3 Hava kirliliği ölçüm noktaları (1.Sarıyer, 2.Beşiktaş, 3.Esenler, 4.Yeni Bosna, 5.Alibeyköy, 6.Sarıyer, 7.Üsküdar, 8.Kadıköy, 9.Ümraniye, 10.Kartal)


2.1.3 Meteoroloji verileri

Meteorolojik veriler Florya’da hava alanları için veri toplayan ölçüm istasyonundan alınmıştır. Veriler günlük ortalama değerler olarak ifade edilmiştir.

Bu çalışmada kullanılan meteorolojik veriler ve prensip olarak hava kirliliğine etkileri aşağıdaki bölümlerde daha detaylı olarak incelenmiştir.

Sıcaklık


Günlük ortalama kuru termometre sıcaklığı olup °C olarak ifade edilmektedir. Ölçülen bir parametredir. Sıcaklıkla hava kirliliği teorik olarak ters orantılıdır. Sıcaklık enversiyonun temeli olduğu için kirlilik bakımından önemli parametredir. Ayrıca yaz aylarında sıcak geçen günlerde ısınma amaçlı yakıt tüketimi az olacağından atmosfere bırakılan kirletici miktarı da az olacaktır, dolayısıyla hava kirliliği de soğuk geçen günlere oranla daha az olacaktır. Şekil 2.4’de sıcaklığın 2003 – 2005 yılları arasındaki değişimi verilmiştir.



Şekil 2.4 Günlük ortalama sıcaklığın 2003-2005 yılları arasında değişimi

Deniz Seviyesi Basıncı


Meteoroloji istasyonunda ölçülen ve milibar olarak ifade edilen günlük ortalama basınçtır. Alçak basınç sistemi kirleticilerin dağıtılması açısından istenen bir durumdur. Yüksek basınç sistemi hava kirliliği açısından olumsuz bir durumdur. Şekil 2.5’de deniz seviyesi basıncının 2003 – 2005 yılları arasındaki değişimi verilmiştir.



Şekil 2.5 Günlük ortalama deniz seviyesi basıncının 2003-2005 yılları arasında değişimi

Bulutluluk

Bu parametre aletsel olmayıp gözle gözlemlenen bir parametredir. Birimi yoktur. Tamamen kapalı, bulutla kaplı hava için 5 ve tamamen açık bulutsuz hava için 0 birim olmak üzere kısmen bulutlu hava durumları bulut miktarına göre 0 – 5 arası bir sayı ile ifade edilmektedir. Bulutluluk bir açıdan güneşlenmeyi etkileyen durum olduğu için bulut miktarı arttıkça hava sıcaklığında düşme görülmektedir. Diğer taraftan bulutların türü ve yükseklikleri de çok önemli olduğundan bulutlanmanın hava kirliliğine etkisi daha karmaşık bir hal almaktadır. Bulutluluk parametresinin fotokimyasal reaksiyonlara dolaylı etkisi nedeniyle NO_x kirleticisini için baskın bir faktör olacağı tahmin edilmektedir. Şekil 2.6’de bulutluluk seviyesinin 2003 – 2005 yılları arasındaki değişimi verilmiştir.




Şekil 2.6 Günlük gözlemlenen bulutluluk seviyesinin 2003-2005 yılları arasında değişimi

Bağıl nem

Havadaki nem miktarının (su buharının) % olarak ifadesidir. Bağıl nem, 1m^3 havada gram olarak ölçülen nem miktarının aynı sıcaklıkta 1m^3 havanın taşıyabileceği azami nem miktarına (mutlak nemlilik) oranıdır. Havadaki su buharı miktarının artması atmosferde bulunan kirletici parametrelerin bu su buharı içinde o oranda çözünüp gaz ortamından sıvı ortama geçmesine sebep olması ve dolayısıyla hava kirliliğini azaltmasının yanı sıra bulutlar, sis ve yağışlar hep havadaki nem miktarına bağlı olarak oluştuğu için bağıl nemin atmosfer olaylarına etkisi oldukça kompleks olup hava kirliliğine etkisi de o derece karmaşıktır. Şekil


2.7’de nem oranının 2003 – 2005 yılları arasındaki değişimi verilmiştir.



Şekil 2.7 Günlük ortalama nem oranının 2003-2005 yılları arasında değişimi

Çiğ Noktası


Çiğ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeridir. Yaz aylarında çiğ noktası değerinde artış, kış aylarında da sıcaklık değişimi ile benzer bir şekilde azalma görülmektedir. Şekil 2.8’de çiğ noktasının 2003 – 2005 yılları arasındaki değişimi verilmiştir.



Şekil 2.8 Günlük ortalama çiğ noktasının 2003-2005 yılları arasında değişimi


Rüzgar yönü

Rüzgar yönü İstanbul genelinde çok sık olarak değişmektedir. Hakim rüzgar yönü gün içerisinde en çok tekrarlanan rüzgar yönü alınarak hesaplanmıştır. Değişen rüzgar yönleri Şekil 2.9’da belirtildiği gibi girdi setine hazırlanmıştır.



Şekil 2.9 Hakim rüzgar yönlerinin YSA modeli için girdi sayısal değerlerine dönüştürülmesi


Rüzgar yönünün kirletici konsantrasyonlarına etkisi geldiği yöne bağlı olarak değişiklik gösterebilir. Rüzgar, deniz gibi temiz hava kütlelerinin bulunduğu bir yönden esiyorsa kirli bölgedeki kirleticileri seyreltebilir. Şekil 2.10’da rüzgar yönünün 2003 – 2005 yılları arasındaki değişimi verilmiştir.



Şekil 2.10 Günlük rüzgar yönünün 2003 – 2005 yılları arasında değişimi

Rüzgar hızı

Rüzgar atmosferdeki hareketliliğin baskın bir parametresi olup kirletici gazların yatay taşınımlarını ve dolayısıyla seyrelmelerini sağlamaktadır. 2003 – 2005 yılları arasındaki ortalama rüzgar hızları Şekil 2.11’de gösterilmiştir.



Şekil 2.11 günlük ortalama rüzgar hızının 2003 – 2005 yılları arasında değişimi

2.1.4 Verilerin Analizi Ve Model İçin Girdi Seti Hazırlanması

İstanbul’da doğalgaz kullanımı 1995 yılından itibaren yaygınlaşmıştır. Bu nedenle hava kirliliğinde belirgin bir azalma gözlemlenmiştir. (Ertürk ve diğerleri,1995) Bu nedenle kullanılan 2003 – 2005 yılları arasındaki kirlilik verilerinde yönetmeliklerde belirtilen sınır değerleri aşacak yüksek değerler bulunmamaktadır.

2003 – 2005 yılları arasındaki meteoroloji ve kirlilik verileri zaman sıralı seri haline getirilerek düzenlenip her bir parametrenin istatistiksel değişim aralığı incelemesi yapılmış ve ölçüm hatalarının ve mantıksal sınır harici değerlerin olup olmadığı kontrol edilmiştir. 2003 - 2005 yılı içindeki model parametreleri ve bu parametrelerin maksimum, minimum ve ortalama değerleri Çizelge 2.1’de verilmiştir. Konsantrasyonu belirli olmayan eksik veriler modelde girdi setinden çıkartılarak veri seti oluşturulmuştur. Gruplandırma model performansı bakımından önemli bir etkidir. İki çeşit veri gruplandırılması yapılabilir; Değer sıralı veri seti gruplandırması ve zaman sıralı veri seti gruplandırması.

Bu çalışmada zaman sıralı veri gruplandırılması kullanıldı. Zaman sıralı veri gruplandırması yönteminde veriler zaman serisi şeklinde sıralanıp numaralandırıldı. Yedi meteorolojik parametre model için girdi verileri olup çıktı olarak PM₁₀, NO_x, CO ve SO₂ konsantrasyonu tahmin edilmiştir.

Çizelge 2.1 Modelde kullanılan parametreler ve bunların 2003 – 2005 yılları arasındaki ortalama değerleri

Parametre	Birim	Ortalama
Basınç (deniz seviyesi)	mbar	1016,22
Sıcaklık	°C	14,8
Çiğ Noktası	°C	8,98
Bulutluluk	-	1
Bağıl Nem	%	69,70
Rüzgar Yönü		0,25
Ort. Rüzgar Hızı	m/sn	4,21
SO ₂	µgr/m ³	15,51
NO _x	µgr/m ³	59,64
PM ₁₀	µgr/m ³	50,92
CO	µgr/m ³	826,39


2.1.5 Meteorolojik Faktörlerin Kirletici Konsantrasyonları İle Değişimleri

Modelde kullanılan meteorolojik faktörlerin ölçülen kirlilik konsantrasyonları ile olan değişimleri aşağıdaki şekillerde incelenmiştir. Ağırlıklı olarak yanma kaynaklı oluşan SO_2 , CO ve PM_{10} benzer eğilimler göstermektedir. Fotokimyasal reaksiyonlar etkisi ile değişen NO_x diğer kirlilik parametrelerinden farklı bir eğilim göstermektedir.

2.1.5.1 SO_2 – Meteorolojik Parametrelerin Değişimleri

SO_2 genellikle şehirselle kaynaklı bir kirleticidir ve çoğunlukla yanma reaksiyonları sonucunda oluşur. Bu nedenle diğer birçok büyükşehirde olduğu gibi İstanbul’da da kış aylarında daha yoğun olarak gözlemlenmektedir. SO_2 ’den kaynaklanan kirlilik türleri sülfirik asit , sülfat aerosolleri ve yer seviyesinde SO_2 ya da sülfat şeklinde birikim olarak tanımlanabilir. (Boubel ve diğerleri, 1994; Khoder, 2002). Bridgman ve diğerleri (2002) yaptığı çalışmada incelediği altı meteoroloji parametresi içinde SO_2 konsantrasyonunun soğuk havalarda, düşük rüzgar hızında ve yüksek bağıl nem oranında arttığını gözlemlemiştir. Turalıoğlu ve diğerleri(2005) çalışmalarında SO_2 konsantrasyonlarının kış aylarında, yüksek basınç altında ve düşük rüzgar hızında maksimum olduğunu belirtmişlerdir.


Şekil 2.12’de İstanbul ili için bağıl nem oranının ve SO_2 konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi verilmiştir. Kirletici konsantrasyonu nem oranı ile doğru orantılı olarak artış göstermektedir.



Şekil 2.12 Nem oranının ve SO_2 konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi


Şekil 2.13’de sıcaklık ve SO_2 konsantrasyonlarının değişimi verilmektedir. SO_2 ve sıcaklık

ters orantılı olarak değişmektedir. Sıcaklığın düşük olduğu kış günlerinde ısınma amaçlı yakıt emisyonlarındaki artış nedeniyle kirletici konsantrasyonlarında artış olmaktadır.



Şekil 2.13 Sıcaklığın ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi


Şekil 2.14’de İstanbul genelindeki rüzgar yönünün değişimi verilmektedir. Rüzgar yönü büyük salınımlar göstermektedir. Bu nedenle kirletici ile arasında bir ilişki kurmak oldukça zordur.



Şekil 2.14 Rüzgar yönünün ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi


Şekil 2.15’de verilen rüzgar hızı – SO₂ grafiğinin genel değişimi incelendiğinde İstanbul genelinde rüzgar hızı günler bazında büyük salınımlar göstermektedir. Bu nedenle kirletici

konsantrasyonu ve rüzgar hızı arasındaki ilişkiyi doğru bir şekilde yorumlamak mümkün değildir.



Şekil 2.15 Rüzgar hızının ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi


Bulutluluk seviyesi sıcaklığın düşük olduğu kış günlerinde artmaktadır. Bu nedenle ısınma kaynaklı emisyonlarda da artış beklenmektedir. Şekil 2.16’da bulutluluk seviyesi ve SO₂ konsantrasyonu arasındaki ilişki verilmektedir.



Şekil 2.16 Bulutluluk seviyesinin ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi


Şekil 2.17’de görüldüğü gibi deniz seviyesi basıncı kompleks bir şekilde değişmektedir. Bu

grafik doğrultusunda İstanbul ili için basınç ile kirletici konsantrasyonu arasında bir ilişki belirlemek zordur.



Şekil 2.17 Deniz seviyesi basıncının ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.18’de SO₂ konsantrasyonu ve çığ noktasındaki değişimler verilmiştir. Çığ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeri olduğundan sıcaklık faktörü ile benzer şekilde kirletici ile ters orantılı olarak değişmektedir.




Şekil 2.18 Çığ noktasının ve SO₂ konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

2.1.5.2 PM – Meteorolojik Parametrelerin Değişimleri


Asılı parçacıklar atmosferde standart şartlarda katı ya da sıvı olarak bulunan çaplar $0.1\mu\text{m}$ ile $100\mu\text{m}$ arasında değişen maddelerdir. Asılı parçacıkların ana kaynaklarını esas olarak çimento fabrikaları, metal endüstrisi ile araçlar oluşturur. Asılı parçacıkların en büyük doğal kaynağı volkanlardır. Okyanustan yayılan parçacıklar ise çok küçük zerrecikler halinde karaların iç kısımlarına kadar girerler. Buharlaşıma sonucunda da sodyum klorür şeklinde denizsel tuz parçacıklarını karalara taşırlar. Deniz tuzları, yağış oluşumu için gerekli olan yoğunlaşma çekirdeklerinin de kaynağıdır. (İncecik, 1994)

Şekil 2.19’da sıcaklık ve PM konsantrasyonlarının 2003 – 2005 yılları arasında değişimi verilmektedir. PM_{10} da SO_2 gibi yanma kaynaklı bir kirletici olduğundan kış aylarında yüksek değerlerde yaz aylarında ise düşük değerlerde bulunmaktadır.




Şekil 2.19 Sıcaklığın ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Rüzgar hızının yüksek salınımı şekil 2.20’de görülmektedir. Rüzgar hızının yüksek olması kirletici yoğunluğunu dağıtarak konsantrasyonunda azalmaya neden olacağından istenen bir durumdur. Şekil 2.20 incelendiğinde PM_{10} kirletici konsantrasyonunun rüzgar hızındaki eğilimden kaynaklanan değişimi anlaşılamamaktadır.




Şekil 2.20 Rüzgar hızının ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.21’de İstanbul genelindeki rüzgar yönünün değişimi verilmektedir. Rüzgar yönü büyük salımlar göstermektedir. Bu nedenle kirlenici ile arasında bir ilişki kurmak oldukça zordur.




Şekil 2.21 Rüzgar yönünün ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.22 incelendiğinde grafikteki genel eğilim göz önüne alındığında nem oranı kirlilik konsantrasyonu ile doğru orantılı olarak değiştiği görülmektedir.




Şekil 2.22 Nem oranının ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Bulutluluk seviyesi sıcaklığın düşük olduğu yakıt tüketiminin yüksek olduğu kış günlerinde artmaktadır. Şekil 2.23’de bulutluluk seviyesi ve SO_2 konsantrasyonu arasındaki ilişki verilmektedir.




Şekil 2.23 Bulutluluk seviyesinin ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.24’de görüldüğü gibi deniz seviyesi basıncı değeri yüksek salınımlar göstermektedir. Bu nedenle deniz seviyesi basıncının kirletici konsantrasyonu ile net bir ilişkisi kurulamamaktadır.



Şekil 2.24 Deniz seviyesi basıncının ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Çiğ noktası sıcaklık ile benzer bir eğimle PM konsantrasyonu ile ters orantılı olarak değişmektedir. Şekil 2.25’de çiğ noktasının PM_{10} ile olan ilişkisi verilmektedir.




Şekil 2.25 Çiğ noktasının ve PM_{10} konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

2.1.5.3 NO_x – Meteorolojik Parametrelerin Değişimleri

Azot oksitlerin ana kaynağı motorlu araçlar ve enerji üretim istasyonlarıdır. Doğal kaynaklarından birisi topraktaki organik çürümelerdir. NO_x ’un doğal kaynakları arasında orman yangınları, yıldırım ve topraktaki mikrobiyolojik işlemler vardır. NO_x ’in çoğu NO


olarak yanma sonucu ortaya çıkar. Hava kirliliği bakımından önemli olan azot oksitler ise NO (azot monoksit) ile NO₂ (azot dioksit) dir. Azot monoksit (NO) renksiz ve kokusuz, oldukça zararsız bir gazdır. Azot dioksit oksitlendiği zaman sarı kahverengi keskin kokulu ve zararlı bir gaz haline gelmektedir. NO ve NO₂ şeklindeki atmosferik konsantrasyonların birleşik değeri NO_x ile temsil edilmektedir. Atmosferde kalıcılık süresi yaklaşık 1 gündür. Malzemeler üzerinde korozif, insan sağlığı için de toksik özellik taşır.

Şekil 2.26 incelendiğinde NO_x konsantrasyonunun incelenen diğer kirleticilere göre daha küçük salınımlar yaptığı görülmektedir. Yani bu kirletici için mevsimsel salınımların yanında mevsim içi salınımlarda mevcuttur. NO_x konsantrasyonu sıcaklıkla ters orantılı olarak değişmektedir. Bu doğrultuda fotokimyasal reaksiyonların İstanbul ili için NO_x konsantrasyonu değişiminde belirgin bir etkisi görülmemektedir.




Şekil 2.26 Sıcaklığın ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Rüzgar hızı ile NO_x konsantrasyonu arasındaki ilişkiyi Şekil 2.27’de verilen grafik incelendiğinde belirlemek mümkün olmamaktadır.




Şekil 2.27 Rüzgar hızının ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.28’de rüzgar yönündeki değişim ve kirletici konsantrasyonu verilmektedir. İstanbul genelinde rüzgar yönündeki değişim fazla olduğunda bu iki parametre arasında ilişki kurmak oldukça zordur.




Şekil 2.28 Rüzgar yönünün ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.29’da görülebileceği gibi nem oranı kirletici konsantrasyonunun artmasında etkili olmaktadır. Nem oranı NO_x konsantrasyonu ile doğru orantılı olarak artmaktadır.




Şekil 2.29 Nem oranının ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Çiğ noktası incelenen diğer kirleticiler gibi NO_x ile ters orantılı olarak değişmektedir. Şekil 2.30’da çiğ noktası ve NO_x konsantrasyonlarındaki değişimler görülmektedir.




Şekil 2.30 Çiğ noktasının ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.31’de verilen grafikler doğrultusunda deniz seviyesi basıncı ile NO_x konsantrasyonundaki değişim arasında net bir ilişki kurmak oldukça güçtür. Deniz seviyesi basıncında belirleyici bir eğilim grafikten görülememektedir.



Şekil 2.31 Deniz seviyesi basıncının ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Bulutluluk seviyesi NO_x konsantrasyonu ile doğru orantılı olarak değişmektedir. Bu durumda fotokimyasal reaksiyonların İstanbul ili için belirleyici bir parametre olmadığı düşünülebilir. Şekil 2.32’de bulutluluk seviyesi ve NO_x konsantrasyonu arasındaki ilişki verilmiştir.




Şekil 2.32 Bulutluluk seviyesinin ve NO_x konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

2.1.5.4 CO – Meteorolojik Parametrelerin Değişimleri


Karbon monoksit renksiz, kokusuz ve tatsız bir gaz olup karbon içeren yakıtların yanması ile ortaya çıkar. Kararlı bir gaz olan karbon monoksitin atmosferde kalıcılık süresi iki aydan

fazladır. Bütün dünyada CO emisyonu yılda toplam 232 milyon ton olduğu göz önüne alındığında, bu miktarın dünya atmosferi için yarattığı sorun daha da belirgin olmaktadır. Dünyadaki CO emisyonunun yaklaşık olarak % 70'inden fazlası ulaşım sektöründen gelmektedir. Ayrıca bütün dünyada karbon monoksit oluşumunun aşağı atmosferde kalması halinde ise, bu kararlı gazın her yıl 0.03 ppm artacağı hesaplanmaktadır (İncecik, 1994). Şehir havasında bulunan CO insan sağlığına önemli etkilerde bulunmaktadır. Bunlardan en önemlisi karbon monoksitin kandaki hemoglobin hücresinin oksijen taşıma kabiliyetini azaltmasıdır. Şekil 2.33'de sıcaklık ve CO konsantrasyonundaki değişimler verilmiştir. Isınma kaynaklı yakıt emisyonlarının arttığı kış aylarında CO konsantrasyonunda da artış olmaktadır. Bu durumun tersine yaz aylarında CO konsantrasyonu daha düşük olmaktadır.




Şekil 2.33 Sıcaklığın ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

CO konsantrasyonu ve rüzgar hızındaki değişim Şekil 2.34'de verilmiştir. Rüzgar hızı kirketicilerin seyrelmesi ve dolayısıyla konsantrasyonlarının azalması açısından belirleyici bir etken olmasına rağmen İstanbul genelindeki yüksek rüzgar hızı salınımı nedeniyle kirletici konsantrasyonu üzerindeki etkisi belirlenememiştir.




Şekil 2.34 Rüzgar hızının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Rüzgar yönü İstanbul ili için çok yüksek salınımlar gösterdiğinden bu parametrenin kirletici konsantrasyonu ile ilişkisini belirlemek mümkün değildir. Şekil 2.35’de rüzgar yönü ve kirletici konsantrasyonundaki 2003 – 2005 yılları arasındaki değişimler verilmektedir.




Şekil 2.35 Rüzgar yönünün ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Nem oranı CO konsantrasyonu ile doğru orantılı olarak değişmektedir. Bunun nedeni kış aylarında mevsimsel salınımlar nedeniyle havanın bağıl nem oranının daha yüksek olması ve aynı aylarda kirletici konsantrasyonunun da yüksek değerlerde olmasıdır. Şekil 2.36’da bağıl nem oranı ve CO konsantrasyonu arasındaki ilişki verilmiştir.




Şekil 2.36 Nem oranı ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Bulutluluk seviyesi de diğer kirletici parametrelerde olduğu CO içinde konsantrasyon artırıcı şekilde etki göstermiştir. Şekil 2.37’de bulutluluk seviyesindeki değişim ve CO konsantrasyonundaki 2003 – 2005 yılları arasındaki değişim verilmektedir.




Şekil 2.37 Bulutluluk seviyesinin ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Şekil 2.38’de görüldüğü gibi deniz seviyesi basıncı değeri İstanbul genelinde çok farklı dağılım aralığındadır. Bu nedenle deniz seviyesi basıncı ve CO konsantrasyonu arasındaki ilişki bu grafikten elde edilememektedir.



Şekil 2.38 Deniz seviyesi basıncının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

Çiğ noktasındaki değişim diğer incelenen parametreler gibi sıcaklık ile benzer bir eğilimle kirlenici konsantrasyonu ile ters orantılı olarak değişmektedir. Şekil 2.39’da çiğ noktası ve CO konsantrasyonundaki değişim verilmektedir.




Şekil 2.39 Çiğ noktasının ve CO konsantrasyonlarının 2003 – 2005 yılları arasındaki değişimi

2.2 Metodoloji

Bu çalışmada dört ayrı hedef parametresi için dört farklı MLP ağı oluşturulmuştur. Modelde kullanılan parametrelerle oluşturulan yapay sinir ağları modelinde giriş katmanı 7 nöronlu


olarak sabitlenmiştir. Çıkış katmanı da her bir model için SO_2 , NO_x , PM_{10} ve CO konsantrasyonunu temsil eden bir nörondan oluşmaktadır. Oluşturulan YSA modelinin topolojik yapısı Şekil 2.40'da gösterilmektedir. Bu çalışmada en uygun model oluşturulmasıyla birlikte, bu modeller yardımı ile meteorolojik faktörlerin kirletici konsantrasyonlarına olan etkileri incelenmiştir.




Şekil 2.40 Kullanılan YSA modelinin topolojik yapısı

2.2.1 Modellenebilirlik


Oluşturulan dört farklı modeldeki hedef parametreleri olan SO_2 , NO_x , PM_{10} ve CO konsantrasyonlarının zamana bağlı değişimleri şekil 2.41 – 2.44’de gösterilmiştir. En iyi sonucu veren MLP ağının belirlenmesi sırasında gizli katmanda kullanılan nöron sayısı değiştirilerek en uygun model bulunmaya çalışılmıştır. Bu yapıda gizli katmandaki nöron sayısı değiştirilerek değişik YSA modellerinin performansları görülmüştür. Gizli katmandaki nöron sayısının yanı sıra katmanlar arası ağırlıkların başlangıç değerleri değiştirilerek en uygun ve genelleme kabiliyeti en yüksek yapay sinir ağı modeli ortaya konulmaya çalışılmıştır. Ayrıca en iyi modelin bulunmasında girdi setinin eğitime ya da doğrulama sırası ile denemeler yapılmıştır. Sınıf eşitlemesi yapılarak girdi setinde az tekrar eden karakteristik değerler de modelde başarı ile etkin kılınmıştır.




Şekil 2.41 Günlük ortalama SO_2 konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi



Şekil 2.42 Günlük ortalama PM₁₀ konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi



Şekil 2.43 Günlük ortalama CO konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi



Şekil 2.44 Günlük ortalama NO_x konsantrasyonunun 2003 – 2005 yılları arasındaki değişimi

2.2.2 Meteorolojik Faktörlerin Kirliliğe Etkilerinin Modellenmesi

Çalışmanın ikinci bölümünde SO₂, NO_x, PM₁₀ ve CO parametreleri için bulunan en iyi MLP ağı modelleri yardımıyla meteorolojik parametrelerdeki değişimin kirletici konsantrasyonları üzerinde nasıl bir etki yarattığı incelenmiştir. Herbir hedef parametre için çalışmanın ilk bölümünde belirlenen en az hataya sahip model kullanılmıştır.

Meteorolojik faktörlerin etkilerinin anlaşılabilmesi için incelenen parametre dışında diğer parametrelerin ortalamaları alınarak sabit tutulmuştur. İncelenen parametre değer aralığına göre küçükten büyüğe belli aralıklara ayrılarak modele girdi olarak sunulmuştur. Böylece sadece incelenmek istenen parametrenin kirletici konsantrasyonu üzerine etkisi belirlenmiş olmaktadır.

3 SONUÇLAR VE DEĞERLENDİRMELER

3.1 Modeli Etkileyen Parametreler

Yapay sinir ağları modellerinden çok katmanlı perceptron modelinin eğitilmesi, model içi birkaç parametrenin iteratif yöntemle değiştirilmesi ve en uygun değerlerinin bulunması ile ağırlık uzayının oluşturulması şeklinde olmaktadır. Bu parametreler;

- Gizli katman sayısı ve bu katmanlardaki toplam nöron sayısı,
- Nöronlarda kullanılan aktivasyon fonksiyonu,
- Öğrenme ve momentum katsayıları,
- Öğrenme algoritması,
- Ağırlıkların başlangıç değerleri ve değişim aralıkları.

Atmosfer ortamı ve özellikle hava kirliliği modellemesi ile ilgili olarak şimdiye kadar yapılan literatür çalışmalarında görülmüştür ki, aktivasyon fonksiyonu olarak sigmoid fonksiyonu atmosfer ortamının nonlineer yapısını karakterize edecek davranışa sahiptir (Boznar et.al.,1993, Gardner et.al.,1998). Yine ilgili literatürde birden fazla gizli katman kullanılması model için ilave bir genelleme kabiliyeti ortaya koymamaktadır. Aksine ezberleme eğiliminin artmasının yanı sıra çok uzun hesaplama zamanı gerektirmektedir. Ayrıca yapılan denemeler sonucunda görülmüştür ki gizli katmandaki nöron sayısı yeterince artırıldığında model, öğrenme setini %100'e varan oranlarda doğrulukla tanıyabilmektedir. Çünkü modelde öğrenme setinin tamamını temsil edecek miktarda ağırlık katsayısı bulunmaktadır. Bir başka deyişle modelin ağırlık uzayı öğrenme setindeki bütün verileri temsil edecek genişlikte olmaktadır. Fakat böyle bir model çok düşük genelleme kabiliyetine sahip bir modeldir ve öğretilmediği değişik meteorolojik durumları, genelleme özelliği zayıf olduğu için doğru tahmin edememektedir.

Öğrenme katsayısının alacağı değer konusunda kesin bir kural olmayıp tamamen veri setinin yapısına bağlıdır. Mesela Boznar et.al.(1993) çalışmalarında öğrenme katsayısını 0.6 almışlardır. Kullandıkları veri seti incelendiğinde tüm periyot boyunca aşırı salınımlar olmadığı ve homojen artış ve azalışların olduğu görülmektedir. Bu çalışmada kullanılan veri seti incelendiğinde ise hemen hemen tüm parametrelerin günler bazında büyük salınımlar gösterdiği görülmektedir. Yapılan denemelerde 0.7'den büyük öğrenme katsayılarının öğrenme aşamasında büyük salınımlar yaptığı ve bazı değerlerde lokal minimumlara takıldığı


görülmüştür. Daha küçük değerler ise öğrenme zamanını uzatmıştır. İdeal olarak öğrenme katsayısının 0,5 – 0,05 arasında değiştiği söylenebilir.

Momentum katsayısında ise 0.9'dan büyük değerler öğrenme işlemini büyük salınımlara sokup hata minimizasyon işlemini uzatmıştır. 0.9'dan küçük değerler de işlemi uzatmış, ancak işlem salınım yapmadan sürmüştür. Bu veri seti için en uygun değer olarak programın atadığı değerler kullanılmıştır.

Reel sayılardan oluşan veri seti kullanıldığında (bu çalışmada olduğu gibi) gizli katmanda kullanılan nöron sayısı ile ilgili olarak herhangi bir kural yoktur. Yapılan denemelerde giriş parametreleri miktarının 1,5 katından az sayıda gizli katman nöronu kullanıldığında modelin veri setini genellemediği görülmüştür. Kesin bir sınır olmamakla beraber 70'den fazla nöron kullanıldığında da işlem zamanını aşırı uzamasının yanı sıra model öğrenme setini ezberleme eğilimine girmekte ve dolayısıyla genelleme özelliğini kaybetmektedir.

3.1.1 Doğrulama ile Denenen Çeşitli Modellerin Performansları

Yapay Sinir ağlarında eğitime esnasında modelin performansını sınamak için eğitime seti haricinde eğitime işlemine dahil olmayan, ancak modelin aldığı her yeni durum ile sonuçları hesaplanıp hatası bulunan bir doğrulama veri seti kullanılır. Bu veri seti ile modelin eğitime seti üzerinde yoğunlaşması ve genelleme kabiliyetini zayıflatması önlenir.



Şekil 3.1 Doğrulama ile eğitmede en iyi model noktası

Şekil 3.1'de görüldüğü gibi öğrenme esnasında öğrenme seti hatası sıfıra yaklaşırken doğrulama seti hatası belli bir noktaya kadar azalıp daha sonra artmaya başlar. Bu noktaya

kadar model tüm veri seti üzerinde (öğrenme + test + doğrulama) bir genelleme kabiliyeti kazanmış olmaktadır. Bu noktadan sonra ise model tamamen öğrenme seti üzerinde yoğunlaştığı için doğrulama setinin hatası artmaya başlar. Tüm veri setinin öğrenme, test ve doğrulama olarak 3 parçaya bölünme şekli, verilerin hassasiyeti (ölçüm hataları), girdi parametrelerinin çıktı parametresi üzerindeki etkileri yanında gizli katmandaki nöron sayısı da en iyi model noktasındaki hata miktarının büyüklüğüne etki etmektedir.

3.1.2 Verilerde Sınıf Eşitlemesinin Model Performansı Üzerindeki Etkileri

Kullanılan veri seti incelendiğinde Nisan – Kasım ayları boyunca kirlilik parametresinin dar bir aralıkta değişim gösterdiği ve bu periyodun tüm periyot içinde geniş bir aralık kapladığı görülmektedir. Kış aylarında da değişim çok olmamakla birlikte yaz aylarına oranla daha değişken değerler mevcuttur.

Diğer taraftan kış aylarındaki SO₂ değişimi hem değer olarak daha geniş aralıkta olmakta ve hem de bu değişimler zaman periyodu içinde az sayıda tekrerrür etmektedir. Dolayısıyla modelin aşırı değerleri öğrenmesi çok tekrar eden düşük değerlere kıyasla daha az hassas olmaktadır.


Bu noktada az tekrerrür eden verilere karşı modelin performansını arttırmak için sınıf eşitlemesi (class equalization) işlemi uygulanmıştır. Az tekrar eden yüksek değerler çoğaltılar modele tanıtılmıştır. Bu şekilde modelin bu verileri daha çok görmesi ve daha iyi tanınması sağlandı. Bu işlem suni bir işlem olup tekrar eden verilerin arkasındaki girdi parametreleri seti tamamen aynı olduğu için gerçek durumlar gibi olmamaktadır. Daha çok, sınıflandırma (classification) yapan yapay sinir ağları modellerinde kullanılmasına rağmen buradaki uygulamada model performansını artırıcı yönde etki göstermiştir.

3.2 Model Tahmin Sonuçları

Aşağıdaki grafikler en iyi model tahmin sonuçlarını vermektedir. Bu sonuçlar elde edilirken herbir kirlitici parametre için bir MLP modeli oluşturulmuştur. Girdi olarak 7 meteorolojik faktör kullanılmış, çıktı olarak da tahmin edilecek kirlitici konsantrasyonu kullanılmıştır. Ağırlıklar, nöron sayısı, model fonksiyonu veri seti sırası, sınıf eşitlemesi gibi etken kullanılarak hata oranı olabilecek en az değere çekilmeye çalışılmıştır. Yapılan deneyler sonucunda herbir kirlitici parametre için en iyi model oluşturulmuştur.


3.2.1 SO₂ Tahmin Sonuçları

MLP ağı model sonucu aşağıdaki grafiklerde gösterilmektedir. Şekil 3.3 ölçülen SO₂ – model tahminini göstermekle beraber eğriler arasındaki ilişki grafikten tam olarak anlaşılamadağı için Şekil3.4’de 10 değer başına hareketli ortalama alınarak grafik tekrar çizilmiştir.Şekil 3.2’de ise ölçülen SO₂ konsantrasyonu ve model tahmin değerleri dağılım diagramı verilmektedir.




Şekil 3.2 Ölçülen SO₂ konsantrasyonunun ve en iyi model tahmininin dağılım diagramı (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5973$)

Model sonucu ve ölçülen SO₂ konsantrasyonu karşılaştırıldığında yapılan tahminlerin SO₂ konsantrasyonlarındaki mevsimsel değişimleri çok iyi takip ettiği görülmektedir. Dağılım diagramından görülebileceği gibi ölçülen değer ile model tahmini arasındaki korelasyon katsayısı 0,5973 olarak bulunmuştur.




Şekil 3.3 Ölçülen SO₂ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5973$)



Şekil 3.4 Ölçülen SO₂ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (10 değer başına hareketli ortalama, zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5973$)


3.2.2 PM₁₀ Tahmin Sonuçları

Şekil 3.5’de ölçülen PM₁₀ konsantrasyonu ve model tahmin değerlerinin dağılım diagramı verilmiştir. Şekil 3.6 ölçülen PM₁₀ – model tahminini, Şekil 3.7 10 değer başına hareketli ortalama alınarak çizilen PM₁₀ – model tahminini göstermektedir.




Şekil 3.5 Ölçülen PM₁₀ konsantrasyonunun ve en iyi model tahmininin dağılım diagramı (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5181$)

Model tahmini, eğrilerdeki mevsimsel değişimleri yakalamakla beraber anlık değişimlerde başarılı sonuçlar ortaya koyamamıştır. Model için korelasyon katsayısı 0,5181 olarak hesaplanmıştır.




Şekil 3.6 Ölçülen PM_{10} konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5181$)



Şekil 3.7 Ölçülen PM₁₀ konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (10. değer başına hareketli ortalama, zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.5181$)


3.2.3 CO Tahmin Sonuçları

Şekil 3.8’de ölçülen CO konsantrasyonu ve model tahmin değerlerinin dağılım diagramı verilmiştir. Şekil 3.9 ölçülen CO – model tahminini, Şekil 3.10 10 değer başına Hareketli ortalama alınarak çizilen CO – model tahminini göstermektedir.




Şekil 3.8 Ölçülen CO konsantrasyonunun ve en iyi model tahmininin dağılım diagramı
(zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.7345$)

Model yüksek doğrulukla tahminler yapabilmiş ve eğrilerdeki değişimleri doğru olarak tahmin edebilmiştir. Korelasyon katsayısı 0,7345 olarak hesaplanmıştır.




Şekil 3.9 Ölçülen CO konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.7345$)



Şekil 3.9 Ölçülen CO konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (10. değer başına hareketli ortalama zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.7345$)


3.2.4 NO_x Tahmin Sonuçları

Şekil 3.11’de ölçülen NO_x konsantrasyonu ve model tahmin değerlerinin dağılım diagramı verilmiştir. Şekil 3.12 ölçülen NO_x – model tahminini, Şekil 3.13 10 değer başına Hareketli ortalama alınarak çizilen NO_x – model tahminini göstermektedir.




Şekil 3.11 Ölçülen NO_x konsantrasyonunun ve en iyi model tahmininin dağılım diagramı (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.573$)

Model sonucu incelendiğinde bu model tahmininde de diğer kirletici parametreler için oluşturulan modellerde olduğu gibi eğrilerdeki değişimlerin model tarafından başarılı olarak tahmin edildiği görülmüştür. Model kirletici konsantrasyondaki anlık değişimleri doğru olarak tahmin edebilmiştir. Şekil 3.13’de belirtildiği gibi korelasyon katsayısı 0,573 olarak bulunmuştur.



Şekil 3.12 Ölçülen NO_x konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.573$)



Şekil 3.13 Ölçülen NO_x konsantrasyonunun ve en iyi model tahmininin karşılaştırılması (10 değer başına hareketli ortalama, zaman sıralı veri, sınıf eşitlemesi yapıldı. $R^2 = 0.573$)

3.3 Meteorolojik Faktörlerin Kirlilik Parametrelerine Etkilerinin YSA ile Belirlenmesi

Çalışmanın ikinci bölümünde SO₂, NO_x, PM₁₀ ve CO parametreleri için bulunan en iyi MLP ağı modelleri yardımıyla meteorolojik parametrelerdeki değişimin kirletici konsantrasyonları üzerinde nasıl bir etki yarattığı incelenmiştir. Herbir hedef parametre için çalışmanın ilk bölümünde belirlenen en az hataya sahip model kullanılmıştır.

Meteorolojik faktörlerin etkilerinin anlaşılabilmesi için incelenen parametre dışında diğer parametrelerin ortalamaları alınarak sabit tutulmuştur. İncelenen parametre değer aralığına göre küçükten büyüğe belli aralıklara ayrılarak modele girdi olarak sunulmuştur. Böylece sadece incelenmek istenen parametrenin kirletici konsantrasyonu üzerine etkisi belirlenmesi amaçlanmaktadır.

3.3.1 SO₂ – Meteorolojik Faktörlerin Etkileşimleri


Oluşturulan en iyi modele çıktı olarak Çizelge 3.1’de verilen meteorolojik faktörlerin ortalama değerleri incelenen parametre dışında diğer parametreler sabit kalacak şekilde hazırlanmıştır. İncelenen parametre değişim aralığına göre sabit aralıklı artan değerlere bölünerek modele girdi olarak sunulmuştur. Böylece diğer meteorolojik faktörler sabit tutularak sadece incelenen parametrenin değişimi belirlenmiştir..

Çizelge 3.1 Modelde kullanılan meteorolojik faktörlerin ortalama değerleri

Parametre	Birim	Ortalama
Basınç (deniz seviyesi)	mbar	1016,22
Sıcaklık	°C	14,8
Çiğ Noktası	°C	8,98
Bulutluluk	-	1
Bağıl Nem	%	69,70
Hakim Rüzgar Yönü		0,25
Ort. Rüzgar Hızı	m/sn	4,21


Şekil 3.14’de SO₂ konsantrasyonunun sıcaklık ile değişimi verilmektedir. Sıcaklık ile SO₂ konsantrasyonunda ters orantı gözlemlenmektedir. Kirletici konsantrasyonundaki artış kış aylarında havanın soğuk olması nedeniyle ısınma kaynaklı emisyonların artması sonucundadır. Havanın daha sıcak olduğu yaz günlerinde yakıt tüketimi az olduğundan kirletici

konsantrasyonu da daha düşük seviyelerde olmaktadır.




Şekil 3.14 SO₂ konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.15’de SO₂ konsantrasyonunun nem oranı ile değişimi incelenmiştir. İstanbul ili için veriler incelendiğinde (Şekil 2.14) nem oranı sıcaklık ile doğru orantılı olarak değişmektedir. Şekil 3.15’de nem oranı değişimi yüksek salınımlar göstermektedir. Ancak genel değişimi görmek amacı ile trend çizgisi geçirildiğinde nem oranının kirletici konsantrasyonu ile doğru orantılı olarak değiştiği görülmektedir.




Şekil 3.15 SO₂ konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.16’da rüzgar hızının kirletici konsantrasyonuna olan etkisi görülmektedir. Rüzgar hızındaki kirleticinin seyrelmesine neden olacağından SO₂ konsantrasyonunda artan rüzgar hızı ile bir düşüş beklenmektedir. Model, rüzgar hızındaki artışın SO₂ konsantrasyonunda azalmaya neden olduğunu başarılı bir şekilde tahmin edebilmiştir.




Şekil 3.16 SO₂ konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.17’de SO₂ konsantrasyonunun çığ noktası ile değişimi verilmektedir. Çığ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeridir. Bu nedenle kirletici ile arasındaki sıcaklık grafiğine benzer bir eğilim olmaktadır.




Şekil 3.17 SO₂ konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi

Bulutluluk seviyesindeki artış ile ısınma kaynaklı yakıt tüketimi artmakta ve dolayısıyla SO₂ konsantrasyonunda da artış olmaktadır. Şekil 3.17’de bulutluluk seviyesi ile SO₂ konsantrasyonu arasında ters bir ilişki ortaya çıkmıştır. Model bulutluluk seviyesi ve SO₂ konsantrasyonu arasındaki ilişkiyi doğru olarak belirleyememiştir.




Şekil 3.17 SO₂ konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.18 incelendiğinde hakim rüzgar yönünün kuzey olduğu durumlarda kirletici SO₂ konsantrasyonunda azalma görülmektedir. Bu azalmanın nedeni Karadeniz'den gelen temiz havanın etkisi olarak yorumlanabilir.



Şekil 3.18 SO₂ konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi


Yüksek basıncın etkin olduğu koşullarda kirleticinin ortamı terk edemediği ve konsantrasyonunda artış olduğu bilinmektedir. Şekil 3.19'da model beklenenin aksine kirletici konsantrasyonunda azalma ortaya koymuştur.



Şekil 3.19 SO₂ konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi


3.3.2 PM₁₀ Meteorolojik Faktörlerin Etkileşimleri

Şekil 3.20’de PM₁₀ konsantrasyonunun sıcaklık ile değişimi verilmektedir. Sıcaklık arttığında konsantrasyonda düşüş gözlemlenmektedir. Yanma kaynaklı kirletici konsantrasyonları için bu azalma kış aylarında havanın soğuk ve ısınma kaynaklı emisyonlar nedeniyle kirletici konsantrasyonunun yüksek ve havanın daha sıcak sıcak olduğu günlerde yakıt tüketimi az olacağından sıcaklığın düşük olmasından ileri gelmektedir.




Şekil 3.20 PM₁₀ konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi

İstanbul ili için ölçülen PM değerleri ve nem oranının değişimi incelendiğinde (Şekil 2.22) genel olarak değişim doğru orantılıdır. Ancak model Şekil 3.21’de görüldüğü gibi bu orantıyı doğru bir şekilde tahmin edememiştir.




Şekil 3.21 PM₁₀ konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi

İstanbul genelinde rüzgar yönünün büyük salınımlar göstermesi nedeniyle (Şekil 2.10) kirletici konsantrasyonu ile değişiminin etkisini belirlemek çok zordur. Şekil 3.22’de PM₁₀ konsantrasyonunun rüzgar yönü ile değişimi verilmektedir.




Şekil 3.22 PM₁₀ konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi

Rüzgar hızındaki artış yanma kaynaklı kirleticilerin dağılmasına neden olmaktadır ve dolayısıyla kirletici konsantrasyonlarında azalma olmaktadır. Şekil 3.23’de görüldüğü gibi model bu değişimi başarılı bir şekilde ortaya koyabilmiştir.




Şekil 3.23 PM₁₀ konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi

Bulutluluk seviyesi genellikle kış aylarında artış göstermektedir. Bu aylarda ısınma kaynaklı yakıt tüketimi nedeniyle kirletici konsantrasyonlarında artış gözlemlenmektedir. Şekil 3.24 incelendiğinde model bu eğilimi başarı ile tahmin edebilmiştir.




Şekil 3.24 PM₁₀ konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.25’de verilen PM₁₀ ve basıncın değişimi grafiği incelendiğinde basıncın yükseldiğinde kirletici konsantrasyonunda azalma gözlemlenmektedir. Oysa yüksek basıncın etkin olduğu koşullarda kirleticinin ortamı terk edemediği ve konsantrasyonunda artış olduğu bilinmektedir.



Şekil 3.25 PM_{10} konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.26’da PM_{10} konsantrasyonunun çığ noktası ile değişimi verilmektedir. Çığ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeri olduğundan sıcaklık faktörü ile benzer bir eğimle değişiklikler gözlenmektedir. Bu noktada model başarılı bir tahmin yapabilmektedir.




Şekil 3.26 PM_{10} konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi

3.3.3 CO Meteorolojik Faktörlerin Etkileşimleri


Şekil 3.26’da CO konsantrasyonunun sıcaklık ile değişimi verilmektedir. Sıcaklık artışı ile CO konsantrasyonunda düşüş gözlemlenmektedir. CO konsantrasyonunda gözlenen bu düşüşün nedeni havanın soğuk olduğu günlerde ısınma amacı ile yakılan yakıtlardan

kaynaklanan emisyonların, havanın ısınması ile ortama daha az verilmesidir.



Şekil 3.26 CO konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi


Şekil 3.27’de CO konsantrasyonunun çığ noktası ile değişimi verilmektedir. Çığ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeridir ve bu değer havanın soğuk olduğu kış aylarında düşüş göstermektedir. Bu nedenle çığ noktası artarken kirletici konsantrasyonunda azalma olması beklenmektedir.



Şekil 3.27 CO konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi


Şekil 3.28’de görüldüğü gibi rüzgar hızı CO konsantrasyonu ile ters orantılı olarak değişmektedir. Rüzgar hızındaki artış yanma kaynaklı kirleticilerin dağılmasına neden olmaktadır.

ve dolayısıyla kirletici konsantrasyonlarında azalma olmaktadır. Bu doğrultuda model başarılı bir tahmin yapabirmiştir.




Şekil 3.28 CO konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.29 incelendiğinde hakim rüzgar yönünün kuzey olduğu durumlarda kirletici SO_2 konsantrasyonunda azalma görülmektedir. Bu azalmanın nedeni Karadeniz'den gelen temiz havanın etkisi olarak yorumlanabilir.




Şekil 3.29 CO konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi

İstanbul genelindeki veriler incelendiğinde (Şekil 2.36) CO konsantrasyonu nem oranı ile doğru orantılı olarak değişmektedir. Şekil 3.30'dan görülebileceği gibi model bu değişimi başarı ile ortaya koymuştur.




Şekil 3.30 CO konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.31 incelendiğinde SO_2 ve PM_{10} konsantrasyonlarının basınç ile değişim tahminlerinde olduğu gibi model artan basınç ile azalan CO konsantrasyonu elde etmiştir. Oysa yüksek basınç değerlerinde artan kirlilik seviyesi beklenmektedir. Bu noktada model bu ilişkiyi doğru olarak orataya çıkaramamıştır.



Şekil 3.31 CO konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi


Bulutluluk seviyesindeki artış genellikle soğuk kış aylarında meydana gelmekte dolayısıyla yanma kaynaklı kirleticilerin konsantrasyonlarında ısınma kaynaklı yakıtların yakılması nedeniyle artış olmaktadır. Şekil 3.32'de bulutluluk seviyesi ve CO konsantrasyonundaki etkileşim verilmiştir. Model bu değişimi başarı ile tahmin edebilmiştir.



Şekil 3.32 CO konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi


3.3.4 NO_x Meteorolojik Faktörlerin Etkileşimleri

NO_x kirleticisinin birincil kaynağı araç emisyonlarıdır. Sıcaklık genel olarak yaz aylarında yüksektir ve yaz aylarında güneş ışınlarının etkisiyle fotokimyasal reaksiyonlar oluşmaktadır. Bu bağlamda Şekil 3.33 incelendiğinde sıcaklık ile NO_x konsantrasyonlarındaki artış grafikte doğru olarak tahmin edilebilmiştir. Ancak elde edilen bu değişim İstanbul ili için genel kirletici eğiliminle örtüşmemektedir. (Şekil 2.26) Ölçülen kirletici konsantrasyonları göz önüne alındığında sıcaklıkla ters orantılı bir değişim söz konusudur. Fotokimyasal reaksiyonlar İstanbul ili için belirleyici bir faktör olmamaktadır.




Şekil 3.33 NO_x konsantrasyonunun sıcaklık ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.34’de NO_x konsantrasyonunun rüzgar hızı ile değişimi görülmektedir. Rüzgar hızındaki artış kirletici konsantrasyonunda seyrelmeye ve dolayısıyla azalmaya neden olmaktadır. Model kirletici konsantrasyonu ile meteorolojik faktör arasındaki ilişkiyi başarılı olarak tahmin edebilmiştir.




Şekil 3.34 NO_x konsantrasyonunun rüzgar hızı ile değişiminin YSA modeli ile belirlenmesi

Ölçülen değerler incelendiğinde (Şekil 2.29) NO_x konsantrasyonu ile nem oranı doğru orantılı olarak değişmektedir. Şekil 3.35’de görüldüğü gibi model bu ilişkiyi doğru bir şekilde tahmin edebilmiştir.




Şekil 3.35 NO_x konsantrasyonunun nem oranı ile değişiminin YSA modeli ile belirlenmesi

Rüzgar yönü İstanbul genelinde çok değişik aralıklarda değişmektedir. Bu nedenle bu parametrenin kirletici konsantrasyonuna etkisini belirlemek oldukça zordur. Şekil 3.36’da rüzgar yönündeki değişimin kirletici konsantrasyonuna etkisi verilmektedir.




Şekil 3.36 NO_x konsantrasyonunun rüzgar yönü ile değişiminin YSA modeli ile belirlenmesi

Şekil 3.37’de NO_x konsantrasyonunun çığ noktası ile değişimi verilmektedir. Çığ noktası sıcaklık düşerken havadaki nemin yoğunlaşmaya başladığı sıcaklık değeridir ve bu değer kış havanın soğuk olduğu kış aylarında düşüş göstermektedir (Şekil2.8). Bu nedenle çığ noktası artarken kirletici konsantrasyonunda azalma olması beklenmektedir. Şekil 3.27’de bu değişim başarılı bir şekilde ortaya konulabilmektedir.




Şekil 3.37 NO_x konsantrasyonunun çığ noktası ile değişiminin YSA modeli ile belirlenmesi

Bulutluluk seviyesindeki artış ile güneşlenme süresi azalacaktır. Bu nedenle fotokimyasal reaksiyonlarda da azalma görülecektir. NO_x oluşumunda fotokimyasal reaksiyonların etkisi göz önüne alınacak olursa Şekil 3.38’de görüldüğü gibi model başarılı bir tahmin yapabilmektedir. Ancak elde edilen bu değişim İstanbul ili için genel kirletici eğilimi (Şekil 2.26) göz önüne alındığında gözlenen değerlerle uyum sağlamamaktadır.



Şekil 3.38 NO_x konsantrasyonunun bulutluluk seviyesi ile değişiminin YSA modeli ile belirlenmesi

Deniz seviyesi basıncı İstanbul için ölçülen değerler incelendiğinde büyük salınımlar göstermektedir.(Şekil 2.5) Bu nedenle basıncın kirlotici konsantrasyonuna etkisini belirlemek oldukça güçtür. Şekil 3.39’da deniz seviyesi basıncının NO_x konsantrasyonunu üzerindeki etkisi verilmektedir.



Şekil 3.39 NO_x konsantrasyonunun deniz seviyesi basıncı ile değişiminin YSA modeli ile belirlenmesi

3.4 Meteorolojik Parametrelerin Çıktı Üzerindeki Etkileri


Meteorolojik parametrelerin kirlotici konsantrasyonları üzerine etkieri incelenirken, etkisi belirlenmek istenen meteorolojik parametre dışında diğer parametrelerin ortalamaları alınarak modele sabit değerler olarak girilmiştir. İncelenen parametre belirli aralıklara bölünmüş ve

kirletici konsantrasyonlarındaki değişim incelenmiştir.

Çizelge 3.2’de SO₂ konsantrasyonları için meteorolojik faktörlerin etkileri verilmektedir. SO₂ konsantrasyonundaki en büyük değişim çiğ noktası parametresinin etkisi altında olmuştur. En az değişim miktarı ise rüzgar yönüne aittir. Çizelge 3.3’de meteorolojik parametrelerin SO₂ konsantrasyonu ile değişim oranları verilmiştir. Değişim oranları incelendiğinde ise rüzgar hızı parametresinin modeli büyük ölçüde etkilediği ortaya çıkmaktadır. Bu parametre küçük bir salınım göstermesine rağmen SO₂ konsantrasyonunu yüksek değerlerde etkileyebilmiştir. Modelde elde edilen en yüksek SO₂ değeri deniz seviyesi basıncı parametresinin etkisi ile elde edilmiştir.

Çizelge 3.2 Meteorolojik parametrelerin SO₂ konsantrasyonuna etkisi

Parametre	Değişim aralığı	Değişim değeri (Δ)	SO ₂ değişim aralığı	SO ₂ değişim değeri (Δ SO ₂)	Değişim Oranı(Δ SO ₂ / Δ Faktör)
Sıcaklık (°C)	-4,44 – 30	34,4	28,66 – 5,48	-23,18	-2,18
Rüzgar Hızı (m/sn)	0 – 14,22	14,22	21,14 – 7,97	-13,17	-8,25
Rüzgar yönü	-0,875 – 1	1,875	11,19 – 23,60	12,41	3,12
Nem Oranı (%)	32 – 98	66	7,42 – 27,95	20,53	0,48
Çiğ Noktası (°C)	-8,89 – 21,67	30,56	36,86 – 7,98	-28,88	-0,78
Bulutluluk	0 – 5	5	13,95 – 2,61	-11,34	-2,25
Basınç (mbar)	996,6 – 1035,5	38,6	38,09 – 10,51	-27,58	-0,52




Şekil 3.40 Meteorolojik parametrelerin SO₂ konsantrasyonu ile değişim oranı

Çizelge 3.4’de PM₁₀ konsantrasyonları için meteorolojik faktörlerin etkileri verilmektedir. Rüzgar hızının incelendiği model sonuçlarında en yüksek PM konsantrasyonu ve en yüksek değişim değeri elde edilmiştir. Çizelge 3.5’de meteorolojik parametrelerin PM₁₀ konsantrasyonu ile değişim oranları verilmiştir. Değişim oranları incelendiğinde en yüksek değişim oranının küçük salınım gösteren rüzgar yönü etkisini inceleyen modelde olduğu görülmektedir.

Çizelge 3.4 Meteorolojik parametrelerin PM₁₀ konsantrasyonuna etkisi

Parametre	Değişim aralığı	Değişim değeri (Δ)	PM ₁₀ değişim aralığı	PM ₁₀ değişim miktarı (ΔPM ₁₀)	Değişim Oranı(ΔPM ₁₀ / ΔFaktör)
Sıcaklık (°C)	-4,44 – 30	34,4	102,62 – 7,09	-75,21	-0,67
Rüzgar Hızı (m/sn)	0 – 14,22	14,22	118 – 0,6	-117,4	-0,92
Rüzgar yönü	-0,875 – 1	1,875	51,75 – 57,6	5,85	6,61
Nem Oranı (%)	32 – 98	66	73,38– 41,35	-32,03	-0,31
Çiğ Noktası (°C)	-8,89 – 21,67	30,56	64,98– 41,03	-23,95	-0,94
Bulutluluk	0 – 5	5	57,25 – 68,54	11,29	2,26
Basınç (mbar)	996,6 – 1035,5	38,6	63,75– 43,5	-20,25	-0,71




Şekil 3.41 Meteorolojik parametrelerin PM₁₀ konsantrasyonu ile değişim oranı

Çizelge 3.6’de CO konsantrasyonları için meteorolojik faktörlerin etkileri verilmektedir. Rüzgar hızı PM tahmininde olduğu gibi CO konsantrasyonun meteorolojik parametreler ile değişiminde de en yüksek değişim değeri ve en yüksek CO konsantrasyonuna sahiptir. Çizelge 3.7’de meteorolojik parametrelerin CO konsantrasyonu ile değişim oranları verilmiştir. Değişim oranları incelendiğinde en yüksek oranın, PM₁₀ modelinde olduğu gibi rüzgar yönü etkisini inceleyen modelde olduğu görülmektedir.

Çizelge 3.6 Meteorolojik parametrelerin CO konsantrasyonuna etkisi

Parametre	Değişim aralığı	Değişim değeri (Δ)	CO değişim aralığı	CO değişim miktarı (Δ CO)	Değişim Oranı(Δ CO / Δ Faktör)
Sıcaklık (°C)	-4,44 – 30	34,4	1567–499	-1068	-31,04
Rüzgar Hızı (m/sn)	0 – 14,22	14,22	2256– 420	-1836	-129,11
Rüzgar yönü	-0,875 – 1	1,875	897–508	-389	-207,46
Nem Oranı (%)	32 – 98	66	357 – 1448	1091	16,53
Çiğ Noktası (°C)	-8,89 – 21,67	30,56	1674– 477	-1197	-39,16
Bulutluluk	0 – 5	5	399 – 737	338	67,6
Basınç (mbar)	996,6 – 1035,5	38,6	1021– 497	-524	-13,57




Şekil 3.42 Meteorolojik parametrelerin CO konsantrasyonu ile değişim oranı

Çizelge 3.8’de NO_x konsantrasyonları için meteorolojik faktörlerin etkileri verilmektedir. NO_x için çiğ noktası model tahmini en yüksek konsantrasyon değeri ve en yüksek değişim değerini elde etmiştir. Çizelge 3.9’de meteorolojik parametrelerin NO_x konsantrasyonu ile değişim oranları verilmiştir. NO_x kirleticisi için de en yüksek değişim oranı bulutluluk seviyesi değişimine aittir.

Çizelge 3.5 Meteorolojik parametrelerin NO_x konsantrasyonuna etkisi

Parametre	Değişim aralığı	Değişim değeri (Δ)	NO _x değişim aralığı	NO _x değişim miktarı (ΔNO _x)	Değişim Oranı(ΔNO _x / ΔFaktör)
Sıcaklık (°C)	-4,44 - 30	34,4	27,61 – 168,92	141,31	4,10
Rüzgar Hızı (m/sn)	0 – 14,22	14,22	230,63– 66,45	-164,18	-11,54
Rüzgar yönü	-0,875 - 1	1,875	137,07– 102,63	-34,44	-18,36
Nem Oranı (%)	32 – 98	66	20,68 – 189,72	169,04	2,56
Çiğ Noktası (°C)	-8,89 – 21,67	30,56	320,50– 33,32	-287,18	-9,391
Bulutluluk	0 - 5	5	141,09– 19,21	-121,88	-24,37
Basınç (mbar)	996,6 – 1035,5	38,6	171,12– 110,04	-61,08	-1,58



Şekil 3.43 Meteorolojik parametrelerin NO_x konsantrasyonu ile değişim oranı

Elde edilen grafikler doğrultusunda aşağıdaki sonuçlara varılmaktadır;

1. Yapay sinir ağları modelleri hava kirliliği tahminlerinde veri setinin kalitesi ve kullanılan veri çeşidinin sayısına bağlı olarak başarılı sonuçlar vermektedir. Kullanılan veri sayısının artması ile model daha fazla durumu öğrenebilmekte dolayısıyla genelleme kabiliyeti de dikkete değer bir şekilde artmaktadır. Model tahmin sonuçlarını gösteren grafikler incelendiğinde (Şekil 3.2 – 3.13) SO₂, CO ve PM₁₀ kirletici konsantrasyonlarının kış aylarındaki yüksek değerlerden ilkbahar ve yaz aylarına doğru düşüş eğilimi ve yine kış aylarına doğru yükseliş eğilimi, yani mevsimsel değişimler yapay sinir ağları modeli ile oldukça iyi temsil edilebilmektedir. Ancak modeller genel eğilim tahmini dışında anlık değişimleri kısmen doğru olarak tahmin edebilmiştir. Model tahmini ve gerçek değerler karşılaştırıldığında korelasyon katsayıları (R^2) SO₂, CO PM₁₀ ve NO_x kirleticileri için sırasıyla 0.5973, 0.7345, 0.5181 ve 0.573 olarak hesaplanmıştır.
2. Modellerde kullanılan girdi ve çıktı parametreleri incelendiğinde kirletici konsantrasyonların yaz aylarında daha düşük salınımlar gösterdiği belirlenmiştir. Bu modelin verileri yaz ayları için nispeten sabit bir değer gibi algılamasına olanak sağlamış ve dolayısıyla model çok daha başarılı tahminler yapabilmıştır. Bu durumun tersine kış aylarında daha yüksek salınımlar olmakta ve modelin doğru tahminler yapabilme yeteneği azalmaktadır. Yani kış aylarındaki yüksek konsantrasyon değerleri modelde tam olarak

algılanamamaktadır. Modelin algılama ve öğrenme kabileyitini yükseltmek için az tekrar eden değerleri yapay olarak çoğaltan sınıf eşitleme metodu kullanılmış ve model performansı artırılmıştır.

3. Oluşturulan dört farklı model için kullanılan en iyi model denemeleri Çizelge 3.6 'da verilmiştir.

Çizelge 3.6 En iyi model verileri

Parametre	Nöron Sayısı	Ağırlık Değişim Aralığı	Transfer Fonksiyon	Sınıf Eşitlemesi	Korelasyon Katsayısı
SO ₂	14	0,07	Sigmoid	Yapıldı	0,5973
CO	9	0,7	Sigmoid	Yapıldı	0,7345
NO _x	9	0,06	Sigmoid	Yapıldı	0,573
PM ₁₀	8	0,6	Sigmoid	Yapıldı	0,5181

Çizelge 3.6 incelendiğinde her bir modelde kullanılan meteorolojik girdiler aynı olmasına rağmen hedef parametrelerindeki değerlerin farklılıkları nedeniyle en iyi model sonuçları çok farklı denemeler sonucunda elde edilmiştir. Nöron sayıları ve ağırlıklar değişken olmakla birlikte en iyi hata oranları sigmoid fonksiyonu ile elde edilmiştir.

4. Meteorolojik faktörlerin etkileri incelendiğinde modelin, grafiklerin geneli göz önüne alındığında başarılı sonuçlar verebildiği görülmüştür. Elde edilen sonuçlar literatür çalışmaları doğrultusunda olması beklenen durumlarla örtüşmektedir. Ancak model tahmin grafikleri salınım aralığı yüksek olan grafikler olduğundan ve lokal salınımları incelemek için yeterli ver altyapısı olmadığından daha sağlıklı yorumlar yapabilmek için genel eğilim doğruları (trend doğruları) geçirilerek değişim yönü incelenmiştir.

Şekil 3.14 – 3.34 incelendiğinde kirleticilerin meteorolojik parametreler ile değişimini veren modellerin başarılı sonuçlar elde ettiği görülmektedir. SO₂, CO ve PM₁₀ konsantrasyonları yakıt emisyonları nedeniyle havanın soğuk olduğu, bulutluluk seviyesinin yüksek olduğu günlerde artış göstermektedir. İncelenen modeller bu ilişkileri başarılı bir şekilde ortaya çıkarabilmiştir. NO_x kirleticisi konsantrasyonu da diğer yanma kaynaklı kirleticilerle benzer bir değişim eğilimindedir. İstanbul ili için ölçülen değerler incelendiğinde NO_x kirleticisinin konsantrasyonu da sıcaklık ile ters orantılı olarak değişmektedir. Bu bilgiler doğrultusunda fotokimyasal reaksiyonların bu kirletici üzerinde baskın bir etkisinin olmadığı görülmektedir.

Ancak model bu noktada sıcaklık ve bulutluluk seviyesi ile NO_x konsantrasyonu deęişimini doęru orantılı olarak tahmin edebilmiř, dolayısıyla bu baęıntı başarılı bir řekilde ortaya konulamamıřtır. Modellerin genelinde kirletici konsantrasyonları ve deniz seviyesi basınç ters orantılı olarak deęişmektedir. Yüksek basınç ile kirletici konsantrasyonlarının arttığı literatürde belirtilmektedir. Bu nedenle modellerin deniz seviyesi basıncı parametresi için yanlış sonuçlar elde ettięi söylenebilir.. Rüzgar yönü için modeller çok çeřitli sonuçlar elde etmiştir. Bunun nedeni İstanbul genelinde çok büyük salınımlar göstermekte ve dolayısıyla modelin bu parametreyi tam olarak algılayamamasıdır.. İstanbul genelindeki ölçülen nem oranı ve kirletici konsantrasyonları arasındaki baęıntı da model ile doęru olarak ifade edilebilmiştir.

5. Grafiklerin geneline bakıldığında modelin başarılı tahminler yaptığı söylenebilir. Ancak meteorolojik parametrelerin birbirleri ile olan etkileřimlerinin kompleks bir yapıya sahip oluřu ve modelde kullanılan parametre sayısının lokal salınımları algılamada yeterli olmaması grafikler üzerine yorum yapmayı zorlařtırmaktadır.

4 ÖNERİLER

Yapay sinir ağlarının hava kirliliği modellemesinde oldukça başarılı sonuçlar verdiği ortadadır. Bu başarının en önemli faktörü veri tabanıdır. Veri tabanı ne kadar geniş ve çeşitli ise modelin genelleme kabiliyeti de o kadar iyi olmaktadır. Sadece meteorolojik parametreler kullanılarak yapılan modelleme çalışmasında istatistiksel olarak oldukça başarılı sonuçlar elde edilmiştir. Kullanılan girdi parametrelerinin sayısı arttığında modelin başarısı da belirgin bir şekilde artmaktadır. Aynı zamanda veri setinde değerlerin bütünlüğü de modelin başarısında önemli rol oynamaktadır. Klasik istatistiksel ve fonksiyonel modelleme tekniklerinde olduğu gibi hiçbir ön şart gereksinimi olmadan ağ modellerinin çeşitli durumları iteratif yöntemlerle birkaç parametre kullanılarak sınanmakta ve genelleme kabiliyeti en yüksek model ortaya çıkmaktadır. Veri tabanının miktar ve kalite bazında genişletilmesi yanında diğer meteoroloji ve kirlletici parametrelerinin modele dahil edilmesiyle çok daha iyi sonuçlar alınabilir. İstanbul'da kullanılan kömür, fuel oil, doğalgaz gibi yakıtların günlük kullanım miktarlarının yanı sıra motorlu taşıtların durumu da hava kirliliğini etkileyen parametreler arasındadır. Bu parametrelerin de modele katılmasıyla kirliliğin kaynak bazındaki etkileri de ele alınmış olur ve daha hassas sonuçlar elde edilebilir.

Bu çalışmada kullanılan veri setinin genişletilmesiyle daha başarılı sonuçlar elde edilebilir. Modelde kullanılan 7 meteorolojik parametrenin ortalama değerleri dışında, maksimum ve minimum değerleri de modele dahil edilerek YSA'nın daha çok veri sayısı ile modelleme yapabilmesi sağlanabilir. Bunun yanında enversiyon durumu, yağış miktarı güneşlenme süresi gibi diğer meteorolojik faktörlerin de modele dahil edilmesi model başarısını büyük ölçüde etkileyecektir. Aynı zamanda İstanbul ilinde diğer meteorolojik ölçüm noktalarından alınan verilerin de modele dahil edilmesiyle, bölgesel değişimler daha başarılı bir şekilde model tarafından tanımlanabilecektir.

Model veri miktarı ve parametre sayısı bakımından ne kadar geniş tabanlı olursa verdiği sonuçlar da o kadar güvenilir olur. Ancak yapay sinir ağları ile çalışmanın en büyük zorluğu yüksek hesap kapasitesine ihtiyaç duyulmasıdır. Bu çalışma sırasında yapılan bazı eğitme iterasyonlarının sonuca ulaşması çok uzun zaman almıştır. Modele ilave edilecek her parametre, her veri paterni, her nöron modelin sonuca ulaşma zamanını uzatmaktadır.

KAYNAKLAR

- Asha B. Chelani, R. N. Singh, S. Devotta Nonlinear Dynamical Characterization And Prediction Of Ambient Nitrogen Dioxide Concentration Water, Air, and Soil Pollution (2005) 166: 121–138
- Asha B. Chelani, C.V. Chalapati Rao, K.M. Phadke, M.Z. Hasan (2002) Prediction of sulphur dioxide concentration using artificial neural networks Environmental Modelling & Software 17 161–168
- Bakshi BR, Utojo U (1999) Anal Chim Acta 384:227–247
- Benvenuto F., Marani A. (2000) Neural Networks For Environmental Problems: Data Quality Control And Air Pollution Nowcasting Global Nest: the Int. J. Vol 2, No 3, pp 281-292,
- Boubel, R.W., Fox, D.L., Turner, D.B., Stern, A.C., (2006) Fundamentals of Air Pollution. USA.
- Boznar, M., Lesjak, M. and Mlakar, P.: (1993) ‘A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain’, Atmosph. Environ. B27(2), 221–230.
- Bridgman, H.A., Davies, T.D., Jickells, T., Hunova, I., Tovey, K., Bridges, K., Surapipith, V., (2002). Air pollution in the Krusne Hory region, Czech Republic during the 1990s. Atmospheric Environment 36, 3375–3389
- Collet, R.S., Oluyemi, K., (1997). Air quality modeling: a technical review of mathematical approaches. Meteorological Applications 4, 235–246.
- Comrie, A. C.: (1997) ‘Comparing neural networks and regression models for ozone forecasting’, J. Air Waste Manage. 47, 653–663.
- Croxford B, Penn A, Hillier B (1996) Sci Total Environ 189/190:3–9
- Dahe Jianga, Yang Zhanga, Xiang Hua, Yun Zenga, Jianguo Tanb, Demin Shaob (2004) Progress in developing an ANN model for air pollution index forecast. Atmospheric Environment 38 7055–7064
- Devlet İstatistik Enstitüsü Nüfus istatistikleri(2000)
- Eagleman Joe R. (1991) Air Pollution Meteorology, Trimedia Publishing Company, 1991
- Eğrioğlu Erol, Aladağ Çağdaş Hakan Yapay Sinir Ağları Ve Arima Modellerinin Melez Yaklaşımı İle Zaman Serilerinde Öngörü Hacettepe Üniversitesi, Fen Fakültesi, İstatistik Bölümü, Ankara
- EPA (1989) National Air Quality and Emssion Trends Report 1987
- Ertürk F., Karaca M., Tayanç M., Saral A., (1995), "İbtanbul'da Hava Kirliliği Haritasının Çıkarılması ve Doğalgaz Kullanımına Öncelik Verilecek Bölgelerin Tespiti", Araştırma Projesi, İstanbul Büyük Şehir Belediyesi, Çevre Koruma ve Geliştirme Daire Başkanlığı.
- Gardner M.W., Dorling S.R., (1998), “Artificial Neural Networks (The Multi Layer Perceptron) – A Review of Applications in the Atmospheric Sciences”, Atm. Env., Vol.32, No.14/15,, pp.2627-2636.
- Gardner M.W., Dorling S.R. (1999) Neural network modelling and prediction of hourly Nox

and NO₂ concentrations in urban air in London Atmospheric Environment 33 709-719

Giuseppe Nunnari, Stephen Dorling, Uwe Schlink, Gavin Cawley, Rob Foxall, Tim Chatterton (2004) Modelling SO₂ concentration at a point with statistical approaches Environmental Modelling & Software 19 887–905

Grivas G., Chaloulakou A. (2006) Artificial neural network models for prediction of PM₁₀ hourly concentrations, in the Greater Area of Athens, Atmospheric Environment 40 1216–1229

Hien P.D., Bac V.T., Tam H.C., Nhan D.D., Vnh L.D., Influence of meteorological conditions on PM_{2.5} and PM_{2.5}–PM₁₀ concentrations during the monsoon season in Hanoi, Vietnam, Atmospheric Environment 36 (2002) 3473–3484.

İgdaş (2006), İstanbul ili doğalgaz kullanım verileri

İncecik, S., (1994). Hava Kirliliği Kitabı, İ.T.Ü Gümüşsuyu Mat., s. 93

Ivanka Videnova, Dimitar Nedialkov, Maya Dimitrova, and Silvia Popova (2006) NEURAL NETWORKS FOR AIR POLLUTION NOWCASTING Applied Artificial Intelligence, 20:493–506

Jaakko Kukkonen, Ari Karppinen, Leena Wallenius, Juhani Ruuskanen, Toni Patama, Mikko Kolehmainen, Stephen Dorling, Rob Foxall, Gavin Cawley, Danilo Mandic, Tim Chatterton, Mindaugas Zickus And Alison Greig Evaluation Of Neural Network, Statistical And Deterministic Models Against The Measured Concentrations Of No₂, Pm₁₀ And Pm_{2.5} In An Urban Area 8th Int. Conf. on Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes

Khoder, M.I., (2002). Atmospheric conversion of sulfur dioxide to particulate sulfate and nitrogen dioxide to particulate nitrate and gaseous nitric acid in an urban area. Chemosphere 49, 675–684.

Kolehmainen Mikko, Martikainen Hannu, Hiltunen Teri, Ruuskanen Juhani (2000) Forecasting Air Quality Parameters Using Hybrid Neural Network Modelling Environmental Monitoring and Assessment 65: 277–286,.

Larssen S, Adams ML, Barrett KJ, Bolscher M, de Leeuw F, Pulles T (2003) Air pollution in Europe 1990–2000, topic report no 4/2003, European Environment Agency, Copenhagen

Lippman, R. P., (1987), "An Introduction to Computing with Neural Nets," IEEE ASSP

Lu W. Z., Wang W. J., Wang X.K., Xu Z. B., Leung A. Y. T. (2003) Using Improved Neural Networkmodel To Analyze Rsp, Nox And No₂ Evals In Urban Air In Hong Kong Environmental Monitoring and Assessment 87: 235–254,

Marra S., Morabito F.C., Senior Member, IEEE, M. Versaci (2003) Neural Networks and Cao's Method: a Novel Approach for Air Pollutants Time Series Forecasting 0-7803-7898-9/03 IEEE

Mayer, H., (1999). Air pollution in cities. Atmospheric Environment 33, 4029–4037.

Mok K.M., Tam S.C. (1998) Short-term prediction of S₀₂ concentration in Macau with artificial neural networks Energy and Buildings 28 279-286

Nagendra S.M. Shiva, Khare Mukesh (2006) Artificial neural network approach for modelling nitrogen dioxide dispersion from vehicular exhaust emissions Ecological Modelling 190 99–115

Nastaran Hashemi (2004) Effects of Artificial Neural Network Speed-Based Inputs on Heavy-Duty üksek Lisans Tezi, Department of Mechanical and Aerospace Engineering, West Virginia University, 2004

Pfeiffer Heiko (2006) Neural Modelling of the Spatial Distribution of Air Pollutants A new method developed considering as example Cyprus Doktora Tezi, Institut für Geographie der Universität Stuttgart,

Perez Patricio, Reyes Jorge (2001) Prediction of Particulate Air Pollution using Neural Techniques Neural Comput & Applic 10:165–171 2001

Reich S.L., Gomez D.R., Dawidowski L.E. (1999) Artificial neural network for the identification of unknown air pollution sources Atmospheric Environment 33 3045-3052

Robert R. Jensen, Shankar Karki, Hossein Salehfar (2004) Artificial neural network-based estimation of mercury speciation in combustion flue gases Fuel Processing Technology 85 451– 462

Saral A. (2000) Hava Kirliliğinin Yapay Sinir Ağları ile Modellenmesi ve Tahmini Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul, 2000

Şen, O., 1996. The effect of Aircraft Engine Exhaust Gases on the Environment, Bulletin of the Technical University of İstanbul, V.49, No.3-4, 593-605.

Turalioğlu F. Sezer , Nuhoğlu Alper, Bayraktar Hanefi (2005) Impacts of some meteorological parameters on SO₂ and TSP concentrations in Erzurum, Turkey Chemosphere 59 1633–1642

Toros Hüseyin (2000) İstanbul'da Asit Yağmurları, Kaynakları Ve Etkileri Doktora Tezi İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Meteoroloji Mühendisliği, 2000

Viott P. i , Liuti G., Genova P. Di (2002) Atmospheric urban pollution: applications of an artificial neural network (ANN) to the city of Perugia Ecological Modelling 148 27–46

Wark K., Warner C.F., (1981) "Air Pollution, Its Origin And Control", 2nd. Edition, Harper and Row Publishers, New York.

Wesolowski Marek . Suchacz Bogdan . Halkiewicz Jan (2006) The analysis of seasonal air pollution pattern with application of neural networks Anal Bioanal Chem 384: 458–467

Yildirim Yilmaz, Bayramoglu Mahmut (2006) Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldak. Chemosphere 63 1575–1582

Ziomass, I.C., Dimitrios, M., Christos, S.Z., Alkiviadis, F.B., (1995). Forecasting peak pollutant levels from meteorological variables. Atmospheric Environment 29 (24), 3703–3711.

ÖZGEÇMİŞ

Doğum tarihi 23.03.1980

Doğum yeri İstanbul

Lise 1990-1997 Kadıköy Anadolu Lisesi

Lisans 1999-2004 Yıldız Üniversitesi Mühendislik Fak.
Çevre Mühendisliği Bölümü

Yüksek Lisans 2004-2006 Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü
Çevre Müh. Anabilim Dalı