

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**METEOROLOJİK PARAMETRELERİN ATMOSFERİK UÇUCU ORGANİK
BİLEŞİKLERİ ÜZERİNE ETKİSİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

NEVRİN ALTINKUM

**YÜKSEK LİSANS TEZİ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
YRD. DOÇ. DR. SELAMİ DEMİR**

İSTANBUL, 2013

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**METEOROLOJİK PARAMETRELERİN ATMOSFERİK UÇUCU ORGANİK
BİLEŞİKLERİ ÜZERİNE ETKİSİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

Nevrin ALTINKUM tarafından hazırlanan tez çalışması 10/06/2013 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Çevre Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Yrd. Doç. Dr. SELAMİ DEMİR
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Yrd. Doç. Dr. SELAMİ DEMİR
Yıldız Teknik Üniversitesi

Prof. Dr. KADİR ALP
İstanbul Teknik Üniversitesi

Doç. Dr. ARSLAN SARAL
Yıldız Teknik Üniversitesi

Bu alıřma, Trkiye Bilim ve Teknoloji Arařtırma Kurumu'nun (TBİTAK) 110Y163 numaralı projesi ile desteklenmiřtir.

ÖNSÖZ

Günümüzde sanayileşmenin ve motorlu araçların kullanımının artması ile bu kaynaklardan yayılan UOB emisyonları çevre ve halk sağlığı açısından ciddi sorunlara yol açabilmektedir. Bu nedenle UOB'lerin atmosferdeki seviyelerinin bilinmesi ve gelecekteki konsantrasyonlarının belirlenmesi önemli bir hal almaktadır. Daha önceki çalışmalarda uçucu organik bileşiklerin kirlilik seviyelerinin ve kaynaklarının belirlenmesi ile ilgili çalışmalar yapılmıştır. Ancak literatürde, UOB'lerin yapay sinir ağları ile modellenmesiyle ilgili daha önceden yapılmış bir çalışma bulunmadığı için bu çalışmayla, hem literatürdeki bu eksikliği bir nebze olsun kapatmasını hem de gelecek çalışmalara örnek teşkil etmesini amaçlamaktayım.

Herşeyden önce, lisans ve yüksek lisans öğrenimim boyunca ve tezimin hazırlanması sırasında emeğini esirgemeyen, çalışmalarımda banayol gösterip destek veren değerli danışmanım Sayın Yrd. Doç. Dr. Selami DEMİR' e teşekkürlerimi bir borç bilirim.

Tez çalışmam boyunca bana bilgi ve deneyimleri ile yol gösterip yardımlarını esirgemeyen ve değerli görüşleri ile çalışmama katkılar sağlayan kıymetli hocam Sayın Doç. Dr. Arslan Saral'a teşekkürlerimi sunarım.

Yapay sinir ağları konusundakiengin bilgisiyle çalışmamı yönlendiren ve sorularıma her zaman içtenlikle cevap veren değerli hocam Sayın Doç. Dr. Kaan Yetilmezsoy'a içten teşekkürlerimi sunarım.

Çalışmalarım sırasında değerli görüşlerini ve manevi desteklerini esirgemeyen Sayın Arş. Gör. Levent KUZU'ya, Gülsüm SUMMAK'a, Hatice ÇOLTU'ya ve Aigerim MUKHANBETKHALI'ye teşekkürlerimisunarım.

Her zaman yanımda olan ve desteklerini hiçbir zaman esirgemeyen sevgili arkadaşlarım, Deniz ERSOY'a, İrem ESEN'e, Sina YILANKAYA'ya ve özellikle Şeyma YAZICI'ya teşekkürlerimi bir borç bilirim.

Tüm hayatım boyunca beni maddi-manevi olarak destekleyen ve her koşulda yanımda bulunan anne ve babama en içten teşekkürlerimi ve sevgilerimi sunarım.

Mayıs, 2013

Nevrin ALTINKUM

İÇİNDEKİLER

	Sayfa
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
ÇİZELGE LİSTESİ	xii
ÖZET	vi
ABSTRACT	viii
BÖLÜM 1	1
GİRİŞ	1
1.1 Literatür Özeti	1
1.1.1 Uçucu Organik Bileşiklerin Çevresel Etkileri	2
1.1.1.1 Troposferik Ozon, Stratosferik Ozon ve İkincil Aerosol Oluşumu	2
1.1.1.2 Sağlık Etkileri	5
1.1.2 Uçucu Organik Bileşiklerin Atmosferik Seviyeleri	6
1.1.3 Uçucu Organik Bileşik Kaynakları	7
1.1.3.1 Antropojenik Kaynaklar	7
1.1.3.2 Doğal Kaynaklar	8
1.1.3.3 Uçucu Organik Bileşiklerin Modellenmesi	10
1.1.4 Yasal Düzenlemeler	12
1.2 Tezin Amacı	13
1.3 Orijinal Katkı	14
BÖLÜM 2	15
ÇALIŞMA ALANI, ÖLÇÜM VE MODELLEME YÖNTEMİ	15
2.1 Çalışma Alanı	15
2.2 Yapay Sinir Ağının Tanımı ve Tarihçesi	16
2.2.1 Biyolojik Sinir Hücresi ve YSA	17
2.3 Yapay Sinir Ağının Özellikleri	19
2.3.1 Doğrusal Olmama	20
2.3.2 Öğrenme	20
2.3.3 Genelleme	20

2.3.4	Uyarlanabilirlik	20
2.3.5	Hata Toleransı	21
2.3.6	Analiz ve Tasarım Kolaylığı	21
2.4	Yapay Sinir Ağlarının Avantaj ve Dezavantajları	21
2.5	Yapay Sinir Ağının Yapısı	22
2.5.1	Girdi Katmanı	23
2.5.2	Ara Katman (Gizli Katman)	23
2.5.3	Çıktı Katmanı	23
2.6	Yapay Sinir Ağlarının İşlemci Elemanları	24
2.6.1	Girdiler	25
2.6.2	Ağırlıklar	25
2.6.3	Birleştirme Fonksiyonu	25
2.6.4	Aktivasyon Fonksiyonları	25
2.6.4.1	Doğrusal Fonksiyon	26
2.6.4.2	Basamak Fonksiyon	26
2.6.4.3	Sigmoid Aktivasyon Fonksiyonu	27
2.6.4.4	Tanjant Hiperbolik Aktivasyon Fonksiyonu	27
2.6.5	Çıktılar	28
2.7	Yapay Sinir Ağlarının Sınıflandırılması	29
2.7.1	Yapılarına Göre Yapay Sinir Ağları	29
2.7.1.1	İleri Beslemeli Ağlar	29
2.7.1.2	Geri Beslemeli Ağlar	35
2.7.2	Öğrenme Algoritmalarına Göre Sınıflandırılma	36
2.7.2.1	Danışmanlı Öğrenme (Supervised Learning)	36
2.7.2.2	Danışmansız Öğrenme (Unsupervised Learning)	37
2.7.2.3	Destekleyici Öğrenme	38
2.7.3	Uygulamaya Göre Yapay Sinir Ağlarının Sınıflandırılması	38
2.7.3.1	Çevrimiçi (On-line) Öğrenme Kuralları	38
2.7.3.2	Çevrimdışı (Off-line) Öğrenme Kuralları	39
2.7.4	Öğrenim Kurallarına Göre Yapay Sinir Ağlarının Sınıflandırılması	39
2.7.4.1	Hebb Kuralı	39
2.7.4.2	Delta Kuralı	40
2.7.4.3	Kohonen Kuralı	40
2.7.4.4	Hopfield Kuralı	40
2.8	Yapay Sinir Ağının Tasarımı	40
2.8.1	Ağın Eğitim ve Test Setlerinin Seçimi	41
2.8.2	YSA Ağ Yapısının Seçimi	42
2.8.3	Yapay Sinir Ağı Algoritmasının Seçimi	43
2.8.4	Ara Katman Sayısının Seçimi	43
2.8.5	Nöron Sayısını Belirlenmesi	43
2.8.6	Aktivasyon Fonksiyonun Seçimi	43
2.8.7	Normalizasyon	44
2.9	Çevre Mühendisliğinde Yapay Sinir Ağları İle İlgili Yapılan Çalışmalar	44

BÖLÜM 3	46
BULGULAR VE TARTIŞMA.....	46
3.1 Yapay Sinir Ağları İle Modellenmesi.....	46
3.1.1 Meteorolojik Parametreler	47
3.1.1.1 Sıcaklık.....	48
3.1.1.2 Rüzgar Hızı ve Yönü.....	48
3.1.1.3 Nem.....	50
3.2 Yapay Sinir Ağının Sonuçları	51
BÖLÜM 4.....	76
SONUÇLAR VE ÖNERİLER	76
KAYNAKLAR	80
ÖZGEÇMİŞ	85

KISALTMA LİSTESİ

ÇKA	Çok katmanlı algılayıcı (Multi Layer Perceptron)
EEA	Avrupa Çevre Ajansı (European Environment Agency)
NMHC	Metan harici hidrokarbonlar (Non-methane hydrocarbons)
NOx	Azot oksitleri (Nitrogen oxides)
UOB	Uçucu organik bileşik (Volatile organic compounds)
USEPA	Amerikan Çevre Koruma Ajansı (US Environmental Protection Agency)
YSA	Yapay sinir ağları (Artificial Neural Network)

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	Uçucu organik bileşiklerin emisyon kaynakları.....10
Şekil 2.1	YTÜ Davutpaşa Kampüsü ve civar bölgesi16
Şekil 2.2	Merkezi sinir ağının yapısı18
Şekil 2.3	Biyolojik Sinir Hücresi19
Şekil 2.4	YSA modeli23
Şekil 2.5	Yapay sinir hücresi.....24
Şekil 2.6	Doğrusal aktivasyon fonksiyonu26
Şekil 2.7	Basamak fonksiyonu.....27
Şekil 2.8	Sigmoid fonksiyonu27
Şekil 2.9	Tanjant hiperbolik fonksiyonu28
Şekil 2.10	İleri beslemeli ağlar için blog diyagramı30
Şekil 2.11	Çok katmanlı algılayıcının topolojik yapısı31
Şekil 2.12	LVQ ağının topolojik yapısı35
Şekil 2.13	Geri beslemeli ağların blog gösterimi36
Şekil 2.14	Danışmanlı öğrenme yapısı.....37
Şekil 2.15	Danışmansız öğrenme yapısı37
Şekil 2.16	Destekleyici öğrenme yapısı38
Şekil 3.1	Günlük ölçülen sıcaklık değerleri48
Şekil 3.2	Ölçüm sayısına göre rüzgar hızları49
Şekil 3.3	Rüzgar yönleri ve sektörleri50
Şekil 3.4	Ölçüm sayısına göre nem yüzdesi50
Şekil 3.5	Kullanılan yapay sinir ağının topolojisi51
Şekil 3.6	Doğrulamalı eğitimde en iyi model sonucu52
Şekil 3.7	Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri, 2,2,4-trimetilpentan(5), 2metilpenatn(10), benzen(18), hekzan(22)54
Şekil 3.8	Modelleme sonucu en iyi korelasyona sahip UOB türleri; (5) 2,2,4-trimetilpentan (10) 2metilpentan, (18) benzen, (22) hekzan55
Şekil 3.9	Girdi parametrelerinin 2,2,4 –trimetilpentan için hassasiyet analizi.....56
Şekil 3.10	2,2,4 trimetilpentan için ağ çıktı konsantrasyonlarının girdi parametreleri ile değişimi.....57
Şekil 3.11	Girdi parametrelerinin hekzan için duyarlılık analizi.....58
Şekil 3.12	Hekzan için ağ çıktı konsantrasyonlarının girdi parametreleri ile değişimi..60
Şekil 3.13	Benzen konsantrasyonlarının girdi parametreleri ile değişimi.....61
Şekil 3.14	Benzen için ağ çıktı değerlerinin girdi parametreleri ile değişimi62

Şekil 3.15	2metilpentan konsantrasyonlarının girdi parametreleri ile değişimi63
Şekil 3.16	2metilpentan için ağ çıktı değerlerinin girdi parametreleri ile değişimi64
Şekil 3.17	Modelleme sonucu en düşük korelasyona sahip UOB türleri; (17) undekan (29) pentan, (25) m&p-ksilen, (12) 3metilpentan.....65
Şekil 3.18	Tahmin ve ölçüm sonucu konsantrasyonların zaman serili grafikleri, undekan(17), pentan(29), m&p-ksilen(25), 3-metilpentan(12)66
Şekil 3.19	İstenen ve tahmin edilen UOB konsantrasyonları arasındaki korelasyon grafikleri.....67
Şekil 3.20	Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri.....71

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 1.1	Dünyada troposferik ozon seviyeleri.....4
Çizelge 1.2	Bazı UOB'lerin inkremental reaktiviteleri.....5
Çizelge 1.3	Global hidrokarbonların kaynak tahmini.....9
Çizelge 1.4	HKDYY'nde izlenmesi öngörülen ozon öncül maddeleri listesi12
Çizelge 1.5	USEPA ozon öncül maddeleri listesi13
Çizelge 2.1	Biyolojik sınır hücresi ve yapay sınır hücresi karşılaştırılması19
Çizelge 2.2	Ağ türleri ve başarılı oldukları alanlar42
Çizelge 3.1	UOB türleri ve ortalama konsantrasyonları.....46
Çizelge 3.2	Meteorolojik parametrelerin değişim aralıkları48
Çizelge 3.3	UOB türleri ve numaraları52
Çizelge 3.4	UOB türleri için mutlak ve yüzdelik hassasiyet analizi sonuçları74
Çizelge 4.1	33 UOB türü için kurulan en iyi model yapıları77

**METEOROLOJİK PARAMETRELERİN ATMOSFERİK UÇUCU ORGANİK
BİLEŞİKLERİ ÜZERİNE ETKİSİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

Nevrin ALTINKUM

Çevre Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. Selami DEMİR

Atmosferik uçucu organik bileşikler (UOB), günümüzde gittikçe artan ortam konsantrasyonları ile birçok araştırmacının ilgisini çekmektedir. Özellikle, motorlu taşıtların kullanımının artması ve sanayinin gelişmesi ile UOB emisyonlarına neden olan kaynaklar gün geçtikçe artmaktadır. Bu UOB emisyonları, halk ve çevre sağlığı üzerine birçok olumsuz etkiye sahip olduğu daha önce yapılan çalışmalar ile saptanmıştır. Uzun süre maruziyet sonucunda canlılarda kanserojen ve mutajen etkiye sahip olabilirler. Atmosferde bir dizi fotokimyasal reaksiyona girerek ikincil kirleticilerinin oluşumuna neden olurlar. Oluşan bu kirleticilerin en önemlisi şüphesiz ki troposferik ozondur.

UOB'ler ilgili geçmiş yıllarda birçok çalışma yapılmıştır. Bu çalışmalarda, daha çok olarak uçucu organik bileşiklerin atmosferik seviyelerinin belirlenmesi ve kaynak tespitleri üzerine yoğunlaşmıştır. Bununla birlikte UOB'lerin modellenmesi ile ilgili bir çalışmaya daha önceden rastlanmamıştır. Bu çalışmada Yapay Sinir Ağları kullanılarak atmosferik uçucu organik bileşiklerin modellenmesi yapılmış ve meteorolojik parametrelerin UOB konsantrasyonları üzerine olan etkileri incelenmiştir. 33 adet farklı uçucu organik bileşik için 33 ayrı yapay sinir ağı modeli oluşturulmuştur. Ağ yapısı, bir girdi katmanı, bir gizli katman ve bir de çıktı katmanından oluşmaktadır. Girdi parametreleri olarak, sıcaklık, nem, rüzgar hızı ve yönü, ölçümün yapıldığı gün ve saat alınmıştır. Saatlik ortalama VOC konsantrasyonunu tahmin etmek için ileri beslemeli YSA-ÇKA modeli 207 adet ölçüm sonucuna uygulanmıştır. Gizli katman nöron sayılarının ise yapılan denemeler sonucu 10 ila 20 nöron arasında olmasının daha iyi bir tahmin sonucu oluşturduğu görülmüştür. Toplam fonksiyonu olarak bütün ağ yapılarında

sigmoid fonksiyonu kullanılmıştır. Aktivasyon fonksiyonu olarak hiperbolik tanjant ya da doğrusal fonsiyonları kullanılmıştır. Öğrenme algoritması olarak Levenberg – Marquardt algoritması kullanılmıştır.

Yapılan denemeler sonucu en iyi sonucu veren ağ yapıları belirlenmiştir. 33 tür için korelasyon katsayıları 0.547 ile 0.818 arasında değişmektedir. Bu sonuç da, yapay sinir ağları modelinin atmosferik uçucu organik bileşiklerin modellemesinde başarılı olduğunu göstermektedir. En iyi sonucu veren dört türün korelasyon katsayıları şu şekildedir: 2,2,4 trimetilpentan (R: 0,81), benzen (R: 0.74), 2metilpentan (R: 0.78) ve hekzan (R: 0.70)'dir. En düşük korelasyon katsayıları ise, undekan(R:0.58), m&p-ksilen(R:0.595), pentan (R:0.47), o-ksilen(R:0.56) ve 3-metilpentan(R:0.54)'a aittir.

Girdi parametrelerinin konsantrasyonlar üzerine etkisi incelendiği zaman en çok etkileyen parametrelerin, sıcaklık nem ve rüzgar yönü olduğu görülmüştür. Nem arttıkça UOB konsantrasyonlarının azaldığı görülmektedir. Genel olarak sıcaklık artışıyla konsantrasyonların azaldığı görülmüştür. Ölçümün yapıldığı kampüsün çevresinde otogarın, işlek caddelerin ve çeşitli sanayi kollarının bulunması ve bu şekilde farklı kaynaklardan emisyon yayılmasından dolayı UOB'lerin modellenmesi zor olmaktadır ve kimi türlerde istenilen başarıya ulaşılamamaktadır..

Anahtar Kelimeler: Uçucu organik bileşikler, Yapay sinir ağları, Modelleme, Meteorolojik parametreler, ÇKA

ABSTRACT

MODELLING OF EFFECTS OF METEOROLOGICAL PARAMETERS ON ATMOSPHERIC CONCENTRATIONS OF VOLATILE ORGANIC COMPOUNDS USING ARTIFICIAL NEURAL NETWORKS

Nevrin ALTINKUM

Department of Environmental Engineering

M.Sc Thesis

Advisor: Assist. Prof. Dr. Selami DEMİR

Atmospheric volatile organic compounds (VOCs) has been attracting gradually increasing interest of researchers due to the increase in their ambient concentrations. VOC concentrations has been gradually increasing as a result of urbanization and industrialization. It has been shown by previous research studies that these VOCs pose adverse effects on human health and welfare. They have carcinogenic and mutagenic effects on living beings for long durations of exposure. Besides, they participate in a number of atmospheric photochemical reactions resulting in the formation of secondary pollutants, the most important of which is tropospheric ozone.

A great number of research papers have been dedicated to ambient VOCs in recent years. These studies focused on assessing ambient levels and determining sources of VOC species. Unfortunately, current literature lacks research studies related with neural modeling of ambient VOC concentrations. This dissertation presents the results of a modeling study in which effects of meteorological factors on ambient levels of VOCs were investigated through artificial neural network (ANN) approach. Thirty-three ANN topologies were constructed for thirty-three VOC species. The network topologies consisted of an input layer, a hidden layer, and an output layer. The input parameters were ambient temperature, relative humidity, wind speed, wind direction, and day-hour of sampling. A multilayer perceptron, feed-forward artificial neural network (ANN-MLP) model was applied to all 207 measurement results for thirty-three VOC

species. Trial-and-error schemes showed that 10 to 20 neurons in the hidden layer produces best results. Sigmoid function was used for all neurons in the hidden layer, while the activation function was one of hyperbolic tangent or purelin functions. Levenberg-Marquart algorithm was applied as the learning algorithm.

The best network topologies were determined through a great number of trials. The correlation coefficients for thirty-three species ranged from 0.547 to 0.818, which indicates ANN successfully predicts ambient concentrations of a number of VOCs. The best correlation coefficients were obtained for 2,2,4-trimethylpentane (R:0.81), benzene (R: 0.74), 2-methylpentane (R: 0.78), and hexane (R: 0.70), while the correlation coefficients for undecane (R: 0.58), m&p-xylene (R: 0.595), pentane (R: 0.47), o-xylene (R: 0.56), and 3-methylpentane (R: 0.54) were the lowest ones.

Sensitivity analyses were also performed for each VOC species. The results showed that ambient temperature, relative humidity, and wind direction are the most effective input parameters. Ambient VOC concentrations were inversely proportional to the relative humidity, that's, the concentration decreases with increasing humidity. In general, an increase in ambient temperature lead to a decrease in VOC concentration. Since the measurements were taken within Davutpaşa Campus of Yildiz Technical University and the campus is surrounded by a great number of industrial facilities, highways and connection roads with high traffic loads, and the Central Bus Station of Istanbul, it is somewhat difficult to efficiently predict the VOC concentrations in such a complex airshed, and the results are considered as a success.

Key Words: Volatile organic compounds, Artificial Neural Network, Modelling, Meteorological factors, MLP

1.1 Literatür Özeti

Günümüzde sanayileşmenin ve insan faaliyetlerinin artması sonucu hava kirliliği önemli bir sorun haline gelmiştir. Atmosfere kirletici kaynaklardan yayılan emisyonların başındakükürtdioksit (SO_2), azotoksitler (NO_x), hidrokarbonlar (HCs), karbonmonoksit (CO) ve partiküller bulunur[1]. Bu kirleticiler arasında bulunan metan olmayan hidrokarbonlar (NMHCs) ya da en genel adlarıyla 'Uçucu Organik Bileşikler (UOB)' hava kirleticilerinin en önemli sınıflarından birini teşkil ederler. Uçucu Organik Bileşikler (UOB), antropojenik ve doğal kaynaklardan atmosfere yayılan önemli bir kirletici grubudur[2]. Uçucu organik bileşikler, normal oda sıcaklığında buharlaşabilen, genellikle karbon ve hidrojenden oluşan bileşiklerdir. UOB'ler, alkanlar (etan, propan, bütan, pentan, hekzan, heptan, oktan, nonan ve dekan), sikloalkanlar (siklopropan, siklobütan, siklobütan, siklopentan vb.), alkinler (asetilen, propin, bütin vb.), alkenler (etilen, propen, bütin vb.), aromatikler (benzen, toluen, stiren, ksilen vb.) ve bunların çok sayıdaki türevlerinden oluşur [3]. Uçucu organik bileşikler, düşük kaynama noktaları sahip bileşiklerdir. Kaynama sıcaklıkları 50°C ila 250°C lere kadar değişir[4].

Atmosferde meydana gelen kimyasal olaylarda, Uçucu Organik bileşikler önemli rol oynarlar. Çünkü organik maddeler, atmosferde reaksiyona girsinler ya da girmesinler kimyasal reaksiyonların çekirdeğini oluştururlar [5].

1.1.1 Uçucu Organik Bileşiklerin Çevresel Etkileri

Uçucu organik bileşikler uzun yıllardır çevre üzerindeki olumsuz etkileri nedeniyle ilgi görmektedirler. Uçucu organik bileşiklerin çevreye olan etkileri şu şekilde sıralanabilir;

1) Troposferde yer seviyesinde ozon oluşumuna neden olur, 2) Stratosferde ozon azaltıcı reaksiyonlarda yer alır, 3) Fotokimyasal reaksiyonlarda yer alır, 4) Küresel ısınmayı arttırır ve dünya üzerinde birikim yaparlar[6].

1.1.1.1 Troposferik Ozon, Stratosferik Ozon ve İkincil Aerosol Oluşumu

İki tür ozon vardır. Bunlardan biri troposferik ozon diğeri ise stratosferik ozondur. Stratosferik ozon insan sağlığı için gereklidir. Güneşten gelen zararlı ışınları filtre ederek dünyaya ulaşmasını engeller. Stratosfer tabakasında, genellikle biyogenik kaynaklı olarak oluşur ve kalınlığı yaklaşık olarak 10-30 mil arasındadır. Stratosferik ozonun azalması insan ve çevre sağlığı açısından son derece zararlıdır. Organik bileşiklerden krom ve brom içerenler, stratosferik fotolize ve hidroksil radikallerinin yıkımına yol açarlar. Dolayısıyla ozonu tahrip edici bileşiklerin ortaya çıkmasına neden olurlar. Bu olay, stratosferdeki ozon konsantrasyonunun azalmasına ve ozon tabakasının incelmesine yol açar. Bu uçucu organik bileşiklerden ozon katmanının incelmesine neden olan en önemli bileşikler KloroFloroKarbon (CFC) bileşikleridir. Uçucu organik bileşik emisyonu ile oluşan en önemli hava kirleticileri troposferik ozon ve ikincil kirleticilerdir. Ozon, kirlenmemiş havada 10 – 50 ppbv aralığında bulunan doğal bir atmosferik bileşendir [7]. Yer seviyesinde ozon (O_3), azot oksitlerin ve uçucu organik bileşiklerinin güneş ışığı varlığında kompleks reaksiyonları sonucu oluşmaktadır. Bu reaksiyonlar, atmosferde ozon ve ikincil kirleticilerin hızlı birikimine neden olurlar. Kısa sürelerde, kirleticiler maddelerin birikimi çok hızlı bir biçimde olabilir ve insan sağlığı, bitki örtüsü üzerinde olumsuz etkileri gözlenebilen fotokimyasal sis vakaları görülebilir [6]. Fosil yakıtların yakılması sonucu ortaya çıkan azotdioksit (NO_2), güneş ışığını absorbe ederek oksijen molekülü varlığında troposferik ozon oluşumuna neden olurlar[8]. Yoğun trafiğin bulunduğu güneşli ve sıcak şehirlerde, ozon oluşumu diğer şehirlere göre daha fazladır. Özellikle hafta içi sabah saatlerinde taşıt emisyonlarından kaynaklanan yüksek NO_x konsantrasyonlarından dolayı ozon oluşumu daha fazla görülmektedir.



Oluşantroposferik ozon, akşam saatlerinde havada bulunan NO molekülü ile birleşerek azotdioksit (NO₂) ve oksijen atomunu oluşturur.



Ozon oluşum mekanizması, [NO₂]/[NO] fotoliz oranına bağlıdır. Eğer reaktif UOB'ler olmasaydı ozon oluşumu büyük oranda olmazdı. UOB varlığında, onların reaktif formları NO'leri tüketirler ya da NO'den NO₂'e dönüşümünü sağlarlar ve bu nedenle O₃ oluşumu artar. Yer seviyesinde ozon oluşumunda çok çeşitli reaksiyonlar etkili olsa da şu şekilde özetlenebilir;



Ozon artış hızı, UOB'lerin bulunma miktarına, UOB'lerin başlangıç reaksiyonlarının hızına, OH radikallerinin seviyelerine ve diğer türlerin UOB'ler ile reaksiyon verebilmelerine bağlı olarak artış göstermektedir. Yeterli NO_x varlığında ozon oluşumu uzun süre devam eder[9]. Atmosferik UOB'ler hidroksil radikalleri ile tepkimeye girerek peroksi radikallerini oluştururlar. Oluşan bu peroksi radikalleri ise azot monoksiti azot dioksite yükseltirler [8].



Normalde havada kirlilik yokken O_3 konsantrasyonu düşüktür. Bunun nedeni, atmosferde bulunan azot monoksitlerin ozon ile reaksiyona girip azot dioksit ve oksijen atomu oluşturmalarıdır.



Bazı şehirlerdeki troposferik ozon seviyeleri önceki çalışmalardan derlenmiş ve Çizelge 1.1 'de sunulmuştur.

Çizelge 1.1 Dünyada troposferik ozon seviyeleri

Şehir	Konsantrasyon	Örnekleme Periyodu
Shangai (Çin) [12]	12-35 ppbv	Saatlik ortalama
Katmandu (Nepal) [50]	11.8-100 pbb	8 saatlik ortalama
Pearl River Delta (Çin) [51]	36-70 pbb	Maks. Saatlik (2006)
	37-88 pbb	Maks. Saatlik (2007)
Texas (Amerika) [52]	70-108 ppbv	Günlük
Voss (Norveç) [52]	17-78 pbb	Günlük
Yarner Wood (İngiltere) [52]	2-95 pbb	Günlük

Her uçucu organik bileşik aynı oranda ozon oluşumunu teşvik etmezler çünkü her UOB'in azot monoksit ile reaksiyona giren radikaller üzerinde reaktivite oranları ve farklı etkileri vardır aynı değildir[10]. Bu farklı etkileri belirlemek için inkremental reaktivite metodu geliştirilmiştir. İnkremental reaktivite, UOB konsantrasyonundaki birim artışa karşılık oluşan ozon konsantrasyonundaki değişimin birim artışa oranıdır[53].Aromatiklerin inkremental reaktiviteleri genellikle daha yüksektir. Bazı UOBlerin farklı UOB:NO_x oranlarındaki inkremental reaktiviteleri Çizelge 1.2' de gösterilmiştir.

Çizelge 1.2 Bazı UOBlerin inkremental reaktiviteleri [53].

Bileşik	UOB:NO _x oranı			
	4:1	8:1	16:1	40:1
Etan	0,024	0,041	0,018	0,007
n-bütan	0,100	0,160	0,069	0,019
n-oktan	0,068	0,120	0,027	-0,031
Etilen	0,850	0,900	0,330	0,140
Propilen	1,280	1,030	0,390	0,140
t-2-büten	1,420	0,970	0,310	0,054
Benzen	0,038	0,330	-0,002	-0,002
Toluen	0,260	0,160	-0,036	-0,051
m-ksilen	0,980	0,630	0,091	-0,025
Formaldehit	2,420	1,200	0,320	0,051
Asetaldehit	1,340	0,830	0,290	0,098
Benzaldehit	-0,110	-0,270	-0,400	-0,400
Metanol	0,120	0,170	0,066	0,029
Etanol	0,180	0,220	0,065	0,006
Kentsel karışım	0,410	0,320	0,088	0,011

1.1.1.2 Sağlık Etkileri

Uçucu organik bileşikler, hem doğrudan kendileri hem de oluşturdıkları ikincil kirleticiler ile insan sağlığı açısından birçok olumsuz etkiye sahiptir. UOB'lerin insan sağlığına ve ekolojiye olan etkileri temas süresine ve maruziyet dozuna bağlıdır. Sanayileşmiş şehirlerde yanma emisyonlarından dolayı ortaya çıkan azot dioksit ve ozonun güneş ışığı altında reaksiyona girmeleri ile oluşan fotokimyasal sis insan, hayvan ve bitki sağlığı üzerinde olumsuz etkilere sahiptir. Uçucu organik bileşiklerden olan alkanların en önemli etkileri, mukus membranlarına, çözünebilir yağlar ve kolesterol üzerinedir. Düşük konsantrasyonlarında alkanlar, ciltte kaşıntıya, kızarıklıklara, şişmelere bronşitlerde ve trakelerde basit iritasyonlara neden olmaktadır. Yüksek konsantrasyonlarında, deride akut egzamalara, akciğerde ödemlere, beyinde kısmi felçlere ve dolayısıyla boğulmalara ve şoklara neden olabilmektedirler. Alkenlerin cis izomerleri, kusmalara, mide bulantısına ve halsizliğe yol açmaktadır. Yüksek konsantrasyonlarında benzenlerin solunmaya devam edilmesi durumunda birkaç dakika içinde ölümcül hale gelmektedir ve daha düşük konsantrasyonlarında, bir saat içinde akur zehirlenmeye yol açmaktadır [4]. Birçok UOB türünün etkileri hala tam olarak bilinmemektedir ancak yapılan çalışmalar sonucu,

kansere, çocuklarda ve yeni doğanlarda gelişim bozukluklarına, hayvanlarda doğurganlıkların azalmasına, su ürünlerinin üretiminde azalmalara neden olduğu görülmüştür [6].

1.1.2 Uçucu Organik Bileşiklerin Atmosferik Seviyeleri

Endüstrileşmenin artmasıyla UOB seviyelerinde son yıllarda önemli artışlar görülmektedir. Yapılan araştırmalar sonucu uçucu organik bileşiklerin insan ve çevre sağlığı üzerinde çeşitli olumsuz etkilere sahip olduğu görüldüğünden dolayı bu seviyelerin izlenilmesi ve bunun sonucunda maruziyet seviyelerinin belirlenmesi önemli bir durum haline gelmiştir. Uçucu organik bileşiklerin konsantrasyonların belirlemek amacıyla çeşitli çalışmalar yapılmıştır. Ting ve arkadaşlarının [11] yaptıkları çalışmada Mount Tai şehrinde, uçucu organik bileşik konsantrasyonlarını belirlemek amacıyla toplamda 60 adet örnek toplanmıştır ve bunların analitik yöntemlerle miktarsal analizleri yapılmıştır. Elde edilen sonuçlarda toplam UOB konsantrasyonları, 6.95 ± 5.71 ppb olarak bulunmuştur. Şangayda, Geng ve arkadaşları [12] tarafından yapılan çalışmada, kasım ayında yedi günlük periyotlarla iki hafta boyunca UOB ve O_3 konsantrasyonlarını belirlemek amacıyla ölçüm yapılmıştır. Yapılan ölçümler sonucunda, ilk periyotta (15-21 Kasım) konsantrasyonların ikinci periyoda (22-28 Kasım) göre daha düşük çıktığı görülmüştür. UOB konsantrasyonları ilk periyotta 30-50 ppbv şeklindeyken ikinci periyotta hızla değişerek 80-100 ppbv mertebelerine çıkmıştır. İki periyot da sonuçların farklı çıkmasının asıl sebebi olarak, bu periyotlar süresince farklı meteorolojik koşulların hakim olmasını göstermişlerdir. İlk periyotta hava bulutlu ve rüzgar hızı yüksek iken, ikinci periyotta hava açık ve rüzgar hızı düşüktür. Bu nedenle ikinci periyotta ozon konsantrasyonu daha yüksek çıkmıştır. Pakistan Karachi'de [1] yapılan çalışmada, 72 UOB türü için, 78 adet hava örnekleme alınmıştır. Metan ve etan seviyeleri diğer şehirlere göre daha yüksek çıkmıştır. Metan konsantrasyonu, 6.3 ppmv etan konsantrasyonu ise 93 ppbv olarak bulunmuştur. Benzen seviyeleri, 0.3-19 ppbv arasındadır. Wang ve Zhao[5] tarafından, Çin'in Nanjing kentinde yapılan çalışmada, beş farklı noktada 10 farklı UOB türü için ölçümler yapılmıştır. Çalışma sonunda, en yüksek konsantrasyon $19.8 \pm 10.3 \mu\text{g} \cdot \text{m}^{-3}$ ile toluene ait olduğu görülmüştür. Tolueni, $6.4 \pm 3.8 \mu\text{g} \cdot \text{m}^{-3}$ ile benzen takip etmektedir. Diğer türlerin konsantrasyonları

daha düşük olup birbirlerine yakındır. Chan ve arkadaşlarının Hong Kong (Çin)'da yaptıkları çalışmada [13], trafik etkisinin yoğun olduğu yol kenarlarında mikroçevrede uçucu organik bileşik konsantrasyonlarını incelemişlerdir. Özellikle toluen, benzen ve klorlu uçucu organik bileşik türleri üzerinde çalışmışlardır. Ortalama ve maksimum toluen konsantrasyonu sırasıyla, 74.9 ve 320 $\mu\text{g}/\text{m}^3$ olarak bulunmuştur. Benzen için bu değerler, 25.9 ve 128.6 $\mu\text{g}/\text{m}^3$ şeklinde bulunmuştur. Klorlu bileşiklerden trikloretilen ve tetrakloretilenin maksimum konsantrasyonları sırasıyla, 248.2 ve 144 $\mu\text{g}/\text{m}^3$ 'tür.

1.1.3 Uçucu Organik Bileşik Kaynakları

Uçucu organik bileşikler çeşitli kaynaklardan atmosfere atılabilmektedirler. Birçok UOB türü, boyamada, petrol ürünlerinde soğutmada, ilaç üretiminde kullanılan ve üretilen insan yapımı kimyasal bileşiklerdir. Genellikle yakıt emisyonlarında, solvent kullanımında, temizlik malzemelerinin kullanımında, biyokütle yakımlarının sonucunda atmosfere atılırlar[14]. Atmosferik UOB'lerin kaynakları, antropojenik ve doğal kaynaklar olarak ikiye ayrılırlar. Doğal kaynaklar bu emisyonların %69'unu oluştururken, antropojenik kaynaklar %31'ini oluşturmaktadır[15]

1.1.3.1 Antropojenik Kaynaklar

Çinin [16] 43 ayrı şehrinde yapılan çalışmada, atmosferdeki UOB emisyonlarına en önemli katkıda bulunan antropojenik kaynakların, yanma, akaryakıt buharlaşması olduğu saptanmıştır. En önemli antropojenik kaynaklardan biri de kırsal kesimlerde hasattan sonra tarlaların (biyokütlenin) yakımıdır. UOB 'leri içeren gaz emisyonlarının en önemli kaynağını hareketli kaynaklar oluşturmaktadır. Eten, asitilen, 1- bütlen, isobütlen, propan, propen, toluen, etilbenzen, m ve pksilen vs. bu emisyonlarda en çok bulunan UOB türleridir. Taşıt egzoz emisyonları yaklaşık olarak %50 'lik bir oranla, şehirlerde ve kasabalarda en önemli UOB kaynağını oluşturmaktadır. Bu taşıt emisyonları içinde de benzinin etkisi dizele göre 4 kat daha fazladır[15]. Soğuk motorları çalıştırırken, araba rölantideyken ve arabalara yakıt doldurulurken atmosfere hidrokarbon salınımı olur. Özel alanlarda rafinerilerden, orman yangınlarından ve diğer endüstriyel kaynaklardan yayılan UOB emisyonlarına rastlanır.

NO_x'larca zengin çevrede UOB kaynakları, otomobil egzozlarını, ticari ya da endüstriyel olarak kullanılan solventleri ve akaryakıt buharlaşmasını içerir. Petrokimyasal üretimin olduğu alanlarda, özellikle benzinli yakıtların ve fuel-oillerin arıtımının yapıldığı alanlarda, etan, propan, propen, n-pentan, benzen, n-heptan, toluen ve n-oktan gibi bileşikler UOB emisyonlarına büyük ölçüde neden olmaktadır (Kansal, 2009).

Boyamada ve endüstrilerde kullanılan solventlerde, uçucu organik emisyonuna büyük oranda neden olan kaynakların başında gelir. Modern boyama teknikleri ile ortaya çıkan bu emisyonlar tutularak yeniden çözücü olarak kullanılabilirler, özellikle toluen mürekkep inceltici olarak boyama sanayinde tekrar tekrar kullanılmaktadır[17].

Bu kaynaklara ek olarak depolama sahalarında ve depo atıklarında büyük oranda ortaya çıkan metan gazına, uçucu organik gazlarda eşlik edebilmektedir[18]. Aseton, alfa terpinen, benzen, butil, alkol, etilmerkaptan, limonen, furanlar, terpenler gibi uçucu organik bileşik türleri depo sahalarında en çok görülen bileşiklerdendir[15].

Uçucu organik bileşik emisyonlarının diğer bir kaynağı ise, kömürle çalışan termik santrallerdir. Bu santrallerden çıkan en önemli UOB bileşikleri, benzen, toluen, etilbenzen, ksilen, tetrakloretan, benzaldehid ve fenol'dür[20].

1.1.3.2 Doğal Kaynaklar

Uçucu organik bileşiklerin diğer bir kaynağında doğal kaynaklardır. Doğal kaynaklar arasında en önemlisi olarak bitkisel (biyojenik) emisyonlar sayılabilir. Bataklıklardan, çürüyen gübre stoklarından, kanalizasyon ve atıksularda meydana gelen oksidasyon sonucunda çeşitli türlerde uçucu organik bileşik emisyonu ortaya çıkmaktadır[21].


Geniş yapraklı ağaçlardan, kozalaklı bitkilerde yayılan terpenler gibi emisyonlar önemli bitkisel kaynaklı emisyonları oluştururlar. Genellikle bu emisyonları, böceklerden ve zararlılardan korunmak için salgırlar.

Biyolojik faaliyetler sonucunda, yılda yaklaşık olarak 1170 milyon ton uçucu organik bileşik emisyonu atmosfere salınır. Bunların %44 'nü izoprenler, %11'ini monoterpenler, %22.5'ünü diğer reaktif hidrokarbonlar ve %22.5'ünü da diğer reaktif olmayan hidrokarbonlar oluşturmaktadır [15]. Global ölçekte uçucu organik bileşiklerin kaynakları Çizelge 1.3' de verilmiştir.

Çizelge 1.3 Global hidrokarbonların kaynaktahmini(Kansal'dan adapte edilmiştir.)

Kaynaklar	Emisyon
Antropojenik	
(1) Taşıma	22
(2) Sabit Kaynaklar	04
(3) Endüstriyel Proseslerde Doğal Gaz Üretimi	17
(4) Biyokütle Yakımı ve Orman Yangınları	45
(5) Organik Çözücüler	15
Toplam	103
Doğal	
Denizsel	
(1) Hafif	5 – 10
(2) C9-C28 Hidrokarbonlar	1 – 26
Karasal	
(1) Mikrobiyal Üretim	6
(2) Bitkisel Kaynaklı Emisyonlar	1140
Toplam	1170
Toplam emisyon	1273 milyon ton

Wang ve arkadaşlarının[5], doğu Çin de yaptıkları çalışmada, biyojenik UOB emisyonlarının ozon oluşumuna etkisi incelenmiştir. 36 saat boyunca antropojenik emisyonlar sabit tutularak, biyojenik emisyonlu ve biyojenik emisjonsuz olarak ozon oluşumu incelenmiştir. Biyojenik kaynaklı UOB'ler tarafından ozon oluşumu 5 ppbv ya da daha az miktarlardadır ancak bu kimi alanlarda 10-30 ppbv konsantrasyonlarına kadar çıkabilmektedir. Sonuçlar, doğu Çin de biyojenik kaynaklı UOB emisyonlarının, ozon oluşumuna önemli derecede katkı sağladığını göstermiştir.Şekil 1.1' de 2010 yılında Avrupa Çevre Ajansı tarafından yayınlanan raporda uçucu organik emisyonlarına farklı sektörlerin yüzdelik katkıları gösterilmiştir.



Şekil 1.1 Uçucu organik bileşiklerin emisyon kaynakları (2010) (EEA)

1.1.3.3 Uçucu Organik Bileşiklerin Modellenmesi

En önemli hava kirleticilerinden olan uçucu organik bileşiklerin gelecekteki seviyelerini tahmin etmek hava kirliliği kontrolü açısından çok büyük önem arz etmektedir. UOB'lerin konsantrasyonları, büyük ölçüde meteorolojik parametrelere bağlıdır. İklim sistemlerinin elemanları, karmaşık, doğrusal olmayan ve düzensiz bir yapıdan oluşmaktadır [22]. Böyle yapıya sahip kirleticileri modellemek son derece zor ve karmaşıktır. Uçucu organik bileşiklerin bu düzensiz ve doğrusal olmayan yapıları nedeniyle, hava kirliliği tahminlerinde sıklıkla kullanılan dispersiyon modelleri, UOB'lerin karmaşık doğasını anlamada ve modellemede zayıf kalmaktadır [8]. Bu noktada, uçucu organik bileşiklerin ortamdaki konsantrasyonlarını modellemek için daha esnek ve geliştirilebilir modellere ihtiyaç duyulmaktadır. Yapay sinir ağları bu amaç için mükemmel bir fırsat sağlamaktadır. Hava kirleticilerinin emisyonları (örneğin trafik, meteorolojik parametreler vs.) ile hava kirliliği seviyeleri arasındaki ilişki tam olarak açıklanamadığı için ve hava kirliliği tahmin mekanizmaları genel olarak doğrusal olmayan bir yapıda olduğundan dolayı yapay sinir ağları gelecekteki hava kirliliği seviyelerini tahmin etmede son derece başarılıdır [23]. Atmosferdeki azotdioksit, ozon, kükürtdioksit, karbonmonoksit, partiküler madde gibi hava kirleticilerinin gelecekteki seviyelerinin tahmin edilmesinde yaygın bir şekilde kullanılmaktadır [24].

Berastegi ve diğeri [26], tarafından yapılan çalışmada İspanya'nın Bilbao kentinin altı ayrı bölgesinde, beş adet kirleticinin (SO_2 , CO , NO , NO_2 , O_3) sekiz saat sonraki seviyelerini tahmin edebilmek için yapay sinir ağı kurulmuştur. Bunun için 2000-2001 yılları arasındaki saatlik trafik, meteorolojik veri ve kirletici konsantrasyonları ölçümleri kullanılmıştır. Sonuç olarak, yapılan çalışmada en iyi tahmin sonucu NO_2 konsantrasyonu için bulunmuştur regresyon katsayısı 0.88'dir. Akkoyunlu ve diğeri [27], tarafından yapılan çalışmada, İstanbul'daki SO_2 seviyesini tahmin etmek için yedi adet girdi parametresinden oluşan üç katmanlı bir yapay sinir ağı oluşturulmuştur. Sonuç olarak, yaz verileri, kış verileri ve tüm ölçümler için korelasyon katsayıları sırasıyla, 0.770, 0.744 ve 0.751 bulunmuştur. Grivas ve Chaloulakou [28] tarafından yapılan çalışmada, yapay sinir ağları kullanılarak saatlik PM_{10} konsantrasyonu tahmini yapılmıştır. Bu çalışmada kullanılan yapay sinir ağı, meteorolojik ve zaman ölçekli girdi değişkenleri ile geliştirilmiştir. Yapay sinir ağı modelinin uygulanması sonucunda, test setlerinin korelasyon katsayıları (R), 0.50 ve 0.67 arasında değişmektedir. Yapılan diğer bir çalışmada [29], ozon konsantrasyonunu tahmin etmek için genetik algoritma optimizasyonuna dayalı, geri yayımlı bir ağ kurulmuştur. Korelasyon katsayıları (R), 0.86 ile 0.90 arasında değişmektedir. Sonuç olarak, yapay sinir ağları, ozon konsantrasyonunu başarılı bir şekilde tahmin etmiştir. Voukantsis ve diğeri [31], Asal Bileşen Analizi ve yapay sinir ağı modelini kullanarak, Selanik ve Helsinki'de P_{10} ve $\text{PM}_{2.5}$ konsantrasyonlarını tahmin etmektedirler. Bu çalışmada, lineer regresyon modeli ve çok katmanlı algılayıcı modeli kombine edilerek yeni bir formülasyon oluşturulmuştur. Sonuç olarak, kullanılan model, PM_{10} konsantrasyonunu 0.80 ve 0.85 oranında bir korelasyon ile başarılı bir şekilde tahmin etmektedir. Mok ve Tam'ın [30]. Macau şehrinde SO_2 konsantrasyonunu tahmin etmek için, üç ay boyunca örnekleme yapmışlardır ve üç katmanlı ileri beslemeli bir yapay sinir ağı geliştirmişlerdir. Yapılan çalışma sonucunda, iki farklı test yapılarak, SO_2 konsantrasyonu sırasıyla %14.15 ve %13.71 hata oranıyla hesaplanmıştır. Bu sonuçlar, yapay sinir ağlarının geliştirilerek gelecekteki hava kirliliği tahminlerinde başarıyla uygulanabileceğini göstermektedir. Viotti ve arkadaşlarının Perugia (İtalya)'da [32], yapmış oldukları çalışmada meteorolojik veriler ve trafik emisyon seviyeleri kullanarak yapay sinir ağları ile

atmosferik hava kirliliği seviyeleri belirlenmiştir. Sonuçlar göstermiştir ki, yapay sınır ağları, kısa ve orta zamanlı konsantrasyon tahminlerinde iyi bir başarı göstermektedir.

1.1.4 Yasal Düzenlemeler

Uçucu organik bileşiklerin içine çok sayıda organik madde dahil edilebilir. Çok sayıda UOB kaynağı olmasından ve çok çeşitli UOB türü olmasından dolayı bu kirleticilerin izlenmesi, yönetimi ve değerlendirilmesi çok zor olmaktadır. Bu yüzden UOB'ler alt gruplara ayrılarak bu gruplar üzerine yasal düzenlemeler getirilmektedir. Özellikle ozon öncül maddeleri ilgili yönetim sistemlerinde daha geniş bir yer almaktadır [8].

6 Haziran 2008 tarih ve 26898 sayılı Resmi Gazete'de yayınlanarak yürürlüğe giren "Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği (HKDYY)"nde, ozon öncül maddelerinin ölçümleri önerilmekte ve bu ölçümlerin ana hedefleri *"kirlilik konsantrasyonlarına sebep olan emisyon kaynaklarını saptamaya yardım etmek, emisyon envanterlerinin tutarlılığını kontrol etmek, emisyon azaltım stratejilerinin verimliliğini kontrol etmek ve ozon öncül maddelerindeki herhangi bir eğilimi analiz etmek"* olarak tanımlanmaktadır [Resmi Gazete]. Aynı yönetmelikte, ozon öncül maddelerinin izlenmesi sırasında ölçümleri yapılacak olan UOBlerin bir listesi de verilmekte olup, bunlar Çizelge 1.4'de gösterilmektedir.

Çizelge 1.4HKDYY'nde izlenmesi öngörülen ozon öncül maddeleri listesi

No	İsim	No	İsim
1	i-oktan	16	i-bütan
2	1,2,3-Trimetil benzen	17	i-hekzan
3	1,2,4-Trimetil benzen	18	i-pentan
4	1,3,5-Trimetil benzen	19	İzopiren
5	1.3-Bütadien	20	m&p-ksilen
6	1-büten	21	n-bütan
7	1-penten	22	n-hekzan
8	2-penten	23	n-heptan
9	Asetilen	24	n-oktan
10	Benzen	25	n-pentan
11	c-2-büten	26	o-ksilen
12	Etan	27	Propan
13	Etil benzen	28	Propen
14	Etilen	29	Tolüen
15	Formaldehit	30	t-2-büten

Diğer yandan, ozon öncül maddeleri olarak USEPA tarafından belirlenen liste daha fazla UOB barındırmakta olup, bu liste deÇizelge 1.5'te gösterilmektedir.

Çizelge 1.5USEPA ozon öncül maddeleri listesi

No	İsim	No	İsim	No	İsim
1	Etilen	21	4-metil-1-penten	41	n-heptan
2	Etan	22	Siklopentan	42	Metilsikloheksan
3	Asetilen	23	2,3-dimetilbütan	43	2,3,4-trimetilpentan
4	Propilen	24	2-metilpentan	44	Tolüen
5	Propan	25	3-metilpentan	45	2-metilheptan
6	İzobütan	26	2-metil-1-penten	46	3-metilheptan
7	1-büten	27	n-heksan	47	n-oktan
8	n-büten	28	Kloroform	48	Perkloroetilen
9	t-2-büten	29	t-2-heksen	49	Etilbenzen
10	c-2-büten	30	c-2-heksen	50	m-ksilen
11	3-betil-1-büten	31	Metilsiklopentan	51	p- ksilen
12	İzopentan	32	2,4-dimetilpentan	52	Stiren
13	1-penten	33	1,1,1-trikloroetan	53	o- ksilen
14	n-pentan	34	Benzen	54	n-nonan
15	İzopren	35	Sikloheksan	55	İzopropilbenzen
16	t-2-penten	36	2-metilheksan	56	α-pinen
17	c-2-penten	37	2,3-dimetilpentan	57	n-propilbenzen
18	2-metil-2-büten	38	3-metilheksan	58	1,3,5-trimetilbenzen
19	2,2-dimetilbütan	39	Trikloroetilen	59	β-pinen
20	Siklopenten	40	2,2,4-trimetilpentan	60	1,2,4-trimetilbenzen

1.2 Tezin Amacı

Son yıllarda, uçucu organik bileşikler, insan ve çevre sağlığına olan olumsuz, toksik etkilerinden ve neden oldukları kötü kokulu etkilerinden dolayı çok sayıda araştırmacının dikkatini çekmiştir. Geniş kaynak çeşitliliğinden ve çok sayıdaki etkilerinden dolayı en önemli hava kirleticilerinden biridir. Hava kirleticileri arasında önemli bir paya sahip olduklarından dolayı, uçucu organik bileşiklerin izlenmesi ve kontrol stratejilerinin geliştirilmesi önemli bir hal almaktadır. Hava kirliliğinin önlenmesi konusunda yapılacak çalışmalar içinde en önemli hususlardan biri, kirletici ve ona neden olan etkenleri bir model içerisinde değerlendirmektir. Model tahminlerini kullanarak, değişik tipteki uçucu organik bileşiklerin davranışlarının kontrolü ve hava kirliliğinin önlenmesi konusunda uygun kararların alınabilmesi mümkün hale gelmektedir [33].

Bu tezin amacı, yapay sinir ağları kullanılarak atmosferik uçucu organik bileşiklerinin oluşumu üzerinde meteorolojik parametrelerin etkisinin modellenmesi ve bu model sonucunda elde edilen sonuçlar doğrultusunda gelecekteki UOB konsantrasyonlarının

seviyelerinin belirlenmesi ve buna göre sonraki çalışmalar için temsil edici kontrol stratejilerinin geliştirilmesidir.

1.3 Orijinal Katkı


En önemli hava kirleticilerinden olan uçucu organik bileşiklerin gelecekteki seviyelerin belirlenmesi ve buna etken olan parametrelerin UOB oluşumuna ne derece katkı sağladığının belirlenmesi önem arz etmektedir. Uçucu organik bileşiklerin yerel ölçekte konsantrasyonlarının belirlenmesi, örnekleme süresi ve analiz yöntemleri açısından pahalı ve uzun bir süreçtir. Meteorolojik parametrelerinin, uçucu organik bileşiklerinin oluşumu üzerine etkilerini tam olarak belirleyebilmek için yaz, kış ve bahar aylarını kapsayan bir süreç gerekmektedir. Ülkemizde uçucu organik bileşiklerinin analizini yapan laboratuvar sayısının ve bu analizi gerçekleştirecek personel sayısının yeteri derece olmaması da bu süreci daha zorlu hala getirmektedir. Bundan dolayı, UOB'lerin modellenmesi sorunu ortaya çıkmaktadır. Ancak, uçucu organik bileşiklerin oluşum mekanizmalarının düzensiz, kararsız, ve doğrusal olmayan yapılarından dolayı geleneksel matematiksel modeller bu ilişkiyi tam olarak açıklayamamaktadırlar. Yapay sinir ağları, bu karmaşık, modellenmesi zor olan hava kirleticilerinin konsantrasyonlarının tahmin edilmesinde son derece başarılı sonuçlar vermektedir.

Ülkemizde ve dünyada yapılan çalışmalara bakıldığında, çeşitli hava kirleticileri için yapay sinir ağları sıklıkla ve başarıyla kullanılmıştır. Ancak atmosferik uçucu organik bileşiklerinin etkileri ve kaynak profilleri nispeten daha yeni araştırma konusu olduğundan dolayı, UOB'lerin modellenmesi ve gelecekteki seviyelerinin tahmin edilmesi konusunda literatürde daha önce yapılan bir çalışmaya rastlanmamaktadır. Literatürdeki bu eksiklik sonucu ve özellikle İstanbul gibi çeşitli sanayi kuruluşuna ev sahipliği yapan, taşıt trafiğinin yoğun olduğu şehirlerde uçucu organik bileşiklerinin konsantrasyonlarının belirlenmesi ve hava kalitesi bakımından değerlendirilmesi önem ve gereklilik arz ettiğinden dolayı böyle bir çalışma yapılmıştır. Bu noktada bu çalışmayla ülkemize hava kalitesi çalışmaları bakımından önemli ölçüde katkı sağlaması ve gelecek çalışmalar için referans teşkil etmesi amaçlanmıştır.

ÇALIŞMA ALANI, ÖLÇÜM VE MODELLEME YÖNTEMİ

2.1 Çalışma Alanı

Bu çalışma kapsamında kullanılan atmosferik uçucu organik bileşiklerin ölçümleri daha önceden Yıldız Teknik Üniversitesi Davutpaşa Kampüsü'nde yapılmıştır. Şekil 2.1' de gösterilmektedir. Kampüsün bulunduğu bölge gelişmekte olan, çeşitli sanayi kuruluşlarına, otobanlara, alışveriş merkezlerine sahip olan bir bölgedir. Haritadan da görülebileceği üzere kampüsün kuzeyinde Esenler Otogarı bulunmaktadır. Bu bölgede, trafik kaynaklı uçucu organik bileşik konsantrasyonlarının fazla olması beklenmektedir. Doğu, batı ve güney yönlerinde çeşitli büyüklükte sanayi siteleri bulunmaktadır. Bu sanayi sitelerinden boya ve solvent kullanımından dolayı yüksek oranda UOB emisyonları yayılmaktadır. Kampüsün etrafında, işlek caddeler, otoyollar ve ana arterlere giden birçok bağlantı yolu vardır. Kampüsün bu konumundan dolayı farklı türde uçucu organik bileşiklerin ölçümü mümkün olmaktadır. Bu özelliğinden dolayı farklı türlerdeki atmosferik uçucu organik bileşiklerin modellenmesi açısından YTÜ Davutpaşa Kampüsü'ü uygun bir çalışma alanıdır.



Şekil 2.1.YTÜ Davutpaşa Kampüsü ve civar bölgesi(Demir, 2011'den adapte edilmiştir)

2.2 Yapay Sinir Ağının Tanımı ve Tarihçesi

Yapay sinir ağları (YSA), insan beyninin yapısından esinlenerek oluşturulan, öğrenme yolu ile yeni bilgiler üretebilme, oluşturabilme, keşfedebilme, geçmiş deneyimlerinden öğrenme gibi özelliklere sahip ve bunları hiçbir yardım almadan otomatik olarak gerçekleştirmek için geliştirilmiş bilgi işleme sistemleridir. Yapay sinir ağları, farklı yapıda olabilen, değişken ve doğrusal olmayan verileri hızlı bir şekilde işleyen, tanımlama, sınıflandırma ve algılama üzerine olan bir işlemcidir. Bu özelliklerinden

dolayı yapay sinir ağıları klasik matematiksel yöntemlerle çözülemeyen mühendislik problemleri için iyi bir alternatiftir.

İnsan beyni eski zamanlardan beri düşünürlerin ve bilim adamlarının ilgisini çekmektedir. Antik yunan düşünürleri, Plato (İ.Ö. 427-327) ve Aristoteles (İ.Ö.384-322) insan beyninin yapısı ve düşünebilme yeteneğiyle ilgili olarak ilk açıklayıcı teori geliştirme denemeleri yapmışlardır. Bilim adamları, insan beyninin üstün özelliklerini matematiksel olarak tanımlayabilmek için öncelikle beynin işlemci elemanları olan nöronların yapısının matematiksel olarak modellenmesi konusunu ele almışlardır. Beynin bütün özelliklerin ve davranışlarının fiziki olarak modellenenebilmesi için çeşitli yapay hücreler ve ağlar oluşturulmuştur. Yapay sinir ağı modelinin ilk temelleri, 1943 yılında W.S. McCulloch ve W.A. Pitts tarafından yazılan “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” adlı makale ile atılmıştır. Çıkarılan bu modeller “Yapay Sinir Ağları” olarak tanımlanmıştır. Sinir sisteminin modellenmesi ile ortaya çıkan YSA modelleri paralel çalışma ve öğrenebilme gibi özellikleri bakımından biyolojik sinir sisteminin özelliğini göstermektedir.

Yapay sinir ağının en önemli özelliklerinden biri, öğrenmenin başlayabilmesi için başlangıçtaki verilerle ya da olaylarla ilgili bir takım kabuller gerektirmemesidir. Bu özelliğinin yanında, paralel çalışmasından dolayı bilgiyi hızlı bir şekilde işleyerek eş zamanlı bir şekilde sonuca ulaşmayı sağlaması gibi özellikleri de YSA’nı kullanım açısından cazip kılmaktadır [34]. Yapay sinir ağları bilgi işleme bakımından verilen girdilere karşılık çıktı üretebilen kara kutu olarak da nitelendirilebilir.

İlerleyen yıllarda kurulan bu model diğer araştırmacılar tarafından geliştirilmiştir ve günümüzde birçok alanda başarıyla ve sıklıkla kullanılan bir model haline almıştır [35].

2.2.1 Biyolojik Sinir Hücresi ve YSA

İnsan beyninin en temel yapısı olan ve insanın düşünme, algılama , yargılama vs. gibi hareketlerini gerçekleştiren biyolojik sinir hücresi ya da nöron sinir sisteminin temel fonksiyonel birimidir ve beyinde yaklaşık olarak 10 milyar sinir hücresi bulunduğu tahmin edilmektedir. Sinir hücrelerinin tepki hızı, günümüz bilgisayarlarının hızından düşük olmasına rağmen duyuşsal tepkileri iletmede son derece hızlıdır. Sinirsel


uyarıları, elektriksel ve kimyasal olarak iletir. Sinir hücresi üç katmandan oluşmaktadır[36].

Alıcı Sinirler (Receptors): Organizma içerisinden ya da dış ortamdan algıladıkları uyarıları elektriksel sinyallere dönüştürerek beyine iletirler.

Merkezi Sinir Ağı – Beyin (Neural Net):Sürekli olarak üretilen bilgiyi alır, ileri ve geri beslemeli olarak değerlendirir ve uygun kararları vererek gerekli yerlere iletilmesini sağlar.

Tepki Sinirleri (Effector):Beynin ürettiği elektriksel uyarıları organizma çıktısı olarak uygun tepkilere dönüştürürler[37].

Şekil 2.2’ de merkezi sinir ağı yapısının çalışma şekli gösterilmiştir.



Şekil 2.2Merkezi sinir ağının yapısı


Bir sinir hücresi dentritler, aksonlar, sinaps ve hücre gövdesi olmak üzere dört bileşenden oluşmaktadır.

Dentritler: Diğer nöronlardan ya da duyu organlarından aldığı bilgiyi, ağaç köküne benzeyen ince yollarla hücre gövdesine iletirler.

Hücre Gövdesi:Nöronun hücre gövdesi olan somaya gelen girdilerin ağırlıkları toplamı yeterli düzeye ulaştığı zaman bu tepkiler çıktı sinyali olarak hücre dışına verilir. Somada yapılan işlemler genelde doğrusal işlemler değildir. Bu şekilde girdiler nöronda işlenerek çıktıya dönüşür.

Aksonlar (Taşıyıcılar):Aksonlar somada işlenen verileri sinapslara aktararak bu sayede diğer nöronların da aktif hale gelmesini sağlar. Aksonlar hücre gövdesinden çıkan tek bir uzantı halindedirler ancak bu tek uzantıdan çıkan çok sayıda dallanmış sinaptik uzantı bulunur.

Sinaps: Sinapslar, sinir hücresinde bulunan aksonlar ile dentritler arasındaki bağlantı noktalarıdır. Bu bağlantı noktalarının görevi aksondan aldıkları elektriksel bilgileri diğer nöron hücrelerine ya da kas ve salgı bezi gibi nöron olmayan hücrelere aktarılmasını sağlamaktır. Sinapslara gelen bilgi genelde elektriksel darbeler halindedir ancak kimyasal ileticilerden etkilenirler bu yüzden sinapslarda elekto-kimyasal süreçlerle iletilerin diğer hücreye geçirilmesi söz konusudur[39]. Biyolojik sinir hücresinin yapısı Şekil 2.3’ de şematik olarak gösterilmiştir.



Şekil 2.3 Biyolojik Sinir Hücresi

Çizelge 2.1 Biyolojik sinir hücresi ve yapay sinir hücresi karşılaştırması

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Dendrit	Girdiler
Soma	Toplama Fonksiyonu
Akson	Aktivasyon Fonksiyonu
Sinaps	Ağırlıklar
Nöron	İşlemci Elemanlar

2.3 Yapay Sinir Ağının Özellikleri

Yapay sinir ağları türlerine göre değişik karakteristik özellikler göstermelerine rağmen temel birkaç ortak özellikleri vardır. Bir sinir ağının çözebileceği problem uzayı, insan beyninin çözebildiği problem uzayına göre oldukça kısıtlıdır ve yapay sinir ağlarını diğer modelleme türlerine göre çekici kılan bu özellikler değerlendirilirken, bu kısıtlanma göz

önünde bulundurulmalıdır. YSA bilgi işleme ve hesaplama özelliklerini paralel dağılmış yapısından, öğrenebilme ve genelleme yapabilme yeteneğinden almaktadır[38].

2.3.1 Doğrusal Olmama

Yapay sinir ağının alt birimlerinden itibaren başlayan doğrusal olmama durumu tüm ağı kapsamaktadır. Bu alt birimler istenen eşleştirmenin denetim ya da tanımlama gibi doğrusal olmayan işlemlerinde işlevin doğru bir şekilde gerçekleştirilmesini sağlar. Bunun nedeni ağ parametrelerinin başarıyı arttıracak ya da maliyeti azaltacak yönde değiştirilebilir olmasının gerekliliğindendir.

2.3.2 Öğrenme

YSA'nın istenilen davranışları gösterebilmeleri için o veriye göre düzenlenmeleri gerekmektedir. Bunun için hücreler arası bağlantıların doğru şekilde yapılması ve bu bağlantılara doğru değerlilikte ağırlıkların olması gerekmektedir. YSA'nın karmaşık yapısından dolayı bu ağırlıklar ve bağlantılar daha önceden ağa verilemez ya da tasarlanamaz. Bu yüzden YSA, söz konusu problemi çözmek için problemle ilgili eğitim örneklerini kullanarak problemi öğrenmelidir.

2.3.3 Genelleme

Yapay sinir ağı, eğitim seti ile öğrenimini tamamladıktan sonra daha önce hiç karşılaşmadığı test örnekleri için de istenen sonucu üretebilir. Ağa verilen bozuk bilgileri de genelleme yeteneğiyle eğitim sürecinde öğrendiği bilgilere göre yeniden üretebilir.

2.3.4 Uyarlanabilirlik

YSA' da problemlerin çözümünde, maliyeti azaltmak ya da başarıyı arttırmak için ağırlıklar değiştirilir. Belirli bi problemin çözümünde çıkan sonuca göre tekrar eğitilebilir, değişimler sürekli ise eş zamanlı olarak da eğitime devam edilebilir.

2.3.5 Hata Toleransı

Yapay sinir ağları paralel şekilde dağılmış yapısı nedeniyle sahip olduğu bütün bilgi ağın tüm birimlerine yayılmış vaziyettedir. Bu nedenle, eğer eğitimden sonra ağın yapısında bazı hatalar oluşursa, bu hataları tolere ederek ağın işleyişini durdurmaz ve doğru bilgi üretmesini önemli ölçüde etkilemez.

2.3.6 Analiz ve Tasarım Kolaylığı

YSA yapısı birbirine benzer hücrelerden oluşmaktadır. Bütün YSA yapıları bu benzerlikten dolayı yaklaşık olarak aynı özelliklere sahiptirler. Farklı alanlardaki problemlerin çözümünde bu benzer yapıdan dolayı aynı algoritmalar ve yaklaşımlar kullanılabilir bu da YSA'nın kullanımı büyük ölçüde kolaylaştırmaktadır[33].

2.4 Yapay Sinir Ağlarının Avantaj ve Dezavantajları

Yapay sinir ağları karmaşık doğrusal olmayan yapılarından dolayı birçok avantaja sahip olmasının yanında dezavantajları da barındırırlar. Bu avantaj ve dezavantajlar şu şekilde sıralanabilirler[40]:

Yapay sinir ağlarının avantajları;

- Makine öğrenmesi gerçekleştirirler.
- Bilgi işleme yöntemleri geleneksel makinelere göre farklıdır.
- Matematiksel modellere ihtiyaç yoktur.
- Eksik bilgi ile çalışabilmektedirler.
- Örüntü tanıma işleminde bulunabilirler.
- Örnekleri kullanarak öğrenirler.
- Bilgiyi saklarlar.
- Sınıflandırma, tahmin etme gibi çözümü zor olan problemleri kolay yolla çözmek için tasarlanmıştır.
- Kendi kendilerini organize ederler ve öğrenirler
- Doğrusal olmadıklarından dolayı hemen hemen her probleme uygulanabilirler.
- Genelleme özellikleri ile görülmemiş örnekler hakkında bilgi üretirler.

Yapay sinir ağlarının dezavantajları;


- Donanım bağımlıdır.
- Uygun ağ yapısının ve ağın parametrelerinin belirlenmesinde belli bir kural yoktur.
- Öğrenilecek problemin ağa gösterimi önemli bir problemidir.
- Ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir kural yoktur. Deneme yanılma yoluyla bulunur.
- Ağın davranışları açıklanamamaktadır.
- Dereceli bozulma gösterirler.
- Sadece sayısal bilgiler ile çalışabilirler.
- Bazı ağlar için kararlılık analizleri yapılamaz.

2.5 Yapay Sinir Ağının Yapısı

Yapay sinir ağları da biyolojik sinir ağlarına benzer yapıda olan yapay sinir hücrelerinden oluşmaktadır. Bu hücreler de, biyolojik sinir sisteminde olduğu gibi nöronlar arası bağlantı kurarak yapay sinir ağlarını oluştururlar. Aynı şekilde bir bilgi girişinin olduğu, bu bilginin değerlendirilip toplandığı ve çıktı sinyali olarak ilettikleri bölümleri bulunur. Bu hücrelerde bulunan işlem elemanları bir araya gelerek katmanları oluştururlar. Katman birbirlerine değişik şekillerde bağlanarak farklı ağ mimarisine sahip yapay sinir ağlarını oluştururlar. YSA üç katmandan oluşur. Bunlar;

- Girdi katmanı
- Gizli katman
- Çıktı katmanı

Tipik bir YSA modeli Şekil 2.4' te gösterilmiştir.



Şekil 2.4 YSA modeli

2.5.1 Girdi Katmanı

Modele giriş değerlerinin verildiği katman girdi katmanıdır. Bu katmanda girdi bilgileri alınarak ağırlıklar ile çarpılarak gizli katmana iletilir.

2.5.2 Ara Katman (Gizli Katman)

Genellikle çıktı katmanından sonra bir ya da daha fazla ara katman bulunur. Girdi katmanı ile alınan bilgiler gizli katmana iletilir. Burada gelen bilgi değerlendirilip toplanarak çıktı katmanına iletilir. Gizli katmana sahip olmayan ağlar karmaşık problemlerin çözümünde yetersiz kalırlar ve bu yüzden en az bir gizli katmana ihtiyaç vardır.


2.5.3 Çıktı Katmanı

Gizli katmandan çıkan giriş değerleri, gizli katman ve çıktı katmanı arasındaki ağırlık değerleri ile çarpılarak çıktı katmanına iletilir. Gelen bu bilgiler gizli katmanda olduğu gibi bir fonksiyon yardımıyla değerlendirilerek dış dünyaya çıktı olarak verilir.

2.6 Yapay Sinir Ağlarının İşlemci Elemanları

YSA biyolojik sinir sisteminin çalışma şeklini simüle edebilmek için tasarlanan sistemlerdir. Biyolojik sinir sistemlerinde olduğu için yapay sinir ağlarında da işlemci elemanlar bulunmaktadır. YSA, insan beyninin kendiliğinden öğrenme, analiz etme, değerlendirme, ön görüde bulunabilme gibi özelliklerinden esinlenerek tasarlanmıştır. Çözümü için düşünme, değerlendirme gibi insani özellikleri gerektiren problemleri çözebilmek için geliştirilmiştir. Bu işlevleri yerine getirebilmesi için biyolojik sinir sistemlerinde olduğu gibi işlemci elemanlara gereksinim vardır. Bu işlem elemanları diğer nöronlardan aldıkları sinyalleri taşıyıp, değerlendirip, toplayarak çıktı sinyali olarak dış dünyaya iletmeyi sağlarlar. Her bir işlem elemanı yapay sinir ağının tüm işleyişinde yer almaz kendilerine özgü görevlerde yer alırlar. Bu görev paylaşımı çok zor problemlerin çözümünü kolaylaştırmaktadır. YSA da genel özellikleri ile bir işlem elemanı 5 bileşenden oluşmaktadır[21]. Bunlar;

- Girdiler
- Ağırlıklar
- Birleştirme Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktı



Şekil 2.5 Yapay sinir hücresi

2.6.1 Girdiler

Girdiler dış ortamdan ya da diğer bir nörondan başka nöronlara gelen bilgilerdir. Bu gelen bilgiler toplanması ve değerlendirilmesi amacıyla gizli katmana iletilir.

2.6.2 Ağırlıklar

Hücreler arasındaki bağlantılarının sayısal değeridir. Bir hücre üzerine gelen bilgilerin değerini ve hücre üzerindeki etkisini gösterir. Bu ağırlıkların değerleri negatif, pozitif ya da sıfır olabilir. Ağırlığı sıfır olan girdinin hücre üzerinde bir etkisi yok demektir. Ağırlığın negatif ve pozitif olması o bilginin ağ üzerinde ne derece etkili olduğunu gösterir.

2.6.3 Birleştirme Fonksiyonu

Hücreye gelen net bilginin toplanması ve değerlendirilmesini sağlayan fonksiyondur. Toplama işlemi, her bir nörondan gelen değerler ağırlıklar ile çarpılarak toplam nöronlardan gelen bilgi girişi bulunur. Toplanan bu değerler nöronun aktivasyon fonksiyonundan geçirilerek ve nöronun eşik değeri de hesaba katılarak çıktı değerleri hesaplanır.

$$I_j = \sum(O_i * w_j) + Q_j \quad (2.1)$$

Bu denklemde;

I_j = Birleştirme fonksiyonuna iletilecek girdi değeri. Bulunan bu değer birleştirme fonksiyonu ile işleme tabi tutulur.

O_i = Nöronlara gelen girdi değerleridir.

w_j = Nöronlara karşılık gelen ağırlıklardır.

Q_j = Gizli katmanda kullanılacak olan birleştirme fonksiyonun eşik değeri (bias) dir.


2.6.4 Aktivasyon Fonksiyonları

Kullanılan yapay sinir ağlarının yapısına göre değişiklik göstermektedirler. Birleştirme fonksiyonundan çıkan net toplamı hücre çıktısı oluşturulmak üzere aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonu olarak genelde doğrusal olmayan bir fonksiyon seçilir. Yapay sinir ağlarının doğrusal olmayan yapısının nedeni kullanılan bu

aktivasyon fonksiyonlarının doğrusal olmamasıdır. Fonksiyonlar seçilirken türevinin kolay anlıyor olmasına dikkat edilmelidir. Geri beslemeli ağlarda, hesaplama adımlarında aktivasyon fonksiyonunun türevi kullanıldığı için hesaplama adımlarında yavaşlamaya neden olunmaması için türevi kolay alınır fonksiyonlar seçilmelidir. Kullanılacak olan fonksiyonun seçimi, ağın neyi öğrenmesi gerektiğine ve ağın verilerine göre seçilmelidir. Örneğin, ağın bir modelin ortalama davranışının öğrenmesi isteniyorsa sigmoid fonksiyonu, standart sapmasını öğrenmesi isteniyorsa hiperbolik tanjant fonksiyon kullanır. En sık kullanılan aktivasyon fonksiyonları şunlardır[41]:

2.6.4.1 Doğrusal Fonksiyon

Bu fonksiyon gelen toplam bilgiyi direkt olarak ağ çıktısı olarak vermektedir. PURELİN fonksiyonu olarak da bilinmektedir. Doğrusal aktivasyon fonksiyonu matematiksel olarak; $y = A v$ olarak tanımlanır. Bu denklemde “A” sabit bir katsayıdır. Bu katsayısı Şekil 2.6’da gösterilen doğrunun çıkış eksenine yaptığı açıya göre değişmektedir.




Şekil 2.6 Doğrusal aktivasyon fonksiyonu

2.6.4.2 Basamak Fonksiyon

Basit algılayıcı olarak bilinen (Perceptron) ağ modellerinde yapay sinir hücresi aktivasyon fonksiyonu olarak bu fonksiyon kullanılır. Girdilerin sıfırdan büyük olup olmamasına göre -1 ile 1 arasında çıktı değerleri veren fonksiyonlardır. Tek ve çift kutuplu olarak değişmektedirler.

$$y = f(v) = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (2.2)$$

$$y = f(v) = \begin{cases} 1, & v \geq 0 \\ -1, & v < 0 \end{cases} \quad (2.3)$$




Şekil 2.7 Basamak fonksiyonu

2.6.4.3 Sigmoid Aktivasyon Fonksiyonu

Yapay sinir ağlarında en yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir. Doğrusal olmayışı, türevinin alınabilir ve sürekli olmasından dolayı tercih sebebidir. Bu fonksiyon girdinin her değeri için 0 ile 1 arasında çıktılar üretir.

$$y = \frac{1}{1+e^{-x}} \quad (2.4)$$




Şekil 2.8 Sigmoid fonksiyonu

2.6.4.4 Tanjant Hiperbolik Aktivasyon Fonksiyonu

Hiperbolik tanjant fonksiyonu sigmoid fonksiyonuna benzer bir fonksiyondur. Bu fonksiyon çift kutuplu fonksiyon olarak da bilinir. Giriş uzayının genişletilmesinde kullanılan bir fonksiyondur. Hiperbolik tanjant fonksiyonunda çıkış değerleri -1 ile 1 arasında değişmektedir.

$$y = \frac{1-e^{-2x}}{1+e^{2x}} \quad (2.5)$$



Şekil 2.9 Tanjant hiperbolik fonksiyonu


Yukarıda anlatılan aktivasyon fonksiyonlarına ek olarak literatürde bulunan diğer aktivasyon fonksiyonları;

- Radyal bazlı aktivasyon fonksiyonu
- Parçalı doğru fonksiyon
- Kutuplamalı basamak fonksiyonu
- Sinüs tipli fonksiyon
- Tribas fonksiyonu
- Satlins fonksiyonu

2.6.5 Çıktılar

Aktivasyon fonksiyonları sonucunda dış dünyaya veya diğer nöronlara gönderilen değerdir. Nöronun bir çıktısı olmasına rağmen bu işte istenildiği kadar nörona bağlı olabilir. Bir nöronun çalışma prensibi örneği;

Girişler	Ağırlıklar
$X_1 = 0.5$	$W_1 = -0.2$
$X_2 = 0.6$	$W_2 = 0.6$
$X_3 = 0.2$	$W_3 = 0.2$
$X_4 = 0.7$	$W_4 = -0.1$



Hücrenin net girdisi;

$$NET = \sum Xi * Wi$$

$$\sum Xi * Wi = (0.5 * -0.2) + (0.6 * 0.6) + (0.2 * 0.2) + (0.7 * -0.1)$$

$$\sum Xi * Wi = 0.23$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılırsa;

$$f(NET) = \frac{1}{1 + e^{-0.23}}$$

$$f(NET) = 0.56 \text{ olur.}$$

2.7 Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları yapılarına ve öğrenme algoritmalarına göre sınıflandırılmaktadırlar. YSA daha önce denildiği üzere nöronlardan oluşmuştur ve bu nöronların birbirleriyle bağlantıları YSA'nın yapısını oluşturur. Bu bağlantıların nasıl olacağı öğrenme algoritmaları ile belirlenir.

2.7.1 Yapılarına Göre Yapay Sinir Ağları


Yapay sinir ağları yapılarına göre ileri beslemeli (feed forward) ve geri beslemeli (feed back) olarak ikiye ayrılır.

2.7.1.1 İleri Beslemeli Ağlar

İleri beslemeli ağlarda nöronlar düzenli bir şekilde katmanlar halinde ağa yayılmışlardır.

Dışarıdan gelen girişler, girdi katmanından çıktı katmanına doğru tek yönlü bağlantılarla iletilir. Bir katmandan sadece kendinden sonra gelen katmanlara bağlantı vardır. Gecikme olmaz ve sinyaller girişten çıkışa doğru iletilir. Bu ağlar statik ağlar olarak da adlandırılır.


İleri beslemeli ağlara örnek olarak Çok Katmanlı Algılayıcı (MultiLayer Perceptron-MLP), LVQ (Learning Vector Quantization) verilebilir. İleri beslemeli ağlar için blok diyagramı Şekil 2.10' da gösterilmiştir.



Şekil 2.10 İleri beslemeli ağlar için blok diyagramı

2.7.1.1.1.1 Çok Katmanlı Algılayıcı (MultiLayer Perceptron)

Çok katmanlı algılayıcı giriş ve çıkış katmanları arasında çok sayıda katman bulunan yapay sinir ağı yapısıdır. Eğer çözülmek istenen problem doğrusal değilse daha önce tasarlanmış yapay sinir ağları yapısı kullanılamaz ve daha gelişmiş yapılara ihtiyaç duyulur, Çok katmanlı algılayıcı da bu nedenle geliştirilmiştir. Birçok öğrenme algoritması bu ağı eğitmede kullanılabildiği için sık kullanılan ağ yapılarından biridir. Bir katmandaki işlem elemanları bir üst katmandaki işlem elemanlarının tümüne bağlıdır. Giriş katmanında herhangi bir bilgi işleme yapılmamaktadır. Gelen her bir bilgi doğrudan diğer katmana gider. ÇKA danışmalı öğrenme kuralını kullanır. Ağa hem öğrenilmesi istenen örnekler hem de istenilen çıktılar ağa verilir. Kullanılan öğrenme kuralına göre, ağın çıkışındaki çıktı değeri ile istenen çıktı arasındaki hata oranına göre geriye yayılarak hatanın minimum değere ulaşması sağlanır. Genel olarak genelleştirilmiş delta kuralı eğitim algoritması kullanılır[42].



2.11 Çok katmanlı algılayıcının topolojik yapısı

2.7.1.1.1.2 Geriye Yayılım Algoritması

Birçok uygulamada kullanılan en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispat edilebilir olması tercih sebebidir. İki temel aşamadan oluşur; ileri besleme ve geriye yayılım. İleri besleme ile ağı giriş değerleri verilmektedir. Bu işlem sonucunda elde edilen sonuçlara göre hata değerleri minimize edilmek amacıyla ağırlık güncellenmesi yapılır ve hata geriye yayılır. Toplam hatayı minimuma indirmek için gradyan iniş kullanılır[43]. Geriye yayılım algoritmasının işlem basamakları şunlardır;

1. Ağ yapısı tanımlanır (girdi, çıktı, ara katman sayısı ve nöron sayısı).
2. Başlangıç ağ parametreleri belirlenir. Ağ parametrelerinin başlangıç ağırlık değerleri rastgele atanır.
3. Girdiler ve çıktılarından oluşan eğitim seti ağı tanıtılır.
4. Her bir işlem elemanı için gerekli hesaplamalar yapılır ve çıktı değerleri bulunur.
5. İstenen sonuç ile model çıktı sonucu karşılaştırılır ve hata oranı hesaplanır.
6. Bulunan hata, çıktı katmanından başlayarak geriye doğru ağırlık güncellemeleri yapılarak yayılır.
7. Eğer hata oranı istenilen seviyede ise ağın eğitimi durdurulur aksi takdirde üçüncü adıma geri dönlür.

Çok katmanlı bir geriye yayılım ağı, bir girdi katmanından, bir çıktı katmanından ve en az bir ara katmandan oluşmaktadır.

Geriye yayılım algoritmasının aktivasyon fonksiyonunu seçerken dikkat edilmesi gereken noktalar vardır. Aktivasyon fonksiyonu, sürekli, türevi alınabilir ve tekdüze bir şekilde azalmıyor olması gerekmektedir.

Bu algoritmaya göre;

İleri Besleme;

$$I_j = \sum(O_i * w_{ij}) + Q_j \quad (2.6)$$

$$O_j = f_j(I_j) \quad (2.7)$$

$$I_k = O_j * w_{jk} + Q_k \quad (2.8)$$

$$O_k = f_k(I_k) \quad (2.9)$$

Hata Hesaplanması;

Geri yayılım algoritmasında ortalama karesel hata olarak bilinen hata kriteri kullanılabilir. Hatanın minimuma ulaşması için, hatanın ağırlıklara olan bağımlılığı hesaplanır ve gradyan bağlı olarak hatalar düşürülür.

$$E = 1/N * \sum_{k=1}^N (T_k - O_k)^2 \quad (2.10)$$

$$w_{jk}' = w_{jk} + \Delta w_{jk} \quad (2.11)$$

$$\Delta w_{jk} = -\delta_k * O_j = \frac{\partial E}{\partial w_{jk}} \quad (2.12)$$

Burada Δw_{jk} ara katman ile çıktı katmanı arasındaki ağırlık güncelleme değeridir. T_k istenen çıkış değeridir O_k ise ağ tarafından hesaplanan çıktı değeridir.

$$w_{jk}' = w_{jk} + l * \delta_k * O_j \quad (2.13)$$

δ_k , çıkış katmanı için hata değeridir. l ise öğrenme hızıdır.

$$w_{jk}' = w_{jk} + l * (f_k' * (T_k - O_k) * O_j) \quad (2.14)$$

$$O_k' = O_k + l * \delta_k \quad (2.15)$$

$$fk' = \frac{d(fk)}{dx} \quad (2.16)$$

Türevi alınması en kolay fonksiyon sigmoid fonksiyonu olduğu için genellikle bu fonksiyon kullanılır. Sigmoid fonksiyonun türevi;

$$y = \frac{1}{1+e^{-x}} \quad (2.17)$$

$$y' = \frac{d}{dx} \left(\frac{1}{1+e^{-x}} \right) \quad (2.18)$$

$$y' = (1 - y) * y \quad (2.19)$$

$$y' = \left(1 - \frac{e^{-x}}{1+e^{-x}} \right) * \frac{e^{-x}}{1+e^{-x}} \quad (2.20)$$

$$fk = (1 - Ok) * Ok \quad (2.21)$$

Bu yöntem sadece logaritmik sigmoid fonksiyonu için kullanılır.

Gizli Katman Güncellenmesi;

$$wij' = wij + \Delta wij \quad (2.22)$$

$$\Delta wij = -\delta j * Oi = \frac{\partial E}{\partial wjk} \quad (2.23)$$

$$wij' = wij + l * \delta j * Oi \quad (2.24)$$

$$\delta j = fj'(\sum \delta k * wjk) \quad (2.25)$$

$$Oj' = Oj + l * \delta j \quad (2.26)$$

Geri yayımlı ağların güçlü yönleri yanında zayıf yönleri de vardır. Uzun öğrenme süreleri dezavantaj olmaktadır. Karmaşık fonksiyonlar yüzlerce hatta binlerce çevrim sürer. Ağ aslında bir kara kutudur. Toplam hata minimuma indirilebilir sıfıra düşürülemez.

2.7.1.1.1.3 Levenberg Marquard Algoritması

Levenberg Marquard optimizasyon algoritması genellikle çok katmanlı ağlarda kullanılan Newton metodunun basitleştirilmiş bir hali olan algoritmadır. Bu algoritma temel olarak, maksimum komşuluk fikri üzerine kurulmuş en küçük kareler hesaplama metodudur. Newton ve adımlı düşüm algoritmalarının en iyi özelliklerinden oluşmuştur ve bu iki ağ yapısının kısıtlamalarını ortadan kaldırır.

Her bir iterasyon adımımda hata yüzeyine parabolik olarak yaklaşır ve parabolün minimumu o iterasyon için sonucu oluşturur.

Gauss Newton metodunda karşılaşılan sorunlardan biri Hessian matrisinin tersininin alınamıyor olmasıdır. LM algoritmasında bu matrise μ değeri eklenerek bu sorun ortadan kaldırılmıştır.

$$H(W) = J^T(W) * J(W) * \mu I \quad (2.27)$$


Burada; H, Hessian matrisidir, J, Jakobien matrisini temsil etmektedir. LM algoritması aşağıdaki yaklaşımı kullanarak Hessian matrisine yakın bir değer bulmaya çalışır.

$$\Delta W = -\varepsilon^T * J * (J^T * J + \mu I)^{-1} \quad (2.28)$$

Bu algoritmanın çalışma adımları şu şekildedir; öncelikle performans fonksiyonu belirlenir. Küçük bir μ değeri ile işleme başlanır. ΔW hesaplanarak performans fonksiyonunun bir sonraki değeri hesaplanır. Performans fonksiyonun bu değeri bir öncekinden büyükse, μ 10 kat arttırılır ancak performans fonksiyonun değeri öncekinden küçükse, μ 10 kat azaltılır. Ağırlıklar güncellenir ve ΔW hesabına geri dönülür.

2.7.1.1.1.4 Öğrenme Vektör Nicelendirilmesi (Learning Vector Quantization)

Learning vector quantization ağı 1984 yılında Kohonen tarafından tasarlanmıştır. Bu ağ yapısı bir giriş katmanı, bir çıkış katmanı ve bir Kohonen katmanından oluşur. Bazı durumlarda istenen çıkış değeri ağa verilememektedir fakat ağın ürettiği çıktının doğru ve yanlış olduğunu ağa belirtilmektedir. Bu tür öğrenme yöntemine destekleyici öğrenme kuralı denilmektedir. LVQ yapısında da destekleyici öğrenme kuralı kullanılmaktadır. LVQ ağları genel olarak sınıflandırma problemlerinin çözümünde kullanılmaktadır. Bu ağ yapısında çıkış değerleri ya 1 ya da 0 olmaktadır. Değerin 1 olması, o çıktının ilgili olduğu sınıfa ait olduğunu göstermektedir. Öğrenme hızı çok katmanlı algılayıcıya göre daha hızlıdır. Girdi katmanında ÇKA ağında olduğu gibi bilgi işleme olmaz alınan bilgiler ara katmana iletilir. Kohonen katmanındaki her eleman bir referans vektörünü göstermektedir. Bu ağın temel prensibi n boyutlu bir vektörü, vektörler setine haritalamaktır.



Şekil 2.12 LVQ ağıının topolojik yapısı

2.7.1.2 Geri Beslemeli Ağlar

Geri beslemeli ağlarda, sinyal iletimi çift yönlü olarak yapılmaktadır. Geri beslemeli ağlarda bir nöronun çıkışı, o nöronun o anki ağırlık değerleri ve girdi değerleri ile bağlantılıyken aynı zamanda bazı nöronların daha önceki çıkış değerlerinden de etkilenmektedir. Bu ağlara Dinamik Ağlar da denilmektedir. Bu çeşit ağların dinamik hafızaları vardır. Bundan dolayı tahmin problemlerinin çözümünde kullanılmaktadır. Bu ağlara örnek olarak, Hopfield, SOM(Self Organizing Map), Elman ve Jordan ağları verilebilir. Ağı dezavantajı olarak, geri besleme sırasında yaşanan gecikme verilebilir. Bu yüzden ağı bu yönünü geliştirebilmek için çalışmalar yapılmaktadır.

Hata oranını minimuma düşürmek amacıyla eğim düşümü (gradient descent) yöntemi ağırlık güncelleme yöntemi olarak kullanılır.

$$E = 1/N * \sum_{k=1}^N (Tk - Ok)^2 \quad (2.29)$$

$$\Delta w(k) = \sum_{k=1}^{\epsilon} -l * \frac{\partial E}{\partial w} + \mu \Delta w(k-1) \quad (2.30)$$

Burada;

E = hata değeri

ϵ = Çevrim sayısı


μ = Momentum katsayısı

ℓ = Öğrenme katsayısı

T_k = İstenen çıktı değeri

O_k = Model çıktı değeri

Geri besleme, bir katmandaki hücreler arasında olabildiği gibi katmanlar arası hücreler arasında da olabilir. Genellikle geri besleme, geciktirici ağ elemanı üzerinden yapılır.



Şekil 2.13 Geri beslemeli ağların blok gösterimi


2.7.2 Öğrenme Algoritmalarına Göre Sınıflandırılma

Yapay sinir ağlarının en önemli özelliklerinden biri öğrenme yeteneğidir. Bir sinir ağında öğrenme, hatanın minimuma gelecek şekilde ağırlıkların değiştirilmesini ifade eder. Ağa daha hiç görmediği değerler verildiği zaman çıkış değerlerini doğru şekilde verebiliyorsa ağ öğrenmiş demektir. Genel olarak üç öğrenme algoritmasından ve bunların kullanıldığı farklı öğrenme kurallarından bahsedilir.

2.7.2.1 Danışmanlı Öğrenme (Supervised Learning)

Danışmanlı öğrenmede ağa, girdi değerlerinin yanında istenilen çıkış değerleri de verilir. Elde edilen çıkış değeri ve istenilen çıkış değeri arasında hataya bakılarak gerekirse ağırlık düzeltmeleri yapılır. Bu nedenle danışmanlı öğrenme algoritmasının bir


“öğreticiye” ya da “danışmana” ihtiyacı vardır. Danışmanlı ağ metodunda öğrenmeden önce ağın eğitilmesi gerekmektedir. Bu eğitim öğreticinin kontrolündedir. Eğitim için seçilen eğitim seti, çözümü istenen problemin tüm yapısını ve modeli temsil edecek tüm özellikleri kapsayacak şekilde olmalıdır. Widrow-Hoff tarafından geliştirilmiş delta kuralı ve Rumelhart tarafından geliştirilmiş genelleştirilmiş delta kuralı veya geri yayılım (back propagation) algoritmaları danışmanlı öğrenme algoritmalarına örnek olarak verilebilir [33].



2.14 Danışmanlı öğrenme yapısı

2.7.2.2 Danışmansız Öğrenme (Unsupervised Learning)


Bu öğrenme algoritmasında ağa istenilen çıkış değerleri verilmemektedir. Ağ model sonucu çıkan değerlere göre sınıflandırma kurallarını kendi belirlemektedir. Öğrenme sürecinde sadece giriş değerleri verilir. Ağ, bağlantı ağırlıklarını aynı dokuya sahip olabilecek örnekleri sınıflandırabilecek şekilde düzenleyerek öğrenmeyi bitirir. Yani dışarıdan bir etki olmadan nöronlar arasındaki ilişki kendi kendine oluşur. Crossberg tarafından oluşturulmuş ART ve Kohonen tarafından geliştirilmiş SOM(Self Organizing Map) algoritmaları danışmansız öğrenme algoritmalarına örnek verilebilir.



2.15 Danışmansız öğrenme yapısı

2.7.2.3 Destekleyici Öğrenme

Destekleyici öğrenme metodu, istenilen çıkışı bilmeye gerek duymaz. Danışmanlı öğrenmeye en çok benzeyen öğrenme algoritmasıdır. Bu öğrenme yaklaşımında, her iterasyon sonucu çıkışın ne derece doğru olduğunu gösteren skorlar ya da dereceler verilir. Ağ bu bilgilere göre ağırlıklarını düzenler. Bu algoritma özellikle maliyet hesapları ve kontrol uygulamaları için uygundur. Boltzman kuralı ve Genetik Algoritma kuralı bu öğrenme algoritmasına örnek verilebilir.



2.16 Destekleyici öğrenme yapısı

2.7.3 Uygulamaya Göre Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarında öğrenme ne olursa olsun hangi strateji uygulanırsa uygulansın belli kurallara göre yapılmaktadır.

2.7.3.1 Çevrimiçi (On-line) Öğrenme Kuralları

Çevrimiçi öğrenmede, eş zamanlı olarak ağ öğrenmeye devam ederken fonksiyonlarını da yerine getirmektedir. ART ve Kohonen öğrenme algoritması bu öğrenme kuralına örnek olarak verilebilir.

2.7.3.2 Çevrimdışı (Off-line) Öğrenme Kuralları

Çevrimdışı öğrenmede, gerçek hayatta kullanılmadan önce örnekler tarafından eğitilirler. Daha sonra gerçek hayatta kullanımları sırasında öğrenme olmamaktadır.

2.7.4 Öğrenim Kurallarına Göre Yapay Sinir Ağlarının Sınıflandırılması

Literatürde kullanılmakta olan birçok öğrenim kuralı bulunmaktadır. Bu kuralların çoğu matematik tabanlı olup ağırlıkların güncelleştirilmesi ile hatanın minimize edilmesi amaçlanmaktadır. Yapay sinir ağının mimarisine ve çözülmek istenen problemin yapısına göre çeşitlilik göstermektedirler. Bu algoritmaların çoğu aşağıdaki kurallardan esinlenerek oluşturulmuştur;

- Hebb Kuralı
- Delta Kuralı
- Kohonen Kuralı
- Hopfield Kuralı

2.7.4.1 Hebb Kuralı

1984 yılında psikolog Donald Hebb tarafından biyolojik sinir hücrelerini baz alarak geliştirilmiş öğrenme kuralıdır. Bu öğrenme kuralı basit bir mantıkla çalışmaktadır. Eğer birbirine bağlı iki nöron aynı anda işaret alıyorsa aralarındaki ağırlık değeri arttırılır.

$$\Delta w_{jk} = \alpha * y_j * x_k \quad (2.31)$$

Burada;

α = Öğrenme katsayısı

y_j = u_j nöronunun çıktısı

x_k = u_k nöronunun çıktısı

Öğrenme katsayısı 0 ile 1 arasında değerler alır. Öğrenme katsayısı ne kadar büyükse o derece hızlı öğrenir ne kadar küçükse öğrenme hızı o derece küçük olur. Ancak yüksek öğrenme katsayılarında ağın genelleme yeteneği düşer ve ezberlemeye başlar bunun sonucunda eğitim seti harici verilen örnek setlerinin tahmininde başarılı sonuçlar elde edilemez. Ağın eğitimden önceki ağırlıkları 0 olmalıdır.

2.7.4.2 Delta Kuralı

Delta kuralı Widrow ve Hoff tarafından gerçekleştirilmiştir. Bu kural, nöronun model çıktısı ile istenen çıkışı arasındaki farkı azaltan aralarında giriş bağlantılarını güçlendiren ve ağırlıkları sürekli olarak değiştiren bir yapıya dayanmaktadır. Nöronlar arası ağırlıkları değiştirerek ortalama en küçük karesel hata değerini düşürmeye çalışır. Bu nedenle bu yöntem en küçük kareler yöntemi olarak da bilinir. Delta algoritması hatayı en aza indirmek için grandyanlı düşüm metodunu kullanır.

2.7.4.3 Kohonen Kuralı

Kohonen tarafından biyolojik sinir sistemlerinden esinlenerek geliştirilmiş algoritmadır. Bu kuralda ağa istenen çıktı değerleri verilmez bu yüzden danışmansız öğrenme yapısına sahiptir. Kohonen kuralında nöronlar yarıştırlarak eğitilirler. Modelin çıktı değeri hangi nöronun daha büyükse o nöron kazanmış olur. Kazanan nöronun ağırlık değerleri güncellenir[49].

2.7.4.4 Hopfield Kuralı

Bu kural Hebb kuralına benzemektedir. Ancak Hopfield kuralında nöronlardan her ikisi de aktifse ya da her ikisi de aktif değilse ağırlık değerleri arttırılır. Diğer durumlarda ise azaltılır. Genelde öğrenme katsayısı 0 ile 1 arasındadır.

2.8 Yapay Sinir Ağının Tasarımı

Yapay sinir ağları ile çözülmeyecek problem çok azdır ancak bunun için doğru ağ yapısının ve metodolojinin seçilmesi gerekmektedir. YSA'larda, nöronların sayısı, kullanılan fonksiyon türleri, nöronlar arasındaki katman sayısı, sinirlerin birbirleriyle konumu, sinirler arasındaki akış YSA'nın yapısını oluşturmaktadır.

YSA'nın tasarımında, çözülmek istenen problemin karakteri iyi bir şekilde tanımlanmalıdır. Uygulamanın başarısında uygun metodolojinin seçilmesi büyük önem taşır. Yapay sinir ağları tasarlanırken şu adımlar izlenmelidir;

- Problem için verilerin toplanması.
- Toplanan verilerin, eğitim seti, test seti ve validasyon seti olarak alt bölümlere ayrılması.

- Yapay sinir ağı'nın ağ yapısının belirlenmesi (ara katman nöron sayısı, katman sayısı)
- Nöronlarda kullanılacak toplama ve aktivasyon fonksiyonlarının seçimi.
- Öğrenme algoritmasının seçimi ve parametrelerinin belirlenmesi
- Eğitim ve test set setlerinin oluşturulması
- İstatistiksel indikatörlerin seçimi

Eğer ağ yapısı bu şekilde belirlenmezse, sistem karmaşıklığına yol açar ve bu da yapısal ve toplam hesapsal karmaşanın artması demektir.

2.8.1 Ağın Eğitim ve Test Setlerinin Seçimi

Proses elemanlarının bağlantı ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denmektedir. Yapay sinir ağı öğrenme sürecinde, gerçek hayattan alınan örnek verileri kullanılır. Yapay sinir ağı'nın eğitilmesinde kullanılan bu örnek setlerine “eğitim seti” denir. Eğitim seti, problemin bütün özelliklerini yansıtacak verilerden seçilmelidir. Eğitim sırasında ağırlıklar değiştirilerek ağın öğrenmesi gerçekleştirilir. Ağırlık değişimi yoksa öğrenme durmuş demektir. Ağ, artık kendisine eğitim seti harici verilen örnekleri de tanıyıp doğru şekilde hesaplayabiliyorsa öğrenimini tamamlamış demektir. Eğitim sonunda hataların karesel ortalaması istenilen düzeye düşmesi beklenir ancak her zaman hatanın düşmesi genelmenin iyi bir şekilde yapıldığını göstermemektedir. Eğer gereğinden fazla gizli katman ve nöron sayısı seçilirse ağ genelleme yerine ezberleme yapar. Bunu önlemek için optimum ağ yapısının belirlenmesi gerekmektedir. Uygulama sırasında performans fonksiyonlarının sonuçları izlenerek ağın uygun öğrenim seviyesine gelmesi sağlanabilir.

Veri setinin içinden, eğitilmiş ağı test etmek amacıyla seçilmiş verilerin oluşturduğu sete “test seti” denir. Eğitim ve test setlerinin seçiminde en önemli husus bu setlerin oranlarının ne şekilde olacağıdır. Ağ, mümkün olduğunca fazla veri ile eğitilmelidir. Ancak veri setlerinin oranlarının yeterli olup olmadığı her zaman kestirilememektedir. Eğer eğitim ve test işlemleri sonucunda modelin performans değerleri birbirlerine yakınsa bu oranın yeterli olduğu söylenebilir. Genellikle veri setinin %50, %80 arası eğitim setine ayrılır. Geri kalan kısım test ve doğrulama seti olarak eşit ya da birbirine yakın oranlarda ayrılır. Önemli bir diğer husus da, veri setinin ağa rastgele bir biçimde

verilmesidir. Ağın tahmin yeteneğinin geliştirilmesi için farklı türden verilerin ağa tanıtılması gerekmektedir.

2.8.2 YSA Ağ Yapısının Seçimi

Kurulan modelden başarılı sonuçları alınabilmesi için, problem yapısına uygun ağ türleri seçilmelidir. Çizelge 2.2’ de bu ağ türleri ve başarılı oldukları alanlar verilmiştir.

Çizelge 2.2 Ağ türleri ve başarılı oldukları alanlar

Uygulama Alanı	Ağ Türü
Tahmin	Geri Yayılım Ağı Delta Bar Delta Perceptron Yüksek Seviyeli Ağlar Genişletilmiş Delta Bar Delta Özörgütlemeli Harita Ağı
Sınıflandırma	Geri Yayılma Ağı Öğrenme Vektörü Nicelemesi Olasılıksal Sinir Ağı Kohonen Ağı Boltzman Ağı
Veri Birleştirme	Hopfiel Ağı Boltzman Ağı Hamming Ağı İki Yönlü Çağrışımlı Bellek Vektör Nicelemesi Ağı

2.8.3 Yapay Sinir Ağı Algoritmasının Seçimi

Seçilen YSA ağ yapısı büyük ölçüde öğrenme algoritmasına da bağlıdır. Çünkü her eğitim algoritmasının başarılı olduğu bir ağ türü vardır ve zorunlu olarak o ağ türü seçilmelidir. Uzun ağ yapısına sahip modellerin genelleme kabiliyetleri düşüktür bu da tasarlanan ağın başarısız sonuçlar vermesine neden olur ve ağ öğrenmekten ziyade ezberlemiş olur.

2.8.4 Ara Katman Sayısının Seçimi

Ara katman sayısı kullanıcının deneyimlerine ve problemin girdi çıktı değerlerine bağlıdır. Ara katman sayısı kesin olarak belirlenmemektedir. 2 ya da 3 katmanlı ağlar genellikle başarılı sonuçlar verebilmektedirler. En iyi sonucu tasarımcı deneme yanılma yoluyla bulabilir. Ağ yapısını karmaşıkleştirmeden, en hızlı öğrenmenin gerçekleşebileceği katman sayısı bulunmalıdır.

2.8.5 Nöron Sayısını Belirlenmesi

Ağ yapısı belirlenirken dikkat edilmesi en önemli özelliklerinden biri de nöron sayısıdır. Girdi ve çıktı katmanlarında problemin yapısına göre nöron sayıları belirlenebilirken, gizli katmanda nöron sayısı da katman sayısı gibi deneme yanılma yoluyla tasarımcının deneyimlerine bağlı olarak bulunur. Model istenilen performansı gösterene kadar nöron sayısı arttırılabilir aynı şekilde istenilen performansın altına inmeden nöron sayısı azaltılabilir. Nöron sayısının çok fazla olması istenmemektedir çünkü fazla nöron sayısı ağ yapısını büyütmeştir bu da genellemenin azalmasına ezberlemenin artmasına neden olmaktadır.

2.8.6 Aktivasyon Fonksiyonunun Seçimi

Aktivasyon fonksiyonlarının seçimi daha çok ağın neyi öğrenmesi isteniyorsa ona göre yapılmalıdır. En çok kullanılan aktivasyon fonksiyonları, sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Sigmoid fonksiyonun çıktı aralığı 0 ile 1 arasında olurken hiperbolik tanjant fonksiyonun çıktı aralığı -1 ile 1 arasında olmaktadır. Eğer ağın ortalama davranışının öğrenilmesi isteniyorsa, sigmoid fonksiyonu, ortalamadan sapmasının öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyonu kullanılmalıdır. Ağın daha iyi

sonular verebilmesi aktivasyon ve toplama fonksiyonu olarak farklı fonksiyonlar kullanılabilir.

2.8.7 Normalizasyon

Yapay sinir ağıının doğrusal olmama özelliğinden dolayı veriler normalizasyona tabii tutulmaktadır. Verilerin normalizasyonu, her bir girdi parametresinin modelin tahmin işlemine eşit oranda katkı sağlamasını sağlar. Aşırı salınımlı olan giriş değeri ağı farklı oranlarda etki ederler bu da ağı öğrenme başarısını etkiler. Normalizasyon işlemi, toplamı çok büyük olan kümülatif değeri oluşturacağı olumsuzlukları engeller. Genellikle veriler 0 ile 1 arasında normalize edilir. Eğitim aşamasında bu normalize veriler kullanılır eğitim ve test seti sonrası çıktı olarak verilen veriler denormalize edilerek gerek değeri getirilir. Normalizasyon şu şekilde yapılmaktadır;

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.32)$$

2.9 evre Mühendisliğinde Yapay Sinir Ağları İle İlgili Yapılan alışmalar

Yapay sinir ağları her alanda kullanıldığı gibi evre mühendisliğinde de sıklıkla kullanılmaktadır. Arıtma tesislerinin verim hesaplamalarında, havzaların su kalite kontrolünde, membran prosesleri konusunda yapılmış birçok alışma mevcuttur. Ancak hava kirliliği ile ilgili yapılmış alışmalar çok eskiye dayanmamaktadır. Yapay sinir ağları hava kirliliği konularında 1990'dan önce nadir olarak uygulanmaktadır.

Reich ve arkadaşları [44], yapay sinir ağlarını kaynağı bilinmeyen hava kirleticileri belirlemede kullanmışlardır. Ü katmanlı ileri beslemeli ağ ile geriye yayımlı eğitim algoritması seçilmiştir. Saatlik ölçülmüş meteorolojik veriler girdi verileri olarak, çıktı olarak kaynakları bilinmeyen hava kirleticilerinin konsantrasyonları belirlenmiştir. Yapılan alışma sonunda, yapay sinir ağlarının hava kirleticilerin tahmininde başarılı sonular verdiği görülmektedir.

Chan ve Jian[25] yaptıkları alışmada, PM_{2.5} ve PM_{1.0} konsantrasyonlarının seviyelerini belirlemek amacıyla meteorolojik parametreleri ve trafik verilerini kullanarak yapay sinir ağlarıyla tahmin etmişlerdir. Sonular bu alışmada önerilen yapay sinir ağıının,

hava kirlilięi seviyelerini ve kullanılan parametrelerin bu seviyeye ne derece etki ettięini belirlemede kullanılabileceęini göstermektedir.

Cai ve arkadaşlarının[45] Guangzhou (Çin)'da yaptıkları çalışmada, saatlik hava kirleticilerinin konsantrasyonları yapay sinir aęları yaklaşımı ile tahmin edilmiştir. Hava kirleticilerinin oluşumunda etkili olan faktörler dört gruba ayrılmıştır; trafik kaynaklı, geri plan konsantrasyonları, meteorolojik ve coęrafi etkiler. Karbon monoksit, nitrojen oksit, partiküler madde ve ozon konsantrasyonları ölçülmüştür. Sonuçlar göstermiştir ki, yapay sinir aęları hava kirleticilerinin konsantrasyonlarını tahmin etmede etkili bir yaklaşım sunmaktadır.

Chelani ve diğerlerinin [46] yaptıkları çalışmada, Levenberg Marquard algoritması kullanarak sülfür dioksit konsantrasyonlarını tahmin etmişlerdir. Yapılan çalışmada regresyon analizi ve yapay sinir aęlarının performansları karşılaştırılmıştır. YSA 'nın, regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Nagendra ve Khare [47] Delhi(Hindistan)' de yaptıkları çalışmada, egsoz emisyonlarından kaynaklanan NO₂konsantrasyonunu yapay sinir aęları ile tahmin etmişlerdir. Modelde girdi olarak 10 adet meteorolojik parametre ve 6 adet trafik verisi kullanılmıştır. Çalışma sonunda, NO₂ konsantrasyonları başarılı bir şekilde tahmin edilmiştir.

BÖLÜM 3

BULGULAR VE TARTIŞMA

3.1 Yapay Sinir Ağları İle Modellenmesi

Bu çalışmada atmosferik uçucu organik bileşiklerin modellenmesinde Yapay Sinir Ağı yaklaşımı kullanılmıştır. 24 Mart 2011 ve 9 Haziran 2011 tarihlerinde yapılmış olan 207 ölçüm sonucukullanılmıştır. Bu tez çalışması kapsamında kullanılan kullanılan UOB ölçüm sonuçları Saral (2010) tarafından yürütülen TÜBİTAK projesinde elde edilen verilerden alınmıştır. Çizelge 3.1’de yapılmış ölçüm sonuçlarına göre UOB türleri ve ortalama konsantrasyonları gösterilmiştir.

Çizelge 3.1 UOB türleri ve ortalama konsantrasyonları

UOB Türleri	Ortalama Konsantrasyon ($\mu\text{g.m}^{-3}$)*	UOB Türleri	Ortalama Konsantrasyon ($\mu\text{g.m}^{-3}$)*
2-metilbütan	3.17 ± 2.24	b-pinen	0.15 ± 0.17
2,3 dimetilbütan	0.73 ± 0.95	Siklopentan	0.32 ± 0.27
2-metilpentan	3.89 ± 6.29	Metilsiklopentan	3.12 ± 5.35
3-metilpentan	3.59 ± 6.00	Sikloheksan	0.83 ± 1.14
2,4-dimetilpentan	0.18 ± 0.22	Benzen	1.86 ± 1.02
2,3-dimetilpentan	0.11 ± 0.08	a-pinen	0.29 ± 0.34
3-metilheksan	0.28 ± 0.18	m&p-ksilen	2.46 ± 1.95
Heptan	0.25 ± 0.15	Stiren	1.28 ± 1.73
Nonan	0.47 ± 0.42	p-etiltoluen	0.36 ± 0.30
Dekan	0.51 ± 0.64	m-etiltoluen	0.18 ± 0.12
1-penten	0.12 ± 0.05	1,2,4-trimetilbenzen	0.20 ± 0.16
t-2-penten	0.23 ± 0.07	1,2,3-trimetilbenzen	0.55 ± 0.45
c-2-penten	0.11 ± 0.05	1,3,5-trimetilbenzen	0.23 ± 0.16
Hekzan	8.76 ± 15.6		

* Belirsizlikler 207 ölçüm sonucu baz alınarak standart sapma olarak verilmiştir.

207 adet veri seti, yapay sinir ağlarının eğitim ve test setleri için kullanılmıştır. Ölçülmüş olan 33 adet UOB türü için 33 farklı yapay sinir ağı oluşturulmuştur.Çok

katmanlı algılayıcı (ÇKA) ağ yapısı kullanılmıştır. Bu çalışmada kurulan ağ yapılarında tek gizli katman kullanılmıştır. Gizli katmanda 10 ila 20 nöron kullanılması durumunda model sonuçlarının tatmin edici olduğu görülmüştür.

Bütün ağ yapılarında toplam fonksiyonu olarak sigmoid fonksiyonu, aktivasyon fonksiyonu olarak hiperbolik tanjant ya da purelin (lineer akson) fonksiyonları kullanılmıştır.

Öğrenme kuralı olarak Levenberg – Marquardt algoritması kullanılmıştır. LM algoritması yapay sinir ağlarında sıklıkla kullanılan bir öğrenme algoritmasıdır. Eğitimde sağlamış olduğu hız ve kararlık nedeniyle tercih edilmiştir. Veriler ağa verilmeden önce ağ üzerinde aynı oranda etki sağlamaları için normalizasyon işlemine tabi tutulmuştur.

Eğitim, validasyon ve test seti oranları değiştirilerek optimum ağ yapısı oluşturulmaya çalışılmıştır. Genellikle veri seti, %60'ı eğitim seti , %15'i validasyon seti ve % 25'i test seti olarak ayrıldığı zaman gerçeğe yakın bir tahmin sonucuna ulaşıldığı görülmüştür. Bu veriler, ağın farklı sonuçlar için tahmin yeteneğinin geliştirilmesi adına, ağa rastgele bir şekilde tanıtılmıştır. Epoch sayısı her model için sabit tutulmuş olup 2000 iterasyon olarak belirlenmiştir. Optimum epoch sayısının belirlenmesi yapay sinir ağları için önemlidir çünkü fazla ya da az sayıda iterasyonda alt seviye ya da üst seviye uyumsuzlukları ortaya çıkabilir. . Bu durumda, modelin, örnekleri öğrenmek yerine ezberlediğini söylemek mümkün olup, farklı örnekler ve gerçek değerler için başarılı sonuçlara ulaşamayacağı açıktır.

3.1.1 Meteorolojik Parametreler

Yapay sinir ağı oluşturulurken UOB konsantrasyonunu etkileyen 6 adet girdi parametresi kullanılmıştır. Bunlar;

- Sıcaklık (°C)
- Nem
- Rüzgar Hızı (m/sn)
- Rüzgar Yönü
- Ölçümün yapıldığı gün

- Ölçümün yapıldığı saat


Çıktı katmanı olarak da UOB ($\mu\text{g}/\text{m}^3$) konsantrasyonları tahmin edilmiştir. Bu parametrelerin ortalama, minimum, maksimum değerleri Çizelge 3.2’de gösterilmiştir. Bu ölçümler Davis Vantage Pro2 meteoroloji istasyonu ile 15 dakikalık sürelerle alınmıştır.

Çizelge 3.2 Meteorolojik parametrelerin değişim aralıkları

Parametre	Ortalama	Standart sapma	Medyan	Minimum	Maksimum
Rüzgar Hızı (m.s^{-1})	2.37	1.54	2.17	0.08	6.24
Sıcaklık ($^{\circ}\text{C}$)	12.57	6.20	12.36	2.32	30.62
Nem (%)	72.70	14.31	73.19	28.32	94.81

3.1.1.1 Sıcaklık

Atmosferik uçucu organik bileşiklerin konsantrasyonları teorik olarak sıcaklıkla ters orantılıdır. Günlük ortalama kuru termometre sıcaklığı olup $^{\circ}\text{C}$ diye ifade edilir. Sıcaklıkla hava kirliliği teorik olarak ters orantılıdır.




Şekil 3.1 Günlük ölçülen sıcaklık değerleri

3.1.1.2 Rüzgar Hızı ve Yönü

Rüzgar atmosferdeki hareketliliğin en önemli parametrelerinden olup, kirleticilerin yatayda taşınımalarını ve dolayısıyla seyrelmelerini sağlamaktadır. Rüzgar geldiği yöne


bağlı olarak hava kirliliği üzerinde farklı etkiler göstermektedir. Rüzgar hızı arttıkça kirletici konsantrasyonları azalmaktadır. Rüzgar, deniz gibi temiz hava kütesinin bulunduğu bir bölgeden geliyorsa UOB konsantrasyonlarını azaltıcı etkiye bulunur. Ölçülmüş olan rüzgar yön ve hızları kullanılarak günlük ortalama rüzgar hızı (m/s) ve yönleri bulunmuştur.



Şekil 3.2 Ölçüm sayısına göre rüzgar hızları

Rüzgar yönleri yapay sinir ağlarında kullanılmak üzere Şekil 3.3’de görüldüğü gibi 4 ayrı sektöre ayrılmıştır. Burada,


- 1 ile gösterilen sektör; NW ve NE arasındaki yönleri,
- 2 ile gösterilen sektör; NE ve E arasındaki yönleri,
- 3 ile gösterilen sektör; SE ve SW arasındaki yönleri,
- 4 ile gösterilen sektör; SW ve NW arasındaki yönleri göstermektedir.



Şekil 3.3 Rüzgar yönleri ve sektörleri


3.1.1.3 Nem

Atmosferde bulunan su atmosferin nemliliği olarak adlandırılmaktadır. Atmosferde bulunan nem miktarı artıkcı kirleticiler su buharı içine çözünüp gazdan sıvı faza geçerler ve böyle havadaki kirletici gaz konsantrasyonları azalmış olur[48].



Şekil 3.4 Ölçüm sayısına göre nem yüzdesi

Kullanılan yapay sinir ağ yapısı Şekil 3.5’de gösterilmiştir.



Şekil 3.5 Kullanılan yapay sinir ağının topolojisi

3.1.1.4 Gün ve Saat

Ölçümün yapıldığı günler haftanın günleri şeklinde verilmiştir. Örneğin, Çarşamba günü yapılmış ölçüm için ağ girdisi olarak 3 yazılmıştır. Bir gün dört farklı zaman dilimine bölünmüştür;


- 6:00 - 12:00 arası, 1. saat dilimi
- 12:00 - 20:00 arası, 2. saat dilimi
- 20:00 - 24:00 arası, 3. saat dilimi
- 24:00 - 6:00 arası, 4. saat dilimi

Ağ girdisi olarak da, ölçüm saati hangi zaman dilimine denk geliyorsa o yazılmıştır. Bu veriler ağa, normalizasyon işlemine tabi tutularak girilmiştir.

3.2 Yapay Sinir Ağının Sonuçları

Yapılan çalışma sonunda 33 UOB türü için elde edilen tahmin edilen konsantrasyonlar ile ölçülen konsantrasyonları arasındaki korelasyon katsayıları 0.547 ile 0.818 arasında değişmektedir. Korelasyon katsayıları 1’e ne kadar yakınsa model sonucu elde edilen değerler ile ölçülen değerler o derece uyumludur. Atmosferin kararsız ve değişken yapısından dolayı atmosferik uçucu organik bileşiklerin yapay sinir ağları

uygulamalarında çok yüksek oranlarda korelasyon katsayılarına ulaşamamaktadır. Genellikle %70 ile %80 arasında korelasyon katsayısı bulunması iyi bir tahmin sonucuna ulaşıldığını göstermektedir. Buna göre MLP modeli atmosferik uçucu organik bileşiklerin modellenmesinde ve konsantrasyonlarının tahmininde başarılı sonuçlar vermiştir.



Şekil 3.6 Doğrulamalı eğitimde en iyi model sonucu

Şekil 3.6’da görüleceği gibi eğitim seti ve doğrulama seti belirli bir noktaya kadar azalmaktadır. Bu noktaya kadar model genelleme yeteneğini kazanmış olur. Bundan sonra eğitim seti hatası sıfıra yaklaşıırken doğrulama seti hatası artmaya başlamaktadır. Bu noktadan sonra model öğrenme üzerine yoğunlaşmaktadır ve artık model verilen örnekleri ezberlemeye başlar bu da modelin tahmin kabiliyetinin azalmasına neden olmaktadır.

UOB’lerin yapay sinir ağıları modeli çıktı değerleri ile ölçüm değerleri arasındaki korelasyon grafikleri Şekil 3.19’ da gösterilmiştir.


Çizelge 3.3 UOB türleri ve numaraları

UOB Türleri	Numara	UOB Türleri	Numara
1,2,3-trimetilbenzen	1	Benzen	18
1,2,4-trimetilbenzen	2	c-2-penten	19
1,3,5-trimetilbenzen	3	Etilbenzen	20
1-penten	4	Heptan	21
2,2,4 trimetilpentan	5	Hekzan	22
2,3 dimetilbütan	6	İsopropilbenzen	23
2,3-dimetilpentan	7	m-etiltoluen	24

2,4-dimetilpentan	8	m&p-ksilen	25
2-metilbütan	9	Metilsiklopentan	26
2-metilpentan	10	Nonan	27
3-metilhekzan	11	Oktan	28
3-metilpentan	12	Pentan	29
a-pinen	13	Siklopentan	30
b-pinen	14	Toluen	31
p-etiltoluen	15	O-ksilen	32
Siklohekzan	16	t- etiltoluen	33
Undekan	17		


Uygulanan model sonucunda en iyi dört sonuç; 2,2,4 trimetilpentan (R: 0,81), benzen (R: 0.74), 2metilpentan (R: 0.78) ve hekzan (R: 0.70)'da elde edilmiştir. Şekil 3.8'de bu dört UOB türü için korelasyon sonuçları gösterilmiştir. en düşük korelasyon katsayıları undekan(R:0.58), m&p-ksilen(R:0.595), pentan (R:0.47), o-ksilen(R:0.56) ve 3-metilpentan(R:0.54)'a aittir. Kırmızı çizgi bire-bir çizgisini, siyah çizgi korelasyon çizgisini, mavi noktalar ölçülen değerlere karşılık gelen model çıktı değerlerini temsil etmektedir. Bire-bir çizgisi ile korelasyon çizgisi birbirine ne kadar yakınsa model sonuçları gerçek değerleri arasında o derece iyi bir uyumluluk vardır ve model sonucu elde edilen tahmin değerleri gerçek ölçüm sonuçlarını o oranda temsil eder. Aynı şekilde iki çizgi birbirine ne kadar paralelse modelin tahmin sonuçları o derece başarılı demektir. Çalışmada kullanılan 33 UOB türü Çizelge 3.3'de gösterildiği gibi numaralandırılmıştır.

En iyi korelasyona sahip 2metilpentan ve hekzan emisyonlarının, solvent kullanımından kaynaklı olduğu bilinmektedir. Benzinli araç ve evaporatif emisyonları da benzen kaynağı olarak bilinmektedir (Demir, 2011).



Şekil 3.7 Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri, 2,2,4-trimetilpentan(5), 2metilpentan(10), benzen(18), hekzan(22)


Konsantrasyon grafiklerine bakıldığı zaman, MLP modelinin UOB konsantrasyonlarını başarılı bir şekilde tahmin ettiği görülmektedir. Özellikle 2,2,4-trimetilpentan ve 2-metilpentan için model tahmin sonuçları pik konsantrasyon değerlerini iyi bir şekilde tahmin etmektedir. Bu dört UOB türünün konsantrasyonları aşırı salınımlar yapmadığı için girdi parametreleri veri setine doğru bir şekilde tanıtılabilmektedir ve modelin eğitimi başarılı bir şekilde yapılmaktadır.



Şekil 3.8 Modelleme sonucu en iyi korelasyona sahip UOB türleri; (5) 2,2,4-trimetilpentan (10) 2metilpentan, (18) benzen, (22) hekzan


Şekil 3.8’ de görüleceği üzere bire-bir çizgisi ve korelasyon çizgisi birbirlerine ne kadar yakınsa tahmin değerleri ile ölçüm sonuçları birbiri ile daha uyumlu olduğu görülmüştür. Özellikle 2-metilpentan ve benzen için kurulan modeller konsantrasyonları büyük doğruluk oranları ile tahmin etmişlerdir.

2,2,4-trimetilpentan için duyarlılık analizi sonuçları Şekil 3.9 ’da verilmiştir.



Şekil 3.9 Girdi parametrelerinin 2,2,4 –trimetilpentan için hassasiyet analizi


2,2,4-trimetilpentan hem sanayi kaynaklı olarak hem de akaryakıt buharlaşması sonucu atmosfere salınmaktadır. 2,2,4-trimetilpentan için duyarlılık analizlerine bakıldığı zaman, konsantrasyonu en fazla etkileyen girdi parametreleri nem, rüzgar yönü ve rüzgar hızıdır. En az etkileyen parametre ise, saattir. Sanayi kaynaklı olarak da salındıkları için saat parametresi pek fazla konsantrasyonları üzerinde etkili değildir. Bunun nedeni kampüs çevresinde bulunan küçük sanayi işletmelerin kesikli çalışmasıdır.



Şekil 3.10 2,2,4 trimetilpentan için ağ çıktı konsantrasyonlarının girdi parametreleri ile değişimi

Şekil 3.10'da görüleceği üzere, nem arttıkça 2,2,4-trimetilpentan konsantrasyonları azalmaktadır. Bunun nedeni, nem miktarı arttıkça kirletici gazlar su içinde çözünerek seyrelmesidir. Rüzgar yönü doğu ve güneybatıya kaydıkça UOB konsantrasyonu artmaktadır. Bölgenin doğusunda, güneyinde ve batısında çeşitli büyüklükte sanayi sitesi olduğu için bu bölgeden gelen solvent emisyonlarından dolayı konsantrasyon artışı olmaktadır. Özellikle hafta ortasına ve hafta sonuna doğru kirletici emisyonların birikiminden dolayı konsantrasyonların arttığı görülmektedir. Sıcaklık ile konsantrasyonların azaldığı görülmektedir. UOB'lerin konsantrasyonları genellikle sıcaklık artışıyla beraber azalması beklenmektedir. Model bu durumu doğru bir şekilde göstermiştir. Özellikle sabah ve öğle saatlerinde konsantrasyonların arttığı görülmektedir. Bunun nedeni kampüs çevresinde bulunan sanayi işletmelerinin sabah ve öğlen saatlerinde yoğun bir biçimde çalışmalarıdır özellikle akşam saatlerinde çalışmalar durduğu için konsantrasyonlarda azalmalar meydana gelmektedir.

Hekzan için girdi parametreleri duyarlılık analizi sonuçları Şekil 3.11' de verilmiştir.




Şekil 3.11 Girdi parametrelerinin hekzan için duyarlılık analizi

Buna göre; yapay sinir ağları ile hekzan konsantrasyonlarının tahminini etkileyen en önemli parametrenin nem değeri olduğu görülmektedir. Nemden sonra hekzan konsantrasyonlarını etkileyen diğer parametreler sıcaklık, rüzgar yönü ve hızıdır. Saat parametresinin düşük oranda etkilemesi, solvent kullanımından dolayı çıkan hekzan


emisyonlarının belirli saatlerde olmadığını, kesikli olarak ortaya çıktığını göstermektedir.

Şekil 3.12 ' ye bakıldığı zaman, hekzan çıktı konsantrasyonlarının nem ile ters orantılı olarak değiştiği görülmektedir. Nem miktarı arttıkça hekzan konsantrasyonu azalmaktadır zaten bilindiği üzere nem miktarı arttıkça UOB emisyonlarına neden olan kirletici konsantrasyonları azalmaktadır. Tarih ile değişimine bakıldığı zaman, hafta başından hafta ortasına doğru hekzan konsantrasyonlarının arttığı görülmektedir, hafta sonuna doğru ise azalmaktadır. Hekzan emisyonları sanayi kaynaklı olduğu için hafta içi ve ortasında iş günlerinde daha fazla faaliyetin olmasından dolayı hekzan emisyonlarında da artış meydana gelmektedir. UOB konsantrasyonları sıcaklıkla ters orantılı olduğu için model sonuçlarında görüldüğü gibi sıcaklık arttıkça hekzan konsantrasyonları azalmaktadır.



Şekil 3.12 Hekzan için ağ çıktı konsantrasyonlarının girdi parametreleri ile değişimi

Benzen için girdi değerlerinin duyarlılık analizleri Şekil 3.13’de verilmiştir.




Şekil 3.13 Benzen konsantrasyonlarının girdi parametreleri ile değişimi

MLP modeli, benzen konsantrasyonlarını son derece başarılı bir şekilde tahmin etmektedir. Benzen konsantrasyonların tahmininde en etkili olan parametreler sıcaklık, rüzgar hızı ve yönüdür. Benzinli araç kullanımından ve evaporatif emisyonlardan kaynaklandığı için rüzgar yönünün ve hızının değişimi benzen konsantrasyonlarını etkilemektedir. Nem değerleri de benzen konsantrasyonları üzerinde etkilidir. Araç kullanımları hafta içi ve hafta sonunda çok büyük farklılıklar oluşturmadığı için tarih parametresi konsantrasyonlar üzerinde büyük bir etki yapmamaktadır.


Şekil 3.14’de girdi parametreleri ile benzen konsantrasyonlarının değişimi görülmektedir. Benzen konsantrasyonlarını en çok etkileyen parametrelere bakıldığı zaman, sıcaklık artışıyla önce benzen konsantrasyonlarının arttığını daha sonra azaldığı görülmektedir. Bunun nedeni, özellikle kış aylarından ilkbahar aylarına geçişte taşıt kullanımları arttığı için buna bağlı olarak benzen konsantrasyonları da artmaktadır. Hava sıcaklığının artmasıyla araç içinde bulunan yakıtın sıcaklığıda artmaya başlamaktadır. Bu sıcaklık artışıyla beraber yakıt buharlaşmaya başlar ve havaya benzen emisyonu salınır. Rüzgar hızı arttıkça kirletici konsantrasyonu azalmaktadır.

Bunun nedeni rüzgar hızı arttıkça kirleticiler dağılarak seyrelmektedir ve konsantrasyonları azalmaktadır. Rüzgar yönü kuzeye doğru yöneldikçe benzen konsantrasyonları artmaktadır. Bunun nedeni kuzeyde büyük Esenler Otogarının bulunması ve bu bölgeden yayılan araç emisyonlarının yüksek oranlarda olmasıdır.



Şekil 3.14 Benzen için ağ çıktı değerlerinin girdi parametreleri ile değişimi


Yüksek korelasyona sahip diğer bir UOB türü de 2metilpentan'dır. % 78'lik bir korelasyon katsayısı ile en iyi tahmin sonucuna 2metilpentan ile ulaşılmıştır. Girdi parametreleri ile arasındaki duyarlılık Şekil 3.15'de gösterilmiştir.



Şekil 3.15 2metilpentan konsantrasyonlarının girdi parametreleri ile değişimi


2metilpentan konsantrasyonlarının değişiminde de hekzan da olduğu gibi nem parametresi ön plana çıkmaktadır. İki UOB türü de solvent kullanımından dolayı oluşan bileşiklerdir. Nem ile birlikte rüzgar yönü ve tarih de 2metilpentan konsantrasyonu üzerinde etkilidir. Saat ve rüzgar hızı 2metilpentan konsantrasyonlarının tahmininde en az etkiye sahip parametrelerdir.

Şekil 3.16'da 2metilpentan konsantrasyonlarının nem ile ilişkisine bakıldığında zaman hekzan da olduğu gibi nem arttıkça UOB konsantrasyonları düşmektedir. Rüzgar yönü doğu ve güneydoğu yönlerine doğru kaydıkça konsantrasyonun arttığı görülmektedir. Bunun nedeni ölçüm yapılan yerin güneyinde ve doğusunda çeşitli büyüklükte sanayi sitelerinin olmasıdır. Bu sanayi sitelerinde çeşitli alanlarda solvent kullanımında kaynaklı 2metilpentan emisyonları yayılmaktadır. Bu sonuç da yapay sinir ağı modeli 2metilpentan konsantrasyonlarını tahmin etmede başarılı olduğunu göstermektedir. Hafta başından hafta sonuna doğru giderek solvent kullanımı azaldığı için 2metilpentan konsantrasyonları da buna bağlı olarak hafta sonuna doğru azalım göstermiştir.



Şekil 3.16 2metilpentan için ağ çıktı değerlerinin girdi parametreleri ile değişimi


Şekil 3.17’de görüldüğü üzere en düşük korelasyon katsayıları undekan(0.58), m&p-ksilen(0.595), pentan(0.47), o-ksilen(0.56) ve 3-metilpentan(0.54)’a aittir. Görüldüğü üzere, tahmin sonuçları ile ölçüm sonuçları uyumluluk içinde değildir. Model ölçüm sonuçlarının çok az bir kısmını doğru tahmin edebilmiştir.



Şekil 3.17 Modelleme sonucu en düşük korelasyona sahip UOB türleri;
(17) undekan (29) pentan, (25) m&p-ksilen, (12) 3-metilpentan

3-metilpentan’ın solvent kullanımından ve akaryakıtlı araçlardan, m&p-ksilen’inin solvent emisyonlarından kaynaklandığı bilinmektedir (Demir, 2011). Solvent emisyonları tek bir kaynaktan değil, rüzgar yönlerine bağlı olarak her yönden gelebilmektedirler. Bu nedenle modellenmesi zordur ve buna bağlı olarak MLP modeli sonucu istenilen düzeyde olmamaktadır. Aynı şekilde o-ksilen de genel boya kullanımından kaynaklanan bir UOB türüdür. Bölgenin doğusunda, batısında ve güneyinde çeşitli sanayi siteleri olduğu için üç yönden de o-ksilen emisyonları yayılmaktadır yapay sinir ağları bu kararsız yapıyı tam olarak açıklayamamaktadır. Dizel


araçlardan kaynaklanan dizel eksoz emisyonları undekan emisyonlarına neden olmaktadır. Pentan emisyonlarının kaynakları çok çeşitli olup tam olarak hangi kaynaktan geldiği bilinmemektedir. Konsantrasyonlarına etki eden birçok faktör olduğu için ve bu faktörler modelin veri setinde tam olarak temsil edilememektedir ve bunun sonucunda başarılı bir tahmin sonucuna ulaşamamaktadır.



Şekil 3.18Tahmin ve ölçüm sonucu konsantrasyonların zaman serili grafikleri, undekan(17), pentan(29), m&p-ksilen(25), 3-metilpentan(12)


Pentan ve m&p-ksilenin ölçüm süresi boyunca salınımları çok fazladır. Model tarafından bu her bir salınım ayrı birer durum olarak algılanmaktadır. Bunun sonucunda MLP modeli ölçüm değerlerinin piklerini başarılı bir şekilde tahmin edememektedir.

Bununla beraber uygulanan MLP modeli çoğu UOB türünün genel davranışını başarılı bir şekilde tahmin etmektedir. Genel olarak 0.70 ile 0.80 arasında korelasyon katsayısı ile iyi bir sonuç vermektedir.




Şekil 3.19. a) İstenen ve tahmin edilen UOB konsantrasyonları arasındaki korelasyon grafikleri (1-9)


Korelasyon grafiklerine bakıldığı zaman, modelin diğer atmosferik uçucu organik bileşik türlerini de başarıyla tahmin ettiği görülmektedir. Özellikle, 1-penten(0.701), 3-metilhekzan(0.719), p-etiltoluen(0.7139), b-pinen (0.7164), siklohekzan(0.704), c-2 penten(0.741), heptan(0.739)' da başarılı tahmin sonuçlarına ulaşılmıştır. 3-metilhekzan, p-etiltoluen, heptan ve siklohekzan emisyonları genel endüstriyel boya kullanımından ve solvent kullanımından dolayı oluşmaktadır. Kampüs çevresinin genel emisyon profilini solvent kullanımı ve genel endüstriyel boya kullanımları oluşturmaktadır (Demir, 2011). Yapay sinir ağları bu genel profili modellemede son derece başarılı olmuştur.




Şekil 3.19.b İstenen ve tahmin edilen UOB konsantrasyonları arasındaki korelasyon grafikleri (9-18)




Şekil 3.19.c İstenen ve tahmin edilen UOB konsantrasyonları arasındaki korelasyon grafikleri (19-27)




Şekil 3.19.d İstenen ve tahmin edilen UOB konsantrasyonları arasındaki korelasyon grafikleri (28-33)



Şekil 3.20.a Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri (1-12)



Şekil 3.20.b Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri (13-24)



● Tahmin Değerleri — Ölcülen Değerler

Şekil 3.20.c Model tahmin değerleri ve ölçüm sonucu konsantrasyonların zaman serili grafikleri (25-33)

33 UOB türü için hassasiyet analizleri sonucu Çizelge 3.4 'de gösterilmiştir. Çizelgeye bakıldığı zaman sıcaklığa daha hassas olan türler 2,4-dimetilpentan, benzen ve pentandır. 2,4-dimetilpentan ile benzen emisyonların dizel yakıtlı araçlardan dolayı oluştuğu bilinmektedir ve sıcaklık artışı ile araç içinde bulunan yakıt ısınıp buharlaşmaya başlar ve dolayısıyla bu türlerin emisyonları artmaya başlar. Hassasiyet analizlerine göre saat parametresi diğer girdi değerlerine göre UOB konsantrasyonlarını en az etkileyen parametre olmuştur. Nem ve rüzgar hızı konsantrasyonlar üzerinde önemli etkileri olan diğer parametrelerdir.

Çizelge 3.4 UOB türleri için mutlak ve yüzdelik hassasiyet analizi sonuçları

No	UOB Türleri	Mutlak veya Bağıl	Rüzgar yönü	Rüzgar Hızı	Sıcaklık	Nem	Tarih	Saat
1	1,2,3-trimetilbenzen	Mutlak Bağıl	0.097 17.60%	0.098 17.80%	0.05 9.09%	0.141 25.60%	0.087 15.80%	0.035 6.36%
2	1,2,4-trimetilbenzen	Mutlak Bağıl	0.036 18.00%	0.027 13.50%	0.035 17.50%	0.035 17.50%	0.031 15.50%	0.014 7.00%
3	1,3,5-trimetilbenzen	Mutlak Bağıl	0.039 17.00%	0.027 11.70%	0.028 12.20%	0.046 20.00%	0.033 14.30%	0.014 6.09%
4	1-penten	Mutlak Bağıl	0.012 10.00%	0.015 12.50%	0.007 5.83%	0.027 22.50%	0.016 13.30%	0.011 9.17%
5	2,2,4-trimetilpentan	Mutlak Bağıl	0.014 20.00%	0.01 14.30%	0.007 10.00%	0.021 30.00%	0.01 14.30%	0.005 7.14%
6	2,3 dimetilbütan	Mutlak Bağıl	0.27 37.00%	0.26 35.60%	0.291 39.90%	0.348 47.70%	0.308 42.20%	0.118 16.20%
7	2,3-dimetilpentan	Mutlak Bağıl	0.018 16.40%	0.019 17.30%	0.019 17.30%	0.032 29.10%	0.023 20.90%	0.012 10.90%
8	2,4-dimetilpentan	Mutlak Bağıl	0.083 46.10%	0.069 38.30%	0.165 91.70%	0.133 73.90%	0.057 31.70%	0.065 36.10%
9	2-metilbütan	Mutlak Bağıl	0.442 13.90%	0.9 28.40%	0.877 27.70%	1.746 55.10%	0.468 14.80%	0.222 7.00%
10	2-metilpentan	Mutlak Bağıl	5.198 134%	1.683 43.30%	2.818 72.40%	8.152 210%	4.156 107%	0.697 17.90%
11	3-metilhekzan	Mutlak Bağıl	0.046 16.40%	0.043 15.40%	0.06 21.40%	0.135 48.20%	0.043 15.40%	0.016 5.71%
12	3-metilpentan	Mutlak Bağıl	1.195 33.30%	1.079 30.10%	1.433 39.90%	2.804 78.10%	0.999 27.80%	0.39 10.90%
13	a-pinen	Mutlak Bağıl	0.198 68.30%	0.178 61.40%	0.127 43.80%	0.332 114%	0.188 64.80%	0.1 34.50%
14	b-pinen	Mutlak Bağıl	0.083 55.30%	0.065 43.30%	0.049 32.70%	0.125 83.30%	0.071 47.30%	0.029 19.30%
15	p-etiltoluen	Mutlak Bağıl	0.075 20.80%	0.056 15.60%	0.035 9.72%	0.066 18.30%	0.059 16.40%	0.027 7.50%
16	Siklohekzan	Mutlak Bağıl	0.284 34.20%	0.25 30.10%	0.157 18.90%	0.411 49.50%	0.256 30.80%	0.157 18.90%
17	Undekan	Mutlak Bağıl	0.081 31.20%	0.051 19.60%	0.044 16.90%	0.073 28.10%	0.058 22.30%	0.028 10.80%
18	Benzen	Mutlak	0.763	1.086	1.162	0.616	0.052	0.522

		Bağıl	41.00%	58.40%	62.50%	33.10%	2.80%	28.10%
19	c-2-penten	Mutlak	0.016	0.009	0.009	0.035	0.01	0.004
		Bağıl	14.50%	8.18%	8.18%	31.80%	9.09%	3.64%
20	Etilbenzen	Mutlak	0.168	0.155	0.168	0.189	0.105	0.044
		Bağıl	22.10%	20.40%	22.10%	24.90%	13.80%	5.79%
21	Heptan	Mutlak	0.037	0.026	0.018	0.04	0.028	0.014
		Bağıl	14.80%	10.40%	7.20%	16% 11	.2% 5.	6%
22	Hekzan	Mutlak	4.166	3.83	4.706	10.38	3.48	2.161
		Bağıl	47.60%	43.70%	53.70%	118%	39.70%	24.70%
23	İsopropilbenzen	Mutlak	0.01	0.007	0.005	0.015	0.009	0.004
		Bağıl	14.30%	10.00%	7.14%	21.40%	12.90%	5.71%
24	m-etiltoluen	Mutlak	0.02	0.01	0.027	0.033	0.024	0.01
		Bağıl	14.40%	10.60%	15.00%	18.30%	13.30%	5.56%
25	m&p-ksilen	Mutlak	0.134	0.309	0.042	0.063	0.077	0.123
		Bağıl	5.45%	12.60%	1.71%	2.56%	3.13%	5.00%
26	Metilsiklopentan	Mutlak	2.131	1.484	1.268	1.849	1.421	0.794
		Bağıl	68.30%	47.60%	40.60%	59.30%	45.50%	25.40%
27	Nonan	Mutlak	0.093	0.07	0.04	0.115	0.074	0.029
		Bağıl	19.80%	14.90%	8.51%	24.50%	15.70%	6.17%
28	Oktan	Mutlak	0.028	0.019	0.02	0.027	0.021	0.009
		Bağıl	17.50%	11.90%	12.50%	16.90%	13.10%	5.63%
29	Pentan	Mutlak	0.127	0.266	0.037	0.085	0.074	0.116
		Bağıl	13.79%	6.58%	47.32%	20.60%	23.66	15.09%
30	Siklopentan	Mutlak	0.089	0.087	0.075	0.139	0.087	0.032
		Bağıl	27.80%	27.20%	23.40%	43.40%	27.20%	10.00%
31	Toluen	Mutlak	0.034	0.023	0.016	0.039	0.025	0.012
		Bağıl	0.14%	0.09%	0.06%	0.16%	0.10%	0.05%
32	O-ksilen	Mutlak	0.11	0.384	0.304	0.454	0.156	0.091
		Bağıl	14.30%	49.90%	39.50%	59.00%	20.30%	11.80%
33	t- 2 penten	Mutlak	0.019	0.015	0.013	0.022	0.015	0.008
		Bağıl	14.60%	11.50%	10.00%	16.90%	11.50%	6.15%

Bağıl hassasiyet, ortalama konsantrasyonların mutlak hassasiyete oranı ile bulunmuştur.

SONUÇLAR VE ÖNERİLER

Yapay sinir ağları, hava kirliliği kalitesi modellemelerinde eldeki veri setinin kalitesine ve miktarına bağlı olarak oldukça iyi sonuçlar verebilmektedir. Bölüm 3'te verilen grafiklerden yola çıkarak şu sonuçlara ulaşılabilmektedir. Özellikle klasik istatistiksel yöntemlerin ve regresyon modellerinin yanında başarılı tahmin sonuçlarına ulaşılabilmektedir. Veri setinin çeşitliliğine ve sayısına bağlı olarak modelin öğrenme kabiliyeti değişmektedir. Aynı şekilde gizli katmanda kullanılan nöron sayısının, aktivasyon ve toplama fonksiyonlarının değiştirilmesi ile model tahmin sonucunda istenilen sonuçlara ulaşılabilmektedir.

Elde edilen grafiklerden (Bölüm 3) şu sonuçlara ulaşılabilmektedir;

1. Uygulanan MLP modeli sonucu, çalışmada kullanılan 33 adet atmosferik uçucu organik bileşiklerin modellenmesi ile elde edilen korelasyon katsayıları 0.547 ile 0.818 arasında değişmektedir. Bu da hava kirliliği kalitesi modellenmesi açısından başarılı bir sonuçtur. Atmosferik uçucu organik bileşiklerin yapay sinir ağları ile modellenmesi ile ilgili daha önce yapılan bir çalışma bulunmadığı için bulunan bu sonuçlar literatür sonuçları ile karşılaştırılamamaktadır ancak daha önce yapılan yapay sinir ağları ile hava kalitesi modelleme çalışmalarına bakıldığı zaman son derece başarılı sonuçlar elde edilmiştir. Kurulan ağ yapılarına bakıldığı zaman, aktivasyon fonksiyonu olarak sigmoid fonksiyonunun diğer fonksiyonlara göre daha iyi sonuçlar verdiği deneme yanılma yolu ile görülmüştür. Aktivasyon fonksiyonu olarak hiperbolik tanjant ve doğrusal fonksiyon uygulanmıştır. Bu iki fonksiyon UOB'lerin türlerine göre farklı sonuçlar vermektedir. Eğitim, validasyon ve test setlerinin oranları modelin

tahmin başarısı için önemlidir. Modelin örneklerin ortalama davranışını öğrenebilmesi için eğitim seti için yeterli oranda veri ayrılmalıdır aksi takdirde model başarılı bir şekilde eğitilemez ve bunun sonucunda tahmin kabiliyeti düşer. Genel olarak veri seti, %60-%70'i eğitim seti , %15- %20'si validasyon seti ve % 25-%20'si test seti olarak ayrıldığı zaman gerçeğe yakın bir tahmin sonucuna ulaşıldığı görülmüştür. Nöron sayısı yapay sinir ağlarının yapısının kurulmasında diğer bir parametredir. Bu çalışmada 14 ile 18 adet nöron kullanılmıştır. Daha az ya da daha fazla sayıda nöron kullanıldığı zaman çıktı değerlerinin istenilen sonuçlarda olmadığı görülmüştür. 33 UOB türü için oluşturulan en iyi yapay sinir ağı modelleri Çizelge 4.1' de verilmiştir.

Çizelge 4.1 33 UOB türü için kurulan en iyi model yapıları

No	UOB Türleri	Nöron Sayısı	Transfer Fonksiyonu	Aktivasyon Fonksiyonu	Eğitim Seti	Validasyon Seti	Test Seti	R
1	1,2,3-trimetilbenzen	16	Sigmoid	Doğrusal	60%	15%	25%	0.68
2	1,2,4-trimetilbenzen	16	Sigmoid	Doğrusal	60%	15%	25%	0.67
3	1,3,5-trimetilbenzen	16	Sigmoid	Tanh	65%	15%	25%	0.67
4	1-penten	15	Sigmoid	Doğrusal	70%	15%	15%	0.70
5	2,2,4-trimetilpentan	15	Sigmoid	Doğrusal	60%	15%	25%	0.81
6	2,3 dimetilbütan	13	Sigmoid	Doğrusal	60%	15%	25%	0.66
7	2,3-dimetilpentan	15	Sigmoid	Tanh	60%	15%	25%	0.78
8	2,4-dimetilpentan	13	Sigmoid	Doğrusal	60%	20%	20%	0.65
9	2-metilbütan	15	Sigmoid	Tanh	60%	15%	25%	0.61
10	2-metilpentan	14	Sigmoid	Doğrusal	60%	15%	25%	0.63
11	3-metilhekzan	15	Sigmoid	Tanh	60%	15%	25%	0.71
12	3-metilpentan	15	Sigmoid	Doğrusal	60%	15%	25%	0.54
13	a-pinen	15	Sigmoid	Doğrusal	60%	20%	20%	0.68
14	b-pinen	15	Sigmoid	Tanh	60%	20%	20%	0.71
15	p-etiltoluen	18	Sigmoid	Tanh	60%	15%	25%	0.71
16	Siklohekzan	15	Sigmoid	Doğrusal	60%	20%	20%	0.70
17	Undekan	17	Sigmoid	Tanh	60%	15%	25%	0.58
18	Benzen	15	Sigmoid	Tanh	70%	15%	15%	0.74
19	c-2-penten	16	Sigmoid	Doğrusal	60%	20%	20%	0.74
20	Etilbenzen	16	Sigmoid	Tanh	60%	15%	25%	0.73

21	Heptan	15	Sigmoid	Tanh	60%	20%	20%	0.73
22	Hekzan	15	Sigmoid	Tanh	60%	20%	20%	0.70
23	İsopropilbenzen	15	Sigmoid	Doğrusal	60%	20%	20%	0.64
24	m-etiltoluen	17	Sigmoid	Doğrusal	60%	15%	25%	0.62
25	m&p-ksilen	19	Sigmoid	Tanh	60%	20%	20%	0.59
26	Metilsiklopentan	15	Sigmoid	Tanh	60%	20%	20%	0.70
27	Nonan	14	Sigmoid	Doğrusal	60%	15%	25%	0.37
28	Oktan	13	Sigmoid	Doğrusal	70%	15%	15%	0.71
29	Pentan	16	Sigmoid	Tanh	60%	15%	25%	0.47
30	Siklopentan	14	Sigmoid	Doğrusal	60%	20%	20%	0.65
31	Toluen	13	Sigmoid	Tanh	70%	15%	15%	0.59
32	O-ksilen	15	Sigmoid	Doğrusal	70%	15%	15%	0.56
33	t- 2 penten	15	Sigmoid	Doğrusal	70%	15%	15%	0.62

2. UOB konsantrasyonları ölçüm yapıldığı tarihler arasında yaz ve kış aylarında büyük salınımlar gösterebilmektedir. Model bu salınımlarının her birini ayrı birer durum gibi algılamaktadır. Bu durumda bu salınımlar veri seti içinde örnek olarak temsil edilememektedirler. Dolayısıyla model bu durumları tek bir durum gibi algılayamadığı için öğrenme kabiliyeti düşmektedir.
3. UOB'lerin kaynakları değiştikçe meteorolojik parametrelerin bu türlere olan etkileri de değişmektedir. Özellikle rüzgar yönüne, sıcaklığa ve neme olan hassasiyet diğer parametrelere göre daha fazla olduğu görülmektedir. Genel eğilim olarak nem miktarı arttıkça UOB konsantrasyonlarının azaldığı görülmektedir. Özellikle solvent kullanımından kaynaklanan UOB türlerinin konsantrasyonları rüzgar yönü doğudan güneye doğru kaydıkça artması beklenmektedir kurulan model bu eğilimi başarılı bir şekilde tahmin etmektedir. UOB konsantrasyonları sıcaklık arttıkça azaldığı bilinmektedir. Hassasiyet analizlerine bakıldığı zaman model bu durumu iyi bir şekilde tahmin etmektedir. Akşam saatlerine doğru uçucu organik bileşikler reaksiyona girerek konsantrasyonları azalmaktadır bunun sonucunda en yüksek konsantrasyonlar sabah ve öğle saatlerinde görülmektedir. Model sonuçları da bu eğilimi doğru bir şekilde göstermektedir.

4. Verilen grafiklere bakıldığı zaman model sonuçları 33 UOB türü için büyük oranda başarılı sonuçlar verdiği söylenebilir. Veri setini oluşturan örneklerin sayısı da model başarısını etkilemektedir. Veri sayısının değişimi ile farklı sonuçlar alınabilmektedir.

Yapay sinir ağlarının hava kirliliği modellemesinde başarılı sonuçlar verdiği görülmektedir. Sadece meteorolojik parametreler, tarih ve saat değerleri kullanılarak oluşturulan model istatistiki olarak iyi sonuçlar vermektedir. Model veri miktarı ve kalitesi ne kadar geniş olursa model başarısı o oranda iyi olmaktadır. Model girdi sayısının arttırılmasıyla ve UOB konsantrasyonlarına etki eden diğer parametrelerin de modele eklenmesiyle daha iyi sonuçlar alınabilir örneğin solar radyasyon ve karışım yüksekliği parametresinin eklenmesi tahmin sonuçlarını olumlu şekilde etkileyebilir. Çünkü sıcaklık, karışım yükseliği ve solar radyasyon arasında birbirini etkileyen bir ilişki vardır ve bu üç parametrenin aynı anda modele verilmesi daha doğru tahmin sonuçlarına ulaşılmasını sağlayacaktır. Özellikle hassasiyet analizlerinde bu parametrelerin konsantrasyonları ne derece etkilediği ya da ne yönde etkilediği daha iyi bir şekilde anlaşılacaktır. Veri setinin genişletilmesi ve eğitim ve test setlerine ayrılan örnek sayısının arttırılması ile daha başarılı sonuçlar elde edilebilir. Şuan ki model de sadece bahar aylarının olmasından dolayı sıcaklık ve nem değerlerinin UOB konsantrasyonları üzerine ne derece etki ettiği tam olarak söylenememektedir. Ölçüm periyodunun uzatılması kış aylarının da modele dahil edilmesi ile mevsimsel değişimlerin konsantrasyonlara ne şekilde etki ettiği daha doğru bir şekilde analiz edilebilirdi. Ölçüm süresi boyunca konsantrasyonların yüksek salınımlara sahip olması tahmin kabiliyetini etkilemektedir. Bu durumu ortadan kaldırmak için sınıf eşitleme metodunu kullanılabilir.

Yapılan bu çalışmaya benzer daha önce yapılmış bir çalışma bulunmadığı için bundan sonraki çalışmalara referans teşkil ederek ülkemizin hava kalitesi çalışmalarına daha fazla katkıda bulunulabilir.

KAYNAKLAR

- [1] Barletta, B., Meinardi, S., Simpson, J.I., Khwaja, A.H., Blake, R.D., and Rowland, S.F., (2002). "Mixing ratios of volatile organic compounds (VOCs) in the atmosphere of Karachi, Pakistan", *Atmospheric Environment* 36 3429–3443.
- [2] Lincoln, R., Boxshall, G., and Clark, P., (1998), VOC, *in* A Dictionary of Ecology, Evolution and Systematics (2 ed.): Cambridge, United Kingdom, Cambridge University Press, p. 314.
- [3] Andiç, Ö., (2008), Determination of Volatile Organic Compounds Around Aliaga By Passive Sampling Methods, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- [4] Yu, M.H., (2005). Environmental toxicology: Biological and health effects of pollutants, 2. baskı, CRC Press, ABD.
- [5] Wang, P., and Zhao, W., (2008). "Assessment of ambient volatile organic compounds (VOCs) near major roads in urban Nanjing, China", *Atmospheric Research* 89 , 289–297.
- [6] Arslanbaş, D., (2008). Kocaeli’nde Konut, İşyeri Ve Okullarda Uçucu Organik Bileşiklerin Belirlenmesi, Doktora Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- [7] Jenkin, E.M., Saunders, S.M., and Pilling, M.J, (1997). "The Tropospheric Degradation Of Volatile Organic Compounds: A Protocol For Mechanism Development", *Atmospheric Environment* 31 (1): 81-104.
- [8] Demir, S., (2011). İstanbul Atmosferinde Uçucu Organik Bileşik Kirliliğinin Kaynaklarının Belirlenmesi: Ytü Davutpaşa Kampüsü Örneği, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [9] Carter, W.P.L., (1994). "Development of ozone reactivity scales for volatileorganic compounds", *Journal of the Air and Waste Management Association* 44: 881-899.
- [10] Chen, J., and Luo, D., (2012). "Ozone formation potentials of organic compounds from different emission sources in the South Coast Air Basin of California", *Atmospheric Environment* 55: 448-455.

- [11] Ting, M., Yue-si, W., Hong-hui, X., Fan-kun, W., and Xiao-bin, X., (2008). "A study of the atmospheric VOCs of Mount Tai in June 2006", *Atmospheric Environment* 43: 2503–2508.
- [12] Geng, F., Zhao, C., Lu, G., and Tie, X., (2007). "Analysis of ozone and VOCs measured in Shanghai: A case study", *Atmospheric Environment* 41: 989–1001.
- [13] Chan, C.Y., Chan, L.Y., Wang, X.M., Liu, Y.M., Lee, S.C., Zou, S.C., Sheng, G.Y. and Fu, J.M., (2002). "Volatile organic compounds in roadside microenvironments of metropolitan Hong Kong", *Atmospheric Environment*, 36: 2039-2047.
- [14] U.S. Geological Survey, (2005), *Water resources data--Definition of terms*: U.S. Geological Survey, access date May 28, 2010.
- [15] Kansal, A., (2009). "Sources and reactivity of NMHCs and VOCs in the atmosphere: A review", *Journal of Hazardous Materials* 166: 17–26.
- [16] B. Barletta, S. Meinardi, F.S. Rowland, Chuen-Yu Chan, X.g. Wang, S. Zou, Lo Yin Chan, and D.R. Blake, (2005). "Volatile organic compounds in 43 Chinese cities", *Atmos. Environ.* 39 (32): 5979–5990.
- [17] Guo, Z., Chang, J.C.S., Sparks, E.L., and Fortman, R.C., (1999). "Estimation of the rate of VOC emissions from solvent-based indoor coating materials based on product formulation", *Atmospheric Environment* 33: 1205-1215.
- [18] Sevimoğlu, O., ve Tansel, B., (2013). "Effect of persistent trace compounds in landfill gas on engine performance during energy recovery: A case study", *Waste Management* 33: 74–80.
- [19] Carter, W.P.L., (1994). "Development of ozone reactivity scales for volatile organic compounds", *Journal of the Air and Waste Management Association*, 44: 881-899.
- [20] Fernandez-Martinez, G., Lopez-Mahia, P., Muniategui-Lorenzo, S., Prada-Rodriguez, D., Fernandez-Fernandez, E., (2001). "Distribution of volatile organic compounds during the combustion process in coal-fired power stations", *Atmospheric Environment* 35: 5823–5831.
- [21] Yılmaz, D., (2006). *Bazı Uçucu Organik Bileşiklerin Absorpsiyonla Giderimi, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun.*
- [22] Spellman, G., (1999). "An application of artificial neural networks to the prediction of surface ozone concentrations in the United Kingdom", *Applied Geography* 19 : 123–136.
- [23] Abdul-Wahap, S.A., and AL-Alevi, S.M., (2002). "Assessment and prediction of tropospheric ozone concentration levels using artificial neural Networks", *Environmental Modelling & Software* 17: 219–228.
- [24] Khedairia, S., and Khadir, T.M., (2012). "Impact of clustered meteorological parameters on air pollutants concentrations in the region of Annaba", *Algeria. Atmospheric Research* 113: 89–101.

- [25] Chan, Y.C., and Jian, L., (2013). "Identification of significant factors for air pollution levels using a neural network based knowledge discovery system", *Neurocomputing* 99: 564–569.
- [26] Berastegi, I.G., Elias, A., Barona, A., Saenz, J., Ezcurra, A., and Diaz de Argando, J., (2008). "From diagnosis to prognosis for forecasting air pollution using neural networks: Air pollution monitoring in Bilbao", *Environmental Modelling & Software* 23: 622-637.
- [27] Akkoyunlu, A., Yetilmezsoy, K., Ertürk, F., ve Oztemel, E., (2010). "A neural network-based approach for the prediction of urban SO₂ concentrations in the Istanbul metropolitan area", *Int. J. Environment and Pollution*, 40 (4).
- [28] Grivas, G., and Chaloulakou, A., (2006). "Artificial neural network models for prediction of PM₁₀ hourly concentrations, in the Greater Area of Athens, Greece", *Atmospheric Environment* 40: 1216–1229.
- [29] Feng, Y., Zhang, W., Sun, D., and Zhang, L., (2011). "Ozone concentration forecast method based on genetic algorithm optimized back propagation neural networks and support vector machine data classification", *Atmospheric Environment* 45: 1979-1985.
- [30] Mok, K.M., and Tam, S.C., (1998). "Short-term prediction of SO₂ concentration in Macau with artificial neural Networks", *Energy and Buildings* 28: 279-286.
- [31] Voukantsis, D., Karatsaz, K., Kukkonen, J., Rasanen, T., Karppinen, A., and Kolehmainen, M., (2011). "Intercomparison of air quality data using principal component analysis, and forecasting of PM₁₀ and PM_{2.5} concentrations using artificial neural networks, in Thessaloniki and Helsinki", *Science of the Total Environment* 409: 1266–1276.
- [32] Viotti, P., Liuti, G., and Di Genova, P., (2001). "Atmospheric urban pollution: applications of an artificial neural network (ANN) to the city of Perugia", *Ecological Modelling* 148: 27–46
- [33] Kunt, F., (2007). Hava Kirliliğinin Yapay Sinir Ağları Yöntemiyle Modellenmesi Ve Tahmini, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- [34] Yılmaz, E.C., (2009). Bir Atıksu Arıtma Tesisinin Girişindeki Biyolojik Oksijen İhtiyacının Yapay Sinir Ağları Kullanılarak Modellenmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Fakültesi, Sakarya.
- [35] Pankaj , M., and Wah, B., (1992). " Mehra Pankaj Wah W Benjamin, Artificial Neural Networks Concepts and Theory", IEEE Computer Society Press, Washington, 45.
- [36] Gülbay, A., (2006). Yapay sinir ağı ve bulanık mantık tabanlı algoritmalar ile uçucu organik bileşiklerin miktarsal tayini, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Fakültesi, Sakarya.
- [37] Saraç, T., (2004). Yapay Sinir Ağları, Seminer Projesi; Gazi Üniversitesi Endüstri Mühendisliği Bölümü Ana Bilim Dalı, Ankara.

- [38] Öztürk, C., (2007). Yapay Sinir Ağları Ve ASM2 Kullanılarak Aktif Çamur Prosesinin Kontrolü Ve Modellenmesi, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [39] Sezer, M., (2007). Yapay Sinir Ağları (YSA) Kullanılarak KOİ Parametresinden BOİ Parametresinin Tahmin Edilmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Fakültesi, Sakarya.
- [40] Açıkalın, S., (2007). Atıksu Arıtma Tesisi Veriminin Yapay Sinir Ağları İle Tahmin Edilmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- [41] Yüksek, A.G., (2007). Hava Kirliliği Tahmininde Çoklu Regresyon Analizi Ve Yapay Sinir Ağları Yönteminin Karşılaştırılması, Doktora Tezi, Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Sivas.
- [42] Lu, W.Z., Fan, H.Y., and Lo, S.M., (2009). "Application of evolutionary neural network method in predicting pollutant levels in downtown area of Hong Kong", *Neurocomputing* 51: 387 – 400.
- [43] İnce, T., Kiranyaz, S., Pulkkinen, J., and Gabbouj, M., (2010). "Evaluation of global and local training techniques over feed-forward neural network architecture spaces for computer-aided medical diagnosis", *Expert Systems with Applications* 37: 8450–8461.
- [44] Reich, S.L., Gomez, D.R., and Dawidowski, L.E., (1999). "Artificial neural network for the identification of unknown air pollution sources", *Atmospheric Environment* 33: 3045-3052.
- [45] Cai, M., Yin, Y., and Xie, M., (2009). "Prediction of hourly air pollutant concentrations near urban arterials using artificial neural network approach", *Transportation Research Part D* 14: 32–41.
- [46] Chelani, A. B., Chalapati Rao, C. V., and Hasan, M. Z., (2002). "Prediction of sulphur dioxide concentration using artificial neural Networks". *Environmental Modelling & Software* 17: 161–168.
- [47] Nagendra, S.S.M., and Khare, M., (2006). "Artificial neural network approach for modelling nitrogen dioxide dispersion from vehicular exhaust emissions", *Ecological Modelling* 190: 99–115.
- [48] Saral, A., (2000). Hava Kirliliğinin Yapay Sinir Ağları ile Modellenmesi ve Tahmini, Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul.
- [49] Aguilera, P.A., Frenich, A.G., Torres, J.A., Castro, H., Martinez Vidal, J.L. and Canton, M., (2001). Application of the kohonen neural network in coastal water management: methodological development for the assessment and prediction of water quality, *Water Research*, 35(17): 4053-4062.
- [50] Pudasainee, D., Sapkota, B., Shrestha, L., M., Kaga, A., Kondo, A., and Inoue, Y., (2006). "Ground level ozone concentrations and its association with NO and meteorological parameters in Kathmandu valley, Nepal", *Atmospheric Environment* 40: 8081–8087

- [51] Zheng, Y., Stevenson, K.J., Barrowcliffe, R., Chen, S., Wang, H. ve Barnes, J.D., (1998). "Ozone levels in Chongqing: a potential threat to crop plants commonly grown in the region?", *Environmental Pollution*, 99: 299-308.
- [52] Jonson, J.E., Sundet, J.K. ve Tarrason, L., (2001). "Model calculations of present and future levels of ozone and ozone precursors with a global and regional model", *Atmospheric Environment* ,35: 525-537.
- [53] Wark, K., Warner, C.F. ve Davis, W.T., (1998). *Air Pollution: Its origin and control*, 3. baskı, Addison-Wesley Longman, Inc., ABD.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	Nevrin ALTINKUM
Doğum Tarihi ve Yeri	24 Aralık 1989, İstanbul
Yabancı Dili	İngilizce
E-posta	nevrinaltinkum@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Y. Lisans	Çevre Mühendisliği	Yıldız Teknik Üniversitesi	2013
Lisans	Çevre mühendisliği	Yıldız Teknik Üniversitesi	2012

Proje

1. Saral, A., Demir, S., Kuzu, S.L., Summak, G., Altinkum, N., Mukhanbetkhali, A., (2012). "Kentsel Atmosferde Poli Klorlu Bifenil (PCB) Konsantrasyonlarının Gaz ve Partiküllerde Fraksiyonel Değişimlerinin Belirlenmesi ile Beraber Uzun Mesafeli Taşınımının İncelenmesi." 111Y225 no.lu Tübitak Projesi.