

95058

**YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

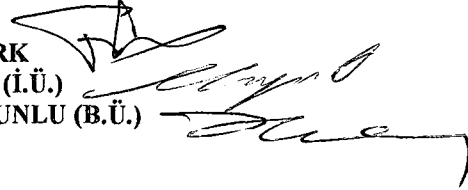
**HAVA KİRLİLİĞİNİN YAPAY SINIR AĞLARI  
YÖNTEMİYLE MODELLENMESİ VE TAHMİNİ**

**Kimya Müh. Arslan SARAL (Çevre Yük.Lis.)**

**F.B.E. Çevre Mühendisliği Anabilim Dalında  
Hazırlanan**

**DOKTORA TEZİ**

**Tez Savunma Tarihi : 28.04.2000**  
**Tez Danışmanı : Prof.Dr. Ferruh ERTÜRK**  
**Jüri Üyeleri : Prof.Dr. Cuma BAYAT (İ.Ü.)**  
**: Doç.Dr. Atilla AKKOYUNLU (B.Ü.)**



**İSTANBUL, 2000**

# İÇİNDEKİLER

Sayfa

ŞEKİL LİSTESİ .....	iv
ÇİZELGE LİSTESİ .....	vi
ÖNSÖZ.....	vii
ÖZET .....	viii
ABSTRACT .....	ix
1 GİRİŞ.....	1
1.1 Tanım.....	1
1.2 Kirleticilerin Atmosferdeki Hareketleri.....	1
1.2.1 Dikey hareketler.....	3
1.2.2 Yatay yöndeki hareketler (rüzgarlar).....	7
1.2.3 Türbülanslı hava hareketleri .....	8
1.2.4 Moleküler diffüzyonla dağılma .....	9
2 ÖNCEKİ ÇALIŞMALAR .....	10
2.1 İstanbul'un Günümüze Kadar Hava Kirliliği Durumu.....	10
2.2 İstanbul'un Hava Kirliliği İle İlgili Önceki Çalışmalar.....	11
2.3 Hava Kirliliği Modellemesinde Yapay Sinir Ağları Uygulamaları ile İlgili Önceki Çalışmalar .....	12
3 YAPAY SİNİR AĞLARI .....	15
3.1 Giriş .....	15
3.2 Biyolojide Nöron ve Nöronun Matematiksel Modeli .....	15
3.3 Yapay Sinir Ağının Yapısı.....	16
3.3.1 İşlem Elemanı .....	17
3.3.2 Giriş işareti sınıfları .....	18
3.3.3 Bağlantı geometrileri .....	19
3.3.4 YSA ağ tipleri .....	20
3.3.5 Eşik fonksiyonları .....	20
3.3.6 Ağırlık uzayı .....	21
3.4 Yapay Sinir Ağlarında Eğitim.....	23
3.4.1 Eğitim algoritmaları .....	23
3.4.2 YSA' da bilgiyi saklama.....	24
3.4.3 Hata toleransı .....	25
3.5 Öğrenme Kuralları .....	25
3.5.1 Perceptron (idrak, almaç).....	26
3.5.2 Çok katmanlı perceptron (Multi-layer perceptron).....	27
3.5.3 Hatanın geriye yayılması algoritması ve geliştirilmiş delta kuralı.....	28
3.6 Hatanın Geriye Yayılması Algoritmasının Geliştirilmesi .....	33
3.6.1 Bağlantı ağırlıklarının atanması.....	33
3.6.2 Öğrenme katsayısı .....	33

3.6.3	Momentum katsayısı.....	34
3.7	YSA Kullanımının Sebepleri.....	35
3.8	YSA'nın Klasik Yazılımlar İle Karşılaştırılması.....	35
4	VERİ TABANI VE ÇALIŞMA BÖLGESİ.....	37
4.1	Çalışma Bölgesinin Topografik Durumu.....	37
4.2	Veri Tabanı .....	38
4.2.1	Hava kirliliği verileri .....	38
1.1.2	Meteoroloji verileri .....	39
4.2.2.1	Sıcaklık .....	39
4.2.2.2	Denize indirilmiş basınç .....	39
4.2.2.3	Bulutluluk .....	39
4.2.2.4	Nispi nem.....	40
4.2.2.5	Toplam yağış .....	40
4.2.2.6	Hakim rüzgar yönü ve hızı .....	40
4.2.2.7	Güneşlenme süresi ve şiddeti.....	41
4.2.2.8	Enversiyon başlangıcı ve şiddeti .....	41
4.3	Verilerin Analizi Ve Model İçin Girdi Seti Hazırlanışı.....	49
4.3.1	Değer sıralı veri gruplandırması .....	50
4.3.2	Zaman sıralı veri gruplandırması.....	51
4.4	Verilerin Normalizasyonu .....	53
5	SONUÇLAR VE ÖNERİLER.....	55
5.1	Model Performansını Ve Öğrenme Aşamasını Etkileyen Parametrelerin Durumu.....	55
5.2	Doğrulama Eğitme İle Denenen Çeşitli Modellerin Performansları .....	56
5.3	Verilerde Sınıf Eşitlemesinin Model Performansı Üzerindeki Etkileri.....	57
5.4	Veri Setleri Sınıflandırmasının Model Performansı Üzerindeki Etkileri .....	58
5.5	Öneriler .....	61
	ÖZGEÇMİŞ.....	82

## ŞEKİL LİSTESİ

Şekil 1.1	Kirleticilerin atmosferde kaynaktan alıcıya kadar izlediği yol .....	2
Şekil 1.2	Kuru bir atmosferde kararlılığa örnek olarak sıcaklık profilleri .....	4
Şekil 1.3	İki önemli enversiyon tipinin oluşumlarının şematik gösterimi.....	6
Şekil 1.4	Kuzey yarım kürede bir siklonda yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri.....	7
Şekil 1.5	Kuzey yarım kürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri.....	7
Şekil 1.6	Basitleştirilmiş olarak bir türbülans girdabının kirletici gaz kütesini parçalaması ve kirleticilerin çok daha hızlı bir şekilde temiz hava ile karışması. ....	9
Şekil 3.1	Nöronun matematiksel modeli .....	16
Şekil 3.2	YSA'nın blok diyagramı .....	17
Şekil 3.3	YSA Genel İşlem Elemanı Yapısı.....	17
Şekil 3.4	Tetikleyici ve yasaklayıcı girişlere sahip bir işlem elemanı. ....	18
Şekil 3.5	Yapay Sinir Ağları Sınıflandırıcıları. ....	19
Şekil 3.6	Çok kullanılan eşik fonksiyonları .....	21
Şekil 3.7	Üç boyutlu uzayda ağırlık vektörünün değişimi. ....	22
Şekil 3.8	MLP'nin izole edilmiş hali .....	25
Şekil 3.9	Perceptron yapısı ve transfer fonksiyonu. ....	26
Şekil 3.10	Lineer Olarak Ayrılmazlığın Gösterimi. ....	27
Şekil 3.11	Çok katmanlı perceptron .....	28
Şekil 3.12	Hatanın geriye yayılması algoritmasının blok akış diyagramı.....	29
Şekil 3.13	Gizli katmanı olmayan ağırlık hata fonksiyonu.....	30
Şekil 3.14	Gizli katmana ait ağırlık hata fonksiyonu.....	31
Şekil 4.1	Hakim rüzgar yönlerinin YSA modeli için girdi sayısal değerlerine dönüştürülmesi .....	41
Şekil 4.2	Günlük ortalama SO <sub>2</sub> konsantrasyonunun 1994 yılı boyunca değişimi.....	42
Şekil 4.3	Ortalama sıcaklığın 1994 yılı boyunca günlük değişimi.....	43
Şekil 4.4	Denize indirilmiş basıncın 1994 yılı boyunca günlük değişimi.....	43
Şekil 4.5	Bulutluluğun 1994 yılı boyunca günlük değişimi .....	44
Şekil 4.6	Nispi nemin 1994 yılı boyunca günlük değişimi .....	44
Şekil 4.7	Toplam yağışın1994 yılı boyunca günlük değişimi .....	45
Şekil 4.8	Hakim rüzgar yönlerinin1994 yılı boyunca günlük değişimi.....	45
Şekil 4.9	Ortalama rüzgar hızlarının 1994 yılı boyunca günlük değişimi.....	46
Şekil 4.10	Güneşlenme sürelerinin 1994 yılı boyunca günlük değişimi .....	46
Şekil 4.11	Güneşlenme şiddetinin 1994 yılı boyunca günlük değişimi .....	47
Şekil 4.12	GMT 00 Enversiyon başlangıçlarının 1994 yılı boyunca günlük değişimleri ....	47
Şekil 4.13	GMT 00 Enversiyon şiddetlerinin 1994 yılı boyunca günlük değişimleri.....	48
Şekil 4.14	GMT 12 Enversiyon başlangıçlarının 1994 yılı boyunca günlük değişimleri ....	48
Şekil 4.15	GMT 12 Enversiyon şiddetlerinin 1994 yılı boyunca günlük değişimleri.....	49
Şekil 4.16	Göztepe istasyonunda ölçülen SO <sub>2</sub> 'nin 1992-1998 yılları arası günlük değişimi50	
Şekil 4.17	1994 yılı içindeki günlük ortalama SO <sub>2</sub> verilerinin küçükten büyüğe sıralanmış hali.....	52
Şekil 4.18	Öğrenme seti SO <sub>2</sub> verileri .....	52
Şekil 4.19	Kullanılan YSA modelinin topolojik yapısı.....	54
Şekil 5.1	Doğrulama eğitmede en iyi model noktası .....	56
Şekil 5.2	Normal öğrenme seti SO <sub>2</sub> konsantrasyonları. ....	58
Şekil 5.3	Sınıf eşitlemesi yapılmış öğrenme seti SO <sub>2</sub> konsantrasyonları. ....	58
Şekil 5.4	Gizli katman nöron sayısının çeşitli tekniklerle eğitilen modellerin performanslarına etkisi (Zaman sıralı veri seti ile çalıştırılan modellerin sonuçları).....	59

Şekil 5.5	Gizli katman nöron sayısının çeşitli tekniklerle eğitilen modellerin performanslarına etkisi (Değer sıralı veri seti ile çalıştırılan modellerin sonuçları).....	59
Şekil 5.6	Zaman ve değer sıralamalı veri setlerinin model performansına etkileri.....	60
Şekil 5.7	4-35-1 YSA modelinin eğitme aşaması sonuçları (Hata=0.05, zaman sıralamalı eğitme seti, sınıf eşitlemesi yok).....	63
Şekil 5.8	14-35-1 YSA modelinin eğitme aşaması en iyi model sonuçları (Hata=0.666, zaman sıralamalı eğitme seti, sınıf eşitlemesi yok).....	64
Şekil 5.9	14-35-1 YSA modelinin eğitme aşaması sonuçları (Hata=0.05, zaman sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	65
Şekil 5.10	14-35-1 YSA modelinin eğitme aşaması en iyi model sonuçları (Hata=0.541, zaman sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	66
Şekil 5.11	14-35-1 YSA modelinin eğitme aşaması sonuçları (Hata=0.05, değer sıralamalı eğitme seti, sınıf eşitlemesi yok).....	67
Şekil 5.12	14-35-1 YSA modelinin eğitme aşaması en iyi model sonuçları (Hata=0.415, değer sıralamalı eğitme seti, sınıf eşitlemesi yok).....	68
Şekil 5.13	14-35-1 YSA modelinin eğitme aşaması sonuçları (Hata=0.05, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	69
Şekil 5.14	14-35-1 YSA modelinin eğitme aşaması en iyi model sonuçları (Hata=0.333, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	70
Şekil 5.15	14-35-1 YSA modelinin test aşaması sonuçları (Hata=1.171, zaman sıralamalı eğitme seti, sınıf eşitlemesi yok).....	71
Şekil 5.16	14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.609, zaman sıralamalı eğitme seti, sınıf eşitlemesi yok).....	72
Şekil 5.17	14-35-1 YSA modelinin test aşaması sonuçları (Hata=1.091, zaman sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	73
Şekil 5.18	14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.482, zaman sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	74
Şekil 5.19	14-35-1 YSA modelinin test aşaması sonuçları (Hata=0.967, değer sıralamalı eğitme seti, sınıf eşitlemesi yok).....	75
Şekil 5.20	14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.668, değer sıralamalı eğitme seti, sınıf eşitlemesi yok).....	76
Şekil 5.21	14-35-1 YSA modelinin test aşaması sonuçları (Hata=0.934, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	77
Şekil 5.22	14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.604, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı).....	78

## ÇİZELGE LİSTESİ

Çizelge 1.1	Kirli atmosfer ile temiz atmosferin karşılaştırılması .....	1
Çizelge 2.1	İstanbul'da 1990'daki kirletici emisyonlarının dağılımı .....	10
Çizelge 4.1	Modelde kullanılan parametreler ve bunların 1994 yılı boyunca maksimum, ortalama ve minimum değerleri .....	51
Çizelge 5.1	Model yapısına bağlı olarak modelin ihtiva ettiği ağırlık katsayısı adedi .....	62



## ÖNSÖZ

Hava kirliliğinin modellenmesi ve önceden tahmini yerel yönetimler için önemli bir husustur. Özellikle kirliliğinin yoğun olarak yaşanacağı kış aylarında, meteorolojik koşullara bağlı olarak hava kirliliğinin önceden (24 saat önceden) bilinmesi zamanında tedbir alınmasına ve hava kirliliğinden en az ölçüde etkilenmeye katkıda bulunacaktır. Bu noktadan bakıldığında hava kirliliği modellemesi ve önceden tahmini çalışmalarının önemi ortaya çıkmaktadır. İstanbul örneği ele alınarak yapılan bu çalışmada, her gün düzenli olarak ölçülen meteorolojik parametreler kullanılarak atmosfer uygulamalarında çok yeni ve klasik istatistiksel metotlara kıyasla oldukça başarılı sonuçlar ortaya koyan yapay sinir ağıları modelleri kullanılarak kirlilik parametresinin (SO<sub>2</sub>) 24 saat sonraki değeri tahmin edilmiştir.

Önceki çalışmalarında olduğu gibi bu tez çalışmasında da özellikle çalışma metodu açısından kendisinden çok istifade ettiğim tez Hocam Prof.Dr. Ferruh Ertürk'e kalbi teşekkürlerimi sunarım. Yine konu ile ilgili fikirlerinden istifade ettiğim kıymetli hocalarım Doç.Dr. Atilla Akkoyunlu ve Doç.Dr. Ercan Öztemel'e teşekkürlerimi sunarım.

Çalışmamın en sıkıntılı zamanında verileri elde etmemde çok büyük yardımlarını gördüğüm Ankara Refik Saydam Hıfzısıhha Enstitüsü Merkez Başkanı Sayın Kadir Başar'a halisane müteşekkirim.

Çevre Mühendisliği Bölümündeki çalışma arkadaşlarım her zaman hatırımda...

Arslan Saral  
İstanbul, 2000

## ÖZET

Ülkemizde hava kirliliği özellikle büyük şehirler için kış aylarında önemli bir problem olarak kendisini göstermektedir. Kirleticilerin atmosfere bırakılma miktarı yanında olumsuz oluşan atmosferik şartlar (stabil veya kararlı durumlar) büyük şehirlerde hava kirliliği olayları oluşmasına sebep olmaktadır. İstanbul örneğinde olduğu gibi geçmişte bu tür hava kirliliği olayları sıkça görülmüştür. Bu noktadan yaklaşıldığında hava kirliliği modellenmesi ve önceden tahmininin bu tür olumsuzlukların oluşmadan önlenmesinde veya tedbir alınmasında büyük yararlar sağlayacağı aşikardır.

Bu çalışmada İstanbul örneği ele alınarak, atmosfer uygulamalarında oldukça yeni ve başarılı sonuçlar veren Yapay Sinir Ağları (YSA) modelleri kullanılarak hava kirliliğinin çeşitli meteorolojik parametreler bazında modellenmesi ve 1 gün sonraki hava kirliliğinin tahmini yapılmıştır. Kullanılan meteorolojik parametreler İstanbul Göztepe Sinoptik Meteoroloji İstasyonunda her gün düzenli olarak ölçülen kuru termometre sıcaklığı, basınç (deniz seviyesi), nispi nem, bulutluluk, toplam yağış, hakim rüzgar yönü ve hızı, güneşlenme süresi ve şiddeti gibi klimatolojik ölçümlerin yanında, enversiyon yüksekliği ve şiddeti (00.00 GMT ve 12.00 GMT olmak üzere günlük 2 ölçüm) gibi radyosonde ölçümleridir. Bu bağımsız parametrelerle, yine İstanbul Hıfzısıhha Enstitüsünün Göztepe Meteoroloji İstasyonunda kurulu bulunan ölçüm noktasında ölçülen günlük ortalama kükürtdioksit parametresi modellenen ve tahmin edilen hava kirliliği parametresi olarak kullanılmıştır.

1992-1998 periyodunu kapsayan altı yıllık veri tabanı incelendiğinde modelleme için ancak 1994 yılı verileri uygun veri seti olarak ortaya çıkmıştır. Bu miktar verinin literatürde rastlanan bu konudaki çalışmalarda kullanılan ortalama veri tabanından daha büyük olduğu görülmüştür. Bu veri seti orijinal haliyle zaman sıralamalı ve SO<sub>2</sub> bazında değer sıralamalı olarak iki yöntem ile sıralanarak öğrenme ve test setleri oluşturuldu. Bu setler kullanılarak gizli katman nöron sayısı bazında değişik YSA modelleri oluşturuldu ve eğitime işlemleri uygulandı. Oluşturulan modellerin gizli katman nöron sayıları 25 ile 50 arasında değiştirilerek her bir model eğitime işlemine tabi tutuldu. Eğitime işlemine performansını arttırmak için ayrıca az tekerrür eden verilerin çoğaltılması yöntemi (sınıf eşitlemesi) uygulandı. Bu yöntem model performansını artırıcı yönde etki göstermiştir. Modellerin eğitilmesi işlemi en iyi model noktası ve global minimum noktası olmak üzere iki noktada incelendi. Veri seti bazında model performansları incelendiğinde, değer sıralamalı veri setinin global minimum noktasında ve zaman sıralamalı veri setinin de en iyi model noktasında daha iyi sonuçlar verdiği görülmüştür. Kullanılan veri seti (1994 yılının ilgili meteoroloji ve kirlilik verileri) dikkate alındığında girdi parametreleri sayısının iki katından az gizli katman nöronlu YSA modellerinin veri setini yeterince genellemediği ve 3 katından fazla gizli katman nöronlu modellerin ise veri setini ezberleme yoluna gidip yine genelleme kabiliyetini kaybettiği gözlenmiştir.

Test seti sonuçları incelendiğinde SO<sub>2</sub>'nin kış aylarındaki yüksek değerlerden ilkbahar ve yaz aylarına doğru düşüş eğilimi ve yine kış aylarına doğru yükseliş eğilimi YSA modeli ile oldukça iyi temsil edilebilmektedir. Verilerin miktarının yanında kullanılan girdi ve çıktı parametrelerinin kendi oluşum aralıklarındaki değer çeşitlilikleri de ne kadar fazla ise modelin bu çeşitlilikleri öğrenebilme kabiliyeti de o derece iyi olmaktadır. Yapay Sinir Ağları ile yapılan modelleme ve tahmin çalışmaları, veri tabanının (daha doğrusu bu veri tabanının kaynağı olan atmosfer ortamının) nonlineer ve kompleks yapısı göz önüne alındığında oldukça başarılı sonuçlar ortaya koymuştur.



## ABSTRACT

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

In this study, İstanbul metropolitan city was taken as the study area, and a new and powerful technique, Artificial Neural Networks (ANN), was used in modelling and predicting the future (next 24 hours) air pollution on the basis of various meteorological parameters. The meteorological parameters used in this study are partly climatological parameters as (on the daily average basis) dry bulb temperature, pressure corrected to sea level, relative humidity, cloudness, total precipitation, wind speed and dominant wind direction, total period and strength of solar radiation, and partly synoptic parameters such as bottom of first inversion layer and temperature gradient in this inversion layer measured at 00.00 GMT and at 12.00 GMT. These independent meteorological parameters were used to model and predict the 24 hour later SO<sub>2</sub> concentration which is also measured at the same location (Göstepe Meteorology Station) by İstanbul Hifzısıhha İnstitute. The data base covering the period of 1992-1998 were examined and only the data of the year 1994 was found convenient to be a data base for the artificial neural networks. This amount of data is obviously greater than the average data base used in the related studies on this field in the literature. This data base, in its original time series form, was divided into training and test sets taking the odd numbered patterns as training data and even numbered ones as test data. This grouping is called time-ordered grouping. Another grouping is the value-ordered grouping in which the data base is ordered in ascending form in terms of the values of SO<sub>2</sub> parameter. Then odd numbered patterns were grouped as training set and even numbered ones were grouped as test set. Various ANN models were tested on these data sets changing the number of neurons in the hidden layer between 25 and 50. The models having more than 50 hidden layer neurons (up to 100) were also tested but the results were not good in terms of the model performance. Class equalization technique was also used on the data sets to improve the model performance. This technique is the duplication of seldom occurring patterns (especially in the winter seasons) in the training data set in some number of times. This technique worked well in terms of model performance. All ANN models were trained up to the best network point and to the global minimum point. When considering the performance of the models in terms of training data sets (time-ordered and value-ordered), value-ordered data set showed the best performance at the global minimum point while the time-ordered data set showed it at the best network point.

When considering the data base (meteorology and pollution parameters of the year 1994) used in this study, the ANN models having the amount of hidden layer neurons less than two times that of input neurons can not generalize the test set well because of the lack of sufficient amount of connection weights. On the other hand, the models having the amount of hidden layer neurons more than roughly three times that of the input neurons tends to memorize the training set and again missing the generalization ability.

Test results show that the trend of SO<sub>2</sub> from higher values in winter to lower values in spring and summer, and again to higher values towards winter can be correctly represented by the neural networks. Beside the amount of the data base, the more the variation of the values of the parameters in their own ranges, the more the network learns the data base. As a result of this study, considerably successful results were obtained when considering the complex and nonlinear structure of the atmosphere which is the source of the data base.

# 1 GİRİŞ

## 1.1 Tanım

Hava kirliliği teknoloji ile birlikte gelen modern hayatın yan ürünlerinden biridir. Fabrikalar, motorlu araçlar, elektrik ve ısı enerjisi üretimi bu kirliliğin önemli kaynaklarıdır. Hava kirliliğinin en önemli kaynaklarından biri yanmadır. Teorik olarak yanma gerçekleştiğinde yakıt içindeki hidrojen ve karbon havanın oksijeni ile birleşerek ısı, ışık, karbondioksit (CO<sub>2</sub>) ve su buharı açığa çıkar. Bununla beraber yakıttaki safsızlıklar, uygun olmayan hava/yakıt oranı veya çok yüksek ya da çok düşük yanma sıcaklıkları karbonmonoksit (CO), kükürt oksitleri, azot oksitleri, uçucu kül ve yanmayan hidrokarbonlar gibi hepsi hava kirleticileri olan maddelerin açığa çıkmasına sebep olabilir.

Hava kirliliğinin çeşitli tanımlarından biri ve en popüler, "atmosferde bulunan kirleticilerin insan sağlığı, bitki, yapı ve malzemelerde zararlı etkiler meydana getirecek miktar (konsantrasyon) ve sürede bulunması" şeklindedir (Wark et al, 1981). Bu tanımda verilen konsantrasyon teriminin bazı kirleticiler için kirli ve temiz hava karşılaştırması Çizelge 1.1'de verilmiştir.

Çizelge 1.1 Kirli atmosfer ile temiz atmosferin karşılaştırılması (Stern, 1976)

Eser Gaz (ppm)	Temiz Hava	Kirli Hava	Kirli/Temiz
CO <sub>2</sub>	320	400	1.3
CO	0.1	40 - 70	400 - 700
CH <sub>4</sub>	1.5	2.5	1.3
N <sub>2</sub> O	0.25	?	?
NO <sub>2</sub> (NO <sub>x</sub> )	0.001	0.2	200
O <sub>3</sub>	0.02	0.5	25
SO <sub>2</sub>	0.0002	0.2	1000
NH <sub>3</sub>	0.001	0.02	2


## 1.2 Kirleticilerin Atmosferdeki Hareketleri

Çeşitli kaynaklardan yayılan bütün hava kirleticileri, meteorolojik şartlara bağlı olarak taşınır (transportation), yayılır (diffusion) veya bir bölgede toplanır (concentration). Bu çevrim mekanizması kirleticilerin kaynaktan bırakılması ile başlar ve atmosferde taşınma ve yayılmaları ile devam eder. Çevrim, kirleticilerin yağmur ile atmosferden yıkanması vasıtasıyla, sonuçta bitkiler, yüzey suları, toprak ve diğer malzemeler üzerine çökmesi ile ya

da uzaya kaçması ile tamamlanır. Bazı durumlarda kirleticiler rüzgar sebebiyle tekrar atmosfere girebilirler. Kirleticilerin bir bölgedeki miktarını belirleyen iki faktör vardır.

- i) Kirletici emisyonlarının özellikleri
- ii) Atmosferin durumu.

Bu iki etkinin birbirleriyle bağlantıları Şekil 1.1'de bir akış şeması şeklinde gösterilmektedir.



Şekil 1.1 Kirleticilerin atmosferde kaynaktan alıcıya kadar izlediği yol (Oke, 1987).

Emisyonların bazı önemli karakteristikleri sonuçta oluşan hava kirliliği üzerinde etkili olmaktadır. Emisyon hızı ve kirleticilerin kimyasal ve fiziksel özellikleri kirlilik yükünün tipini ve miktarını belirleyen önemli parametrelerdir. Bölgenin topografik yapısı, emisyon süresi ve kirleticilerin atmosfere bırakıldıkları efektif yükseklik gibi diğer faktörlerin bilinmesi de aynı derecede önem arz etmektedir. Kaynakların çoğunluğu yer seviyesine yakın bulunmaktadır. Sonuçta, kirlilik en çok yeryüzüne yakın seviyelerde yoğunluk kazanmakta ve yükseldikçe kirlilik yoğunluğu azalmaktadır.

Atmosfere bırakılan kirleticiler Gezegenel Sınır Tabaka (Planetary Boundary Layer) denilen atmosferin yaşadığımız yeryüzüne yakın tabakası içinde kaldığı zaman kirlilik probleminden büyük ölçüde bahsedilmektedir. Kirleticiler üst atmosfere çıktıktan veya bir şekilde Gezegenel Sınır Tabakayı terk ettikten sonra kirleticilik durumlarından bahsedilmez. Gezegenel sınır tabakanın bu bakımdan hava kirliliğinde önemi büyüktür.

### Gezegensel sınır tabaka

Radyasyon enversiyonu durumunda enversiyon tabakasının tabanının yer seviyesinden yüksekliği 100 m'ye kadar inebildiği gibi yaklaşık birkaç km kalınlığa kadar ulaşmaktadır. Bu

tabaka içinde, Dünyanın dönmesi sonucu oluşan Coriolis kuvvetinin de kirleticilerin taşınımında etkisi vardır. Yine bu tabakada rüzgarın yönü de yükseklikle değişmektedir. Gezegenel Sınır Tabakanın üst sınırı, sürtünme sürüklemesi kuvvetinin önemsiz bir değere (mesela, yüzeydeki değerinin %5'ine) ulaştığı nominal yükseklik olarak tanımlanmaktadır. Gezegenel Sınır Tabaka, bazen Ekman Tabaka veya Ekman Spiral Tabaka olarak anılmaktadır.

Kirleticiler atmosfere bırakıldıktan sonra, çeşitli ölçeklerdeki atmosferik hareketlerle yayılmaktadır. Bu yayılma ve dağılma hareketlerini dört ana başlık altında toplamak mümkündür.

Buradaki sınıflandırma, hava hareketlerinin meteorolojik ölçekleri (mikro ölçek, mezo ölçek, sinoptik ölçek vs.) ile ilgili olmayıp, sadece kirleticilerin taşınım ve yayılma yönleri bazında yapılmıştır. Buna ilaveten, genel olarak gaz olmayan partiküllerin boyut, şekil ve ağırlık gibi aerodinamik karakterleri de yeryüzüne çökmelerini veya kaldırma (bouyant) kuvveti ile yukarı hareketlerini etkilemektedir.

### 1.2.1 Dikey hareketler

Kirleticilerin atmosferde dikey taşınımlarını sağlayan veya engelleyen atmosferik hareketler, meteorolojik ölçeklerine bakılmaksızın, atmosfer kararlılığı, alçak ve yüksek basınç durumları (siklonik ve antisiklonik durum), atmosferik durgunluk (blocking) olarak önemli başlıklar altında sıralanabilir.

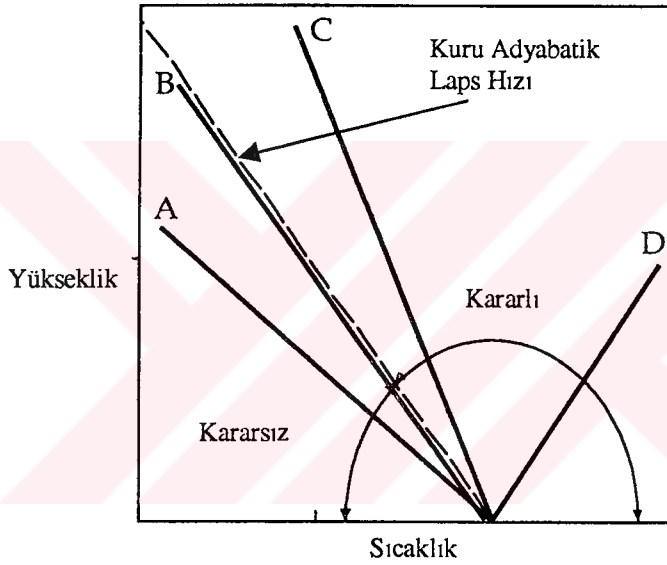
#### Atmosferin kararlılığı ve laps Hızı

Atmofere bırakılan kirleticilerin dağılma derecesini tahmin edebilmek için atmosferin kararlılık durumunun bilinmesi gerekmektedir. Atmosferin kararlılığı, dikey karışım veya hareket yapma derecesinin ölçüsüdür. Atmosfer kararlı ise, yani yeterince dikey karışım veya hareket göstermiyorsa, kaynaktan bırakılan kirleticiler yer yüzeyine yakın bölgede kalır ve dağılmazlar. Atmosferin kararlılığı doğrudan düşey sıcaklık profiline (laps hızı) bağlıdır. Yani sıcaklığın yükseklikle değişme oranı kararlılığı belirleyen parametredir. Bu sıcaklık profiline bağlı olarak atmosferin kararlılığı genel olarak kararsız, nötr, kararlı ve enversiyon olmak üzere dört tiptir (Şekil 1.2).

Bunlara geçmeden önce, yukarıda bahsi geçen laps hızını açıklamak gerekir.

**Laps hızı:** Sıcaklığın yükseklikle değişme hızı Laps Hızı (lapse rate) olarak anılmaktadır.

"Normal" bir atmosfer için laps hızı  $-0.64^{\circ}\text{C}/100\text{m}$ 'dir. Termodinamik olarak "Kuru Adyabatik" laps hızı ise  $-1^{\circ}\text{C}/100\text{m}$ 'dir. Belli bir bölge için gerçek sıcaklık laps hızı çevre hava şartları ile değişmekte olup havanın türbülanslı dikey hareketleri üzerindeki etkileri açısından önem arz etmektedir. Hava parseli olarak adlandırılan kirletici gaz kütesinin atmosferde dikey doğrultuda hareket yönü, çevre havası ile gaz kütesi arasındaki sıcaklık farkının arttığı yöndür. Yani gaz kütesi, kendisi ile kendisini çevreleyen hava kütesi arasındaki sıcaklık farkının arttığı yönde hareket etme eğilimindedir. Dikey yönde iyi bir karışım, kirleticilerin yer seviyesindeki ani etkilerini asgariye indirir. Diğer taraftan, hava yukarı doğru etkin bir şekilde karışmazsa düşük irtifalarda atmosfere bırakılan kirleticiler bırakıldıkları irtifalarda kalma eğilimi gösterirler.



Şekil 1.2 Kuru bir atmosferde kararlılığa örnek olarak sıcaklık profilleri: A. Kararsız, B. Nötr, C. Kararlı ve D. Çok Kararlı Enversiyon laps hızları

#### a. Kararsız durum:

Yükselen bir sıcak hava parseli (kaynaktan bırakılan ve kirletici ihtiva eden gaz karışımı), yükselirken soğusa da, kendisini yukarı doğru hareket ettirecek kaldırıcı (bouyant) kuvveti bulmaya devam ederse etkili bir karışma gerçekleşir. Bu ise ancak sıcak hava parselini içine alan çevre havasının laps hızının kuru adyabatik laps hızından büyük olduğu durumda gerçekleşir. Yükselen hava parseli kuru adyabatik laps hızı ile soğumaktadır. Çevre havasının laps hızı adyabatik laps hızından büyükse **kararsız** durum oluşur (Şekil 1.2. A). Yani hava parseli ile çevre havası arasındaki sıcaklık farkı yükseldikçe artar ve bu da hava parselinin

daha da yükselmesini sağlar. Bu durum, kirleticilerin dağılması bakımından en uygun durumdur.

**b. Nötr durum:**

Atmosferin laps hızının yaklaşık olarak kuru adyabatik laps hızına eşit olduğu durumdur (Şekil 1.2. B). Bu durumda hava parselini yukarı doğru hareket ettirecek sıcaklık farkı yükseklikle değişmeyeceğinden atmosfere bırakılan gaz karışımı bırakıldığı irtifada kalma eğilimi gösterecektir.

**c. Kararlı durum:**

Atmosferin laps hızı kuru adyabatik laps hızından küçüktür (Şekil 1.2. C). Bu durumda yükselmeye çalışan hava parseli ile çevre havası arasındaki sıcaklık farkı azalma eğiliminde olacağından hava parseli yükselmeyecektir.

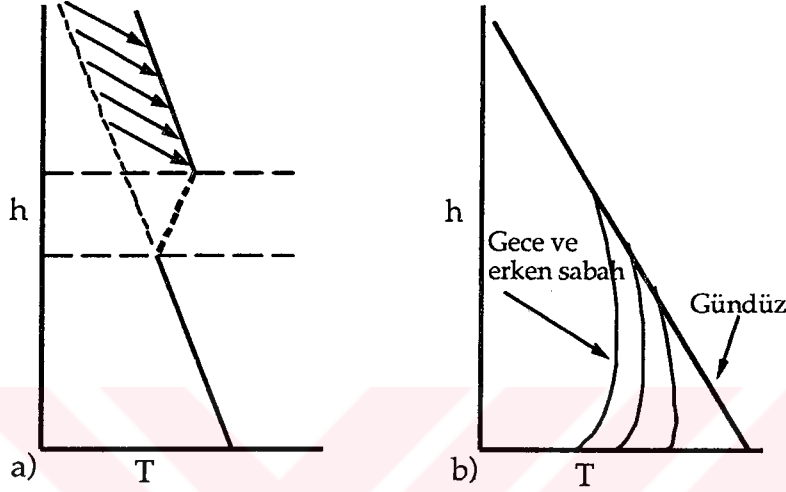
**d. Enversiyon durumu:**

Buraya kadar bahsedilen kararlılık durumlarının hepsinde sıcaklık yükseklikle azalmaktadır. Sıcaklığın yükseklikle arttığı durum ise **enversiyon** durumu olarak adlandırılmaktadır (Şekil 1.2. D). Hava kirliliği bakımından en kötü kararlılık durumudur. Atmosfere bırakılan gaz kütlesi ile çevre havası arasındaki sıcaklık farkı, yer yüzeyine doğru artacağı için gaz kütlesi aşağı doğru hareket edecektir.

Çok çeşitli inversiyon durumlarından iki tipi en çok oluşanlardır. Bunlardan birisi yüksek basınç içinde kalan bir hava tabakasının alçalması ile oluşan **çökme inversiyonudur** (Şekil 1.3a). Bir yüksek basınç bölgesinde kalan hava tabakası düşük irtifalara doğru alçalırken adyabatik olarak sıkışır ve ısınır. Hava tabakasının adyabatik olarak alçalması esnasında bu tabakanın tabanı tavanından daha az ısınır. Dolayısıyla yeterli miktarda çökme olduğunda hava tabakasının tavanı tabanından daha yüksek sıcaklıkta olacak ve bu sıcaklık gradyanı inversiyonu oluşturacaktır. Çökme inversiyonları genelde emisyon kaynaklarından yüksek irtifalarda oluşmaktadır. Dolayısıyla kısa vadeli kirlilik problemlerinde etkili olmamaktadır. Bununla beraber bu tip inversiyon günlerce devam edebilir ve uzun vadede kirleticilerin birikmesine sebep olabilir.

İkinci önemli inversiyon tipi ise  **radyasyon inversiyonudur** (Şekil 1.3b). Atmosferin yüzey tabakası gündüz vakti, iletim (conduction), konveksiyon ve radyasyon mekanizmaları ile yer yüzeyinden ısı alır ve ısınır. Bunun sonucu olarak aşağı atmosferde negatif sıcaklık profili oluşur. Bunu müteakip açık bir gece oluşursa yer yüzeyi ısı yayar ve hızlı bir şekilde soğur.

Soğuyan yer yüzeyi kendisine yakınlık sırasındaki hava tabakalarını da mesafelerinin tersi nispetinde soğutur. Dolayısıyla yükseldikçe hava daha az soğumuş olmaktadır. Sonuçta gündüz vakti oluşan sıcaklık profili ters dönmüş olur ve alt atmosferde kararlı bir enversiyon tabakası oluşur. Bu tip enversiyon güneş doğmadan hemen önce, açık gökyüzü ve hafif rüzgar şartlarında en kuvvetli durumdadır. Sabah güneşinin yeryüzünü ısıtması ve yükselen sıcak hava akımlarını yeniden oluşturmasıyla kırılır.



Şekil 1.3 İki önemli enversiyon tipinin oluşumlarının şematik gösterimi: a) Çökeltme enversiyonu, b) Radyasyon enversiyonu


### Alçak basınç (Siklon hareketi)

Bir sıcak hava kütesinin soğuk hava kütesi altına girmesi ile oluşur. Oluşan sıcaklık farkı dolayısıyla altta kalan sıcak hava kütesi yükselme eğilimi gösterir. Sıcak hava kütesi yükselirken düşük irtifalarda yerini çevresinden gelen hava doldurur. Oluşan bu içeri doğru hareket, yakınsayan siklonik bir harekettir ve spiral şeklinde yukarı doğru oluşur (Şekil 1.4). Bu spiralın yönü kuzey yarım kürede saat yönünün tersinde, güney yarım kürede ise saat yönünde oluşur. Oluşan bu yukarı doğru hareket alt atmosferdeki kirleticileri de yukarı doğru taşıyarak dağıtır. Bu bakımdan alçak basınç sistemi kirleticilerin dağıtılması açısından istenen bir durumdur.

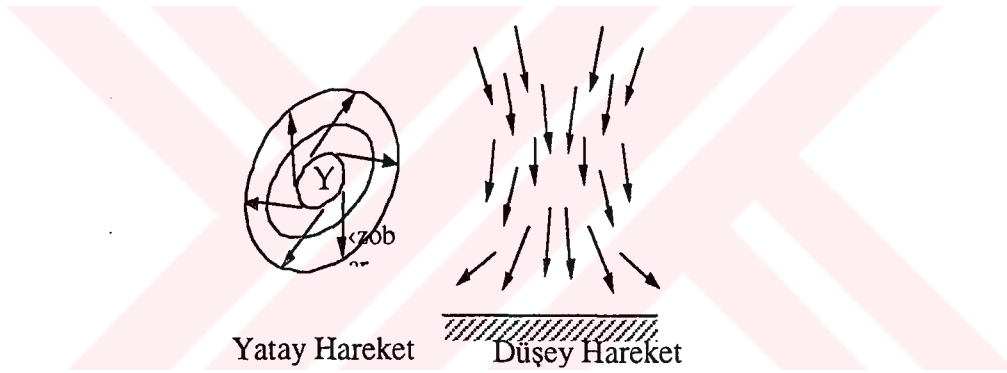
### Yüksek basınç (Antisiklon hareketi)

Yüksek basınç durumu da alçak basınç durumunun tersine bir soğuk hava kütesinin bir sıcak hava kütesi üzerine çıkması ile oluşur. Yukarıda kalan soğuk hava kütesi aşağı doğru hareket etme eğilimi gösterir. Aşağı inerken yerini çevresinden gelen hava doldurur. Bu durumda oluşan aşağı doğru hareket iraksayan (dışarı doğru) bir spiral şeklini alır (Şekil 1.5). Bu hava

hareketine antisiklon hareketi de denilmektedir. Hareket aşağı doğru olduğu için böyle bir basınç sisteminin bulunduğu bölgede atmosfere bırakılan kirleticiler yukarı doğru yükselmez. Bunun için hava kirliliği açısından istenmeyen bir durumdur.



Şekil 1.4 Kuzey yarımkürede bir siklonun yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri. Havanın dikey doğrultudaki hareketi sağdaki şekilde gösterilmiştir.



Şekil 1.5 Kuzey yarımkürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri. Havanın dikey doğrultudaki çökme hareketi sağdaki şekilde gösterilmiştir.

### Atmosferik durgunluk (blocking)

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

### 1.2.2 Yatay yöndeki hareketler (rüzgarlar)

Kirleticilerin atmosferde yatay yayılmaları, emisyon kaynağı yüksekliğindeki ortalama rüzgar hızına büyük ölçüde bağlı bir fonksiyondur. Rüzgar hareketi yeryüzüne yakın irtifalarda yüzey pürüzlülüğü ile orantılı olan sürtünme kuvvetinden etkilenmektedir. Bölgenin topografik



yapısı, ağaçların yoğunluğu ve yerleşimi, göllerin, nehirlerin, tepelerin ve yapıların yerleşimi ve boyutları dikey yönde farklı rüzgar hızı profillerini oluşturmaktadır. Sürtünmeden etkilenen hava tabakası (Gezegensel Sınır Tabaka) yeryüzünden itibaren birkaç yüz metreden birkaç km'ye kadar uzanmaktadır. Bu sınır tabakanın derinliği kararsız durumlarda, kararlı durumdakinden daha büyüktür. Bu sebeple, kirleticiler kararsız atmosferik şartlarda daha büyük bir dikey mesafede yayılacak ve dolayısıyla kirletici konsantrasyonu daha düşük olacaktır.

### 1.2.3 Türbülanslı hava hareketleri

Atmosferik türbülans tamamen açıklanmış ve matematik temellere dayandırılmış bir olay değildir. Türbülans genellikle rüzgar hızındaki dalgalanmaların 2 devir/saat'ten daha yüksek frekanslı olanları olarak tanımlanmaktadır (Wark et al, 1981). Daha önemli dalgalanmalar ise 1 ile 0.01 devir/saniye arasındaki frekanslara sahiptir.


Atmosferik türbülans iki önemli etki sonucu oluşmaktadır:

a) Atmosferik ısınma: Yoğunluk farklılaşması dolayısıyla doğal konveksiyon akımlarının oluşmasına sebep olur.

b) Rüzgar Etkisi: Rüzgar hızının yükseklikle değişimi mekanik türbülans oluşturur.

Her iki etki de her türlü atmosferde oluşmasına rağmen değişik durumlarda biri diğerine göre daha baskın olmaktadır. Güneşli günlerde hafif rüzgar ve oldukça yüksek laps hızı olduğu zaman termal girdaplar (eddy) daha etkilidir. Bu dalgalanmaların periyodu dakikalar mertebesinde olabilmektedir. Diğer taraftan mekanik türbülans rüzgarlı gecelerde nötr kararlılık durumunda daha baskındır ve rüzgar dalgalanmalarının periyodu saniyeler mertebesinde olmaktadır. Mekanik türbülans havanın yer yüzeyi üzerinde hareketi sonucu oluşmaktadır ve binaların yerleşimi ve yer yüzeyinin pürüzlülüğünden etkilenmektedir.

Türbülansın kirleticileri nasıl dağıttığı oldukça basitleştirilmiş olarak Şekil 1.6'da gösterilmektedir. Şekilde bir gaz kirletici bulutunun alt kenarı gösterilmektedir. Burada kirleticiler belirli bir hızda temiz hava ile karışmaktadır. Bir türbülans girdabı gaz kütesinden kopardığı küçük bir kirletici bulutun temiz hava ile karışma yüzeyinin arttırarak daha hızlı bir şekilde seyrelmesini sağlamaktadır.



Şekil 1.6 Basitleştirilmiş olarak bir türbülans girdabının kirlenici gaz kütlesini parçalaması ve kirlenicilerin çok daha hızlı bir şekilde temiz hava ile karışması.

#### 1.2.4 Moleküler diffüzyonla dağılma

Düzenliliğe (Uniformity) doğru olan eğilim, kirlenicilerin atmosferdeki konsantrasyonları için de geçerlidir. Kirleniciler atmosfere bırakıldıklarında oldukça yüksek konsantrasyonda bulunmaktadır. Kirlenici bulutu ile temiz hava arasında oluşan bu yüksek konsantrasyon gradyanı kuvveti ile kirleniciler çevredeki temiz hava içine doğru yayılırlar. Yayılma ilerledikçe konsantrasyon gradyanı azalacağı için yayılma hızı da yavaşlar (Fick Kanunu). Dolayısıyla atmosferde tam bir karışımın olması sadece diffüzyon mekanizması ile gerçekleşmez. Moleküler diffüzyon kirlenicilerin atmosferde dağılmasında yer alan bir mekanizma olmasına rağmen, yukarıda bahsedilen diğer mekanizmalar yanında önemsiz kalmaktadır.

## 2 ÖNCEKİ ÇALIŞMALAR

### 2.1 İstanbul'un Günümüze Kadar Hava Kirliliği Durumu

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

1960-1990 yılları arasında tüketim miktarları açısından yaygın şekilde kullanılan yakıtlar çeşitli dönemlerde değişik görüntüler arz etmiş, 1960-1980 yılları arasında fuel-oil, 1980'den sonra ise linyit kömürü ısınma amacıyla tüketilen yakıtlar arasında öncelik göstermiştir. 1992 yılından itibaren tedrici olarak kullanıma sunulan doğalgaz 1994 yılından itibaren önemli bir kullanım yüzdesine sahip olmuş ve yıllık ortalama hava kirliliği seviyesinin düşmesine önemli katkıda bulunmuştur.

Bu yakıtların yakılması neticesinde atmosfere verilen belli başlı kirleticiler arasında, partiküler madde (PM), kükürdioksit ( $SO_2$ ), azot oksitler ( $NO_x$ ), karbonmonoksit (CO), hidrokarbonlar (HC) bulunmaktadır. Bunlardan son üçünün önemli bir kaynağını motorlu taşıtlar (otomotiv kaynaklı emisyonlar) teşkil etmektedir. İstanbul'da sabit kaynaklar ve taşıtlardan meydana gelen kirletici miktarları, emisyon faktörleri kullanılarak hesaplandığında bu emisyonların izafi (relatif) dağılımları bulunabilir. 1990 yılı için bu faktörler kullanılarak tahmin edilen kirletici emisyonlarının dağılımı Çizelge 2.1'de gösterilmiştir.

Çizelge 2.1 İstanbul'da 1990'daki kirletici emisyonlarının dağılımı (Borat ve diğerleri, 1990)

Kirletici	Toplam Emisyon İçindeki Payı (%)	Kaynak Payları (%)	
		Sabit Kaynaklar	Taşıtlar
PM	48.1	47.5	0.65
$SO_2$	29.4	29.1	0.26
CO	16.3	9.9	6.64
$NO_x$	3.1	1.6	1.44
HC	3.1	1.6	1.40
<b>TOPLAM</b>	100	≈90	≈10

Çizelge 2.1'den görüldüğü gibi, İstanbul'da hava kirlenmesine büyük ölçüde sabit kaynaklarda (evler, endüstri tesisleri) ısınma ve enerji temini maksadıyla kullanılan yakıtlar sebep olmaktadır. Taşıtların hava kirliliğindeki payı ise %10 mertebesindedir. Ancak bu dağılım genellikle kış ayları için geçerlidir. Bilhassa yaz aylarında, sabit kaynaklarda yanma asgari seviyede olduğu için, motorlu taşıtların katkısı daha fazla olabilmektedir.

## 2.2 İstanbul'un Hava Kirliliği İle İlgili Önceki Çalışmalar

İstanbul'daki bölgesel hava kirliliği seviyesi ile ilgili bazı çalışmalar Kartal bölgesinde Çataltaş (1969) tarafından ve Nişantaşı bölgesinde de Tebbens (1970) tarafından yapılmıştır. Bu çalışmalarda, İstanbul'un rüzgarlı ikliminin o tarihlerde, oluşabilecek ciddi bir hava kirliliği problemini önlediği belirtilmiştir. Ancak gelecekte kullanılacak yakıt türünün seçiminde dikkatli olunması gerektiği de ifade edilmiştir.

Ayalp (1976) tarafından yapılan çalışmada ise İstanbul'un ticari, meskun ve endüstriyel bölgelerinde kurulan istasyonlarda yapılan ölçümlerde kükürtdioksit, azotoksit, karbonmonoksit, toplam askıda katı madde ve duman parametreleri ölçülmüştür. Aynı rüzgar yönü alınarak bir istasyon için yapılan kükürtdioksit ve rüzgar hızı parametreleri arasındaki regresyon analizlerinde çeşitli lineer ve parabolik ilişkiler kurulmuştur. Kükürtdioksitin en düşük seviyede kaydedildiği günlerde hakim rüzgar yönünün kuzey ve kuzey-doğu, en yüksek seviyede kaydedildiği günlerde ise kuzey-batı yönlerinde olduğu gözlenmiştir.

İstanbul'daki hava kirliliğinin deterministik modellemesi ile ilgili ilk çalışma Ertürk (1981 ve 1986) tarafından Haliç bölgesinde alan kaynaklardan ileri gelen hava kirliliğinin göstergesi olarak kükürtdioksit ve asılı partiküler madde parametreleri üzerinde, ikinci olarak Öztürk (1983) tarafından Beyoğlu Caddesi'nde motorlu taşıtlardan ileri gelen karbonmonoksit konsantrasyonu üzerinde yapılmıştır. Her iki çalışmada da gözlenen ve matematik modellerle hesaplanan değerler arasında yüksek korrelasyonlar bulunmuştur. İncecik (1986) tarafından Haliç bölgesinde alt atmosferin mikrometeorolojik yapısı ile ilgili yapılan çalışmada ise, düşük rüzgar hızları, gece vakti oluşan kararlı atmosfer durumu ve zayıf dağılıma (dispersiyon) gibi meteorolojik şartların, kirleticilerin bu bölgede birikmesine sebep olduğu belirtilmiştir.

Bir başka çalışma ise İşli (1990) tarafından yapılmıştır. Bu çalışmada da yine meteorolojik parametrelerle kirlilik parametrelerinin birlikte istatistiksel ilişkileri ile beraber kirlilik verileri, zaman serileri şeklinde analiz edilerek geleceğe dönük tahmin çalışması yapılmıştır.

Saral (1995) tarafından yapılan çalışmada, İstanbul ölçeğinde geniş bir bölgede 16 istasyonda

ölçümü yapılan kükürtdioksitin, Krigging uzaysal enterpolasyon yöntemi kullanılarak aylık bazda İstanbul'un hava kirliliği haritaları çıkarılmış ve İstanbul'da kirliliğin yoğun olduğu bölgelerle, gelecekte kirlilik potansiyeli olan bölgeler ortaya konulmuştur. Ayrıca kış aylarında oluşan yoğun kirliliğin kaynakları tespit edilmiştir.

### **2.3 Hava Kirliliği Modellemesinde Yapay Sinir Ağları Uygulamaları ile İlgili Önceki Çalışmalar**

Yapay sinir ağları modellerinin hava kirliliğine, veya daha genel bir ifadeyle atmosfer ortamına, uygulanması oldukça yeni olup bu konudaki çalışmaların geçmişi 1990'lı yılların öncesine gitmemektedir.

Literatürde rastlanan ilk çalışma Boznar (1993) ve ekibine aittir. Bu çalışmada, kompleks bir topografya içinde bulunan bir termal enerji santralinden çıkan baca gazındaki SO<sub>2</sub>'nin belirli mesafede yarım saat sonraki konsantrasyonu tahmin edilmiştir. Boznar et al. bu çalışmada model için girdi parametreleri olarak termal enerji santralinin bulunduğu bölgenin çeşitli noktalarında ölçülen SO<sub>2</sub> konsantrasyonlarının yanı sıra rüzgar hız ve yönü, sıcaklık ve zaman parametrelerini kullanmıştır. Santralin bulunduğu topografik bölge oldukça kompleks olmasına rağmen yapay sinir ağları klasik istatistiksel metotlara göre oldukça iyi sonuçlar vermiştir.

Perautonis et. al. (1994) Atina'da SO<sub>2</sub> episodları olup olamayacağını tahmin edebilmek için kullandığı yapay sinir ağları modellerinde başarılı sonuçlar elde etmişlerdir.

Mlakar et. al. (1994) Slovenya'da yine termal enerji santrali çevresindeki SO<sub>2</sub> kirliliğini tahmin etmek için kullandıkları yapay sinir ağları modelleriyle başarılı sonuçlar elde etmişlerdir.

Mlakar et. al (1994) kısa vadeli hava kirliliği tahmininde kullanılacak modeller ve parametre seçimi konusunda yaptıkları çalışmalarda yine bu modellerin ileride hava kirliliğine uygulanabilirliği konusunda cesaret verici sonuçlar elde etmişlerdir.

Boznar et. al. (1995) yer seviyesi rüzgar yön ve hızlarını tahminde yapay sinir ağları kullanmışlar, hız tahminleri başarılı sonuçlar vermesine karşılık yön tahminleri istenilen seviyede başarılı olamamıştır. Bu noktada kullanılan girdi parametrelerinin yeterli olmadığı anlaşılmaktadır.

Mlakar et. al. (1996) yine rüzgar hız ve yönlerinin kümelenmesinde değişik yapay sinir ağları

modeli kullanarak başarılı sonuçlar elde etmişlerdir ve bu çalışma sonuçlarının hava kirliliği tahminlerinde kullanılabilecek seviyede olduklarını ifade etmişlerdir.

Potukuchi et. al. (1997) amonyak, nitrik asit, hidroklorik asit, amonyum nitrat bileşiklerinin buhar basınçlarının tahmininde yapay sinir ağlarını kullanmışlar ve temel termodinamik bulgularla karşılaştırıldığında oldukça iyi sonuçlar elde etmişlerdir.

Comrie (1997) Amerika'da 8 şehrin verileriyle yaptığı günlük ozon konsantrasyonları tahmininde regresyon modelleriyle yapay sinir ağları modellerini karşılaştırmış ve yapay sinir ağlarının daha iyi sonuçlar verdiğini ortaya koymuştur.

Boznar (1997) hava kirliliği tahmininde patern seçim stratejilerini incelemiştir. Patern seçimi, tahmin edilen parametrenin genelleme yapılarak modellenmesi için önemli sorunlardan biridir.

Mlakar et. al. (1997) çok katmanlı perceptron (multi layer perceptron) modeli kullanarak dış hava SO<sub>2</sub> konsantrasyonu tahmini yapmıştır. Uygulamayı yaptıkları çalışma bölgesi için bu modelin hangi şartlarda optimum sonuçlar verdiğini ortaya koymuşlardır.

Mlakar (1997) hava kirliliği tahmininde yapay sinir ağları için kullanılan girdi parametrelerinin önem sırası ile sıralanması yöntemlerini incelemiş, literatürde belirtilen bir yöntemi bir termal enerji santrali çevresindeki SO<sub>2</sub> tahmininde kullandığı girdi parametrelerini önem sırasına göre sıralamak için kullanmış ve kendisi de bu konuda bir metodoloji önermiştir. Kullanılan bu yöntemde girdi parametreleri çok önemli, oldukça düşük önemde ve önemsiz olarak üç grupta toplanmıştır.

Clair et. al. (1998) mevsimsel iklim değişikliklerinin atmosfere atılan çözünmüş organik karbon ve azot miktarına etkisini yapay sinir ağları modeli kullanarak ortaya koymaya çalışmışlardır.

Aviolat et. al. (1998) İsveç havaalanlarında kullanılabilecek otomatik bulut gözlem sisteminde klasik ampirik yöntemler yerine yapay sinir ağları ile bulut miktarlarını tahmin eden bir veri işlem ünitesi üzerinde çalışmışlardır. Elde ettikleri sonuçlar insan gözlemleri ile oldukça uyumlu sonuçlar ortaya koymuştur.

Gardner et. al (1998) yapay sinir ağları modellerinin en yaygın kullanıma sahip çok katmanlı perseptron (multi layer perceptron) modelinin atmosfer bilimlerine uygulamalarının incelemesini ve bu modelin özellikleri ile beraber atmosfer bilimlerine uygulandığındaki literatür çalışmalarını ortaya koymuştur.

Gardner et. al. (1999) Londra'da şehir atmosferinde saatlik NO<sub>x</sub> ve NO<sub>2</sub> konsantrasyonlarının tahmininde çok katmanlı perseptron modelini kullanmışlar ve elde ettikleri sonuçlar göstermiştir ki NO<sub>2</sub>/NO<sub>x</sub> konsantrasyonları ile lokal meteorolojik parametreler arasında kuvvetli bir ilişki vardır ve bu ilişki yapay sinir ağları yardımıyla oldukça uyumlu bir şekilde modellenenmektedir.

Reich et. al. (1999) bir noktada ölçülen SO<sub>2</sub> konsantrasyonunun oluşum kaynaklarının tanımlanmasında ve bu kaynakların ölçüm noktasındaki konsantrasyona katkılarının bulunmasında yapay sinir ağları modellerini kullanmışlardır.



### 3 YAPAY SİNİR AĞLARI

#### 3.1 Giriş

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

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

#### 3.2 Biyolojide Nöron ve Nöronun Matematiksel Modeli


En karmaşık sinir ağı Cerebral Cortex denilen "beyin"dir. Yaklaşık  $10^{10}$  sinir hücresinin bulunduğu beyinde, hücre başına bağlantı sayısı ise  $10^4$  mertebesindedir. Fiziksel boyutları yaklaşık 1.3 kg ve  $0.15 \text{ m}^2$  kesitli olan beyin için çalışma frekansı 100 Hz.'dir (Songar, 1985). Vücudun değişik yerleri ile bilgi alışverişi yapan nöron hücresidir.

Nöron, soma adı verilen hücre gövdesi dentrit denilen kıvrımlı uzantılar ve somanın dalları sayesinde nöronu dallarına bağlayan tek sinir fiberli aksondan oluşur. Dentritler hücreye gelen girişleri toplarlar. Dentrit tarafından alınan işaretler hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir. Beyindeki kortekste her nöronun bir karşılığı vardır. Bir nöronun çıkışı ona bağlı olan bütün nöronlara iletilir. Fakat korteks, işin yapılabilmesi için hangi nöron harekete geçirilecekse, sadece ona komut gönderir.

Somanın içinde ve çevresinde sodyum, kalsiyum, potasyum ve klor iyonları vardır. Potasyum yoğunluğu nöronun içinde, sodyum yoğunluğu dışındadır. Somanın zarı elektriksel olarak uyarılınca (söz konusu uyarı genellikle bir gerilim düşmesidir) zar, Na ve Ca gibi diğer



iyonların içeri geçmesine izin verir ve somanın iç durumunu değiştirir. Nöronlar arasındaki bağlantılar "sinaps" adı verilen geçişlerde olur. Sinir sistemi; milyarlarca nöronun oluşturduğu ve bir nörondan çıkan aksonun 10000 kadar diğer nörona bağlandığı bir ağdır. Aksonlarla düzeltilen işaretleri taşıyan sinapslar ile dentritler ve iç içe geçmiş nöronlar bir sinir ağı oluştururlar. Şekil 3.1'de bir eşik birimi olarak algılanabilecek nöron modeli en basit formda gösterilmiştir.



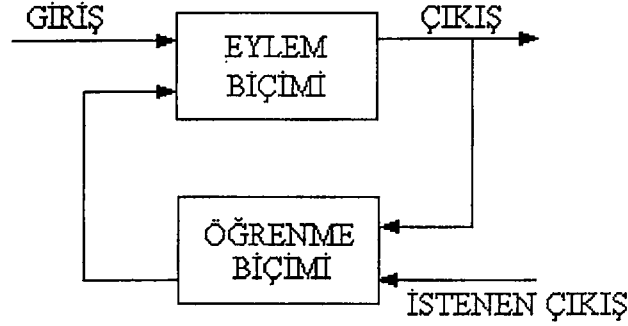
Şekil 3.1 Nöronun matematiksel modeli

Eşik birimi, çıkışları toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır. Bir eşik birimi olarak nöron sinapslarındaki işaretleri alır ve hepsini toplar. Eğer toplanan işaret gücü eşiği geçecek kadar güçlü ise diğer nöronları ve dentritleri uyaran akson boyunca bir işaret gönderilir. Kesişen dentritlerden gelen sinapslarla kapılanan bütün işaretleri soma toplar. Toplam işaret daha sonra nöronun iç eşik değeri ile karşılaştırılır ve eşik değerini aşmışsa aksona bir işaret yayar. Yapay sinir ağları da, bu nöronlara benzer düğümlerin veya ünitelerin birbirlerine bağlanarak bir ağa dönüştürülmesiyle meydana getirilir.

### 3.3 Yapay Sinir Ağının Yapısı

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


sinir ağının genel blok diyagramı Şekil 3.2’de görülmektedir.



Şekil 3.2 YSA'nın blok diyagramı

### 3.3.1 İşlem Elemanı

Yapay sinir ağı basit yapıda ve yönlü bir grafik biçimindedir. Ağın her bir düğümü hücre denilen  $n$ . dereceden lineer olmayan bir devreden oluşur. Düğümler işlem elemanı olarak tanımlanır ve aralarında bağlantılar vardır. Her bağlantı tek yönlü işaret iletim yolu (gecikmesiz) olarak görev yapar. Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Fakat bu bağlantı kopya edilebilir. Yani bu tek çıkış birçok hücreyi besleyebilir. Ağdaki tek gecikme, çıkışları ileten bağlantı yollarındaki iletim gecikmeleridir. İşlem elemanının çıkışı istenilen matematiksel tipte olabilir. Kısmen sürekli çalışma konumunda, "aktif" halde eleman bir çıkış işareti üretir. Giriş işaretleri YSA'ya bilgi taşır. Sonuç ise çıkış işaretlerinden alınabilir. Şekil 3.3 'de genel bir işlem elemanı (nöron, düğüm) gösterilmiştir.



Şekil 3.3 YSA Genel İşlem Elemanı Yapısı.


YSA birtakım alt kümelere ayrılabilir. Bu alt kümelerdeki elemanların transfer fonksiyonları

aynıdır. Bu küçük gruplara "katman" (layer) adı verilir. (örn: çok katmanlı perceptron MLP) Ağ, katmanların birbirlerine hiyerarşik bir şekilde bağlanmasından oluşmuştur. Dış dünyadan alınan bilgi giriş katmanı ile taşınır. Giriş katmanı düğümlerinin transfer fonksiyonları yoktur. YSA transfer fonksiyonu ve yerel bellek elemanı bir öğrenme kuralı ile giriş çıkış işareti arasındaki bağıntıya göre ayarlanır. Aktif yapma girişi için bir zamanlama fonksiyonu tanımlaması gerekebilir. Kısaca bir YSA'dan beklenen görev, gerçek dünyadaki nesnelere ile biyolojik sinir ağının yaptığı işlevi, benzer bir yolla yerine getirmesidir. YSA'nın giriş veri tipleri ikili (binary) 0-1 veya sürekli değerlerdir. Bu giriş durumlarından başka, işlem elemanlarına ait girişleri matematiksel olarak da sınıflamak gerekmektedir. Çünkü bir işlem elemanına gelen girişlerin bir kısmı azaltıcı uyarı girişleri olmaktadır. Bu arttırıcı veya azaltıcı girişler "giriş sınıflarını" oluşturur.

### 3.3.2 Giriş işareti sınıfları

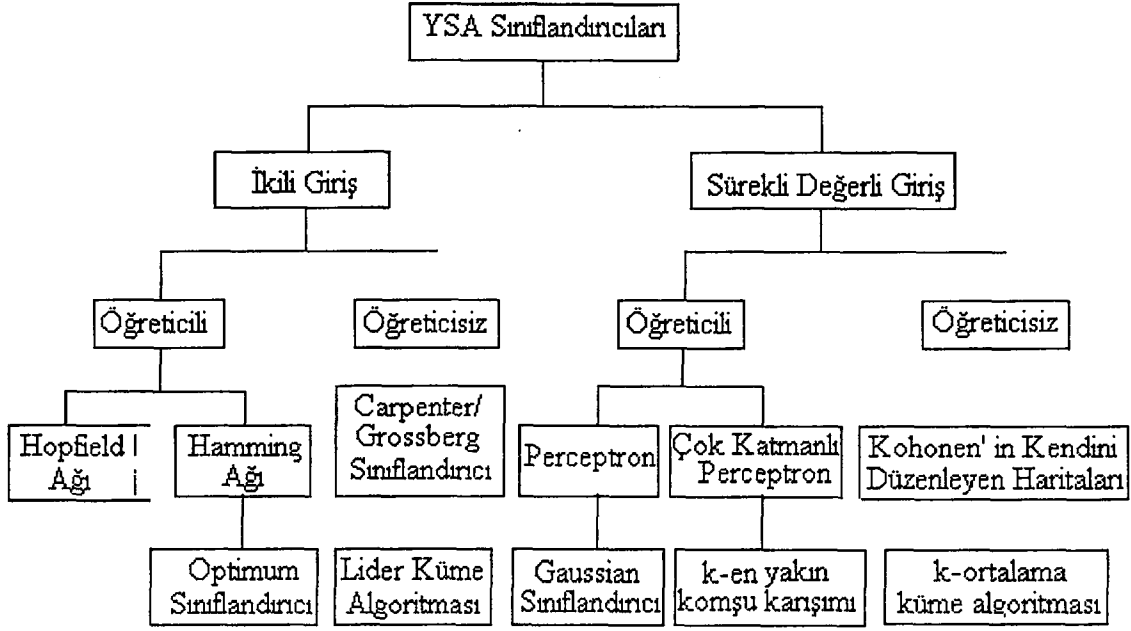
İşlem elemanının transfer fonksiyonu gelen bütün giriş işaretleri için tanımlanır. Bazen değişik katman davranışlarının farklı olması tabiidir. İşaretlerin hangi bölgelerden geldiğinin bilinmesi gerekir. Değişik bölgelere göre işaretlerin sınıfları tamamlanabilir. Sıkça izlenen bir yapı ise merkezde evet/çevrede hayır (on centre/off surround) yapısıdır. Bu yapı meksikalı şapkasına benzer bir eğri tipindedir.

İşlem elemanı tetikleyici girişlerin kendine yakın komşu girişlerden yasaklanan girişlerini daha uzaktan alır. Böylece işlem elemanına gelen girişler sınıflarına göre değerlendirilmiş olur. Tetikleyici bölgeden gelen girişler yasaklanan sınıfı oluşturur. Şekil 3.4 böyle bir işlem elemanını gösterir.



Şekil 3.4 Tetikleyici ve yasaklayıcı girişlere sahip bir işlem elemanı.

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



Şekil 3.5 Yapay Sinir Ağları Sınıflandırıcıları.

### 3.3.3 Bağlantı geometrileri

Bağlantı geometrisi YSA için çok önemli olduğu için, bağlantılarda taşınan işaret verisinin cinsi tanımlanmalıdır. Bağlantı işareti her cinsten olabilir. Bağlantının nerede başlayıp nerede bittiğinin bilinmesi gerekir. 1'den n'e kadar olan bir işlem elemanı kümesinin bağlantıları aşağıda tanımlandığı gibi  $n \times n$  boyutlu matris biçiminde gösterilebilir.

$$[w_{ij}] = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \dots & \dots & \dots & \dots \\ w_{n1} & w_{n2} & \dots & w_{nn} \end{bmatrix} \quad (3.1)$$

Bu matrisin elemanlarında;

$$w_{ij} = w_{ji} = 1 \Leftrightarrow i. \text{ işlem } j. \text{ işlem elemanına bağlı}$$

$$w_{ij} = w_{ji} = 0 \Leftrightarrow i. \text{ işlem } j. \text{ işlem elemanına bağlı değil}$$

Bağlantılar çeşitli geometrik bölgeler arasında demetler halinde düşünülebilir. Bu bağlantı demetlerinin uyması gereken kurallar şunlardır:

- Bağlantı demetini oluşturan işlem elemanları aynı bölgeden çıkmalıdır

- Bağlantı demetinin işaretleri aynı matematiksel ve sınıftan olmalıdır
- Bağlantı demetinin bir seçim fonksiyonu olmalıdır.

### 3.3.4 YSA ağ tipleri

Üç çeşit ağ tipi vardır:

- 1- İleri beslemeli ağ: Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir.
- 2- Kaskat bağlantılı ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir.
- 3- Geri beslemeli ağ: En az bir hücre sonraki katmanlardaki hücrelerce de beslenir.

### 3.3.5 Eşik fonksiyonları

Transfer veya işaret fonksiyonları olarak da adlandırılan eşik fonksiyonları; muhtemel sonsuz domen girişli işlem elemanlarını, önceden belirlenmiş sınırdaki çıkış olarak düzenler. Dört tane yaygın eşik fonksiyonu vardır. Bunlar lineer, rampa, basamak ve sigmoid fonksiyonlarıdır. Şekil 3.6'da bu fonksiyonlar gösterilmiştir.

Şekil 3.6.a'da gösterilen lineer fonksiyonun denklemi aşağıdaki gibidir:


$$f(x) = \alpha x \quad (3.2)$$

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

$$f(x) = \begin{cases} \tau: & \text{eger } x \geq \tau \\ x: & \text{eger } |x| < \tau \text{ şeklini alır.} \\ -\tau: & \text{eger } x \leq -\tau \end{cases} \quad (3.3)$$

$+\tau$  (  $-\tau$ ) işlem elemanının maksimumu (minimumu), çoğu zaman doyma seviyesi olarak adlandırılan çıkış değeridir. Eğer eşik fonksiyonu bir giriş işaretine bağlı ise yaydığı  $+\tau$  giriş toplamı pozitif, bağlı değilse eşik basamak fonksiyonu  $[-\delta]$  olarak adlandırılır. Şekil 3.6.c, basamak eşik fonksiyonunu gösterir ve denklemi;

$$f(x) = \begin{cases} \tau & \text{eger } x > 0 \\ -\delta & \text{diger durumlar} \end{cases} \text{şeklindedir.} \quad (3.4)$$



Şekil 3.6 Çok kullanılan eşik fonksiyonları

Çok kullanılan eşik fonksiyonu sigmoid fonksiyonudur. Şekil 3.6.d'de gösterilen sigmoid fonksiyonu; seviyeli, lineer olmayan çıkış veren, sınırlı, monoton artan fonksiyondur. Denklemi (Comrie, 1997);

$$f(x) = \frac{1}{1 + e^{-x}} \text{ biçimindedir.} \quad (3.5)$$

Her işlem elemanı kendisine verilen yerel veriye göre, kendisini ayarlayacak bütün YSA'nın enformasyon bölgesinin öğrenmesini sağlar. (Enformasyon bölgesi olasılık-yoğunluk fonksiyonu ile de tanımlanabilir). Enformasyon bölgesi birçok uygulamada, gerçek değer "0" ile "1" arasında normalize edilmesi gerekir. Normalizasyon aynı anda bütün girişlere uygulanabilir.

### 3.3.6 Ağırlık uzayı

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

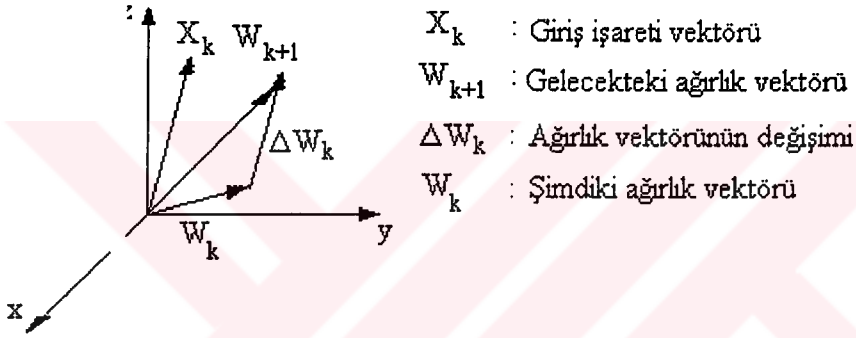
$$w = (w_{11}, w_{12}, \dots, w_{1n}, w_{21}, w_{22}, \dots, w_{2n}, \dots, w_{N2}, w_{N2}, \dots, w_{Nn})^T \quad (3.6)$$

$$w = (w_1^T, w_2^T, w_3^T, \dots, w_N^T) \quad (3.7)$$

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

$$w_1 = \begin{bmatrix} w_{11} \\ w_{12} \\ \vdots \\ w_{1n} \end{bmatrix}, \dots, w_N = \begin{bmatrix} w_{N1} \\ w_{N2} \\ \vdots \\ w_{Nn} \end{bmatrix} \quad (3.8)$$

YSA ağırlık vektörü  $N, n$  boyutlu orkit uzayında yayılır. YSA'nın enformasyon işleme performansı, ağırlık vektörünün belirli bir değeri ile bulunacaktır. Aşağıda Şekil 3.7' de ağırlıkların düzeltiminin vektörel çizimi verilmiştir.



Şekil 3.7 Üç boyutlu uzayda ağırlık vektörünün değişimi.

Şekilde görüldüğü gibi  $\Delta W_k, X_k$  ile aynı doğrultuda olduğunda istenen hata düzeltimini en küçük ağırlık değişimi ile elde etmek mümkündür. Böylece yeni bir giriş örüntüsü uygulandığında önceki eğitim örüntülerinin cevabı en az bozulmuş olur. Hata değişimini inceleyen iki çeşit kural vardır.

1- Hata düzeltme kuralları ,

2- Gradyan kuralları.

Hata düzeltme kuralları; Her bir giriş örüntüsünde ağırlıkları yeniden ağırlayarak çıktı hatasını en aza indirmeye çalışırlar. Gradyan kurallarında ise, ağırlıklar yeniden ayarlanarak ortalama karesel hatayı (MSE) en aza indirilmeye çalışılır.

Bu noktada gradyan kuralından kısaca bahsedecek olursak, hatayı düzeltmenin (yani minimize etmenin) geometrik bir yorumunu yapmak mümkündür. Bunu yapabilmek için

ağırlıkların mümkün olan tüm değerleri, hataların kareleri toplamına karşı gelecek şekilde üç boyutlu koordinat sisteminde çizilir. Bu çizim sonunda hata yüzeyi küresel bir top şeklindedir. Bu yüzeyi bir tasa da benzetmek mümkündür. Tasın en alt kısmı hataların kareleri toplamının en küçük değerlerine karşı gelmektedir. Eğitime sırasında amaç ağırlıklar kümesinin en iyisini bulmak olan, en alt kısmına ulaşmaktır. Geriye yayılım algoritması o andaki ağırlıklar yerine, yüzey hatasının eğimini hesaplayarak amacına ulaşır. Daha sonra da bu ağırlıkları tasın alt kısmına doğru artımsal olarak değiştirir. İşte bu artımsal olarak tasın üst kısmından alt kısmına doğru ilerleme işlemine “gradyan iniş” denir.

Ağırlık vektörü ile çalışan YSA'da önemli noktalardan birisi, bir öğrenme kuralı geliştirip, enformasyon bölgesi kullanarak (eşik fonksiyonu ile) ağırlık vektörü "w" yı istenilen YSA performansı verecek noktaya yöneltmektir. Genellikle öğrenme kuralı için bir performans ya da maliyet fonksiyonu tanımlanır. Minimizasyon veya maksimizasyon ile "w" vektörü bulunur. Bir performans çeşidi olarak bilinen, MSE (karesel ortalama hata) şu şekilde tanımlanır.

$$F(w) = \int_A |f(x) - G(x, w)|^2 \rho(x) dv(x) \quad (3.9)$$

Formülde :

$y=G(x,w)$ :sistemin giriş çıkış fonksiyonu.

$y$ :çıkış işareti vektörü

$x$ :giriş işareti vektörü

$w$ :ağırlık vektörü

$\rho(x)$ :olasılık yoğunluk fonksiyonu olup amaç  $F(w)$ 'i küçültmeye çalışmaktır.

### 3.4 Yapay Sinir Ağlarında Eğitim

#### 3.4.1 Eğitim algoritmaları

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

1- Öğreticili eğitim (supervised training).



2- Skor ile eğitime (graded training).

3- Kendini düzenleme ile eğitime (self-organization training)

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

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

Kendini düzenleyen ağ; giriş işaretine göre kendini düzenleyerek organize eder. Olasılık yoğunluk fonksiyonlarına, sınıflandırma ve şekil tanıma problemlerine uygulanabilir.

Ne tür eğitim yöntemi kullanılırsa kullanılsın, herhangi bir ağ için gerekli karakteristik özellik, ağırlıkların verilen eğitim örneğine nasıl ayarlanacağını belirtmek öğrenme kuralının oluşturulmasıdır. Öğrenme kuralının oluşturulması için bir örneğin, ağa defalarca tanıtılması gerekebilir. Öğrenme kuralı ile ilişkili parametreler ağın zaman içinde gelişme kaydetmesiyle değişebilir. Hangi YSA algoritmasında ne tür bir eğitim kullanıldığı bu bölümün giriş işaretlerinin sınıflandırılması kısmında gösterilmiştir.

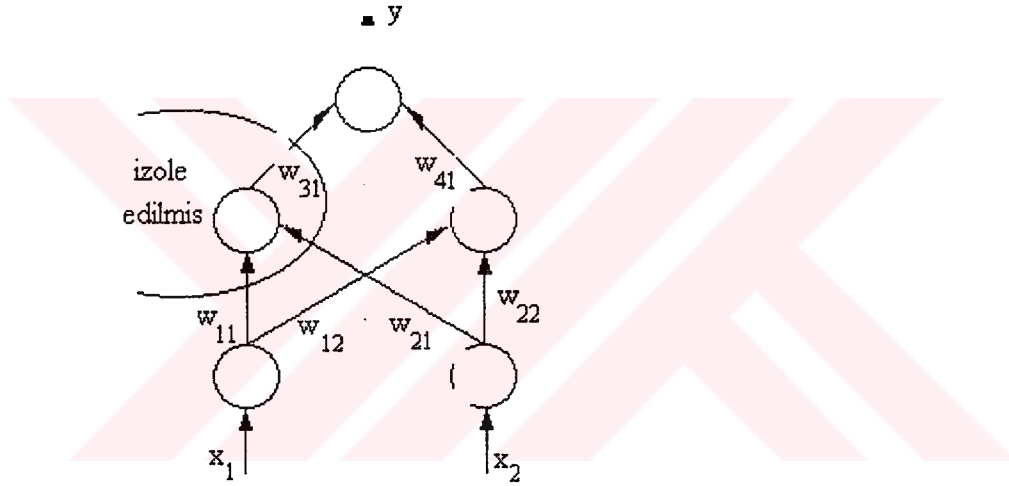
### 3.4.2 YSA' da bilgiyi saklama

YSA'nın önemli bir özelliği bilgiyi saklama şeklidir. YSA'da bellek dağıtılır. Bağlantı ağırlıkları YSA bellek biçimleridir. Ağırlıkların değerleri ağın o anki bilgi durumunu temsil eder. Mesela; bir giriş/istenen çıkış çiftinin belirtilen bilgi parçası ağın içinde birçok bellek biçimine dağıtılmıştır. Bellek üniteleri ile diğer saklı bilgiler, bu bilgiyi paylaşırlar. Bazı YSA bellekleri ilişkilidir. Öyle ki eğitilen ağa bir kısmı uygulanırsa, ağ bu giriş belleğindeki en yakın çıkışı bu giriş için seçer ve tam girişe bağlı çıkış ortaya çıkar. Eğer YSA oto-ilişkili ise, kısmi giriş vektörlerinin ağa verilmesi bu girişlerin tamamlanması ile sonuçlanır. YSA belleğinin yapısı; eksik, gürültülü ve tam seçilemeyen bir giriş uygulandığı zaman bile mantıklı çıkış üretmeye uygundur. Bu kurala "genelleme " adı verilir. Bir genellemenin kalitesi ve anlamı, uygulama çeşidine, ağın tipine ve karmaşıklığına dayanır. Lineer olmayan çok katmanlı ağlar (özellikle geriye yayılım ağları) gizli katmandaki özelliklerden öğrenirler ve bunları çıkışlar üretmek için birleştirirler. Gizli katmandaki bilgi, yeni giriş örüntülerine akılcı çözümler oluşturmak için kullanılabilir.

### 3.4.3 Hata toleransı

Klasik hesaplama sistemleri çok az bir zarardan bile etkilenir. YSA için durum farklıdır. Bu farklılık YSA'nın hata toleranslı olmasıdır. İşlem elemanlarının az da olsa zarar görmesi sistemin bütününe etkiler. YSA paralel dağılmış parametrelere sahip bir sistem olduğundan her bir işlem elemanı izole edilmiş bir ada olarak düşünülebilir. Şekil 3.8 'de çok katmanlı perceptron (MLP) için bu durum gösterilmiştir.

Daha çok işlem elemanın zarar görmesi ile sistemin davranışı biraz daha değişir. Performans düşer ama sistem hiç bir zaman durma noktasına gelmez. YSA sistemlerinin hata toleranslı olmasının nedeni bilginin tek bir yerde saklanmayıp, sisteme dağıtılmasıdır. Bu özellik sistemin durmasının önemli bir zarara neden olacağı uygulamalarda önem kazanır.



Şekil 3.8 MLP'nin izole edilmiş hali

### 3.5 Öğrenme Kuralları


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

Öğreticisiz öğrenmede her giriş işareti için istenen çıkış sisteme tanıtılır ve YSA giriş/çıkış ilişkisini gerçekleştirene kadar kademe kademe kendini ayarlar. Günümüzde kullanılan birçok öğrenme kuralı vardır. Bilinen en çok kullanılan öğrenme kuralları şunlardır.

- Rastlantısal (Hebb) öğrenme kuralı
- Performans (Widrow ve ADALİNE) öğrenme kuralı
- Kompetitif (Kohonen) öğrenme
- Filtreleme (Grossberg)
- Spotitemporal öğrenme
- Genelleştirilmiş Delta Kuralı Öğrenme

### 3.5.1 Perceptron (idrak, almaç)


Perceptron ağı, ilk 1943 yılında Mc Culloch ve Pitts tarafından saptandı. Bahsedilen YSA tipi aşağıda Şekil 3.9'da gösterildiği gibidir.



Şekil 3.9 Perceptron yapısı ve transfer fonksiyonu.

$$\sum_{j=1}^n w_j x_j - \theta = 0; n\text{- boyutlu uzayda } n-1 \text{ boyutlu bir düzlem belirler.} \quad (3.10)$$

Yani bu ilk perceptron modeline göre, giriş bilgisinin mevcut iki sınıftan hangisine eşit olabileceğini bulacak şekilde eğitilen basit bir ağıdır. Daha sonra 1960 yıllarında F.Rosenblatt yukarıdaki ağ tipini biraz daha geliştirdi (Hebb, 1949). Ama Minshy ve Papert bu tek katmanlı perceptronun XOR (ayrıcalıklı veya) işlemini gerçekleştiremediğini ispatladılar (Lippman, 1987). Şekil 3.10'dan anlaşılacağı gibi 0'ları bir tarafta 1'leri bir tarafta ayıracak şekilde bir bölge oluşmuyor. XOR gibi 3 veya daha fazla sınıfa ihtiyaç duyulan problemleri çözmek için yapılması gereken işlem; yapay sinir ağına yeni katmanlar eklemektir. Eşik bağlarıyla oluşturulan karar bölgesi şeklinin karmaşıklığı sadece eklenmiş olan katmanların sayısıyla sınırlıdır.



Şekil 3.10 Lineer Olarak Ayrılamazlığın Gösterimi.

Bilgi lineer yayılamıyorsa 2.katmanın çıkışı konveks bölgededir bunun neticesi olarak 3.katmandan gelecek olan çıkış bilgisinin şekli, herhangi bir bölgenin şeklinde olabilir. Bu sebeple ihtiyaç duyulan katman sayısı üç olmaktadır. İç-bükey olmayan, hatta basit bağlantılı olmayan bölgeleri kümelemek ancak 3 katmanlı ağ ile mümkündür.

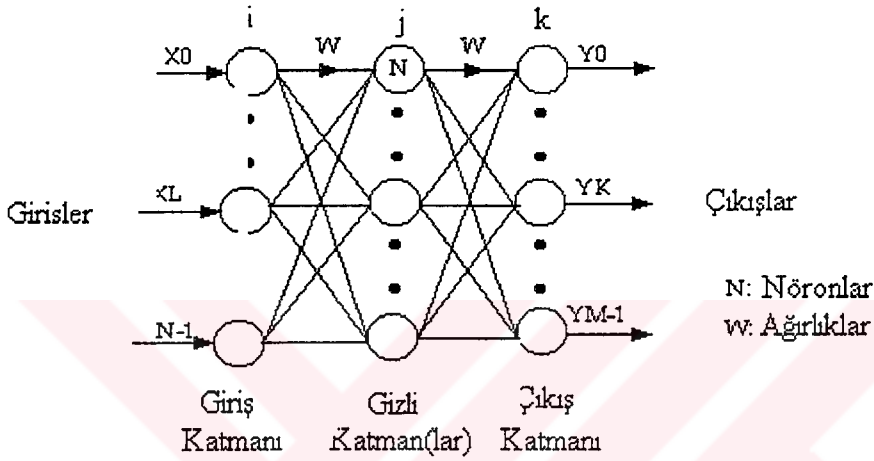
Gutierrez ve arkadaşları değişik perceptron ağlarının ihtiyacı olan düğüm sayıları hakkında çalışma yaptılar ve çok fazla düğüm kullanmanın; yetersiz sayıda düğüm kullanmada olduğu gibi zararlı etkisi olduğunu buldular (Gutierrez et al, 1989). Tek katmanlı perceptronda, uygulanan her eğitimin seti modelinin özelliği lineer biçimde dağılmak zorunda olmasıdır. Rosenblatt perceptron ağının lineer dağılım varsa kararlı olacağını gösterdiler.

### 3.5.2 Çok katmanlı perceptron (Multi-layer perceptron)

Çok katmanlı perceptron giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı YSA sistemleridir. Gizli katman (hidden layer) olarak isimlendirilen bu katmanlarda, düğümleri aracısız giriş alamayan ve aracısız çıkış veremeyen üniteler vardır. Şekil 3.11 'de çok katmanlı perceptronun genel yapısı verilmiştir.

İki katmanlı ağlarda veriler giriş katmanı tarafından kabul edilirler. Ağ içinde yapılan işlemler sonucunda çıkış katmanında oluşan sonuç değer işlenen cevap ile karşılaştırılır. Bulunan cevap ile istenen cevap arasındaki herhangi bir fark varsa ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Girişteki değer, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkışlar istenilen cevaplarla karşılaştırılarak sonuçta gerekirse hata işaret belirtilir. Hata işareti gizli birimlerden çıkış birimine olan ağırlıkları değiştirmekte kullanılır. Ama bunu yaparken giriş katmanından gizli katmana gelenin değiştirilip değiştirilemediğini düşünmek gerekir. Gizli birimlerden ne tür bir çıkış istendiği bilinmeyeceği için gizli birimlerin çıkışında hata işareti verilmesi kolay bir şey değildir. Bunun yerine her bir birimin, çıkış biriminin hatalarına olan etkisi bilinmelidir. Bu hatalı birim için gizli birime bağlı olan çıkış

birimlerinin hata işaretlerinin ağırlıkları toplamı alınarak yapılır. Çok sayıda gizli katmana sahip sistemlerde her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde, giriş seviyesine varana kadar devam eder. Sonuçta sistem hatalar yapar, ama bu hatalardan bir şeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yönetime "hatanın geriye yayılması algoritması" (Error back-propagation algorithm) denir. Çalışmada bu algoritma kullanıldığından incelenecektir.



### 3.5.3 Hatanın geriye yayılması algoritması ve genelleştirilmiş delta kuralı

Hatanın geriye yayılması algoritması, karesi alınmış hata fonksiyonunu minimize eden kodlu bir algoritma olup, genelleştirilmiş delta kuralını eğitime için kullanılır. Şekil 3.12'de blok akış diyagramı gösterilen algoritma, ana hatlarıyla şöyledir:

Her bir j biriminin çıkışı  $o_j$  şu şekilde tanımlanır;

$$o_j = f(net_j) = f(x) \quad \text{ise} \quad net_j = \sum_i w_{ji} o_i + \theta_j \quad (3.11)$$

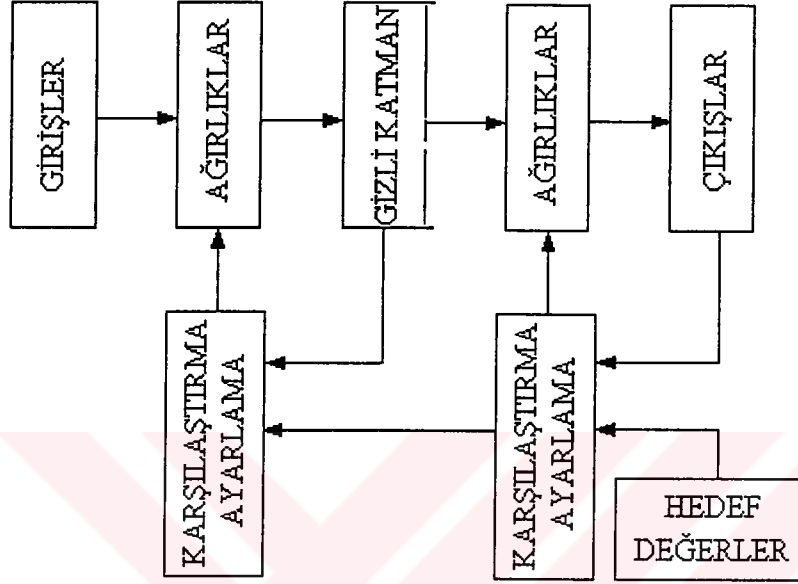
Burada:  $o_i$  ; i. biriminin çıkışı

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

$\theta_j$  ; j biriminin kutbu (bias)

net<sub>j</sub>; çıkışı j birimine akan her i biriminin toplamıdır.

$f(x)$ ; bir monoton artan ve türevi alınabilen fonksiyondur. Pratikte bir lojistik aktivasyon fonksiyonu olarak (3.5) numaralı eşitlikte verilen sigmoid fonksiyonu daha çok kullanılır.



Şekil 3.12 Hatanın geriye yayılması algoritmasının blok akış diyagramı

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

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

$$E_p = \frac{1}{2} \sum (t_{pj} - o_{pj})^2 ; j \in \text{çıkış katmanı} \quad (3.12)$$

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

$i_{pi}$  : Giriş işaretinin i bileşeni;

$t_{pj}$  : Çıkış vektörünün j bileşeni;

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

$$\delta_{pj} = (t_{pj} - o_{pj}) \quad (3.13)$$

$$\Delta_p w_{ji} = -\varepsilon \left( \frac{\partial E_p}{\partial w_{ji}} \right) \quad (3.14)$$

$$\Delta_p \theta_j = -\varepsilon \left( \frac{\partial E_p}{\partial \theta_j} \right) \quad (3.15)$$

Burada  $\varepsilon$  : öğrenme oranı adı verilen küçük bir pozitif sabit sayılır. Şayet gizli katman yok ise; (3.14) ve (3.15)'in sağ tarafı hesaplanır, o zaman;

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial w_{ji}} \quad (3.16)$$

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj}) = -\delta_{pj} \quad (3.17)$$


$$o_p = \sum_i w_{ji} i_{pi} \text{ ise;} \quad (3.18)$$

$$\frac{\partial o_{pj}}{\partial w_{ji}} = i_{pi} \quad (3.19)$$

elde edilir. (3.17) ve (3.19) ifadelerini (3.16)'da yerine konulursa;


$$-\frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} i_{pi} \quad (3.20)$$

olur. Hata fonksiyonu Şekil 3.13'te gösterildiği gibidir.



Şekil 3.13 Gizli katmanı olmayan ağın hata fonksiyonu

Gizli katman bulunan yapay sinir ağlarında ; hata düzeyi Şekil 3.13'de olduğunun aksine bir minimumdan daha fazladır. Şekil 3.14'teki gibi çeşitli minimumlar oluşur. Öğrenmede en küçük minimuma ulaşılmak istenir.



Şekil 3.14 Gizli katmana ait ağırlık hata fonksiyonu

Bu durumda j. düğümün lineer olmayan çıkışı;

$$o_{pj} = f_j(netp_j) \Rightarrow netp_j = \sum_i w_{ji} o_{pi} \quad (3.21)$$

şeklindedir. Bu durumda;

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial netp_j} \frac{\partial netp_j}{\partial w_{ji}} \Leftrightarrow \frac{\partial netp_j}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \sum_k w_{jk} o_{pk} = o_{pi} \quad (3.22)$$

$$\delta_{pj} = -\frac{\partial E_p}{\partial netp_j} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial netp_j} = -\frac{\partial E_p}{\partial o_{pj}} f'_j(netp_j) \quad (3.23)$$

İki durum söz konusudur:

1-  $o_{pj}$  YSA'nın çıkışı ise; (3.17) ifadesini (3.23)'de yerine koyarsak,

$$\delta_{pj} = (t_{pj} - o_{pj}) f'_j(netp_j) \quad (3.24)$$

bulunur.

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

$$\sum_k \frac{\partial E_p}{\partial netp_k} \frac{\partial netp_k}{\partial p_j} \quad \text{şeklinde ise,} \quad (3.25)$$



$$\sum_k \frac{\partial E_p}{\partial netp_k} \frac{\partial}{\partial o_{pj}} \sum_i w_{ki} o_{pi} = - \sum_k \delta_{pk} w_{kj} \quad (3.26)$$

olur. Bulunan sonuç (3.23)'de yerine konulursa;

$$\delta_{pj} = f'(netp_j) \sum_k \delta_{pk} w_{kj} \quad (3.27)$$

elde edilir. (3.26) denklemindeki (-) işareti, ağırlıkların ters yönde değiştiğini belirtir.

Bütün yapılan işlemler kısaca özetlenecek olursa;

1. Genelleştirilmiş  $\Delta$  (delta) kuralı:

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

2. Çıkış katmanı elemanları için;

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

3. Gizli katman elemanları için;

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

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

$$o_{pj} = \frac{1}{1 + e^{-\left(\sum_i w_{ji} o_{pi} + \theta_j\right)}} \quad (3.28)$$

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

$$\frac{\partial o_{pj}}{\partial netp_j} = o_{pj} (1 - o_{pj}) \quad (3.29)$$

bulunur. Bu (3.24) de yerine konulursa, çıkış elemanı için;

$$\delta_{pj} = (t_{pj} - o_{pj}) o_{pj} (1 - o_{pj}) \quad (3.30)$$

elde edilir. (3.29); (3.27) de yerine konulursa, gizli katman elemanı için;

$$\delta_{pj} = o_{pj} (1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (3.31)$$

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

$$\Delta_p w_{ji}(t+1) = \varepsilon \delta_{pj} o_{pi} + \alpha \Delta_p w_{ji}(t) \quad (3.32)$$

$$\Delta_p \theta_j(t+1) = \varepsilon \delta_{pj} + \alpha \Delta_p \theta_j(t) \quad (3.33)$$

Burada; t: öğrenme devirlerinin sayısını gösterir. ( $\alpha$ ) küçük pozitif bir sayıdır.

### 3.6 Hatanın Geriye Yayılması Algoritmasının Geliştirilmesi

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

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

#### 3.6.1 Bağlantı ağırlıklarının atanması

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

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

#### 3.6.2 Öğrenme katsayısı

Hatanın geriye yayılması algoritmasında çözüme ulaşma hızı ile öğrenme katsayısının değeri doğrudan alakalıdır. Eğer öğrenme katsayısı küçük seçilirse YSA'nın takip edeceği araştırma

yolu gradyan yola çok yakın olacaktır. Bu durumda yerel minimuma ulaşmak için alınacak adım sayısı artacağından çözüme ulaşmak uzun zaman alacaktır. Diğer yandan, öğrenme katsayısı çok büyük seçilirse başlangıçta YSA çözüme kolay yaklaşacak fakat çözüm civarında osilasyon yaparak çözümü bulamayacaktır. Genelde minimumdan uzak bölgelerde büyük adım kat etmek ve minimum civarında küçük adımlar kullanmak en uygun çözümdür.

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

### 3.6.3 Momentum katsayısı

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

$$\Delta w_i(t) = -\rho \frac{\partial E}{\partial w_i(t)} + \alpha \Delta w_i(t-1) \quad (3.34)$$

Burada;  $\rho$ , öğrenme katsayısı ve  $\alpha$  momentum katsayısıdır.  $\alpha$  normalde 0 ile 1 arasında değişen bir sayıdır. Momentum katsayısı :

$$\alpha(t) = \frac{\frac{\partial E}{\partial w_i(t)}}{\frac{\partial E}{\partial w_i(t-1)} - \frac{\partial E}{\partial w_i(t)}} \text{ şeklindedir.} \quad (3.35)$$

(3.35) eşitliğini; (3.34) de yerine koymakla elde edilen ağırlık değişim formülü; dinamik olarak değişen öğrenme katsayısı kullanımıyla “steepest gradient-descent-based” adaptasyon algoritmasına dönüşmüş olur. (3.34) eşitliğinde olduğu gibi hata gradyanı bilgisinin ard arda iki zaman adımında kullanılması, Newton’un ikinci dereceden araştırma metoduna benzetilebilir.

Momentum katsayısını değiştirmede diğer bir metod “conjugate gradient method” dur. Bu

metotla ağırlıkların değiştirilmesine ait eşitlik:

$$\Delta w(t) = -\rho \nabla E(t) + \frac{[\nabla E(t) - \nabla E(t-1)]^T \nabla E(t)}{\|\nabla E(t-1)\|^2} \Delta w(t-1) \text{ dir.} \quad (3.36)$$

### 3.7 YSA Kullanımının Sebepleri

YSA'lar verilerden hareketle, bilinmeyen ilişkileri akıllıca hemen ortaya çıkarabilmektedir. Bu özellikleri, uygulama açısından son derece önemlidir. Ayrıca veri toplama için bir ön sorgulama ya da açıklama gerekmemektedir. YSA'lar çözüm olarak genelleştirilebilir. Bir örnekten hareketle, diğer örneklerdeki benzerlikleri doğru olarak anlayabilirler. Genelleştirme yapılabilmesi bu bakımdan çok iyi bir özelliğidir, çünkü gerçek dünya verilerinde sürekli olarak gürültü ve bozucu etkiler mevcuttur.

YSA'lar non-lineerdir. Bu özellikleri nedeni ile daha karmaşık problemleri lineer tekniklerden daha doğru çözerler. Non-lineer davranışlar hissedilir, algılanır, bilinebilir, ancak bu davranışları ya da problemleri matematiksel olarak çözmek zordur. YSA'lar son derece paralellığe sahiptir. Bağımsız işlemleri aynı anda çok hızlı yürütebilirler. Paralel donanımlar yapıları gereği YSA'lara uygun olduğundan kendisine alternatif çözüm metodlarından daha elverişlidir.

### 3.8 YSA'nın Klasik Yazılımlar İle Karşılaştırılması

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

YSA'ların uygulamadaki dezavantajlarını sıralayacak olursak;

- 1- Bir problemin çözümünde çok uygun bir çözüm bulamayabilirler ve çözümde hata yapabilirler. Buna sebep ise eğitilecek bir fonksiyonun bulunamamasıdır. Fonksiyon bulunsa bile yeterli veri sağlanamayabilir.
- 2- Sonuç almak yüzlerce giriş örneğinin hesaplanmasına bağlı olabilir. Ayrıca hangi ağırlığın sonucu nasıl etkileyeceğini tahmin etmek zordur.

3- YSA'larla bir dizi işlem yapmak, bunları eğitmek yavaş ve pahalı olabilir. Maliyeti arttıran sebeplerden ilki eğitme verilerinin toplanması ve değerlendirilmesidir. Doğru değerleri bulmak için deneyler yapmak gerekebilir.

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

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



## 4 VERİ TABANI VE ÇALIŞMA BÖLGESİ

### 4.1 Çalışma Bölgesinin Topografik Durumu

İstanbul, yaklaşık 5712 km<sup>2</sup> yüzölçümüne sahip ve 1990 yılı sayımına göre 7 milyon (Devlet İstatistik Enstitüsü, 1993) nüfuslu bir şehir olup, arazisi genelde birçok vadi ile birbirinden ayrılmış tepelerden oluşmaktadır. Bugün son derece büyük bir sahaya yayılmış olan şehrin surlar içinde kalan kısmına Eski İstanbul adı verilir. Surlar içindeki bu bölge Topkapı Sarayı, Ayasofya ve Sultanahmet, Çemberlitaş ve Nuruosmaniye, Fatih, Yavuz Sultan Selim, Edirnekapı ve Samatya olmak üzere yedi tepe üzerinde kurulmuş olduğu eskiden beri kabul edilmektedir. Surlar içinde kalan bu kısmın yüzölçümü 25 km<sup>2</sup> kadardır.

İstanbul'un topografyası 4 ana bölümden oluşmaktadır:

**Batı Bölgesi:** Kumburgaz'dan Bakırköy'e kadar uzanan 35 km uzunluğundaki Batı Bölgesinde, Büyükçekmece, Küçükçekmece ve Marmara Denizi'ne ulaşan başlıca üç vadi bulunmaktadır. Bu üç vadi sularını Büyükçekmece'ye, Küçükçekmece'ye ve doğrudan Marmara Denizi'ne vermektedir. Vadiler Marmara Denizi'nden kuzeye doğru uzanan alçak tepelerle sınırlanmıştır. Topografik bakımdan Kuzey Marmara sahilleri karakteristiğindedir. Bu bölgede arazi kotları 0-200 m arasında değişmektedir.

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

**Boğaziçi Bölgesi:** Asya ve Avrupa kıtalarını ayıran ve toplam uzunluğu 27 km olan İstanbul Boğazı'nı içine alan Boğaziçi Bölgesi, boğaza dik olarak gelen vadilerden oluşmaktadır. Boğaz'ın Avrupa kıyası, Ortaköy'e kadar düzgün olarak giden yükseklikleri yaklaşık 130 m'yi bulan tepelerle 5 km genişliğindeki şerit halinde Haliç drenaj sahasından ayrılır. Ortaköy'den Rumeli Kavağı'na kadar olan kısımda bulunan tepelerin rakımları 150 m'ye kadar çıkar. Boğaz'ın Anadolu tarafında ise, Avrupa yakasına göre daha engebeli ve daha yüksek

tepelere oluřan bir topografya mevcuttur. Bu kesimde, 200 m'ye kadar ıkan Kısıklı ve 250 m'ye kadar ıkan Byk ve Kk amlıca tepesi, en yksek rakımları teřkil etmektedir. Anadolu Kavađı'na kadar devam eden blgede 16 adet kk vadi vardır.

Pendik-Kadıky Blgesi: İstanbul'un topografik olarak drdnc nemli blmn Kadıky ile Pendik arasında uzanan, kuzeyde Kayıřdađı ve Yakacık tepeleri ile sınırlanan ve deniz seviyesinden yaklaşık 50 m yksekliđe kadar deđiřen araziler teřkil etmektedir. Blge genel olarak fazla yksek olmayan tepe ve platolardan oluřmuřtur. Topografik ynden blgeyi iki blme ayırabiliriz. Bunlar sularını Marmara Denizi'ne ve Bođaz'a veren sahalardır. Blge iinde zaman zaman kuruyan derelerin de bulunduđu drt vadi mevcuttur. Bunlardan Kurbađalıdere, Bostancı Deresi ve İbrahimađa Deresi Marmara Denizi'ne, Beylerbeyi Deresi ise Bođaza dklmektedir.

## 4.2 Veri Tabanı

İstanbul'un hava kirliliđinin yapay sinir ađları ile modellenmesinde, model ıktısı olarak gnlk ortalama SO<sub>2</sub> parametresi kullanılmıřtır. Bu parametrenin tahmininde bir gn nceki meteorolojik parametreler model iin girdi parametreleri olarak kullanılmıřtır. Diđer bir deyiřle bugnn meteorolojik parametreleriyle yarının (24 saat sonranın) kirlilik durumu tahmin edilmiřtir. Modelde kullanılan girdi parametreleri, temin edildikleri merkezler, lm birimleri ve hava kirliliđine olan muhtemel etkileri ařađıda ifade edilmiřtir.

### 4.2.1 Hava kirliliđi verileri

Bu alıřmada kullanılan kirlilik verileri İstanbul İl Sađlık Mdrlđ Hıfzısıhha Enstitsnn 1992'den 1998 yılı sonuna kadar olan sre iinde İstanbul'daki eřitli lm istasyonlarında ltđ veriler olup bu istasyonlarda llen gnlk (24 saatlik) ortalama kkrtdioksit (SO<sub>2</sub>) konsantrasyonları deđerlendirilmiřtir. Bu veriler toplu olarak Bařbakanlık Devlet İstatistik Enstitsnden temin edilmiřtir (DİE, 1998).

Kkrtdioksit lm prensip olarak havanın bu gaz sebebi ile sahip olduđu asiditesinin lm olarak yapılmaktadır ve eřdeđer  $\mu\text{gr}/\text{m}^3$  řeklinde ifade edilmektedir. lm, asidimetrik titrasyon metodu ile yapılmaktadır. Bu metotta, hava numunesi 24 saat boyunca seyreltik hidrojen peroksit zeltisi iinden geirilmekte ve kkrtdioksit zeltide absorbe olup slfrik aside dnřmektedir. Daha sonra bu zeltinin asiditesi standart NaOH zeltisi ile titre edilip sonu eřdeđer SO<sub>2</sub> konsantrasyonu řeklinde ifade edilmektedir.

#### 4.2.2 Meteoroloji verileri

Meteorolojik veriler Göztepe Sinoptik Meteoroloji İstasyonunun ölçtüğü veriler olup 1992 - 1998 yılları arasında kapsayan günlük klima ve radyozonde verileridir. Bu veriler de toplu olarak Devlet Meteoroloji İşleri Genel Müdürlüğünden temin edilmiştir (DMİ, 1998)

Bu çalışmada kullanılan meteorolojik veriler ve prensip olarak hava kirliliğine etkileri aşağıdaki gibidir.

##### 4.2.2.1 Sıcaklık

Günlük ortalama kuru termometre sıcaklığı olup °C olarak ifade edilmektedir. Ölçülen bir parametredir Sıcaklıkla hava kirliliği teorik olarak ters orantılıdır. Sıcaklık enversiyonun temeli olduğu için kirlilik bakımından önemli parametredir. Ayrıca kış aylarında sıcak geçen günlerde ısınma maksatlı yakıt tüketimi az olacağından atmosfere bırakılan kirletici miktarı da az olacaktır, dolayısıyla hava kirliliği de soğuk geçen günlere oranla daha az olacaktır.

##### 4.2.2.2 Denize indirilmiş basınç

Meteoroloji istasyonunda ölçülen ve milibar olarak ifade edilen günlük ortalama basınç, istasyonun bulunduğu topografik konum (Göztepe istasyonu için rakım 39 m) dolayısıyla belli bir yükseklikteki basınç olup beynelmilel kullanım için deniz seviyesi basıncı hesaplanarak bu çalışmada kullanılmıştır.

Deniz seviyesi basıncı yükseklik ve hava sıcaklığına bağlı olarak Göztepe Meteoroloji İstasyonunun rakımsal konumu için sadeleştirilen aşağıdaki formülle hesaplanmaktadır.

$$\text{Denize İndirilmiş Basınç} = \text{Ölçülen Basınç} * (-0,00001 * \text{Ölçülen Sıcaklık} + 1,0041)$$

Buradaki katsayılar istasyonun bulunduğu yüksekliğe göre hesaplanmış sabitlerdir.

Basıncın hava kirliliği ile ilişkisi Giriş Bölümünde de ifade edildiği gibi iki durumla kendini göstermektedir:

-Alçak basınç sistemi kirleticilerin dağıtılması açısından istenen bir durumdur.

-Yüksek basınç sistemi hava kirliliği açısından olumsuz bir durumdur.(Bakınız Giriş Bölümü)

##### 4.2.2.3 Bulutluluk

Bu parametre aletsel olmayıp gözle gözlemlenen bir parametredir. Birimi yoktur. Tamamen



kapalı (bulutla kaplı) hava için 10 ve tamamen açık (bulutsuz) hava için 0 birim olmak üzere kısmen bulutlu hava durumları bulut miktarına göre 0 –10 arası bir sayı ile ifade edilmek suretiyle bu parametre belirlenmektedir. Bulutluluk bir açıdan güneşlenmeyi etkileyen durum olduğu için bulut miktarı arttıkça hava sıcaklığında düşme görülmektedir. Diğer taraftan bulutların türü ve yükseklikleri de çok önemli olduğundan bulutlanmanın hava kirliliğine etkisi daha karmaşık bir hal almaktadır

#### 4.2.2.4 Nispî nem

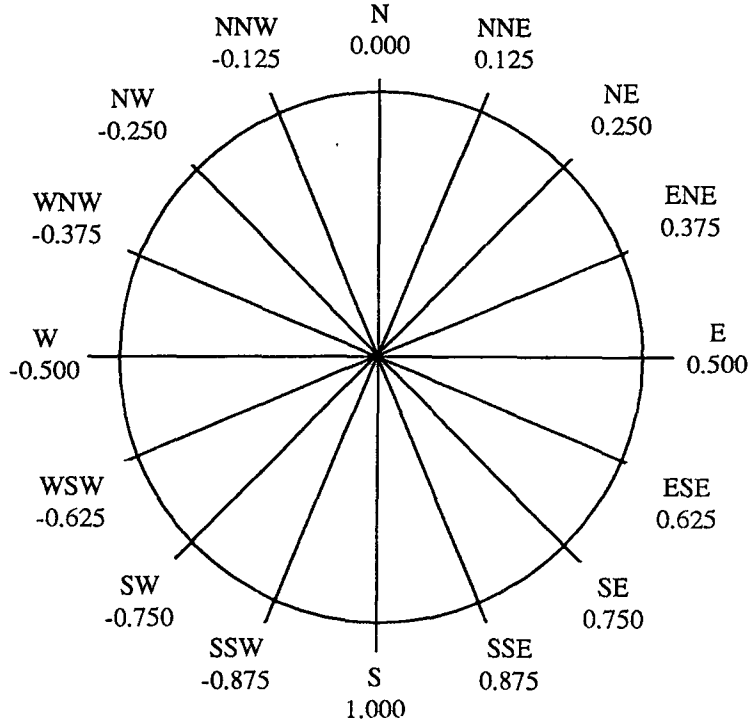
Havadaki nem miktarının (su buharının) % olarak ifadesidir. Nisbi nem,  $1m^3$  havada gram olarak ölçülen nem miktarının aynı sıcaklıkta  $1m^3$  havanın taşıyabileceği azami nem miktarına (mutlak nemlilik) oranıdır. Havadaki su buharı miktarının artması atmosferde bulunan kirletici parametrelerin bu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

#### 4.2.2.5 Toplam yağış

Bir gün boyunca  $1m^2$  alana düşen yağış miktarının milimetre olarak yüksekliğini veya kilogram olarak ağırlığını ifade etmektedir. Yağan yağmur atmosferde bulunan kirletici gazları absorblayıp gidereceğinden hava kirliliğini azaltıcı yönde etki gösterebilmektedir.

#### 4.2.2.6 Hakim rüzgar yönü ve hızı

Saatlik rüzgar yön ve hızları kullanılarak günlük ortalama rüzgar hızı m/s olarak ve frekans olarak en çok esen yön de hakim rüzgar yönü olarak hesaplanmaktadır. Hakim rüzgar yönü rüzgar gülünde bulunan 16 yönden biri olarak ifade edilmektedir. Rüzgar atmosferdeki hareketliliğin en baskın parametresi olup kirletici gazların yatay taşınımını ve dolayısıyla seyrelmelerini sağlamaktadır. Rüzgar yönünün kirletici konsantrasyonlarına etkisi geldiği yöne bağlı olarak değişiklik gösterebilir. Rüzgar, deniz gibi temiz hava kütesinin bulunduğu bir yönden esiyorsa kirli bölgedeki kirleticileri seyreltebilir. Hakim rüzgar yönü parametresi yapay sinir ağları modellerinde kullanılmak üzere Şekil 4.1'de gösterildiği gibi sayısal değerlere dönüştürülmüştür.



Şekil 4.1 Hakim rüzgar yönlerinin YSA modeli için girdi sayısal değerlerine dönüştürülmesi

#### 4.2.2.7 Güneşlenme süresi ve şiddeti

Güneşlenme süresi bir gün boyunca güneşin çıplak olarak gözleendiği toplam sürenin saat olarak ifadesidir. Şiddeti ise bu süre boyunca saatlik  $\text{Cal/cm}^2/\text{dakika}$  değerlerinin toplamı olarak ifade edilmektedir.

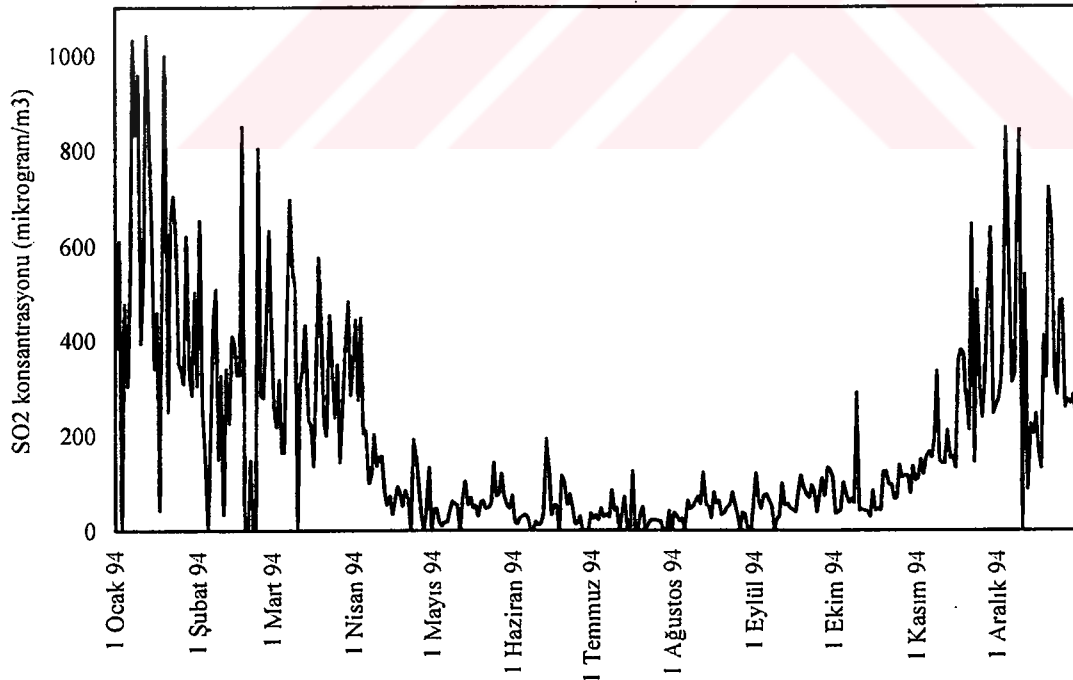
Güneşlenme süresi ve enerjisi kışın ısınma maksatlı yakıt tüketimini azaltıcı yönde etki etmektedir.

#### 4.2.2.8 Enversiyon başlangıcı ve şiddeti


Göztepe Meteoroloji İstasyonundan her gün 00.00 GMT ve 12.00 GMT saatlerinde atılan radyosonde balonu ile ölçülen çeşitli seviyelerdeki sıcaklık ile yükseklik arasındaki ilişkiler kullanılarak sıcaklığın yükseklikle artmaya başladığı (sıcaklık gradyanının pozitif duruma geçtiği) ve yükseklik ile bu artışın sona erdiği seviye hesap yoluyla bulunarak enversiyon başlangıcı metre olarak hesaplanmaktadır. Aynı bilgiler kullanılarak  $^{\circ}\text{C}/100\text{m}$  olarak enversiyon kuvveti (dikey sıcaklık gradyanı) hesaplanmaktadır. Enversiyon olmayan günlere ait sayısal veri olmadığı için veri setinde bu günler için 0 (sıfır) değeri koymak model için anlamsız olmaktadır. Bu sayısal anlamsızlığı ortadan kaldırmak için enversiyon olmayan

günlerde enversiyon başlangıç değeri olarak 1992-1998 periyodu içinde oluşan en yüksek enversiyon başlangıç değerinden daha da yüksek olarak 20.000 m değeri alınmıştır. Bu kadar yüksek bir enversiyon başlangıcı da gerçekte enversiyon olmaması olarak algılanabilir. Çünkü bu yükseklikteki bir hava kütlesi zaten kirleticilerin dağılıp seyrelmesi açısından yeterli bir yüksekliktir. Yine enversiyon olmayan günlere ait enversiyon şiddeti olarak da o günlere ait radyosonde ölçümlerinde atmosferin ilk yüksekliklerine ait sıcaklık gradyanı hesaplanarak veri setinde sayısal değer olarak kullanılmıştır. Bu değerler de o günlere ait atmosfer kararsızlığının sayısal ifadesi olarak veri setinde kullanılmıştır. Enversiyon durumu hava kirliliği bakımından en kötü kararlılık durumudur. Atmosfere bırakılan gaz kütlesi ile çevre havası arasındaki sıcaklık farkı, yer seviyesine doğru artacağı için gaz kütlesi atmosferde yükselmek yerine aşağı doğru hareket edip bulunduğu bölgede sıkışacaktır (Çeşitli enversiyon durumları için Giriş Bölümüne bakınız).


Çalışmada kullanılan bütün parametrelerin 1994 yılı boyunca günlük değişimleri grafiksel olarak Şekil 4.1 ile Şekil 4.14 arası şekillerde gösterilmiştir. Bu şekillerin görsel incelenmesi de bu parametrelerin bazılarının modelleme açısından ne kadar kompleks ve non lineer ilişki içinde olduklarını göstermektedir.




Şekil 4.2 Günlük ortalama SO<sub>2</sub> konsantrasyonunun 1994 yılı boyunca değişimi



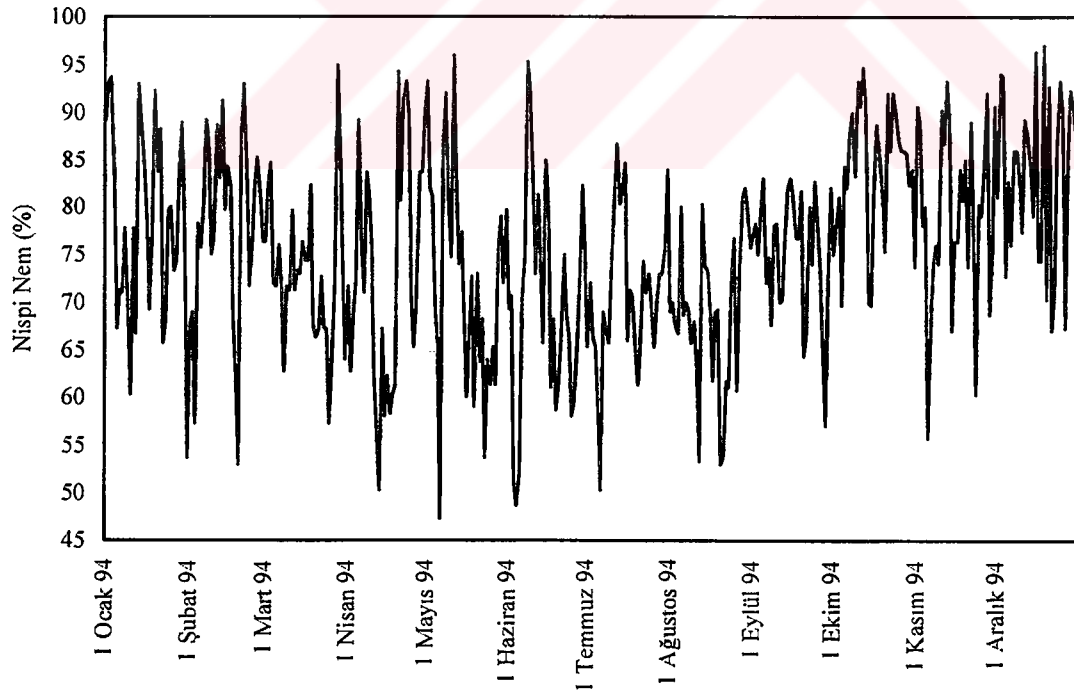
Şekil 4.3 Ortalama sıcaklığın 1994 yılı boyunca günlük değişimi




Şekil 4.4 Denize indirilmiş basıncın 1994 yılı boyunca günlük değişimi




Şekil 4.5 Bulutluluğun 1994 yılı boyunca günlük değişimi




Şekil 4.6 Nispi nemin 1994 yılı boyunca günlük değişimi



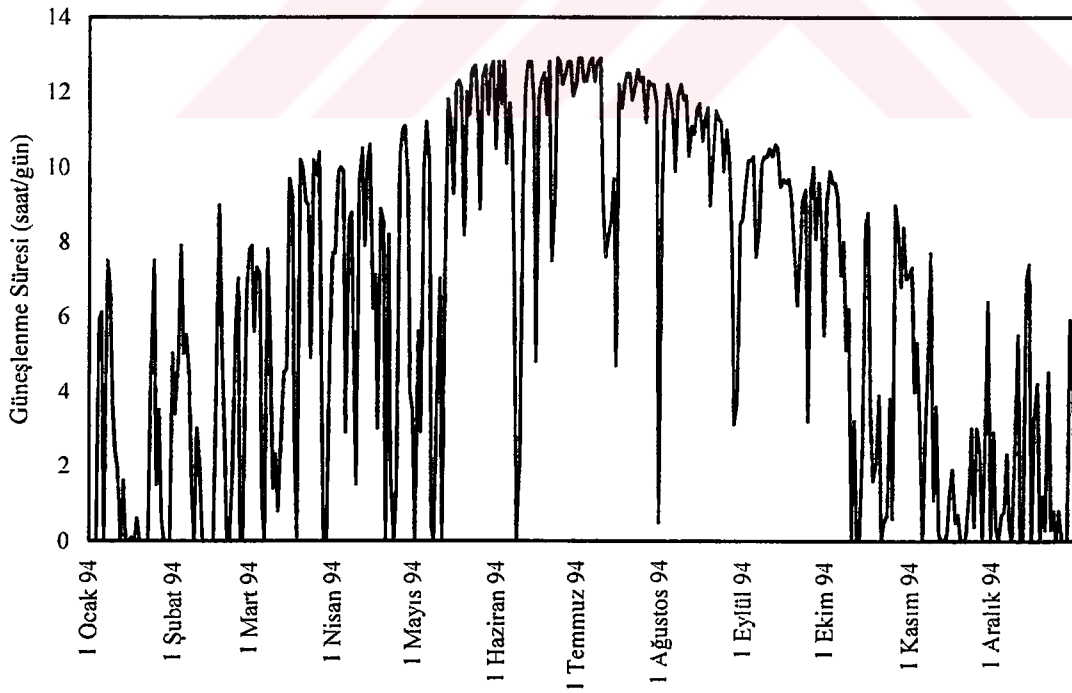
Şekil 4.7 Toplam yağışın 1994 yılı boyunca günlük değişimi




Şekil 4.8 Hakim rüzgar yönlerinin 1994 yılı boyunca günlük değişimi (Haziran ayı verileri yoktur.)




Şekil 4.9 Ortalama rüzgar hızlarının 1994 yılı boyunca günlük değişimi (Haziran ayı verileri yoktur.)



Şekil 4.10 Güneşlenme sürelerinin 1994 yılı boyunca günlük değişimi




Şekil 4.11 Güneşlenme şiddetinin 1994 yılı boyunca günlük değişimi




Şekil 4.12 GMT 00 Enversiyon başlangıçlarının 1994 yılı boyunca günlük değişimleri






Şekil 4.13 GMT 00 Enversiyon şiddetlerinin 1994 yılı boyunca günlük değişimleri



Şekil 4.14 GMT 12 Enversiyon başlangıçlarının 1994 yılı boyunca günlük değişimleri



Şekil 4.15 GMT 12 Enversiyon şiddetlerinin 1994 yılı boyunca günlük değişimleri


### 4.3 Verilerin analizi ve model için girdi seti hazırlanışı

Meteoroloji verileri Göztepe istasyonunda ölçüldüğü için Hıfzısıhha Enstitüsünün bu noktadaki günlük ortalama SO<sub>2</sub> ölçüm değerleri kirlilik parametresi olarak kullanılmıştır.

Elde edilen ve 1992 – 1998 yıllarını kapsayan hava kirliliği ve meteoroloji verileri incelendiğinde Göztepe bölgesindeki kirlilik ölçümlerinin 1994 yılından itibaren başladığı saptanmıştır. Bunun yanında 1995 yılından itibaren İstanbul’da doğalgaz kullanımı yaygınlaşmıştır. Bu sebeple hava kirliliğinde belirgin bir azalma gözlemlenmiştir (Ertürk ve diğerleri,1995, Şekil 4.15). Dolayısıyla 1995 yılı ve sonrası yıllar için yapılacak modelleme çalışmasında günlük doğalgaz kullanım miktarı model için önemli bir girdi parametresini teşkil edecektir. Ancak zikredilen bu yıllara ait günlük doğalgaz kullanım verilerine ulaşamadığı için 1995 yılı ve sonrası yıllar çalışmaya dahil edilmemiştir. Bütün bu kıstaslar çerçevesinde elde edilen verilerden ancak 1994 yılının model için uygun girdi verileri setini teşkil ettiği görülmüştür.

1994 yılı meteoroloji ve kirlilik verileri zaman serisi şeklinde (1 Ocak 1994 – 31 Aralık 1994) düzenlenip her bir parametrenin istatistiksel değişim aralığı incelemesi yapılmış ve ölçüm hatalarının ve mantıksal sınır harici değerlerin olup olmadığı kontrol edilmiştir. Bu

kontrollerden geçirilen model parametreleri ve bu parametrelerin 1994 yılı içindeki maksimum, minimum ve ortalama deęerleri izelge 4.1'de verilmiřtir. SO<sub>2</sub> kirlilik konsantrasyonu bilinmeyen (lülmemiř) gnler veri setinden ıkarıldıęında modelin alıřtırılması iin 333 veriden oluřan veri seti oraya ıkmaktadır. Bu 333 veri ařaęıda ifade edilen yntemlerle eřit Őekilde ęrenme ve test seti olarak iki gruba ayrılmıřtır.



Őekil 4.16 Gztepe istasyonunda llen SO<sub>2</sub>'nin 1992-1998 yılları arası gnlk deęiřimi (1994'ten nceki veriler en yakın istasyon olan Kadıky istasyonundan alınmıřtır)

Test ve ęrenme seti gruplandırması model performansı bakımından nemli bir husustur. Gruplandırma rasgele olarak sonsuz biimde yapılabilir. Bu alıřmada iki deęiřik durum kullanılmıř ve sonuları karřılařtırılmıřtır.

1. Deęer sıralı veri seti gruplandırması
2. Zaman sıralı veri seti gruplandırması

#### 4.3.1 Deęer sıralı veri gruplandırması

Bu gruplandırma iřleminde nce btn veriler ıkıř verisi (SO<sub>2</sub> konsantrasyonu) bazında kkten byęe doęru (1. sırada en dřk SO<sub>2</sub> konsantrasyonuna sahip gn ve o gne ait girdi verileri, ve sonuncu sırada en yksek SO<sub>2</sub> konsantrasyonuna sahip gn ve o gnn girdi verileri) sıralandı (Őekil 4.17). Daha sonra tek sıralı veriler ęrenme seti, ift sıralı veriler de

test seti olarak ayrıldı (Şekil 4.18). Bu şekilde gruplandırma ile yılın bütün aylarında oluşan her kirlilik durumu öğrenme setinde temsil edilebilmektedir. Böylelikle modelin çıktı verisi bazında daha fazla durum öğrenmesi sağlanmış ve dolayısıyla genelleme yapabilme kabiliyeti de arttırılmış olmaktadır.


#### 4.3.2 Zaman sıralı veri gruplandırması

Bu yöntemde veriler zaman serisi şeklinde sıralanıp numaralandırıldı. Tek numaralı veriler öğrenme setine ve çift numaralı veriler de test setine ayrıldı. Bu şekilde sınıflandırma ile verilerin yıl içindeki mevsimsel değişimleri test ve öğrenme setinde eşit olarak temsil edilmiş olmaktadır.


Çizelge 4.1’de bulunan ilk 13 parametre model için girdi parametreleri olup çıktı olarak 1 gün sonraki SO<sub>2</sub> konsantrasyonu tahmin edilmiştir. Ayrıca meteorolojik verilerin bulunduğu güne ait SO<sub>2</sub> konsantrasyonu da (yani tahmin edilen günden önceki günün kirlilik seviyesi) girdi olarak kullanılmış, böylelikle kirlilik parametresinin atmosfer ortamındaki sürekliliğinin muhtemel etkisi modele dahil edilmiştir. Yani bugünün hava kirliliği seviyesinin yarınki hava kirliliği seviyesine etkisi bu parametre ile modele dahil edilmiştir.

Çizelge 4.1 Modelde kullanılan parametreler ve bunların 1994 yılı boyunca maksimum, ortalama ve minimum değerleri

Parametre	Birim	Minimum	Ortalama	Maksimum
Basınç (deniz seviyesi)	mbar	998,7	1016,2	1032,7
Ort. Sıcaklık	°C	0,2	15,3	28,6
Bulutluluk	-	0	3,9	10
Nispi Nem	%	47	75	97
Toplam Yağış (günlük)	mm	0	1,7	32,1
Hakim Rüzgar Yönü		1	6,8	16
Ort. Rüzgar Hızı	m/sn	0	2,3	6,3
Güneşlenme Süresi	Saat	0	6,4	12,9
Güneşlenme Şiddeti	Cal/cm <sup>2</sup> .dak	4	328	645
00 Enversiyon Başl.	metre	0	560	7329
00 Enversiyon Kuvv.	°C/100m.	0	1,553	26,976
12 Enversiyon Başl	metre	0	1304	4915
12 Enversiyon Kuvv	°C/100m	0	1.031	8,829
SO <sub>2</sub> (günlük ortalama)	µgr/m <sup>3</sup>	10	203	1041



Şekil 4.17 1994 yılı içindeki günlük ortalama SO<sub>2</sub> verilerinin küçükten büyüğe sıralanmış hali



Şekil 4.18 Öğrenme seti SO<sub>2</sub> verileri (Test seti de grafiksel görünüm olarak aynı eğilimdedir)

Bu parametrelerle oluşturulan yapay sinir ağı modelinde giriş katmanı 14 nöronlu olarak sabitlenmiştir. Çıkış katmanı da SO<sub>2</sub> konsantrasyonunu temsil eden 1 nöronlu oluşmaktadır. Gizli katmanda kullanılan nöron sayısı değiştirilerek en uygun model bulunmaya çalışılmıştır. Oluşturulan YSA modelinin topolojik yapısı Şekil 4.19'da gösterilmektedir. Bu yapıda gizli katmandaki nöron sayısı değiştirilerek değişik YSA modellerinin performansları görülmüştür. Gizli katmandaki nöron sayısının yanı sıra katmanlar arası ağırlıkların başlangıç değerleri, öğrenme ve momentum katsayıları değiştirilerek en uygun ve genelleme kabiliyeti en yüksek

yapay sinir ağırları modeli ortaya konulmaya çalışılmıştır.

#### 4.4 Verilerin Normalizasyonu

Verilerin normalizasyonu girdi setindeki her bir parametrenin modelin tahmin işlemine eşit ölçüde katkıda bulunmasını sağlar. Eğer girdi parametreleri normalize edilmezse sayısal olarak düşük aralıklarda değişen bir parametrenin etkisi yine sayısal olarak daha geniş aralıklarda değişen bir başka girdi parametresine göre daha önemsiz kalacaktır. Mesela basıncın kendi değişim aralığında (998 mbar – 1032 mbar) ortalama değere göre azami değişim yüzdesi -1.6 ile 1.7 civarında iken sıcaklığın kendi değişim aralığında (0.2 °C – 28.6°C) ortalama değere göre azami değişim yüzdesi -98 ile 86 civarındadır. Bu farklılıkları ortadan kaldırmak ve her bir parametrenin modele eşit katkıda bulunmasını sağlamak için veri setindeki bütün parametreler kendi değişim aralıklarında normalize edilir. Denklem (4.1) tipik bir normalizasyon denklemidir (Gardner et.al. 1999).

$$x_{\text{norm}} = 2 \left( \frac{(x - x_{\text{min}})}{x_{\text{max}} - x_{\text{min}}} \right) - 1 \quad (4.1)$$

Burada

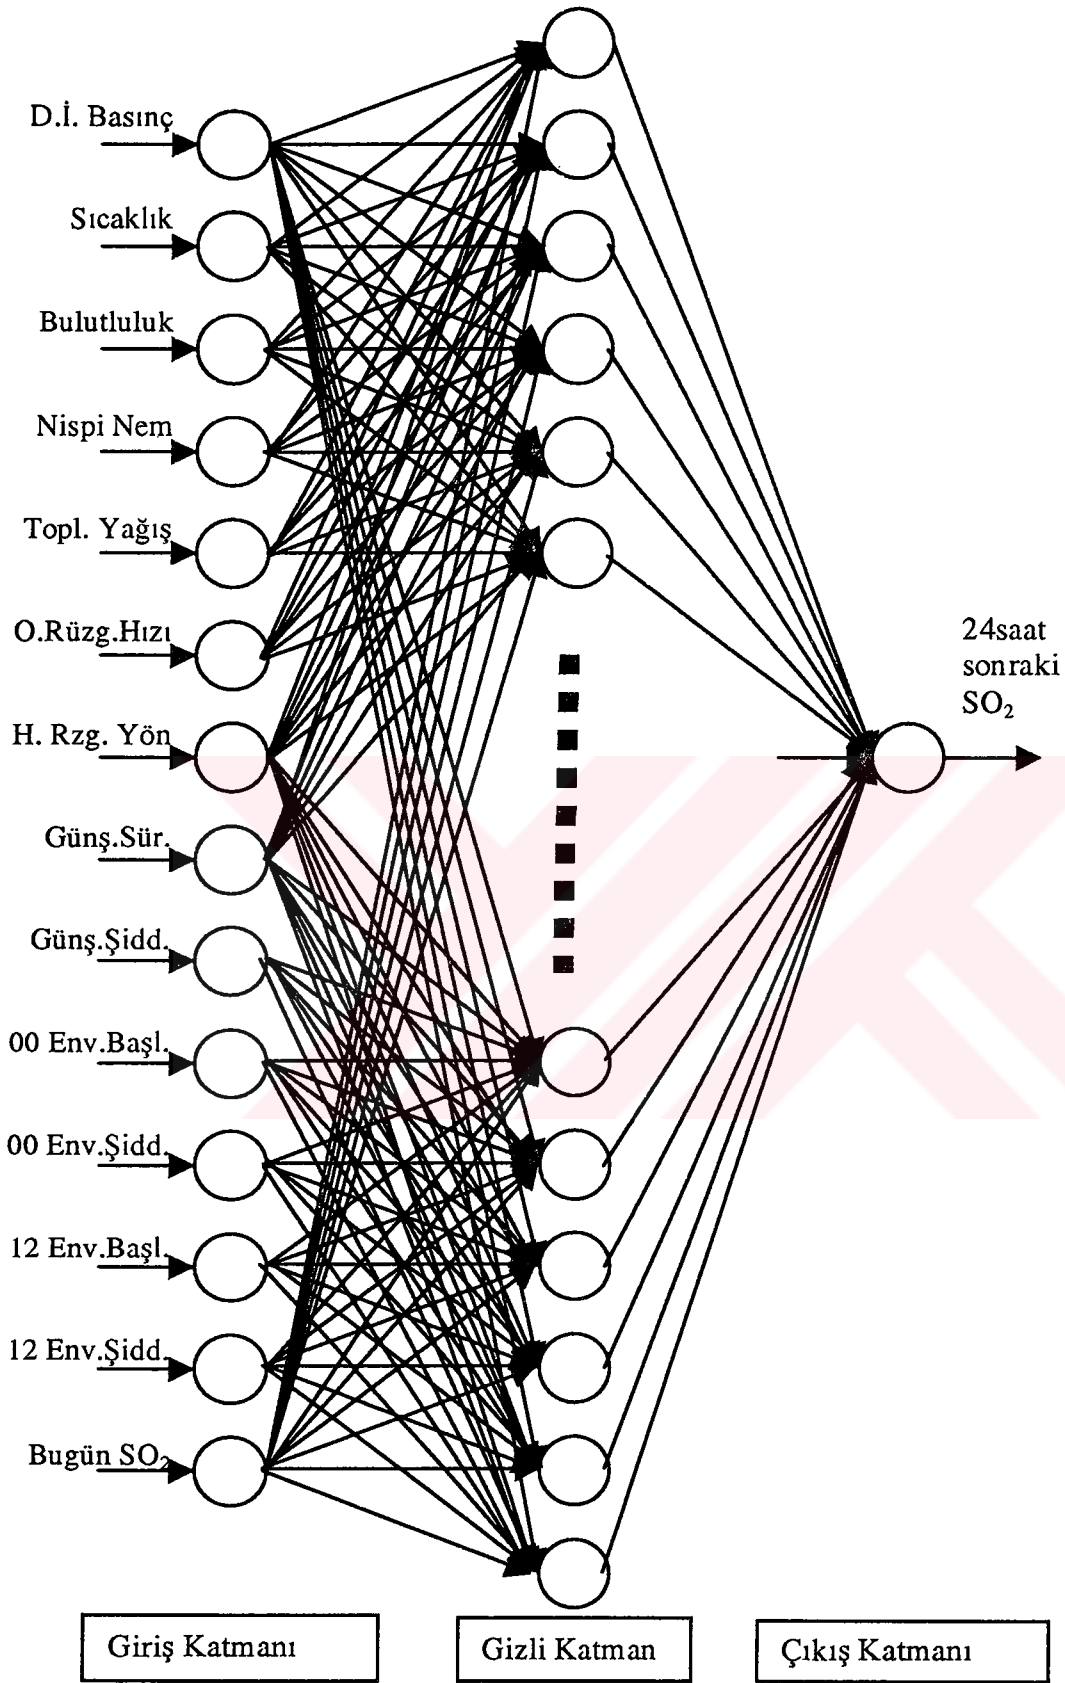
$x_{\text{norm}}$  : x verisinin normalize edilmiş hali

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

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

Model çıktısı veriler Denklem (4.2) ile orijinal durumlarına dönüştürülür.

$$x = \left( \frac{(x_{\text{norm}} + 1) \times (x_{\text{max}} - x_{\text{min}})}{2} \right) + x_{\text{min}} \quad (4.2)$$



Şekil 4.19 Kullanılan YSA modelinin topolojik yapısı (Şekil karmaşıklığı sebebiyle nöronların ve bağlantıların tamamı gösterilmemiştir).

## 5 SONUÇLAR VE ÖNERİLER

### 5.1 Model Performansını Ve Öğrenme Aşamasını Etkileyen Parametrelerin Durumu

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

Gizli katman sayısı ve bu katmanlardaki toplam nöron sayısı,

Nöronlarda kullanılan aktivasyon fonksiyonu,

Öğrenme ve momentum katsayıları,

Öğrenme algoritması,

Ağırlıkların başlangıç değerleri ve değişim aralıkları.

Atmosfer ortamı ve özellikle hava kirliliği modellenmesi ile ilgili olarak şimdiye kadar yapılan literatür çalışmalarında görülmüştür ki, aktivasyon fonksiyonu olarak sigmoid fonksiyonu atmosfer ortamının nonlineer yapısını karakterize edecek davranışa sahiptir (Boznar et.al.,1993, Gardner et.al.,1998). Yine ilgili literatürde 1'den fazla gizli katman kullanılması model için ilave bir genelleme kabiliyeti ortaya koymamaktadır. Aksine ezberleme eğiliminin artmasının yanı sıra çok uzun hesaplama zamanı gerektirmektedir. Ayrıca yapılan denemeler sonucunda görülmüştür ki gizli katmandaki nöron sayısı yeterince arttırıldığında model, öğrenme setini %100'e varan oranlarda doğrulukla tanıyabilmektedir. Çünkü modelde öğrenme setinin tamamını temsil edecek miktarda ağırlık katsayısı bulunmaktadır. Bir başka deyişle modelin ağırlık uzayı öğrenme setindeki bütün verileri temsil edecek genişlikte olmaktadır. Fakat böyle bir model çok düşük genelleme kabiliyetine sahip bir modeldir ve öğretilmediği değişik meteorolojik durumları, genelleme özelliği zayıf olduğu için doğru tahmin edememektedir.

Öğrenme katsayısının alacağı değer konusunda kesin bir kural olmayıp tamamen veri setinin yapısına bağlıdır. Mesela Boznar et.al.(1993) çalışmalarında öğrenme katsayısını 0.6 almışlardır. Kullandıkları veri seti incelendiğinde tüm periyot boyunca aşırı salınımlar olmadığı ve homojen artış ve azalışların olduğu görülmektedir. Bu çalışmada kullanılan veri seti incelendiğinde ise hemen hemen tüm parametrelerin günler bazında büyük salınımlar gösterdiği görülmektedir. Yapılan denemelerde 0.3'ten büyük öğrenme katsayılarının öğrenme aşamasında büyük salınımlar yaptığı ve bazı değerlerde lokal minimumlara takıldığı




görülmüştür. Daha küçük değerler ise öğrenme zamanını aşırı uzatmıştır. En ideal değer olarak (bu veri seti için) 0.2 katsayısı kullanılmıştır.

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

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

## 5.2 Doğrulama Eğitme İle Denenen Çeşitli Modellerin Performansları

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



Şekil 5.1 Doğrulama eğitmede en iyi model noktası

Şekil 5.1'de görüldüğü gibi öğrenme esnasında öğrenme seti hatası sıfıra yaklaşırken doğrulama seti hatası belli bir noktaya kadar azalır daha sonra artmaya başlar. Bu noktaya kadar model tüm veri seti üzerinde (öğrenme + test + doğrulama) bir genelleme kabiliyeti kazanmış olmaktadır. Bu noktadan sonra ise model tamamen öğrenme seti üzerinde yoğunlaştığı için doğrulama setinin hatası artmaya başlar. Tüm veri setinin öğrenme, test ve doğrulama olarak 3 parçaya bölünme şekli, verilerin hassasiyeti (ölçüm hataları), girdi parametrelerinin çıktı parametresi üzerindeki etkileri yanında gizli katmandaki nöron sayısı da en iyi model noktasındaki hata miktarının büyüklüğüne etki etmektedir.


En iyi model noktasından bağımsız olarak modelin eğitime işlemi devam ettirilebilir. Nitekim bu çalışmada 0.05 ortalama karesel hata miktarına kadar eğitime işlemleri devam ettirilmiş ve en iyi model noktası ile karşılaştırma yapılmıştır.

### 5.3 Verilerde Sınıf Eşitlemesinin Model Performansı Üzerindeki Etkileri


Kullanılan veri seti incelendiğinde (Şekil 4.2) Nisan – Kasım ayları boyunca kirlilik parametresinin dar bir aralıkta değişim gösterdiği ve bu periyodun tüm periyot içinde geniş bir aralık kapladığı görülmektedir. Kış aylarını kapsayan periyotla kıyaslandığında SO<sub>2</sub> değerlerinin bu aralıkta hemen hemen sabit kaldığı düşünülebilir. Girdi parametrelerinin aynı aralıktaki değişim çeşitliliği de incelendiğinde SO<sub>2</sub>'nin yaz aylarındaki düşük değerlerinin çok çeşitli girdi kombinasyonlarında ifade edildiği görülmektedir. Bu da modelin bu düşük değerleri daha iyi tanıyabilmesine imkan vermektedir.

Diğer taraftan kış aylarındaki SO<sub>2</sub> değişimi hem değer olarak çok geniş aralıkta olmakta ve hem de bu değişimler zaman periyodu içinde az sayıda tekerrür etmektedir. Mesela 1041 µgr/m<sup>3</sup> kirlilik değeri sadece bir kere oluşmuştur. Dolayısıyla modelin bu gibi değerleri öğrenmesi çok tekrar eden düşük değerlere kıyasla daha az hassas olmaktadır.

Bu noktada az tekerrür eden verilere karşı modelin performansını arttırmak için sınıf eşitlemesi (class equalization) işlemi uygulanmıştır. 1041 µgr/m<sup>3</sup> gibi az tekrar eden veriler belli sayıda (bu çalışmada 10 kere) çoğaltılarak öğrenme veri setine katıldı (Şekil 5.2 ve Şekil 5.3). Bu şekilde modelin bu verileri daha çok görmesi ve daha iyi tanınması sağlandı. Bu işlem suni bir işlem olup tekrar eden verilerin arkasındaki girdi parametreleri seti tamamen aynı olduğu için gerçek durumlar gibi olmamaktadır. Daha çok, sınıflandırma (classification) yapan yapay sinir ağları modellerinde kullanılmasına rağmen buradaki uygulamada model performansını artırıcı yönde etki göstermiştir.




Şekil 5.2 Normal öğrenme seti SO<sub>2</sub> konsantrasyonları.




Şekil 5.3 Sınıf eşitlemesi yapılmış öğrenme seti SO<sub>2</sub> konsantrasyonları.

#### 5.4 Veri Setleri Sınıflandırmasının Model Performansı Üzerindeki Etkileri


Gizli katman nöron sayısı 25 ile 50 arasında çeşitli aralıklarla değiştirilerek yapay sinir ağı modelleri oluşturuldu. Öğrenme ve test setleri verileri, yukarıda ifade edilen iki tekniğin birlikte ve ayrı ayrı kullanımları bu modellerde çalıştırıldı. Zaman sıralı veri setleri ile eğitilen ve test edilen modellerin gizli katman nöron sayısına göre hata performansları Şekil 5.4'te, yine aynı modellerin değer sıralı veri setleri ile ortaya çıkan sonuçları da Şekil 5.5'te gösterilmiştir. Bu iki şekil incelendiğinde öğrenme verilerine uygulanan sınıf eşitlemesi işleminin, hem zaman sıralı ve hem de değer sıralı veri setleri ile yapılan eğitme ve test



Şekil 5.4 Gizli katman nöron sayısının çeşitli tekniklerle eğitilen modellerin performanslarına etkisi (Zaman sıralı veri seti ile çalıştırılan modellerin sonuçları) E: en iyi model noktası, 0.05: global minimum noktası, S: verilerde sınıf eşitlemesi işlemi uygulandı.



Şekil 5.5 Gizli katman nöron sayısının çeşitli tekniklerle eğitilen modellerin performanslarına etkisi (Değer sıralı veri seti ile çalıştırılan modellerin sonuçları) E: en iyi model noktası, 0.05: global minimum noktası, S: verilerde sınıf eşitlemesi işlemi uygulandı.



Şekil 5.6 Zaman ve değer sıralamalı veri setlerinin model performansına etkileri. E: en iyi model noktası, 0.05: global minimum noktası, S: verilerde sınıf eşitlemesi işlemi uygulandı, ZS: zaman sıralamalı veri seti, DS: değer sıralamalı veri seti.

işlemlerinde hata miktarını oldukça düşürdüğü gözlenmiştir. Şekil 5.6'da da zaman ve değer sıralamalı veri setlerinin performans karşılaştırması yapılmıştır. Şekil 5.6 incelendiğinde, değer sıralamalı veri setlerinin 0.05 hata noktasında daha iyi sonuçlar verdiği, buna mukabil zaman sıralamalı verilerin ise en iyi model noktasında daha iyi sonuçlar verdiği görülmektedir.

Örnekleme olması bakımından 35 gizli katman nöronlu modelin öğrenme ve test çıktıları ile ölçülen  $SO_2$  değerlerinin karşılaştırmalı grafikleri Şekil 5.7 ile Şekil 5.22 arasındaki grafiklerde verilmiştir. Bütün modellerin öğrenme aşaması kıyaslama yapabilmek amacıyla 0.05 hata miktarında bitirilmiştir.

Elde edilen bütün grafikler incelendiğinde aşağıdaki sonuçlar ortaya çıkmaktadır.

1. Yapay sinir ağları modelleri hava kirliliği tahminlerinde eldeki verinin kalitesi ve miktarına bağlı olarak oldukça iyi sonuçlar verebilmektedir. Veriler (patern sayısı) ne kadar çoksa model o kadar fazla durumu öğrenebilmekte dolayısıyla genelleme kabiliyeti o kadar fazla olmaktadır. Test seti sonuçlarını gösteren grafikler incelendiğinde  $SO_2$ 'in kış aylarındaki yüksek değerlerden ilkbahar ve yaz aylarına doğru düşüş eğilimi ve yine kış aylarına doğru yükseliş eğilimi yapay sinir ağları modeli ile oldukça iyi temsil edilebilmektedir.

2. Verilerin miktarının yanında kullanılan girdi ve çıktı parametrelerinin kendi oluşum aralıklarındaki değer çeşitlilikleri de ne kadar fazla ise modelin bu çeşitlilikleri öğrenebilme kabiliyeti de o derece iyi olmaktadır. Yani model o kadar çok hava kirliliği durumu öğrenebilmektedir. Mesela  $100 \mu\text{gr}/\text{m}^3$   $\text{SO}_2$  kirlilik seviyesini oluşturan ne kadar çok çeşitli meteorolojik durum varsa ve bu durumlar veri setinde patern olarak ne kadar çok temsil edilmişse modelin bu çıktı değerini o kadar iyi öğrenmesi söz konusudur. Yani model her türlü meteorolojik şartlarda oluşan  $100 \mu\text{gr}/\text{m}^3$   $\text{SO}_2$  kirlilik seviyesin kendisine tanıtıldığı ölçüde çok yönlü tanıyacaktır. Yine test sonuçlarını gösteren grafikler incelendiğinde  $\text{SO}_2$  seviyesinin düşük olduğu ilkbahar ve yaz aylarındaki oluşumlar genelde düşük ve bu sezon boyunca çok küçük salınımlar dahilinde sabit kaldığı için model bu aralıktaki  $\text{SO}_2$  seviyelerini herhangi bir sabit değermiş gibi çok geniş ve çeşitli girdi parametreleri aralığında tanımlayıp algıladığı için bu aylardaki tahmin kabiliyeti oldukça yüksek olmaktadır. Bu durumun aksi olarak kış aylarındaki  $\text{SO}_2$  seviyelerinde oldukça çok miktarda ve büyüklükte salınımlar olduğu ve bu salınımların her biri ayrı birer durum olarak ortaya çıktığı için bu çeşitli durumlar kendi başlarına veri seti içinde patern olarak çok fazla temsil edilememektedir. Dolayısıyla modelin bu durumları çok iyi algılayıp öğrenme şansı da olmamaktadır. Bunun sonucu olarak ilk duruma göre tahmin kabiliyeti düşük olmaktadır. Bu noktada suni bir iyileştirme metodu olan sınıf eşitlemesi yöntemi model performansını artırıcı yönde etki göstermektedir.
3. Bu çalışmada kullanılan veri seti ile elde edilen sonuçlar her ne kadar 35 gizli katman nöronlu YSA modelleri üzerinde yoğunlaşmış ise de bu sonuçlar kullanılan veri setine bağlı olarak değişebilir. Daha büyük veri seti (hem günlük veri sayısı ve hem de girdi parametreleri sayısı olarak) kullanıldığında en uygun model daha çok gizli katman nöronlu olabilir. Gizli katman nöron sayısı ayrıca parametrelerin kendi değişim aralıklarındaki sayısal çeşitliliklerine bağlı olarak ta değişmektedir. Çok fazla sayısal çeşitlilik gösteren parametrelerin model içinde yeterince temsil edilebilmeleri gizli katman nöron sayısına bağlıdır.

## 5.5 Öneriler


Yapay sinir ağlarının hava kirliliği modellemesinde oldukça başarılı sonuçlar verdiği ortadadır. Burada en önemli husus veri tabanıdır. Veri tabanı ne kadar geniş ve çeşitli ise modelin genelleme kabiliyeti de o kadar iyi olmaktadır. Sadece meteorolojik parametreler kullanılarak yapılan modelleme çalışmasında istatistiksel olarak oldukça başarılı sonuçlar elde

edilmiştir. Klasik istatistiksel ve fonksiyonel modelleme tekniklerinde olduğu gibi hiçbir on şart gereksinimi olmadan ağ modellerinin çeşitli durumları iteratif yöntemlerle birkaç parametre kullanılarak sınanmakta ve en uygun (genellme kabiliyeti en yüksek) model ortaya çıkmaktadır. Veri tabanının miktar ve kalite bazında genişletilmesi yanında diğer meteoroloji ve kirlenici parametrelerinin modele dahil edilmesiyle çok daha iyi sonuçlar alınabilir. İstanbul'da kullanılan kömür, fuel oil, doğalgaz gibi yakıtların günlük kullanım miktarlarının yanı sıra motorlu taşıtların durumu da hava kirliliğini etkileyen parametreler arasındadır. Bu parametrelerin de modele katılmasıyla kirliliğin kaynak bazındaki etkileri de ele alınmış olur ve daha hassas sonuçlar elde edilebilir.

SO<sub>2</sub> parametresinin İstanbul genelindeki ölçüm istasyonlarının verilerinin yanında Göztepe istasyonu dışında İstanbul'daki diğer meteorolojik ölçüm istasyonlarındaki parametreler de çalışmaya dahil edilebilir. Model veri miktarı ve parametre sayısı bakımından ne kadar geniş tabanlı olursa verdiği sonuçlar da o kadar güvenilir olur. Ancak yapay sinir ağları ile çalışmanın en büyük zorluğu yüksek hesap kapasitesine ihtiyaç duyulmasıdır. Bu çalışma esnasında yapılan bazı eğitime iterasyonlarının (100 gizli katman nöronlu modelde) sonuca ulaşması Pentium II 233MHz işlemciyle bazen 30 saati bulmuştur. Modele ilave edilecek her parametre, her veri paterni, her nöron modelin hesap külfetini arttırmakta bu da sonuca ulaşma zamanını uzatmaktadır. Çizelge 5.1 bu çalışmada kullanılan modellerin bağlantı sayılarını, dolayısıyla ağırlık uzayının büyüklüğünü göstermektedir. Yukarıda önerilen şekilde kurulacak ağ modellerinin çalıştırılması için çok daha yüksek kapasiteli bilgisayarlara (mesela paralel bilgisayarlar veya iş istasyonları) ihtiyaç olacaktır.


Çizelge 5.1 Model yapısına bağlı olarak modelin ihtiva ettiği ağırlık katsayısı adedi

Model yapısı	Modeldeki ağırlık katsayıları adedi
14-25-1	375
14-30-1	450
14-35-1	525
14-40-1	600
14-45-1	675
14-50-1	750
14-100-1	1500




Şekil 5. 7 14-35-1 YSA modelinin eğitime aşaması sonuçları (Hata=0.05, zaman sıralamalı eğitime seti, sınıf eşitlemesi yok)







Şekil 5. 8 14-35-1 YSA modelinin eğitime aşaması en iyi model sonuçları (Hata=0.666, zaman sıralamalı eğitime seti, sınıf eşitlemesi yok)




Şekil 5.9 14-35-1 YSA modelinin eğitim aşaması sonuçları (Hata=0.05, zaman sıralamalı eğitim seti, sınıf eşitlemesi yapıldı)




Şekil 5. 10 14-35-1 YSA modelinin eğitime aşaması en iyi model sonuçları (Hata=0.541, zaman sıralamalı eğitime seti, sınıf eşitlemesi yapıldı)




Şekil 5.11 14-35-1 YSA modelinin eğitime aşaması sonuçları (Hata=0.05, değer sıralama eğitme seti, sınıf eşitlemesi yok)




Şekil 5. 12 14-35-1 YSA modelinin eğitime aşaması en iyi model sonuçları (Hata=0.415, değer sıralamalı eğitime seti, sınıf eşitlemesi yok)



Şekil 5.13 14-35-1 YSA modelinin eğitime aşaması sonuçları (Hata=0.05, değer sıralamalı eğitime seti, sınıf eşitlemesi yapıldı)



Şekil 5. 14 14-35-1 YSA modelinin eğitime aşaması en iyi model sonuçları (Hata=0.333, değer sıralamalı eğitime seti, sınıf eşitlemesi yapıldı)




Şekil 5. 15 14-35-1 YSA modelinin test aşaması sonuçları (Hata=1.171, zaman sıralamalı eğitime seti, sınıf eşitlemesi yok)







Şekil 5.16 14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.609, zaman sıralamalı eğitme seti, sınıf eşitlemesi yok)




Şekil 5. 17 14-35-1 YSA modelinin test aşaması sonuçları (Hata=1.091, zaman sıralamalı eğitime seti, sınıf eşitlemesi yapıldı)




Şekil 5. 18 14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.482, zaman sıralamalı eğitim seti, sınıf eşitlemesi yapıldı)




Şekil 5.19 14-35-1 YSA modelinin test aşaması sonuçları (Hata=0.967, değer sıralamalı eğitim seti, sınıf eşitlemesi yok)



Şekil 5. 20 14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.668, değer sıralamalı eğitim seti, sınıf eşitlemesi yok)



Şekil 5.21 14-35-1 YSA modelinin test aşaması sonuçları (Hata=0.934, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı)



Şekil 5. 22 14-35-1 YSA modelinin test aşaması en iyi model sonuçları (Hata=0.604, değer sıralamalı eğitme seti, sınıf eşitlemesi yapıldı)

## KAYNAKLAR

Aviolat F., Cornu T., and Cattani D., (1998), "Automatic Clouds Observation Improved by an Artificial Neural Network", *J. Of Atmospheric and Oceanic Technology*, Vol15, pp.114-126.

Ayalp A., (1976), "İstanbul'da Atmosfer Kirlenmesi", Doktora Tezi, İstanbul Üniversitesi.

Borat O., Kadı İ., Uslu M., (1990), "İstanbul'da Emisyon Kaynaklarının Öncelikleri ve Motorlu Taşıt Emisyonlarının Kontrolü", İstanbul'un Çevre Sorunları ve Çözümleri Sempozyumu, 9-13 Nisan, İTÜ.

Boznar M., (1997), "Pattern Selection Strategies for a Neural Network – Based Short Term Air Pollution Prediction Model", *Proceedings on Intelligent Information Systems, IIS'97*, IEEE Computer Society, 0-8186-8216-3, pp.340-344.

Boznar M., Lesjak M., and Mlakar P., (1993), "A Neural Network Based Method for Short Term Predictions of Ambient SO<sub>2</sub> Concentrations in Highly Polluted Industrial Areas of Complex Terrain", *Atm. Env.*, Vol.27B, No.2, pp.221-230.

Boznar M., Mlakar P., (1995), "Neural Networks – A New Mathematical Tool for Air Pollution Modelling", *Air pollution III Volume 1. Air Pollution Theory and Simulation*, Computational Mechanics Publications, pp. 259-266, Southampton Boston.

Clair T.A., Ehrman J.M., (1998), "Using Neural Networks to Assess the Influence of Changing Seasonal Climates in Modifying Discharge, Dissolved Organic Carbon, and Nitrogen Export in Eastern Canadian Rivers", *Water Resources Research*, Vol.34, pp.447-455, March.

Comrie A.C., (1997), "Comparing Neural Networks and Regression Models for Ozone Forecasting", *J. Of the Air and Waste Management Assoc.*, Vol. 47, pp.653-663, June.

Çataltaş İ., (1969), "Kartal'da Endüstriyel Hava Kirlenmesi", *İTÜ Bülteni*, NO.22, Sayfa 24-42

DİE, (1998), Devlet İstatistik Enstitüsü, İnternet kanalıyla elde edilen hava kirliliği verileri

DMİ, (1998), Devlet Meteoroloji İleri Genel Müdürlüğü, İnternet kanalıyla elde edilen meteoroloji verileri.

Ertürk F., (1981), "İstanbul'un Haliç Bölgesinde Hava Kirlenmesinin Matematik Modelle İncelenmesi", Doçentlik Tezi, İTÜ.

Ertürk F., (1986), "Investigation of Strategies for the Control of Air Pollution in the Golden



Horn Region, İstanbul, Using a Simple Dispersion Model", Environmental Pollution (Series B), Vol. 11, pp.161-168.

Ertürk F., Karaca M., Tayanç M., Saral A., (1995), "İstanbul'da Hava Kirliliği Haritasının Çıkarılması ve Doğalgaz Kullanımına Öncelik Verilecek Bölgelerin Tespiti", Araştırma Projesi, İstanbul Büyükşehir Belediyesi, Çevre Koruma ve Geliştirme Daire Başkanlığı.

Gardner M.W., Dorling S.R., (1998), "Artificial Neural Networks (The Multi Layer Perceptron) – A Review of Applications in the Atmospheric Sciences", Atm. Env., Vol.32, No.14/15., pp.2627-2636.

Gardner M.W., Dorling S.R., (1999), "Neural Network Modelling and Prediction of Hourly NO<sub>x</sub> and NO<sub>2</sub> Concentrations in Urban Air in London", Atm. Env., Vol.33, pp.709-719.

Gutierrez, Wang, J. ve Grandin, R.D., (1989), "Estimating Hidden Units for Two Layer Perceptrons", Proceeding of the 1<sup>st</sup>. International Conference on Artificial Neural Networks, London, U.K.

Hebb, O., (1949), The Organization of Behavior, John-Wiley, New York.

İncecik S., (1986), "Hava Kirliliğinin Meteorolojik Parametrelerinin Analizi İle İlgili Bir Uygulama", Çevre, Sayı 1, Sayfa 15-21.

İşli İ., (1990), "Statistical Analyses of Air Pollution and Meteorological Data in İstanbul", Doktora Tezi, Boğaziçi Üniversitesi.

Lippman, R. P., (1987), "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, April, 4-22.

Mlakar P., (1997), "Determination of Features For Air Pollution Forecasting Models", Proceedings on Intelligent Information Systems, IIS'97, IEEE Computer Society, 0-8186-8218-3, pp.350-354.

Mlakar P., Boznar M., (1994), "Short Term Air Pollution Prediction on the Basis of Artificial Neural Networks" Air Pollution II Volume 1:Computer Simulation, Computational Mechanics Publications, pp.545-552, Southampton Boston.

Mlakar P., Boznar M., (1996), "Analysis of Winds and SO<sub>2</sub> Concentrations in Complex Terrain", Air Pollution IV: Monitoring, Simulation and Control, Computational Mechanics Publications, pp. 455-464.

Mlakar P., Boznar M., (1997), "Perceptron Neural network – Based Model predicts Air pollution", Proceedings on Intelligent Information Systems, IIS'97, IEEE Computer Society, 0-8186-8218-3, pp.345-349.

Mlakar P., Boznar M., Lesjak M., (1994), "Neural Networks Predict Pollution", Air Pollution Modelling and Its Application X, Plenum Press, pp.659-660, New York.

Öztürk M., (1983), "Şehiriçi Yollarda Taşıtlardan İleri Gelen Karbonmonoksit Kirliliğinin İncelenmesi", Doktora Tezi, İTÜ.

Perantonis S.J., Vassilas N., Amanatidis G.T., et. al., (1994), "Neural Network Techniques for SO<sub>2</sub> Episode Prediction", Air Pollution Modelling and Its Application X, Plenum Press, pp.305-313, New York.

Potukuchi S., Wexler A.S., (1997), "Predicting Vapor Pressures Using Neural Networks", Atm. Env. Vol.31, No.5, pp.741-753.

Reich S.L., Gomez D.R., Dawidowski L.E., (1999), "Artificial Neural Networks For the Identification of Unknown Air Pollution Sources", Atm.Env., 33, pp.3045-3052.

Rumelhart D.E. and McClelland J.L., (1986), Parallel Distributed Processing, 1,2. MIT Press, Cambridge, MA.

Saral, A., (1995), İstanbul'un Hava Kirliliği Haritasının Çıkarılması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, F.B.E., İstanbul

Songar A., (1985), Beynimiz ve Sinirlerimiz, Yeni Asya Yayınevi, İstanbul

Stern A.C.,(1976), "Air Pollution", Volume I (Air Pollutants, Their Transformation and Transport", Academic Press Inc., New York.

Tebbens B.D., (1970), "Investigating Air Quality in İstanbul", İTÜ Bülteni, Cilt 22, Sayı 2, Sayfa 55-63.

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

**ÖZGEÇMİŞ**

Doğum tarihi	6.9.1969	
Doğum yeri	Trabzon	
Lise	1983-1986	Bakırköy Endüstri Meslek Lisesi, Elektronik Bölümü
Lisans	1986-1992	Boğaziçi Üniv. Mühendislik Fak. Kimya Mühendisliği Bölümü
Yüksek Lisans	1993-1995	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Çevre Müh. Anabilim Dalı, Çevre Müh. Programı
Doktora	1995-1999	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Çevre Müh. Anabilim Dalı, Çevre Müh. Programı
<b>Çalıştığı kurum</b>	1992-Devam ediyor YTÜ İnşaat Fakültesi, Araştırma Görevlisi	

