

SİVAS İLİNDE YAPAY SİNİR AĞLARI İLE HAVA KALİTESİ MODELİNİN OLUŞTURULMASI ÜZERİNE BİR UYGULAMA

Ahmet Gürkan YÜKSEK*, Hüdaverdi BİRCAN**, Metin ZONTUL***
ve Oğuz KAYNAR****

Özet

Hava kirliliği, yoğun araç trafiği, şehirselleşme ve artan ticari ve endüstriyel aktiviteler sebebiyle büyüyen bir problemdir. Sağlık açısından, kentsel bölgelerdeki hava kalitesi parametrelerini takip etmek ve tahmin etmek önemlidir. Yapay Sinir Ağları teknikleri karışık ve doğrusal olmayan modellerde çok başarılıdır. Bu çalışmada Geri Yayılımlı Yapay Sinir Ağları modeli kullanılarak, SO₂ kirlilik seviyesi üzerindeki meteorolojik ve diğer kirlilik parametrelerinin, kentsel bölgedeki etkisi incelenmiştir. Tahmin modelinin performansı 84-88 % değerleri arasında kullanılan modele göre başarı sağlanmıştır.

Anahtar kelimeler: Yapay Sinir Ağları, Geri yayılma Sinir Ağları, Hava Kalitesi Modeli.

An Application of Neural Networks Applied on Whether Quality of Sivas

Abstract

Air pollution is a growing problem arising from domestic heating, high density of vehicle traffic, and expanding commercial and industrial activities. Monitoring and forecasting of air quality parameters in the urban area are important due to health impact. Artificial intelligent techniques are successfully used in modelling of highly complex and non-linear phenomena. In this study, backpropagation neural network model has been proposed to estimate the impact of meteorological factors on SO₂ pollution levels over an urban area. The model forecasts satisfactorily the trends in SO₂ concentration levels, with performance 84-88%.

Key Words: SO₂ pollution, Neural Networks, Backpropagation Neural Networks, Air Quality Model.

* Cumhuriyet Üniversitesi, SMYO, Bilgisayar Prog., Sivas

** Cumhuriyet Üniversitesi, İİB Fakültesi, İşletme Böl., Sivas

*** Anadolu Bil Meslek Yüksekokulu., Bil Prog., Sivas

**** Cumhuriyet Üniversitesi, SMYO, Bilgisayar Prog., Sivas

Giriş

Yapay sinir ağları, insan beynindeki sinir hücrelerinin (nöron) bilgisayar ortamında matematiksel ve grafiksel bir modellemesidir. Yapay sinir ağlarında kullanılan öğrenme algoritmaları da klasik bilgisayar algoritmalarından farklıdır. Bu algoritmalar insan beyninin sezgisel gücünü içinde taşırlar. Bu sebeple, birçok bilim dalı yapay sinir ağları ile ilgilenmektedir. Genellikle, yapay sinir ağları ile oluşturulan modeller istatistiksel veri analizi veya sistem optimizasyonu için kullanılmaktadır. Özellikle regresyon ve diğer klasik yöntemlerin yoğunlukla kullanıldığı tahmin ve sınıflandırma problemlerinde yoğun şekilde tercih edilmektedirler (Warner & Misra 1996) .

1980'lerin ortalarından itibaren istatistik bilim adamları yapay sinir ağlarıyla ilgilenmeye başlamışlardır. White (1989) yapay sinir ağlarında kullanılan öğrenme algoritmaları ile klasik istatistiksel yöntemlerdeki matematiksel modellerin birbirine benzerlik gösterdiğini ispatlamıştır. Cheng ve Titterington (1994) bir çalışmada istatistiksel açıdan yapay sinir ağlarını incelemiştir. Amaçları istatistikçileri bu konuda bilgilendirmektir. Bu araştırmacılar, yapay sinir ağları ile istatistiksel yöntemlerin birbirine alternatif gibi gözükmeye rağmen aslında aynı temaların farklı isimler altında işlendiğini, bir nörobilimcinin ne kadar istatistiksel bilgiye ihtiyacı varsa o ölçüde de bir istatistikçinin yapay sinir ağları bilgisine ihtiyacı olduğunu belirtmektedir. Sarle (1994) birçok yapay sinir ağı modelinin istatistiksel yöntemlere uygunluk gösterdiğini belirtmiştir. Gizli katmansız ileri beslemeli ağlar lineer modellere, bir gizli katmanlı ileri beslemeli ağlar lineer olmayan regresyon modellerine, Hebbian öğrenme temel bileşenler analizine ve Kohonen SOM ağları kümeleme analizine karşılık gelmektedir. Kay ve Titterington (1999) istatistik ve yapay sinir ağlarının kesişiminde yapılan birçok çalışmayı bir kitap haline getirmişlerdir. Bu çalışmalarda, çok değişkenli istatistikte kullanılan birçok metot yerine yapay sinir ağları kullanılmıştır.

Yapay Sinir ağları yaklaşımının klasik istatistiksel yöntemlere göre avantajı, verilerin dağılım varsayımları ile değişkenlerle ilgili varsayımlara gereksinim duymamasıdır. Yapay sinir ağları, bazı değişkenlere ait eksik verileri de tolare etme özelliğine sahiptir. Ancak, yapay sinir ağlarının eğitimleri esnasında ki veri sayısına bağımlılıkları, yani performanslarının veri oranıyla yükselmesi (Warner & Misra, 1996) ve ağ modelinin kurulmasındaki güçlükler dezavantaj olarak görülebilir (Öztemel 2003,).

Yapay sinir ağlarının istatistiksel uygulamalarına bakıldığında genellikle "Geri Yayılım (Back-Propagation)" ve "SOM (Self-Organizing Maps)" öğrenme algoritmalarının kullanıldığı görülür. Bunlardan ilki, ileri beslemeli çok katmanlı ağ modellerinde, sonraki ise ileri beslemeli tek katmanlı ağ modellerinde kullanılmaktadır. Geri yayılım algoritmasını kullanan ağlar genellikle doğrusal olmayan regresyon problemleri için kullanılmaktadır. Diskriminant analizi gibi

bazı sınıflama yöntemleri de regresyon modeli ile ifade edilebilir. Geri yayılım algoritması bir denetimli öğrenme (Supervised Learning) algoritmasıdır. Ağın eğitilmesinde kullanılacak veriler bağımlı ve bağımsız değişkenleri içermelidir. Verilerin bir kısmı ağın eğitimi için bir kısmı da eğitilen ağın testi için kullanılır. Test işleminde bağımsız değişkenlerden oluşan veriler sinir ağına girildiğinde elde edilen değerler eldeki bağımlı değişkenlerle yaklaşık aynı değeri veriyorsa ağ doğru eğitilmiş demektir (Patterson 1996).

Genelleştirilmiş delta kuralı olarak da bilinen ve Widrow-Hoff (En küçük Kareler Yöntemi) öğrenme kuralının çok katmanlı ağlar için genelleştirilmesinden oluşturulan “Geri Yayılım Öğrenme Algoritması (Backpropagation) doğası içerisinde temel olarak iki basamak içermektedir. İlk basamak da; giriş verileri giriş katmanları, gizli katmanlar, çıkış katmanları ve tüm bu katmanların arasında var olan bağlantılar aracılığı ile her bir çıkış ünitesi için ağ çıkış değerini hesaplamak üzere ağı yayılır . Hesaplanan bu çıkış değerleri, asıl çıkış değerleri ile karşılaştırılarak her bir çıkış hücresi için hata değeri bulunur . İkinci basamak da ise; bulunan bu hata değerleri ağı ters yönde sunularak gerekli ağırlık değişimleri hesaplanır. (kalin network kitabı)


Çevresel kirlilik modelleri üzerinde (Bonzer et al. 1991) gerçekleştirilen ilk uygulamalarından itibaren Yapay Sinir Ağları, hedeflenen amaçlara ulaşılma konusunda güvenilir yöntem olmuştur. Yapay Sinir Ağı modelleri, değişen zaman aralıklarında kirlleticiler ve konsantrasyonlarının tahmin edilmesinde çok başarılı sonuçlar vermiştir (Comrie,1997; Gardner ve Dorling 199; Hadjiiski ve Hopke, 2000; Kolehmainen et al., 2001). Yapay Sinir Ağlarının performanslarını belirlemek için gerçekleştirilen birçok uygulama sonucunda, klasik istatistiksel yöntemlere göre çok başarılı sonuçlar alındığı sergilenmiştir (Yi ve Prybutok, 1996; Gardner ve Dorling, 2000; Chalouklakou et al., 2003b).

K.M. Mok , S.C. Tam, 1998 yaptıkları çalışmada, var olan veriler üzerinde kısa dönemlerde atmosferdeki SO₂ konsantrasyonu nu belirlemek üzere kurulan Yapay sinir ağları algoritmasından elde edilen sonuçların, çok sınırlı veri gruplarından elde edilmesine rağmen çok başarılı modeller ortaya koymuşlardır. Daha sonraki dönemlerde yapılan çalışmalarda ise atmosferik şartların (rüzgar yönü, hızı, hava sıcaklığı v.s.) modellerin başarıları üzerinde önemli etkenler olduğu gözlenmiştir (K.M. Mok , S.C. Tam, 1998). Atmosfer içerisindeki SO₂ konsantrasyonların tahminleri üzerinde birçok araştırmacı Yapay Sinir Ağları Modellerini başarı ile uygulamışlardır (Boznar et al., 1993; Mlakar and Boznar,1997; Reich et al., 1999; Andretta et al.,000; Perez, 2001; Chelani et al., 2002).

1.Yöntem

1.1. Yapay Sinir Ağları Yaklaşımı

Yapay zeka (artificial intelligence) kavramı ile insanın en önemli özellikleri olan düşünebilme ve öğrenebilme yetenekleri en önemli araştırma konuları durumuna gelmiştir. Özellikle son zamanlarda bilgisayar kullanımının hızla yaygınlaşması sonucunda yapay zeka çalışmaları da bir ivme kazanmıştır (Yurtoğlu, 2005:12). Doğrusal olmayan (non-lineer) eşitsizliklerde Yapay Sinir ağları evrensel bir yaklaşım olmuştur (Hornik at al, 1989), sonuç olarak atmosferik şartlar gibi çok karmaşık doğrusal olmayan yapılar üzerinde de başarılı bir şekilde kullanılmaktadır.



Şekil 1.1. Temel Yapay Zeka Nöron Modeli

Geril Yayılım Algoritması (Backpropagation) çok katmanlı, geri beslemeli ve danışmanlı öğrenme yapısına sahip ve birçok uygulamalarda kullanılmış en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geril yayılım ismini almıştır. Geril yayılım öğrenme algoritması kullanarak eğitilen ağlar üzerinde meydana gelen üç temel işlem vardır: eğitim giriş verileri ileri yönde (feedforward) ağı sunulur, hata hesaplanarak ağ üzerinde geril yayılır ve ağırlıklar yeniden düzenlenir. Tipik çok katlı geril yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Gizli tabakaların sayısında teorik olarak bir sınırlama yoktur. Geril yayılım algoritması, sinir ağının denetimli sınıfına giren genel bir algoritmadır. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata yani $e(t)$, arzu edilen çıkış $t(t)$ ile sinir ağının çıkışı $y(t)$ arasındaki farktır.

$$e(t) = t(t) - y(k) ; t=1, \dots, m$$

Eşitlik 1

Backpropagation öğrenme algoritmasının temel yapısı, zincir kuralı kullanılarak, ağ üzerindeki tüm ağırlıklara E hata fonksiyonunun etkilerini yaymaktır. Böylelikle toplam hata değerini enküçükmektir.

$$E_{Top} = \lim_{t \rightarrow \infty} \left(\frac{\sum_{t=1}^t E^t}{t} \right)$$

Eşitlik 2

Herhangi bir 't' denemesinde E^t değeri küçültülebilirse sistemin hatasının azalacağı Eşitlik 2'de kolaylıkla gözlenmektedir. Sistem hatasındaki azalmayı temel olarak alarak ve bu azalmayı destekleyecek şekilde ağ üzerindeki ağırlık değerleri yeniden belirlenecek yöntemler kullanılmaktadır. Eğitim işlemi ve eğitimden sonraki test işlemi bu akışa göre yapılır. Bu algoritma ile, x_i giriş için, i ve j kat işlem elemanları arasındaki ağırlıklardaki w_{ji}(t) değişikliği hesaplanır. Bu ifade,

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1)$$

Eşitlik 3

olarak verilir. Eşitlik 4'de η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j)$$

Eşitlik 4

Burada, $net_j = \sum x_j w_{ji}$ ve y_j(t) ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki (İşlem Elemanları – Nöronlar) İşlem Elemanları (İE) için ise bu faktör,

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum w_{qi} \delta_q$$


Eşitlik 5

olarak verilir. Ara katlardaki İE'ler için herhangi bir hedef çıkış olmadığından, Eşitlik 4 yerine Eşitlik 5 kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki İE'ler için hesaplanır. Daha sonra Eşitlik

3'deki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir.

Şekil 1.2'de birçok sinir hücresinin bir birine bağlandığı ileri yönlü çok katmanlı bir yapay sinir ağı görülmektedir. Giriş nöronlarıyla ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir. Probleme göre değişen bu nitelikler deneme-yenilme yoluyla bulunur (Skapura 1996).

Geri yayılım algoritmasında kullanılacak aktivasyon fonksiyonu birkaç önemli karakteristiğe sahip olmalıdır. Aktivasyon fonksiyonu, sürekli, türevi alınabilir ve tekdüze bir şekilde azalmayan bir fonksiyon olmalıdır. Bu fonksiyonun türevinin kolay alınması tercih sebebidir. Genellikle, fonksiyonun minimum ve maksimum asimtotlar arasında uzanması beklenir.



Şekil 1.2. İleri beslemeli çok katmanlı sinir ağı: x, z, y vektörleri ile V, W matrisleri

En çok kullanılan aktivasyon fonksiyonlarından biri ikili sigmoid fonksiyonudur. Bu fonksiyon 0 ile 1 arasında bir değere sahiptir.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad \text{Eşitlik 6}$$

Diğer yoğun kullanılan aktivasyon fonksiyonu ise bipolar sigmoid fonksiyonudur. Bu fonksiyon ise -1 ile 1 arasında bir değere sahiptir.

$$f(x) = \frac{2}{1 + \exp(-x)} - 1 \quad \text{Eşitlik 7}$$

Şekil 1.1 'deki gibi bir ağıın eğitimi geri yayılım algoritması ile Tablo 1.1 de incelendiği gibi yapılır (Fausett 1994:294).

Tablo 1.1. Geri Yayılma Algoritması.

Adım 0	Ağırlıklara (katsayılara) rasgele küçük katsayılar ata.
Adım 1	Tüm giriş eğitim vektörü ve hedef çıkış çiftleri için, s.t. adım 2-9 arasındaki işlemler gerçekleştirilir
Adım 2	Her bir eğitim verisi (\mathbf{x}, \mathbf{t}) için 3-8 adımlarını takip et.
İLERİ BESLEME (FEEDFORWARD)	
Adım 3	Her bir X_i (X_1, \dots, X_n) nöronu x_i input sinyalini alır ve bir üst katmandaki gizli katmanda yer alan nöronlara aktar.
Adım 4	Her bir Z_j nöronu, ağırlıklandırılmış giriş sinyallerini toplar ve çıkış sinyalini hesaplar. $z_in_j = v_{0j} + \sum x_i v_{ij}$ $z_j = f(z_in_j).$ Sonra bu değeri çıkış katmanındaki nöronlara gönder.
Adım 5	Her bir çıkış Y_k nöronu, ağırlıklandırılmış giriş sinyallerini toplar ve çıkış sinyalini hesapla. $y_in_k = w_{0k} + \sum z_j w_{jk}$ $y_k = f(y_in_k).$
HATANIN GERİYE YAYILMASI (BACKPROPAGATION OF ERROR)	
Adım 6	Her bir çıkış nöronu Y_k (Y_1, \dots, Y_m), giriş eğitim verisine karşılık gelen hedef değeri alır ve hata terimini hesapla: $\delta_k = (t_k - y_k) f'(y_in_k).$ Sonra, w_{jk} katsayısını güncellemede kullanılacak katsayı düzeltme terimini hesapla: $\Delta w_{jk} = \alpha \delta_k z_j.$ Daha sonra, w_{0k} eğilim değerini güncellemede kullanılacak eğilim düzeltme terimini hesaplar: $\Delta w_{0k} = \alpha \delta_k.$
Adım 7	Her bir gizli nöron Z_j (Z_1, \dots, Z_p), yukarı katmandan gelen delta girişlerini toplar: $\delta_in_j = \sum_{k=1}^m \delta_k w_{jk}.$ Sonra, hata terimini hesapla: $\delta_j = \delta_in_j f'(z_in_j).$ Daha sonra, v_{ij} katsayısını güncellemede kullanılacak katsayı

	düzeltilme terimini hesapla: $\Delta v_{ij} = \alpha \delta_j x_i.$ Son olarak, v_{0j} eğilim değerini güncellemede kullanılacak eğilim düzeltilme terimini hesapla: $\Delta v_{0j} = \alpha \delta_j.$
	AĞIRLIK KATSAYILARINI VE EĞİLİM DEĞERLERİNİ GÜNCELLEŞTİR
Adım 8	Her bir çıkış nöronu Y_k (Y_1, \dots, Y_m) eğilim değerlerini ve ağırlık katsayılarını ($j=0, \dots, p$) güncelle. $w_{jk}(\text{yeni}) = w_{jk}(\text{eski}) + \Delta w_{jk}$ Her bir gizli nöron Z_j (Z_1, \dots, Z_p) eğilim değerlerini ve ağırlık katsayılarını ($i=0, \dots, n$) güncelle. $v_{ij}(\text{yeni}) = v_{ij}(\text{eski}) + \Delta v_{ij}$
Adım 9	Bitiş şartını kontrol et.

2. Uygulama

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_2) ve su buharı açığa çıkar. Bununla beraber yakıttaki safsızlıklar, uygun olmayan hava/yakıt oranı veya çok yüksek ya da çok düşük yanma sıcaklıkları karbon monoksit (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 kirliliği ve temiz hava karşılaştırması Tablo 3.1 de verilmiştir.

Bu çalışmada, Sivas il merkezinin hava kalitesi modelinin yapay sinir ağları ile oluşturulması üzerinde durulmuş ve model çıktısı olarak günlük ortalama SO_2 (Kükürtdioksit ($\mu\text{g} / \text{m}^3$)) parametresi kullanılmıştır. Bu parametrenin tahmininde bir gün önceki meteorolojik parametreler, günlük ortalama SO_2 değeri ve Partiküller Madde (Duman ($\mu\text{g} / \text{m}^3$)) için girdi parametreleri olarak kullanılmıştır. Bir gün öncesinin aşağıda kısaca özetlenecek olan parametreleri ile yirmi dört saat sonrasının kirlilik, başka bir deyişle hava kalitesi modeli tahmin edilmiştir.

Bu çalışmada kullanılan verilerin bir kısmı Devlet İstatistik Enstitüsünden, bir kısmı Sivas İl Sağlık Müdürlüğü, Halk Sağlığı Laboratuvar Müdürlüğünden ve bir bölümü de benzer konuda hazırlanan çalışmalardan alınmıştır.

Kükürtdioksit ölçümü prensip olarak havanın bu gaz sebebi ile sahip olduğu asiditesinin ölçümü olarak yapılmaktadır ve eşdeğer $\mu\text{gr}/\text{m}^3$ şeklinde ifade edilmektedir. Ölçüm asidimetrik titrasyon metodu ile yapılmaktadır. Bu metodda, hava numunesi 24 saat boyunca seyreltik hidrojen peroksit çözeltisi içinden geçirilmekte ve kükürtdioksit çözeltide absorbe olup sülfirik aside dönüşmektedir. Daha sonra bu çözeltinin asiditesi standart NaOH çözeltisi ile titre edilip sonuç eşdeğer SO_2 konsantrasyonu şeklinde ifade edilmektedir.

Tablo 2.1. Kirli atmosfer ile temiz atmosferin karşılaştırılması

Eser Gaz (ppm)	Temiz Hava	Kirli Hava	Kirli/Temiz
CO_2	320	400	1.3
CO	0.1	40-70	400-700
CH_4	1.5	2.5	1.3
N_2O	0.25	?	?
$\text{NO}_2(\text{NO}_x)$	0.001	0.2	200
O_3	0.02	0.5	25
SO_2	0.0002	0.2	1000
NH_3	0.001	0.02	2

2.1. Verilerin Analizi ve Model İçin Girdi Seti Hazırlanışı

Hava kalitesi modelinin yapay sinir ağları yaklaşımı ile tahmin edilmesi ve modellenmesi için ağa sunulacak olan veri kümesi, 1990 – 2004 yılları arasında Sivas ilinde yapılan ölçümlerden elde edilen verilerdir. Bu veriler genel olarak günlük sıralı veriler olarak ağa sunulmaktadır. Fakat çeşitli sebeplerden dolayı alınamayan günlük set üzerindeki parametrelerden herhangi birisi eksik olan veri grubu eğitim setinden çıkartılmıştır. Eğitim seti üzerindeki veri gruplarının dağılımı Sivas ili için hava kirliliğinin yoğun olduğu kış ve sonbahar mevsimlerinde yapılan ölçümlerdir. Sivas ili merkezinde yaz ve bahar aylarında hava kirliliği değerleri yüksek olmadığı için eğitim setine bu mevsimlere ait bilgileri içeren 5 yıllık veri grupları dahil edilmiştir. Hazırlanan eğitim setinde 3151 güne ait meteorolojik ve hava kirliliği ölçüm değerleri yer almaktadır. Yapay Zekâ Modelinin, eğitimi esnasında bu veri seti, eğitim, test ve doğrulama veri seti olarak üç kısma ayrılarak ağa sunulmaktadır. Tablo 3.2’de Modelde kullanılacak olan bağımsız değişkenlere ait parametrelerin istatistiksel değerleri verilmiştir.

Tablo 2-2 Modelde kullanılan parametreler için istatistiksel oranlar

Parametre	Birim	Ortalama	Maksimum	Minimu
Günlük Maksimum Sıcaklık	°C	12,4	38,2	-14,2
Günlük Minimum Sıcaklık	°C	1	18,0	-27,2
Günlük Ortalama Yağış	mm	1,3	55,0	0
Günlük Ortalama Rüzgâr	m/sec	1,3	6,2	0
Günlük Ortalama Nem	%	68,3	96,0	26,3
Günlük Ortalama Basınç	Mb	87,2	88,5	84,8
Günlük Ortalama Buhar Basıncı	Mb	69,4	182	9
Günlük Ortalama Bulutluluk	-	4,6	10	0
Günlük Güneşlenme Süresi	Saat	5,9	14,8	0
Günlük Güneşlenme Şiddeti	CAL/CMy	284,6	696,6	0
SO ₂	Mgr/m ³	144,7	1976	9
P.M (Partikül Madde)	Mgr/m ³	118,9	871	10

Tablo 2.2’de bulunan ilk 12 parametre, model için girdi parametreleri olup; çıktı olarak bir gün sonraki SO₂ konsantrasyonu tahmin edilmiştir. Ayrıca meteorolojik verilerin bulunduğu güne ait SO₂ konsantrasyonu ve P.M. (Partikül Madde) konsantrasyonu da 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 dâhil edilmiştir.

Bu parametrelerle oluşturulan yapay sinir ağları modelinde giriş katmanı 12 nöronlu olarak sabitlenmiştir. Çıkış katmanı da SO₂ konsantrasyonunu temsil eden 1 nörondan oluşmaktadır. Gizli katmanda kullanılan nöron sayısı, öğrenme yöntemleri ve ağ parametreleri değiştirilerek en uygun model bulunmaya çalışılmıştır. Kurulan modele giriş verileri tarihsel sıralama ile sunularak model eğitilmiştir. MATLAB üzerinde kurulan birçok farklı geri yayılım (backpropagation) modeli üzerinde yapılan çok sayıda denemeler sonucunda en elverişli model seçilmiştir.

2.2. Yapay Sinir Ağları Modelleri Deneme Sonuçları

Yapay Sinir Ağları ile yapılan deneylerde, modelin başarısını test etmek için Hata Kareler Ortalaması (MSE, Mean Square Error) ve R² Çoklu Belirleme Katsayısının aldığı değerler göz önüne alınarak modele karar verilir. Modelin başarısını daha iyi irdelemek için ise, SO₂ konsantrasyonunu temsil eden ölçümsel gerçek değerler ile, o an deney için kullanılan Yapay Sinir Ağları modelinin

hesapladığı tahmin değerleri arasındaki ilişkiyi gösteren grafik çizdirildi. Modeller içinden MSE değerinin sıfıra en yakın olduğu model aranılır iken, R^2 değerinin de bire en yakın olan değer aranmıştır. Seçilen model üzerinde ağ performansı üzerinde en etkili olan momentum katsayısı parametresi ve öğrenme algoritması parametresi değiştirilerek, ağ üzerindeki etkileri de incelenmiştir.

Bacpropagation algoritmasında, çoğunlukla iniş (descent) algoritmasını kullanılmaktadır. Bu algoritma temel olarak, T zamanı içerisinde düzenli parametre vektörlerinin ağa sunulması ile ε_m toplam hata değeri için en küçük değeri bulmayı amaçlar.

Descent algoritmasında eğitim veri seti üzerinde standartlaştırma veya verilerin ön hazırlanması olarak adlandırılan işlem gerçekleştirilir. Uygulama verileri üzerinde yüzeysel bir inceleme yapılırsa, aynı veri seti üzerindeki bazı değerlerin 0 dan küçük bazılarının ise daha büyük değerlere sahip olduğu, veriler arasındaki bu uzaklıkların özellikle uç verilerin sonuçlar üzerinde daha etkin olacağını göstermektedir. Verilerin normalleştirilmesi işlemi ile eğitim giriş setindeki her bir parametrenin modelin tahmin işlemine eşit ölçüde katkıda bulunması sağlanır.

Her bir değişkene karşı gelen sütunların aritmetik ortalaması ve standart sapması bulunmuştur. Sonra da, Eşitlik 11'de belirtilen formülle veriler normalleştirilerek veriler arasındaki uzaklıklar ortadan kaldırılmıştır. Eğitim bittikten sonra normalleştirilen veriler tekrar orijinal haline dönüştürülür.

$$x'_i = \frac{x_i - \mu}{\sigma} \quad \text{Eşitlik 8}$$

Levenberg-Marquardt Öğrenme algoritması kullanılarak gerçekleştirilen deneyler ile ilgili sonuçlar Tablo 3.3 ve Tablo 3.4 de görüldüğü gibidir.

Kullanılan öğrenme algoritmasında ağırlıkların ve biasların güncelleştirilmesinde kullanılan öğrenme oranı ağ performansı üzerinde önemli bir etkiye sahiptir ve $[0, 1]$ aralığında seçilen reel bir sayıdır ve adım büyüklüğünü belirler. Öğrenme oranının küçük değerler alındığı uygulamalarda eğitim işlemi uzun süreler alırken, bu değerlerin büyütülmesi ile eğitim işlemi daha kısa sürede gerçekleşebilmektedir. Eşitlik 9'de temel ağırlık düzenleme eşitliğine α öğrenme oranının etkisi gözlemlenmektedir. Öğrenme oranının artırılması durumunda öğrenme için gerekli adım sayısında azalmada gözlemlenebilir bir değişme olması beklenilir.

$$w_{ij} = w_{ij} + \alpha(y_i - t_i)x_j \quad \text{Eşitlik 9}$$

Denemelerde kullanılan algoritmalar içerisinde kullanılan momentum, ağırlıklar üzerindeki değişimleri aktif olan ve bir önceki eğimlerin birleşimi olarak

gerçekleştirir. Yani; bir önceki denemedeki değişimin belirli oranının yeni değişim miktarına eklenmesidir. Hesaplamalarda momentum terimini ilave edilmesi ağ performansı üzerinde etkili olduğu gözlenmiştir. Momentum kullanmanın sağladığı en önemli avantajlardan birisi ise eğitime giren veri setlerinden bir grup diğerlerinden farklı özellikler gösteriyor ise (muhtemelen yanlış veri olabilir) önceki ağırlıklarında düzenlemeye katılması sebebi ile oluşacak hata değerini indirgemesidir.

Momentum katsayısı öğrenmenin performansını etkiler. Bu özellik yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile önerilmiştir (Öztemel, 2003; s:99). Momentum değerinin küçük olması yerel çözümlerden kurtulmayı zorlaştırırken, çok büyük değerler ise tek bir değere ulaşmada sorunlar yaratabilir.

Momentum katsayısının kullanılmasının ağırlık düzenlemelerine etkisi Eşitlik 10'de, Şekil 1.1'de gösterilen ağ üzerinde incelenmektedir.

$$w_{jk}(t+1) = w_{jk}(t) + \alpha \delta_k Z_j + \mu(w_{jk}(t) - w_{jk}(t-1)) \quad \text{Eşitlik 10}$$

veya

$$\Delta w_{jk}(t+1) = \alpha \delta_k Z_j + \mu \Delta w_{jk}(t) ,$$

burada

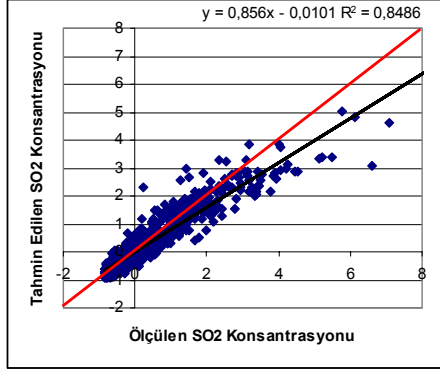
$$\Delta w_{jk} = \alpha \delta_k Z_j$$

olmaktadır.

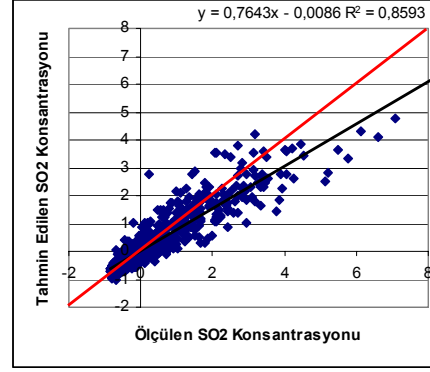
Tablo 2.3. Yapay Zeka Deneme Sonuçları

Den. No	Öğr. Oranı	Momentum	Deneme Sayısı	MSE	R	Regresyon Denklemi
1	0,01	0,5	56	0.00533397	0,921	Y=0,806x-0,101
2	0,01	0,9	55	0.0026273	0,927	Y=0,724x-0,00862
3	0,05	0,5	61	0.00320193	0,942	Y=0,8x-0,0217
4	0,05	0,9	57	0.00240595	0,925	Y=0,8005x-0,0018
5	0,1	0,5	58	0.00312267	0,927	Y=084x+0,0158
6	0,1	0,9	58	0.00204885	0,942	Y=0,708x-0,0419

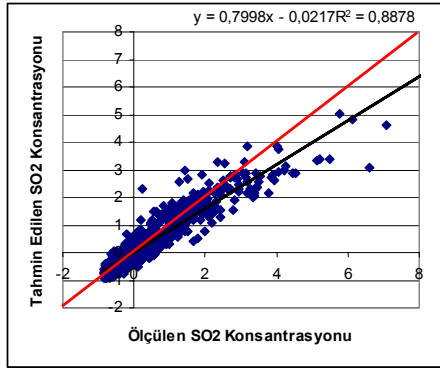
Tablo 2.4. Yapay Sinir Ağı Deneme Sonuç Grafikleri




Grafik 1-Deneme 1



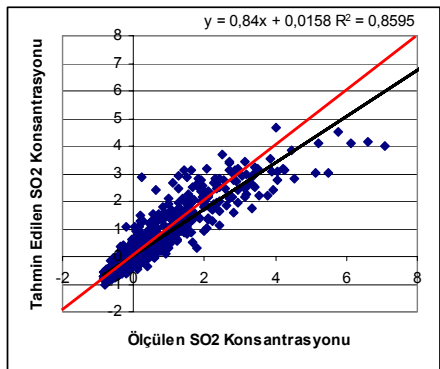
Grafik 2-Deneme 2



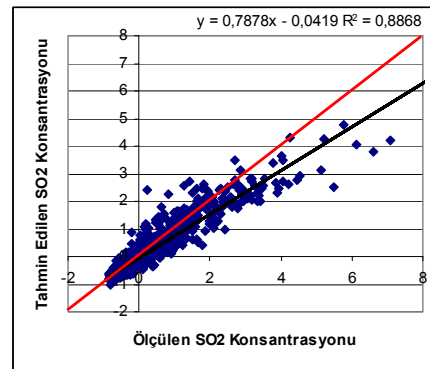
Grafik 3-Deneme 3



Grafik 4-Deneme 4




Grafik 5-Deneme 5



Grafik 6-Deneme 6

Levenberg-Marquardt algoritmasını kullanan öğrenme algoritması ile ilgili gerekli program yapısı MATLAB ortamında hazırlanarak, Tablo 2.3'te verilen öğrenme katsayısı ve momentum katsayısı değerleri sıra ile ağı sunulmuştur. Her model için belirlenen sayıda yapılan denemeler içerisinde en iyi performansı gösteren deneme sonuç değerleri alınarak tabloda incelemeye tabi tutulmuştur. Kolaylıkla görülebileceği gibi bu parametreler deneme sayılarını R^2 ve MSE değerini etkilemektedir. Bu değerler "Doğrulama Veri Seti" içerisindeki verilerin eğitim esnasında belli değerden fazla hataya sebebiyet verince öğrenmeyi bitirdiği durumda elde edilmiştir. Burada önemli olan, eğitim sonucunda elde edilen tahmin değerleri ve orijinal değerler arasındaki Tablo 2.4'te incelenen dağılım diyagramlarında çizilen ilişki doğrusunun, en iyi dağılım doğrusuna olan yakınlığı ve değerler arasındaki ilişki göz önüne alınarak çizilen regresyon doğrusu etrafındaki dağılımın bu doğruya olan yakınlığıdır. R^2 değerinin 1'e yaklaşırken MSE değerinin 0'a yaklaştığı göz önüne alınarak modeller arasındaki en başarılı model parametreleri seçilebilir.

Şekil 2.1'de inceleneceği gibi modelde uç noktadaki (genel ortalamadan çok uzaklaşan) noktaların tahmininde model yetersiz kalırken, genel dağılımın içerisindeki noktaların tahmininde çok başarılıdır.



Şekil 2.1. Ölçülen Değerler İle Tahmin (Hesaplanan) Değerlerin Grafiksel Karşılaştırılması

- Kesiksiz Düz Çizgi Ölçülen gerçek değerleri temsil ediyor.
- Kesikli Noktalar YSA tarafından hesaplanan değerleri temsil ediyor.

Sonuçlar

Hava kalite modelinin belirlenmesinde önemli bir parametre olan SO₂ konsantrasyonunu tahmin etmek için, Tablo 2.2’de verilen 12 parametre girdi değişkeni kullanılmıştır. Modelde kullanılan SO₂ değerleri 1 gün sonraki değerlerdir. Bugünün hava kirliliği seviyesinin yarınki hava kirliliği seviyesine etkisini de ölçmek için, modele P.M. (Partikül Madde) konsantrasyonu da girdi değeri olarak dahil edilmiştir.

Bu parametrelerle oluşturulan yapay sinir ağları modelinde giriş katmanı 12 nöronlu olarak sabitlenmiştir. Çıkış katmanı da SO₂ konsantrasyonunu temsil eden 1 nöronlu olmaktadır. Gizli katmanda kullanılan nöron sayısı, öğrenme yöntemleri ve ağ parametreleri değiştirilerek en uygun model bulunmaya çalışılmıştır. Kurulan modele giriş verileri tarihsel sıralama ile sunularak model eğitilmiştir.

MATLAB üzerinde kurulan birçok farklı geri yayılım (backpropagation) modeli üzerinde yapılan yoğun denemeler sonucunda bir çok model oluşturulmuştur. Oluşturulan modellerin başarısı MSE (Mean Square Error) ve R² Çoklu Belirleme Katsayısının aldığı değerler göz önüne alınarak belirlenir. Tablo 2.3’de değerlerin belirlenmesi için yapılan deneme sonuçları gözlenmektedir. Belirtilen bu denemeler sonucunda, en uygun model olarak Deney 6 seçilmiştir. Bu modelde MSE = 0.00204885 ve R² = 0.88 bulunmuştur.

Yapay sinir ağları hesaplamalara tamamen farklı bir yaklaşım getirmektedir. Yani belirli bir problemi çözmek için programlama yerine direkt olarak mevcut örnekleri kullanır ve ne kadar fazla örnekle ağ eğitilirse problemin çözümündeki teşhisi o kadar doğru olur.

KAYNAKÇA

- Benvenuto, M., (2000), “ *Neural Networks For Environmental Problems: Data Quality Control and Air Pollution Nowcasting*” Global Nest Vol 2, No 3, pp 281-292.
- Bonzar, M., Lesjak, M., Mlakar, P., (1991) “*A neural network based method for short-term predictions of ambient SO₂ concentration in highly polluted industrial areas of complex terrain*”. Atmospheric Environment 27B(2), 221-230
- Comrie, A.C., 1997. Comparing neural Networks and regression models for ozone forecasting. Journal of the Air & Waste Management Association 47, 653-663
- Efe, Ö., (2000), Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul.

- Elmas, Ç., (2003), Yapay Sinir Ağları, Seçkin Yayınları, Ankara.
- Fausett, L., (1994), Fundamentals of Neural Networks, Prentice Hall, New Jersey.
- Graupe, D., (1997), Principles of Artificial Neural Networks, World Scientific Publishing, Singapore.
- Grivas, C., (2005), “*Artificial neural network models for prediction of PM₁₀ hourly concentrations, in the Greater Area of Athens, Greece.*” Atmospheric Environment, Yayında.
- Kay, J. W. and D.M. Titterington (1999), Statistics and Neural Networks, Oxford University Pres. New York.
- Neter, J., W. Wasserman and M. H. Kutner (1989), Applied Linear Regression Models, IRWIN, Boston.
- Öztemel, E., (2003), Yapay Sinir Ağları, Papatya yayınevi, İstanbul.
- Patterson, D. W., (1996), Artificial Neural Networks, Prentice Hall. New York.
- Roa, R., Castro, J., Jorquera, H., Correa, J.R., Vesovic, V., (2005) “*Air- Pollution modelling in urban ares: Correlating turbulent diffusion coefficients by means of an artificial neural network approach*” Atmospheric Environment, Yayında.
- Saral, A., 2000, Hava kirliliğinin yapay sinir ağları yöntemi ile modellenmesi ve tahmini. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmamış Doktora tezi.
- Sarle, W. S. (1994), “*Neural Networks and Statistical Models*”, Proceedings of the Nineteenth Annual SAS Users Group International Conference, Cary, NC: SAS Institute.
- Skapura, D. M. (1996), Building Neural Networks, Addison-Wesley, New York.
- Wark, K., Warner, C.F., 1981, Air Pollution, its Origin and Control, Harper-Collins, New York.
- Warner, B., & Misra, M. (1996), “*Understanding neural Networks as statistical tools*”. The American Statistician, 50, 284-293.
- White, H. (1992), Artificial Neural Networks: Approximation and Learning Theory, Blackwell, Oxford, UK.
- White, H., (1989), “*Learning in Artificial Neural Networks: A Statistical Perspective.*”, Neural Computation, Vol. 1, No. 4, pp. 425—464.
- Yurtoğlu, H., 2005, Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği. Uzmanlık Tezi, Yayın No: Dpt: 2683, Ankara.
- Yi, J., Prybutok, V.R., 1996. “*A Neural network model forecasting for prediction of daily maximum ozone concentration in industrialized urban area*”. Environmental Pollution 92, 349-357.