

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI İLE
KISA DÖNEM YÜK TAHMİNİ**

YÜKSEK LİSANS TEZİ

Müh. Gülden CEYLAN

Anabilim Dalı: Elektrik Mühendisliği

Programı: Elektrik Mühendisliği

MAYIS 2004

**YAPAY SİNİR AĞLARI İLE
KISA DÖNEM YÜK TAHMİNİ**

YÜKSEK LİSANS TEZİ

Müh. Gülden CEYLAN

(504011020)

Tezin Enstitüye Verildiği Tarih : 26 Nisan 2004

Tezin Savunulduğu Tarih : 18 Mayıs 2004

Tez Danışmanı Prof. Dr. Ayşen DEMİRÖREN

Diğer Jüri Üyeleri Prof. Dr. Adnan KAYPMAS

Yrd. Doç. Neslihan Serap ŞENGÖR

MAYIS 2004

ÖNSÖZ

Öncelikle, tez çalışmasının en zor aşamalarında biri olan gerçek yük verilerini temini konusunda bana yardımcı olan ve yönlendiren Sayın Ulaş Karaağaç'a ve bana verileri ulaştırarak tez çalışmasında kullanmama izin veren TEİAŞ Ulusal Yük Dağıtım Merkezi'ne ve Sayın Nurhan Ozan'a teşekkürlerimi sunarım.

Tez çalışmam ve tüm eğitim hayatım boyunca beni destekleyerek bu aşamaya gelmemi sağlayan anneme, babama ve ablalarıma teşekkürü borç bilirim.

Ayrıca her zaman beni destekleyen ve moral aşılayan tüm arkadaşlarıma buradan teşekkür etmek isterim.

Tez çalışmam süresince, yoğun programı içinde benim için geniş vakit ayırıp çalışmalarımı yakından ilgilenen, yol gösteren ve desteğini esirgemeyen hocam Prof. Dr. Ayşen Demirören'e sonsuz teşekkürlerimi sunarım.

MAYIS 2004

Gülden CEYLAN

İÇİNDEKİLER

ÖNSÖZ	ii
KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SEMBOL LİSTESİ	x
ÖZET	xi
SUMMARY	xii
1. GİRİŞ	1
2. YÜK TAHMİNİ	5
2.1. Giriş	5
2.2. Yük Tahmininin Zamana Göre Sınıflandırılması	6
2.2.1. Uzun Dönem Yük Tahmini	6
2.2.2. Orta Dönem Yük Tahmini	7
2.2.3. Kısa Dönem Yük Tahmini	7
2.2.4. Çok Kısa Dönem Yük Tahmini	10
2.3. Yüklerin Sınıflandırılması	11
2.4. Yükü Etkileyen Faktörler	15
2.4.1. Meteorolojik Koşullar	16
2.4.2. Zaman Faktörü	16
2.4.3. Ekonomik ve Demografik Faktörler	16
2.4.4. Rastlantısal Faktörler	17
2.5. Yük Eğrisinin Özellikleri	17
3. YÜK TAHMİNİNDE KULLANILAN YÖNTEMLER	23
3.1. Giriş	23
3.2. Regresyon Analizi	23
3.2.1. Basit Regresyon	24
3.2.2. Doğrusal Çoklu Regresyon	26
3.3. Zaman Serileri	26
3.4. Box Jenkins Modelleri ve Türevleri	28
3.4.1. Otoregresif Model, AR(p)	28
3.4.2. Hareketli Ortalamalar Modeli, MA(q)	29
3.4.3. Karışık Otoregresif-Hareketli Ortalamalar Modeli, ARMA(p,q)	29
3.5. Bulanık Mantık (Fuzzy Logic)	29
3.6. Yapay Sinir Ağları (YSA)	31

4. YAPAY SİNİR AĞLARI	33
4.1. Giriş	33
4.2. Biyolojik Sinir Sistemi	34
4.3. Yapay Sinir Ağlarının Tarihsel Gelişimi	37
4.4. YSA'nın Özellikleri	39
4.4.1. Doğrusal Olmama	39
4.4.2. Öğrenme	39
4.4.3. Genelleme	39
4.4.4. Uyarlanabilirlik	40
4.4.5. Hata Toleransı	40
4.4.6. Donanım ve Hız	40
4.4.7. Analiz ve Tasarım Kolaylığı	40
4.5. YSA'nın Uygulama Alanları	40
4.6. Nöron Modeli	41
4.6.1. Aktivasyon Fonksiyonları	43
4.6.2.1. Doğrusal Fonksiyon	43
4.6.2.2. Parçalı Doğrusal Fonksiyon	43
4.6.2.3. Eşik Fonksiyonu	44
4.6.2.4. Sigmoid Fonksiyonu	44
4.6.2.5. Hiperbolik Tanjant Fonksiyonu	45
4.7. YSA'ların Sınıflandırılması	46
4.7.1. Yapılarına Göre Sınıflandırma	46
4.7.1.1. İleri Beslemeli YSA	46
4.7.1.2. Geri Beslemeli YSA	47
4.7.2. Öğrenme Şekillerine Göre Sınıflandırma	48
4.7.2.1. Eğitici Öğrenme	48
4.7.2.2. Eğitici Öğrenme	49
4.7.2.3. Özdenetimli Öğrenme	50
4.8. Çok Katmanlı Perseptronlar ve Öğrenme Algoritmaları	50
4.9. Diğer YSA'lar ve Öğrenme Algoritmaları	52
4.9.1. Vektör Kuantalama (Learning Vector Quantization, LVQ)	52
4.9.2. Hopfield Ağı	53
4.9.3. Elman ve Jordan Ağları	54
4.9.4. Kohonen Ağı	55
4.9.5. Radyal Tabanlı Fonksiyon Ağları (RTFA)	56
5. GERİYE YAYILIM ALGORİTMASI	58
5.1. Giriş	58
5.2. Standart Geriye Yayılım Algoritması (Dik İniş Algoritması)	59
5.2.1. Yapay Sinir Ağlarında Öğrenme ve Ezberleme Problemi	60
5.2.2. Aktivasyon Fonksiyonlarının Türevleri	61
5.2.3. Geriye Yayılım Algoritmasında Ağırlıkların Güncellenmesi	61
5.2.3.1. Çıkış Katmanındaki Ağırlıkların Güncellenmesi	61
5.2.3.2. Ara Katman Ağırlıklarının Güncellenmesi	64
6. KISA DÖNEM YÜK TAHMİNİNİN YAPAY SİNİR AĞLARI İLE	
BİLGİSAYAR BENZETİMİ	68
6.1. Giriş	68
6.2. Yük Tahmini Modeli	69

6.2.1. Yk Tahmininde Kullanılacak Verilerinin Belirlenmesi	70
6.2.2. Benzer Gnlerin Seimi	74
6.3. Yapay Sinir Ađı	76
6.3.1.Eđitim Kmesinin Normalizasyonu	78
6.3.2. Algoritmanın Uygulanması	80
6.4. Regresyon	81
6.5. Bilgisayar Benzetim Programı	82
6.6. Sonular	83
7. SONULAR	85
KAYNAKLAR	89
EK A	93
EK B	94
ZGEMİř	104

KISALTMALAR

ARIMA	: Otoregresif-Hareketli Ortalama Yöntemi
AR	: Otoregresif Model
MA	: Hareketli Ortalamalar Modeli
ARMA	: Karışık Otoregresif-Hareketli Ortalamalar Modeli
YSA	: Yapay Sinir Ağları
ADALINE	: Genlikte Sürekli Algılayıcı (Adaptive Linear Neuron)
MADALINE	: Multiple Adaline (Katmanlı Genlikte Sürekli Algılayıcı)
SOM	: Özdenetimli Harita, (Self Organizing Feature Map)
MLP	: Çok Katmanlı Perseptron (Multilayer Perceptron)
LVQ	: Vektör Kuantalama (Learning Vector Quantization)
BP	: Geriye Yayılım (Back Propagation)
QP	: Hızlı Yayılım (Quick Propagation)
DBD	: Delta-bar-delta
EDBD	: Genişletilmiş delta-bar-delta (Extended delta-bar-delta)
RTFA	: Radyal Tabanlı Fonksiyon Ağları
VLSI	: Büyük Ölçekli Entegre Devre (Very Large Scale Integrate)

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 4.1 Sinir sistemi ile YSA'nın benzerlikleri	37
Tablo 6.1 Gölbaşı Bölgesi illerinin elektrik enerjisi tüketimleri	71
Tablo 6.2 Yapay sinir ağı parametreleri	81
Tablo 6.3 Bilgisayar benzetimi sonuçları.....	84

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1	: 2002 yılı Türkiye elektrik tüketiminin tüketici gruplarına göre dağılımı	15
Şekil 2.2	: Gölbaşı Bölgesi 2003 yılı yük eğrisi	18
Şekil 2.3	: Gölbaşı Bölgesi 2002 Haziran ayı yük eğrisi	19
Şekil 2.4	: Gölbaşı Bölgesi 12-18 Haziran yük eğrisi.....	19
Şekil 2.5	: Gölbaşı Bölgesi için farklı dört mevsimden seçilen salı günlerinin yük eğrileri (a) 15.01.2002 (Kış), (b) 16.04.2002 (İlkbahar), (c) 16.07.2002 (Yaz), (d) 15.10.2002 (Sonbahar).....	20
Şekil 2.6	: Gölbaşı Bölgesi için Kurban Bayramı'nı da içine alan 18.02.2002-27.02.2002 günlerinin yük eğrisi	21
Şekil 2.7	: Gölbaşı Bölgesi için 22.04.2002-28.04.2002 günleri arası yük eğrisi	22
Şekil 3.1	: a) Bulanık üyelik fonksiyonu b)Klasik üyelik fonksiyonu.....	31
Şekil 4.1	: Biyolojik sinir sisteminin blok gösterimi	34
Şekil 4.2	: Biyolojik sinir hücresi ve bileşenleri	35
Şekil 4.3	: Nöron ve sinapsdaki iletim	36
Şekil 4.4	: Bir nöron modeli	42
Şekil 4.5	: Doğrusal aktivasyon fonksiyonu	43
Şekil 4.6	: Parçalı doğrusal fonksiyon	44
Şekil 4.7	: Eşik fonksiyonu	44
Şekil 4.8	: Sigmoid fonksiyonu	45
Şekil 4.9	: Hiperbolik tanjant fonksiyonu	46
Şekil 4.10	: İleri beslemeli yapay sinir ağı	47
Şekil 4.11	: Geri Beslemeli YSA	48
Şekil 4.12	: Eğitici öğrenmenin blok diyagramı	49
Şekil 4.13	: Eğitici öğrenmenin blok diyagramı	49
Şekil 4.14	: Özdenetimli öğrenmenin blok diyagramı	50
Şekil 4.15	: Çok katmanlı perseptron modeli	51
Şekil 4.16	: Vektör kuantalama ağı	52
Şekil 4.17	: Hopfield Ağı	54
Şekil 4.18	: Elman Ağı	55
Şekil 4.19	: Jordan Ağı	55
Şekil 4.20	: Kohonen Ağı	56
Şekil 4.21	: Radyal tabanlı fonksiyon ağı	57
Şekil 5.1	: Eğitimin durdurulması	60
Şekil 5.2	: Çıkış katmanındaki j nöronunun işaret akış diyagramı	62
Şekil 5.3	: j gizli katmanına bağlı k çıkış nöronunun işaret akış diyagramı ..	65
Şekil 6.1	: Maksimum yük – maksimum sıcaklık ilişkisi	70
Şekil 6.2	:Gölbaşı Bölgesi elektrik enerjisi tüketiminin illere göre yüzdesel dağılımı	71

Şekil 6.3	: Benzer gün seçimi için sınırlar	75
Şekil 6.4	: Yapay sinir ağı modeli	77
Şekil 6.5	: Sigmoid fonksiyonu	78
Şekil B.1	: 26.02.2003 Çarşamba günü için yapılan yük tahminleri	94
Şekil B.2	: 13.05.2003 Salı günü için yapılan yük tahminleri	95
Şekil B.3	: 14.08.2003 Perşembe günü için yapılan yük tahminleri	96
Şekil B.4	: 13.11.2003 Perşembe günü için yapılan yük tahminleri	97
Şekil B.5	: 26.05.2003 Pazartesi günü için yapılan yük tahminleri	98
Şekil B.6	: 13.06.2003 Cuma günü için yapılan yük tahminleri	99
Şekil B.7	: 20.09.2003 Cumartesi günü için yapılan yük tahminleri	100
Şekil B.8	: 19.10.2003 Pazar günü için yapılan yük tahminleri	101
Şekil B.9	: 10.02.2003-16.02.2003 tarihlerindeki Kurban Bayramı haftası için yapılan yük tahminleri	102
Şekil B.10	: 19.05.2003, 19 Mayıs Gençlik ve Spor Bayramı için yapılan yük tahminleri	103

SEMBOL LİSTESİ

$X_1, X_2, \dots$	: Serbest değişkenler (Regresyon analizi)
Y	: Bağımlı değişken (Regresyon analizi)
$a, b_1, b_2, \dots$	: Regresyon katsayıları
$\Phi_1, \Phi_2, \dots$	: Otoregresif model parametreleri
$Y_{t-1}, Y_{t-2}, \dots$	: Gözlem değerleri
$a_t, a_{t-1}, a_{t-2}, \dots$	: Hata değişkeni
$\theta_1, \theta_2, \dots$	: Hareketli ortalamalar modeli parametresi
x	: YSA girişi
w	: Ağırlıklar
u	: Lineer toplayıcı çıkış
b_k	: Bias terimi
v	: Aktivasyon fonksiyonu girişi
ϕ	: Aktivasyon fonksiyonu
a	: Sigmoid fonksiyonu eğim parametresi
y	: YSA çıkışı
d	: İstenen çıkış
e	: Hata işareti
E	: Ani hata
E_{ort}	: Ortalama hata
δ	: Yerel gradyan
η	: Öğrenme hızı
α	: Momentum terimi
T	: Sıcaklık
D	: Öklit normu
g	: Öklit normu ağırlıkları
$\hat{T}_{mak}$	: Yük tahmini yapılacak günün maksimum sıcaklık değeri
$\hat{T}_{min}$	: Yük tahmini yapılacak günün minimum sıcaklık değeri
T_{mak}^p	: Araştırılan günün maksimum sıcaklık değeri
T_{min}^p	: Araştırılan günün minimum sıcaklık değeri
$\hat{G}_{\hat{u}n}$	: Yük tahmini yapılacak günün gün tipi değeri
$G_{\hat{u}n}^p$	: Araştırılan günün gün tipi değeri
$P_1, P_2, \dots, P_{24}$	: Tahmin edilen saatlik güç değerleri
$P_{1, \dots, 24}^k$	: Benzer günün saatlik güç değerleri
T_{mak}^k	: Benzer günün maksimum sıcaklık değeri
T_{min}^k	: Benzer günün minimum sıcaklık değeri
V_{mak}	: Gerçek değerlerin en büyük olanı
V_{min}	: Gerçek değerlerin en küçük olanı
A_{mak}	: En büyük normalizasyon değeri
A_{min}	: En küçük normalizasyon değeri
V	: Normalize edilecek değer
A	: Normalize edilmiş değer

YAPAY SİNİR AĞLARI İLE KISA DÖNEM YÜK TAHMİNİ

ÖZET

Kısa dönem yük tahmini, enerji üretim ve enerji yönetim sistemlerinin gerçek zamanlı kontrolü için en önemli adımlardan biridir. Enerji santralının ve generatör ünitelerinin çalışmasının planlanması ve üretimin minimum maliyette tutulması için kısa dönem yük tahminine gereksinim vardır.

Bu tez çalışmasında, Gölbaşı Bölgesi'ne ait gerçek güç verileri kullanılarak geriye yayılım algoritması ile eğitilen çok katmanlı yapay sinir ağı modeli ile ertesi günün 24 saatlik yük tahmini yapılmıştır. Yapay sinir ağı yönteminin etkinliğini ölçebilmek amacı ile geleneksel yöntemlerden regresyon analizi ile de tahminler yapılmıştır.

Yük tahmini modeli oluşturulmadan önce Gölbaşı Bölgesi'nin 2002 ve 2003 yıllarındaki yük karakteristikleri incelenmiştir. Yapılan inceleme sonucu kısa dönem yük tahmini için, maksimum sıcaklık, minimum sıcaklık ve gün tipi etkilerinin modele dahil edilmesi gerektiği sonucu çıkarılmıştır. Benzer gün, yük tahmini yapılacak günden önceki 30 gün ve geçmiş yılda yük tahmini yapılacak güne denk düşen günden önceki ve sonraki 30 gün, toplamda 90 gün arasında araştırılır. 90 gün içinde en uygun olanı öklit normundaki ağırlık faktörleri vasıtasıyla bulunmuştur. Ağırlık faktörleri ise 90 gün için kurulan çoklu regresyon modelinden bulunur.

Kısa dönem yük tahmini için, yapay sinir ağı modeli olarak ileri beslemeli çok katmanlı perseptron ağı kullanılmıştır. Yapay sinir ağının gizli katmanında sigmoid aktivasyon fonksiyonu, çıkış katmanında ise doğrusal aktivasyon fonksiyonu kullanılmıştır. Giriş katmanında 30, gizli katmanda 53, çıkış katmanında ise 24 nöron bulunmaktadır. Gizli katmandaki nöron sayısı, deneme yanılma yolu ile elde edilmiştir. Ağın giriş verileri, benzer günün saatlik güçleri (24 giriş), yük tahmini yapılacak günün maksimum ve minimum hava sıcaklıkları tahmini (2 giriş), yük tahmini yapılacak gün ile benzer günün maksimum ve minimum sıcaklıklar farkı (2 giriş), yük tahmini yapılacak günün gün tipi endeks (1 giriş) ve yük tahmini yapılacak gün ile benzer günün gün tipi endeksleri farkıdır (1 giriş). 24 çıkış nöronu ise 24 saatlik yük tahmini değerleridir.

Matlab 6.5 programında m-file dosyaları yaratılarak hazırlanan bilgisayar benzetim programı ile farklı mevsimlerdeki ve farklı gün tiplerindeki günler için yük tahminleri yapılmıştır. Sonuçlar gerçek güç değerleri ve regresyon analizi ile yapılan tahminler ile karşılaştırılmıştır.

Sonuçlar incelendiğinde yapay sinir ağı yönteminin regresyon analizi yöntemine göre daha iyi tahmin sonuçları verdiği görülmüştür. Bayram günlerinin tahmininde de yapay sinir ağı yöntemi ile regresyondan daha iyi sonuçlar elde edilmiştir. Ancak işlem zamanları karşılaştırıldığında, regresyon analizine ilişkin program yapay sinir ağı yöntemine göre çok daha kısa sürede yanıt vermektedir. Sonuç olarak, oluşturulan yapay sinir ağı ile yük tahmini modeli pratikte uygulanabilir bulunmuştur.

SHORT TERM LOAD FORECASTING WITH ARTIFICIAL NEURAL NETWORKS

SUMMARY

Short term load forecasting is an essential task for real time control of power supply and power system planning. It plays a key role for economic and secure operation of power systems. Short term load forecasting should be accomplished for planning of operation of generator units and power plants .

In this thesis, 24-hour ahead short term load forecasting with real actual data of Gölbaşı Region is examined by multilayer perceptron neural network. Also, short term load forecasting is applied with regression method to measure the effectiveness of artificial neural network method.

Load characteristic of Gölbaşı Region on years 2002 and 2003 studied before the load forecasting model established. As a result of this study maximum temperature, minimum temperature and day type factors are determined to construct the forecasting model. Similar day is searched from the past 30 days from the day before forecasted day and past 30 days before and after forecasted day in previous year. The best similar day is evaluated from euclidean norm with weight factors. Weight factors are determined by the least squares method based on regression model.

Multilayer feed forward artificial neural network model is used for short term load forecasting. The activation function on hidden layer is sigmoid and it is linear on output layer. There are 30 neurons on input layer, 53 neurons on hidden layer and 24 neurons on output layer. Input datas are, hourly load data of similar day (24 inputs), minimum and maximum temperature of forecasted day (2 inputs), minimum and maximum temperature deviation between similar day and forecasted day (2 inputs), day type of forecasted day (1 input) and deviation of day types of forecasted day and similar day (1 input). 24 output neurons are forecasted load values.

Load forecastings of different days on different seasons and different day types are examined on simulation program which is prepared with m-files of Matlab 6.5. Simulation results are compared with results of regression method and actual load values.

Studies show that, artificial neural networks performance is better than regression method. But, regression methods operation time is less than artificial neural networks operation time. As a result artificial neural network method is practically applicable to short term load forecasting problem.

1. GİRİŞ

Elektrik enerjisi üretimi, iletimi ve dağıtımındaki amaç, enerjinin tüketicilere ucuz ve kaliteli olarak ulaştırılmasıdır. Kişi başına düşen elektrik tüketimi, çeşitli ölçütlerin yanı sıra, ülkelerin gelişmişlik durumlarını da açıklamakta kullanılan önemli bir faktördür.

Tüketicilere ekonomik, güvenilir ve kaliteli elektrik enerjisi sunabilmek için mevcut olan elektrik enerji sistemlerinin gelecekteki elektrik enerjisi ihtiyacını ve puant yükü karşılayabilecek şekilde büyütülmesi gerekmektedir.

Enerji sisteminin planlamasının ilk adımı ve en önemli adımlarından biri yük tahminidir. Enerji sistemin planlaması, yük tahminini farklı zaman dilimleri için, ayrı ayrı ele almayı gerektirir.

Kısa dönem yük tahmini, üretim birimlerinin çalışma programlarının hazırlanmasında, bakım programlarının kontrol edilmesinde kullanılır. Generatörlerin devreye girip çıkması kısa dönem yük tahminleri ile belirlenir. Enerji santralleri arasında yük paylaşımı, en uygun ünitenin belirlenmesi ve ekonomik işletmenin yapılabilmesi açısından kısa dönem yük tahmininin büyük önemi vardır. Kısa dönem yük tahmininde genellikle, yük eğrisindeki puant yük değerleri gerçek zamanlı olarak önceden görülmeye çalışılır. Kısa dönem yük tahmini, bir saatten başlayıp bir aylık periyoda kadar yapılabilir.

Enerji sistemlerinin operasyonundaki büyük önemi neticesinde, kısa dönem yük tahmininin doğruluğu da büyük önem taşımaktadır. Bu sebeple, literatürde, kısa dönem yük tahminindeki doğruluğu artırma hedefi ile öne sürülmüş çok çeşitli çalışmalar bulunmaktadır. Bugüne kadar yapılan çalışmalarda, regresyon analizi ve zaman serileri gibi geleneksel yöntemlerden; uzman sistemler, bulanık mantık, yapay sinir ağı gibi akıllı sistem örneklerine kadar çok farklı yöntemler uygulanmış ve denenmiştir.

Bu tez çalışmasında, kısa dönem yük tahmini problemine yapay sinir ağları yöntemi ile çözüm getirmek amaçlanmıştır. Yapay sinir ağlarının kullanılmasının nedeni,

özellikle doğrusal olmayan problemlerin çözümünde, geleneksel yöntemlere nazaran gösterdikleri performans ve eğitim için kullanılan sınırlı sayıdaki değerlerden hareketle genelleme yapabilme yetenekleridir. Kısa dönem yük tahmininde de yük ile sıcaklık arasındaki doğrusal olmayan ilişkinin çözümlenmesinde, yapay sinir ağı yöntemi, geleneksel yöntemlere göre daha başarılıdır.

Yapay sinir ağları ile kısa dönem yük tahmini çalışması, Gölbaşı Bölgesi'ne (orta anadolu) ait gerçek güç verileri ile yapılmıştır.

Literatürde kısa dönem yük tahmini ile ilgili yapılmış çalışmaların başlıcaları aşağıda sıralanmıştır:

[1] numaralı kaynakta, geniş bir enerji sisteminin kısa dönem yük tahmini için farklı yapay sinir ağı yapıları denenmiştir. 24 saatlik yükün eşzamanlı tahmin edildiği statik yaklaşım yöntemi ve 24 saatlik yükün peş peşe tahmininin yapıldığı dinamik yaklaşım yöntemleri karşılaştırılmıştır. Dinamik yaklaşımın kullanıldığı yöntemde, nöron sayıları ve ağırlık sayıları daha az olduğundan daha hızlı öğrenmiştir ve daha iyi yanıt vermiştir.

[2] numaralı kaynakta, ertesi günün yük tahmini için 63 girişli, 24 çıkışlı çok katmanlı ileri beslemeli yapay sinir ağı modeli uygulanmıştır. Giriş değişkenleri olarak bir gün önceki ve iki gün önceki 24 saatlik güç değerleri (48 giriş), hava sıcaklıkları (8 giriş) ve gün tipi (7 giriş) kullanılmıştır. Ayrıca bayram günlerindeki yük tahmini için farklı bir model çıkarılmıştır. Önerilen yöntemler Yunanistan Enerji Sistemi'nin gerçek verileri ile denenmiştir.

[3] numaralı kaynakta, bayram ve özel günlerin tahminindeki doğruluğun artırılması amacıyla, Kohonen ağı ve çok katmanlı perseptron ağı bir arada kullanılmıştır. İtalya şebekesinin verileri ile yapılan denemelerde, öne sürülen bu eğitici ve eğiticili ağ kombinasyonunun normal çok katmanlı perseptron ağına nazaran özel günler için daha iyi sonuç verdiği görülmüştür.

[4] numaralı kaynakta, yapay sinir ağı modelinin sistem bağımlı ve/veya durum bağımlı olup olmadığının araştırması yapılmıştır. Bunun için, Asya ve Amerika kıtalarındaki iki farklı yük karakteristiğindeki bölgeler için, 1 saat sonrasının ve ertesi günün 24 saatlik yük tahmini için farklı modeller oluşturulmuştur. 1 saat sonrasının tahmini için, her şebekede, farklı ağ yapılarıyla oluşturulmuş modeller daha uygun sonuç vermiştir. Fakat, ertesi günün 24 saatlik yük tahmininde, aynı

yapay sinir ağı modeli, her iki şebekeye de uygun sonuç vermiştir. Farklı yük karakteristiği olan sistemler için farklı ağ yapılarının uygun yanıtlar verebileceği sonucu çıkarılmıştır.

[5] numaralı kaynakta, kontrol merkezindeki uzman operatörün, deneyimleri ile yönetebileceği yeni bir ARIMA yapısı kullanılarak, kısa dönem yük tahminine farklı bir yaklaşımda bulunulmuştur. Yöntemin İran şebekesi verileri ile test edilmesiyle uygun sonuçlar elde edilmiştir.

[6] numaralı kaynakta, regresyon tabanlı puant yük tahmini yapılmıştır. Bağlı nem, son iki günün ortalama sıcaklığı ve yük tahmini yapılacak günün maksimum sıcaklığı regresyon parametresi olarak sisteme dahil edilmiştir. Mevsimsel etkilerden dolayı yük karakteristiğinin doğrusal olmadığı ilkbahar ve sonbahar aylarındaki tahminler için bir dönüşüm tekniği kullanılarak, doğrusallık sağlanmaya çalışılmıştır. Yöntemin sonuçları Tokyo elektrik şebekesinde denenmiştir.

[7] numaralı kaynakta, kısa dönem yük tahmini için kısmi bağlantılı yapay sinir ağı modeli kullanılmıştır. Yapay sinir ağında geriye yayılım algoritması ile eğitilen 1 adet ana, 3 adet yardımcı ağ bulunmaktadır. Geriye yayılım algoritmasındaki öğrenme hızı teriminin değerinin belirlenmesi için adaptif bir yöntem uygulanmıştır. Böylelikle eğitim süresi kısaltılabilmektedir.

[8] numaralı kaynakta, ertesi günün 24 saatlik yük tahmini için radyal tabanlı yapay sinir ağı modeli kullanılmıştır. Optimal performansını yakalaması için giriş değişkenlerinin seçimi ve parametre ayarı, radyal tabanlı yapay sinir ağı tarafından yapılmıştır.

[9] numaralı kaynakta, ertesi günün yük tahmini için benzerlik tabanlı bir yöntem sunulmuştur. Kullanılan çok katmanlı perseptronun giriş parametrelerini benzer günün 24 saatlik güç verileri, yük tahmini yapılacak günün maksimum ve minimum sıcaklıkları, yük tahmini yapılacak gün ile benzer günün minimum sıcaklık ve maksimum sıcaklık farkları oluşturulmaktadır.

Bu tez çalışmasında da aynı model temel alınmıştır. Yukarıdaki çalışmaya ilaveten, bayram günlerinin ve özel günlerin tahminindeki doğruluğu arttırmak amacıyla, yapay sinir ağı girişine gün tipi girişleri eklenmiştir. Benzer günün seçiminde kullanılan modele de gün tipi bilgisi eklenerek, benzer gün seçimindeki doğruluk artırılmıştır.

Tez çalışmasının ikinci bölümünde kısa dönem, orta dönem, uzun dönem ve çok kısa dönem yük tahmini konuları, yüklerin sınıflandırılması ve yükü etkileyen faktörler konuları anlatılacaktır. Yük tahmini çalışmasının yapıldığı Gölbaşı Bölgesi'nin yük karakteristiği incelenecek ve Bölüm 6'da yapılacak uygulama çalışmasına zemin hazırlanacaktır.

Üçüncü bölümde kısa dönem yük tahmininde kullanılan diğer yöntemlerden bahsedilecektir.

Dördüncü bölümde yapay sinir ağları konusu, beşinci bölümde de bu tez çalışmasında kullanılan geriye yayılım algoritması anlatılacaktır.

Altıncı bölümde, yapılan kısa dönem yük tahmini uygulaması ve bilgisayar benzetimi anlatılacaktır. Yük tahmin modelinin oluşturulması, benzer günlerin seçilmesi, yapay sinir ağı modelinin oluşturulması ve gerçekleştirilmesi, bilgisayar benzetim programının çalışması detaylandırılacaktır.

Yedinci bölümde ise uygulamadan çıkarılan sonuçlar ve öneriler verilecektir.

2. YÜK TAHMİNİ

2.1 Giriş

Elektrik enerjisinin üretimi, iletimi, dağıtımı ile yükümlü bulunan kuruluşların başlıca amacı, üretilen enerjinin tüketicilere ucuz ve kaliteli olarak sunulmasıdır. Kaliteli enerji de sürekli olmalı ve harmoniksiz, sabit sinüs şeklinde gerilim sağlamalıdır. Elektrik enerji sisteminde bulunan çeşitli tüketicilerin gereksinim duyacakları elektrik enerjisinin bu nitelikleri sağlaması gereği, oldukça zorluk getirmekte ve bütün ülkelerde ulusal yatırımların önemli bölümünün elektrik enerji sektörüne ayrılmasını zorunlu kılmaktadır. Bundan dolayı elektrik enerji sisteminin planlanması, ekonomik, güvenilir, geleceğe yönelik ve esnek olmalıdır.

Elektrik enerji sistemi planlamasının ilk adımı, gelecekteki yük ihtiyacının tahminidir. Etkili bir sistem planlaması için, puant yük ve enerji ihtiyacının tahmin edilmesi gereklidir.

Elektrik enerji sistemlerinin planlama ve kurulmasında mühendislik yönünden başlıca iki önemli unsur olduğu söylenebilir. Bunlardan birincisi yeterlilik, ikincisi ise güvenilirliktir. Yeterlilik, puant yükte tüm tüketici merkezlerinin güç gereksinimlerini karşılayabilmek için yeterli üretim ve iletim kapasitesinin sağlanması, güvenilirlik ise herhangi bir arıza sonucu sisteme gelecek bir darbenin, bir zincirleme arızalar dizisine yol açmasının ve böylece sistemin çökmesinin önlenmesi şeklinde açıklanabilir. Yukarıdaki kriterleri sağlamanın öncelikli koşulu doğru yük tahmini yapmaktır.

Gereğinden düşük yük tahminlerine dayalı yapılan planlama, sistemin güvenilirliğinin azalmasına, tüketiciye sunulan enerji arzının kısıtlanmasına ve enerji kalitesinde düşmelere neden olacaktır. Gerektiğinden fazla yük tahminlerine dayalı yapılan planlama ise tam kapasite ile hizmet veremeyen, düşük kapasiteyle çalışan ve dolayısıyla ekonomik olmayan işletme koşullarına neden olacaktır. Bu durumda sisteme yapılan büyük ölçekli yatırımlar enerji kurumu içinde önemli mali sonuçlar ortaya çıkaracaktır [10].

2.2 Yk Tahmininin Zamana Gre Sınıflandırılması

Elektrik enerjisi planlaması, ekonomik ve sosyal hedeflerle uyumlu bir şekilde, yerinde, zamanında, istenen kalite seviyesiyle, gvenilir ve en dřk maliyette ve yeterli olması gereęi gz nne alınarak yapılır. Elektrik enerji sistemi planlamasının ilk adımı olan yk tahmini de, planlama gereęince farklı zaman dilimleri iin ayrı ayrı yapılır. Yk tahmini, enerji sisteminin planlanmasına baęlı olarak: kısa, orta, uzun dnem tahminler olmak zere alt dnemlere ayrılarak yapılır.

-Uzun dnem yk tahmini

-Orta dnem yk tahmini

-Kısa dnem yk tahmini

-ok kısa dnem yk tahmini

2.2.1 Uzun Dnem Yk Tahmini

Uzun dnem yk tahminleri,  yıldan daha uzun sreli olup otuz yıllık bir periyodu da kapsayabilen tahminlerdir. Tahmin sresinin uzunluęuna baęlı olarak, yapılan tahminin doęrulundaki belirsizlik artar.

Uzun dnem yk tahminleri ile enerji puant g tahminleri yapılarak, eldeki retim kapasitelerinin bu talebi karřılayıp karřılamadıęı arařtırılır. Talebin karřılanabilmesi iin potansiyel enerji kaynakları (termik, hidrolik, nkleer) belirlenir. retim yerleri belirlenip enerji sistemi geliřimi iin modeller hazırlanır.

Tketicilere ekonomik, gvenilir ve kaliteli elektrik enerjisi sunabilmek iin mevcut olan elektrik enerji sistemlerinin gelecekteki elektrik enerji ihtiyaını ve puant yk karřılayabilecek şekilde bytlmesi gerekmektedir. Enerji santrallarına yapılması gereken eklemeler ve yeni sistemlerin kurulması, puant gler gz nne alınarak, ngrlen enerji talebini karřılamak zere belirlenir. Ayrıca duruma gre tesis tipleri ve bu tesisler iin retim olanakları arařtırılır. Yk tahminleri sonucuna gre retimle birlikte iletim ve daęıtım sistemlerine yapılması gereken kapasite eklemeleri ile bu eklemelere iliřkin yatırım maliyetleri belirlenmektedir.

Uzun dnem yk tahminleri zellikle ekonomik ve sosyal verilere dayandıęı iin, blgenin enerji talep tahmini bu veriler gz nne alınarak yapılır. Bu veriler tketic

tipine bağılı olarak nüfus, gayri safi milli hasıla, kiři bařına milli gelir, sanayi gelişim hızı (üretim endeksi) gibi deęişkenlerdir.

Uzun dönem tahminlerde belirsizliklerin ve deęişkenlerin fazla olması nedeniyle hatalar olabilecektir. Tahminlerin doęruluęu kesin bir şekilde belirtilmez, fakat hataların meydana getireceęi olası sorunlar göz önüne alınır. Gerçek talep ve enerji tahminlerindeki hataların sonucunun süresi ve etkisi sistem üzerinde etkili olacaktır. Bu hataların en aza indirilmesi için eldeki veriler arttıkça tahminlerin güncellenmesi gerekir [10,11].

2.2.2 Orta Dönem Yük Tahmini

Orta dönem yük tahmini, sonucu doęrultusunda, fiziksel donanımların planlanmasının ve bakım programlarının yapıldıęı dönemdir. Bir aylık bir dönemden üç yıllık bir periyoda kadar uzanabilir. Enerji talebinin artışına bağılı olarak yeni tesislerin kurulması; iletim ve dağıtım sistemlerine yapılacak olan eklemeler ve bu sistemler için koruma ve kontrol sistemlerinin tasarımı gibi planlama çalışmaları için orta dönem yük tahminine ihtiyaç vardır. Hidroelektrik sistemler için, akarsu akış koşullarının incelenmesi ve su haznesi tutulması, su miktarının karşılaştırılması, termik sistemler için gerekecek yakıt miktarının kontrolü ve temini gerçekleştirilir. Ayrıca satış tarifelerinin oluşturulması ve puant yükler için kısa sürede devreye alınabilecek santrallerin planlanması orta dönem yük tahmini çalışması ile yapılır. Toplu planlama çalışmalarına girişilmesi ve ekonomik incelemelerin yapılabilmesi için uygun bir dönemdir [12].

2.2.3 Kısa Dönem Yük Tahmini

Kısa dönem yük tahmini, üretim birimlerinin çalışma programlarının hazırlanmasında, bakım programlarının kontrol edilmesinde kullanılır. Generatörlerin devreye girip çıkması kısa dönem yük tahminleri ile belirlenir. Genellikle, yük eğrisindeki puant yük deęerleri gerçek zamanlı olarak önceden görölmeye çalışılır. Bu tahmin yönteminde en önemli veri hava koşullarıdır. Kısa dönem yük tahmini, bir saatten başlayıp bir aylık periyoda kadar yapılır.

Elektrik enerji sistemlerinin çalışmasında, sistem yükünün üretimi yakından takip etmesi en temel beklentilerden biridir. Sistem için ekonomik çalışma ve etkin

kontrolün sağlanması için, bunun geniş ve farklı zaman aralıklarında gerçekleşmesi gerekmektedir.

Yük değişimlerinin çok küçük olduğu saniyeler mertebesinde, üretimin yüke denk olmasının otomatik üretim kontrolü (automatic generation control) sağlar. Daha büyük yük değişimlerinin mümkün olduğu dakikalar mertebesinde, yükün üretim kaynakları arasında ekonomik paylaşılması, ekonomik dağıtım (economic dispatch) fonksiyonu ile gerçekleştirilir. Saat ve gün mertebesinde ise yük değişimi daha da artar. Bu çerçevede, yük – üretim dengesini sağlamak için, generatör ünitelerinin devreye girip çıkma durumu veya komşu sistemler ile enerji alışverişi söz konusu olabilir. Bunlar, hidrolik planlama (hydro scheduling), birim tahsisatı (unit commitment), hidrotermal koordinasyon (hydro-thermal coordination), değişim değerlendirme (interchange evaluation) gibi birtakım üretim kontrol fonksiyonu ile sağlanabilir. Yükteki salınımların çok daha geniş olduğu haftalar mertebesinde, yükün mevcut kaynaklardan en ekonomik şekilde karşılanması için; yakıt, hidrolik ve bakım planlaması gerçekleştirilir.

Bunlarla beraber, elektrik enerji sisteminin gelecekte güvenilir çalışmasının sağlanması için off-line şebeke analiz fonksiyonları ile belirlenmiş çeşitli olasılık koşulları altındaki davranışının incelenmesi gereklidir. Ancak bu analiz fonksiyonun sistem yükü bilgisine ihtiyacı vardır. Gerçek zaman koşullarında her baradaki gerilimin genliği ve açısını kestirim değerlerinden, ölçümlerin geçerli kılınması için durum kestirimi (state estimation) kullanılır. Bu değerler, anlık yük için kestirimin hesaplanması için gereklidir. Saniyeler ve dakikalar öncesi için çok kısa dönem yük tahmini prosedürlerini, otomatik üretim kontrol ve ekonomik yük dağıtım fonksiyonlarının içine girmiştir. Hidrolik planlama, birim tahsisatı, hidrotermal koordinasyon ve değişim değerlendirme fonksiyonları için gereken yük bilgisi ise kısa dönem yük tahmininden sağlanır. Yakıt ve hidrolik paylaşımı ve bakım planlaması için bir haftadan fazla periyotlar için yük tahmini gereklidir.

Elektrik enerji sisteminin ekonomik ve güvenilir işletim stratejilerinin oluşturulmasında kısa dönem yük tahmininin anahtar rolü vardır. Kısa dönem yük tahmininin temel amacı:

- temel üretim planlama fonksiyonları
- enerji sisteminin her an için güvenilirliğinin değerlendirilmesi

- zamanında dağıtım bilgisi

için yük tahminlerinde bulunmaktadır.

Kısa dönem yük tahmininin başlıca uygulaması; güvenilirlik koşulları, işletme sınırlamaları ve politikaları, fiziksel, çevresel ve ekipman sınırlamalarını da dikkate alarak üretim kaynaklarının en ekonomik işletimini belirleyen planlama fonksiyonlarını yürütmektir.

Tek başına çalışan hidrolik sistemler için, yük tahmini, su rezervinden optimal su tahliyesi ve üretim seviyelerini belirleyen hidrolik planlama, fonksiyonu için gereklidir.

Tek başına çalışan termik sistemlerde, tahmin yükünü sağlamak amacıyla ünitelerin devreye girip çıkması için saatlik minimum maliyet stratejilerini belirleyen birim tahsisatı fonksiyonunun yük tahminine gereksinimi vardır.

Termik ve hidroliğin birlikte olduğu sistemlerde, üretim maliyetini minimize etmek amacıyla kaynakların saatlik işletiminin planlamasını yapan hidrotermal koordinasyon fonksiyonu yük tahminine ihtiyaç duyar.

Bu fonksiyonların sistem işletmesi üzerine getirilen çeşitli sınırlamalarla karşı karşıya olan minimum maliyetle işletme planları için ertesi gün yada ertesi haftanın yük tahminine gerek vardır.

Kısa dönem yük tahmininin ikinci bir uygulaması ise, elektrik enerji sisteminin güvenilirliğinin tahminsel değerlendirilmesidir. Yük tahmini enerji sisteminin savunmasız kalabileceği koşulların tespitini sağlayan off-line şebeke analizi için de temel bilgi kaynağıdır. Bu çalışmalar dağıtıcının önemli düzeltici faaliyetleri (puant birimleri devreye alma, yük atma, enerji satın alma, anahtarlama işlemleri vb.) hazırlamasına ve uygulamasına yardımcı olur. Böylelikle sistem daha güvenli çalışmaya devam eder.

Kısa dönem yük tahmininin üçüncü uygulaması, dağıtıcıya anlık bilgiler sağlamasıdır. En yakın yükün tahmini, en son hava tahminleri ve hesaba katılan rastlantısal faktörler bu bilgiler arasında yer alır. Dağıtıcıların ekonomik ve güvenilir bir sistem işletmesi için bu bilgilere gereksinimi vardır.

Kısa dönem yük tahmininin doğruluğunun, enerji sisteminin çalışmasında ve üretim maliyetinde önemli etkisi vardır. Sistem dağıtıcısı, sistem yük bileşenlerini önceden

bilmeli ki, talebi karşılamak için yeterli üretim yapılabilirsin. Aynı zamanda tahminin doğasında bulunan belirsizlikleri hafifletmek için her zaman yeterli seviyede yedek rezerv hazır tutulmalıdır.

Rezervleri oluşturan üniteler tam yüklenmedikçe, rezervlerin maliyeti yüksek kalacaktır ve sonuç olarak maksimum verimlerinin altında kalacaklardır. Yedek rezerv kapasiteleri, o sistem için arzulanan güvenilirlik ölçütünde, belirlenen seviyede tutulur. Tahmin hatalarını azaltarak sistem güvenilirliğini etkilemeden, rezerv seviyesi düşürülebilir. Böylelikle sistem verimi artacak ve maliyet de düşecektir.

Yük tahmininde oluşan hatalar, artan işletme maliyetine neden olur. Tahminin yük talebinden düşük hesaplanması sonucu rezervlerin kullanılması, puant birimlerin kullanılmasından daha fazla maliyete yol açacaktır. Diğer taraftan tahminin yük talebinden fazla hesaplanması sonucu fazlaca ünitenin devreye alınması gereksiz yere rezerv artışına, dolayısıyla, işletme maliyetinin de yükselmesine neden olacaktır.

Modern enerji yönetim sistemlerinde, manuel yük tahmini hesaplamaları artık yerini kısa dönem yük tahmini yazılım paketlerine bırakmaktadır [9,13,14].

2.2.4 Çok Kısa Dönem Yük Tahmini

Bir saatten daha kısa süreler için yapılan tahminler, çok kısa dönem yük tahmini olarak adlandırılırlar. Çok kısa dönem yük tahmininin amacı, işletme kontrol merkezlerindeki operatöre, talep probleminde yol açacak yük artış eğiliminin meydana gelip gelmeyeceği bilgisini vermektir. Bu durumda üretim-yük dengesini bozmamak amacıyla acil bir karar alınıp işletilmesi gerekir. Bu durum ile, çoğunlukla puant olarak nitelendirilen 17:00-22:00 saatleri arası sistemin aşırı yüklendiği zamanlarda karşı karşıya kalınır [15].

Enterkonnekte enerji sistemlerinde, otomatik üretim kontrol sisteminin başlıca amacı:

- 1- Üretimin yük ile örtüşmesi,
- 2- Sistem frekansı ve net alan güç değişim değerlerinin önceden belirlenmiş değerlerine regüle edilmesi,
- 3- Mevcut kaynaklardan, üretimin ekonomik olarak sağlanmasıdır.

Generatör devir sayısı regülatörünün ani yük değişimlerine birincil yanıtı, bir dakikaya yakın süre içinde yükte bozulmalarla beraber gelir. Bu yanıt otomatik üretim kontrol sisteminin birinci amacını sağlar ancak governor ayar faktöründen dolayı sistem frekansı ve net alan güç değişimi “yarı sürekli durum” tipi hatalara maruz kalır. Bu yüzden enerji yönetim sistemindeki yük frekansı kontrol (load frequency control) fonksiyonu, birkaç dakika içerisinde belirlenmiş frekans ve net alan güç değişim değerlerini yerine getirerek ikinci amacı da sağlamış olur. Üçüncü amaç ise ekonomik dağıtım fonksiyonu tarafından gerçekleştirilir.

Yük frekansı kontrolü ve ekonomik dağıtım, yalnızca yük bozulmalarında yada belirlenmiş frekans ve net alan güç değişim değerlerinde önemli sapmalar oluştuğunda yanıt verir. Bu yüzden, daha yüksek derecede ayar yöntemine gereksinimleri vardır. Yük talebinin anlık tahminlerine dayalı yük frekansı kontrol sistemi geliştirilmiştir. Ancak, yük talebindeki dalgalanma hızının üretim arz hızına hızına göre daha yüksek olması, anlık yük tahminlerinin yetersiz kılar. Yeterli bir yük frekansı kontrolü için, ileriye dönük bakışa gereksinim vardır. Yük frekansı kontrol stratejilerinin daha iyi tasarlanması için çok kısa dönem yük tahmini çalışması sonucu elde edilen 15-30 dakikalık yük eğilimleri bilgisi faydalı olacaktır [16-17].

2.3 Yüklerin Sınıflandırılması

Yük tahmini yapılırken, tüketicilerin hangi gruba dahil olduğu dikkate alınmalıdır. Farklı gruplardaki tüketicilerin, elektrik enerjisi tüketimi ve yük karakteristikleri farklılık göstermektedir.

Tüketicilerin sınıflandırılması ile ilgili düzenlemeler Elektrik Piyasası Tarifeler Yönetmeliği esas alınarak yapılır. Elektrik enerjisi satış esasları, elektrik enerjisinin satış tarifelerinin belirlenmesi, tüketici grupları ve bu tüketicilere uygulanacak elektrik enerjisi satış tarifi bu yönetmelikte ayrıntılı olarak bahsedilmiştir. Buna göre abone grupları şu şekilde belirlenmiştir:

A) Mesken: Mesken olarak kullanılan müstakil binalar, apartmanlar ve apartmanlar içindeki bağımsız bölümler, konut kooperatifleri ve sitelerdir. Bu yerlerin kalorifer, asansör, hidrofor tesisatları için kullanılan elektrik motorları, merdiven otomatığı,

kapıcı dairesi ve bunun gibi elektrik enerjisi tüketimi ayrı sayaç ile ölçülen ortak kullanım yerleri bu abone grubunda değerlendirilir.

B) Sanayi: 6948 sayılı Sanayi Sicili Kanununda tanımı yapılan sanayi işletmeleridir. Sanayi ve Ticaret Bakanlığının olumlu görüşünü ifade eden belgeyi almaları şartıyla şantiye dönemi de dahil olmak üzere sanayi abonesi olarak kabul edilirler. Haddehaneler, soğuk hava deposunun buz üreten tesisleri bu gruba dahil edilirler.

C) Endüksiyon ve Ark Ocakları: Endüksiyon ve ark ocaklı potaları bulunan tesislerdir. Endüksiyon ve ark ocaklı tesislerin endüksiyon ergitme ocağı, ark ocağı, pota ocağı, toz tutma tesisi ve oksijen tesisi ve bu birimlerin aydınlatması.

D) İçme ve Kullanma Suyu: İl, İlçe, Belde ve Köylerin içme ve kullanma suyunu sağlamak için kamu tüzel kişilikleri ve içme suyu birlikleri tarafından kurulmuş olan elektrik tesisleridir.

E) Ticarethane, Yazıhane, Resmi Daire, Şantiye ve Geçici Aboneler:

a)Ticaretane ve Yazıhane: Tüccar, esnaf ve serbest meslek sahiplerinin faaliyetlerini yürüttükleri; ticarethane, ofis, atölye, depo, ardiye, yazıhane, muayenehane, laboratuvar ve benzeri yerler, özel ve vakıf sağlık kuruluşları (hastane, poliklinik, sağlık ocağı ve dispanserler) kamu yararına çalıştığına veya vergi muafiyeti tanındığına ilişkin Bakanlar Kurulu Kararı olmayan dernekler ve vakıflar, parti binaları, sendika binaları, özel okullar, vakıf okulları, dersaneler, yurtlar, 2634 sayılı Turizm Teşvik Kanununda belirtilen turizm belgeli yatırım ve işletmeler dahil, turistik otel, otel, motel, pansiyon, kamping ve devremülk işletmeleri, soğuk hava depoları, seralar, matbaalar, et entegre tesisleri, kesimevleri, fırınlar (hamur pişiren), GSM baz istasyonları, iş merkezleri ve iş hanlarındaki ortak kullanım yerleri.

b) Resmi Daire: 1050 sayılı Muhasebe-i Umumiye Kanun'una tabi genel ve katma bütçeli dairelerin bürolarıyla kamu kurum ve kuruluşlarının ticari olmayan bürolarıdır. Bu kuruluşların üretime yönelik tesisleri aynı bina dahilinde olsa bile sanayi abone grubuna dahil edilirler.

c) Şantiye ve Geçici Aboneler: İnşaat, maden arama, çeşitli amaçlarla kazı yapma ve bunun gibi nedenlerle gerçek yada tüzel kişilerin bu etkinliklerini sürdürmek için veya bu etkinliklerini sürdürmeyi sağlayacak kalıcı tesislerin tamamlanmasıyla varlığı sona erecek olan geçici tesisler ile İl, İlçe, Belde ve Köylerde gezici olarak kurulan sergi, fuar, sirk ve panayırıdır.

F) Hayır Kurumları, Dernekler, Vakıflar, Müzeler, Resmi Okullar, Resmi Yurtlar, Resmi Üniversite, Resmi Yüksek Okullar, Resmi Kurslar, Resmi Sağlık Kuruluşları, Spor Tesisleri, Kültür Balıkçılığı ve Kümes Hayvanları Çiftliği:

a) Hayır Kurumları, Dernekler, Vakıflar, Müzeler, Resmi Okullar, Resmi Yurtlar, Resmi Üniversite ve Resmi Yüksek Okullar, Resmi Kurslar ve Resmi Sağlık Kuruluşları.

b) Spor Tesisleri: Kamu spor görevini yüklenmiş resmi kuruluşların spor tesisleridir.

c) Kültür Balıkçılığı ve Kümes Hayvanları Çiftliği.

G) Aydınlatma:

a) **İbadethane Aydınlatması:** Toplumun ibadetine açılmış ve ücretsiz girilen yerlerdir

b) **Genel Aydınlatma:** İl, İlçe, Belde ve Köylerdeki, cadde, sokak ile kamuya ait ücretsiz girilen park ve bahçe gibi halka açık yerlerin aydınlatılmasıdır.

c) **Karayolları Aydınlatması:** Karayolları Genel Müdürlüğüne ait paralı yollar ile meskun mahaller dışındaki yollar, köprüler ve tünellerin aydınlatmalarıdır.

H) Şehit Aileleri ve Muharip/Malul Gaziler

İ) Tarımsal Sulama Tesisleri: Tarımsal sulama için kurulmuş sulama kooperatifleri, pompaj tesisleri ile münferit olarak tesis edilmiş tarıma dayalı arazilerin sulanmasını sağlayan elektrik tesisleridir.

J) Arıtma Tesisleri : Çevre ve insan sağlığını korumak üzere içme suyu ve alıcı ortama verilen sıvı, gaz ve katı zehirli ve zararlı atıkların arıtılması amacıyla kurulan tesislerdir.

K) Tarımsal Amaçlı Soğuk Hava Depoları [18]

Yukarıdaki sınıflandırma farklı tüketicileri tarifelendirme amacıyla yapılmıştır. Yüklerin karakteristiklerini inceleyebilmek için sınıflandırmayı şu şekilde indirgeyebiliriz:

1. Mesken yükleri
2. Ticari yükler
3. Sanayi yükleri

4. Tarımsal sulama
5. Aydınlatma
6. Diğer yükler

Mesken tipi tüketiciler enerjiyi evdeki ihtiyaçlarını karşılamak amacıyla kullanırlar. Nüfus artışı ve göç olayları nedeniyle mesken yükleri yıllık sabit bir büyümeye sahiptir. Özellikle yoğun göç alan bölgelerde mesken yükünde aşırı artışlar gözlemlenmektedir. Mesken yüklerinin günlük ve yıllık yük eğrileri incelendiğinde, mevsimlik değişimlerden çok fazla etkilendiği görülür. Görülen bu mevsimlik değişimler toplam sistem yükünde de mevsimlik değişimlere yol açmaktadır. Yaz aylarında soğutma, kış aylarında ise ısıtma amaçlı cihazların kullanılması yükün karakteristiğini önemli ölçüde etkilemektedir. Özellikle gecekondü bölgelerinde kaçak elektrik kullanma oranı yüksek olduğu için bu kesimdeki halkın ısınma ihtiyacını elektrikli ısıtıcılar kullanarak gidermeleri nedeniyle mesken yükünde dengesiz artışlar görülebilir. Ayrıca mesken yüklerinin elektrik enerjisi tüketimi, bölgenin refah seviyesine ve insanların kullanım alışkanlıklarına göre de bölgesel olarak farklılık gösterebilir. Bununla beraber meskenler için elektrik tüketiminde esas olan bireyler olduğu için insan psikolojisi de devreye girer. Sosyal ve kültürel olaylar, tatiller, televizyon programları, popüler diziler de yükü etkileyebilir. Gelecekte güneş, rüzgar gibi alternatif enerji teknolojisinde oluşacak ilerlemeler, hava koşullarına duyarlı cihazların kullanımını ve dolayısıyla mesken tipi tüketicinin karakteristiğini etkileyecektir.


Ticari yüklerin enerji tüketimi mevsimlik etkilere bağlı olarak ısıtma ve soğutma amaçlı kullanımlar ve iş yerinin özelliğine bağlı olarak kullandığı elektrikli cihazların tüketimini kapsar. Ticari yüklerin enerji tüketimi mevsimlik etkilere bağlı olarak değişim gösterir.

Sanayi yükü, hava koşullarına bağlı olarak çok az değişim gösteren temel yükler olarak düşünülebilir. Ancak mevsimsel ve saatlik değişimlerden az, ekonomik değişimlerden ise çok etkilenirler. Sanayi yüklerinde, endüstri tipine bağlı olarak yük karakteristiği değişim gösterir. Sanayi kuruluşunun çalışma sistemi, vardiyalı olup olmaması, öğle yemeği ve çay molası saatleri de yük değişimini etkilemektedir. Bununla birlikte tesis içi arızalar ve grev gibi beklenmedik olaylar yükte tahmin edilemeyen değişikliklere yol açacağından, sanayi yüklerinin tüketiminde çoğu

zaman bir şüphe söz konusudur. Sanayi grubunda tüketilen enerji hem yıllık hem de aylık bazda bir değişim göstermektedir. Bu değişim daha çok yıllık bazda sanayiye yönelik yatırımlar neticesinde, hem sanayi ağırlıklı talep sayısındaki artış hem de talep edilen güçteki artıştan dolayı tüketilen enerjinin her geçen yıl artmasına sebep olmaktadır.

Tarım bölgelerinde elektrik enerjisi ihtiyacı ziraat işletmelerinin kendine has özelliklerinden dolayı çok değişir Zirai üretim bölgelerinde başlıca yükler hasat ve sulama zamanlarında genellikle gündüz saatlerinde baş gösterir. Mevsimlik değişimlerden büyük ölçüde etkilenir [10,12,19].

Tüm bu tüketim sınıflarının yüklerinin toplamı, toplam sistem yükünü verir. Toplam sistem yüküne, mesken ticarethane ve sanayi grubundaki değişimler yön vermektedir. Bölgenin net tüketimi şebeke kayıplarının brüt tüketime ilave edilmesi ile bulunur. Şekil 2.1’de bir yıllık elektrik enerjisi tüketiminin tüketici gruplarına göre dağılımı verilmiştir [20].



Şekil 2.1 2002 yılı Türkiye elektrik tüketiminin tüketici gruplarına göre dağılımı (MWh)

2.4 Yüğü Etkileyen Faktörler

Elektrik şebekesi, önceki bölümde bahsedilen farklı tüketim gruplarının birleşmesinden oluşur. Tüketimin büyük bölümü endüstri tüketicisinin aktiviteleri ile, diğer bir büyük bölümü ise bireylerin kullanımları ile oluşur. Yük tahminindeki genel yaklaşım, her bir yük grubuna ayrı ayrı değil de, genel yük dağılımına

konsantre olmaktır. Bu sebeple mesken yükünü etkileyen faktörlerin toplam sistem yüküne etkisi, sistemdeki konut yüzdesi ile orantılıdır. Sistem yükünün modellenebilmesi için, hangi koşulun yada faktörün yükü nasıl etkileyeceği anlaşılmalıdır. Yükü etkileyen en önemli faktörler şu şekildedir:

2.4.1 Meteorolojik Koşullar

Yük talebinin artmasında hava koşullarının önemli etkisi vardır. Bunun nedeni ısıtma, havalandırma, iklimlendirme, tarımsal sulama gibi hava şartlarının etkili olduğu yüklerin, toplam sistem yükünde belirli bir oranda bulunmasıdır [14]. Elektrik sistemlerinin kayıtları incelendiğinde bir çok sistemdeki puant yüklerin olağan dışı hava koşullarına denk düştüğü görülmektedir. Dünyanın bir çok yerinde kış puantı genellikle en yüksek puanttır. Özellikle sıcak ve nemli bölgelerde nem de sıcaklık gibi sistem yükünü etkiler. Sıcaklık ve nemin dışında, rüzgar hızı, yağış ve bulut yoğunluğunun da elektrik tüketiminde etkisi vardır.

2.4.2 Zaman Faktörü

Yük tahmini açısından bakıldığında zaman faktörü en önemli olandır. Mevsimsel etkiler ve dönemsel davranışlar (günlük ve haftalık ritimler) ile beraber resmi ve dini bayramlardan kaynaklanan tatiller de zaman faktörüne girer.

Yük eğrisinin yıllık, aylık, haftalık ve günlük bazda detaylı olarak incelendiği .Bölüm 2.5’de zaman faktörünün yüke etkisi daha iyi anlaşılabacaktır.

2.4.3 Ekonomik ve Demografik Faktörler

Uzun dönem yük tahmininde, yük talebinin belirlenmesinde en önemli faktörler ekonomik ve demografik faktörlerdir. Teknolojinin gelişmesi, kişi başına düşen gelirin yükselmesi gibi etkenlerle, elektrikle çalışan modern cihazların kullanımı yaygınlaşmakta ve elektrik tüketiminin artmasına neden olmaktadır. Nüfusun artması ile beraber yük talebi de doğru orantılı olarak artacaktır. Yeni ticarethane ve sanayi kuruluşlarının, mal ve hizmetlerdeki tüketimin artmasıyla üretimdeki özellikle sanayideki enerji ihtiyacının artmasına sebep olur.

Bu çalışmada sadece kısa dönem yük tahmini yapılacağından ekonomik ve demografik faktörler ele alınmayacaktır.

2.4.4 Rastlantısal Faktörler

Yükü etkileyen ve yukarıda sayılan faktörler ile açıklanamayan olaylar, rastlantısal faktörler olarak sınıflandırılırlar. Bunlar çoğunlukla bireysel tüketici bazındaki küçük olaylar olsa da, büyük sosyal olaylar ve popüler televizyon programları tahmine bir belirsizlik ekler. Diğer taraftan sanayi tesislerindeki arızalar ve grev gibi etkenler yükte büyük belirsizliklere yol açarlar .


2.5 Yük Eğrisinin Özellikleri

Günlük yük eğrisi, bir gün için 24 saat boyunca tüketilen güç değerlerini gösterir. Yük eğrisi, her birisi saatlik yük değeri olan gerçek sayıların zaman serisi olarak görülebilir.


Bu çalışmada, tüm faktörlerin doğru olarak gözlemlenebilmesi için 2 yıllık bir zaman aralığı incelenmiştir. Kullanılan veriler Gölbaşı Bölgesine (Orta Anadolu) ait gerçek güç değerleridir.

Şekil 2.2’de 1.Ocak.2003’den başlayıp, 31.Aralık 2003’e kadar devam eden 2003 yılına ait yük eğrisi verilmiştir. Şekilden mevsimsel farklılıklar ayırt edilebilmektedir. Kış ve yaz aylarında çekilen yük, bahar aylarına nazaran daha fazladır. Yıllık yük eğrisinde görülen, hava faktörünün etkisiyle oluşan mevsimsel ritimdir.


Şekil 2.3’de bir aya ait yük eğrisi verilmiştir. Bir ay dahilindeki 4 hafta, haftalık ritimler olarak rahatlıkla gözlemlenebilmektedir. Seyri diğer günlere göre daha düşük gözlemlenebilen saatler, hafta sonlarına denk düşen saatlerdir. Haftalık ritmi oluşturan da çoğu insanın uyduğu işgünü – hafta sonu farklılığıdır.



Şekil 2.2 Gölbaşı Bölgesi 2003 yılı yük eğrisi (MW)



Şekil 2.3 Gölbaşı Bölgesi 2002 Haziran ayı yük eğrisi (MW)




Şekil 2.4 Gölbaşı Bölgesi 12-18 Haziran yük eğrisi (MW)

Şekil 2.4’de pazartesi gününden başlayıp, pazar gününe kadar devam eden haftalık yük eğrisinden günlük ritimler gözlemlenebilmektedir. Pazartesi cumaya devam eden seri birbirine yakın beş örnekten oluşmaktadır. Cumartesi ve pazarı gösteren son iki gün ise, hafta içi günlerine göre farklılık göstermektedir. Hafta içi günleri sosyal aktiviteler hafta sonuna oranla daha yüksek seviyede olduğundan bu fark

doğmaktadır. Pazartesi ve cuma günlerine tekrar bakıldığında, bu günlerin hafta sonunun kapalılığından etkilenecek diğer iş günlerine (salı, çarşamba, perşembe) oranla elektrik tüketiminin daha az olduğu görülmektedir. Buradan anlaşılan pazartesi, cuma, cumartesi, pazar ve diğer iş günlerinin ayrı sınıflandırılması gerektiğidir.


Günlük ritimler, insanların gün boyunca bulundukları senkron davranışlar sonucu oluşur. Çoğu insan gece aynı saatlerde uyudukları için gece saatlerinde yük düşüktür. Aynı şekilde insanların çoğu tarafından aynı vakitlerde yapılan çalışmak, öğle yemeği yemek, televizyon seyretmek gibi aktiviteler vardır. Günlük ritim yıl boyunca değişir. Şekil 2.5’de farklı 4 mevsimden seçilen çarşamba günlerinin yük eğrileri gösterilmiştir. Mevsimsel farklılıklara göre yük eğrilerinde hafif farklılıklar gözlemlenmektedir.




Şekil 2.5 Gölbaşı Bölgesi için farklı dört mevsimden seçilen salı günlerinin yük eğrileri.(MW) (a) 15.01.2002 (Kış), (b) 16.04.2002 (İlkbahar), (c) 16.07.2002 (Yaz), (d) 15.10.2002 (Sonbahar)

Şimdiye kadar anlatılan takvimsel farklılıklardan başka, ayrı incelenmesi gereken özel günler vardır. Milli ve dini bayramlar özel günler olarak ele alınır. İşgünü – haftasonu farklılığı tüm ülkeler için global olarak gözlemlenmekle beraber, özel günler olarak sınıflandırılan günler, farklı ülkeler ve toplumlar için ayrılık gösterir.

Şekil 2.6’da Kurban Bayramı’nı içine alan 10 günlük periyodun yük eğrisi gösterilmiştir. Periyodun ilk günü pazartesidir. Dördüncü gün arife günü; beşinci, altıncı, yedinci ve sekizinci günler bayram günüdür. Şekil 2.7’de ise 23 Nisan Ulusal Egemenlik ve Çocuk Bayramı’nı içine alan haftanın yük eğrisi gösterilmiştir. Bayram günlerinin diğer günlerden farklı bir karakteristiğe sahip olduğu gözlemlenmektedir. Ancak, milli bayramlar ve dini bayramlar birbirleri ile karşılaştırıldığında, dini bayramlarda daha az yük çekildiği görülmektedir. Şekil 2.2’deki yıllık yük eğrisini tekrar inceleyecek olursak, yılın ilk ayları ve son aylarına yakın iki kez sistem yükünün çok düşük olduğu fark edilir. Şubat ayında gözlemlenen düşüş Kurban Bayramı’na, aralık ayında gözlemlenen düşüş ise Ramazan Bayramı’na karşı düşmektedir.



Şekil 2.6 Gölbaşı Bölgesi için Kurban Bayramı’nı da içine alan 18.02.2002-27.02.2002 günlerinin yük eğrisi (MW)



Şekil 2.7 Gölbaşı Bölgesi için 22.04.2002-28.04.2002 günleri arası yük eğrisi (MW)

3. YÜK TAHMİNİNDE KULLANILAN YÖNTEMLER

3.1 Giriş

Kısa dönem yük tahmininin, enerji sisteminin planlanması ve işletilmesindeki artan önemi nedeni ile, özellikle son yıllarda yapılan çalışmalar artmıştır. Regresyon, zaman serisi analizi gibi yöntemlere ek olarak çok hızlı işlem yapan bilgisayarların geliştirilmesiyle yapay zeka, bulanık mantık gibi günümüzün popüler yöntemleri de yük tahmininde kullanılmaya başlamıştır. Bu bölümde, kısa dönem yük tahmini için en yaygın olarak kullanılan yöntemler olan regresyon analizi, zaman serileri, Box-Jenkins modelleri ve türevleri, bulanık mantık ve yapay sinir ağı yöntemleri anlatılacaktır. Literatürde bu yöntemlerin dışında, çok değişik yöntemler de kullanılmıştır.

3.2 Regresyon Analizi

Serbest değişkenlerin bağımlı değişkenler üzerindeki etki biçimi ve yönü, istatistik denklemlerle belirtilebilmektedir.

Bir örnek üzerindeki $x_1, x_2, \dots$ serbest ve y bağımlı değişken ölçülerine dayanarak Y ile $X_1, X_2, \dots$ değişkenleri arasındaki,

$$Y = f(X_1, X_2, \dots) \quad (3.1)$$

fonksiyonel ilişkiyi kestirme işlemine regresyon analizi adı verilmektedir [11,21]. Fonksiyonel ilişki sayesinde, $X_1, X_2, \dots$ serbest değişkenleri ölçülerek, bu ölçüler yardımı ile ölçülemeyen Y değeri tahmin edilebilmektedir. Trendde zaman süresi önemlidir; regresyon ise belirli bir dönemde söz konusu Y ve X_1 gibi iki veya daha fazla değişken arasındaki ortalama ilişkiye denir.

Regresyon analizi için önce, belirli bir model halinde, fonksiyon biçimine karar verilmelidir. Bu model bir yada çok sayıda serbest değişkenli, doğrusal yada eğrisel, toplanabilir ya da toplanamaz şekilde olabilir. Fonksiyon biçiminin kararlaştırılmasında, grafik çizimden yararlanılabilir.

Regresyon analizi ile, bir değişkenin başka bir veya birkaç değişken karşısında gösterdiği farklı durumlar, sürekli bir fonksiyon halinde belirtilmektedir. Bu şekilde,

- İncelenen değişkenler arasında bulunduğu sanılan ilişkinin varlığı, yönü, biçimi ve standart hatası saptanmaktadır.
- Gözlenmesi ve ölçülmesi güç olan bir değişkenin belirli koşullardaki değeri, diğer değişkenler yardımıyla tahmin edilebilmektedir.

Regresyonun varlığı ve standart hatasının küçük görülmesi değişkenler arasında bir "neden-sonuç" ilişkisi olduğunu kanıtlayamaz. Aralarındaki ilişki; bir yönlü etkiden yada karşılıklı etkileşimden gelebileceği gibi, ortak bir yada birkaç neden yüzünden birlikte değişme yada birbirini izleme hali olabilir. İlişkinin nedeni ayrıca düşünsel (akıl yürütme) yoldan da saptanmalıdır.

Değişkenler arasındaki ilişki ne kadar kuvvetli ise, regresyon denklemi ile yapılacak tahminlerin hatası o kadar küçülecek, ilişki zayıfladıkça tahminlerin hata payı büyüyecektir.

3.2.1 Basit Regresyon

Basit regresyon analizinin amacı, iki değişken arasındaki gerçek ilişkinin Denklem (3.2) de görüleceği gibi doğrusal bir bağıntı yardımıyla bir tahmini elde etmektir. Başka bir deyişle, değişkenler arasında bulunduğu kabul edilen gerçek doğrusal ilişkiyi,

$$Y = a + bX \quad (3.2)$$

ile gösterilirse, regresyon sonucu ortaya çıkacak olan a ve b katsayıları gerçek α ve β parametrelerinin birer tahmini mahiyetinde olacaklardır. Bilindiği gibi, doğrusal fonksiyonda a , fonksiyonun Y eksenini kestiği noktayı; b ise doğrunun eğimini ifade etmektedir.

Serpilme diyagramı vasıtası ile tespit edilen doğrusal bir ilişki çok sayıda doğru ile gösterilebilir. Ancak ilişkiyi en iyi belirleyecek denklem, en küçük kareler metodu yardımıyla tespit edilecek olan denklemdir. Bu kritere göre çizilen eğriden serpilme diyagramındaki noktalara olan dikey uzaklıkların karelerin toplamı minimum olacaktır. Fakat bir doğrunun bu kritere göre çizilmiş olması uyumun da iyi olması anlamına gelmez. Kriter olarak noktalardan uzaklıkların toplamının değil,

uzaklıkların karelerinin toplamının kullanılmasının sebebi, gerçek uzaklıkların göz önüne alınabilmesidir.

En küçük kareler metodunu kullanarak, doğru denklemindeki a ve b parametreleri şu şekilde hesaplanır:

$$\sum (Y - (a + bX))^2 = \min \quad (3.3)$$

Bilindiği gibi yukarıdaki denklemin minimumunu bulmak için, önce a'ya daha sonra b'ye göre kısmi türevlerini alarak sıfıra eşitlemek gerekir. Bu yapılırsa,

$$\frac{\partial \sum}{\partial a} = -2 \sum (Y_i - a - bX_i) = 0 \quad (3.4)$$

$$\frac{\partial \sum}{\partial b} = -2 \sum (Y_i - a - bX_i)(-X_i) = 0 \quad (3.5)$$

buradan,

$$\sum Y_i = na + b \sum X_i \quad (3.6)$$

$$\sum Y_i X_i = a \sum X_i + b \sum X_i^2 \quad (3.7)$$

denklemleri elde edilir. Bu denklemler normal denklemleri olarak adlandırılmaktadır. a ve b değerleri bu normal denklemlerin çözülmesiyle elde edilir:

$$\bar{Y} = \frac{\sum Y_i}{n} \quad (3.8)$$

$$\bar{X} = \frac{\sum X_i}{n} \quad (3.9)$$

$$a = \bar{Y} - b\bar{X} \quad (3.10)$$

$$b = \frac{\sum X_i Y_i - \bar{Y} \sum X_i}{\sum X_i^2 - \bar{X} \sum X_i} \quad (3.11)$$

3.2.2 Doğrusal Çoklu Regresyon

Çoklu regresyon birden fazla bağımsız değişken $X_1, X_2, \dots, X_n$ ile bir bağımlı değişken Y arasındaki ilişkiyi verir. Burada her bir bağımsız değişkenin bağımlı değişkenle doğrusal ilişkisi,

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_nX_n \quad (3.12)$$

şeklinde doğrusal bir fonksiyondur ve basit analizden farklı olarak bir regresyon katsayısı b yerine n tane net veya kısmi regresyon katsayısı ihtiva etmektedir. Bu katsayıların her biri katsayı ile ilgili bağımsız değişkende meydana gelebilecek bir değişikliğin bağımlı değişken üzerindeki etkisini ölçmektedir. Basit regresyon analizinde olduğu gibi çoklu regresyon analizinde de a ve b , katsayılarını hesaplayarak regresyon fonksiyonuna varmak için en küçük kareler metodu kullanılabilir.

$$Y = a + b_1X_1 + b_2X_2 \quad (3.13)$$

şeklindeki bir çoklu regresyon modelinde basit modeldeki normal denklem yerine aşağıdaki üç normal denklemin bir arada çözülmesi gerekmektedir. Bunlar,

$$\sum Y = na + b_1 \sum X_1 + b_2 \sum X_2 \quad (3.14)$$

$$\sum X_1Y = a \sum X_1 + b_1 \sum X_1^2 + b_2 \sum X_1X_2 \quad (3.15)$$

$$\sum X_2Y = a \sum X_2 + b_1 \sum X_1X_2 + b_2 \sum X_2^2 \quad (3.16)$$

dır.

X serbest değişken ile Y bağımlı değişken arasındaki ilişkinin eğilimi bir eğri biçiminde görülürse bu iki değişken arasındaki bağıntı ikinci derece bir parabol veya daha genel olarak bir polinom modeli ile verilebilir. Katsayılar yine en küçük kareler yöntemi ile hesaplanabilir.

3.3 Zaman Serileri

Zaman serileri, aynı değişkenin belirli bir zaman dönemi içerisindeki gözlem sonuçlarını gösteren serilerdir. İstatistiki verilerin oluş zamanları esas alınarak

sıralanmasıyla elde edilirler. Zaman serileri, bir olayın zaman boyunca aldığı farklı değerlerin bir araya getirilmesi ile oluşur. Zaman serilerinin analizinde gözlemler geçmişe ait dokümanlardan oluşur, belirli bir zamandaki gözlemlerin değerleri ile ilgilenir ve genellikle analizler için eşit zaman aralıkları ele alınır (yıllık, aylık, günlük,...). Serideki dalgalanmalar sadece rastlantısal etkenlerden ileri gelmemektedir. Dalgalanmaların dört hareketin bir arada gösterdikleri etkiden meydana geldikleri varsayılmaktadır: trend, devresel değişimler, mevsimlik değişimler, rastlantısal değişimler olarak verilebilir.

Trend, uzun bir zaman devresi içerisinde, zaman serisinin belirli bir yönde gösterdiği genel eğilimdir. Trend analizi uzun bir dönem analizi olduğundan verilerin aylık veya mevsimlik olarak verilmiş olması tahlilin sonucunu etkilemeyecektir. Serinin genel eğiliminin ölçülebilmesi için, ele alınan dönemin 10 seneden az olmaması gerekli görülmektedir. Bir serinin trendi doğrusal veya eğrisel olabilir. Ancak trendin önemli bir özelliği her iki durumda da istikrarlı oluşudur. Trendi etkileyen faktörlere bünyesel faktörler denir.

Devresel değişimler, bir trend doğrusu etrafındaki uzun dönem dalgalanmalara denir. Bu hareketler mevsimsel değişimlere benzer şekilde devresel olarak tekrarlınsalar da, devrelerinin uzunluğu ve sürelerinin belirsizliği ile dikkati çekerler.

Genel olarak 12 aylık dönem içerisinde oluşan az veya çok, düzenli iniş ve çıkışlara mevsimlik değişimler denir. Mevsim dalgalanmaları doğal, sosyal veya zahiri nedenlerle ortaya çıkar. Yıllar itibarıyla düzenlenen zaman serisinde mevsimlik dalgalanmaları gözlemlenemez.

Zaman serilerinin üzerinde düzensiz değişimler denilen rastlantısal olayların da etkisi vardır. Belirli faktörler dışında kalan ve varlığı daha önceden tahmin edilemeyen ve etkisini devamlı olarak göstermeyen olayların sonucunda ortaya çıkar. Bunlar grevler, devalüasyonlar, doğal afetler vb. siyasal, ekonomik veya doğal sebepler olabilir. Zaman serisi analizleriyle trend, devresel değişimler, mevsimlik değişimler hesaplanabilir, fakat rastlantısal değişimler hesaplanamaz [11,21].

3.4 Box Jenkins Modelleri ve Türevleri

Bu sınıfa giren modeller veya genel tanımıyla Birleştirilmiş Otoregresif-Hareketli Ortalama Yöntemi (ARIMA), zaman serilerinin modelleştirilmesinde kullanılan diğer yöntemlere göre daha kapsamlı ve genel bir tahmin modelidir. Zaman serisi analizlerinde tahmin ve denetim amacı ile kullanılan Box-Jenkins tahmin yöntemleri yeni ve başarılı fakat oldukça karmaşık bir yöntemdir. Yöntem çeşitli koşullarda elde edilen süreksiz zaman serileri ve dinamik sistemler için modeller kullanılması kolaylıklar ve yararlar sağlamaktadır.

Box ve Jenkins birbirini tamamlayan beş aşamadan geçerek tahmin modellerinin kurulmasını önermektedirler.

İlk aşamada, araştırmacı kuramsal bilgileri ve uygulamalı çalışmalardan elde edilen bulguları kullanarak amaca yönelik genel modeller ortaya koyar. Bundan sonraki aşamalar; belirleme, parametre tahminleri, uygunluk testleri ve öngörü olarak sıralanmaktadır. Belirleme aşamasında verinin özelliklerinin incelenmesinden elde edilecek bilgilere dayanarak genel modellerden uygun olabilecekler seçilir. Belirleme aşamasında seçilen modellerin mutlaka uygun modeller olacağı düşünülmemelidir. Tahmin aşamasında, belirlenen modelin katsayıları en etkin istatistiksel yöntemlerle tahmin edilmeye çalışılır. Uygunluk testi aşamasında, belirlenmiş ve katsayıları tahmin edilmiş modelin veri setine uygun olacağı garantisi yoktur. Bunun için bu modele uygunluk testi uygulanır. Bu gibi testler belirlenmiş modelin hangi yönde aksadığını gösterir ve daha uygun modellerin seçilmesi için de bazı ipucu verir. Test başarılı bir sonuç ortaya koymamışsa, belirleme aşamasına göre dönülerek, yeni uygun bir diğer modelin belirlenmesi gerekir.

3.4.1 Otoregresif Model, AR(p)

Bu modelde değişkenin, t dönemdeki değeri değişkenin geri dönemlerdeki belirli sayıda değerleriyle, hata değişkeni a_t 'nin doğrusal bileşimi olarak ifade edilmektedir.

$$Y = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t \quad (3.17)$$

Burada Y 'ler, değişkenin eşit zaman aralıklarıyla ifade edilen gözlem değerleridir.

(3.17) denkleminde p mertebesinde otoregresif model denir ve AR (p) ile gösterilir.

3.4.2 Hareketli Ortalamalar Modeli, MA(q)

Bu modelde değişkenin t dönemdeki değeri aynı dönemdeki hata terimi a_t ve belirli sayıda geri dönem hata terimleri a_{t-q} 'lerin bileşimi olarak yazılır:

$$Y = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.18)$$

burada q , model mertebesidir.

Hareketli ortalama bir zaman serisine ait her değer yerine, o değer ve daha önce ve sonra gelen birkaç değer ortalamasını koymak suretiyle elde edilmiş bir zaman serisidir. Bu yöntemde zaman değerleri 3, 5, 7'şerlik gruplar halinde bir araya getirilerek, her grup için aritmetik ortalamayı hesaplayıp, bulunan değerleri grupların tam orta noktalarına isabet eden değer yerine koymaktır. Kümeler hareket halinde ve gerçek seride her defasında bir değer aşağı kaydırılmak suretiyle oluşturulduğundan, bunların ortalamaları adeta hareket etmekte ve bu nedenle yönteme hareketli ortalamalar metodu denilmektedir. Bu şekilde ortalamalarla oluşturulan yeni seri, dalgalanmaları gidermiş kabul edildiğinden olayın trendi anlamını taşımaktadır.

3.4.3 Karışık Otoregresif-Hareketli Ortalamalar Modeli, ARMA(p,q)

Zaman serilerinin modellenmesinde esneklik sağlamak ve en az sayıda parametre ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif ve hem de hareketli ortalama parametrelerinin alınması birçok yararlar sağlamaktadır. Bu düşünce ARMA(p,q) modelini ortaya çıkarmıştır. Model şu şekilde gösterilebilir:

$$Y = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3.19)$$

3.5 Bulanık Mantık (Fuzzy Logic)

Bulanık kümeler teorisi, belirsiz bilginin gösterimi ve işlenmesinde olasılık teorisine ve ikili mantığa alternatif ya da tamamlayıcı olarak ortaya atılmıştır [22].

Bulanık mantık ilk defa 1960 yılında, University of California, Berkeley'den Azerbaycanlı bilim adamı Dr. Lotfi Zadeh tarafından, doğal dildeki belirsizliği

modellemek için ortaya konmuştur. Zadeh, bulanık mantık teorisinin bağımsız ve tam bir teori olmaktan çok bulanıklaştırma yönteminin (fuzzification), herhangi bir teorisinin ayırık formdan sürekli forma dönüştürülmek suretiyle genelleştirilmesi için kullanılan bir metodoloji olarak ele alınmasını istemektedir.

Klasik mantık “her önerme doğru veya yanlıştır” varsayımına dayanır. Bulanık mantık, insan düşünme ve algılamasını modellemek için kullanılan güçlü bir araçtır. İki değerli önerme yerine bulanık sistemler, çok değerli kümelerle sonuç verir. Bulanık sistemler kuralları saklayıp dilsel girişten dilsel çıkışa örneklenmiş fonksiyonları tahmin eder.

Bazı önermelerin doğruluklarının, doğal ölçümlerin temel sınırlamaları yüzünden belirsiz olduğu bilinmektedir. Bu tür durum ve önermelerden bahsetmek için “belirsiz” olarak adlandırılan bir üçüncü doğruluk değerine izin vererek klasik iki değerli mantığın doğru ve yanlış olan doğruluk değerleri daha esnek hale getirilmelidir. Bunun sonucunda da bulanık mantık ortaya çıkmıştır.

Bulanık küme teorisi, kısmi üyeliğe izin veren bir mantık sistemidir. Yani bir kümenin tam üyeliği ile o kümenin üyesi olmama durumları arasında derece derece geçişe izin verir. Verilen bir elemanın bir kümede kısmi üyeliğinin bulunması demek, aynı zamanda bu elemanın bu kümenin üyesi olmama durumunun da kısmen başlaması demektir. Çünkü bulanık küme teorisi hem tam üyeliğe hem de hiç üye olmamaya izin verir. Bundan dolayı bulanık küme teorisi, klasik küme teorisinin genelleştirilmiş bir hali denebilir.


Bulanık küme mantığı, klasik mantıktan gelmektedir. Kesin kümeler, ihtiyaçları karşılasa da karşılamasa da kesin üyeliklere sahiptir. Sadece doğru ve yanlışın bulunduğu kesin bir kümede sadece 0 veya 1 bulunabilir. Oysa bulanık mantıkta 0 ile 1 arasında değişen birçok değer alınabilir. Yani bulanık mantıkta bir şey ne tam doğru ve ne de tam yanlış olmalıdır. Doğruluk derecelerine göre ayrılabilir. Bulanık sistemler ile gerçekleştirilen çözümlerde kullanılan kümelerde kısmi üyeliğe geçiş bölgesi oluşturulmaktadır.

Bulanık küme tabanlı sistemler genel olarak,

- Bulanıklaştırma
- Bulanık kural tabanı ve çıkarım ünitesi

- Berraklaştırma

birimlerinden oluşur.



Şekil 3.1 a) Bulanık üyelik fonksiyonu
b) Klasik üyelik fonksiyonu

Bulanıklaştırma birimi, giriş bilgilerini önceden belirlenmiş üyelik fonksiyonlarını kullanarak uygun sözel değerlerden oluşan bulanık ifadelere dönüştürür. Şekil 3.1’de bulanık ve klasik üyelik fonksiyonları görülmektedir. Kural tabanı, uzman kişinin kontrol yöntemini “Eğer-ise” (If-then) kuralları şeklinde ifade eden, bulanık kurallar kümesinden oluşur. Çıkarım ünitesi, bulanıklaştırıcı çıkışını kural tabanındaki bulanık kurallar ile eşleştirir ve bulanık uygulamayı gerçekleştirecek uygun bir yorumlama yaptıktan sonra bulanık bir kontrol davranışına karar verir. Berraklaştırıcı, kontrol edilen sisteme uygulayabilmek için sayısal kontrol işaretine çevirir. Bulanık mantık mekanizmasının tasarımındaki en önemli sorun, bulanık mantık kuralları ve uygun üyelik fonksiyonlarının tasarlanmasıdır.

3.6 Yapay Sinir Ağları (YSA)

Yapay sinir ağları biyolojik nöronlardan (sinir hücresi) esinlenerek, beyin çalışma sistemine yapay olarak benzetim çalışmaları sonucunda ortaya çıkmıştır. Genel anlamda insan beynindeki birçok biyolojik nöronun birbirine bağlanması gibi, YSA'lar biyolojik nöronun girdi, işlem, çıktı karakteristiğini taklit eden birçok basit, genellikle adaptif işlem birimlerinin (yapay nöron) değişik etki seviyelerinde, belirli bir bütün işlem yapısını gerçekleştirmek üzere birbirine bağlanması ile oluşturulmuş karmaşık bir yapı olarak düşünülebilir. Yapay sinir ağlarının pratik kullanımı genelde, çok farklı yapıda ve formlarda bulunabilen verilerin hızlı bir şekilde tanımlanması ve algılanması; doğrusal olmayan modelleme ve adaptasyon sağlayabilmesi; bu işlemler için geleneksel modellerde olduğu gibi bir model ve

yönteme ihtiyaç duymamasından dolayı, fizik, matematik, mühendislik, sosyal bilimler gibi çok çeşitli alanlarda kullanım imkanı bulmuştur.

Yapay sinir ağlarının sağladığı avantajlar: eldeki verilerden bilinmeyen ilişkileri kolay bir şekilde ortaya çıkarabilmesi; genelleştirme yeteneği sayesinde bir örnekten hareketle, diğer örneklerdeki benzerlikleri doğru olarak anlayabilmesi; doğrusal olmayan işlem birimleri sayesinde doğrusal olmayan ilişkileri ortaya çıkarabilmesi; paralel olarak işlem yapabildiği için, bağımsız işlemleri çok hızlı bir şekilde yapabilmesidir.

Bu tez çalışmasında kısa dönem yük tahmini anlatılan yöntemler içinden, yapay sinir ağları yöntemi ile yapılmıştır. Bu yüzden Bölüm 4 ve Bölüm 5’de yapay sinir ağları konusu detaylı incelenecektir.

4. YAPAY SİNİR AĞLARI

4.1 Giriş

Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerine yoğunlaşmıştır. Bu çalışmaların ortaya çıkardığı bulgular, her bir nöronun komşu nöronlardan bazı bilgiler aldığı ve bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğü şeklinde idi. Bugün yapay sinir ağları olarak isimlendirilen alan, birçok nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleşmesi üzerindeki yapısal olduğu kadar matematiksel ve felsefi sorunlara yanıt arayan bir bilim dalı olmuştur.

İnsan beyninin çalışma mekanizmasını taklit etmeye çalışan bu sistemler, her ne kadar günümüz teknolojisinin ürettiği, birim işlem zamanı nanosaniyeler mertebesinde olan silikon kapılar ile gerçekleştirilebilirler de insan beyninin birim işlem zamanı milisaniyeler mertebesindeki nöronların toplu biçimde ele alındıklarında işlevselliklerinden çok uzakta kalırlar. Yapay sinir ağları, karar hızı açısından insan beyni ile yarışabilecek aşamayı henüz katedememiş olmalarına rağmen, karmaşık eşleştirmelerin hassas bir biçimde gerçekleştirilebilmesi ve yapısal gürbüzlüğe sahip olmaları nedeniyle gün geçtikçe uygulama alanları genişlemektedir [23]

En genel haliyle bir yapay sinir ağı, beyinin belirli bir işi veya fonksiyonu yerine getirme yönteminin modelini tasarlayan bir makinedir. Ağ genellikle, elektronik bileşenler kullanarak tanımlanır veya bilgisayar yazılımlarıyla benzetimi yapılır. Yapay sinir ağları, öğrenme adı verilen bir süreçle, kullanışlı hesaplamalar yapmaktadır. Yapay sinir ağı, iyi bir performans elde edebilmek için, sinir hücresi veya işleme birimi adı verilen, basit hesaplama hücreleri arasında sağlam bir bağlantı kullanır. Bu bilgilere göre, yapay sinir ağının tanımı şu şekilde yapılabilir: Yapay sinir ağı, deneysel bilgiyi saklama ve kullanıma hazır hale getirme yeteneğine sahip

basit işleme birimlerinden oluşan, çok yoğun, paralel ve dağıtılmış düzende çalışan bir işlemcidir.

Bu işlemci iki yönden insan beynine benzemektedir:


1. Ağ, bilgiyi ortamdan öğrenme yoluyla elde eder,
2. Gerekli bilgiyi saklamak için, sinir hücreleri arasındaki bağlantılar kullanılır.

Ağın bilgiyi ortamdan almasını sağlayan öğrenme işlemi, öğrenme algoritması adıyla bilinen, ağın sinaptik ağırlıklarını güncelleyerek istenen modele ulaşılmasını sağlayan fonksiyonlardır.

Yapay sinir ağları, bilgisayarlar gibi programlanmak yerine, sinir hücreleri arasındaki bağlantı ağırlıkları, eşik değerleri ve ağ yapısı gibi parametrelerin değiştirilip, ayarlanmasıyla eğitilir. Yapay sinir ağındaki bellek ve işlemci birimleri ayrık değildir, paralel ve asenkron çalışır. Büyük boyutta fazlalıklı ve dağılmış olduğu için hataya toleranslıdır. Öğrenme süresince özdenetimli olan yapay sinir ağları, bilgiyi sinir hücrelerini birleştiren bağlantılarda saklayabilir ve bilgi değiştirilebilir [24, 26].

4.2 Biyolojik Sinir Sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da, dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 4.1 de bir sinir sisteminin blok gösterimi verilmiştir.




Şekil 4.1 Biyolojik sinir sisteminin blok gösterimi [25].

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin

temel işlem elemanı, sinir hücresidir (nöron) ve insan beyinde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir. Sinir hücresi 3 bileşenden meydana gelir:

1. Hücre gövdesi
2. Gövdeye giren alıcı lifler (dendrit)
3. Gövdeden çıkan sinyal iletici lifler (akson)

Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur. Şekil 4.2’de görüldüğü gibi akson-dendrit bağlantı elemanı sinaps olarak söylenir.




Şekil 4.2 Biyolojik Sinir Hücresi ve Bileşenleri [25].

Sinapsa gelen ve dendritler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, sinapstaki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi sinaps belirler.

Beyin, sıkışık olarak ara bağışlı milyarlarca nörondan oluşmaktadır. Her eleman kendi aralarında oldukça çok sayıda nörona (eleman başına yaklaşık olarak 104 bağlantı) bağlanmıştır. Bir nöronun aksonu ayrıştırılmıştır ve sinaps olarak

adlandırılan jonksiyon vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Bu jonksiyon uçlarındaki iletim doğal olarak kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Bu sinaptik büyüklük, beyin öğrenirken hangi bilginin düzeltileceğini belirtir. Ayrıca, beyin temel hafıza mekanizmasına dayanarak nöron içerisindeki bilginin işlenmesi ile birleştirilir.



Şekil 4.3 Nöron ve sinapsdaki iletim [25]

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşsal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir.

YSA'lar, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak bazı benzerlikler vardır. Bu benzerlikler Tablo 4.1'de verilmiştir [25].

Tablo 4.1 Sinir sistemi ile YSA'nın benzerlikleri

SİNİR SİSTEMİ	YSA SİSTEMİ
Nöron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Aktivasyon fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

4.3 Yapay Sinir Ağlarının Tarihsel Gelişimi

Yapay Sinir Ağları (YSA), beynin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Literatürde 100'den fazla yapay sinir ağı modeli vardır. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise, beynin fonksiyonlarını kısmen yerine getiren bir çok modelleri oluşturmaya çalışmışlardır.

YSA'ların öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder.

1943 yılında bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, "Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap" başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur. John Von Neumann bu makaleyi, "elektronik beyinler" için bir kopya olarak görmüştür.

1949 yılında, Hebb, kendi adıyla anılan öğrenme kuramını, yapay sinir ağına uyguladı. Öğrenen uyarlamalı sistemlere esin kaynağı olan öğrenme kuramı şöyledir: "A hücresinin bir aksonu, B hücrelerini uyaracak ve tekrarlı veya sürekli olarak tetikleyecek kadar yakında ise, hücrelerde B'yi tetikleyen A'nın etkinliğini arttıracak bir büyüme işlemi veya metabolik değişiklik olur".

Yapay zeka alanındaki araştırmacılar içerisinde istisnai bir yeri olan Marvin Minsky, bu makaleden aldığı ilhamla makroskobik zeka fikrini ortaya atmış ve uzman sistemlerin doğmasına neden olmuştur. Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bu bilim adamları, öğrenmenin ve

zekanın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zeka konferansında tartışmışlardır.

1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve "ADALINE" (Adaptive Linear Neuron) olarak adlandırılan bir adaptif lineer elemanı geliştirmiştir. Adaline ve iki tabakalı biçimi olan "MADALINE" (Multiple Adaline); ses tanıma, karakter tanıma, hava tahmini ve adaptif kontrol gibi çok çeşitli uygulamalar için kullanılmıştır. Daha sonraları adaline, ayrık bir çıkış yerine sürekli bir çıkış üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki yansımaları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif lineer eleman algoritmasını kullanmıştır. Bununla ilk defa YSA'lar gerçek bir probleme uygulanmıştır.

Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, 1970'lerin ilk yıllarında adaptif öğrenme ve birleşik hafızalar üzerine temel çalışmalar yapmış ve bu olduğu çalışmaları ile danışmansız öğrenme metotlarının gelişmesine ışık tutmuştur.

1969 yılında, Minsky ve Papert tarafından yapılan bir çalışmayla, perseptronun XOR lojik kapısını gerçekleyemediği ispatlanmıştır. Minsky ve Papert'in perseptron isimli kitaplarında, YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri bir çok araştırmacının bu alanda çalışmaktan vazgeçmelerine sebebiyet vermiştir. 1969-1982 yılları arasında, yapay sinir ağlarıyla ilgili yapılan çalışmalar, karanlık bir döneme girmiştir.

YSA konusunda çalışmaya devam eden Grossberg , YSA modellerini yapılandırmak için nörolojik verinin kullanılması, algı ve hafıza için YSA tabanlı mekanizmaların önerilmesi, belirgin eşitliklerle bütünleşen bir sinaptik model için bir ilişkilendirici kural üzerinde çalışmıştır.

1974 yılında Werbos, Geriye Yayılım (Back Propagation) algoritmasını ortaya attı. Willshaw ve Malsburg 1976 yılında Özdenetimli harita (SOM – Self Organizing Feature Map) adındaki kümelenme algoritmasını kurdular. 1982 yılında Kohonen, özdenetimli harita kuramını beyindeki oluşumların karşılaştırılmalı haritasını çıkarabilmek için ortaya koydu.

1982 yılında ilgi çeken bir başka gelişme, moleküller biyolojiden beyin kuramcılığına geçiş yapan bir model Caltech fizikçisi Hopfield tarafından

sunulmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve bir çok alana uygulanmıştır.

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA'larla ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam edeceklerdir. [24-25].

4.4 YSA'nın Özellikleri

YSA, hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden alır. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

4.4.1 Doğrusal Olmama

YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

4.4.2 Öğrenme

YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez yada tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

4.4.3 Genelleme

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir yada bir

sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

4.4.4 Uyarlanabilirlik

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

4.4.5 Hata Toleransı

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

4.4.6 Donanım ve Hız

YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

4.4.7 Analiz ve Tasarım Kolaylığı

YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, bölüm 1.3'de açıklandığı gibi bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir [25-27].

4.5 YSA'nın Uygulama Alanları

Son yıllarda YSA'ları, özellikle günümüze kadar çözümü güç ve karmaşık olan yada ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmektedir. YSA'ları çok farklı alanlara

uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla birlikte genel bir sınıflandırma ile YSA'nın uygulama alanları aşağıdaki gibi 6 grup içerisinde toplanabilir.

Arıza Analizi ve Tespiti (Fault Diagnosis): Bir sistemin, cihazın yada elemanın düzenli (doğru) çalışma şeklini öğrenen bir YSA yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı vardır. Bu amaçla YSA; elektrik makinelerinin, uçakların yada bileşenlerinin, entegre devrelerin v.s. arıza analizinde kullanılmıştır.

Tıp Alanında: EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu v.s gibi uygulama yeri bulmuştur.

Savunma Sanayi: Silahların otomasyonu ve hedef izleme, nesneleri/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme v.s gibi alanlara uygulanmıştır.

Haberleşme: Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.s gibi alanlarda uygulama örnekleri vardır.


Üretim: Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin (entegre, kağıt, kaynak v.s.) kalite analizi ve kontrolü, planlama ve yönetim analizi v.s. alanlarına uygulanmıştır.

Otomasyon ve Kontrol: Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü v.s. gibi yaygın bir uygulama yeri bulmuştur [25].

4.6 Nöron Modeli

YSA'lar çeşitli bağlantılarla birbirine bağlı birimlerden oluşmuş sistemlerdir. Bir YSA modelinin temel birimi Şekil 4.4'de gösterilen işlem elemanı yani nöronudur. Burada girişler dış kaynaklardan ya da diğer nöronlardan gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıklar da farklıdır. Bu model ayrıca dışarıdan bir girişe sahiptir. b_k ile gösterilen, bias adı verilen

referans değeri, aktivasyon fonksiyonunun net girişini pozitif ise yükseltir, negatif ise düşürür.



Şekil 4.4 Bir nöron modeli

Şekilden de görüldüğü gibi bir nöron 5 bileşenden meydana gelmektedir.

- 1) Giriş sinyalleri,
- 2) w_{kj} ile gösterilen sinaptik ağırlıklar,
- 3) Birleştirme fonksiyonu ya da toplayıcı,
- 4) Aktivasyon fonksiyonu,
- 5) Çıkış.

K nöronunun işlevi şu şekilde matematiksel ifadeye indirgenebilir:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (4.1)$$

u_k , lineer toplayıcı çıkışıdır. Bias terimi b_k da eklenecek olursa:

$$v_k = u_k + b_k \quad (4.2)$$

$$y_k = \varphi(v_k) \quad (4.3)$$

Burada, $x_1, x_2, \dots, x_m$ giriş işaretleri; $w_{k1}, w_{k2}, \dots, w_{km}$ k nöronunun sinaptik ağırlıkları; $\varphi(.)$ aktivasyon fonksiyonu ve y_k nöronun çıkış işaretidir [24, 28].


4.6.1 Aktivasyon Fonksiyonları

Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili yada uyarlanabilir parametrelili seçilebilir. Hücre modellerinde en yaygın olarak kullanılan aktivasyon fonksiyonları aşağıda verilmiştir [24-25].

4.6.1.1 Doğrusal Fonksiyon

Doğrusal aktivasyon fonksiyonları çok katmanlı yapay sinir ağlarının çıkış katmanında sıklıkla kullanılırlar. Doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Matematiksel ifadesi şu şekildedir:

$$\varphi(v) = v \quad (4.4)$$




Şekil 4.5 Doğrusal aktivasyon fonksiyonu

4.6.1.2 Parçalı Doğrusal Fonksiyon

Parçalı doğrusal aktivasyon fonksiyonu ise aktif çalışma bölgesinde doğrusaldır ve hücrenin net girdisinin belirli bir değerinden sonra hücre çıkışını doyuma götürür.

$$\varphi(v) = \begin{cases} 1, & v \geq +1 \\ v, & +1 > v > -1 \\ 0, & v \leq -1 \end{cases} \quad (4.5)$$




Şekil 4.6 Parçalı doğrusal fonksiyon

4.6.1.3 Eşik Fonksiyonu

Eşik fonksiyonlu nöronlar, mantıksal çıkış verir ve sınıflandırıcı ağlarda tercih edilir. Modeldeki temel mantık “ya hep ya hiç”tir.

$$\varphi(v) = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (4.6)$$




Şekil 4.7 Eşik fonksiyonu

4.6.1.4 Sigmoid Fonksiyonu

Sigmoid fonksiyonu, yapay sinir ağlarında çok sık kullanılan, s biçimli bir fonksiyondur. Bu fonksiyon doğrusal ve doğrusal olmayan davranışlar arasında çok iyi bir denge kurar. Matematiksel ifadesi aşağıdaki gibidir:

$$\varphi(v) = \frac{1}{1 + e^{(-av)}} \quad (4.7)$$

Fonksiyonun matematiksel ifadesindeki a katsayısı, eğim parametresidir. Eğim parametresinin değeri arttıkça, sigmoid fonksiyonu, eşik fonksiyonuna yaklaşır. Sigmoid fonksiyonu, değerleri 0-1 arasında olan, sürekli ve türevi alınabilen bir fonksiyondur. Yapay sinir ağlarında, aktivasyon fonksiyonunun türevi alınabilir olması, önemli bir özelliktir. Bu seçimin sebebi, dönüşüm işleminin analitik kontrolünü kolaylaştırmaktır. Özellikle en küçük kareler metodunu kullanan öğrenme algoritmalarında, hesaplamalar için fonksiyonun türevine ihtiyaç duyulur. Doğrusal ve eşik fonksiyonları bu özelliği taşımadıkları için, sigmoid fonksiyonu daha çok tercih edilen bir fonksiyondur.




Şekil 4.8 Sigmoid fonksiyonu

4.6.1.5 Hiperbolik Tanjant Fonksiyonu

Hiperbolik tanjant fonksiyonu da sigmoid fonksiyonu gibi türevi alınabilir bir fonksiyon olduğundan, sıklıkla kullanılmaktadır. Sigmoid fonksiyonundan farklı olarak hiperbolik tanjant fonksiyonunun çıkışları -1 ve +1 arasındadır. Hiperbolik tanjant fonksiyonu aşağıdaki şekilde ifade edilir:

$$\varphi(v) = \tanh(v) \quad (4.8)$$



Şekil 4.9 Hiperbolik tanjant fonksiyonu

4.7 YSA'ların Sınıflandırılması


4.7.1 Yapılarına Göre Sınıflandırma

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine göre çeşitli YSA yapıları geliştirilmiştir.

4.7.1.1 İleri Beslemeli YSA

İleri beslemeli YSA'lar tek katmanlı olabileceği gibi çok katmanlı da olabilirler. İleri beslemeli bir ağda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Bir katmandan diğer bir katmana bağlantı kurarlarken, nöronların aynı katman içerisinde bağlantıları bulunmaz. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştıracabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denmektedir. Şekil 4.10'da giriş, orta ve çıkış katmanı olmak üzere 3 katmanlı ileri beslemeli YSA yapısı verilmiştir. İleri


beslemeli ağılara örnek olarak Çok Katmanlı Perseptron (Multi Layer Perceptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir [24-28].



Şekil 4.10 İleri beslemeli yapay sinir ağı [25]

4.7.1.2 Geri Beslemeli YSA

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 4.11’de bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundurlar. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir [24-29].




Şekil 4.11 Geri Beslemeli YSA [25]

4.7.2 Öğrenme Şekillerine Göre Sınıflandırma

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. O halde, birtakım metot ve kurallar, gözlem ve eğitime göre ağıdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak üç öğrenme metodundan söz edilebilir [24-28].

4.7.2.1 Eğitici Öğrenme

Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre nöronlar arası bağlantıların ağırlığını en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple eğitici öğrenme algoritmasının bir eğiticiye ihtiyacı vardır. Ortam hakkında bilgiye sahip olan eğitici, ortam hakkında bilgiye sahip olmayan eğitilen sisteme bilgiyi aktarır.




Şekil 4.12 Eğitici öğrenmenin blok diyagramı

4.7.2.2 Eğitici öğrenme

Eğitici öğrenmede, öğrenme işleminin sonucu önceden bilinmez. Öğrenme işlemi içinde, nöronları birleştiren bağlantıların ağırlıkları, verilen giriş değerlerine bağlı olarak belirli bir aralık içinde düzenlenir. Burada amaç, birbirine benzeyen birimleri, belirli değer aralıkları içinde gruplamaktır.


Öğrenme işleminin her adımında, istenilen yanıt sağlayacak eğitici yoktur fakat bir beklenti vardır. Bu beklenti, eleştirmen tarafından eğitilen sisteme aktarılarak doğru cevaba ulaşılmaya çalışılır. Eğitilen sistem, elde edilecek yanıtı açarak her etkiyi kendisi oluşturur ve eleştiriye göre yorumlayarak öğrenme işlemi tamamlanır. Eğitici öğrenmeye ait blok diyagram Şekil 4.13’de verilmiştir.



Şekil 4.13 Eğitici öğrenmenin blok diyagramı

4.7.2.3 Özdenetimli Öğrenme


Özdenetimli öğrenmede, hedeflenen bir çıkış değeri, istenen çıkışı verecek bir eğitici veya eleştirmen yoktur. Burada amaç, birbirlerine benzer birimleri, belirli değer aralıkları içinde gruplamaktır. Bu öğrenmede girişlerin istatistiksel düzeni belirlendikten sonra, sistem sınıflamayı başaracak beceriyi kendi oluşturur.



Şekil 4.14 Özdenetimli öğrenmenin blok diyagramı

4.8 Çok Katmanlı Perseptronlar ve Öğrenme Algoritmaları

Bir çok katmanlı perseptron sinir ağı modeli, Şekil 4.15’de gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bir çok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir çok katmanlı perseptron modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemler giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanarak belirlenir.



Şekil 4.15 Çok katmanlı perseptron modeli [25]

Çok katmanlı perseptron ağlarında, ağa bir giriş gösterilir ve giriş neticesinde nasıl bir sonuç üreteceği de bildirilir (eğitici öğrenme). Girişler, giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitim algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilir.

İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur.

Çok katmanlı perseptronlar bir çok öğretim algoritması kullanılarak eğitilebilirler. Bunlar arasında eğitici öğrenme algoritmaları olan geriye yayılım (BP:back-propagation), hızlı yayılım (QP-Quickprop), delta-bar-delta (DBD), genişletilmiş delta-bar-delta (EDBD-extended delta-bar-delta) bulunmaktadır.


Geriye yayılım algoritması, en yaygın olarak kullanılan öğretim algoritmasıdır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu tez çalışmasında

da geriye yayılım algoritması uygulandığından Bölüm 5’de bu konu detaylı anlatılacaktır [25].

4.9 Diğer YSA’lar ve Öğrenme Algoritmaları

4.9.1 Vektör Kuantalama (Learning Vector Quantization, LVQ)

Şekil 4.16, üç kattan oluşan LVQ ağını göstermektedir. Bu tabakalar, giriş, gizli tabaka ve çıkış tabakasıdır. LVQ ağı, giriş ve gizli tabaka arasında tamamen, gizli ve çıkış tabakası arasında da kısmen bağlıdır. Her çıkış işlemci elemanı farklı bir gizli işlemci eleman kümesine bağlıdır. Gizli ve çıkış işlemci elemanları arasındaki ağırlıklar 1’e sabitlenmiştir. Giriş-gizli işlemci eleman bağlantılarının ağırlıkları “referans” vektörlerinin elemanlarını oluşturur (her gizli işlemci elemana bir referans vektör atanmıştır). Ağın öğretilmesi esnasında bunlar yeniden değerler alırlar. Hem gizli işlemci elemanlar (bunlar Kohonen işlemci elemanları olarak da bilinir) hem de çıkış işlemci elemanları ikili (binary) çıkışa sahiptir. Ağa bir giriş deseni verildiğinde referans vektörü giriş desenine en yakın olan gizli işlemci eleman kümesi “1”, diğerleri “0” üretir. “1” üreten çıkış işlemci elemanı giriş işaretini sınıflar ve her işlemci eleman ayrı bir sınıfa atanmıştır



Şekil 4.16 Vektör kuantalama ağı [25]

4.9.2 Hopfield Ağı

Şekil 4.17’de Hopfield ağıının bir şekli gösterilmiştir. Bu ağ genellikle ikili (0 veya 1) ve bipolar (+1 veya -1) girişler kabul eder. Tek tabaka işlemci elemanları vardır ve her işlemci eleman bir diğerine bağlanmıştır. Bu da daha önceden belirtilen geri beslemeli yapıdır. Hopfield ağıının eğitilmesi sadece bir adım alır ve w_{ij} ağırlıkları aşağıdaki gibi hesaplanır:

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^P x_i^c x_j^c, & i \neq j \\ 0, & i = j \end{cases} \quad (4.9)$$

Burada w_{ij} , i işlemci elemanından j işlemci elemanına olan bağlantının ağırlığını, x_i^c c sınıfı için eğitim girişi deseninin i . elemanını, P sınıf sayısını ve N de işlemci eleman sayısını gösterir. Denklem (3.44)’de $w_{ij}=w_{ji}$ ve $w_{ii}=0$ durumları ağıın kararlılığını garantiler. Bilinmeyen bir bilgi ağı girildiğinde, ağıın çıkışları bilinmeyen bir desen elemanlarına eşitlenir, yani;


$$y_i(0) = x_i \quad 1 \leq i \leq N \quad (4.10)$$

Bu başlangıç değerleri ile başlayarak Hopfield ağı bir sonraki denklemi kullanarak minimum enerji durumuna geçmek için döngüye girer.

$$y_i(n+1) = f \left[\sum_{j=1}^N w_{ij} y_j(n) \right] \quad 1 \leq i \leq N \quad (4.11)$$

burada f aşağıdaki gibi tanımlanan keskin sınırlama (hard limiting) fonksiyonudur.


$$f(x) = \begin{cases} -1 & x < 0 \\ 1 & x > 0 \end{cases} \quad (4.12)$$




Şekil 4.17 Hopfield Ağı [25]

4.9.3 Elman ve Jordan Ağları

Şekil 4.18’de Elman ve Şekil 4.19’da Jordan ağlarını göstermektedir. Bu ağlar, MLP’lere benzer bir yapıdadır ve çok katlıdır. Her iki ağda da gizli tabakaya ek olarak diğer bir “durum” tabakası denilen özel bir gizli tabaka daha vardır. Bu tabaka gizli tabakadan veya çıkış tabakasından geri besleme işaretleri alır. Jordan ağının aynı zamanda durum tabakasındaki her işlemci elemandan kendisine bağlantıları vardır. Her iki ağda da durum tabakasındaki işlemci elemanların çıkışları ileriye doğru gizli tabakaya verilmektedir. Eğer sadece ileri doğru bağlantılar göz önüne alınır ve geri besleme bağlantılarına sabit değerler verilirse, bu ağlar sıradan ileri beslemeli ağlar haline gelirler.



Şekil 4.18 Elman Ağı [25]




Şekil 4.19 Jordan Ağı [25]

4.9.4 Kohonen Ağı

Kohonen ağı, bir giriş katmanı ve bir de çıkış katmanı olmak üzere iki katmandan oluşur. Bu ağ Şekil 4.20’de gösterilmiştir. Çıkış katmanındaki nöronlar genellikle düzenli iki boyutlu aralıklar olarak düzenlenir. Çıkıştaki her nöron, bütün giriş

nöronlarına bağlıdır. Bağlantıların ağırlıkları verilen çıkış nöronu ile ilgili olan referans vektörünün elemanlarını oluşturur.

İyi öğrenmiş bir Kohonen ağında birbirine yakın çıkış nöronlarının referans vektörleri vardır. Öğrenmeden sonra bir etiketleme işlemine başlanır. Bilinen sınıfların giriş desenleri ağına giriş olarak verilir ve bu giriş desenleri tarafından aktif hale gelen çıkış nöronlarına bu sınıf etiketleri verilir. LVQ ağında ise bir çıkış nöronu eğer yarışmayı diğer çıkış nöronlarına karşı kazanırsa bir giriş deseni tarafından aktif hale getirildiği hatırlatılır.




Şekil 4.20 Kohonen Ağı [25]

4.9.5 Radyal Tabanlı Fonksiyon Ağları (RTFA)

Katmanlı YSA'nın tasarımında eğitici geriye yayılım öğrenme algoritması bir en iyileme uygulamasıdır. Radyal tabanlı fonksiyon ağı tasarımı ise çok boyutlu uzayda eğri uydurma yaklaşımıdır ve bu nedenle RTFA'nın eğitimi, çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemine dönüşür. RTFA'nın genellemesi ise test verilerini interpolasyon yapmak amacıyla, eğitim sırasında

bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Radyal tabanlı fonksiyonlar, sayısal analizde çok değişkenli interpolasyon problemlerinin çözümünde kullanılmış ve YSA'nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımında yararlanılmıştır. RTFA, ileri beslemeli YSA yapılarına benzer şekilde giriş, orta ve çıkış katmanından oluşur ancak, giriş katmanından orta katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Orta katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir.



Şekil 4.21 Radyal tabanlı fonksiyon ağı [25]

Bu tez çalışmasında, ileri beslemeli çok katmalı perseptron ağının eğitiminde kullanılan algoritma olan “geriye yayılım algoritması” Bölüm 5’de detaylı olarak anlatılacaktır [25].

5. GERİYE YAYILIM (BACK PROPAGATION) ALGORİTMASI

5.1 Giriş

İleri beslemeli yapay sinir ağlarının parametrelerinin güncelleştirilmesi için literatürde en çok kullanılan yöntem geriye yayılım algoritmasıdır. Bu tez çalışmasında da, ileri beslemeli yapay sinir ağının eğitiminde geriye yayılım algoritması kullanılmıştır.

Geriye yayılım algoritmasının eğitimi sırasında ağ, çıkış katmanında sonuç üretmek üzere, giriş örüntüleri gizli katmanlardan geçirilir. Çıkış nöronlarında elde edilen sonuç ile beklenen sonuç karşılaştırılır ve çıkış katmanının hataları bulunur. Hataların bulunmasından sonra ağ, hataların türevini çıkış katmanından geriye doğru gizli katman veya katmanlara geçirilir. Geriye yayılım algoritmasına ismini veren, algoritmanın bu özelliğidir.

Geriye yayılım algoritması, sadece ileri beslemeli ağlar için kullanılabilir. Herhangi bir katmandaki nöron, bir üst katmandaki nöronların hepsine bağlı olduğu gibi, bir alt katmandaki nöronların da hepsine bağlıdır. Üst katman nöronlarına işaret gönderirken, alt katman nöronlarından işaret alır. Bu yapı “tam bağlılık” olarak isimlendirilir. Bir nöron, bulunduğu tabaka içindeki hiçbir elemana doğrudan bağlı olamaz.

Her çıkış ve gizli katmandaki nöronların hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için sinaptik ağırlıkları ayarlar. Ağırlık değiştirme denklemleri, ağın performans fonksiyonunu minimum yapacak şekilde düzenlenir. Standart geriye yayılım algoritmasında performans fonksiyonu olarak, ortalama hata karesi kullanılır. Geriye yayılımın kullanılan diğer türevleri de, eksiklikler ve gereklilikler düşünülerek, performans fonksiyonu, ağ parametreler ve/veya ağırlık güncelleme denklemlerinde değişiklikler yapılarak geliştirilebilir.

5.2 Standart Geriye Yayılım Algoritması (Dik İniş Algoritması – Gradient Descent Algorithm)

Geriye yayılım algoritması, Widrow – Hoff öğrenme kuralının genelleştirilerek, doğrusal olmayan, türevi alınabilir transfer fonksiyonları kullanılan çok katmanlı ağlara uygulanmasıyla geliştirilmiştir. Giriş vektörleri ve bunlara karşılık düşen beklenen çıkış değerleri, ağ bir yaklaşık fonksiyona ulaşana kadar, giriş vektörlerini belirli çıkış vektörleriyle birleştirene kadar veya giriş vektörlerini tasarımcı tarafından belirlenen şekilde sınıflayana kadar ağı eğitmek için kullanılır. Bias terimleri, sigmoidal katmanı ve doğrusal çıkış katmanı olan ağlar, sınırlı sayıda süreksizliği olan herhangi bir fonksiyonu tahmin etme yeteneğine sahiptir. İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması dik iniş algoritmasıdır.


Dik inişten başka, eşlenik gradyen ve Newton yöntemleri gibi diğer standart optimizasyon tekniklerine dayanan basit algoritmaların çeşitli şekilleri vardır.

Geriye yayılım algoritmasıyla eğitilen ağlar, daha önceden tanıtılmayan giriş değerlerine mantıklı sonuçlar verir. Bu algoritmada, eğitimde kullanılan giriş vektörüne benzeyen yeni bir giriş ağı uygulandığında, yeni giriş vektörüne karşı ağı hesapladığı çıkış vektörü, eğitimde kullanılan çıkış vektörüne yakın bir sonuç verir. Bu genelleştirme özelliği, ağı olası bütün giriş çıkış çiftlerini kullanmadan da güzel sonuçlar vermesini sağlar.

5.2.1 Yapay Sinir Ağlarında Öğrenme Ve Ezberleme Problemi

Yapay sinir ağlarında öğrenme ve ezberleme sınırının belirlenmesinde iki farklı uygulamadan söz edilir. Birinci tipteki uygulama sonlu sayıda durumdan oluşur ve bu durumların her biri eğitim çiftleri tarafından temsil edilir. Lojik işlemler, XOR problemleri bu durumlara örnektir. Eğitim kümesi, girişlerin alabileceği tüm değerleri içeriyorsa, toplam karesel hata değeri sıfıra ne kadar yaklaşırsa ağ başarımı o kadar yüksek olacaktır. İkinci tipteki uygulamalarda ise sonsuz sayıda eleman bulunması gerekir. Pratikte sonsuz sayıda eğitim çifti kullanılamayacağına göre, sonlu sayıda çift ile eşleştirmenin gerçekleştirilebilmesi, öğrenme ve ezberleme

arasındaki sınırın iyi çizilmesini gerektirir. Eğer yapay sinir ağı, verilen noktalarda sıfıra çok yakın bir ortalama hata karesi elde edecek biçimde eğitilmişse, eğitim çiftleri kümesinde bulunmayan ancak aynı sürekli yüzey denklemlerinden elde edilen bir başka noktada, büyük hata içeren bir sonuç üretmesi olası bir durumdur. Bu nedenle eğitim kümesinin yanında, test kümesi de oluşturulmalı ve bu iki küme mümkün olduğunca az sayıda özdeş eleman bulundurmamalıdır.



Şekil 5.1 Eğitimin durdurulması

Eğitim sırasında eğitim kümesine göre parametreler güncelleştirilirken, test kümesi için de gözlenen ortalama hata karesi kontrol edilmelidir. Her iki büyüklüğün de azalma gösterdiği süre boyunca genelleme mantığına uygun bir öğrenme gerçekleşmektedir. Bir süre sonra eğitim kümesi için hata azalmaya devam ederken, test kümesi için hata artmaya devam edecektir. Bu noktada eğitime son verilmelidir; çünkü kullanılan eğitim kümesindeki örüntüler için ezberleme süreci başlamıştır. Bu durum Şekil 5.1’de gösterilmiştir [24].

5.2.2 Aktivasyon Fonksiyonunun Türevleri

Geriye yayılım algoritmasında kullanılan zincir kuralı, aktivasyon fonksiyonun türevini almayı gerektirir. Aktivasyon fonksiyonu olarak en fazla kullanılan fonksiyonlardan, sigmoid fonksiyonu, tanjant hiperbolik fonksiyonu ve doğrusal fonksiyon için türev denklemleri aşağıda verilmiştir [24].

1. Doğrusal Fonksiyon: $\phi(v) = v$,

$$\text{Türev: } \phi'(v) = 1 \quad (5.1)$$

2. Sigmoid Fonksiyonu: $\varphi(v) = \frac{1}{1 + e^{-av}}$,

Türev: $\varphi'(v) = a\varphi(v)(1 - \varphi(v))$ (5.2)

3. Tanjant Hiperbolik Fonksiyonu: $\varphi(v) = \frac{e^{av} - e^{-av}}{e^{av} + e^{-av}}$,

Türev: $\varphi'(v) = a(1 - \varphi(v)^2)$ (5.3)

Burada a sabiti eğim parametresidir genellikle 1 seçilir; v ise, nöron içinde hesaplanan net giriştir ve şu şekilde ifade edilir:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (5.4)$$

5.2.3 Geriye Yayılım Algoritmasında Ağırlıkların Güncellenmesi

Geriye yayılım algoritmasında, daha önce açıklandığı gibi, giriş vektörleri ağa uygulanarak, bu giriş vektörlerine karşılık gelen çıkış değerleri hesaplanır. Ağ çıkışları ile beklenen çıkışların karşılaştırılmasıyla hata değerleri elde edilir. Hatanın azaltılması için ağırlıkların pozitif veya negatif yönde değiştirilmesi gerekliliği belirlenir. Her ağırlık değeri için değişiklik miktarı belirlenerek düzenleme yapılır. Algoritma bütün eğitim örüntüleri için, hata limit değeri sınırına düşene kadar tekrar edilir [24, 26-28].

5.2.3.1 Çıkış Katmanındaki Ağırlıklarının Güncellenmesi

n . iterasyonda, j . nöronun çıkışındaki hata işareti, j . nöron çıkış katmanındaysa;

$$e_j(n) = d_j(n) - y_j(n) \quad (5.5)$$

şeklinde tanımlanır. j nöronu için hata fonksiyonunun ani değeri ise, $\frac{1}{2}e_j^2(n)$

şeklinde tanımlanır. Ani hata değerlerinin bütün nöronlar için toplamı ise toplam hata fonksiyonunu belirtir.


$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (5.6)$$

(5.6) denklemindeki C kümesi, ağıın çıkış katmanındaki bütün nöronları içerir. Ortalama karesel hata fonksiyonu, N eğitim kümesindeki tüm örüntü sayısı olmak üzere, (4.7) denklemiyle bulunur:

$$E_{ort} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (5.7)$$

Ani hata $E(n)$ ve ortalama hata $E_{ort}(n)$, ağıın bütün serbest parametrelerinin (ağırlıklar ve bias) fonksiyonudur. Verilen bir eğitim kümesi için, $E_{ort}(n)$ ağıın performans fonksiyonudur. Bu öğrenme algoritmasının amacı, performans fonksiyonunu minimum yapmak için serbest parametrelerin ayarlanmasıdır.

Bu algoritmada, ağırlıklar performans fonksiyonun azalması yönünde ayarlanır. Öğrenme sırasında performans fonksiyonu, dik iniş yöntemiyle en küçük değere indirilir. Geriye yayılım algoritmasında performans fonksiyonu olarak, ortalama karesel hata kullanılır. Ağırlıkların değişim yönünü bulmak için, $E(n)$ 'nin w_{ji} ağırlıklarına göre, negatif gradyeni hesaplanır. Böylece ağırlık değerleri, hatayı azaltacak yönde değiştirilebilir. $E(n)$ 'yi, ağırlık uzayında bir yüzey olarak düşünmek, daha kullanışlı olacaktır. Ağırlık değişimleri, hata değerinde hızlı azalışın gerçekleştiği negatif gradyen yönünde yapılmaktadır.



Şekil 5.2 Çıkış katmanındaki j nöronunun işaret akış diyagramı [26, 28]

Şekil 5.2'de görüldüğü gibi j nöronu, solundaki katman tarafından oluşturulan fonksiyon işaretleri tarafından beslenir. Aktivasyon fonksiyonunun girişi, denklem (5.8)'de görüldüğü gibi hesaplanır:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (5.8)$$

burada m , toplam giriş sayısıdır (bias hariç). n . iterasyonda j çıkış nöronundaki fonksiyon işareti $y_j(n)$,

$$y_j(n) = \phi_j(v_j(n)) \quad (5.9)$$

şeklinde gösterilebilir.

Geriye yayılım algoritmasında, ağırlıkların değişimi Widrow – Hoff kuralına benzer şekilde gerçekleştirilir. Ağın gradyeni hata fonksiyonunun ağırlıklara göre türevi alınarak bulunabilir. Zincir kuralına göre, gradyen aşağıdaki şekilde ifade edilebilir:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (5.10)$$

$\frac{\partial E(n)}{\partial w_{ji}(n)}$ kısmi türevi, w_{ji} ağırlığı için ağırlık uzayında arama yönünü hesaplayan duyarlılık faktörüdür.

Denklem (5.6)'da iki tarafın türevi alınırsa denklem (5.11) elde edilir.

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (5.11)$$

Denklem (5.5)'te, her iki tarafın $y_j(n)$ 'ye göre türevi alınırsa,

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (5.12)$$

elde edilir. Denklem (5.9)'un $v_j(n)$ 'ye göre türevi alınarak, denklem (5.13) bulunur.

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi'(v_j(n)) \quad (5.13)$$

Son olarak (5.8) denkleminin $w_{ji}(n)$ 'ye göre türevi alınarak, denklem (5.14) elde edilir.

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (5.14)$$

(5.11), (5.14) ve (5.10) denklemleri kullanılarak, $\frac{\partial E(n)}{\partial w_{ji}(n)}$ kısmi türevi bulunur:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \phi'_j(v_j(n)) y_i(n) \quad (5.15)$$

$\Delta w_{ji}(n)$, ağırlık düzeltmesi, delta kuralına göre hesaplanır.

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (5.16)$$

denklem (5.16)'da η öğrenme hızıdır. Buradaki $-$ işareti, ağırlık uzayındaki dik inişi temsil eder. Denklem (5.15) ve (5.16) kullanılarak,

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (5.17)$$


elde edilir. Burada $\delta_j(n)$ yerel gradyen şu şekilde tanımlanır:

$$\begin{aligned} \delta_j(n) &= -\frac{\partial E(n)}{\partial v_j(n)} \\ &= -\frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= e_j(n) \phi'_j(v_j(n)) \end{aligned} \quad (5.18)$$

Yerel gradyen, ağırlıktaki gerekli değişikliğe işaret eder. Denklem (5.18)'e göre, j çıkış nöronu için $\delta_j(n)$ yerel gradyeni, o nöronun hata işareti ile, aktivasyon fonksiyonunun türevinin çarpımına eşittir.

5.2.3.2 Ara Katman Ağırlıklarının Güncellenmesi

Ara katman ağırlıkları belirlenirken, çıkış katmanında olduğu gibi, çıkış değerleri hakkında bir ön bilgi bulunmamaktadır. Bu nedenle gizli katman çıkışları belirli bir değere hedeflenememektedir [24, 26-28].



Şekil 5.3 j gizli katmanına bağlı k çıkış nöronunun işaret akış diyagramı [26, 28]

Şekil (5.4)'te görülen j nöronu gizli katman nöronudur. Denklem (5.18)'e göre, j gizli katman nöronunun $\delta_j(n)$ yerel gradyeni aşağıdaki şekilde yeniden tanımlanır.

$$\begin{aligned}\delta_j(n) &= -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)}, \quad j \text{ gizli katmanda} \\ &= -\frac{\partial E(n)}{\partial y_j(n)} \phi'_j(v_j(n))\end{aligned}\quad (5.19)$$

$\frac{\partial E(n)}{\partial y_j(n)}$ kısmi türevini hesaplamak için ikinci satırda (5.13) kullanılmıştır. Şekil (5.4)'e göre

$$E(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n), \quad k \text{ çıkış katmanında} \quad (5.20)$$

bulunur. (5.20) denkleminde $y_j(n)$ 'ye göre türev alınırsa

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (5.21)$$

elde edilir. $\frac{\partial E(n)}{\partial y_i(n)}$ kısmi türevini bulmak için zincir kuralı kullanılır.

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (5.22)$$

Şekil (5.4)'ten

$$e_k(n) = d_k(n) - y_k(n)$$

$$=d_k(n)-\varphi_k(v_k(n)), \quad (5.23)$$

k çıkış katmanında bulunur. Yani,

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (5.24)$$

olarak yazılabilir. Yine şekil (5.4)'e göre, aktivasyon fonksiyonunun girişi de denklem (5.25)'te görüldüğü gibi yazılır:

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (5.25)$$

burada m, k nöronuna uygulanan toplam giriş sayısıdır (bias hariç). Denklem (5.25)'in $y_j(n)$ 'ye göre türevi alınır, denklem (5.26) bulunur.

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (5.26)$$

İstenen kısmi türevi elde edebilmek için denklem (5.24), (5.26) ve (5.22) kullanılır.

$$\begin{aligned} \frac{\partial E(n)}{\partial y_j(n)} &= -\sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) \\ &= -\sum_k \delta_k(n) w_{kj}(n) \end{aligned} \quad (5.27)$$

Son olarak, denklem (5.27), denklem (5.19)'da kullanılırsa, geriye yayılım algoritmasının $\delta_j(n)$ yerel gradyen formülü bulunur.

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \quad j \text{ gizli katmanda} \quad (5.28)$$

1986 yılında Rumelhart, geriye yayılım algoritmasının ağırlık güncelleme denklemine, momentum terimi ekleyerek, ağırlık yerel minimuma takılması olasılığını azaltmıştır [26]. Momentum terimi eklendikten sonra ağırlık güncelleme denklemi aşağıdaki hali alır:

$$w(n+1) = w(n) + \Delta w(n) \quad (5.29)$$

$$\Delta w_{ji}(n+1) = \eta \delta_j(n) y_i(n) + \alpha \Delta w_{ji}(n) \quad (5.30)$$

Yukarıda ayrıntılı bir biçimde anlatılan yapının bu çalışmada nasıl kullanıldığı ve Gölbaşı Bölgesi'ndeki yük tahmini sırasında nelere dikkat edildiği bir sonraki bölümde anlatılacaktır.

6. KISA DÖNEM YÜK TAHMİNİNİN YAPAY SİNİR AĞLARI İLE BİLGİSAYAR BENZETİMİ

6.1 Giriş

Literatürde, üçüncü bölümde bahsedilen ve yük tahmini için “geleneksel” olarak nitelendirilen yöntemler ile uygulaması yapılan çok sayıda kısa dönem yük tahmini çalışması bulunmaktadır. Bu bölümde, son yıllarda önemi iyice artan ve farklı alanlarda çok fazla uygulaması bulunan yapay sinir ağları yönteminin, kısa dönem yük tahmini problemine gerçek veriler ile uygulaması yapılacaktır. Yapay sinir ağlarının, kısa dönem yük tahmininde etkinliğini göstermek için regresyon yöntemi ile de karşılaştırma yapılacaktır.

Bu çalışmada kullanılan güç verileri Gölbaşı bölgesinin 2002 ve 2003 yıllarına ait gerçek verileridir [30]. Gölbaşı bölgesine dahil olan iller Ankara, Çankırı, Kayseri, Kırıkkale, Kırşehir, Konya, Nevşehir, Niğde, Yozgat ve Aksaray illeridir.

Yapay sinir ağları ve regresyon tekniklerine ilişkin bilgisayar benzetimi programları Matlab 6.5 programında m-file dosyaları hazırlanarak oluşturulmuştur [31]. Matlab 6.5 programının kendi bünyesinde bulunan Neural Network Toolbox kullanılmamıştır. Hazırlanan programa ilişkin akış diyagramı EK 1’de verilmiştir. Programların çalıştırıldığı bilgisayarın ve işletim sisteminin özellikleri şu şekildedir:

- AMD Athlon(TM) XP1800+ 1.63 GHz
- 256 MB RAM
- 30 GB Hard Disk
- 32 MB Ekran kartı
- Microsoft Windows XP Professional işletim sistemi

Tez çalışmasındaki yük tahmini modelinin kurulmasında [9]’daki benzerlik tabanlı model esas alınmıştır. Tezde, bu çalışmaya katılan yenilik, ağın eğitiminde kullanılacak benzer günün yük karakteristiğinin, yük tahmini yapılacak gününküne daha yakın seçilebilmesi için, benzer gün seçimindeki öklit normuna gün tipi endeksi

eklenmesidir. İkinci bir yenilik, haftasonu günlerinin ve bayramlar gibi diğer özel günlerin tahminindeki doğruluğu arttırmak amacıyla yapay sinir ağının girişine birincisi yük tahmini yapılacak günün gün tipi, diğeri yük tahmini yapılacak gün ile benzer günün gün tipleri farkı olmak üzere iki giriş daha eklenmesidir. Ayrıca yük tahmini yapılacak Gölbaşı Bölgesi'nin yük karakteristiğine bağlı olarak, dini bayramlara farklı bir gün tipi endeksi verilerek gün tipi sınıflandırmasında da değişikliğe gidilmiştir.

6.2 Yük Tahmini Modeli

Literatürde, kısa dönem yük tahmini için hem geleneksel yöntemler hem de yapay sinir ağları yöntemi ile yapılmış çok çeşitli çalışmalar vardır. Çalışmaların çoğunda birbirinden farklı modeller oluşturulmuştur. Her elektrik şebekesinin ve her tüketici bölgenin özellikleri birbirinden farklılık gösterdiği için fazla sayıda yük tahmini modelinin öne sürülmesi normal bir durumdur. Yük tahmini modeli oluşturulurken, tahmini yapılacak bölgenin iklimsel ve coğrafi özellikleri göz önünde bulundurulmalıdır. Bölgenin sadece tahminde kullanılacak olan birkaç aylık güç verisi değil birkaç yıllık güç tüketimi incelenmelidir. Böylelikle bölgenin yük tüketim karakteri çözümlenebilir ve sistem modeli buna göre oluşturulabilir.

Bu çalışmada, ertesı günün yük tahmini yapılmıştır. 24 saatlik tahmin yapıldığı için gün içindeki puant değerin de tahmini yapılmış olur. Ayrıca tahmin edilen 24 saatlik yük değerinden günlük yük eğrisi de çizilebilir.


Bölüm 2.5'de, 24 saatlik yük tahmini yapılacak olan Gölbaşı Bölgesi'nin yük etüdü yapılmıştır. Şekil 2.5'de dört farklı mevsimden örnek alınan salı gününün günlük yük eğrisi verilmiştir. Farklı mevsimlerdeki yük eğrileri incelendiğinde, gündüz-gece saatleri ve hava sıcaklıkları gibi etkilere dolaylı olarak yılın farklı mevsimlerinde yük eğrisinin karakterinin değiştiği gözlemlenir. Kış ve yaz aylarında bu farklılık kendini daha fazla göstermektedir. Kış aylarında puant yük akşam saatlerinde oluşurken, yaz aylarında öğlen saatlerinde oluşmaktadır. Bu yüzden, yük tahmini işlemi yapacak yapay sinir ağı eğitilirken tahmin edilecek güne takvimsel olarak en yakın olan günlerin verileri kullanılmalıdır. Eğitimi benzer günler ile yapmak tahminin doğruluğunu arttıracaktır. Daha sonra benzer günler arasındaki farklılığın nasıl yansıtıldığı ayrıntılı biçimde bahsedilecektir.

6.2.1 Yk Tahmininde Kullanılacak Verilerinin Belirlenmesi

Yk tahmininde kullanılacak veriler belirlenirken yk etkileyen faktrler gz nne alınmalıdır. Blm 2.4'e gre yk etkileyen faktrler,

- 1-Meteorolojik kořullar,
- 2- Zaman faktr,
- 3- Ekonomik ve demografik faktrler,
- 4- Rastlantısal faktrler idi.

Tahmin iřleminde kullanılacak verilerin belirlenmesi iin tm faktrleri tek tek incelemek yerinde olacaktır. Yk etkileyen meteorolojik kořulların bařında sıcaklık, nem, rzgar hızı, yaęıř ve bulut yoęunluęu gelir. Sıcaklıęa gre dięer faktrlerin yke etkisi ihmal edilecek kadar azdır. Sıcaklık haricindeki faktrler ihmal edilerek, hem iřlemler karmařıklıktan kurtarılıp daha yalın hale getirilir hem de yapay sinir aęının giriř sayısı azaltılmıř olunur. Bylelikle aęın eęitim sresi de kısalır. Ancak, yk tahmini yapılacak blgenin iklimsel zelliklerine gre bu faktrlerin yke etkisi ihmal edilemeyecek kadar fazla olabilir.




Şekil 6.1 Maksimum yk – maksimum sıcaklık iliřkisi

Şekil 6.1’de Gölbaşı Bölgesi’nin, 2002 yılı için günlük en yüksek sıcaklığı ile maksimum çekilen yük ilişkisi gösterilmiştir. Hava sıcaklığının en yüksek ve en düşük değerlerini bulduğu günlerde, talep edilen gücün de en yüksek değerlere ulaştığı gözlemlenebilmektedir. Sıcaklığın ortalama değerlerinde seyrettiği günlerde çekilen güç ise, yıllık en düşük değerlerindedir.

Tablo 6.1 Gölbaşı Bölgesi illerinin elektrik enerjisi tüketimleri

İLLER	TÜKETİM (MWh)
ANKARA	4.958.375
ÇANKIRI	128.872
KAYSERİ	1.475.192
KIRIKKALE	372.750
KIRŞEHİR	180.455
KONYA	1.777.542
NEVŞEHİR	424.483
NİĞDE	406.786
YOZGAT	402.241
AKSARAY	242.839



Şekil 6.2 Gölbaşı Bölgesi elektrik enerjisi tüketiminin illere göre yüzdesel dağılımı (MWh)

Bu çalışmada inceleme amacıyla verileri kullanılacak olan Gölbaşı Bölgesi için günlük maksimum ve minimum sıcaklık değerleri, bölge dahilindeki illerin yükünün, bölge toplam yüküne etkileri oranında ağırlıklı olarak hesaplanmıştır. Tablo 6.1’de Gölbaşı Bölgesi’ne dahil olan illerin MWh cinsinde tüketimleri ve Şekil 6.2’de

tüketimlerinin yüzdeleri verilmiştir. Bu yüzdeler incelendiğinde; Ankara, Kayseri ve Konya dışındaki illerin toplam yüke etkilerinin, Ankara, Kayseri ve Konya illerinin yükleri ile karşılaştırıldıklarında çok düşük ve ihmal edilebilir oldukları gözlenmektedir. Bu sonuçtan yola çıkarak Gölbaşı Bölgesi'nin maksimum ve minimum sıcaklıklarının hesaplanmasında, sadece Ankara, Kayseri ve Konya illerinin değerleri ağırlıklı olarak kullanılmıştır. Ankara, Kayseri ve Konya illerinin tüketim yüzdelerinden yola çıkarak aşağıdaki formül oluşturulmuştur:

$$T = 0,6T_{ank} + 0,18T_{kay} + 0,22T_{kon} \quad (6.1)$$

Formül oluşturulurken, ihmal edilen illerin toplam %21'lik tüketim yüzdesi; Ankara, Kayseri ve Konya illerine tüketim yüzdeleri ile orantılı olarak ilave edilmiştir. Bu nedenle, Ankara ilinin bölge içinde %48 olan tüketim yüzdesi, tüketimi az olan iller ihmal edildiğinde %60'a çıkar. Böylelikle bölge sıcaklığı hesabında kullanılan Ankara ili sıcaklık katsayısı 0,6; Kayseri ili sıcaklık katsayısı 0,18 ve Konya ili sıcaklık katsayısı ise 0,22 bulunmuştur. Bu hesaplamalar aşağıdaki gibi yapılmıştır:

Hesaba katılmayacak illerin toplam sıcaklık yüzdesi:

$$0,04 + 0,04 + 0,04 + 0,04 + 0,02 + 0,02 + 0,01 = 0,21$$

Hesaba katılacak illerin toplam sıcaklık yüzdesi: $0,48 + 0,17 + 0,14 = 0,79$

Ankara ilinin yeni sıcaklık yüzdesi:

$$0,48 + 0,21 \frac{0,48}{0,79} \cong 0,60$$

Konya ilinin yeni sıcaklık yüzdesi:

$$0,17 + 0,21 \frac{0,17}{0,79} \cong 0,22$$

Kayseri ilinin yeni sıcaklık yüzdesi:

$$0,14 + 0,21 \frac{0,14}{0,79} \cong 0,18$$

Hem maksimum sıcaklık hem de minimum sıcaklık hesabında bu formül kullanılmıştır. Tez çalışmasında Gölbaşı bölgesi'nin yük tahmini yapılacağı için bundan sonra bahsedilen tüm sıcaklık verileri Denklem (6.1)'e göre hesaplanan bölge sıcaklığıdır.

Ankara, Kayseri ve Konya illerine ait 2002 ve 2003 yıllarındaki günlük maksimum ve minimum hava sıcaklık verileri internetten elde edilmiştir [32].

Bölüm 2.5'deki yük eğrileri incelenecek olursa yükte gözle görülür en büyük etki zaman faktörüne aittir. Grafiklerde öncelikle göze çarpan haftalık ve günlük değişimlerdir. Haftalık ritimleri oluşturan işgünü - hafta sonu farklılığı, günlük ritimleri oluşturan ise insanların gün boyunca bulundukları sürekli ve belirli zamanlarda tekrarlanan senkron davranışlardır. Yük tahmini modeline zaman faktörünü ekleyebilmek için bir gün tipi endeksi belirlenmiştir. Hafta içi ve hafta sonu günlerinin ayrı ayrı sınıflandırılması gerektiği ortadadır. Ancak yük tahminin doğruluğu için bu da yeterli değildir. Yük karakterinin incelenmesi sonucu cumartesi, pazar, pazartesi ve cuma, diğer hafta içi günleri ve bayram gibi özel günler ayrı ayrı sınıflandırılmalıdır. Buna göre gün tipi faktörü şu şekilde belirlenmiştir:

- 1: dini bayramlar (Kurban Bayramı ve Ramazan Bayramı)
- 2: pazar, milli bayramlar, dini bayramların arife günleri, 1 Ocak günü
- 3: cumartesi
- 4: pazartesi, cuma
- 5: salı, çarşamba, perşembe

Dini bayramlar, tüm yıl içinde en az elektrik enerjisi tüketilen zamanlardır. Bununla birlikte bayramların yük eğrisinde gözlemlenen düzensizlik ve belirsizlikleri bu günlerin tahmininde zorluk getirmektedir. Dini bayramların yük karakteristiğindeki bu farklılıktan ötürü, onlar için ayrı gün endeksi belirlemek gerekmiştir. Yük eğrisinde milli bayramlar ve diğer resmi tatiller incelendiğinde, yükün diğer günlerden daha düşük olduğu fakat dini bayramlar seviyesine düşmediği görülür. Bu durumda milli bayramlar ve diğer resmi tatil günlerini pazar günleri ile aynı sınıfa sokmak uygun olacaktır.

Ekonomik ve demografik faktörler başlığı altına giren nüfus sayısı, mili gelir gibi faktörlerin etkisi ancak yıllık incelemelerde kendini gösterir. Kısa dönem yük tahmini en fazla aylık veriler ile ilgilendiği için bu faktörler göz önünde bulundurulmayacaktır. Ekonomik ve demografik faktörler uzun dönem yük tahmininde, yük talebinin belirlenmesinde en önemli etkenlerdir.


Rastlantısal faktörler, yükü etkileyen ancak yukarıda sayılan faktörler ile açıklanamayan olaylar idi. Rastlantısal faktörler bozucu etki olarak işin içine girer ve yük tahmine belirsizlik katar.

Sıcaklık ve gün tipinden başka yük tahmininde kullanılacak veri ise geçmiş günlerin yük yani çekilen güç bilgisidir. 24 saatlik yük tahmini yapılacağı için, geçmiş döneme ait güç bilgilerinin yine saatlik olarak kullanılması gerekmektedir.

6.2.2 Benzer Günlerin Seçimi

Yapay sinir ağının eğitiminde kullanılacak her gün için bir benzer gün seçilerek, eğitim bu benzer günün verileriyle gerçekleştirilir. Ancak, öncelikle tahmin edilecek güne göre çalışma aralığı belirlenmelidir. Benzer gün, yük tahmini yapılacak günden önceki 30 gün ile geçmiş yıldaki yük tahmini yapılacak güne denk düşen günden önceki ve sonraki 30 gün arasından seçilir [9,33,34]. Toplam 90 gün arasında araştırma yapılır. Bahsedilen çalışma aralığı Şekil 6.3’de gösterilmiştir. Her yıl aynı zamanlarda mevsimsel etkilerden ötürü yük karakteristikleri benzerlik gösterdiğinden, çalışma aralığını bu sınırlar dahilinde tutmak yeterli olacaktır.

Dini Bayramların yük tahmini yapılacağı zaman, bu sınırlar, geçmiş yıldaki bayram günlerini de kapsayacağından, eğitim kümesinde tahmin edilecek güne yakın örnekler bulunacaktır.



Şekil 6.3 Benzer gün seçimi için sınırlar

Yapılacak çalışmada, 90 günlük çalışma aralığı seçildikten sonra, sıra hem tahmin edilecek gün hem de eğitim kümesindeki tüm günler için, bu aralıktan benzer gün seçmeye gelir. Benzer gün, günlük maksimum sıcaklık, minimum sıcaklık ve gün tipi kullanarak oluşturulan ağırlıklı öklit normu ile bulunur. Ağırlıklı öklit normu aşağıdaki formül ile bulunur:

$$D = \sqrt{\hat{g}_1 \Delta T_{mak}^2 + \hat{g}_2 \Delta T_{min}^2 + \hat{g}_3 \Delta G\ddot{u}n^2} \quad (6.1)$$

$$\Delta T_{mak} = \hat{T}_{mak} - T_{mak}^p \quad (6.2)$$

$$\Delta T_{min} = \hat{T}_{min} - T_{min}^p \quad (6.3)$$

$$\Delta G\ddot{u}n = \hat{G\ddot{u}n} - G\ddot{u}n^p \quad (6.4)$$

Yukarıdaki denklemlerde verilen $\hat{T}_{mak}$ ve $\hat{T}_{min}$ tahmin edilecek güne ait maksimum ve minimum sıcaklıklar, T_{mak}^p ve T_{min}^p ise araştırılan güne ait maksimum ve minimum sıcaklıklardır. $\hat{G\ddot{u}n}$; tahmin edilecek günün gün tipi, $G\ddot{u}n^p$; araştırılan günün gün tipidir. $\hat{g}_1$, $\hat{g}_2$ ve $\hat{g}_3$ ise ağırlık faktörlerini verir. Ağırlıklar aşağıda formülü de verilen çoklu regresyon modeline dayandırılan en küçük kareler yöntemi ile bulunur.

$$P_{mak} = \hat{g}_0 + \hat{g}_1 T_{mak} + \hat{g}_2 T_{min} + \hat{g}_3 G\ddot{u}n \quad (6.5)$$

Ağırlık faktörlerinin sisteme dahil edilmesinin nedeni yükü etkileyen maksimum sıcaklık, minimum sıcaklık ve gün tipi faktörlerinin her birinin maksimum güç üzerindeki etkisini bularak, etkisi oranında öklit normuna dahil edilip en uygun

benzer günü bulmaktır. Bu formülde P_{mak} , güç içindeki maksimum yük (puant güç) değeri; T_{mak} , maksimum sıcaklık; T_{min} , minimum sıcaklık, $Gün$ ise Bölüm 6.2.1’de değerleri gösterilen gün tipidir.

(6.5)’deki denklem takımı, incelenen (verileri kullanılacak olan) 90 gün için kurulur. Oluşturulan 90 denklemin çoklu regresyon modeline uyarak ortak çözülmesi ile $\hat{g}_i$ ($i=0\sim3$) ağırlıkları bulunur. Bulunan ağırlıklar (6.1)’de yerine konarak yine araştırılan 90 gün için D değerleri hesaplanır. Bulunan 90 adet D değeri içinden en küçük olanını veren gün, tahmin edilecek güne ait benzer gündür. Yapay sinir ağının eğitimi tamamlandıktan sonra tahmin işlemi yapılırken bu benzer güne ait veriler ağı sunulur.

Eğitim aşamasında, eğitim kümesindeki günlerin benzer gün seçimi de bu yolla yapılır.

6.3 Yapay Sinir Ağı

Bu çalışmada kısa dönem yük tahmini için eğitici öğrenmeli, çok katmanlı, ileri beslemeli bir yapay sinir ağı modeli kullanılmıştır. Eğitici öğrenmede, nöronları birleştiren ağırlıklar, eğitici tarafından ayrıntılı hata bilgileri ağı uyarlanacak şekilde yerleştirilirler. Yapay sinir ağı, giriş – çıkış çiftleri yani örüntüler kullanılarak eğitilir. Bu uygulamada ağın girişlerini, ağın çıkışındaki güne ait benzer gününün değerleri oluşturmaktadır. Giriş – çıkış eğitim kümesi bilindiğine göre eğitici öğrenmeli bir yapay sinir ağı modeli kullanılması uygundur.


Eğitici öğrenmeli en basit ağ yapısı, bir giriş ve bir çıkış katmanı bulunan, iki katmanlı, ileri beslemeli ağıdır. Çıkış katmanındaki her bir nöron, düzeltilebilen ağırlıklar yoluyla, bütün giriş nöronlarından işaret alır. Ancak iki katmanlı ileri beslemeli yapay sinir ağları sadece doğrusal ayrıştırılabilir fonksiyonları hesaplayabilir. Daha karmaşık problemlerin çözümünde, birden fazla uyarlamalı ağırlıklı katmana sahip olan bir ileri beslemeli ağ kullanılmalıdır. Yük tahmini problemi de doğrusal olmadığından, kullanılacak ağ da çok katmanlı yapay sinir ağı olmalıdır.

Çok katmanlı yapay sinir ağlarında, birden çok gizli katman kullanılması, çoğu problem için hatanın değerini fazla etkilemediği gibi, sonuçların kesinliğinin artmasına da fazla katkıda bulunmaz. Bununla beraber, ikinci bir gizli katmanın

varlığı, hesaplama süresinin uzamasına sebep olur. Bu yüzden oluşturulan yapay sinir ağı modelinde tek gizli katman bulunmaktadır.

Gizli katmanda kullanılan aktivasyon fonksiyonu sigmoiddir. Çıkış katmanında ise doğrusal aktivasyon fonksiyonu kullanılmıştır.

Kısa dönem yük tahminini yapacak 24 çıkışlı yapay sinir ağı modeli Şekil 6.4’de verilmiştir. Giriş katmanında 30, gizli katmanda 53, çıkış katmanında ise 24 adet nöron bulunmaktadır. Gizli katman nöron sayısı deneme yanılma yoluyla bulunmuştur.



Şekil 6.4 Yapay sinir ağı modeli

Yapay sinir ağının çıkış katmanını oluşturan 24 nöron, tahmin edilecek günün saat 01:00’dan gece saat 00:00’a olan saatlik güç değerleridir.

Giriş katmanında 30 giriş vardır. Bunların dağılımı şu şekildedir:

1-24. girişler: Benzer güne ait 24 saatlik güç değerleri, P_i^k ($i=1\sim 24$)

25. giriş: Yük tahmini yapılacak güne ait maksimum sıcaklık tahmini değeri, $\hat{T}_{mak}$

26. giriş: Yük tahmini yapılacak güne ait minimum sıcaklık tahmini değeri, $\hat{T}_{min}$

27. giriş: Tahmin edilecek gün ile benzer gün maksimum sıcaklıklarının farkı, ΔT_{mak}^k

$$\Delta T_{mak}^k = \hat{T}_{mak} - T_{mak}^k \quad (6.8)$$

28. giriş: Tahmin edilecek gün ile benzer gün minimum sıcaklıklarının farkı, ΔT_{min}^k

$$\Delta T_{\min}^k = \hat{T}_{\min} - T_{\min}^k \quad (6.9)$$


29. giriş: Tahmin edilecek günün gün tipi, $\hat{G}_{\min}$ (1,2,3,4 yada 5)

30. giriş: Tahmin edilecek gün ile benzer günün gün tipi endeksleri farkı, $\Delta G_{\min}^k$

$$\Delta G_{\min}^k = \hat{G}_{\min} - G_{\min}^k \quad (6.10)$$

6.3.1 Eğitim Kümesinin Normalizasyonu

Çok katmanlı yapay sinir ağında, beşinci bölümde anlatılan aktivasyon fonksiyonlarından logaritmik sigmoid fonksiyonu kullanılmıştır. Logaritmik sigmoid fonksiyonu, sonsuz giriş aralığını, sonlu sayıda çıkış aralığına (0 – 1) sıkıştırır. Şekil 6.5’de logaritmik sigmoid fonksiyonu grafiği ve denklem (6.11)’de matematiksel ifadesi verilmiştir.



Şekil 6.5 Logaritmik sigmoid fonksiyonu

$$\varphi(v) = \frac{1}{1 + e^{(-av)}} \quad (6.11)$$

Logaritmik sigmoid fonksiyonunun çıkışı 0 – 1 değerleri arasında olduğu için, eğitim kümesi elemanlarının değerleri de 0 – 1 arasında olmalıdır. Bununla birlikte, logaritmik sigmoid fonksiyonunun hemen doymaya girmemesi için, giriş değerlerinin de yeterince küçük olması gerekir. Sigmoid fonksiyonunun bu özelliğinden dolayı, ağ eğitilmeden önce giriş ve çıkış verileri normalize edilerek, istenen sınırlar dahilinde olmaları sağlanmalıdır.

Normalizasyonu gerçekleştirmek için aşağıdaki formülasyon kullanılmıştır:

$$r = \frac{A_{mak} - A_{min}}{V_{mak} - V_{min}} \quad (6.12)$$

olmak üzere;

$$A = r(V - V_{min}) + A_{min} \text{ dir.} \quad (6.13)$$

Yukarıdaki formüllerde;

V_{mak} : Gerçek değerlerin en büyük olanı,

V_{min} : Gerçek değerlerin en küçük olanı,

A_{mak} : En büyük normalizasyon değeri,

A_{min} : En küçük normalizasyon değeri,

V : Normalize edilecek değer,

A : Normalize edilmiş değerdir.

Matlab’de m-file dosyalarında hazırlanan programın normalizasyon ile ilgili bölümü A_{mak} ve A_{min} değerleri değiştirilebilir, serbest parametre olacak şekilde hazırlanmıştır. Böylelikle farklı normalizasyon sınırlarını test etmek mümkün olmuştur. Yapılan denemeler sonucu maksimum normalizasyon için 0,9 ve minimum normalizasyon için 0,1 değerleri en uygun sonucu vermiştir.

Yapay sinir ağının girişindeki veya çıkışındaki her bir nörona karşılık gelen değerler kendi aralarında normalize edilmiştir. Örneğin, yapay sinir ağının girişindeki maksimum sıcaklık verilerine denk düşen 25. girişe bakacak olursak, normalizasyon işlemi sonunda eğitim kümesindeki bu nörona denk düşen en büyük değer olan 36,64 değeri 0,9’a ve en küçük değer olan -8,84 değeri ise 0,1’e dönüşmüştür.

Yük tahmini işlemi sonucu ağın çıkışındaki bulunan değerler, normalize edilmiş değerlerdir. Gerçek tahmin değerlerinin bulunabilmesi için normalize edilmiş değerlerin geri normalize edilmesi gerekmektedir. Ters normalizasyon için şu formül kullanılır:

$$V = \frac{(A - A_{min})}{r} + V_{min} \quad (6.14)$$

6.3.2 Algoritmanın Uygulanması

Yapay sinir ağları konusunda çok çeşitli çalışmalar yapılmasına karşın, ağda kullanılan parametrelerin kesin hesabına yönelik bir yöntem bulunamamıştır. Parametre hesaplarına ilişkin çeşitli çalışmalar yapılmış olsa da bunlar her problemin çözümüne uygun yanıt veremezler. Yapay sinir ağlarının, dördüncü bölümde de anlatıldığı gibi çok farklı disiplinlerde çok çeşitli uygulamaları olup, farklı problemler için farklı ağ yapıları sunar. Bu yüzden, ağ parametrelerinin hesaplanması için deneme yanılma yöntemi kullanılmıştır.

Geriye yayılım algoritmasında, öğrenme hızı, sonuca ulaşma hızı ile doğrudan ilgilidir. Öğrenme hızı çok küçük seçilirse, ağırlıklardaki değişim bir iterasyondan diğerine geçerken az olacaktır. Bu yüzden sonuca ulaşmak uzun zaman alır. Buna karşılık öğrenme hızı çok büyük seçilirse, öğrenme hızlı olmasına rağmen, çözüm civarında salınım yaparak yakınsamayı uzaklaştırır. Hem hızlı bir öğrenme sağlamak hem de salınımları engellemek için standart geriye yayılım algoritmasına aşağıdaki formülde görüldüğü gibi momentum terimi (α) eklenir.

$$\Delta w(n+1) = \eta \delta_j y_i + \alpha \Delta w(n) \quad (6.15)$$

Formülde η , öğrenme hızını ve α ise momentum terimini ifade eder.

Öğrenme hızı ve momentum katsayısı 0 – 1 değerleri arasında olur.

Durdurma koşulu olarak tanımlanan hata ise; rms hata olup,

$$rms = \sqrt{\frac{1}{N \cdot n_o} \sum_{j=1}^N \sum_{k=1}^{n_o} (d_{jk} - y_{jk})^2} \quad (6.16)$$

olarak tanımlanır. Eğer hata belirlenmiş 0.01 değerini yakalayamazsa, önceden tanımlanmış iterasyon sayısı kadar ağ eğitilir. İterasyon sayısı 500 olarak tanımlanmıştır.

Geriye yayılım algoritması ile eğitilen çok katmanlı yapay sinir ağındaki parametreler

- gizli katman nöron sayısı,
- öğrenme hızı,
- momentum terimi ve

- sigmoid fonksiyonu için α değeridir.

Bir parametrelerin en uygun değerinin bulunması için diğer parametreler sabitken, bu parametrenin değeri değiştirilerek, en az hatayı veren değer sabit kılınmıştır. Tüm parametreler için bu deneme yanılma işlemi tekrarlandıktan sonra, değerler Tablo 6.2’de verildiği gibi sabitlenmiştir:

Tablo 6.2 Yapay sinir ağı parametreleri

gizli katman nöron sayısı	53
öğrenme hızı (η)	0,057
momentum terimi (α)	0,1
sigmoid fonksiyonu katsayısı (a)	1

6.4 Regresyon

Kısa dönem yük tahmini probleminde, yapay sinir ağı yönteminin etkinliğini karşılaştırmak amacıyla, istatistiksel tahmin yöntemlerinden regresyon yöntemi ile de tahminler gerçekleştirilmiştir.

Oluşturulan regresyon modelinde, yapay sinir ağına olduğu gibi değişken olarak maksimum sıcaklık, minimum sıcaklık ve gün tipi kullanılmıştır. Tahmin edilecek günün her saati için, aşağıdaki denklemdeki gibi maksimum sıcaklık, minimum sıcaklık ve gün tipi bağımsız değişken oluştururlar.

$$P_i = a_{i0} + a_{i1}T_{mak} + a_{i2}T_{min} + a_{i3}Gün \quad (i=1\sim24) \quad (6.17)$$

Bu denklem her saat için ayrı oluşturulur.

Yapay sinir ağı yönteminde kullanılacak modelde olduğu gibi bu modelde de tahmin edilecek günden önceki 30 gün ile geçmiş yıldaki tahmin edilecek güne denk düşen günden önceki ve sonraki 30 gün toplamda 90 günün verileri kullanılır. Her iki yöntemde de aynı veri grubunun kullanılmasıyla, daha sonra yapılacak karşılaştırmaya, bu bakımdan bir denklik getirilmiş olunur. Tahmin edilecek her saat için çalışma aralığındaki 90 günün maksimum sıcaklık, minimum sıcaklık ve gün tipi bilgileri kullanılarak 90 adet denklem kurulur. Çoklu regresyon en küçük kareler tekniğine göre denklem takımlarının ortak çözülmesi ile her saat için a_0 , a_1 , a_2 ve a_3

katsayıları çözülür. Yük tahmini yapılacak günün maksimum sıcaklık, minimum sıcaklık ve gün tipi değerlerinin, a katsayıları çözümlenen 24 ayrı güç denkleminde yerine konması ile, 24 saat için yük tahmin değerleri bulunmuş olur.

6.5 Bilgisayar Benzetim Programı

Kısa dönem yük tahmininin bilgisayar benzetimi için Matlab 6.5 programı kullanılmıştır. Benzetim için hazırlanan program, giriş olarak dört veri dosyasını kullanır. Bunlar:

- 2002 ve 2003 yıllarındaki tüm günlere ait 24 saatlik güç değerleri,
- 2002 ve 2003 yıllarındaki tüm günlere ait maksimum sıcaklık değerleri,
- 2002 ve 2003 yıllarındaki tüm günlere ait minimum sıcaklık değerleri,
- 2002 ve 2003 yıllarındaki tüm günlere ait gün tipi değerleridir.

Kullanıcı tarafından belirlenen serbest değişkenler ise, yük tahmini yapılacak günü gösteren sayı, en küçük ve en büyük normalizasyon değerleri, gizli katmandaki nöron sayısı, öğrenme hızı, momentum terimi, iterasyon sayısı, durdurma hatası ve sigmoid fonksiyonu eğim katsayısıdır.

Tahminci tarafından belirlenen, yük tahmini yapılacak güne göre, yük tahmini benzetim programı Şekil 6.3'de gösterilen sınırlar dahilinde kullanacağı veriler seçer, diğer verileri ayıklar. Bu sınırlar dahilindeki günler eğitim kümesinin elemanlarını oluşturur. Ancak, eğitim kümesindeki her bir gün için tek tek benzer gün belirlenir ve buna göre eğitim kümesi yani girişler ve girişlere karşılık düşen çıkışlar tekrar düzenlenir. Ayrıca yük tahmini yapılacak gün için de benzer gün seçilir. Eğitim kümesinin belirlenip düzenlenmesinden sonra, tüm giriş ve çıkışlar, ağa sunulabilmeleri için normalize edilir. Normalize edilen değerler, yapay sinir ağı girişlerine uygulanır. Geriye yayılım algoritması, belirlenmiş iterasyon sayısı gerçekleştirilene kadar yada, hata belirli bir değeri yakalayana kadar devam eder. Eğitim işleminin sonunda, ağ üzerindeki ağırlıklar belirlenmiş olur. Programın ağa, tahmin edilecek güne ait girişleri sunması sonucu , ağın çıkışında normalize edilmiş 24 saatlik tahmin değerleri elde edilir. Bu değerleri geri normalize eden program gerçek tahmin değerlerini verir.

6.6 Sonular

Kısa dnem yk tahmini yapmak amacıyla geliřtirilen yapay sinir ağı modeli, hazırlanan bilgisayar benzetimi programı ile test edilmiřtir. 2003 yılına ait gerek g deęerleri bilindięi iin, testler karřılařtırma imkanının olduęu, 2003 yılı gnleri iin yapılmıřtır. Yapay sinir ağı ynteminin elveriřlilięinin kontrol edilmesi amacıyla aynı testler regresyon analizi yntemi ile de yapılmıřtır. Aynı gn iin yapılan yapay sinir ağı yntemi ile yapılan tahmin, regresyon analizi yntemi ile yapılan tahmin ve gerek g deęerleri aynı grafik zerine izdirilerek oluřan farkların gzlemlenebilmesi saęlanmıřtır.

Bilgisayar benzetimi sonularının en iyi řekilde gzlemlenebilmesi iin yılın farklı zamanlarından, farklı mevsimlerden ve farklı gn tipi endeksine sahip gnler iin testler yapılmıřtır:

1. Hafta ii gn, kış mevsimi,
2. Hafta ii gn, ilkbahar mevsimi,
3. Hafta ii gn, yaz mevsimi,
4. Hafta ii gn, sonbahar mevsimi,
5. Pazartesi gn,
6. Cuma gn,
7. Cumartesi gn,
8. Pazar gn,
9. Milli Bayram rneęi,
10. Dini Bayram rneęi.

Yukarıda sıralanan gn rneklarine ait yapay sinir ağı ve regresyon analizi yntemlerine iliřkin karřılařtırmalı tahmin sonuları EK-B’de verilmiřtir.

Yk tahmini yntemlerinin performanslarını ortaya koymak amacıyla her iki yntem iin yzde hata hesaplanmıřtır. Tablo 6.3’de bilgisayar benzetim programı ile yapılan yk tahmini testleri iin bir gnlk maksimum yzde hata deęerleri ve programların alıřma sreleri verilmiřtir. Yzde hata 24 saat iin hesaplanır. Bir saatin yzde hata hesabı ařaęıdaki řekilde yapılır:

$$yüzdehata = \frac{|gerçekdeğer - tahmindeğeri|}{gerçekdeğer} . 100 \quad (6.18)$$

Tablo 6.3 Bilgisayar benzetimi sonuçları

		YSA		Regresyon	
Test edilen veriler	Tarih	Mak. Hata Yüzdesi (%)	Süre	Mak. Hata Yüzdesi (%)	Süre
1	26.02.2003	8.5938	32.7650	10.6487	0.2650
2	13.05.2003	9.0270	31.1410	11.5413	0.2030
3	14.08.2003	5.7212	31.5780	10.1632	0.2340
4	13.11.2003	6.2354	32.1410	9.1384	0.2190
5	26.05.2003	7.9779	32.0620	15.9388	0.2810
6	13.06.2003	8.8751	34.2180	9.6664	0.2340
7	20.09.2003	4.6661	33	16.5026	0.1250
8	19.10.2003	10.2408	30.7820	11.0919	0.2190
9	19.05.2003	13.1591	32.7810	11.7897	0.1250
10	12.02.2003	13.5815	32.8590	30.3498	0.2190

7. SONUÇLAR VE ÖNERİLER

Bu çalışmada, İç Anadolu'daki Gölbaşı bölgesi'nin 2002 ve 2003 yılına ait yük ve sıcaklık verilerini kullanarak 2003 yılına ait farklı özelliklere sahip günlerin yük tahmini, regresyon analizi ve geriye yayılım algoritması ile eğitilmiş yapay sinir ağı ile yapılmış ve 2003 yılına ait gerçek değerlerle karşılaştırılmıştır.

Tezin giriş bölümünde genel olarak çalışmanın amacından ve kısa dönem yük tahmininin gerekliliğinden bahsedilmiştir. Ayrıca daha önce konuyla ilgili yapılan önemli çalışmalara değinilmiştir. İkinci bölümde yük tahmini konusu detaylı olarak anlatılmıştır. Konu bütünlüğü açısından kısa dönem yük tahmini ile birlikte uzun dönem, orta dönem ve çok kısa dönem yük tahmini konularından da bahsedilmiştir. Kısa dönem yük tahmini için önemli unsurlardan biri olan yük sınıflarına ve farklı yük sınıflarının özelliklerine değinilmiştir. Bununla beraber yükü etkileyen faktörler gösterilerek Gölbaşı Bölgesi'nin gerçek güç verileri üzerinde bu faktörler anlatılmıştır. Gölbaşı Bölgesi'nin yük etüdü yapılarak, bu çalışma ışığında hangi faktörlerin oluşturulacak yük tahmini modeline nasıl eklenmesi gerektiğine karar verilmiştir. Üçüncü bölümde kısa dönem yük tahmininde kullanılan yöntemlerden bahsedilmiştir. Dördüncü bölümde, bu tez çalışmasında kullanılan yöntem olan yapay sinir ağı yöntemi anlatılmıştır. Yapay sinir ağı çalışmalarının tarihsel gelişimi, yapay sinir ağlarının özellikleri ve kullanım alanları, yapay sinir ağı nöronunun gerçek sinir hücresi ile benzeşimi, kullanılan aktivasyon fonksiyonları, yapay sinir ağlarının yapılarına ve öğrenme şekillerine göre sınıflandırılması ve farklı yapay sinir ağı modelleri burada anlatılmıştır. Beşinci bölümde ise, tez çalışmasında yapay sinir ağının eğitiminde kullanılan geriye yayılım algoritmasından bahsedilmiştir. Çalışmanın esasını oluşturan altıncı bölümde, detaylı olarak yapılanlar anlatılmıştır. Yük tahmin modelinin oluşturulması, benzer günlerin seçilmesi, yapay sinir ağı modelinin oluşturulması ve gerçekleşmesi, bilgisayar benzetim programının çalışması anlatılmıştır.

[9] numaralı referansdaki benzerlik tabanlı model esas alınarak, tez çalışmasındaki yük tahmini modeli kurulmuştur. Ağın eğitiminde kullanılacak benzer günün yük

karakteristiğinin, yük tahmini yapılacak gününküne daha yakın seçilebilmesi amacıyla, benzer gün seçimindeki öklit normuna gün tipi endeksi eklenmiştir. Hafta sonu günlerinin ve bayramlar gibi diğer özel günlerin tahminindeki doğruluğu arttırmak amacıyla da yapay sinir ağının girişine birincisi yük tahmini yapılacak günün gün tipi, diğeri yük tahmini yapılacak gün ile benzer günün gün tipleri farkı olmak üzere iki giriş daha eklenmiştir. Ayrıca yük tahmini yapılacak Gölbaşı Bölgesi'nin yük karakteristiğine bağlı olarak, dini bayramlara farklı bir gün tipi endeksi verilerek gün tipi sınıflandırmasında değişikliğe gidilmiştir.

Kısa dönem yük tahmini çalışması yapay sinir ağları yönteminin yanı sıra geleneksel yöntemlerden regresyon yöntemi ile de gerçekleştirilmiştir. Böylelikle her iki yöntemin farklı yönlerden karşılaştırmasını yapmak mümkün olmuştur. Yöntemlerin eşit koşullar altında çalışması, dolayısıyla karşılaştırmanın mümkün olduğunca sağlıklı olması için her iki yöntemde de aynı veri tipleri ve aynı veri grubuyla çalışılmıştır. Kullanılmış olan veri tipleri; 24 saatlik güç verileri, günlük maksimum sıcaklık ve minimum sıcaklık verileri ve gün tipi verileridir. Yük tahmini yapılacak günden önceki 30 günün ile geçmiş yıldaki yük tahmini yapılacak güne denk düşen günden önceki ve sonraki 30 günün, toplamda 90 günün verileri kullanılan veri grubunu oluşturmuştur.

Bilgisayar benzetimi sonuçlarının en iyi şekilde gözlemlenebilmesi ve daha objektif sonuçlar çıkarabilmek için yılın farklı zamanlarından, farklı mevsimlerden ve farklı gün tipi endeksine sahip günler için testler yapılmıştır. Buna göre kış, ilkbahar, yaz, sonbahar mevsimlerinde hafta içi günleri, pazartesi, cuma, cumartesi ve pazar günü ayrıca milli bayram ve dini bayram günleri için testler yapılmıştır. Testler sonucu her saat için hatalar yüzde cinsinden hesaplanmıştır. YSA ve regresyon yöntemleri ile yapılan testler sonucu bulunan maksimum hata yüzdeleri ve bilgisayar benzetimi işlem zamanları Tablo 6.3'de verilmiştir. Ayrıca sonuçların görsel ifadesi için, test edilen günlere ait hem yapay sinir ağları yöntemi sonucu elde edilen, hem regresyon yöntemi sonucu elde edilen, hem de gerçek değerlere ait 24 saatlik günlük yük eğrileri aynı grafikler üzerinde EK B'de verilmiştir.

Tüm grafikler incelendiğinde, yapay sinir ağı yönteminin sonucunun regresyon yöntemine göre, gerçek değerlere daha yakın olduğu görülmüştür. Aynı sonuç, tabloda verilen hata yüzdeleri incelendiğinde de çıkarılabilir.

Sonuçlara bakıldığında, yapay sinir ağı'nın performansının regresyon yöntemine göre daha üstün olmasına karşın, işlem zamanları karşılaştırılacak olunursa; regresyon yöntemine ait programın, yapay sinir ağı yöntemini gerçekleyen programa göre çok daha kısa sürede yanıt verdiği anlaşılmaktadır. Aynı zamanda, regresyon yöntemi için kurulan algoritma, yapay sinir ağı'ninki ile karşılaştırıldığında daha yalın kalmaktadır. Ancak yük tahmini programının sadece bir kez oluşturulup, daha sonra aynı program üzerinden çalışılacağı hesap edilirse, yapay sinir ağı yöntemine ait bu olumsuz özelliğin tolere edilebilir olduğu görülür. Aynı şekilde, bu tez çalışmasında gerçekleştirilen, ertesi günün yük tahminini yapan programın günde sadece bir kez çalıştırılacağı ve de bilgisayar teknolojinin sürekli geliştiği düşünülürse, 30-35 saniyelik işlem süresinin çok fazla etkileyici olmadığı kabul edilebilir.

Dini bayram günü için yapılan tahminlere bakılırsa, her ne kadar yapay sinir ağı yöntemi regresyona göre daha iyi sonuç verse de yine de, yüzde hata diğer günlere göre yüksek kalmıştır ve istenilen sonuca yeteri kadar yaklaşmamıştır. Bunun nedeni eğitim kümesinde dini bayram günlerine ait çok az sayıda örnek bulunmasıdır. Eğer yük tahmini modeli içine 2 yıl öncesinin yük tahmini yapılacak günden önceki ve sonraki 30 günü de dahil edilirse sonuçların gerçek değerlere daha yakın olacağı ve hatanın düşeceği öngörülebilir. Ancak kısa dönem yük tahmini konusunda çalışma yapmanın en büyük zorluklarından biri de gerçek 24 saatlik güç verilerine ulaşmaktır. Bu sebeple, bu tez çalışması için sadece 2002 ve 2003 yıllarına ait veriler elde edilebildiği için iki yıl öncesinin verileri eğitim kümesine katılmamıştır. Bu çalışmada kullanılan 24 saatlik güç verilerini sağlayan TEİAŞ Ulusal Yük Dağıtım Merkezi'ne teşekkürlerimi sunarım.

Bu tez çalışmasında, yapılan tüm çalışmalar sonucu yapay sinir ağı yönteminin kısa dönem yük tahmini problemine uygulanabilirliği gösterilmiştir. Yöntemin geleneksel yöntemlerden üstünlüğünü göstermek amacıyla ise regresyon yöntemi karşılaştırmalar yapılmıştır.

Elde edilen sonuçlar, kullanılan model ve yöntemin pratikte uygulanabilir olduğunu göstermektedir. Tez çalışmasında Matlab 6.5 programı kullanılarak yazılan m-file dosyalarıyla oluşturulan bilgisayar benzetimi kullanılmıştır. Ancak kısa dönem yük tahmini programının pratikte uygulanabilirliği için kullanıcı arayüzü oluşturmak uygun olacaktır. Konu ile ilgili ileride yapılacak çalışmalarda, özel günler için yapılan tahminlerdeki hatanın azaltılması hedef alınabilir. Özellikle dini bayram

günlerinin yük tahminini iyileştirme yönünde çalışmalara gereksinim vardır. Bunun için eğitim kümesindeki örnekler arttırılarak, ağın bayram günlerini daha iyi öğrenmesi sağlanabilir ve gün tipi endeksi üzerinde daha detaylı çalışılabilir.

KAYNAKLAR


- [1] **LEE, K. Y., PARK, J. H.**, 1992. Short-Term Load Forecasting Using An Artificial Neural Network, IEEE Transactions on Power Systems, **Vol. 7, No.1**, pp.124-132.
- [2] **BAKIRTZIS, A. G., PETRIDIS, V., KLARTZIS, S. J., ALEXIADIS, M.C.**, 1996. A Neural Network Short Term Load Forecasting Model For Greek Power System, IEEE Transactions on Power Systems, **Vol. 11, No.2**, pp.858-863.
- [3] **LAMEDICA, R., PRUDENZI, A., SFORNA, M., CACIOTTA M., CENCELLI V.O.**, 1996. A Neural Network Based Technique For Short-Term Forecasting of Anomalous Load Periods, IEEE Transactions on Power Systems, **Vol. 11, No.4**, pp.1749-1755.
- [4] **LU, C. N., WU, H. T., VEMURI, S.**, 1993. Neural Network Based Short Term Load Forecasting, IEEE Transactions on Power Systems, **Vol. 8, No.1**, pp.336-342.
- [5] **AMJADY, N.**, 2001. Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability, IEEE Transactions on Power Systems, **Vol. 16, No.4**, pp.798-805.
- [6] **HAIDA, T., MUTO, S.**, 1994. Regression Based Peak Load Forecasting Using A Transformation Technique, IEEE Transactions on Power Systems, **Vol. 9, No.4**, pp.1788-1794.
- [7] **KRUNIC, S., KRCDMAR, I., RAJAKOVIC, N.**, 2000. An Improved Neural Network Application For Short-Term Load Forecasting in Power Systems, Electric Machines and Power Systems, **Vol. 28**, pp.703-721.
- [8] **SINGH, D., SINGH, S. P.**, 2001. A Self Selecting Neural Network For Short-Term Load Forecasting, Electric Power Components and Systems, **Vol. 29**, pp.117-130.

- [9] **SENJYU, T., SAKIHARA, H., TAMAKI, Y., UEZATO, K.**, 2001. Next-Day Load Curve Forecasting Using Neural Network Based On Similarity, Electric Power Components and Systems, **Vol.29**, pp.939-948
- [10] **AKSEL, F.**, 2000. Regresyon Analizi ve Yapay Sinir Ağı Yöntemleri ile Uzun Dönem Yük Tahmini, *Yüksek Lisans Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul
- [11] **GÜRSOY, E.**, 2000. Yük Tahmini Yöntemleri ve Çukurova Elektrik A.Ş., Kepez Elektrik T.A.Ş. Bölgelerine Uygulanması, *Yüksek Lisans Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul
- [12] **KENÇ, N.**, 1998. Yük Tahmini ve Beyoğlu Bölgesine Uygulanması, *Yüksek Lisans Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul
- [13] **GROSS, G., GALIANA, F. D.**, 1987. Short-Term Load Forecasting, Proceedings of the IEEE, **Vol.75, No.12**, pp.1558-1573.
- [14] **MURTO, P.**, 1998., Neural Network Models for Short-Term Load Forecasting, Hesinki University of Technology, Helsinki,
<http://www.hut.fi/Units/SAL/Publications/pdf-files/tmur98.pdf>
- [15] **NETO, L. S. R., VELLASCO, M., FIGUEIREDO, K., PACHECO, M. A.**, Modeling Neural Networks to Very Short-Term Load Forecasting,
http://www.ica.ele.puc-rio.br/publicacoes/pbl_abstract.asp?Referencia=cnf_0021
- [16] **CHARYTONIUK, W., CHEN, M. S.**, 2000. Very Short-Term Load Forecasting Using Artificial Neural Networks, IEEE Transactions on Power Systems, **Vol. 15, No.1**, pp.263-268.
- [17] **LIU, K., SUBBARAYAN, S., SHOULTS, R. R., MANRY, M. T., KWAN, C., LEWIS, F. L., NACCARINO, J.**, 1996. Comparison of Very Short-Term Load Forecasting Techniques, IEEE Transactions on Power Systems, **Vol. 11, No.2**, pp.877-881.
- [18] <http://www.tedas.gov.tr/2004yiliparakedesatistarifesiusulveesaslari.doc>
- [19] **PALA, İ.**, 1998, Elektrik Sistemlerinde Bölgesel Yük Tahmini, *Yüksek Lisans Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul


- [20] Türkiye Elektrik Dağıtım ve Tüketim İstatistikleri, AR-GE Planlama ve Dış İlişkiler Daire Başkanlığı Enerji Talepleri Değerlendirme ve İstatistik Müdürlüğü, Türkiye Elektrik Dağıtım A.Ş. Genel Müdürlüğü, <http://www.tedas.gov.tr/sayfa2.htm>
- [21] **SPIEGEL, M. R.**, 1981. Theory and Problems of Statistics in SI Units. McGraw-Hill, New York.
- [22] **ERKOÇ, K., TEMURTAŞ, F., GÜLBAĞ, A.**, 2003. Bulanık Mantık Kullanarak İmza Tanıma, IJCI Proceedings of International Conference on Signal Processing, Volume.1, Number.2, www.ijci.org/product/ijci12/T2004.pdf
- [23] **EFE, Ö., KAYNAK, O.**, 2000. Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi Yay., İstanbul.
- [24] **BOLAT, S.**, 2003. Yapay Sinir Ağı ile Elektrot ve İzolatör Biçim Optimizasyonu, *Yüksek Lisans Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul
- [25] <http://batitrakya.dotweb.com/yapaysiniraglari/yapaysiniraglari.htm>
- [26] **HAYKIN, S.**, 1999. Neural Networks: A Comprehensive Foundation Second Edition, Prentice Hall, New Jersey.
- [27] **ZURADA, J. M.**, 1992. Introduction to Artificial Neural Systems, West, St. Paul
- [28] **ŞENGÖR, N. S.**, 2001. Yapay Sinir Ağlarına Giriş, Ders Notları.
- [29] **ŞEKER, S.**, 2001. Artificial Neural Networks for System Identification and Control, Ders Notları
- [30] Gölbaşı Bölgesi 2002-2003 yılları saatlik yük verileri
- [31] **YÜKSEL, İ.**, 2000. MATLAB ile Mühendislik Sistemlerinin Analizi ve Çözümü, Uludağ Üniversitesi Güçlendirme Vakfı Yay., Bursa.
- [32] <http://turkish.wunderground.com/>

- [33] **SENJYU, T., TAKARA, H., UEZATO, K., FUNABASHI T.**, 2002. One-Hour –Ahead Load Forecasting Using Neural Network, IEEE Transactions on Power Systems, **Vol.17, No.1**, pp.113-118
- [34] **SENJYU, T., SAKIHARA, H., TAMAKI, Y., UEZATO, K.**, 2000. Next Day Peak Load Forecasting Using Neural Network With Adaptive Learning Algorithm Based on Similarity, Electric Machines and Power Systems, **Vol.28**, pp. 613-624.


EK A AKIŞ DİYAGRAMI




EK B BİLGİSAYAR BENZETİMİ SONUÇLARI




Şekil B.1 26.02.2003 Çarşamba günü için yapılan yük tahminleri




Şekil B.2 13.05.2003 Salı günü için yapılan yük tahminleri




Şekil B.3 14.08.2003 Perşembe günü için yapılan yük tahminleri




Şekil B.4 13.11.2003 Perşembe günü için yapılan yük tahminleri




Şekil B.5 26.05.2003 Pazartesi günü için yapılan yük tahminleri




Şekil B.6 13.06.2003 Cuma günü için yapılan yük tahminleri




Şekil B.7 20.09.2003 Cumartesi günü için yapılan yük tahminleri



Şekil B.8 19.10.2003 Pazar günü için yapılan yük tahminleri



Şekil B.9 10.02.2003-16.02.2003 tarihlerindeki Kurban Bayramı haftası için yapılan yük tahminleri



Şekil B.10 19.05.2003, 19 Mayıs Gençlik ve Spor Bayramı için yapılan yük tahminleri

ÖZGEÇMİŞ

Gülden Ceylan, 1979 yılında Bandırma’da doğdu. Ortaokulu Bandırma Kültür ve Eğitim Vakfı Özel Lisesinde tamamladı. 1997 yılında Bandırma Kemal Pireci Lisesi’nden birincilik derecesi ile mezun oldu. 1997-2001 yılları arasında İstanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektrik Mühendisliği’nde okudu. 2001 yılında Elektrik Mühendisi ünvanını alarak mezun olduktan sonra İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Programında yüksek lisans eğitimine başladı. Halen bu bölümde öğrenciliğini devam ettirmektedir.

Mayıs 2004

Gülden CEYLAN