

**EN KÜÇÜK KARELER DESTEK VEKTÖR MAKİNELERİ İLE
TÜRKİYE’NİN UZUN DÖNEM ELEKTRİK TÜKETİM TAHMİNİ VE
MODELLEMESİ**

Fazıl KAYTEZ

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EKİM 2012
ANKARA**

Fazıl KAYTEZ tarafından hazırlanan “EN KÜÇÜK KARELER DESTEK VEKTÖR MAKİNELERİ İLE TÜRKİYE’NİN UZUN DÖNEM ELEKTRİK TÜKETİM TAHMİNİ VE MODELLEMESİ” adlı bu tezin Doktora tezi olarak uygun olduğunu onaylarım.

Prof. Dr. M. Cengiz TAPLAMACIOĞLU

Tez Danışmanı, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir.

Prof. Dr. İlhan KOCAARSLAN

Elektrik-Elektronik Mühendisliği Anabilim Dalı, İ.Ü.

Prof. Dr. M. Cengiz TAPLAMACIOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Doç. Dr. Ertuğrul ÇAM

Elektrik-Elektronik Mühendisliği Anabilim Dalı, K.Ü.

Doç. Dr. Fırat HARDALAÇ

Elektrik-Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Yrd. Doç. Dr. Nursel AKÇAM

Elektrik-Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Tarih: 30/10/2012

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onamıştır.

Prof. Dr. Şeref SAĞIROĞLU

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Fazıl KAYTEZ

**EN KÜÇÜK KARELER DESTEK VEKTÖR MAKİNELERİ İLE
TÜRKİYE’NİN UZUN DÖNEM ELEKTRİK TÜKETİM TAHMİNİ VE
MODELLEMESİ**

(Doktora Tezi)

Fazıl KAYTEZ

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Ekim 2012

ÖZET

Elektriksel enerji kaynaklarını yönetmek karmaşık bir görevdir. Enerji kaynak planlamasının en önemli parçası bölgesel ve ulusal hizmet alanlarında gelecekteki elektrik tüketiminin tahminidir. Doğru tüketim modelleri devletlere satın alma, elektrik güç üretimi ve altyapı geliştirme kararlarını içeren önemli kararlar almaya yardımcı olur. Bu çalışma çoklu lineer regresyon analizi(ÇLR), yapay sinir ağları(YSA) ve en küçük kareler destek vektör makineleri(EKK-DVM) metotları kullanılarak 2018 yılına kadar Türkiye’nin net elektrik tüketiminin tahmini ile ilgilidir. Kurulu güç, brüt elektrik üretimi, nüfus ve toplam abone sayısı bağımsız değişkenler olarak seçilmiştir. EKK-DVM ile bulunan sonuçlar, ÇLR ve YSA teknikleri sonuçları ile karşılaştırılmıştır. Bulunan sonuçlar EKK-DVM’nin elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

Bilim Kodu : 905.1.150
Anahtar Kelime : Elektrik Tüketimi, En Küçük Kare-Destek Vektör Makinaları, EKK-DVM, YSA
Sayfa Sayısı : 129
Tez Yöneticisi : Prof. Dr. M. Cengiz TAPLAMACIOĞLU

**MODELING AND FORECASTING OF TURKEY'S LONG TERM
ELECTRICITY CONSUMPTION WITH LEAST SQUARE SUPPORT
VECTOR MACHINES**

(Ph.D. Thesis)

Fazil KAYTEZ

GAZI UNIVERSITY

INSTITUTE OF SCIENCE AND TECHNOLOGY

October 2012

ABSTRACT

Managing electrical energy supply is a complex task. The most important part of energy resource planning is forecasting of the future electricity consumption in the regional or national service area. Accurate consumption models help government to make important decisions including decisions on purchasing, generating electric power and infrastructure development. This study deals with estimation of the net electricity consumption of Turkey until the year 2018 based on multiple linear regression analysis(MLR), artificial neural network(ANN) and least square-support vector machines(LS-SVM) methods. Installed capacity, gross electricity generation, population and total subscribership are selected as independent variables. The results obtained by LS-SVM are compared to those obtained by MLR and ANN technique. It is shown that, LS-SVM is a good forecasting tool for forecasting of electric energy consumption.

Science Code : 905.1.150

**Key Words : Electricity consumption, Least-Square Support Vector
Machine, LS-SVM, ANN**

Page Number : 129

Adviser : Prof. Dr. M. Cengiz TAPLAMACIOGLU

TEŞEKKÜR

Yüksek lisans eğitimim ve doktora eğitimim boyunca hep bana güvenmiş, değerli yardım ve katkılarını hiç esirgememiş, bir bilim adamı olarak kendisini daima örnek aldığım ve alacağım kadirşinas, alçakgönüllü ve içten insan kıymetli hocam Prof. Dr. M.Cengiz TAPLAMACIOĞLU hocama, tez çalışmam sürecinde hatalarımı göz ardı ederek bana güvenen, kendimi mahcup hissettiğim ve daima yol gösterici bir baba, bir ağabey gibi sevdiğim Prof.Dr.İlhan KOCAARSLAN ve Doç.Dr.Fırat HARDALAÇ hocama, tez çalışmam sürecinde desteklerini aldığım İTÜ öğretim üyelerinden Prof.Dr.Zekai ŞEN'e, Kobe Üniversitesinden Dr. Shigeo ABE'ye tez hazırlama sürecinde kaybettiğim işitme duyumu, cerrahi bir operasyonla tekrar kazandıran Doç.Dr.Hakan GÖÇMEN beye teşekkürü bir borç bilirim.

Bu yaşlara ve kariyere ulaşmamda maddi manevi büyük emekleri olan anne ve babama, doktora eğitimim sürecinde tanışarak evlendiğim sevgisi ve desteği ile hep yanımda olmuş sevgili eşime ve bu süreçte dünyaya gelen biricik kızım Ezgiye teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	xi
ŞEKİLLERİN LİSTESİ	xiii
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ	1
2. ENERJİ KAYNAKLARI	7
2.1.Yenilenemez Enerji Kaynakları	7
2.2.Yenilenebilir Enerji Kaynakları	10
2.3.Yeni Nesil Enerji Kaynakları.....	12
3. TÜRKİYE ELEKTRİK SİSTEMİ.....	13
3.1. Elektrik Üretim.....	13
3.2. Elektrik İletim.....	16
3.3. Elektrik Dağıtım.....	18
3.4. Sistem Kayıpları.....	21
3.5. Elektrik Tüketimi.....	23
3.6. Elektrik Piyasası.....	26
3.6.1. Piyasa gelişim süreci.....	26
3.6.2. Piyasa yapısı (konfigürasyonu).....	27
4. ELEKTRİK ENERJİ SİSTEMLERİNDE PLANLAMA.....	31

Sayfa

4.1. Planlama Kavramı ve Süreçleri	31
4.1.1. Enerji tüketim ve puant yük tahmini.....	32
4.1.2. Üretim sistem planlaması.....	33
4.1.3. İletim sistem planlaması.....	34
4.1.4. Dağıtım sistem planlaması.....	35
4.1.5. Çevresel planlama.....	35
4.1.6. Finansal planlama.....	36
4.1.7. Yakıt destek ve yöneylem planlamaları.....	36
4.1.8. Ar-Ge planlaması.....	36
5. ELEKTRİK TÜKETİM TAHMİNİ VE TAHMİN YÖNTEMLERİ.....	37
5.1. Tahmini Etkileyen Faktörler ve Tahmin Yöntemleri.....	37
5.2. Regresyon Analizi.....	39
5.2.1. Basit doğrusal regresyon analizi.....	41
5.2.2. Çoklu doğrusal regresyon analizi.....	43
5.2.3. Polinom(eğrisel) regresyon analizi.....	45
5.3. Yapay Sinir Ağları(YSA).....	46
5.3.1. Yapay sinir ağlarının genel özellikleri.....	49
5.3.2. Bir yapay nöronun ana öğeleri.....	50
5.3.3. Aktivasyon fonksiyonları.....	51
5.3.4. Yapay sinir ağlarının oluşturulması.....	53
5.3.5. İleri beslemeli ağlar.....	54
5.3.6. Geri beslemeli ağlar.....	55
5.3.7. Öğrenme, adaptif öğrenme ve test etme.....	56

5.3.8. Yapay sinir ağlarının sınıflandırılması.....	56
5.3.9. Geri yayılım algoritması.....	57
5.3.10. Levenberg-Marquardt metodu.....	59
5.3.11. Yapay sinir ağları tasarım aşamaları.....	60
5.3.12. SOM(Self Organizing Map) ağları.....	66
5.4. Destek Vektör Makineleri(DVM).....	68
5.4.1. Vapnik-Chervonenkis(VC) boyutu.....	69
5.4.2. Deneysel risk minimizasyonu(DRM).....	70
5.4.3. Yapısal risk minimizasyonu(YRM).....	72
5.4.4. Destek vektör sınıflandırıcı.....	72
5.4.5. Maksimal marjlı sınıflandırıcı ve optimizasyon.....	76
5.4.6. Çekirdek hilesi(kernel trick).....	78
5.4.7. Destek vektör regresyon.....	80
5.4.8. En küçük kareler destek vektör regresyon.....	83
6. YÖNTEMLERİN UYGULANMASI VE SAYISAL SONUÇLAR.....	85
6.1. Giriş verilerinin belirlenmesi.....	85
6.2. Ön ve Son Verilerin İşlenmesi.....	90
6.3. Performans Fonksiyonları.....	90
6.4. Çoklu Lineer Regresyon çözümü.....	91
6.5. Yapay Sinir Ağı Analizi.....	93
6.6. Öz örgütlenmeli harita(SOM) analizi.....	98
6.7. En Küçük Kareler Destek Vektör Makineleri Analizi.....	100
6.8. Sayısal Sonuçların Değerlendirilmesi.....	103

6.8.1. ROC(Receiver Operating Characteristic) eğrisi analizi.....	107
6.8.2. ETKB projeksiyonları ile EKK-DVM model sonuçlarının karşılaştırması.....	114
7. SONUÇLAR VE ÖNERİLER.....	119
8. KAYNAKLAR.....	122
EKLER SAYFASI.....	126
EK-1. Türkiye tüketim istatistikleri.....	127
EK-2. TEİAŞ 2010-2020 yılları arası üretim kapasite projeksiyonları.....	128
ÖZGEÇMİŞ.....	129

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Kurulu güç ve üretim miktarlarının üretici gruplara göre dağılımı.....	13
Çizelge 3.2. İletim hat uzunluklarının yıllar itibari ile gelişimi.....	18
Çizelge 3.3. Türkiye’de elektrik dağıtım bölgeleri.....	20
Çizelge 3.4. Türkiye’de eski-yeni piyasa yapılarının karşılaştırılması.....	30
Çizelge 6.1. Model eğitimleri için giriş verileri.....	87
Çizelge 6.2. Model eğitimleri için test verileri.....	88
Çizelge 6.3. Regresyon katsayıları.....	93
Çizelge 6.4. Regresyon parametreleri.....	93
Çizelge 6.5. Model 3 regresyon kalite parametreleri.....	93
Çizelge 6.6. Gradient descent öğrenme tabanlı tasarım.....	94
Çizelge 6.7. Levenberg-Marquart öğrenme tabanlı tasarım.....	94
Çizelge 6.8. Resilient backpropagation öğrenme tabanlı tasarım.....	95
Çizelge 6.9. YSA eğitim ve test performans kriterleri sonuçları.....	97
Çizelge 6.10. σ^2 ve γ parametre MSE hata değişimi.....	102
Çizelge 6.11. EKK-DVM eğitim ve test sonuçları.....	102
Çizelge 6.12. Eğitim grubu için denormalize edilmiş eğitim grupları.....	104
Çizelge 6.13. Test grubu için denormalize edilmiş test grupları.....	105
Çizelge 6.14. Performans sonuçları.....	105
Çizelge 6.15. Çoklu lineer regresyon modeli için ihtimal matrisi.....	112
Çizelge 6.16. Yapay sinir ağı modeli için ihtimal matrisi.....	112

Çizelge	Sayfa
Çizelge 6.17. EKK-DVM modeli için ihtimal matrisi.....	113
Çizelge 6.18. Modellerin hassaslık ve özgüllük performansı.....	113
Çizelge 6.19. Geçmiş yıllar için ETKB brüt tüketim projeksiyonu ve sapmalar....	116
Çizelge 6.20. Modellerin uzun dönem gelecek projeksiyonları.....	118
Çizelge 7.1. 2010 yılı yüksek talep durumu validasyon sonuçları.....	120
Çizelge 7.2. 2010 yılı düşük talep durumu validasyon sonuçları.....	120
Çizelge 7.3. EKK-DVM metodu ile tüketim tahmini.....	121

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Türkiye’de termik santrallerde kullanılan yakıt türleri dağılımı.....	9
Şekil 2.2. Türkiye’de üretilen enerjinin kaynaklara göre dağılımı.....	9
Şekil 3.1. Türkiye’deki kurulu kapasitenin yıllara göre gelişimi.....	14
Şekil 3.2. Türkiye’de elektrik üretiminin yıllara göre gelişimi.....	15
Şekil 3.3. Türkiye iletim ve dağıtım sistem kayıplarının yıllara göre yüzdesel değişimi.....	23
Şekil 3.4. Türkiye net elektrik tüketiminin yıllara göre değişimi.....	24
Şekil 3.5. Türkiye kişi başı elektrik tüketiminin yıllara göre değişimi.....	24
Şekil 3.6. Türkiye elektrik tüketiminin sektör tabanlı dağılımı.....	25
Şekil 3.7. Türkiye elektrik piyasası genel yapısı.....	29
Şekil 5.1. Basit doğrusal regresyon doğrusu.....	41
Şekil 5.2. Yapay sinir ağı örneği.....	47
Şekil 5.3. Yapay nöron yapısı.....	50
Şekil 5.4. Çift kutuplu eşik(basamak) fonksiyon.....	51
Şekil 5.5. Sigmoid fonksiyon.....	52
Şekil 5.6. Tanjant hiperbolik fonksiyon.....	52
Şekil 5.7. SOM ağ mimarisi.....	66
Şekil 5.8. VC boyutu.....	69
Şekil 5.9. Destek vektör sınıflayıcı ve hiperdüzlem.....	73
Şekil 5.10. Lineer DVM ε kayıp fonksiyonu.....	81
Şekil 6.1. Türkiye brüt üretiminin yıllar itibari ile gelişimi.....	88
Şekil 6.2. Türkiye’de nüfusun yıllar itibari ile gelişimi.....	89

Şekil	Sayfa
Şekil 6.3. Türkiye’de kurulu gücün yıllar itibari ile gelişimi.....	89
Şekil 6.4. Türkiye’de toplam abonenin sayısının yıllar itibari ile gelişimi.....	89
Şekil 6.5. Tüketim modeli seçimi.....	92
Şekil 6.6. Oluşturulan YSA gizli katman mimarisi.....	95
Şekil 6.7. Eğitim hedef performans eğrisi.....	96
Şekil 6.8. YSA çıkışlarını hedef performans uyum eğrisi.....	97
Şekil 6.9. SOM ağı komşu ağırlık mesafeleri ve pozisyonları.....	99
Şekil 6.10. Destek vektör regresyon doğrusu.....	100
Şekil 6.11. Sigma2 ve gama parametrelerini belirleme algoritması.....	101
Şekil 6.12. EKK-DVM eğitim sonucu elde edilen regresyon doğrusu.....	103
Şekil 6.13. Tahmin model sonuçlarının gerçek tüketim eğrisi ile kıyaslanması.....	106
Şekil 6.14. İhtimal tablosu.....	108
Şekil 6.15. Beş ayrı sınıflayıcı gösteren basit bir ROC grafiği.....	109
Şekil 6.16. ROC eğrisi AUC yaklaşımları.....	110
Şekil 6.17. Tüketim değişimi üzerinde sınıf etiketleri gösterimi.....	111
Şekil 6.18. Elektrik tüketim değişiminin ROC eğrileri.....	114
Şekil 6.19. Model sonuçlarının gerçekleşme değerlerine yakınlığı.....	117
Şekil 6.20. 2010-2018 yılları arası uzun dönem gelecek projeksiyonları.....	117

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
a_i	Lagrange çarpanı
α	Momentum katsayısı
r	Korelasyon katsayısı
ε	Duyarsızlık kayıp terimi
β	Kısmi regresyon katsayısı
C	Düzenleştirme parametresi
η	Öğrenme katsayısı
ξ_i	Yapay değişken(slack)
λ	Levenberg-Marquardt parametresi
J_k	Değerlendirilmiş jakobiyen
I	Birim matris
w	Ağırlık vektörü
ξ	Yapay değişken(slack)
σ	Kernel band genişliği
γ	Kernel boyutu
Kısaltmalar	Açıklama
ARM	Ampirik risk minimizasyonu
ÇLR	Çoklu lineer regresyon
DPT	Devlet Planlama Teşkilatı
DVM	Destek vektör makinaları
DVS	Destek vektör sınıflayıcı
DVR	Destek vektör regresyon

Kısaltmalar**Açıklama****EKK-DVM**

En küçük kareler destek vektör makinası

ETKB

Enerji ve Tabii Kaynaklar Bakanlığı

EÜAŞ

Elektrik Üretim A.Ş.

EPDK

Enerji Piyasası Düzenleme Kurumu

GA

Genetik Algoritma

GSYİH

Gayri Safi Milli Hasıla

MSE

Karesel ortalama hata

MAPE

Ortalama mutlak hata yüzdesi

RBF

Radyal tabanlı fonksiyon

RMSE

Karesel ortalama hata karekökü

SSE

Toplam karesel hata

TEK

Türkiye Elektrik Kurumu

TEDAŞ

Türkiye Elektrik Dağıtım A.Ş.

TEİAŞ

Türkiye Elektrik İletim A.Ş.

TEP

Ton Eşdeğer Petrol

TUİK

Türkiye İstatistik Kurumu

VC(H)

Vapnik-Chervonenkis boyutu

YPK

Yüksek Planlama Kurulu

YSA

Yapay sinir ağı

1. GİRİŞ

Enerji, günümüzde tüm insanlığın en yaşamsal ihtiyaçlarından biri haline gelmiştir. Yapılan her üretim sürecinin bir enerji ihtiyacı vardır. İnsanlığın artan yaşam talepleri ve gelişen üretim süreçleri, enerjiye ve enerji kullanımına olan ihtiyacı artırmıştır. Bu enerjinin çok önemli miktarını ise elektrik enerjisi oluşturmaktadır. Elektrik enerjisi birçok farklı kaynaktan elde edilip yine çok çeşitli tüketim alanlarında kullanılmaktadır. Ayrıca elektrik enerjisi, ekonomik büyümedeki önemli rolü ile kalkınma programlarının vazgeçilmez bir ögesidir. Ülkelerin ekonomik gelişme düzeyleri yükseldikçe, toplam enerji tüketimleri içinde elektrik enerjisinin payı artmaktadır. Ayrıca birçok ülkede ekonomik gelişmeyi sürükleyen sanayi sektörünün oransal olarak en fazla elektrik enerjisi tüketen sektör olması da ekonomik gelişme – elektrik enerjisi ilişkisinin artmasına neden olmaktadır.

Enerji tüketimindeki payı sürekli yükselen elektrik enerjisine yönelik talep, her geçen gün hızlı bir şekilde artmaya devam etmektedir. Oluşan talebin kesintisiz olarak en düşük maliyetle ve en kaliteli biçimde karşılanması, arz ve çevre güvenliğinin sağlanması, günümüz yeni nesil elektrik sistemlerinin tasarım ve kaynak planlamalarında temel hedefler haline gelmiştir.

Enerji politikaları, özellikle gelişmekte olan ülkelerde, sürdürülebilir kalkınma planlarının tümleşik bir parçasıdır. Dünya pazarlarında ülkemizin rekabet gücünü artırmak üzere ekonomiyi büyütecek ve yaşam standartlarını yükseltecek yeterli, sürekli ve temiz enerjinin temini, “güvenilir ve sürdürülebilir enerji politikaları” ile mümkündür.

Elektrik enerjisinin sürdürülebilir ve yüksek verimli kullanılabilmesi için, ana felsefe tüketilen elektrik enerjisi kadar elektrik üretilmelidir. Bunun yanında bugün mevcut olan elektrik enerji sistemlerinin, gelecekteki artan enerji ihtiyacını karşılayacak şekilde büyütülmesi gerekmektedir. İnsan yaşamının tüm alanlarında, elektrik enerjisine olan bağımlılık bu zorunluluğu doğurmaktadır. Bu nedenlerle; kesintisiz

bir elektrik enerjisi için gerekli olan planlamaların yapılabilmesi için doğru yük veya enerji tüketim tahmininin yapılması elektrik mühendisliği ana bilim dalının önemli araştırma konularından biri olmuştur. Özellikle bu tahmin araştırmalarının üç farklı kategori altında toplandığı görülmektedir. Bunlar kısa dönemli (saatlik, günlük veya haftalık) tahmin çalışmaları, orta dönemli (aylık, üç aylık, yıllık) tahmin çalışmaları ve uzun dönemli (bir yıldan daha uzun dönem) tahmin çalışmalarıdır. Bu türlü dönemsel farklılıklar gösteren tahminlerin gerçeğe yakın ve hassas yapılması; altyapı, elektrik piyasası dengeleme uygulamaları, büyük sermaye gerektiren enerji yatırımları ve kurumsal planlamalarda büyük önem taşımaktadır.

Tahmin performansını yükseltmek için model seçiminde kimi zaman teorik kriterler yerine, tahmin performansını artırmaya yönelik kriterler ön plana çıkmaktadır. Tahmin doğruluğuna yönelik çalışmalar, çeşitli modellerin tahmin doğruluklarını değerlendirmeye ve karşılaştırmaya yönelik metotlar üzerinde yoğunlaşmıştır. Diğer yandan, alternatif bir yöntem olarak farklı modellerden alınan öngörülerin kompozisyonu (birleştirilmesi) ile performans (öngörü) kalitesinin artırılmasına yönelik çalışmalar da bulunmaktadır [Oğurlu, 2011].

Bilhassa, son yıllarda bilimsel literatürde farklı birçok elektrik tüketim tahmini çalışması yapılmış ve bu çalışmalarda farklı sistematik yöntemler kullanılmıştır. Uluslararası alanda farklı ülkelerde yapılan ve bu tez çalışmasında da incelenen, çalışmalardan bazıları aşağıda sıralanmıştır.

Çoklu Lineer regresyon analizi metodu ile giriş verisi olarak brüt elektrik üretimi, Nüfus ve ortalama elektrik fiyatı gibi ekonomik-demografik değişkenler kullanılarak, Yeni Zelanda'nın uzun dönemli gelecek elektrik tüketim tahmini yapılmıştır [Mohamed ve Bodger, 2005].

Tayvan'ın ulusal gelir, brüt iç üretim, nüfus ve tüketici fiyat endeksi gibi konular göz önünde tutularak yapay sinir ağları (YSA) ve lineer/lineer olmayan istatistiksel modeller kullanılarak elektrik enerjisi talep gelişim projeksiyonu yapılmıştır [Pao, 2006].

Brüt elektrik üretimi, nüfus, ithalat ve ihracat ekonomik ve sosyal göstergeler alınarak YSA modeli ile Güney Kore'nin uzun dönemli tüketim tahmini test edilmiş ve modelin başarısı incelenmiştir [Geem ve Roper, 2010].

Yunanistan'ın uzun dönemli elektrik tüketim tahmini için; ortam sıcaklığı, kurulu güç kapasitesi, konut başı yıllık elektrik tüketimi ve brüt elektrik üretimi geçmiş verileri giriş değişkenleri olarak seçilerek, YSA modeli oluşturularak gelecek tüketim tahminleri yapılmıştır [Economou, 2010].

Aylık ortalama dış kuru hava termometre sıcaklığı, bağıl nem ve global güneş radyasyonu gibi üç farklı giriş değişkeni kullanılarak Singapur'un tropikal bölgesinde, rastgele seçilen dört ticari binanın aylık enerji tüketim hesaplaması için Destek Vektör Makinalarının (DVM) uygulanabilirliği incelenmiştir. Tüm tahmin sonuçlarının %3'den daha az varyans katsayısına sahip olduğu görülmüştür [Dong ve ark., 2005].

Malezya'da kimyasal işlem yoğunlaşması ve viskozitesi okuma süresi, uluslar arası havayolu yolcuları, özel ürünlerin günlük fiyat tahminleri gibi birçok farklı alanda ve farklı giriş verileri üzerinden, DVM uygulaması farklı giriş parametreleri kullanılarak yapılmış ve elde edilen sonuçların anlamlılığı Çok Katmanlı Geri Beslemeli Ağ ile kıyaslanmıştır [Samsudin ve ark., 2010].

Brezilya'da kısa dönemli (saatlik) yük tahmini için En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) tercih edilmiştir. Çalışma 3000 adet örnek geçmiş saatlik yük verisi ve günlük sıcaklık değişimleri baz alınarak yapılmış ve test verileri (verilerin 1/3'ü) üzerinde performanslar maksimum hata, ortalama yüzde mutlak hata ve çoklu korelasyon katsayısı sonuçları ile irdelenmiştir. Sonuç olarak bu metodun çok iyi sonuçlar vermediği fakat giriş parametrelerinin ayarlanması ile ümit kar sonuçlar elde edilebileceği vurgulanmıştır [Coelho ve Klein, 2009].

Yine son yıllarda Türkiye'de de yük tahmininde ve enerji tüketim tahmininde farklı yöntemlerle farklı çalışmalar yapılmıştır.

Nüfus, brüt elektrik üretimi, kurulu güç, net elektrik üretimi, ithalat ve ihracat gibi ekonomik ve demografik değişkenlerin 1975 - 2003 yılları arası geçmiş verileri, giriş verileri olarak baz alınarak, YSA ağ modeli tasarlanmış ve Türkiye'nin 2020 yılına kadar uzun dönemli elektrik tüketim tahmini yapılmıştır [Sözen ve Arcaklioğlu, 2007].

Türkiye'nin 2015 yılına kadar toplam ve endüstriyel elektrik tüketim tahmini için, 1970 - 2004 arası geçmiş verileri kullanılarak, silindirik mekanizmalı kapalı tahmin methodu (Grey prediction with rolling mechanism) kullanılmıştır [Akay ve Atak, 2007].

1979 - 2005 yılları arası brüt elektrik üretimi, nüfus, ithalat ve ihracat data setleri kullanılarak, Türkiye'nin 2025 yılına kadar elektrik yük tahmini parçacık sürüsü optimizasyonu (particle swarm optimization) kullanılarak yapılmıştır [Ünler, 2008].

1970 - 2001 yılları arası brüt elektrik üretimi, nüfus, ithalat ve ihracat geçmiş data setleri baz alınarak, Türkiye'nin 2025 yılına kadar elektrik demand tahmini Genetik Algoritma (GA) yaklaşımı ile yapılmıştır [Canyurt ve ark., 2004].

2003 - 2020 yılları arasında Türkiye'nin sektörel bazlı net elektrik tüketimini tahmin etmek için, sektörel bağımsız değişkenlere (ulaşım, ziraat, rezidans vb..) sahip bir yapay sinir ağı modeli kurulmuştur [Hamzaçebi, 2007].

1953 - 2000 yılları arasındaki geçmiş nüfus, brüt üretim, kurulu güç ve yılların bağımsız değişkenleri olduğu ve Türkiye'nin net elektrik tüketimini tahmin etmek için YSA tabanlı bir model kurulmuştur [Sözen ve ark., 2006].

Türkiye'de uzun dönemli elektrik demand tahmini için alternatif bir yaklaşım olarak Destek Vektör Makineleri (DVM) ve YSA modeli kurulmuştur. Çalışmada 1980 - 2000 yılları arasındaki veriler eğitim, 2001 - 2008 yılları arasındaki veriler test için kullanılmıştır. Özellikle test verileri üzerinde, DVM algoritmasının daha iyi sonuçlar verdiği gözlenmiştir [Küçükdeniz, 2010].

Türkiye'nin 2016 yılına kadar uzun dönemli elektrik tüketim tahmin modellemesi için altı farklı giriş parametresi kullanılan Destek Vektör Regresyon metodolojisi oluşturulmuştur. Gerçek data değerleri ile tahmin sonuçları arasında ortalama kare hatanın karekökü (RMSE) kriter sonuçları verilerek, bulunan sonuçların geleceğe uzun dönemli tahmin çalışmalarında kullanılabileceği sonucuna varılmıştır [Kavaklıoğlu, 2011].

Türkiye ve dünyanın farklı ülkelerinde yapılan çalışmalarda görüldüğü üzere yük veya tüketim tahmin çalışmalarında farklı teknik ve yöntemler kullanılmıştır. Bu çalışmaların bütününde amaç gelecekteki yıllarda elektrik enerji tüketiminin ne kadar artış göstereceğini gerçeğe en yakın şekilde tahmin etmeye çalışarak ilgili kuruluşların yatırım ve planlamalarına yardımcı olmaktır. Bu nedenle de her çalışma kullandığı metodolojiye göre farklı bağımsız değişkenler seçmiş, yine farklı sayıda giriş verisi kullanmıştır. Ortak amaç gerçekliği ve hassaslığı yüksek tahminler yapabilmektir.

Çalışmamızda gerçeğe yakın tahminler yapabilmek için Türkiye'de net elektrik tüketimini etkileyen parametreler çeşitli tahmin çalışmaları incelenerek ve analizler yapılarak elde edilmiştir. Kurulan modellerde bağımsız değişkenler olarak *kurulu güç* (installed power), *brüt elektrik üretimi* (gross electricity generation), *nüfus* (population) ve *toplam abone sayısı* (total subscribership) seçilmiştir. Bu giriş verilerinin 1970 -2009 yılları arasındaki gerçekleşme değerleri TEİAŞ, TEDAŞ, DPT, EPDK ve TUIK gibi resmi kurumların istatistikî bilgilerinden elde edilmiştir. Bu veriler tahmin çalışmalarında kullanılmadan önce Matlab 2009 programı ile ortalaması 0, standart sapması 1 olacak şekilde normalize edilerek yeniden düzenlenmiştir.

Tahmin çalışmasına başlamadan önce çalışmamızın ikinci bölümünde Türkiye yenilenebilir ve yenilenemez enerji kaynakları üzerine, üçüncü bölümünde ise Türkiye'nin üretim, iletim ve dağıtım sistemleri üzerine bilgiler verilmiştir. Dördüncü bölümde ise enerji sistemlerinde planlamanın önemi ve enerji sistemlerinde planlama stratejileri üzerine ön bilgiler sunulmuştur.

Çalışmamızın beşinci bölümünde; elektrik tüketim tahmini, tahmin yöntemleri ve tahmini etkileyen faktörler açıklanmıştır. Tezimizde kullanacağımız çoklu lineer regresyon (ÇLR), yapay sinir ağları (YSA), destek vektör makineleri (DVM) ve destek vektör makinelerinin bir türü olan EKK-DVM metotlarının, teorik alt yapısı verilmiştir.

Altıncı bölümde; ÇLR, YSA, EKK-DVM metotlarının Türkiye net elektrik tüketim tahminine uygulaması yapılmış ve sayısal sonuçlar elde edilmiştir. Sonuçların hata oranları tipik performans kıstasları kullanılarak, metotların birbirleri ile kıyaslaması verilerek ve tahminleme başarı performansı yüksek bulunan EKK-DVM metodu kullanılarak, Türkiye net elektrik tüketimi düşük ve yüksek talep durumları da göz önüne alınarak 2018 yılına kadar tüketim projeksiyonunda bulunulmuştur.

Çalışmamızın yedinci ve son bölümünde ise; altıncı bölümde elde edilen sonuçların ne tür anlamlar taşıdığı ve bilime katkısı sunulmuştur.

2. ENERJİ KAYNAKLARI

2.1. Yenilenemez Enerji Kaynakları

Enerji, bir cisim ya da sistemin iş yapabilme kapasitesidir ve değişik şekillerde karşımıza çıkar. Bunlar; Isı enerjisi, ışık enerjisi, mekanik enerji, elektrik enerjisi, kimyasal enerji ve nükleer enerji bunlardan bazılarıdır. Enerji kaynaklarının ise yenilenebilir, yenilenemeyen (tükenen) ve yeni nesil enerji kaynakları olmak üzere üç grup altında toplandığı görülmektedir.

Yenilenemez enerji basit bir ifade ile kısa zaman aralığında yeniden oluşmayan enerji olarak tanımlanabilir. Bunlar genelde, petrol, doğal gaz ve kömür gibi fosil yakıtlardır. Bu tür enerjiler, yaşamları milyonlarca yıl önce sona ermiş bitki ve hayvan gibi organik kalıntıların fosillerinden kaynaklanmaktadır. Hâlihazırda dünya enerji ihtiyacının önemli bir bölümünü karşılamakta olan fosil yakıtların rezervleri hızla tükenmektedir. Bu yüzyılın ikinci yarısında petrol ve doğalgaz gibi bazı fosil yakıtların rezervlerinin sonuna gelineceği tahmin edildiğinden, bütün enerji kaynaklarının verimli bir şekilde kullanılması büyük önem taşımaktadır. Enerji ihtiyacının sürekli arttığı ama kaynakların gittikçe azaldığı dünyada, enerjinin verimli kullanılmasını sağlamak için çok çeşitli programlar uygulanmaktadır. Enerji sektörlerinde kullanılan fosil yakıtlar, iklim değişikliğine yol açan ve atmosfere dağılan en önemli sera gazlarından biri olan CO₂'nin (karbondioksit) de başlıca kaynağıdır.

Linyit, ısı değeri düşük, barındırdığı kül ve nem miktarı fazla olduğu için genellikle termik santrallerde yakıt olarak kullanılan bir kömür çeşididir. Buna rağmen yerkabuğunda bolca bulunduğu için sıklıkla kullanılan bir enerji hammaddesidir. Taşkömürü ise yüksek kalorili kömürler grubundadır. Yerli kaynak potansiyelimizin 12,4 milyar tonunu linyit, 1,33 milyar tonunu taşkömürü oluşturmaktadır. Türkiye'nin toplam linyit rezervi 12,4 milyar ton seviyesinde olup işletilebilir rezerv miktarı ise 3,9 milyar ton düzeyinde bulunmaktadır. Bununla birlikte linyit kaynaklarımızın, büyük kısmının ısı değeri düşük olduğundan, termik santrallerde

kullanımı ön plana çıkmıştır. Ülkemiz linyit rezervinin yaklaşık %46'sı Afşin-Elbistan havzasında bulunmaktadır. Ülkemizin en önemli taşkömürü rezervleri ise Zonguldak ve civarındadır. Zonguldak Havzası'ndaki toplam taşkömürü rezervi 1,33 milyar ton, buna karşılık görünür rezerv ise 519 milyon ton düzeyinde bulunmaktadır.


2008 yılında 106 milyon TEP¹ olan ülkemizin toplam birincil enerji tüketiminde kömürün payı %28'dir. Ülkemizde 2008 yılı sonu itibariyle linyite dayalı termik santrallerimizin kurulu gücü 8205MW olup bu değer toplam kurulu gücümüzün %19,6'sını karşılamaktadır. Kömürün toplamda kurulu güce katkısı 10191MW olup bu değer toplam kurulu gücümüzün %24'ünü oluşturmaktadır. Taşkömürüne dayalı termik santralimizin kurulu gücü 335MW olup, toplam kurulu gücümüzün %0,8'ine karşılık gelmektedir.

2009 sonu itibariyle Türkiye petrol rezervleri 44,3 milyon ton, 2008 yılı üretimi 2,2 milyon ton, 2008 yılı tüketimi 27,8 milyon tondur. 2009 yılı üretim miktarı ise 2,4 milyon ton olarak gerçekleşmiştir. Ülkemizde petrol arama faaliyetlerinin başladığı tarihten 2009 yılı sonuna kadar ham petrol üretimi ise 132,5 milyon tondur. Ülkemizde 2008 yılı sonu itibariyle petrol ve petrol ürünlerine dayalı termik santrallerimizin kurulu gücü yaklaşık 2300MW olup bu değer toplam kurulu gücümüzün %5,5' ini karşılamaktadır. 2008 yılında petrole dayalı santrallerden üretilen elektrik enerjisi miktarı 7519GWh'dir [ETKB, 2010].

Doğal gaz rezervlerinin ise; 76 trilyon metreküpü (%41) Orta Doğu ülkelerinde, 59 trilyon metreküpü (%33) Rusya ve BDT ülkelerinde, 31 trilyon metreküpü (%17) Afrika/Asya Pasifik ülkelerinde bulunmaktadır. 2009 yılı sonu itibari ile kalan üretilebilir doğalgaz rezervimiz 6,2 milyar m³tür. Elektrik enerjisi üretiminde doğalgaza dayalı kurulu gücümüz 14576MW olup, bu değer toplam kurulu gücümüzün 32,7'sini karşılamaktadır [ETKB, 2010].


¹ TEP(Ton Eşdeğer Petrol); Enerji üretim ve tüketim hesaplamalarında kullanılan bir ton ham petrolün eşdeğeridir. 1000kWh'lik elektrik enerjisi 0,0860TEP çevrim katsayısı ile ifade edilmektedir.

Türkiye’de 2010 yılında yakıt tiplerine göre, termik santrallerde elde edilen elektrik enerjisi miktarları incelendiğinde; katı yakıtlardan (taşkömürü, linyit) 55046,4GWh, sıvı yakıtlardan (Fuel-oil, motorin, LPG vb..) 2180,0GWh ve doğalgazdan 98143,7 GWh’lik enerji elde edilmiştir (Şekil 2.1). Doğalgazın termik santraller içindeki enerji payı %62,98’dir [ETKB, 2010]. Ülkemizde özellikle doğalgazda talebin yoğun olduğu kış aylarında kaynak ülkelerdeki veya güzergâh ülkelerindeki aksamalarında, dönemsel arz-talep dengesizliklerine yol açabildiği bilinmektedir.



Şekil 2.1. Türkiye’de termik santrallerde kullanılan yakıt türleri dağılımı

Özetle; Ülkemizdeki üretilen enerjinin büyük bir bölümü (%73,78’i) özel veya kamu termik santrallerinden karşılanmakta, bu karşın diğer yenilenebilir enerji kaynaklarının(hidrolik, jeotermal, rüzgar, güneş) genel pasta içerisindeki toplamı %26,22 değerini aşmamaktadır (Şekil 2.2). Bu durumun dışa bağımlı olduğumuz bu hammaddeye, alternatif olacak diğer kaynaklara yönelimin ülkemizin gelecekteki enerji politikalarını belirleyecek en önemli ölçüt olacağı aşikardır.



Şekil 2.2. Türkiye’de üretilen enerjinin kaynaklara göre dağılımı

2.2. Yenilenebilir Enerji Kaynakları

Yenilenebilir enerji, basit bir ifade ile sınırsız varsayılan, sürekli, tekrar tekrar kullanılabilen enerji biçimlerini ifade etmektedir. Güneş enerjisi, rüzgâr enerjisi, yerküreden gelen jeotermal enerji, bitkilerden üretilen biokütle ve sudan elde edilen hidrolik güç de yenilenebilir enerji grubunda değerlendirilmektedir. Yenilenebilir enerji, kısa sürede yerine konulan enerjidir.

Türkiye'nin coğrafi konumu nedeniyle sahip olduğu güneş enerjisi potansiyeli ortalama yıllık toplam güneşlenme süresi 2640 saat (günlük toplam 7,2 saat) ve ortalama toplam ışıınım şiddeti 1311 kWh/m²-yıl (günlük toplam 3,6 kWh/m²) olduğu tespit edilmiştir. Güneş Enerjisi potansiyeli 380 milyar kWh/yıl olarak ifade edilmektedir. Ülkemizde kurulu olan güneş kolektörü miktarı toplam yaklaşık 12 milyon m² ve teknik güneş enerjisi potansiyeli toplamı 76 TEP olup, yıllık üretim hacmi 750 000 m²'dir ve bu üretimin belli bir miktarı ise ihraç edilmektedir. Bu kullanım miktarı, kişi başına 0,15 m² güneş kolektörü kullanıldığı şeklinde de yorumlanabilir. Ülkemizin Güneş enerjisinden, ısı enerjisi yıllık üretimi 420 000TEP dolaylarındadır. Bu genel görüntü itibari ile ülkemiz, dünyada kayda değer bir güneş kolektörü üreticisi ve kullanıcısı durumundadır. Ülkemizde birçoğu çoğu kamu kurum ve kuruluşlarında olmak üzere, küçük güçlerin karşılanması ve araştırma amacıyla kullanılan güneş pili kurulu gücü 1 MW' a ulaşmıştır [ETKB, 2010].

Rüzgâr santralleri, geleneksel güç santrallerinin aksine, enerji güvenliği açısından yakıt maliyetlerini ve uzun dönemli yakıt fiyatı risklerini elimine eden, aynı zamanda politik/mali veya tedarik riskleri açısından diğer ülkelere bağımlılığı azaltan, yerli her zaman kullanılabilir santrallerdir.

Dünyada rüzgâr enerji kapasitesinde en büyük pay % 72 ile Avrupa kıtasındadır. Türkiye 2001 yılında, Avrupa'da kurulu kapasitede % 0,11'lik bir paya sahiptir [Ogolata, 2003]. Türkiye'de 2004 yılında 18 MW olan rüzgâr kurulu gücü, 2009 yılı sonu itibariyle 802,8 MW gibi azımsanmayacak oranda artış göstermiştir. Yine yaklaşık olarak 1100 MW kurulu gücünde rüzgâr santralinin ise yapımına devam

edilmektedir. Jeotermal enerji tanım itibari ile yerin derinliklerindeki kayalar içerisinde birikmiş olan ısı enerjisinin akışkanlarca taşınarak, rezervuarlarda depolanması ile oluşan sıcak su, buhar ve kuru buhar ile kızgın kayalardan suni yollarla elde edilen ısı enerjisidir. Türkiye, Alp-Himalaya kuşağı üzerinde yer aldığından, oldukça yüksek jeotermal potansiyele sahip olan bir ülke konumundadır. Ülkemizin toplam jeotermal potansiyeli 31500 MW'tır. Ülkemizde jeotermal potansiyel oluşturan alanlar genelde Batı Anadolu'da (%77,9) yoğunlaşmıştır. Bu güne kadar potansiyelin %13'ü yani 4000 MW'lık kısmı MTA tarafından kullanıma hazır hale getirilmiştir. Jeotermal enerji potansiyelimizin 1500 MW'lık bölümünün elektrik enerjisi üretimi için uygun olduğu değerlendirilmekte olup, kesinleşen veri şu an için 600 MWe'dir. 2009 yılı sonu itibari ile Türkiye'nin jeotermal enerjisi kurulu gücü 77,2 MW düzeyine ulaşmıştır [ETKB,2010].

Biyoyakıt tanımsal olarak; içeriklerinin hacim olarak en az % 80'i son on yıl içerisinde toplanmış canlı organizmalardan elde edilmiş her türlü yakıt olarak tanımlanmaktadır. Bunlar; biyodizel, biyoetanol, biyogaz ve biyokütle olarak örneklenebilir. Biyokütle kaynaklarımız; tarım, orman, hayvan, organik şehir atıkları ve benzeri türevlerinden oluşmaktadır. Atık potansiyelimiz yaklaşık olarak 8,6 milyon TEP olup, bu toplam potansiyelin 6 milyon TEP civarı ısınma amacı ile kullanılmaktadır. 2008 yılında biyokütle kaynaklarından elde edilen toplam enerji miktarı 66 bin TEP'tir [ETKB, 2010].

Hidroelektrik santraller yenilenebilir, temiz, çevreye uyumlu, verimli, enerji fiyatlarında bir sigorta görevi üstlenen, uzun ömürlü, işletme gideri çok düşük dışa bağımlılık oranı sınırlı olan santrallerdir.

Enerji ve Tabii Kaynaklar Bakanlığı teknik verilerine göre; Türkiye'de ekonomik olarak değerlendirilebilir hidroelektrik potansiyeli yılda 140 GWh olarak ifade edilmektedir [ETKB,2010]. Yine 2010 yılı TEİAŞ raporlarına göre; ülkemizin hidroelektrik santralleri toplam kurulu gücü 15.831,2MW ve elde edilen enerji miktarı ise 51795,5 GWh'dir [TEİAŞ, 2010].

2.3. Yeni Nesil Enerji Kaynakları

Yeni nesil enerji kaynakları ülkemizde yeni projelendirme çalışmaları başlamış, teknolojisi henüz fazla gelişmemiş veya kullanımı henüz kısıtlı olan enerji kaynakları olarak da ifade edilebilir.

Hidrojen enerjisi tanımsal olarak, Güneşin veya galaksideki diğer yıldızların termonükleer tepkimeye vermiş olduğu ısının yakıtıdır ve evrenin temel enerji kaynağıdır. Bilinen tüm yakıtlar içerisinde, birim kütle başına en yüksek enerji içeriğine sahiptir. Dünyada her yıl yaklaşık 500 milyar m³ hidrojen üretilmekte, depolanmakta, taşınmakta ve kullanılmaktadır. Özellikle ülkemizde ve dünyada Petrokimya sanayi ve rafinerilerde daha çok tercih edilen hidrojen enerjisinin, fiyatının diğer enerji kaynaklarından ortalama üç kat fazla olması nedeni ile özellikle enerji alanında şu an için fazla kullanım alanı bulacağı düşünülmemektedir. Ancak teknolojiye ilerleme ile birlikte, üretimindeki maliyet düşürücü gelişmelere bağlı olarak kullanımı gelecek vaat eden bir enerji türüdür.

Ülkemiz için güncel olan bir diğer yeni nesil enerji türü nükleer enerjidir. Nükleer enerji, maddenin atom çekirdeklerinin parçalanması sonucu açığa çıkan ısı enerjisi olarak tanımlanabilir. Nükleer reaktörler açığa çıkan bu ısı enerjisini, kinetik enerjiye ve daha sonrasında jeneratör sisteminde elektrik enerjisine dönüştürürler.

Ülkemizde elektrik enerjisi arz ve talep tahminlerine bağlı olarak, 2020 yılına kadar, nükleer enerji santrallerinin, elektrik enerjisi üretimi içerisindeki payının en az % 5 seviyesine ulaşması hedeflenmektedir. Bu amaçla hükümetce 2007 yılında 5710 sayılı Nükleer Güç Santrallerinin Kurulması ve İşletilmesi ile Enerji Satışına İlişkin Kanun çıkartılmıştır. Yine 2010 yılı mayıs ayında, Türkiye ile Rusya Federasyonu arasında Mersin-Akkuyu'da nükleer santral yapımına ilişkin hükümetler arası anlaşma imzalanmıştır [ETKB,2010].

3. TÜRKİYE ELEKTRİK SİSTEMİ

3.1. Elektrik Üretim

Bir kamu kuruluşu olan Elektrik Üretim A.Ş. (EÜAŞ) Türkiye’de üretim alanında halen en büyük paya sahip kuruluştur ve 2010 yılı sonu itibariyle 11674,7MW kurulu güce sahip 106 adet hidroelektrik santrale ve 12524,9MW kurulu güce sahip 19 termik santrale sahiptir. Özel sektör yatırımları dâhil 2010 yılı sonu itibariyle Türkiye toplam kurulu gücü 48587,8MW’dır. Kurulu güç itibari ile EÜAŞ Türkiye kurulu gücünün % 49,81’ini diğer bir ifade ile yaklaşık olarak yarısını oluşturmaktadır. Çizelge 3.1.’de Türkiye’de 2010 yılı itibariyle, kurulu güç ve üretim miktarlarının üretici sınıflarına göre dağılımı gösterilmiştir [TEİAŞ,İstatistik2010]. Çizelge 3.1’de mobil santraller, işletme hakkı devredilen santraller ve yap-işlet-devret (YİD) santralleri “diğer grubu” altında gösterilmektedir.


Çizelge 3.1. Kurulu güç ve üretim miktarlarının üretici gruplara göre dağılımı

Üretici	Santral tipi	Kurulu Güç(MW)	Üretim(GWh)
EÜAŞ	Termik	12524,9	54156,2
	Hidrolik	11674,7	41210,4
Özel Üretim Şirketleri	Termik	8215,8	31525,1
	Hidrolik	3547,7	8380,9
Otoprodüktör	Termik	2625,4	10582,7
	Hidrolik+Rüzgar	545,4	1225,1
Diğer	Termik	8434,1	59580,1
	Hidrolik+Rüzgar	1019,9	3520,9
Toplam	Termik	31800,2	155844,2
	Hidrolik+Rüzgar	16787,6	54337,4

2010 yılı sonu itibariyle 210,18 milyar kWh olarak gerçekleşen Türkiye elektrik üretimi miktarının, 95,37 milyar kWh’i EÜAŞ tarafından gerçekleştirilmiştir. Bir diğer ifade ile EÜAŞ ve bağlı ortaklıkları, Türkiye elektrik üretiminin ise % 45,4’ünü


karşılacaktır. Türkiye’de 1999 yılından sonra özel sektör yatırımlarının hızlanarak özellikle de termik santrallerin faaliyete girmesi yerleşik kurulu gücün artmasına neden olmuştur.

1970 - 2010 yılları arası Türkiye’deki Kurulu güç kapasitesinin gelişimi Şekil 3.1.’de görülmektedir. Türkiye’deki kurulu güçteki bu gelişim incelendiğinde; özellikle yenilenebilir enerji kaynaklarından Jeotermal ve Rüzgar enerjisine dayalı gücün, enerji ihtiyaçları da göz önüne alınarak 1984 yılına kadar artan oranda kullanılmadığı veya kullanılmadığı anlaşılmaktadır. Türkiye’nin 1984 yılında 17,5MW olan jeotermal ve rüzgâr enerjisi toplam kurulu gücü, 2010 yılı itibarıyla 1414,4MW değerine ulaşmıştır. Sadece 2010 yılında bir önceki yıla göre artış oranı %10,6 civarında olmuştur [TEİAŞ, İstatistik2010]. Bu durum şuan için yeterli olmasa bile, özellikle yeni elektrik piyasasındaki gelişmelerde göz önüne alındığında, öncelikle rüzgâr enerjisinin kullanımının ve dolayısıyla bu alandaki kurulu kapasitenin artacağı yönünde işaretler vermektedir. Yine 1997 yılından sonra Türkiye’deki Kurulu güçteki toplam artışın, özellikle termik Santraller ile birlikte artış gösterdiği, buna karşın yenilenebilir enerji kaynaklarına dayalı üretim tesislerinin aynı paralelde genel toplama katkısının az olduğu, açık şekilde görülmektedir.



Şekil 3.1. Türkiye’deki kurulu kapasitenin yıllara göre gelişimi

Özellikle 1990'lı yılların sonlarından itibaren özel sektöre ait kurulu gücün artmış olması, bu kurulu gücün büyük kısmının termik olması ve üretimlerine devlet tarafından satın alma garantisi verilmiş olması, kamu santrallerinin talebe bağlı olarak ihtiyaç duyulmadığı zamanlarda kısıtlı çalıştırılmaları sonucunu ortaya çıkartmıştır. Bilindiği üzere; elektrik enerjisi ihtiyaç duyulduğu anda üretilir. Tabii neticesi olarak üretim kapasitesi miktarı, enerji talebinden yüksek olduğu zaman fazla olan kurulu kapasite kullanılamayacaktır. Santrallerin eşit koşullarda olduğu hallerde ise; elektrik enerjisi üretimine maliyeti düşük olan santralden başlanıp yüksek olana doğru sıra ile üretim yaptırılması en ekonomik işletme yöntemlerinden birisidir.



Şekil 3.2. Türkiye’de elektrik üretiminin yıllara göre gelişimi

1970 - 2010 yılları arası Türkiye’de elektrik üretiminin yıllar itibari ile değişimi ise Şekil 3.2’de verilmiştir [TEİAŞ, 2010]. Türkiye’de 2010 yılı sonu itibari ile elektrik üretiminin genel toplamı içerisinde hidrolik enerji payı, 51795,5 GWh ile son 40 yıllık dönemde 50000 GWh’lik üretim sınırını son dönemlerde aşabildiği görülmektedir. Üretimin yıllar itibari ile genel seyrine bakıldığında; termik santrallerden karşılanan üretimde, bazı yıllarda ufak düşmeler olmasına rağmen toplam üretim içerisinde en büyük paya sahip olduğu açık bir şekilde görülmektedir. Ayrıca, jeotermal enerjinin Türkiye için 2007 yılı son çeyreğinden itibaren enerji üretiminde aktif hale gelmeye başladığı ve alternatif olarak kullanılabileceği

görülebılır. Üretim santrallerinin (tesislerinin) yakıt tipi ve sisteme giriş yılı itibariyle, yatırım kararlarının yatırımcı kuruluş veya şirketler tarafından verildiği bir enerji piyasa yapısında, Türkiye toplam talebinin güvenilir bir yedekle karşılanması için gerekli üretimin takip edilmesi, arz güvenliği açısından önemli bir husustur. Ayrıca talebin önemli bir artış oranı ile gelişmesinin beklendiği bir piyasada lisans alan, lisans almak için başvuruda bulunan üretim tesislerinin taahhüt ettikleri tarihte gerçekleştirmelerini sağlamak için gerekli önlemlerin alınması yine arz güvenliği açısından önemlidir.

TEİAŞ tarafından 2011 - 2020 yılları arası Türkiye'nin üretim kapasite projeksiyonu yapılmıştır. Bu projeksiyon raporunda; EPDK tarafından lisans verilmiş ve çalışma döneminde işletmeye girmesi beklenen inşa halindeki kamu ve özel sektör santralleri dikkate alınarak iki farklı senaryo oluşturulmuştur. Senaryo 1'e göre toplam 17183 MW ve Senaryo 2'ye göre toplam 15369 MW ilave kapasitenin sisteme dâhil olması beklenmektedir [TEİAŞ, 2011]. Yine ETKB tarafından belirlenen yüksek talep ve düşük talep serileri her iki senaryo için uygulanarak proje ve güvenilir üretim kapasitelerine göre arz-talep dengeleri kurulmuştur. Her iki senaryo sonuçlarına göre ve beklenen talebin yüksek oranda gerçekleşmesi durumunda güvenilir üretim kapasitesine göre 2016 - 2017 yılları arasında Türkiye'de elektrik enerjisi açığı beklenmektedir [TEİAŞ, 2011]. EPDK tarafından üretim lisansı verilmiş ancak sisteme (işletmeye) giriş tarihi tam olarak belirsiz olan veya lisans alma aşamasına gelinmiş ve işletmeye giriş tarihi belirsiz projelerden oluşan uygun üretim yatırımlarından, yeni ilave güç kapasitesinin 2016 - 2017 yıllarından itibaren devrede olacak şekilde, sisteme dâhil edilmesi için bugünden itibaren önlemlerin alınması, yatırım planlamalarının yapılması ülkemizin enerji dengesi için çok büyük önem taşımaktadır.

3.2. Elektrik İletim

Türkiye'de elektrik iletimi ve işletiminden sorumlu yegâne kuruluş TEİAŞ'dır. 4628 sayılı elektrik piyasası kanunu hükümlerine göre, iktisadi devlet teşekkülü olarak yapılandırılan TEİAŞ, sermayesinin tamamı iktisadi alanda ticari esaslara göre

faaliyet göstermek üzere kurulmuştur. TEİAŞ'ın ana faaliyet alanı; elektrik iletimi ile ilgili tesislerin planlanmasından yapımına, bakımından işletilmesine kadar her türlü hizmetleri yapmak ve elektrik piyasa işletmecisi olarak ilgili her türlü hizmetleri yürütmektedir. İletim Sistemi, üretim tesislerinden itibaren gerilim seviyesi 36 kV üzerindeki hatlar üzerinden elektrik enerjisinin iletiminin gerçekleştirildiği tesisler olup, 380 kV'luk Çok Yüksek Gerilim (ÇYG) ve 154 kV Yüksek Gerilim Hatları, 380/154 kV oto-trafolar ve 154/OG indirici trafolardan oluşan Türkiye İletim Sistemi teknik ve ekonomik açıdan avantajları nedeniyle yeterli miktarda seri ve şönt kapasitörlerle donatılmıştır. İletim Sistemi gerilim seviyesi 380 kV ve 154 kV ile standartlaştırılmıştır. Gürcistan ve Ermenistan ile olan enterkonneksiyon hatlarımız bu ülkelerdeki gerilim seviyesine uygun olarak 220 kV'tur. Türkiye üretim ve iletim sistemi, bir Milli Yük Tevzi Merkezi (Gölbaşı) ile 9 adet Bölgesel Yük Tevzi Merkezinden (Adapazarı, Çarşamba, Keban, İzmir, Gölbaşı, İkitelli, Erzurum, Çukurova ve Kepez) gözlenip yönetilmektedir. Elektrik sistemi işletmesi, sistemin 380 kV trafo merkezlerini ve 50 MW'ın üzerindeki tüm santralleri kapsayan bir SCADA ve Enerji Yönetim Sistemi Programı (EMS) ile yapılmaktadır. Sistem işleticisi (Sistem Operatörü) bu sistem sayesinde daha kaliteli bir işletme için gerekli olan her tür sistem çalışmasını, günlük işletme programlarını ve yük frekans kontrolünü yapabilmektedir.

TEİAŞ iletim şebekesi; 2010 yılı itibariyle 48 760 km uzunluğunda enerji güç iletim hattı, 588 adet TM (trafo merkezi) ve 93 672 MVA trafo gücü yine komşu ülkelerle bütünleşik toplam 10 adet enterkonneksiyon sisteminden meydana gelen büyük bir iletim ağıdır. TEİAŞ, 2009 yılı sonu itibariyle 44 761 MW kurulu gücü, 29 870MW ani puantı, 610 milyon kWh maksimum günlük tüketimi ve 194,1 milyar kWh'lik yıllık elektrik enerjisi üretimi olan enterkonnekte(bağlaşımlı) elektrik sistemini kesintisiz, kaliteli ve güvenilir bir şekilde işletmektedir [TEİAŞ, 2011].

Yıllar itibari ile Türkiye elektrik dağıtım bölgelerinin genişlemesi bununla birlikte elektrik tüketiminin artış göstermesi neticesinde; elektrik iletim hatlarının hat kapasitesi ve hat uzunluklarında yıllar itibari ile değişiklikler ve artışlar olmuştur. Özellikle 66kV gerilim seviyesindeki hatların, 33kV gerilim hatlarına

dönüştürülmesi bu hatların uzunluğunda düşüşler şeklinde kendini göstermektedir. Yine 220kV gerilim seviyesindeki iletim hatlarının son on yıllık dönemde uygulanan projeler ışığında, tesis edilmesinin durdurulduğu açık şekilde görülecektir. Bu bahsi edilen durumlar Çizelge 3.2.'de görülmektedir [TEİAŞ, 2011].

Çizelge 3.2. İletim hat uzunluklarının yıllar itibari ile gelişimi

Yıllar	380kv (km)	220kV (km)	154kV (km)	66kV (km)	Toplam hat uzunluğu(km)
1999	12802,9	84,5	28871,4	678,8	42437,7
2000	12957,3	84,5	29443,7	682,3	43167,9
2001	13166,6	84,5	29731,8	670,7	43653,7
2002	13625,5	84,5	30163,2	670,7	44544,0
2003	13958,1	84,5	30961,7	718,9	45723,2
2004	13970,4	84,5	31005,7	718,9	45779,6
2005	13976,9	84,5	31030,0	718,9	45810,3
2006	14307,3	84,5	31163,4	477,4	46032,6
2007	14338,4	84,5	31383,0	477,4	46283,3
2008	14420,4	84,5	31653,9	508,5	46667,3
2009	14622,9	84,5	31931,7	508,5	47147,6
2010	15559,2	84,5	32607,8	508,5	48760,0

Türkiye’de işlevsel, etkin ve rekabetçi bir elektrik piyasa yapısı için genel politika; kamunun elektrik sektöründe iletim haricinde yatırımcı olmaktan arındırılması ve sahip olduğu tesisleri özelleştirmesi, gerekli yatırımların rekabetçi bir piyasa pazarında özel teşebbüs tarafından yapılması ile kamunun düzenleyici konumunun güçlendirilmesi ve arz güvenliğini temin etmesi olarak özetlenebilir.

3.3. Elektrik Dağıtım

Elektrik enerjisi, gerilimi düşürüldükten sonra bölgesel şebekelere iletilir ve bu şebekeler yardımıyla ayrılarak dağıtım merkezlerine ve dolayısıyla tüketicilerin

kullanımına sunulur. Dağıtım merkezlerinin ise temel olarak iki farklı görevi vardır. Bunlar; hatların birbirine bağlantısını (interconnection) ve gerilim seviyesinin dönüştürülmesini (transformation) sağlamaktır. Dağıtım kuruluşu veya şirketleri tüketim ihtiyacına göre yeni tesisler kurmak, bunları yönetmek/yenilemek, yeni tüketicileri şebekeye almak, serbest tüketici işlemlerini yapmak, arızaları onararak dağıtılan elektriğin sürekliliğini sağlamak ve miktarını sabit kılmakla yükümlüdür.

Türkiye Elektrik sektöründe tekel olan Türkiye Elektrik Kurumu (TEK) 1994 yılında Dağıtım hizmetleri için TEDAŞ, üretim ve iletim hizmetleri için ise TEAŞ olarak yeniden kurgulanmış devamında TEAŞ'ta EÜAŞ, TEİAŞ ve TETAŞ olmak üzere üç farklı şirket hüviyetine bürünmüştür. 2005 yılında, yaklaşık 28 milyon müşterisi, toplam 93 milyar kWh elektrik satışı ve elektrik dağıtımında ülke genelinde %98'lik pazar payı ile TEDAŞ ve sahibi olduğu dağıtım şirketleri, topluca Türkiye'nin en büyük organizasyonlarından birini oluşturmaktadırlar.

Elektrik dağıtım ve perakende satış sektöründe rekabete dayalı bir ortamın oluşturulması ve gerekli reformların yapılmasını temin etmek için; dağıtım bölgeleri baz alınarak kamu mülkiyetindeki elektrik işletmelerinin yeniden yapılandırılması suretiyle elektrik enerjisi dağıtım hizmetlerinin özelleştirilmesine karar verilmiş ve TEDAŞ 02.04.2004 tarih ve 2004/22 sayılı Özelleştirme Yüksek Kurulu Kararı ile özelleştirme kapsam ve programına alınmıştır.

Dağıtım bölgeleri coğrafi yakınlık, yönetim yapısı ve enerji talebi gibi etkenler göz önüne alınarak yeniden belirlenmiş, Türkiye 21 elektrik dağıtım bölgesine ayrılmıştır.

Dağıtım bölgeleri ve 2008 yılı mevcut abone sayıları¹ Çizelge 3.3.'de gösterilmektedir [TEDAŞ, 2008]. Dağıtım bölgeleri içerisinde ilk işletme hakkı devri yapılan şirket, 1990 yılında devri gerçekleşen KCETAŞ (Kayseri ve civarı)'dır.

¹ Dağıtım şirketlerinin 2009 yılından itibaren hızla özel sektöre devri ile birlikte doğru istatistiki bilgilerin raporlanmasında ve yayınlanmasında TEDAŞ zorluklar yaşamıştır. Bu itibarla dağıtım şirketlerinin abone büyüklüğünü doğru yansıtmaları açısından 2008 yılı değerleri kullanılmıştır.

2009 yılı başı itibari ile de Başkent ve Sakarya dağıtım bölgelerindeki özelleştirmeler ile elektrik dağıtım bölgelerindeki özelleştirme uygulamaları ivme kazanmıştır.

Çizelge 3.3. Türkiye’de elektrik dağıtım bölgeleri

Bölge	Dağıtım Bölgesi	Abone sayısı	Yönetim	Görev alanı
1	Dicle EDAŞ	1 044 300	Kamu	Diyarbakır, Şanlıurfa, Mardin, Batman, Siirt, Şırnak
2	Van Golu EDAŞ	401 400	Kamu	Bitlis, Hakkari, Muş, Van
3	Aras EDAŞ	725 200	Kamu	Erzurum, Ağrı, Ardahan, Bayburt, Erzincan, Iğdır, Kars
4	Coruh EDAŞ	989 600	Özel	Trabzon, Artvin, Giresun, Gümüşhane, Rize
5	Fırat EDAŞ	663 700	Özel	Elazığ, Bingöl, Malatya, Tunceli
6	Camlibel EDAŞ	734 700	Özel	Sivas, Tokat, Yozgat
7	Toroslar EDAŞ	2 597 400	Kamu	Adana, Gaziantep, Hatay, Mersin, Osmaniye, Kilis
8	Meram EDAŞ	1 530 500	Özel	Kırşehir, Nevşehir, Niğde, Aksaray, Konya, Karaman
9	Enerjisa Baskent EDAŞ	3 075 800	Özel	Ankara, Kırıkkale, Zonguldak, Bartın, Karabük, Çankırı, Kastamonu
10	Akdeniz EDAŞ	1 469 800	Kamu	Antalya, Burdur, Isparta
11	Gediz EDAŞ	2 331 500	Kamu	İzmir, Manisa
12	Uludağ EDAŞ	2 278 500	Özel	Balıkesir, Bursa, Çanakkale, Yalova
13	Trakya EDAŞ	767 800	Özel	Edirne, Kırklareli, Tekirdağ
14	Anadolu Y. EDAŞ	2 037 900	Kamu	İstanbul ili Anadolu Yakası
15	Sakarya EDAŞ	1 307 300	Özel	Sakarya, Bolu, Düzce, Kocaeli
16	Osmangazi EDAŞ	1 277 300	Özel	Eskişehir, Afyon, Bilecik, Kütahya, Uşak
17	Bogazici EDAŞ	3 832 800	Kamu	İstanbul ili Rumeli Yakası
18	Kayseri(KCETAŞ)	521 453	Özel	Kayseri
19	Aydem EDAŞ	1 475 700	Özel	Denizli, Aydın, Muğla
20	Goksu EDAŞ	479 800	Özel	K.Maraş, Adıyaman
21	Yesilirmak EDAŞ	1 466 700	Özel	Samsun, Amasya, Çorum, Ordu, Sinop

2012 yılı nisan ayı sonu itibari ile Türkiye’de mevcut 21 dağıtım şirketinin yaklaşık %60’ı yani 13 tanesinin özel sektöre devri tamamlanmıştır. Bir kamu iktisadi teşekkülü (KİT) olan TEDAŞ’a bağlı ve özelleştirmesi tamamlanmamış (veya devir işlemleri bitmemiş) 8 adet dağıtım şirketi kalmıştır. Türkiye’de 2009 yılı itibari toplam 31,85 milyon abonesi olan dağıtım sisteminde tüm dağıtım hatlarının toplam uzunluğu 969 238 km’dir [TEDAŞ, 2009].

0,4kV gerilim seviyesindeki hat uzunluğu 562 342 km iken 33kV gerilim seviyesindeki hat uzunluğu ise 364 407’dir. Yine 2009 verilerine göre Türkiye

dağıtım şebekesinde toplam 111 082 MVA kurulu gücünde 335 099 adet dağıtım trafosu mevcuttur [TEDAŞ, 2009].

3.4. Sistem Kayıpları

Genel bir elektrik sisteminde meydana gelen kayıplar, üretim, iletim ve dağıtım sistemlerinde olmak üzere ayrı alanlar olarak incelenebilir. Üretimden elde edilen elektrik, iletim (transmisyon) hatlarıyla transformatörlere taşınmaktadır. Talep edilen gerilim seviyelerine göre kullanıcıların kullanımına sunulmaktadır. Global olarak genel kabul; ortalama maliyetler dikkate alındığında, sistem maliyetlerinin % 50'si üretimden, % 20'si iletimden ve % 30'u ise dağıtımdan kaynaklanmaktadır. Fakat kayıplara bakıldığında bu durum tam tersi olarak ortaya çıkmaktadır. Kayıpların büyük kısmı iletim ve dağıtım tesislerinde oluşmaktadır. Dağıtım tesisleri veya sistemlerinde gerilim seviyesinin düşük ve akımın yüksek olmasından dolayı daha fazla kayıplar oluşmaktadır. Enerji santrallerinde üretilen elektriğin ortalama % 6'sı iç kayıp ve iç tüketime harcanırken bu oran iletim tesislerinde Avrupa normlarına yakın seyretmekte olup yaklaşık %3 dolaylarındadır. Dağıtım tesislerinde ise teknik kayıpların ve abonesel kaçak oranının yüksek olmasından dolayı % 20'nin üzerine olmaktadır. Bu oranlar göz önüne alındığında; toplam üretilen enerjinin % 30'nun kayıpları karşıladığı ve büyük bir enerji gücünün yok olduğu görülmektedir [Sargın, 2006]. Türkiye'de elektrik dağıtım sistemindeki kayıpları ise; teknik ve teknik olmayan kayıplar olmak üzere iki farklı şekilde incelemek doğru olacaktır.

Teknik kayıplar dağıtım hatlarındaki dağıtılan enerjiden ve gücün dağıtımı için kullanılan donanımlardan kaynaklanan kayıplardır. Enerji dağıtımda meydana gelen teknik kayıpların büyük bir çoğunluğunu akıma bağlı kayıplar (kablo bağlantı klemenslerinde, kablolarda zırh, siper kayıpları ile karşılıklı reaktanstan kaynaklanan kayıplar vb.) oluşturmaktadır. Hatlardaki akıma bağlı bu kayıplar ısı enerjisi olarak ortaya çıkmaktadır. Bununla birlikte yüke bağlı olan ve yükten bağımsız olarak hatlarda veya trafoların çekirdek ve bakır kısımlarında da teknik kayıplar meydana gelmektedir. Teknik olmayan kayıplar ise daha çok son tüketiciler ile ilgili bir kavram olup kasıtlı (kaçak) veya kasıtsız (bilinçsiz) olarak enerji kullanımları

sonucunda ortaya çıkmaktadır. Teknik olmayan kayıp elektrik abonelerine teslim edilen ve tüketilen ama bazı sebeplerden dolayı satış olarak kaydedilmeyen değerleri de içermektedir. Bunun temel sebepleri kaçak elektrik kullanımı, eksik ölçümler ve hatalı sayaç okuma ya da faturalandırmada yapılan hatalar olarak ifade edilebilir.


Türkiye’de özelleştirme işlemleri tamamlanmamış, yani TEDAŞ bağlı ortaklık konumundaki dağıtım şirketlerinin verilerine göre; TEDAŞ’a 2009 yılı sonu itibariyle toplam 129 789 010MWh’lik elektrik enerjisi, iletim sistemi üzerinden aktarılmış bu enerjinin ancak 106 755 880MWh’lik kısmı faturalandırılmıştır. Sistemdeki kayıp-kaçak miktarı ise 23 033 130MWh (%17,7) olarak gerçekleşmiştir [TEDAŞ, 2009].

Elektrik dağıtım hizmetinin özel sektör aracılığı ile yapıldığı sektörel toplamlara bakıldığında ise; 2009 yılı itibariyle 30 683 346 MWh’lik enerji teminine karşılık, 28 698 483MWh enerji faturalandırılmış ve toplam 1 984 864MWh’lik (%6,5) sistemsel kayıp-kaçak oluşmuştur [TEDAŞ, 2009].

Ülkemizin nüfus yoğunluğu, arz kaynaklarının yeri ve coğrafi koşullarına uygun olarak Avrupa standartlarına göre dizayn edilen iletim sistemi kayıpları, uluslararası performans düzeyindedir [TEİAŞ, 2011].

Türkiye iletim sistemi kaybı 2009 yılı için %2,1 (3973,4GWh) iken 2010 yılı için %2,8 (5690,5GWh) olarak ölçülmüştür. Türkiye’de iletim ve dağıtım sistemlerindeki kayıp ve kaçakların yıllara göre yüzdesel değişimi Şekil 3.3’de gösterilmektedir [TEİAŞ, 2011].

Enerji nakli yapılan dağıtım ve iletim sistemlerinde, kayıpların tamamını ortadan kaldırmak doğal olarak pratikte pek mümkün değildir. Özellikle dağıtımdaki teknik kayıpları minimum seviyelere indirmek için; güç sistemlerinde güç faktörünün düzeltilmesi, kablo kesitinin doğru seçilmesi, dağıtım transformatör gücünün yeterli miktarda olması, ölçü aletlerinin hassas olması gibi ölçütlere öncelik verilmelidir.




Şekil 3.3. Türkiye iletim ve dağıtım sistem kayıplarının yıllara göre yüzdesel değişimi

3.5. Elektrik Tüketimi


Ülkemizde sanayileşmenin bir sonucu olarak; köylerden şehirlere göçlerin olması, tüketim toplumuna dönüşüm, işsizlik ve nüfus artışı, enerji talebimizi ve bunun sonucu olarak enerji ithalatımızı artırmaktadır. Enerji hammaddeğini ithal eden ve elektrik üretiminde % 60 oranında ithalata bağımlı olan ülkemizde, elektrik fiyatları da bununla paralel olarak artış göstermektedir. Türkiye’de bu elektrik fiyatlarındaki artışa rağmen, ülkemizdeki sanayileşme ve modernleşme süreçleri ile net elektrik tüketiminin yıllar itibari ile (Şekil 3.4) lineer biçimde artış gösterdiği görülmektedir.

Türkiye elektrik tüketim verileri baz alındığında; brüt tüketim (Türkiye brüt üretimi+dış alışı+dış satışlar) 2009 yılında % 2 azalarak 194,1 Milyar kWh, 2010 yılında ise % 8,4 artış ile 210,4 Milyar kWh olarak gerçekleşmiştir. Türkiye net elektrik tüketimi ise (iç tüketim, şebeke kaybı ve kaçaklar hariç) 2009 yılında 156,9 Milyar kWh, 2010 yılında ise 169,4 Milyar kWh olarak gerçekleşmiştir [TEİAŞ, 2011].



Şekil 3.4. Türkiye net elektrik tüketiminin yıllara göre değişimi


Türkiye'nin net elektrik tüketimi yıllar itibari ile doğrusal bir artış gösterir. Ancak Şekil 3.4'de görüldüğü üzere, 2001 yılında büyük oranda yaşanan ekonomik krizin de etkisi ile net elektrik talebi düşmüştür. Yine 2009 yılında elektrik tüketiminde büyük oranda düşüş yaşanmış ancak 2010 yılında tekrar normal artış eğilimini (trend) yakaladığı görülmektedir. Türkiye kişi başı tüketim verileri (Şekil 3.5) incelendiğinde ise; Türkiye net elektrik tüketimi ile paralel olarak, lineer bir artış seyri olduğu ve 2009 yılında kişi başı tüketiminde genel yapı içerisinde düşüş meydana geldiği görülmektedir.



Şekil 3.5. Türkiye kişi başı elektrik tüketiminin yıllara göre değişimi

Türkiye tüketim istatistiklerine göre; 2009 yılı için toplam 156894,1 GWh'lik net elektrik enerjisi tüketilmiştir. Bu tüketilen enerjinin büyük bir kısmı 70470,1 GWh'i (%44,9'ü) sanayi iş kolunda ve 39147,5 GWh'lik kısmı ise meskenlerde kullanılmıştır.

Yine Türkiye elektrik enerjisi tüketim pastası içerisinde, aydınlatma tüketimleri yaklaşık % 2,5'lik ve resmi daireler ise % 4,5'lik pay ile tüketimin az gerçekleştiği kolları oluşturmaktadır [TEDAŞ, 2009]. Türkiye'deki net tüketimin 2009 yılı sonu verilerine göre sektörel dağılımı Şekil 3.6'da gösterilmektedir.



Şekil 3.6. Türkiye elektrik tüketiminin sektör tabanlı dağılımı

ETKB tarafından hesaplanan elektrik enerjisi yüksek ve düşük enerji taleplerinin gerçekleşmesi halinde; 2010 yılı sonunda işletmede olan üretim tesislerinden oluşan mevcut elektrik enerjisi üretim sistemimize, Senaryo 1'e göre 13707 MW ve Senaryo 2'ye göre 11893 MW Lisans almış ve inşa halindeki özel sektör projeleri, 3475.7 MW İnşa halindeki kamu üretim tesislerinin ilave edilmesi ile her iki senaryo için de; proje üretim kapasitelerine göre 2018 – 2019 yıllarından itibaren, güvenilir üretim kapasitelerine göre ise 2016 - 2017 yıllarından itibaren öngörülen elektrik enerjisi talebinin karşılanamayacağı hesaplanmaktadır [TEİAŞ, 2011].

3.6. Elektrik Piyasası

3.6.1. Piyasa gelişim süreci

Elektrik üretimi Türkiye’de ilk defa Tarsus’ta su değirmeni ile çevrilen 2 kW’lık bir dinamo ile gerçekleştirilmiştir. Yine ilk santral ise, 1913 yılında İstanbul Silahtar Ağa’da kurulmuştur. Cumhuriyetin ilk yıllarında yerli sermaye birikimindeki ve mali kaynaklardaki yetersizlik sebebi ile elektrik sektörü yatırımları ağırlıklı olarak yabancı kaynaklı yatırımcılar tarafından gerçekleştirilmiştir. Bahsi edilen bu dönemde, genellikle Belçika, Almanya, İtalya ve Macaristan menşeli şirketler elektrik tedarikine ilişkin faaliyetleri yürütmüşlerdir [Hepbaşlı, 2005].

Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) 1963 yılında teşkilat yapısına kavuşturulmuş, bundan yedi yıl sonra yani 1970 yılında ise Türkiye Elektrik Kurumu (TEK) kurulmuştur. Elektrik dağıtım hizmetleri haricinde, elektrik sektörünün bütün hizmet kollarında faaliyet gösteren TEK’in kurulması ile elektrik sektörü dikey bütünleşik yapıda bir tekel olarak konumlandırılmıştır. Belediyelerin elektrik dağıtım yetkisi 1982 yılında elinden alınması ile TEK elektrik sektörünün bütün kollarında hizmet veren milli bir elektrik kurumu konumuna gelmiştir.

1980’li yıllar ile birlikte ihracata dayalı büyüme stratejisini benimseyen Türkiye, özel müteşebbislerin elektrik endüstrisine girmesi için değişik alternatifler ve teşvikler üretmeye başlamıştır [Bağdadioğlu, 2009]. TEK’in elektrik sektöründeki tek ve bütünleşik yapısını sona erdirmek için; 1984 yılında düzenlenen 3096 sayılı kanun ile özel sektörün İşletme Hakkı Devri (İHD) veya Yap-İşlet-Devret (YİD) gibi yöntemlerle Türkiye elektrik piyasasının iştirak etmesi ve piyasa oluşumunun temelleri atılmak istenmiştir. Yine bu kanunda; yeni tesis edilecek elektrik üretim tesisleri için YİD modeli, hali hazırda kurulu olan elektrik dağıtım ve üretim tesisleri için ise mülkiyeti TEK’te kalmak üzere işletme hakkının özel sektör yatırımcılarına devri düşünülmüştür. Ancak bazı siyasi ve hukuki etmenlerden dolayı bu kanun 1994 yılına kadar, tam olarak uygulamaya konulamamıştır. 1994 yılında TEK iki ayrı şirket olarak ikiye ayrılmış ve elektrik enerjisi üretim ve iletim faaliyetlerini

yürütmek üzere Türkiye Elektrik Üretim ve İletim A.Ş. (TEAŞ) ve elektrik dağıtım faaliyetlerini yürütmek üzere Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) kurulmuştur. 2001 yılında ise; 4628 sayılı elektrik piyasası kanunu yürürlüğe sokularak, elektrik piyasasının serbest rekabet esasları çerçevesinde yürütüleceği bir piyasa mekanizması kurulması hedeflenmiştir. Bu kanunla birlikte, TEAŞ üç farklı şirket hüviyetine bölünmüştür. TEAŞ'ın elektrik üretim faaliyetlerini gerçekleştirmek üzere Elektrik Üretim A.Ş. (EÜAŞ), elektrik iletim faaliyetleri için Türkiye Elektrik İletim A.Ş. (TEİAŞ) ve elektrik ticaret faaliyetleri için Türkiye Elektrik Ticaret ve Taahhüt A.Ş. (TETAŞ) kurulmuştur. Elektrik piyasa kanunu ile birlikte eş zamanlı olarak Enerji Piyasası Düzenleme Kurumu (EPDK) kurulmuştur. EPDK, Türkiye'de elektrik piyasasının düzenleyicisi ve tüm enerji sektörü üzerinde, piyasa yaptırım kimliğine haiz üst kurum hüviyetindedir.

3.6.2. Piyasa yapısı (konfigürasyonu)

Elektriğin üretimi, iletimi, dağıtımı, toptan satışı, perakende satışı, perakende satış hizmeti, ticareti, ithalatı ve ihracat faaliyetleri toplamı, elektrik piyasasının genel kapsamını oluşturmaktadır.


Türkiye'de elektrik üretim faaliyetleri, EÜAŞ (ve bağlı ortaklıkları), özel elektrik üretim şirketleri, otoprodüktörler, kojenerasyon tesisleri ile YİD/Yİ hükümleri çerçevesinde üretim yapan şirketlerce gerçekleştirilmektedir. 17 Mart 2004 tarihinde Yüksek Planlama Kurulu (YPK) Kararı ile açıklanmış olan Elektrik Enerjisi Sektörü Reformu ve Özelleştirme Strateji Belgesinde özelleştirilecek portföy üretim gruplarının belirlenmesini öngörmüştür. Strateji belgesinde, belirlenen portföy üretim gruplarının 30 Eylül 2005 tarihine kadar özelleştirilmesi öngörülmüştür. Ancak, belirlenmiş olan portföy üretim gruplarının özelleştirilme süreçleri henüz başlatılmamıştır. Ayrıca elektrik üretim veya otoprodüktör lisansı başvuruları EPDK tarafından incelenmekte ve uygun bulunan şirketlere kurul kararı ile lisans düzenlenmektedir.

TEİAŞ, Türkiye’de ise 4628 sayılı yasa gereğince iletim sistemi işletmecisi tek kuruluştur. Güncel mevzuatlar gereği ve YPK kararı ile açıklanmış olan Strateji Belgesinde, iletim hizmetlerinin kati surette özelleştirme kapsamı dışında tutulacağı açıkça ifade edilmektedir. TEİAŞ, Enerji Bakanlığı’nın ilgili bir kuruluşu durumundadır. TEİAŞ, piyasa işletim hizmetini bünyesindeki Piyasa Mali Uzlaştırma Merkezi (PMUM) aracılığı ile yürütmektedir. TEİAŞ’ın piyasa işletmecisi ana görevinin dışında, yük dağıtımı ve frekans kontrolünü gerçekleştirmek, iletim sisteminde gerekli kapasite artışı sağlamak, gerçek zamanlı sistem güvenilirliğini Yük Tevzi Merkezi (YTM) aracılığı ile takip etmek gibi stratejik görevleri vardır.

Türkiye’de elektrik dağıtımı faaliyetleri TEDAŞ tarafından yürütülürken; TEDAŞ 21 coğrafi dağıtım şirketine bölünmüş olup, strateji belgesinde bu şirketlerin tamamının 2009 yılı sonuna kadar özelleştirilmesi planlanmıştır. Ancak 2012 yılı ilk yarısı itibari ile halen 8 adet dağıtım şirketinin henüz ihale veya devir işlemleri tamamlanamamıştır. 4628 sayılı yasa elektrik dağıtım şirketlerinin çok sayıda olmasını ve lisanslarında yer alan bölgelerde faaliyet göstermelerini zorunlu kılmaktadır. EPDK tarafından elektrik dağıtım lisans başvuruları değerlendirilmekte ve uygun bulunan şirketlere kurul tarafından dağıtım lisansı düzenlenmektedir. Ayrıca, Türkiye’de elektrik piyasasında Organize Sanayi Bölgeleri (OSB) elektrik dağıtım hizmetleri kapsamında dağıtım şirketleri olarak değerlendirilmektedir.

Türkiye elektrik piyasasında elektrik ticareti, ikili anlaşmalar kapsamında veya dengeleme uzlaştırma piyasasında gerçekleştirilmektedir. Şekil 3.7’de Türkiye’de mevcut elektrik piyasasının genel yapısı görülmektedir. Kamuya ait üretim tesisleri, TETAŞ aracılığı ile veya doğrudan iletim sistemi aracılığıyla dağıtım şirketlerine elektriklerini ulaştırabilmektedir. Otoprodüktörler ve özel üretici şirketler, TETAŞ veya iletim şebekesi aracılığı ile ürettikleri elektriği piyasa havuzuna satabilecekleri

gibi doğrudan iletim ve dağıtım şebekesi aracılığı ile serbest tüketicilere¹ ürettikleri elektriği satabilmektedirler.



Şekil 3.7. Türkiye elektrik piyasası genel yapısı

EÜAŞ (ve bağlı ortaklıkları) üretmiş olduğu enerjiyi TETAŞ'a satmakta ve yine şekil 3.7'de görüldüğü üzere, EÜAŞ elektrik dağıtım şirketlerine de iletim sistemi üzerinden direkt olarak elektrik satışı yapabilmektedir. Ayrıca YİD, Yİ sözleşmeleri kapsamında üretim faaliyeti gerçekleştiren güç santralleri de üretmiş oldukları enerjiyi TETAŞ'a satmaktadır. TETAŞ, söz konusu santraller ve EÜAŞ'tan almış olduğu enerjiyi, dağıtım şirketleri ile özel perakende şirketlere satabilmektedir. Türkiye elektrik piyasasında otoprodüktörler tesisleri de elektrik ticareti yapabilmektedir. Elektrik piyasası hükümlerine göre bir otoprodüktör şirketi, bir takvim yılı içerisinde lisansına derç edilen yıllık ortalama elektrik enerjisi üretim miktarının yüzde yirmisini, piyasada satabilmektedir.

Türkiye elektrik piyasasında, dengeleme ve uzlaştırma piyasası katılımcıları lisanslı üretim, otoprodüktör, toptan satış ve perakende satış şirketlerinden meydana gelmektedir. Dengeleme sistemi katılımcıları kendi adına PMUM'a kayıtlı en az bir dengeleme birimi olan ve piyasada üretim faaliyeti gösteren tesisleri ifade etmektedir. Bu tesisler, aynı zamanda Milli Yük Tevzi Merkezi tarafından uygun

¹ Elektrik tüketimi, EPDK tarafından belirlenen yıllık elektrik enerjisi tüketim miktarından daha fazla olan veya iletim sistemine doğrudan bağlı olması nedeniyle tedarikçisini seçme serbestisine sahip gerçek veya tüzel kişiler serbest tüketici(eligible consumer) olarak tanımlanmaktadır.

bulunan yük alma (YAL) ve yük atma (YAT) gibi fonksiyonel işlevleri bağımsız yapabilme yetisine sahiptirler.

Milli Yük Tevzi Merkezi'nin yürütmüş olduğu gerçek zamanlı (real time) dengeleme işlemine katılan üretim tesisleri, YAL ve YAT fiyatlarına ilişkin önerilerini ayda iki kez Milli Yük Tevzi Merkezine bildirmekte ve piyasa işletmecisi olan PMUM bu teklifleri ekonomik sıralamalarına göre değerlendirmektedir. Sistemde enerji açığı olacağının tespiti halinde yük alma talimatları aracılığıyla en düşük fiyat teklifini veren üreticiden başlanarak elektrik üretimi artırılmaktadır. Enerji fazlası olacağının tespiti halinde ise en yüksek yük atma teklifini vermiş olan üreticiden başlanarak elektrik üretiminin azaltılması sağlanmaktadır.

Elektrik piyasası kanunun yayımlanması ve EPDK'nın kuruluşu ile birlikte Türkiye'de elektrik piyasası yapısında eskiye göre büyük değişiklikler meydana gelmiştir. Bazı değişiklikler ve eski-yeni yapının karşılaştırması Çizelge 3.4'de verilmektedir. Çizelge 3.4'de de görüleceği üzere; yeni elektrik piyasası öncesi yapıda rekabetçi bir yapıdan söz etmek olanaksızdır.

Çizelge 3.4. Türkiye'de eski-yeni piyasa yapılarının karşılaştırılması

Parametre	Piyasa öncesi yapı	Yeni piyasa
Genel yapı	Tek alıcı-tek satıcı	Dengeleme piyasası, ikili anlaşmalar
Tüketici	Aynı müşteri grupları	Farklı müşteri grupları
Tüketici tarifeleri	Tek tip tarife	Farklı tarifeler
Fiyatlandırma	Maliyetin etkisi yok	Maliyet tabanlı
Piyasaya giriş	Öneri yolu ile	Lisans ile
Düzenleme	ETKB ve ilgili kurumlar	EPDK
Avrupa Birliğine uyum	Uyumlu değil	Uyumlu

4. ELEKTRİK ENERJİ SİSTEMLERİNDE PLANLAMA

4.1. Planlama Kavramı ve Süreçleri

Planlama, geleceğe bakma ve muhtemel seçenekleri saptama sürecidir. Planlamanın bir özelliği de geleceği bugünden görme ve kontrol etme aracı olmasıdır. Ekonomik manada, bir kaynak dağıtım mekanizması olarak da görülebilir. Yani sınırsız ihtiyaçlar ile sınırlı kaynaklar arasında bir denge sağlar. Geleceği yönetme ve kaynakları dağıtma aracı olan planlama neyin, ne zaman ve nasıl yapılacağını, bütün bu çalışmalarda kimlerin sorumlu olacağını belirlenmesi ve saptanmasına da olanak verir. Bu özellikler planlamanın disiplinler arası bir aktivite olduğunu göstermektedir.

Elektrik enerji sistemlerinde planlama ise, belirlenen hedefler doğrultusunda göz önüne alınan çalışma koşullarına göre sistemin gelişiminin ve buna ilişkin seçimlerin kesin ve açık olarak belirlenmesini gerektirmektedir. Elektrik enerjisinin üretimi, iletimi ve dağıtımındaki en önemli amaç, enerjinin tüketicilere ucuz ve kaliteli olarak ulaştırılmasıdır.

Tüketicilere güvenilir, kaliteli, sürekli ve ekonomik elektrik enerjisi arz edebilmek için hâlihazırda var olan elektrik enerji sistemlerinin, gelecekteki elektrik enerji ihtiyacını ve demant yükünü karşılayabilecek biçimde revize edilmesi gerekmektedir [Ceylan, 2004].

Kısa dönem planlamalarda doğrudan doğruya süratle ve değişmeyecek kesin kararlar alınmalıdır. Kısa dönemde, önerilen işletme programının seçimi yapılarak, kısa vadeli amaçların gerçekleştirilmesinde kullanılacak en kullanışlı alternatif yöntemlerin de değerlendirilmesiyle, yakın gelecek için en iyi çözümlerin bulunması temel hedefler olarak ifade edilebilir.

Orta dönem planlamada yapılacak işlemler kısa dönem planlamaya göre daha geniş bir zamana yayılmıştır. Bu tür planlamada yapılacak yatırım programının seçiminin

yanı sıra, amaçların gerçekleştirilmesi için alternatif seçenekler göz önünde bulundurularak, geleceğe ilişkin belirlemeler yapılır ve program kapsamına dâhil edilir.

Enerji sistemlerinde uzun dönem planlamada ise; güç üretimi, elektrik iletimi ve dağıtım hizmetlerinde değişik alternatiflerin incelenebilme imkanı vardır. Planlama için kullanılacak birçok verinin farklı araçlar kullanılarak değerlendirilmesi ile reel yaklaşımlar ortaya çıkarılır. Finansal gelişmelerden, sosyal verilere kadar uzanan pek çok farklı veriyi birleştirerek elde edilen sonuçları enerji tüketimi ile ilişkilendirmek ve geleceğe dönük reel sonuçlar ortaya çıkarmak için uzun ve ayrıntılı bir çalışma yapılır. Bu çalışma, kısa dönemli ve orta dönemli planlamada alınan kararlarda ve yatırım programlarında da yön gösterici olarak işlev görür [Oğurlu, 2004].

Elektrik sistemlerinin planlanmasında; planlama dönemleri ve planlamanın muhteviyatı göz önüne alındığında, elektriğin üretiminden elektriğin tüketiciye dağıtımına kadar süreçte belirli bir sıra takip edilir. Her donanımın planlanması için bir önceki planda yer alan verilerden faydalanılır. Elektrik sistemlerinin planlanmasında ilk adım, talep edilecek yükün veya enerji tüketiminin tahmin edilmesidir. Bununla birlikte üretim, iletim ve dağıtım sistemlerinin planlaması ile bu bölümde de ayrıntılı olarak bahsedilen planlama çalışmaları (finansal, çevresel vb..) bir sıra dahilinde icra edilmektedir.

4.1.1. Enerji tüketim ve puant yük tahmini

Etkili bir sistem planlaması için, demant (puant) yük ve elektrik enerji ihtiyacının tahmin edilmesi gereklidir. İhtiyaç olan enerjinin tahmini, üretim sistemi planlaması için oldukça önem arz etmektedir. Güç santrallerine yapılması gereken ilave ve/veya yeni güç santrallerinin tesis edilmesi, puant güçlerde dikkate alınarak, tahmin edilen enerji talebini karşılamak üzere belirlenmektedir. Yine duruma uygun tesis türü ve bu tesisler için üretim imkânları araştırılır. Yük tahminleri sonucuna göre; üretimle birlikte iletim ve dağıtım sistemlerine yapılması gereken kapasite artırımları ile bu eklemelere ilgili yatırım ve risk maliyetleri belirlenmektedir.

Gerekenden daha düşük yük ve tüketim tahminlerine dayalı yapılan planlamada, güç sistem güvenilirliğinin azalmasına, tüketiciye arz edilen enerjinin kısıtlanmasına ve enerji kalitesinde kaydadeğer düşmelere neden olacaktır. Gerekenden fazla tahminlerde ise; tam kapasite ile hizmet veremeyen, düşük kapasite ile çalışan ve dolayısıyla ekonomik olmayan sistem işletme sorunlarına neden olacaktır. Bu gibi durumlar, aynı zamanda elektrik sistemine büyük ölçekli yatırımlar yapan enerji kuruluşlarında önemli mali problemler ile karşı karşıya kalmasına neden olacaktır [Yoldaş, 2004].

Elektrik tüketim tahmini, elektrik piyasası oyuncuları ve enerji sektöründeki şirketler açısından planlama ve koordinasyonun yapılabilmesi için her zaman stratejik öneme sahip bir konu olmuştur. Bununla birlikte EPDK tarafından enerji mevzuatı üzerinde yapılan değişiklikler ile üretim, iletim ve dağıtım sistem operatörlerine verilen yeni görevler, elektrik tüketim tahminini daha fazla önemli hale getirmiştir.

4.1.2. Üretim sistem planlaması

Elektrik enerjisinin üretiminin gelecekteki maliyetinin daha ekonomik olması ve kullanıcıların talep edeceği elektrik enerjisini karşılayabilecek yeterlikte, optimum üretim kapasitesinin sağlanabilmesi için daha öncede bahsi edilen üretim sistem planlaması yapılmaktadır. Hali hazırda kurulu bulunan güç sistem donanımlarına eklenmesi gereken veya eklenecek yeni tesis, tesis güçleri ve eklenecek donanımların devreye alınma zamanlarını gösteren termin planlarının oluşturulmasında üretim sistem planlaması önem arz etmektedir. Üretim planlamasında üç tür aşamadan söz edilebilir. Bunlar kapasite planlanması, üretim ve yatırım maliyetinin hesaplanması ve tesis kurulduktan sonraki işletme, bakım masraflarının hesaplanmasıdır.

Güç sistemlerinin üretim sistem planlaması geliştirilirken, sisteme ilişkin olarak güvenilirlik analizi (enerjideki süreklilik kriteri) sağlanmalıdır. Gerekli olan güç kapasiteni belirlemek üzere, programlanan sistem bakım görevlerini de kapsayan güç üretim modelleri ile elektrik yük modelleri birleştirilerek incelenmelidir. Enerji güç sistemlerindeki üretim birimlerine ilişkin, kullanılacak hammaddeye yakın ve kolay

elde edilmesi, dışa bağımlılık yönü, işletme bakım çalışmalarının ve öngörülen zorunlu devre dışı kalma sürelerinin sistem üzerindeki etkileri göz önüne alınarak, sistemin enerji ihtiyaçlarına karşı düşen üretim maliyetleri hesaplanabilir. Santralin kurulması düşünülen saha araştırması yapılırken ise; santrallerin kurulması düşünülen yerlerin jeolojik/jeofizik özelliklerinin ve deprem risklerini göz önünde bulundurulması önemlidir. Bununla birlikte, yatırım işletme ve bakım maliyetlerinin aktüel değerleri hesaplanarak, önceden belirlenen bu değerler üzerinde daha ayrıntılı ve hassas incelemelerde bulunulabilir [Yoldaş,2004].

4.1.3. İletim sistem planlaması

İletim sistemi planlamasının, üretim ve yük merkezlerinin yerleşim yerleri ile kapasitelerine bağlı olması bununla birlikte yeni iletim sistemi donanımlarının tesis edilme, tesislerin devreye alınma zamanlarının üretim tesisleri kurulması için harcanan zamandan az olması üretimden sonra iletim planlaması yapılması yönünde bir sıralama oluşturmaktadır. Bu planlamada temel amaç; planlama süreci içerisinde iletim sisteminin geleceğini belirlemektir. Bir diğer ifade ile, geleceğe dönük öngörüsü yapılan yük, tüketim ve üretim senaryolarına göre enerji iletim koridorlarına ilişkin kısıtlamaların, yatırım maliyetlerinin ve iletim sistemi elemanlarının kapasitelerinin belirlenmesidir. İletim sistemi üzerinde yapılacak geliştirmeler ve değişik şartlar altında iletim sisteminde çıkabilecek problemler bilgisayar yazılımlarından yararlanılarak yapılmaktadır. Optimal şartlar altında iletim hatlarının devreden çıkarılması veya bazı ana iletim hatlarında arızaların meydana gelmesi durumları ayrı olarak incelenmelidir. Enterkonnekte sistemlerin her bir parçasında güç ve enerji alışverişleri gerçekleştirildiğinden, her bir parçanın ve bütün sistemin ilave devre eklemeleri planlama üzerinde etkili olacaktır.

Alt iletim sistemi planlaması ise; indirici merkezlerini dağıtım trafolarına (veya baralarına) bağlayan, gerilimi 154kV ana iletim sistemine oranla daha düşük gerilim kademesinde olan iletim elemanlarının ve dağıtım trafolarının yüksek gerilim tarafındaki planlamalar olarak düşünülebilir.

4.1.4. Dağıtım sistem planlaması

Hızla artan nüfusun doğal sonucu olan yüksek yük ve artan elektrik tüketimi, bağlaşıklık (interkonnekte) sistemden dağıtım trafoları aracılığıyla alınan elektrik enerjisinin, mümkün olduğu kadar düşük maliyette, sürdürülebilir ve yeterli güç kalitesinde abonelere ulaştırılması dağıtım sistem planlaması ile sağlanır.

Elektrik dağıtım sistem planlamasında indirici trafo merkezlerinin lokasyonları, kurulu güçleri, teknik karakteristikleri, gerilim kademeleri, besleme sahalarının büyüklükleri, yoğunlukları ve özellikleri dikkate alınır. Bununla birlikte etkin, güvenilir ve düşük maliyetli sistem planlamalarını sağlayabilmek için, ayrıntılı bir alt iletim sistem planlamaları ve iletim sistemi planlamalarının öngördüğü düzenlemeler göz önünde bulundurulmalıdır [Yoldaş,2006].

Dağıtım sistem özelliklerini, mevcut dağıtım sistemine bağlı tüketicilerin enerji talep miktarı, talep türü, yük faktörü ve diğer teknik kapasiteleri şekillendirir. Elektrik dağıtımda tüketicilerin mevcut yük karakteristiği saptandıktan sonra, dağıtım şebekelerine bağlı alt dağıtım sistemleri kendi aralarında gruplandırılır. Bu şekilde yapılan gruplamalar sonucunda ana dağıtım şebekeleri diğer bir deyişle dağıtım trafoları üzerindeki yükler, talep miktarını belirlemek için bir araya getirilir. Ana dağıtım şebekeleri üzerindeki toplam yük talebi bir üst indirici merkezlerine aktarılır. Dağıtım şebekeleri üzerindeki yükler, indirici trafo merkezlerinin yerleşimini ve teknik karakteristiğinin belirlenmesini de sağlayacaktır. İletim sistemi planlamasında olduğu gibi dağıtım sistemi planlamalarında da bilgisayar yazılımından faydalanılmaktadır. Bu tür bilgisayar yazılımları ile mevcut dağıtım ağlarındaki güç akışı, gerilim düşümü, kısa devre, gerilim regülasyonu ve yük tahminlerinin gerçeğe yakın simülasyonuna imkân tanınmaktadır.

4.1.5. Çevresel planlama

Elektrik enerji tesislerinin planlamalarında konumlandırma, boyutlandırmalarının ve geçerli yakıt imkânlarının değerlendirilmesinde çevre ile ilgili mevzuat hükümlerine

uygun hareket etmek bir zorunluluktur. Çevresel planlamalar, enerji tesislerinde genişletme planları yapılırken alternatif seçeneklere veya farklı sınıflandırmalara da olanak vermektedir.

4.1.6. Finansal planlama

Finansal analiz ve modeller, yıllık, aylık veya belirli bir dönemi kapsayan raporların hazırlanmasında kullanılır. Üretim, iletim ve dağıtım enerji tesislerinde, sistem genişletmesine ilişkin yatırımlarda parasal giriş ve çıkışları, vergi, harç, sigorta gibi hukuki kısıtlamaları de içerecek şekilde finansal planlamalar yapılmaktadır. Finansal bir planlama şirketlerin veya kurumların bütçe olanakları içinde, yatırım harcamaları üzerinde sınırlamalar getirmektedir.

4.1.7. Yakıt destek ve yöneylem planlamaları

Yakıt destek ve yöneylem planlamalarının temel hedefi şebeke işletmesine en uygun sistem modelini belirlemek için ilgili dataları, üretim sistem planlamasının geliştirilmesine yönelik olarak kullanılmaktadır. Yakıt destek planlamasında, farklı yakıt tiplerinin geçerlilikleri ve maliyet fiyatları tahmin edilir, uzun dönemli yakıt tedarikine ilişkin olarak yapılan girişimler, bunların sonuçları toplu olarak değerlendirilir. Yöneylem planlamasında ise, alternatif olabilecek enerji kaynakları, enerji güç santrallerinin kapasitelerine ilişkin sınırlandırmalar, mevcut enerji santrallerinin sistem bakımları gibi etkenler göz önüne alınmalıdır [Yoldaş,2006].

4.1.8. Ar-Ge planlamaları

Tüzel veya gerçek kişiliklerin bilimsel ve teknolojik bilgiyi ürüne, sürece, yöntem, uygulamaya ya da sisteme dönüştürme safhalarında üreteceği teknolojik geliştirme, her türlü yenilik amaçlı geliştirme ve revizyon (yenileme) projelerinin değerlendirilmesine dönük süreçler araştırma-geliştirme planlaması kapsamında değerlendirilebilir.

5. ELEKTRİK TÜKETİM TAHMİNİ VE TAHMİN YÖNTEMLERİ

5.1. Tahmini Etkileyen Faktörler ve Tahmin Yöntemleri

Elektrik enerji sistem planlamalarının ilk safhası, gelecekteki net elektrik tüketim tahminidir. Net elektrik tüketim tahmini geçmiş ve mevcut koşulların incelenmesi, değişim analizlerinin yapılması ve sonucunda gelecekteki durumun öngörüsüne dayanır. Bu öngörünün yapılması üretim sistemi planlaması için oldukça önemlidir. Üretim santrallerine yapılması gerekecek ilave veya yeni üretim santrallerinin tesis edilmesi yapılacak olan tahmine göre belirlenmektedir.

Genel itibari ile tahmin yöntemleri, sübjektif, tek değişkenli, çok değişkenli, son kullanıcı ve birleştirme yöntemi olmak üzere beş ana grupta incelenebilir. Sübjektif tahmini yaklaşımlar; karar, önsezi, deneyim ve benzer bilgileri kullanarak, tahmini yapan kişinin geçmiş bilgileri göz önüne alarak yapacağı tahminlerdir. Tek değişkenli tahminsel yaklaşımlar; zaman serisi analizi biçiminde verilerin geçmişteki değerlerine bağlı olarak elde edilen tahminlerdir. Çok değişkenli tahminler sebepsel ilişkileri ortaya koymaya uğraşmaktadır. Son kullanıcı metodu ise öngörü yapılırken veriler temel bileşenlerine ayrılarak projeksiyonlar ortaya çıkarılır. Birleştirme yaklaşımı ise değişik tahminleri bütünleştirerek, daha iyi tahminler elde etmeyi hedeflemektedir [Yoldaş,2006].

Tüketim ve yük tahmini için son yıllarda birçok farklı yöntem geliştirilmiştir. Zaman serisi analizi, regresyon analizi gibi geleneksel yöntemlere ilave olarak bilgisayar yazılımlarının geliştirilmesiyle yapay zekâ, bulanık mantık gibi yöntemlerde tahmin çalışmalarında kullanılmaya başlanmıştır.

Tüketim veya yük tahmin yöntemleri genel olarak istatistiksel yöntemler ve öğrenmeye dayalı yöntemler olarak ayrılmaktadır. İstatistiksel yöntemler içerisinde zaman serisi analizi, ekonomik göstergeler ile yapılan tahmin, yüzeysel verilerle yapılan tahmin ortalama artış yüzdelerinden elde edilen tahmin ve regresyon analizi yöntemleri gösterilebilir. Öğrenmeye dayalı tahmin yöntemleri ise; yapay sinir

ağları(YSA), bulanık mantık algoritmaları, sinirsel-bulanık veya bulanık-sinirsel algoritmaları kullanan yöntemler olarak ifade edilebilir. Ancak yukarıda bahsedilen istatistiksel yöntemler ve öğrenmeye dayalı yöntemler dışında, hem istatistiksel hem de öğrenme tabanlı çalışan, ilaveten makine öğrenmesinden çeşitli teknikleri kombine eden, bilimsel literatürde yeni popülerlik kazanmaya başlayan destek vektör makineleridir.

Zaman kavramı bakımından ise tahmin yöntemlerini üç bölüm altında değerlendirebiliriz; bunlar kısa dönemli tüketim tahminleri (saatlik,haftalık), orta dönemli tüketim tahminleri (aylık, on iki aylık) ve uzun dönemli (bir yıldan fazla) tüketim tahminleridir.

Kısa dönemli tahminler için tüketim zaman dilimi, elektriksel veri ve tüketici sınıfları gibi etkenler göz önünde bulundurulurken, orta ve uzun dönem tahminlerde ise geçmiş tüketim verileri, elektriksel veriler, farklı tüketici (abone) sayıları, uygulama sahası, ekonomik etkenler daha önem kazanır.

Elektrik tüketimini etkileyebilecek birçok faktör vardır. Geçmişteki veriler, endüstriyel planlar, gayri safi yurt içi hâsıla (GSYİH), nüfus ve demografik göstergeler, toplam tüketici sayısı, ortalama hane halkı büyüklüğü, elektrikli hane sayısı, köy oranı, çok odalı konut yüzdesi, brüt elektrik üretimi, kurulu güç şehirleşme oranı, istihdam verileri ve elektrik fiyatı bu faktörlerden bazılarıdır. Bu etkenlerden bazıları elde edilecek tahminler üzerinde doğrudan ve büyük oranda etkiye sahipken, bazıları ise dolaylı şekilde ve daha zayıf etki göstermektedir. Talebi etkilediği saptanan faktörler, etki derecelerine bağlı olarak elektrik tüketim tahmin modellerinde bağımsız değişken olarak kullanılmaktadır.

Bunun yanında yukarıda bahsi edilen etkenlerin birbirleri ile etkileşimi olanlar da bulunabilir. Bu türlü etkileşimler yapılacak tahminler için daha kompleks matematiksel denklemlerin ortaya çıkmasına veya hatalı tahmin algoritmalarının kurulmasına sebep olmaktadır. Misal olarak sanayinin gelişmesi ile ortaya çıkan nüfus yoğunluğu ve buna bağlı olarak artış göstermesi beklenen sosyal yaşam

farklılıkları yapılacak tüketim tahmini üzerinde etkili olacaktır. Veya GSYİH ile elektrik tüketiminden hangisinin birbirini daha çok etkilediği her zaman tartışma konusu olmuştur.

Gelişmiş elektrik tüketim tahmin modellerinde, tüketimi etkileyen faktörler göz önüne alınarak, sektör bazında net elektrik talepleri tahmin edilerek, bunların toplamına kayıp ve kaçak öngörülürleri eklenmek suretiyle brüt tüketim hesaplanmaktadır.

Geleceğe yönelik yük veya tüketim taleplerinin belirlenmesinde, kullanılacak tahmin modelinin seçimi oldukça önemlidir. Talepdeki değişimlerin yapısına bağlı olarak bir yöntem diğerine göre üstünlük sağlayabilir. Verimize özel bir metodu seçmeden önce, talebin davranışını incelemek oldukça önemlidir. Talebin davranışından uygun bir eğrinin mi, yoksa stokastik bir modelin mi seçilmesinin uygun olduğu kolaylıkla saptanabilir. Elektrik dağıtım sistemleri birbirinden çok farklı karakteristikler sergilediğinden, mevcut şebekenin yapısı da incelenmelidir. İncelenen sisteme göre en uygun tahmin modelini seçmek için farklı yöntemlerin avantaj ve dezavantajlarının da bilinmesi önem arz etmektedir [Oğurlu, 2011].

Son yıllarda bilimsel literatürde elektrik tüketim tahmini için birçok yöntem geliştirilmiş ve değişik algoritmalar kullanılmıştır. İstatistiksel yöntemlerden zaman serisi analizi, regresyon analizi, eğri uydurma yöntemi, ortalama artış yüzdesi vb.. pek çok farklı yöntem kullanılırken, öğrenmeye dayalı metotlardan bilgisayar yazılımları ile yapay sinir ağları ve bulanık mantık gibi yöntemler enerji tüketim tahminlerinde kullanılmaya başlanmıştır. Çalışmamızda tahmin yöntemlerinden regresyon analizi, yapay sinir ağları ve istatistiksel öğrenme tabanlı çalışan destek vektör makineleri kullanılmaktadır.

5.2. Regresyon Analizi

Bilimsel araştırmalarda karşılaştığımız sorunların çoğunluğu iki veya daha fazla değişken arasında bir ilişki bulunup bulunmadığının saptanması ile ilgilidir.

Değişkenler arasında bir ilişki bulunup bulunmadığı, eğer varsa bu ilişkinin derecesinin saptanması, istatistiksel çözümlemelerde sık karşılaşılan bir problemidir. Regresyon, değişkenler arasındaki ilişkinin irdelenmesinde en çok uygulanan tekniklerden birisidir. İstatistik biliminde iki değişken arasındaki ilişki, değerlerinin karşılıklı değişimleri arasında bir bağıllık şeklinde ifade edilmektedir.

X değişkeninin değerleri değişirken buna bağlı olarak Y değişkeninin değerleri de değişiyorsa, bu iki değişken arasında pozitif doğrusal veya negatif doğrusal bir ilişki olduğu söylenebilir. Regresyon analizinde; değişkenler bağımlı değişken ve bağımsız değişkenler olarak isimlendirilmektedir. Bağımsız değişkenlerin, bağımlı değişkenler üzerindeki etki biçimi ve yönü, istatistik denklemler ile ifade edilmektedir. Genel regresyon denklemleri bize bağımlı ve bağımsız değişkenler arasındaki gerçek ilişkiden ziyade, noktaların dağılımına göre teorik ortalama bir ilişkiyi vermektedir. Bu nedenle bir x gerçek değerine karşılık tahmin edilen $f(x)$ fonksiyon değeri regresyon doğrusunun üstünde bir nokta olacaktır. Ancak uygulamada gerçekleşen değerler, regresyon doğrusunun yakın noktalarına serpilmiş olacaklarından tahmin değerlerinde hatalar meydana gelecektir. Hata payının küçük olması, bağımlı ve bağımsız değişkenler arasındaki ilişkinin kuvvetlilik derecesi ile orantılı olacaktır. Değişkenler arasındaki ilişkinin çok kuvvetli olması, regresyon analizi ile elde edilen tahminlerdeki hataların düşük olmasına neden olmaktadır. Bağımlı ve bağımsız değişkenler arasındaki ilişkinin bağıllığı, önemi ve ilişkinin derecesi korelasyon tekniği ile incelenmektedir.

İki veya daha çok değişken arasında ilişki olup olmadığı, ilişki var ise ilişkinin yön ve gücü korelasyon yöntemi ile bulunur. Korelasyon, özellikle regresyon denklemlerinde yer alan, bağımsız değişkenlerin seçimi açısından son derece önem arz etmektedir. İki değişken arasındaki ilişkinin gücünü gösteren ölçü korelasyon katsayısı ile ifade edilmektedir.

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (5.1)$$

Eş 5.1’de görüldüğü gibi genellikle “r” sembolü ile gösterilen korelasyon katsayısı x ve y gibi iki değişken arasında doğrusal ilişkinin gücünü ölçer. Korelasyon katsayısı $-1 \leq r \leq 1$ aralığında değerler alabilir. İki değişken arasında mükemmel bir pozitif doğrusal ilişki olması durumunda $r=1$ olurken, negatif doğrusal bir ilişkide $r=-1$ olarak ölçülür. $r=0$ durumunda ise iki değişken arasında doğrusal bir ilişkiden söz edilemez.

Regresyon analizi, bağımsız değişken sayısına göre; basit regresyon ve çoklu regresyon analizi ve yine fonksiyon tipine göre; doğrusal ve doğrusal olmayan (eğrisel) regresyon gibi farklı problem tiplerine göre, farklı analizler içerebilmektedir.


5.2.1. Basit doğrusal regresyon analizi

Basit regresyon analizi, Y bağımlı değişkeninin tek bir bağımsız değişken X ile ifade edilmesine dayanmaktadır. Bu model genellikle aşağıdaki gibi ifade edilebilir.

X ve Y ana kütle verilerini göstermek üzere, X ile Y arasında ilişkinin

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad (i=1,2,3,\dots) \quad (5.2)$$

gibi lineer bir ilişki olduğu tahmin ediliyor ise; ilk olarak modelin bilinmeyen α ve β parametrelerinin tahmin edilmesi gerekmektedir. Bu modelin α ve β parametrelerini bulmak için ise X bağımsız değişkeni, Y bağımlı değişkeni ve ε hata terimi ile ilgili gözlemlere ihtiyaç duyulmaktadır. Modelin bilinmeyen parametreleri tahmin edilerek bağımsız değişkenlerin farklı değerler alması ile birlikte bağımlı değişkenin alacağı değeri tahmin etmek regresyonun ana hedeflerinden birisidir. Burada α doğrusal fonksiyonun sabitidir. $X=0$ olduğunda regresyon doğrusunun dikey eksen olan Y ile kesiştiği noktayı göstermektedir. β doğrusal fonksiyonun eğimidir. Aynı zamanda regresyon katsayısı olarak isimlendirilmektedir.



Şekil 5.1. Basit doğrusal regresyon doğrusu

Şekil 5.1.'deki çeşitli X değerleri karşısındaki Y değerlerinin dağılımını gösteren serpilme diyagramındaki gözlem noktaları arasından, çok sayıda doğrusal fonksiyon geçebilir ancak bu fonksiyonlardan en uygun olan Y gözlem değerine en yakın teorik tahmini Y' değerini veren doğrusal fonksiyon olmalıdır. Diğer bir ifade ile;

$$e = Y - Y' = Y_i - \hat{\alpha} - \hat{\beta}x \text{ (minimum)} \quad (5.3)$$

minimum olan fonksiyon seçilmelidir. Bu durumun tüm gözlem değerlerine uygulanması gerektiğinden,

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X)^2 \quad (5.4)$$

fonksiyonunun da minimum yapılması gerekmektedir. Bu yöntem “En Küçük Kareler Yöntemi (EKK)” olarak bilinmektedir. Bu fonksiyonun minimum olabilmesi için $\hat{\alpha}$ ve $\hat{\beta}$ parametrelerine göre kısmi türevlerinin alınması ve bunların 0'a eşitlenmesi gerekir. Denklemlerin çözülmesi ile;

$$\sum Y_i = n\hat{\alpha} + \hat{\beta} \sum X_i \quad (5.5)$$

$$\sum X_i Y_i = \hat{\alpha} \sum X_i + \hat{\beta} \sum X_i^2 \quad (5.6)$$

elde edilir. Bu denklemlerin gözlem değerleri kullanılarak $\hat{\alpha}$ ve $\hat{\beta}$ için birlikte çözülmesi ile;

$$\bar{X} = \frac{\sum X_i}{n} \quad (5.7)$$

$$\bar{Y} = \frac{\sum Y_i}{n} \quad (5.8)$$

$$\alpha = \bar{Y} - b\bar{X} \quad (5.9)$$

$$b = \frac{\sum X_i Y_i - \bar{Y} \sum X_i}{\sum X_i^2 - \bar{X} \sum X_i} \quad (5.10)$$

olarak elde edilir. Yordamada (tahminde) kullanılan normal eşitlikte bilinmeyen saptandıktan sonra, artık X yerine değişik değerler koyarak, bunların karşılığı olarak yordanacak Y değerleri kolayca bulunabilir [Arıcı, 2006].

5.2.2. Çoklu doğrusal regresyon analizi

Eğer Y bağımlı değişkeni, çok sayıda bağımsız X değişkeni ile ifade ediliyor ise bu analize “Çoklu Regresyon Analizi (Multiple Regression Analysis) adı verilmektedir. Çoklu regresyon analizinde lineer bir ilişki;

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \epsilon_i \quad (5.11)$$

şeklinde verilebilir. Çoklu regresyon analizinde n adet β kısmi regresyon katsayısı içermektedir. Bu katsayıların her biri ilgili bağımsız değişkenlerde meydana gelebilecek bir değişkenliğin bağımlı değişken üzerindeki etkisini ölçmektedir.

Çoklu regresyon modelinde katsayıların çözümü normal olarak bilgisayar programı kullanılarak yapılmaktadır. Bununla birlikte, metodun temelini anlaşılmaması önemlidir [Makridakis, 1998]. Örneğin iki bağımsız değişkenli doğrusal bir regresyon denklemi;

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \quad (5.12)$$

olarak ifade edilebilir. Bu fonksiyon üç boyutlu uzayda bir düzlem ifade eder. β_0 , β_1 ve β_2 kısmi regresyon katsayıları, basit regresyon analizinde Eş.5.2'de olduğu gibi hatayı minimize etme ilkesi, diğer bir ifade ile en küçük kareler yöntemi kullanarak bulunabilir.

$$\sum y_i = n\hat{\beta}_0 + \hat{\beta}_1 \sum x_{1i} + \hat{\beta}_2 \sum x_{2i} \quad (5.13)$$

$$\sum y_i x_{1i} = \hat{\beta}_0 \sum x_{1i} + \hat{\beta}_1 \sum x_{1i}^2 + \hat{\beta}_2 \sum x_{1i} x_{2i} \quad (5.14)$$

$$\sum y_i x_{2i} = \hat{\beta}_0 \sum x_{2i} + \hat{\beta}_1 \sum x_{1i} x_{2i} + \hat{\beta}_2 \sum x_{2i}^2 \quad (5.15)$$

burada x_i ve y_i değerleri yerine, her x_i ve y_i değerinin aritmetik ortalamasından farkları $x'_i = x_i - \bar{x}$ ve $y'_i = y_i - \bar{y}$ denklemlerde yerine konulursa ve denklemlerdeki terimlerin, aritmetik ortalamadan farklarının cebirsel toplamının sıfır olduğu varsayımı altında aşağıdaki çözümler yapılarak bilinmeyen katsayılar ait denklemler elde edilebilir.

Veya gözlem sonuçlarına göre matrislerden yararlanılarak da $\hat{\beta}_0$, $\hat{\beta}_1$ ve $\hat{\beta}_2$ değerlerine ulaşmak mümkündür:

$$|\Delta| = \begin{vmatrix} n & \sum x_{1i} & \sum x_{2i} \\ \sum x_{1i} & \sum x_{1i}^2 & \sum x_{1i} x_{2i} \\ \sum x_{2i} & \sum x_{1i} x_{2i} & \sum x_{2i}^2 \end{vmatrix} \quad (5.16)$$

$$|\Delta_0| = \begin{vmatrix} \sum y_i & \sum x_{1i} & \sum x_{2i} \\ \sum x_{1i} y_i & \sum x_{1i}^2 & \sum x_{2i} x_{1i} \\ \sum x_{2i} y_i & \sum x_{1i} x_{2i} & \sum x_{2i}^2 \end{vmatrix} \quad (5.17)$$

$$|\Delta_1| = \begin{vmatrix} n & \sum y_i & \sum x_{2i} \\ \sum x_{1i} & \sum x_{1i} y_i & \sum x_{1i} x_{2i} \\ \sum x_{2i} & \sum x_{2i} y_i & \sum x_{2i}^2 \end{vmatrix} \quad (5.18)$$

$$|\Delta_2| = \begin{vmatrix} n & \sum x_{1i} & \sum y_i \\ \sum x_{1i} & \sum x_{1i}^2 & \sum x_{1i} y_i \\ \sum x_{2i} & \sum x_{1i} x_{2i} & \sum x_{2i} y_i \end{vmatrix} \quad (5.19)$$

$$\hat{\beta}_0 = \frac{|\Delta_0|}{|\Delta|} \quad \hat{\beta}_1 = \frac{|\Delta_1|}{|\Delta|} \quad \hat{\beta}_2 = \frac{|\Delta_2|}{|\Delta|} \quad (5.20)$$

5.2.3. Polinom(eğrisel) regresyon analizi

X bağımsız değişken ile Y bağımlı değişkeni arasındaki ilişki polinomal diğer bir deyişle eğrisel form;

$$Y_i = \beta_0 + \beta_1 X^1 + \beta_2 X^2 + \dots + \beta_n X^n \quad (5.21)$$

şeklinde olabilir. Eğrisel regresyon denkleminde $\beta_0, \beta_1, \dots, \beta_n$ katsayıları örnekleme yoluyla saptanan X ve Y ölçü değerlerinde ve en küçük kareler yöntemi ile hesaplanır. Değişken olan $\beta_0, \beta_1, \dots, \beta_n$ regresyon katsayıları, fonksiyonun tahmin değerleri ile gerçek değerleri arasındaki farkların kareleri toplamı en küçük(minimum) olacak şekilde seçilmelidir. Örneğin üç katsayılı bir regresyon denkleminde katsayıların bulunması için minimum amaç fonksiyonunun, katsayılar cinsinden kısmi türevleri sıfıra eşitlenerek çözüme devam edilmelidir.

$$\min = \sum (Y' - Y)^2 = \sum (\beta_0 + \beta_1 X + \beta_2 X^2 - Y)^2 \quad (5.22)$$

$$\frac{\partial \Sigma}{\partial \beta_0} = 2 \sum (\beta_0 + \beta_1 X + \beta_2 X^2 - Y).1 = 0 \quad (5.23)$$

$$\frac{\partial \Sigma}{\partial \beta_1} = 2 \sum (\beta_0 + \beta_1 X + \beta_2 X^2 - Y).X = 0 \quad (5.24)$$

$$\frac{\partial \Sigma}{\partial \beta_2} = 2 \sum (\beta_0 + \beta_1 X + \beta_2 X^2 - Y).X^2 = 0 \quad (5.25)$$

Eşitliklerin çözülmesi ile yeni denklem takımları elde edilir.

$$n\beta_0 + \beta_1 \sum X + \beta_2 \sum X^2 = \sum Y \quad (5.26)$$

$$\beta_0 \sum X + \beta_1 \sum X^2 + \beta_2 \sum X^3 = \sum XY \quad (5.27)$$

$$\beta_0 \sum X^2 + \beta_1 \sum X^3 + \beta_2 \sum X^4 = \sum X^2 Y \quad (5.28)$$


Elde edilen denklem takımları hiperbolik ya da üstel olması nedeniyle denklemlerin çözümünde güçlükler olabilir bu durumlarda ters sayı veya logaritmik dönüşümler yapılarak model doğrusal çoklu regresyon modeline dönüştürülerek çözümler elde edilir.

5.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi hafızasına sahip proses elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Yapay sinir ağları, bir başka ifade ile insanın biyolojik sinir sistemini taklit eden bilgisayar programlarıdır. Yapay sinir ağları zaman zaman paralel dağıtılmış ağlar (parallel distributed networks), bağlantılı ağlar (connectionist networks), nuromorfik sistemler

(neuromorphic systems), sinirsel işlem, doğal zeka sistemleri ve makine öğrenme algoritmaları gibi, isimlerle de anılmaktadır.

Yapay sinir ağları günümüzde birçok probleme çözüm üretebilecek yeteneğe sahiptir. Değişik biçimlerde tanımlanmaktadır. YSA için temel tanımların ortak birkaç noktası vardır. Bunların en temeli yapay sinir ağlarının birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden meydana gelmesidir. Proses (işlem) elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin(öneminin) olduğu kabul edilir. Bilginin öğrenme yolu ile elde edildiği ve işlem elemanlarının bağlantı değerlerinde (ağırlık) saklandığı dolayısıyla dağıtık bir hafızanın söz konusu olduğu da ortak noktalarıdır. Proses elemanlarının birbirleri ile bağlanmaları sonucu oluşan ağa *yapay sinir ağı* olarak bilinir. Şekil 5.2’de örnek bir yapay sinir ağı yapısı görülmektedir. Bu ağın oluşturulması biyolojik sinir sistemine ilişkin bulgulara dayanmaktadır [Öztemel, 2006].



Şekil 5.2. Yapay sinir ağı örneği

Teknik olarak da, bir yapay sinir ağının esas işlevi, kendisine gösterilen bir girdi setine karşılık, bir çıktı seti belirlemektir. Ağın bunu yapabilmesi için, ilgili olayın örnekleri ile eğitilerek (öğrenme) genelleme yapabilecek özelliğe(yeteneğe) ulaşması gerekir. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir [Öztemel, 2006]. YSA üzerindeki ilk çalışmanın 1943 yılında başladığı kabul edilir.

McCullogh ve Pitts ilk olarak yapay sinir tanımını yaparak hücre modelini geliştirdiler. Yapılan bu çalışmada sinir hücreleri sabit eşik değerli mantıksal elemanlar olarak modellenmiştir. Yapısında ± 1 sabit bağlantı ağırlıklarına sahip olan bu model aritmetik mantık hesaplama elemanları olarak da adlandırılmıştır. Öğrenme üzerine çalışmaların yoğunlaştığı 1949'lu yıllarda, bilim adamları insan öğrenme sürecini modellemeye uğraşmaları ile artmıştır. Hebb, YSA'daki öğrenme için başlangıç noktası sayılabilecek bir kuralı geliştirmiştir. Ortaya atılan bu öğrenme kuralı, o dönemde bir sinir ağının öğrenme işini nasıl gerçekleştirebileceği konusunda fikir vermekle birlikte, günümüzde halen geçerli olan öğrenme kurallarından birçoğunun da temelini teşkil etmiştir. Çalışmaların hızlandığı 1960'lı yılların başında yeni bir yaklaşım olarak Widrow ve Hoff tarafından ADALINE (Adaptive Linear Combiner) geliştirildi. Bununla birlikte yeni ve güçlü bir öğrenme kuralı olarak Widrow-Hoff öğrenme kuralı ortaya atıldı. Bu kuralın en önemli özelliği eğitim boyunca toplam hatayı en aza indirmeyi hedeflemesidir. YSA'daki ilk yöntemlerin, karmaşık hesaplama problemlerini çözemeyecek kadar zayıf olması bu konudaki çalışmaların ilerlemesini engelledi. 1969 yılında matematikçi Minsky ve Papert tarafından algılayıcı karşıtı olan yayınlar YSA'ya ve özellikle TDA'ya (perceptron) karşı olan ilgiyi iyice azalttı. 1980'li yıllar başında yapılan çalışmalarla YSA yeniden yaygın hale geldi. İlk kıpırdanmalar Hopfield tarafından eğrisel ağların geliştirilmesi ile başladı. O çalışmalarını özellikle çağrışımlı YSA ağları mimarisi üzerine yoğunlaştırdı. Bununla birlikte Kohonen ve Anderson tarafından yapılan çalışmalar sonucunda eğiticişiz öğrenen ağların geliştirilmesiyle çalışmalar yeniden ivme kazanmıştır. Böylece bu yıllar YSA'ya olan ilginin yeniden canlandığı ve çalışmaların yoğunlaştırıldığı yıllar olmuştur. 1986 yılında Rumelhart ve arkadaşları tarafından çok tabakalı algılayıcı tipi ağlar için *geriye yayılma* olarak adlandırılan bir eğitime algoritması geliştirildi. Bu algoritma güçlü olmakla birlikte oldukça karmaşık matematik esaslara dayanmaktaydı. Ayrıca bu algoritmanın etkin bir öğrenmeyi mümkün kılma yeteneği dikkatleri tamamen üzerine çekmiştir. En çok kullanılan öğrenme algoritmalarından biri olan bu algoritmanın ortaya atılması YSA alanında bir çığır açmıştır. Günümüzde YSA üzerinde yapılan çalışmalar her geçen gün değişik öğrenme algoritmaları ve ağ mimarileri ile büyük bir hızla aynen devam etmektedir [Öztemel, 2006; Sağıroğlu 2003].

5.3.1. Yapay sinir ağlarının genel özellikleri


Yapay sinir ağlarının esas görevi yazılımlar ile bilgisayarların öğrenmesini sağlamaktır. Geçmiş olayları öğrenerek, benzer olaylar ile karşılaşıldığında benzer kararlar almaya çalışırlar. Yapay sinir ağlarının geleneksel programlama ve yapay zeka yöntemlerinin uygulandığı veri işleme metotlarından tamamen farklı bir bilgi işleme metodu vardır. Yapay sinir ağlarında bilgi ağın bağlantılarının ağırlık değerleri ile ölçülmekte ve ağ bağlantılarında gizlenmektedir. Diğer programlarda olduğu gibi bilgiler bir veri tabanında veya programın içerisinde saklı değildir. Veriler ağın üzerinde saklıdır ve çıkartılması, yorumlanması oldukça güçtür [Öztemel, 2006].

Yapay sinir ağlarının olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar. Bu yetenek adaptif öğrenme yeteneği olarak bilinmektedir. Olayla ilgili örnek yok ise YSA'nın eğitilmesi mümkün değildir. Yapay sinir ağına, olaylar bütün yönleri ile gösterilemez ve eldeki örnekler bütünüyle sunulmaz ise başarılı sonuçlar elde edilemez. Bir yapay sinir ağına örnekler sadece nümerik olarak gösterilebilir. Zira bir yapay sinir ağı, bulanık mantık tabanlı sistemlerde olduğu gibi sözel ifadeler ile işlem yapması olanaksızdır.

YSA'lar eğitimden sonra eksik bilgiler ile işlem yapabilmekte ve gelen yeni bilgilerle, modelde eksik bilgi olmasına rağmen doğru sonuçlar üretebilmektedir. Yapay sinir ağlarının bu tür eksik verilerle çalışabilme yetenekleri onların hatalara karşı toleranslı olmalarını sağlamaktadır. Ağ üzerindeki bazı işlem elemanlarının bozulması veya işlemez duruma gelmesi durumunda bile ağ çalışmasını yürütmektedir. Hangi proses (işlem) elemanının ağ üzerinde daha çok öneme sahip olacağına yine ağın eğitimi esnasında kendisi belirlemektedir [Öztemel, 2006]. YSA'nın en büyük dezavantajı ağ içerisinde ne olduğunun ve bilgilerin nasıl saklandığının bilinmemesidir. Diğer en büyük dezavantajları arasında; tasarlanan bir YSA yapısının, farklı sistemlere uyarlanması zor olması ve bazı ağlar hariç kararlılık analizlerinin yapılamamasıdır.

5.3.2. Bir yapay nöronun ana öğeleri

Yapay sinir ağları birbirine bağlı doğrusal veya doğrusal olmayan birçok yapay nöron hücresinden oluşmaktadır. Bir yapay sinir hücresi girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış elemanından oluşmaktadır. Şekil 5.3’de i adet girişi olan tek bir işlem (proses) elemanı gösterilmektedir. Bu şekilden de görüleceği gibi $x_1, x_2, \dots, x_i$ girişleri, $w_1, w_2, \dots, w_i$ ağırlıkları, v toplam fonksiyonu çıkışını ve y ise proses elemanı (veya aktivasyon fonksiyonu) çıkışını göstermektedir.



Şekil 5.3. Yapay nöron yapısı

Bir yapay nöronda giriş desenlerinin uzayı i -boyutlu olarak ifade edilebilir. Diğer bir ifade ile; giriş işaretleri i elemanlı sütun vektörü olarak düzenlenir. Ağırlıklar ise i elemanlı satır vektörü olarak ifade edilebilmektedir.

$$v = \sum_{i=1}^i w_i x_i = wx = WX^T = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \end{bmatrix} \cdot [w_1 w_2 \dots w_i] \quad (5.29)$$

Bir yapay nöron işlemcisinde Eş. 5.29’da elde edilen toplam fonksiyonu, çıkış işaretini üreten aktivasyon fonksiyonundan geçirilerek, çıkış fonksiyonu üretilir.


5.3.3. Aktivasyon fonksiyonları

Transfer fonksiyonu olarak da bilinen aktivasyon fonksiyonları öğrenme eğrisi olarak da adlandırılmaktadır. Aktivasyon fonksiyonları bir YSA'da nöronun çıkış büyüklüğünü (genliğini) istenilen değerler arasında sınırlamaktadır. Bu değerler çoğunlukla 0 ve 1 veya -1 ve 1 aralıklarında yer almaktadır. Ayrıca, yapay sinir ağına bir kutuplama(bias) değeri ekleyerek aktivasyon fonksiyonu artırılabilir. Kutuplama değeri, eşik değerinin negatif değerlisi olarakta ifade edilebilir [Sağıroğlu, 2003].

YSA'larda kullanılacak olan aktivasyon fonksiyonlarının türevi alınabilir ve süreklilik arz eden özellikte olması gerekmektedir. YSA'nın kullanım amacına göre tek veya çift yönlü aktivasyon fonksiyonları tercih edilebilir [Sağıroğlu, 2003]. Aktivasyon fonksiyonu özellik olarak, çıkış işaretini normalize eden bir fonksiyon olmalıdır. Aktivasyon fonksiyonu olarak uygulamalarda en çok *sigmoid* veya *tanjant hiperbolik* fonksiyonları tercih edilmektedir. Pratik uygulamalarda en çok kullanılan aktivasyon fonksiyonları aşağıda özetlenmektedir.

Eşik(basamak) fonksiyonu: Bu fonksiyon tek veya çift kutuplu fonksiyon olabilmektedir. Bu fonksiyonun matematiksel ifadesi Eş. 5.30'da verilmiştir. Çift kutuplu fonksiyonun genel davranışı ise Şekil 5.4'de gösterilmektedir.


$$y = f(v) = \begin{cases} +1 & v > 0 \\ -1 & v < 0 \end{cases} \quad (5.30)$$



Şekil 5.4. Çift kutuplu eşik(basamak) fonksiyon

Sigmoid fonksiyonu: Yapay sinir ağlarında en çok kullanılan aktivasyon fonksiyonu türüdür. Lineer ve lineer olmayan davranışlar arasında, denge vazifesi gören bir fonksiyon olarak tanımlanır.


$$y = \frac{1}{1 + e^{-v}} = \frac{1}{2} \left[\tanh\left(\frac{v}{2}\right) + 1 \right] \quad (5.31)$$



Şekil 5.5. Sigmoid fonksiyon

Tanjant hiperbolik: Sigmoid fonksiyonundan sonra uygulamalarda en çok kullanılan aktivasyon fonksiyonudur. Giriş uzayının genişletilmesinde etkili bir fonksiyondur. Tanjant hiperbolik fonksiyonu çift kutuplu bir fonksiyon yapısındadır.

$$y = \frac{1 - e^{-2v}}{1 + e^{2v}} = \tanh(\beta v) \quad (5.32)$$



Şekil 5.6. Tanjant hiperbolik fonksiyon

5.3.4. Yapay sinir ağlarının oluşturulması

Yapay sinir ağları düğüm veya sinir hücresi olarak adlandırılan çok sayıda işlem elemanının bütünleşmesinden oluşmaktadır. Hiyerarşik bir sinir ağı düğümlerin sıralı bir şekilde art arda bağlantısından oluşmaktadır. Bu tür ağların özelliği sahip oldukları basit dinamik yapılarıdır. Fakat giriş katmanına bir işaret girdiğinde bu işaret sinir elemanı arasındaki bağlantılar aracılığıyla diğer katmana gönderilir. Giriş katmanının düğümleri tarafından diğer katmana iletilmeden önce, bu işaret üzerinde basit bir işlem yerine getirilir. Bu süreç çıkış katmanına ulaşınca kadar tekrar eden bir süreç görünümündedir [Elmas, 2003].

YSA'da düğümler ve ara bağlantıları çok değişik biçimlerde bir araya getirilebilir. YSA'lar bu düğüm ve bağlantı mimarilerine göre değişik adlar alırlar. Yapay sinir ağ mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ yapısı içindeki işaretlerin akış yönlerine göre birbirlerinden farklılık göstermektedir. Buna göre yapay sinir ağları için, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki esas ağ mimarisi mevcuttur [Elmas, 2003].

Bir ağ içerisinde düğüm(proses) elemanları katmanlar halinde yerleştirilir. İlk katmandan girişe verilen veriler ağ içinde ileriye doğru yayılır. Her katmandaki düğümlere sadece önceki katmandaki düğümlerden girişlere izin verilmektedir. Bir düğüm kendinden sonraki herhangi bir düğüme bağlanabilirken kendisine asla bağlanmamaktadır. Son katmandaki elde edilen işaretler ağın çıkışını vermektedir. Geri beslemeli veya tekrarlanan ağlarda en azından bir düğümün geriye yayıldığı bir dönüş bağlantısı mevcuttur. Tekrarlanan ağlar tamamen veya kısmi olarak geri besleme yollarına sahiptirler. Bu tür ağların davranışları ve tasarımları oldukça karmaşık yapıdadır [Elmas, 2003].

Sinir ağlarında istenen sonucun elde edilmesi için ağın uyarlanabilir olması gerekir. Bunu sağlamak için uygun değerli ağırlıklar ve doğru bağlantılar seçilmelidir. Ağ bu şartları karşılayabilmek için sistemin davranışlarını öğrenmeli veya ya da kendi kendini örgütlemelidir. Öğrenme yapay sinir ağının ayrılmaz bir parçasıdır.

Öğrenme; giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağırlık bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı olarak gerçekleştirilir.

YSA'ların eğitilmesi için kullanılan öğrenme kuralları genellikle danışmanlı öğrenme (supervised learning), danışmanlı öğrenme (unsupervised learning) ve pekiştirerek öğrenme (reinforcement learning) olmak üzere üç öğrenme yöntemi başlığı altında toplanabilir [Elmas, 2003].

Danışmanlı öğrenme kuralları, arzu edilen ağ çıkışının elde edilebilmesi için, çıkış hatasının düşürülmesinde ağırlıkların uyarlanabilir hale getirilmesini gerektirir. Danışmanlı öğrenmede her giriş değeri için istenen çıkış sisteme tanıtılır ve yapay sinir ağına giriş-çıkış ilişkisini gerçekleştirene kadar aşama aşama ayarlar. Danışmanlı öğrenmeye çok katmanlı perceptron, geriye yayılım, delta kuralı, widrow-hoff veya en küçük karelerin ortalaması (least mean square) ve uyarlanabilir doğrusal eleman anlamına gelen ADALINE örnek olarak verilebilir.

Danışmansız öğrenmede bir danışman veya öğretmen, sinir ağına girişin hangi vergi parçası sınıfına ait olduğunu veya ağına nerede iyi sonuç vereceğini söylemez. Ağ veriyi üyeleri birbirinin benzeri olan öbeklere yol gösterilmeksizin ayırır. Danışmansız öğrenme danışmanlı öğrenmeye göre çok daha hızlıdır. Ayrıca matematik algoritmaları da daha basittir. Danışmansız öğrenmeye yarışmacı öğrenme (competitive learning), Kohonen'in özörgütlenmeli harita ağı (SOM), hebbian öğrenme, grossberg öğrenme gibi öğrenme kuralları örnek olarak verilebilir.

5.3.5. İleri beslemeli ağlar

Reel değerli n boyutlu girdi özel vektörleri şu şekilde ifade edilir; j gizli katman siniri, i girdisini $w_{ij}(i=1,2,...,n, j=1,2,...)$ ağırlığına göre alır. j birimi x girdi işaretinin ve w_{ij} ağırlıklarının bir işlevini hesaplayıp, sonucu sonraki tüm komşu sinirlere iletir. İlk gizli katman gibi ikinci gizli katman sinirleri de ağırlıklarla önceki katmana tam bağlıdır. Bu sinirler de girişlerin ve girişlerin ağırlıklarının bir işlevini hesaplayıp sonucu sonraki aşamaya aktarır. Bu işlem, çıkış katmanındaki sinirler

tarafından da yapıldıktan sonra tamamlanır. Bu ağlar, çok katmanlı ileri beslemeli ağlar olarak isimlendirilir [Elmas, 2003]. Widrow-Hoff ve en küçük ortalama kareler (least mean square) veya delta öğrenme kuralı, doğrusal etkinlik işlevleri için tanımlanmasının dışında, perceptron öğrenme algoritmasına benzer. Gerçekte türevi alınabilir etkinlik işlevi kullandığımız için, eğimli iniş öğrenme yönteminin gerçekleştirilebileceği bir türevi alınabilir hata işlevi tanımlanabilir.

$$\Delta w_{ij} = \eta \delta_j x_{ij} \quad (5.33)$$

Eş. 5.33’de tanımlanan bu kural, daima “hataların kareleri toplamını” en küçükleyecek ağırlık kümelerini belirlemeyi amaçlar. Bu metotlar gizli ağırlık katmanlarının nasıl ayarlanacağını ve saptanacağını belirlemede başarısız olmaktadır. Bu metotlar, çıkış katmanındaki hataların hangi gizli katmanda hangi ağırlıkta meydana gelebileceğini belirleyemediği için bu durum kredi atama problemi ile belirtilebilir. Oysa genelleştirilmiş delta kuralı (geri yayılım yöntemi), gizli katmanların nasıl ayarlanacağını tanımlamaktadır [Elmas, 2003].

5.3.6. Geri beslemeli ağlar

Geri beslemeli ağ mimarileri, genelde danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri beslemeli ağlar adında anlaşılabileceği üzere, bir tür geri besleme işlemine sahiptir. Örneğin Hopfield ağı bu tür mimariye sahip bir yapay sinir ağı türüdür. Ağın çalışması Eş. 5.34 ile ifade edilmektedir.

$$\frac{du}{dt} = -u_i + \sum_{i=1}^n w_{ij} y_i + x_i \quad (5.34)$$

Burada $y_j = g(u_j)$ ise;

$$g(x) = \frac{1}{2} \left(\tanh \left(\frac{x}{a_0} \right) + 1 \right) \quad (5.35)$$

olarak ifade edilmektedir. $a_0=0$ olması katı sınırlayıcı transfer işleve karşılık gelir. a_0 değeri yeterince küçük olduğunda, ağırlıkların simetrik yani tüm i ve j 'ler için $w_{ij}=w_{ji}$ olması durumunda hopfield ağı,

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i y_j - \sum_{i=1}^n y_i x_i \quad (5.36)$$

biçiminde bir sistem, enerji işlev fonksiyonunu en küçükleyecek şekilde davranır ve bu enerji işlevinin bir yerel minimuma karşılık gelen kararlı duruma erişmesi sağlanır [Elmas 2003].

5.3.7. Öğrenme, adaptif öğrenme ve test etme

Daha önce yapay sinir ağlarında işlem elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine “*ağın eğitilmesi*” olarak ifade edilmişti. Başlangıçta bu ağırlık değerleri rastgele olarak atanır. Yapay sinir ağları kendilerine örnekler gösterildikçe bu ağırlık değerlerini değiştirirler. Amaç ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Örnekler ağa defalarca gösterilerek en doğru ağırlık değerleri bulunmaya çalışılır. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine *ağın öğrenmesi* denir. Ağırlıkların değerlerinin değişmesi belirli kurallara göre yürütülmektedir. Bu kurallara “öğrenme kuralları” denir. Kullanılan öğrenme stratejisine göre değişik öğrenme kuralları geliştirilmiştir.

5.3.8. Yapay sinir ağlarının sınıflandırılması

YSA'lar, genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile nöronlar veya proses elemanlarından oluşurlar. Nöronlar arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği, öğrenme algoritması tarafından belirlenir. Kullanılan bir öğrenme kuralına göre, hatayı sıfıra indirecek şekilde, ağın ağırlıkları değiştirilir. Yapay sinir

ağları, yapılarına göre, ileri beslemeli (“feed-forward”) ve geri beslemeli (“feed-back”) ağlar olmak üzere iki farklı yapıda incelenmektedir.

İleri beslemeli bir ağda proses elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Süreç elemanlar bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak çok katmanlı perseptronlar (multi-layer perceptrons-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir. Bu ağlar statik ağlar olarak da bilinirler.

Geri beslemeli bir sinir ağı, çıkış ve ara katman çıkışlarının giriş katmanına veya önceki ara katmanlara geri besleme yapıldığı bir ağ biçimidir. Bu şekilde veriler hem ileri yönde, hem de geri yönde iletilmiş olur. Bu tür sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtabilmektedir. Bundan sebeple, bu ağlar özellikle ileriye dönük tahmin uygulamaları için uygundurlar. Bu ağlar farklı tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara Hopfield, Elman ve Jordan ağları örnek gösterilebilir [Öztemel, 2006].

5.3.9. Geri yayılım algoritması

En yaygın ve çok tercih edilen öğretim algoritmasıdır. Teorik olarak kolayca ispatlanabilir ve basit olmasından dolayı tercih edilen bir öğretim algoritması türüdür. Bu algoritmanın en temel esası hataları çıkıştan geriye doğru yayarak hatayı düşürmeye çalışmasıdır [Rumelhart ve ark., 1986].

Geri yayılım algoritması çok katmanlı yapay sinir ağlarını eğitmede çok tercih edilmektedir. YSA’nın eğitilmesi ve eğitimden sonraki süreçteki test işlemi bu algoritma yönüne göre yapılmaktadır. Burada i ve j kat proses elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği ile bulunmaktadır. Bu ifade Eşitlik 3.1’de verilmiştir.

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha w_{ji}(t-1) \quad (5.37)$$

Eş. 5.37’de α momentum katsayısını η öğrenme katsayısını, δ_j ara ve çıkış katındaki herhangi bir j çıkış nöronuna ait bir faktörü temsil etmektedir. Çıkış katı için bu faktör Eş. 5.38 ve Eş. 5.39’daki denklemlerle verilmektedir.

$$\delta_j = \frac{\partial f}{\partial net_j} = (y_j^{(t)} - y_j) \quad (5.38)$$

$$net_j = \sum x_j w_{ji} \quad (5.39)$$

burada $y_j^{(t)}$ ise proses elemanının amaç(hedef) çıkışıdır. Ara katmanlardaki yapay nöronlar için ise bu faktör Eş. 5.40’daki şekilde ifade edilmektedir [Sağıroğlu, 2003].

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum w_{qi} \delta_q \quad (5.40)$$

Ara katmanlarda bulunan yapay nöronlar için bir hedef çıkış var olmadığından, Eş. 5.39 yerine Eş. 5.40 kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki nöronlar için hesaplanmalıdır. Devamında Eş. 5.38'deki formüle bağlı olarak, bütün ara bağlantılar için ağırlıkların güncelleştirilmesi sağlanmaktadır. Bu aynı zamanda bir dereceli azalma algoritması olmakla birlikte, çok katmanlı yapıları eğitmede kullanılan bir algoritmadır. Burada amaç arzu edilen çıkış ile ağ çıkışı arasındaki hatanın ağırlıklara bağlı olarak azaltılması temeline dayanmaktadır. Hızlı ve kaliteli bir eğitim süreci için, β ve α değerlerinin seçimi önem arz etmektedir. Geri yayılım öğrenme süreci β ve α değerlerinden oldukça etkilenmektedir. Bu katsayıların seçilmesi deneysel olarak belirlense de bu değerler, uygulamalara ve problemlere göre farklılıklar göstermektedir. Öğrenme katsayısı için tipik değerler, 0.01 ile 0.9 arasında değişmektedir. Daha karmaşık ve zor çalışmalarda daha küçük değerlerin seçilmesi önerilmektedir [Sağıroğlu, 2003].

5.3.10. Levenberg-Marquardt metodu

Esas itibari ile bu algoritma, maksimum komşuluk düşüncesi temelinde kurulmuş bir en az kareler hesaplama yöntemidir. Bu algoritma, Gauss-Newton ve Steepest-Descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını ve dezavantajlarını ortadan kaldırmaktadır Genel itibari ile bu metod yavaş yakınsama probleminden etkilenmemektedir. $E(w)$ 'nin bir hedef hata fonksiyonu olduğu farz edilirse m adet hata terimi için $e_i^2(w)$ aşağıda verilmektedir

$$E(w) = \sum_{i=1}^m e_i^2(w) = \|f(w)\|^2 \quad (5.41)$$

$$e_i^2(w) = (y_i - yd_i)^2 \quad (5.42)$$

Burada, hedef fonksiyonu $f(w)$ ve onun jakobiyeni olan J 'nin yalnız bir noktada bilindiği düşünülür. Levenberg-Marquardt algoritmasında öncelikli hedef, parametre vektörü (w) 'nin, $E(w)$ minimum olduğu durumda bulunmasıdır. Levenberg-Marquardt algoritması ile yeni vektör w_{k+1} , tahmin edilen vektör w_k 'dan hesaplanmaktadır [Sağıroğlu, 2003].

$$w_{k+1} = w_k - \delta w_k \quad (5.43)$$

Eş. 5.43'deki δw_k ise; Eş. 5.44'deki gibi ifade edilmektedir.

$$(J_k^T J_k + \lambda I) \delta w_k = -J_k^T f(W_k) \quad (5.44)$$

Burada J_k f 'nin değerlendirilmiş jakobiyenini, λ Levenberg-Marquardt parametresini ve I birim matrisini göstermektedir. Levenberg-Marquardt algoritması sırası ile şu basamakları içermektedir:

1. basamakta: Öncelikle $E(w)$ 'yi δw_k hesapla.
2. basamakta: Minimum bir λ değeri ile başlat.
3. basamakta: δw_k için Eş.5.44'ü bul ve $E(w_k + \delta w_k)$ değerini hesapla
4. basamakta: $E(w_k + \delta w_k) \geq E(w_k)$ ise λ yı 10 kat arttır ve 3. basamağa geri döndür
5. basamakta: $E(w_k + \delta w_k) \leq E(w_k)$ ise λ yı 10 kat azalt $(w_k + \delta w_k)$ güncelleştir ve basamak 3'e geri döndür şeklindedir.

Hedef çıkışı hesaplamak için çok katmanlı bir yapay sinir ağının, Levenberg-Marquardt algoritmasının kullanılarak eğitilmesi, ağırlık dizisi w_0 için bir başlangıç değerinin atanması ile başlamakta ve hataların kareleri toplamı e_i^2 teriminin hesaplanmasıyla süreç devam etmektedir [Sağıroğlu, 2003].

Her e_i^2 terimi, amaç çıkış (y) ile reel çıkış (y_d) arasındaki farkın karesini temsil etmektedir. Bütün giriş seti için e_i^2 hata terimlerinin tümünün elde edilmesiyle, ağırlık dizileri Levenberg-Marquardt algoritması adımlarının uygulanmasıyla daha öncede ifade edildiği gibi uyumlu hale getirilir. [Sağıroğlu, 2003].

5.3.11. Yapay sinir ağları tasarım aşamaları

YSA uygulamalarının başarısı, uygulanacak olan yaklaşımlar ve deneyimlerle yakından ilgilidir. YSA sisteminin davranışını etkileyen çok sayıda yapısal parametre vardır. Bu parametrelerin her problem için en uygununu belirleyebilmek başlı başına bir problemdir ve seçimi çok önemlidir. En uygun parametreleri belirleyebilmek teorik olarak mümkün gibi görülse de pratik olarak pek mümkün değildir. Genellikle bu parametreleri önceden kestirmek de oldukça güçtür. Bu uygun parametrelerin elde edilmesi uzun ve zahmetli benzetimler sonunda mümkün olabilmektedir. Bunun için literatürdeki benzer çalışmalar gözden geçirilerek uygulanacak problem için belirlenmiş olan parametrelerle yapıyı tasarlamaya ve eğitmeye başlamak en akılcı yaklaşım olacaktır. Eğer YSA yeni bir probleme uygulanıyorsa, mevcut yazılımlardaki belirlenmiş parametre değerlerini kullanmak,

başlangıç için uygun bir yaklaşım olabilir. Yapay sinir ağlarının tasarımı dikkat edilmesi gereken en önemli faktörler aşağıda açıklanmaktadır.

Yapı seçimi: Uygun yapay sinir ağı mimarisi veya yapısı, mevcut probleme bağlı olarak seçilmelidir. Bunun için YSA bağlantı yapılarının hangi tür uygulama problemlerinde başarılı olacağının önceden bilinmesi fayda sağlamaktadır. YSA yapısı uygulamaya bağlı olarak seçilmelidir. Uygulanacak problemin giriş data yapısı, bu seçimi etkileyecek diğer önemli bir husustur. Problem bir sınıflandırma problemi ise problemin zorluğuna ve ayrıştırılacak sınıf sayısına göre çok katmanlı perceptron (MLP) ağlardan başlayarak, Lineer vektör nicelendirme (LVQ), RBFNN ve SOM gibi yapılar sırasıyla denenmelidir. MLP ve Radyal tabanlı ağlar (RBFNN) yapılarının literatürdeki çalışmalarda yüksek performans gösterdiklerini görülmüştür. Karmaşık ve zor uygulamalarda genellikle çok katmanlı ağ mimarisi ile başlamak doğru bir tercih olacaktır [Öztemel, 2006].

Bir YSA'nın karmaşıklığının azaltılmasında en etkili vasıta, ağın mimari yapısını değiştirmektir. Gerektiğinden çok sayıda proses elemanı içeren ağ yapılarında, daha düşük genelleme yeteneği ile karşılaşılacağı belirtilmektedir. Bunun yanında belli sayının üstünde proses elemanı kullanmak da YSA'nın performansını çoğu zaman yükseltmediği vurgulanmıştır [Yamaçlı, 2010].

Öğrenme algoritması seçimi: Bir yapay sinir ağının yapı seçiminden sonra uygulama etkinliğini belirleyen en önemli faktör öğrenme algoritmasıdır. YSA yapısı için en uygun optimal öğrenme algoritmasının seçimi ağ yapısının belirlenmesinden sonra çözülmesi gereken en önemli sorundur. Genellikle ağ yapısı öğrenme algoritmasının seçiminde belirleyici olmaktadır. Bu sebeple ağ yapısı üzerinde kullanılabilecek öğrenme algoritması, genellikle ağ mimarisine de bağlı olmaktadır. Bazen tasarımı öğrenme algoritmasının kurgulanması ağ yapısının tasarımı ile paralel veya daha önce gerçekleştirilebilir. Bu genellikle basit sınıflandırıcı ağ yapısı ya da basit öğrenme algoritmaları için geçerlidir. Öğrenme algoritmalarından herhangi birisi uygun olan YSA yapısı ile ağı eğitimi için kullanılabilir.

Yapay sinir ağlarının az sayıda giriş verisi ile öğrenebilmesi veya genelleme yapabilmesi YSA'ları birçok uygulamada uygulanması için tercih edilir yapmaktadır. Bunun sebebi ise, pratik olarak fazla sayıda veri elde etmenin maliyeti veya zorluğu oldukça yüksektir. YSA sistemlerinin öğrenme başarısı, kullanılabilirliğini belirleyen genelleme etkisi ile belirlenmektedir. Genelleme yeteneği, gerçekleştirilen testlerle kontrol edilmelidir. Genelleme testlerinde karşılaşılan aşırı-öğrenme (overfitting) eğilimi, yapay sinir ağlarının probleme ilişkin verileri, istenilen seviyede öğrenmiş olmasına rağmen, eğitimde karşılaşmadığı veri kümeleri için kabul edilebilir sistem çıkışları üretememesi olarak tanımlanır. Bu duruma, gürültü içeren uygulamalarda sıkça rastlandığı vurgulanmaktadır [Yamaçlı, 2010].

En uygun öğrenme seviyesi, öğrenme fonksiyonunun kontrolü için kullanılan performans fonksiyonunun önceden amaçlanan bir değere ulaşması ile sağlanamayabilir. Uygulamalarda, eğitim süreci boyunca performans fonksiyonunun izlenmesi ile birlikte sık sık genelleme testlerinin gerçekleştirilmesi yolu ile en uygun öğrenme seviyesi elde edilebilir. Eğer en uygun öğrenme seviyesine, performans fonksiyonunun öngörülerinden önce ulaşılmış ise eğitim süresi daha erken dönemlerde de sona erdirilebilir.

Ön/son veri işleme(Pre/Post Processing): Yapay sinir ağlarının en belirgin özelliklerinden olan doğrusal olmama(nonlinearity) özelliğini mantıklı kılan yaklaşım, girişlerin bir normalizasyona tabi tutulmasıdır. Normalizasyon yapılmasının nedeni aktivasyonu fonksiyonunun veri setinin minimum ve maksimum aralığındaki giriş verileri için ayırt edilebilir çıktılar verebilmesi olduğu vurgulanmaktadır. Bu aralığın dışındaki girişler için, eşit çıktılar elde edilmektedir ve işlem yapılan proses elemanın yakınsaması olanaksız hale gelmektedir. Genelde verinin $[0 \ 1]$ veya $[-1 \ +1]$ aralıklarından birine ölçeklenmesi önerilmektedir. Ölçekleme, verinin geçerli eksen sisteminde sıkıştırılması anlamı taşıdığından data kalitesi aşırı salınımlar içeren sorunlarda YSA modellerini olumsuz yönde etkileyebilir. Bu durum kullanılacak öğrenme fonksiyonunu da başarısız duruma düşürebilir. Eğer öğrenme fonksiyonu bipolar bir fonksiyon ise ölçekleme $[-1 \ +1]$ aralığına, aksi durumda ölçekleme $[0 \ +1]$ aralığına yapılmalıdır. Bir X veri

kümesinin, 0.0 ile 1.0 arasında bir ölçeklendirmeye tabi tutulabilmesi için o kümenin X_{min} , X_{maks} aralığı bulunur ve Eş. 5.45'deki gibi yeni değer aralığı tanımlanır.

$$X_{yeni} = \frac{X - X_{min}}{X_{mak} - X_{min}} \quad (5.45)$$

Eğer ölçeklendirmede en genel ifade ile a ve b gibi iki sayı aralığına çekilmek istenirse Eş. 5.46'da kullanılabilir [Sağıroğlu, 2003].

$$X_{yeni} = \frac{X - X_{min}}{X_{maks} - X_{min}} (b - a) + a \quad (5.46)$$

Eğitim esnasında, bu işlemlerden elde edilen normalize edilmiş giriş ve çıkış değerleri kullanılır. İşlem tamamlandıktan sonra elde edilen YSA sonuçları ters normalize işlemine tabi tutularak gerçek değerlerine çevrilmelidir. Veri ölçeklemede kullanılan normalizasyon araçlarından birisinin de kullanılan transfer fonksiyonu olduğu unutulmamalıdır. Fonksiyonun kendisinin aynı zamanda bir veri ölçekleme aracı olarak da kullanılabileceği ise unutulmamalıdır. Bununla beraber bu öneri YSA sisteminden beklenen giriş ve çıkış sayısının değişmediği durumlar için geçerlidir. Bununla beraber seçilen bir ağ yapısı için en uygun ağ mimarisinin aranmasında çok sayıda birbirinden farklı ağ mimarisi ile gerçekleştirilen benzetimler elde edilerek problemin çözümüne en uygun ağ yapısının ne olduğu tahmin edilebilir. Bu amaçla kullanılabilecek uygun arama yaklaşımları bulunmaktadır. Monte-Carlo ile Quasi-Newton metodu bunlara örnek verilebilir.

Öncül veri işleme aşaması, verinin en doğru, en kısa ve en hızlı şekilde işlenmesi için hazırlanmasını ifade eder. Öncül işlemler sırasında çeşitli veri geliştirme araçlarından faydalanılabilir. Son yıllarda en çok ilgi çeken ön işlem Temel Bileşenler Analizi yöntemidir. Bu aşamada temel amaç verinin YSA modeli ile uyum içerisinde olmasını sağlamaktır.

YSA tasarımında sistem karmaşıklığı üzerinde en fazla etkiye sahip dış faktörler, veri kodlama yapısı ve normalizasyon yöntemidir. Veri kodlama, bir verinin bilgiye dönüştürülmesi için işlenebilmesini kolaylaştırıcı bir araçtır ve verinin genel mimarisinin değiştirilmesini ifade eder. Buna veri ön işleme de denilmektedir.

Aktivasyon fonksiyonu seçimi: YSA tasarımı için seçilecek olan transfer fonksiyonları öğrenmede önemli bir yaklaşım olarak karşımıza çıkmaktadır. Problemin davranışına uygun olan fonksiyon tipinin belirlenmesi başarı yüzdesini yükseltebilir. Bazı problemlerde tek bir tip transfer fonksiyonu seçimi yerine karma kullanım başarıyı arttırabilecektir. Aktivasyon fonksiyonlarından herhangi birisi, çözülecek veya uygulanacak olan problemin davranışı göz önünde bulundurularak seçilmesi büyük önem taşımaktadır.

Ara katman ve ara katman nöron sayısını belirleme: YSA mimarisinde optimal sayıda ara katman sayısını ve ara katmanlardaki nöron sayılarını saptamak için bilimsel literatürde farklı yaklaşımlar görülmektedir. Fakat bazı özel uygulamalarda, bu yaklaşımlar geçerli sonuçlar vermeyebilir. Geçerli bir sonuç elde etmek için bir kaç deneme yapılarak en uygun yapının ve nöron adedi belirlenebilir. Literatürde, her türlü problemin maksimum iki ara katman kullanılması gerektiği ile ilgili ispatlarında olduğu vurgulanmaktadır. Bazı özel problemler için bu yaklaşım her zaman geçerli olmayabilmektedir. Bunun beraber, bazı özel problemlerin çözümünde bazı düğüm elemanları arasında kompleks karmaşık bağlantılara ihtiyaç duyulabilir. Bu durumlarda en uygun düğüm elemanı sayısını saptamanın yanında uygun bağlantı sayısı ve yapısını da bulmak yararlı olmaktadır. YSA tasarımıda temel amaç, YSA sisteminin mümkün olduğunca sade ve basit bir yapıda tasarlanmasına dikkat etmektir. Bu karmaşıklığın artması öğrenme sürecini doğrudan arttırmakta ve yapının performansını olumsuz yönde etkileyebileceği de söylenmektedir [Yamaçlı, 2010].

Ara bağlantı tiplerini belirleme: Ara bağlantıların, kısmi olarak veya tamamı itibari ile, ileri beslemeli veya çift yönlü olmaları tasarım için önemli kriterlerdir. İleri beslemeli ve çift yönlü bağlantılar birbirleri ile kısmen veya tamamen ilişkili olabilmektedir. Aşırı kompleks yapılarda, yapay nöronların aynı kat içerisinde

birbirleri ile iletişim kurmasına intra-ara katman bağlantıları denilmektedir. “Recurrent” ve “On-center/off” sarmal bağlantıları bu tip bağlantılar olmakla birlikte tasarımlarda dikkate alınması önemlidir [Yamaçlı, 2003].

Performans Fonksiyonu Seçimi: Bir yapay sinir ağının öğrenme performansını etkileyen önemli faktörlerden birisi de performans fonksiyonudur. Özellikle İleri beslemeli(feedback) ağlarda kullanılan tipik performans fonksiyonları olarak; karesel ortalama hata (MSE), toplam karesel hata (SSE) ve karesel ortalama hata karekökü (RMSE) olarak verilebilir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \quad (5.47)$$


$$SSE = \sum_{i=1}^N (t_i - td_i)^2 \quad (5.48)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (5.49)$$

YSA’ların genelleştirme özelliğini yükseltmek için kullanılan metotlardan biri de öğrenmeyi erken sonlandırma (early stopping) işlemidir. Bu metotta veri kümesi üç bölüme ayrılmaktadır. İlk set YSA nesnesinin eğitiminde kullanılarak bağlantı ağırlıklarının, biasların ve gradiyentin güncelleştirilmesinde kullanılmaktadır. İkinci set bir onaylama verisi olarak kullanılmaktadır. YSA eğitimi, test ve onaylama işlemi ile birlikte yapılabilmektedir. Bu kapsamda eğitim, test ve onaylama için 3 set data kümesi gerekmektedir. Eğitim esnasında, test veri kümesine ait hata normal olarak düşmektedir. Bu azalma, eğitim verilerinden hesaplanan hata miktarında da görülmektedir. Bununla birlikte YSA, eğitim verisi üzerinde bir overfitting eğilimine girerse, onaylama veri kümesinden hesaplanan hata değeri artmaya başlayacaktır. Onaylama veri kümesinden hesaplanan hata değeri saptanan bir değeri aşarsa, eğitim durdurularak bağlantı ağırlıkları ve biaslar onaylama veri kümesinden elde edilen hataların olduğu andaki değerlerine geri çevrilir [Yamaçlı, 2010].

5.3.12. SOM(Self Organizing Map) ağı

Öz örgütlemeli harita veya öz örgütlemeli özellik haritası olarak da bilinen SOM ağı, eğitim örneklerinin giriş uzayının düşük boyutlu ayrık bir gösterimini üreten, danışmansız öğrenme kullanan bir yapay sinir ağı çeşididir. SOM ağı, giriş uzayının topolojik özelliklerini korumak için bir komşuluk fonksiyonu kullandığı için diğer yapay sinir ağı modellerinden farklı yapıdır. Bu özellik yüksek boyutlu verinin, düşük boyutlu görselleşmesi için faydalıdır. SOM ağı ilk olarak Finli Prof. Tuevo Kohonen tarafından bir yapay sinir ağı modeli olarak tanıtılmıştır ki bu nedenle bu ağı Kohonen ağı/haritaları olarak da bilinmektedir.



Şekil 5.7. SOM ağ mimarisi

SOM ağı yapısal olarak oldukça sade şekilde bir girdi ve bir çıktı katmanından meydana gelmektedir. Çıktı katmanı genellikle iki boyutlu bir düzlemde oluşmaktadır. Şekil 5.7’de görüleceği gibi proses elemanları diğer bir deyişle ağ düğümleri(node), çıktı katmanı üzerine dağılmış vektörleri göstermektedir. SOM ağlarının temel çalışma prensibi yarışmayı kazanma ve kazanan elemanın “1” diğerlerinin “0” değerini alması üzerinedir. Tüm girdi uzayı, tüm çıktı elemanlarına

belirli bir ağırlıklar ile bağlıdır. Çıktı uzayında değerlendirilen bir diğer ifade ile yarışmayı kazanan çıkış elemanının etrafında yer alan komşuları ağırlık eğitimi sırasında ağırlıklarını değiştirmektedir [Öztemel, 2006].

SOM ağırlıklarının eğitilmesi sürecinde; bir t zamanında girdi uzayından bir örnek ağırlık verilir. Burada önemli bir nokta diğer yapay sinir ağlarında olduğu gibi giriş ve ağırlık vektörlerinin mutlaka ölçeklenmesi yani normalize edilmesi gerekmektedir. Her düğüm çıktısı ağırlıklar ile girdi örneğinin çarpımının toplamı ile ifade edilir. Bulunan bu toplam değerinden en yüksek ölçüme sahip olan düğüm(proses) elemanı, yarışmayı kazanmış kabul edilmektedir. Diğer elemanların çıktıları ise sıfır olmaktadır. Euclid mesafesi(d) ile girdi vektörüne en yakın ağırlık vektörüne sahip eleman kazanan elemanı temsil etmektedir. İki vektör arasındaki uzaklık Eş. 5.50'deki şekilde hesaplanmaktadır.

$$d_j = \|X - w_j\| \quad (5.50)$$

SOM ağırlıklarında her çıktı elemanı için euclid mesafesi hesaplanarak en küçük uzaklık değerine sahip eleman kazanan eleman olmaktadır. Kazanan elemanını belirlenmesi ile birlikte komşularının ağırlıkları Eş. 5.51'deki formül ile güncellenmektedir.

$$w(t+1) = w(t) + \lambda e(l,i)(x(t) - w(t)) \quad (5.51)$$

Eş. 5.51'de verilen λ öğrenme katsayısını, $e(l,i)$ ise komşuluk fonksiyonunu temsil etmektedir. $e(l,i)$ komşuluk fonksiyonunda l ve i elemanlarının komşuluklarını göstermektedir. $l = i$ iken $e(l,i) = 1$ olmaktadır. $|l - i|$ değeri arttıkça, $e(l,i)$ komşuluk fonksiyonu, zaman içerisinde bir gauss eğrisi şeklinde azalan bir fonksiyondur.

$$e(l,i) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{(l-i)^2}{2\sigma^2}\right] \quad (5.52)$$

Hassas bir yakınsama için, ağırlık öğrenme sürecinde komşuluk fonksiyonunun genişliği yavaş şekilde azalır. Örnek olarak; komşuluk fonksiyonu bir gauss fonksiyonu ise bu σ değerinin düşürülmesine karşılık gelmektedir. Komşu birimlerde ağırlık güncellemeleri ile birlikte, komşu birimlerde girdiye doğru çekildiğinden, önemsiz birimler engellenmiş olmaktadır [Alpaydın, 2010].


5.4. Destek Vektör Makineleri(DVM)

Destek Vektör Makineleri (DVM), Destek Vektör Sınıflandırıcı (DVS) ve Destek Vektör Regresör (DVR)'den oluşan ve bilinen tüm veri madenciliği algoritmaları içinde en sağlam, en doğru metotlardan birisidir [Cortes, 1995]. DVM'ler orijinal olarak Vapnik tarafından 1990'larda geliştirilmiştir. İstatistik öğrenme teorisinde köklü sağlam bir teorik temele sahiptirler ve öğrenme için bir düzüne kadar az sayıda örnek ile çalışabilmektedirler. Çoğu zaman boyutların sayılarına duyarsızdırlar. Geçen on yıllık sürede, hem pratik hem de teori alanlarda DVM kullanımı artmıştır. Destek vektör makinesi temeli diğer bir değişle kökeni yapısal risk minimizasyon prensibine dayanmaktadır, ayrıca yapısal risk minimizasyon, VC-boyut(Vapnik Chernonveki Dimension) içerisinde yer aldığından destek vektör makinesini daha da önemli kılmaktadır. Adından anlaşıldığı üzere, makine tasarımı destek vektörler olarak hizmet veren eğitme verisinin bir alt kümesinin elde edilmesine dayanmaktadır ve bu nedenle verinin bir istikrarlı özelliğini ifade etmektedir. Destek vektör makinesi çok terimli (polinom) makine öğrenmesi, radyal temelli fonksiyon ağ ve iki katmanlı algılayıcı (two-layer perceptron) fonksiyonlarını içermektedirler. Bu yöntemler eğitim verisinde bulunan yapısal istatistik düzenliliğin değişik temsillerini sağlasa bile, bunların hepsi bir destek vektör makinesi temelinde ortak bir kökten gelmektedirler [Haykin, 2001]. Destek vektör makineleri istatistiksel öğrenme teorisi üzerine inşa edilmiştir. Öğrenme, sınıflandırma, kümeleme, yoğunluk tahmini ve veriden regresyon kuralları üretmek için kullanılan bir eğitme algoritmasıdır.

5.4.1. Vapnik-Chervonenkis(VC) boyutu

Vapnik-Chervonenkis(VC dimension) boyut bir fonksiyonlar sınıfının elemanlarının ne kadar dinamik olduğunun saptanarak, bu sınıfın karmaşıklığını ölçen bir metottur. [Hastie ve ark., 2009]. Hatalarının(örnekleme) öngörülenmesinin kullanılmasındaki güçlük, adaptasyonda kullanılan parametrelerin ya da karmaşıklığın saptanmasıdır.

Vapnik-Chervonenkis(VC) teorisi karmaşıklığın(d) böyle bir ölçütünü vermektedir. $\{f(x, \alpha)\}$ gibi bir fonksiyonlar sınıfı olduğunu düşünürsek ve bunun α gibi bir vektör tarafından indekslendiğini ve $x \in \mathfrak{X}^p$ olduğunu düşünelim. f gösterge fonksiyonu 0 veya 1 değerlerini almaktadır. Eğer $a = (a_0, a_1)$ ve f lineer gösterge fonksiyonlar ise $I(a_0 + a_1^T x > 0)$, o halde sınıf f 'in karmaşıklığının $p+1$ olduğu ifade edilmektedir. Şekil 5.8'de verilen düzlemlerin soldan ilk üç lineer gösterge fonksiyonların VC boyutunu göstermektedir. Ancak soldan dördüncü düzlemde ise bir VC boyut söz konusu değildir çünkü belirli bir doğrular kümesi tarafından dört adet nokta parçalara bölünememiştir. p boyuttaki bir lineer gösterge fonksiyonu $p+1$ sayıda VC-boyut'a sahip ve bu serbest parametrelerin sayısını ifade etmektedir. Şekil 5.8'deki soldan ilk üç panelde, düzlemdeki doğrular verileri parçalara böldüğü görülmektedir [Kuzey, 2012].



Şekil 5.8. VC boyutu

Problemimizde N adet noktadan oluşan bir veri kümesi olduğunu farz edersek, bu N nokta, pozitif ve negatif olarak 2^N yolla türetilabilir veya etiketlenebilir denilmektedir. Bu yüzden 2^N farklı öğrenme problemi N veri noktaları tarafından ifade edilebilir. Bu problemlerden bir tanesi için, negatif örnekleri diğer pozitif

örneklerden ayıran $h \in H$ olacak şekilde bir hipotez sınıfı bulabileceği söylenebilir. Bu duruma H N adet noktaları tuz buz ettiği(shattering) diğer bir ifade ile *parçalara ayırdığı* benzetmesi yapılabilir. N adet örnek yolu ile tanımlanabilen herhangi bir öğrenme problemi H den çekilen bir hipotez yolu ile hatasız şekilde öğrenilebilir. H tarafından parçalara ayrılabilen maksimum noktaların sayısına H 'nin *Vapnik-Chervonenkis*(VC) boyutu adı olarak tanımlanır ve $VC(H)$ olarak gösterilir ve H 'nin kapasitesini ölçmektedir. VC- boyut, bir sınıflandırıcının karmaşıklığının ölçüsüdür. Yani, bu ölçüm bir ikili sınıflandırıcının iki sınıf arasındaki sınırı ne kadar iyi ölçmesi olarak bilinir. Eğer VC-boyut çok büyük ise sınıflandırıcı daha karmaşık bir hal alır ve böylece ilgili sınıflara ait olan gözlemleri daha iyi bölebilir. Daha açık bir ifadeyle, karmaşık sınıflandırıcılar karmaşık sınıf sınırlarını daha az karmaşık sınıflandırıcılara oranla daha iyi modeller. Daha doğrusu, bir model ne kadar çok karmaşık ise, bir eğitme kümesindeki gözlemleri daha iyi böler [Kuzey, 2012].

5.4.2. Deneysel risk minimizasyonu(DRM)

Ampirik diğer bir deyişle deneysel risk minimizasyonu (ARM) bir öğrenme kümesi prensipler bütünü olarak tanımlanabilir ve öğrenme algoritmalarının kalitesi için sınırlar belirlemektedir.

Bir genelleme hatası tahmin yöntemi olan PAC (probably approximately correct) öğrenme teorisi, deneysel (ampirik) risk minimizasyon (DRM) ile örnek veriler üzerinden çalışır. Model olmadığı durumlarda, reel değerli bir fonksiyonun dağılımı olmaksızın öğrenme için bir perspektif sunabilir [Vapnik, 1982]. Destek Vektör makinaları yöntemi bir nevi kernel çekirdeği tabanlı deneysel risk minimizasyon(DRM) algoritmasıdır. Faydalı özellikleri olması nedeni ile popülerliği günden güne artmaktadır ve deneysel performansı açısından oldukça ümit verici olduğu ifade edilebilir [Cortes, 1995].

$R[\hat{f}]$ beklenen riski göstermek üzere, makine öğrenimi beklenen riskin minimizasyonudur.

$$\hat{f}^* = \arg \min_{\hat{f} \in \hat{F}} R[\hat{f}] \quad (5.53)$$

Eş. 5.53’de $P(\bar{x}, y)$ bileşik olasılık dağılımını bilinmediğinden, makine öğrenimi mümkün değildir. Bunun yanında D eğitme verisinde, gözlemler şeklinde bileşik olasılık dağılımı hakkında Eş.5.54’deki bilgiye sahip olduğumuz kabul edilir.

$$D = \{(\bar{x}_1, y_1), \dots, (\bar{x}_l, y_l)\} \subset \mathfrak{R}^n \times \{+1, -1\} \quad (5.54)$$

Bu gözlemleri kullanarak risk tahmin edilebilir. Buna bazı model $\hat{f}$ lerin *deneysel riski* $R_{emp}[\hat{f}]$ adı verilir ve aşağıdaki şekilde tanımlanır:

$$R_{emp}[\hat{f}] = E[L(y, \hat{f}(\bar{x}))] = \frac{1}{l} \sum_{i=1}^l L(y_i, \hat{f}(\bar{x}_i)) \quad (5.55)$$

Eş. 5.55’de yer alan $(\bar{x}_i, y_i) \in D$ şeklinde tanımlanmaktadır. Giriş eğitme kümeleri çoğunlukla sonlu olduğundan ve ayrık örnekler içermesi nedeniyle ayrık numeriksel beklenti Eş. 5.56’de gibi kullanılmaktadır.

$$E[g] = \frac{1}{k} \sum_{i=1}^k g(x_i) \quad (5.56)$$

Olması muhtemel diğer bir değişle olması beklenen riske benzer biçimde deneysel riski minimize ederek en iyi model elde edilmektedir [Kuzey, 2012].

$$\hat{f}^* = \arg \min_{\hat{f} \in \hat{F}} R_{emp}[\hat{f}] = \arg \min_{\hat{f} \in \hat{F}} \left(\frac{1}{l} \sum_{i=1}^l L(y_i, \hat{f}(\bar{x}_i)) \right) \quad (5.57)$$

Ampirik riski küçükleme için muhtemel tüm $\hat{F}$ modellerinin sınıfından bir model seçimine izin verildiği için, deneysel riski sıfıra veya sıfıra yakın bir değere indiren

herhangi bir model her zaman olabilir. Amprik riski küçüklemek için aşırı optimist olması olasılık dahilinde olduğu vurgulanmaktadır [Hamel, 2009].


5.4.3. Yapısal risk minimizasyonu(YRM)

Orijinal adı “Structural Risk Minimization” olan yapısal risk minimizasyonu Vapnik tarafından 1974 yılında geliştirilen ve öğrenme için sonlu sayıda eğitime giriş kümesinden, optimal model seçimi için geliştirilmiş tümevarımsal prensipler bütünüdür. Bu model fonksiyonların VC boyutu ile giriş eğitime verisinin adaptasyon kalitesi arasında ödünleşim eğrisini vermektedir. Yapısal risk minimizasyonu işleyiş süreci genel olarak şu şekilde özetlenebilir; Giriş kümesinin ön bilgilerini kullanarak, k dereceli polinomlar, k sayıda gizli katman nöronlara sahip sinir ağlar, k nöronlu kübik fonksiyonları gibi sınıflar seçilerek, her bir alt kümede deneysel risk minimizasyonu sağlanır.

5.4.4. Destek vektör sınıflandırıcı

Lineer olarak ayrılabilen iki sınıflı öğrenme için, destek vektör sınıflandırıcının hedefi verilen örneklerin iki sınıfın maksimal bir marj ile bölebileceği bir aşırı düzlem tanımlamaktır. Bu tür aşırı düzlemin en iyi genelleştirme yeteneğini verebildiği ispatlanmıştır. Genelleştirme yeteneği bir sınıflandırıcının giriş eğitime verisinde çok iyi sınıflandırma performansı olduğu gibi aynı zamanda giriş eğitime verisi gibi aynı dağılımdan gelecek verisi için yüksek tahmin kalitesini garanti eder [Kuzey, 2012].

Bir sınıflandırıcının genelleştirme yeteneği giriş eğitime verisinde çok iyi sınıflayıcı performansına sahip olduğunu(örneğin doğruluk) göstermesi yanında eğitime verisi gibi aynı dağılımdan gelen gelecek verisi için de yüksek öngörü doğruluğunu garanti edeceği ifade edilmektedir [Kuzey, 2012].



Şekil 5.9. Destek vektör sınıflayıcı ve hiperdüzlem

Bir marjın bir aşırı düzlem tarafından tanımlanan iki sınıf arasındaki mesafe miktarı olarak ifade edilmektedir. Geometrik manada marjın düzlemde en yakın veri noktaları ile aşırı düzlem üzerindeki herhangi bir nokta arasındaki en kısa mesafeye denk gelmektedir. Şekil 5.9 bir iki-boyutlu girdi uzayı için optimal aşırı düzlemin bir geometrik yapısını görülmektedir.

Farz edelim w ve b sırası ile hiper düzlemde ağırlık vektörü ve yanlı(bias) olsun. İlgili hiper düzlem şu şekilde ifade edilebilir;

$$w^T \cdot x + b = 0 \quad (5.58)$$

X örnek verisinden optimal hiper düzleme ve istenilen yönde geometrik uzaklık $r = g(x)/w$ olarak ifade edilir. Burada $g(x) = w^T x + b$ aşırı düzlem tarafından tanımlanan bir diskriminant fonksiyonudur [Christianini ve Taylor, 2000].

w ve x 'in bilinmesiyle $g(x)$ fonksiyonel marjın olarak oluşturulmaktadır. Destek vektör sınıflayıcısı optimal aşırı düzlem için ayırma marjı p 'yi aşırı yükseltmek için w ve b parametrelerinin bulunmasını amaçlamaktadır. Bu parametreler iki sınıftan en kısa geometrik uzaklıklar olan r^* yolu ile saptanmaktadır. Böylece destek vektör

sınıflayıcısının ismi *maksimal marj sınıflandırıcı* adını almaktadır. Genellik kayıp olmadan, fonksiyonel marjı 1' e eşit olacak şekilde düzeltilir ve verilen bir eğitme kümesi $\{x_i, y_i\}_{i=1} \in \Re^m \times \{\pm 1\}$ olmak üzere Eş. 5.59'daki denklemler ile elde edilmektedir [Christianini ve Taylor, 2000].

$$\begin{aligned} w^T x_i + b &\geq 1, & y_i &= +1 \\ w^T x_i + b &\leq -1, & y_i &= -1 \end{aligned} \quad (5.59)$$

Eş. 5.59'daki birinci veya ikinci parçalardaki eşitlikleri sağlayan özel veri noktaları (x_i, y_i) destek vektörler olarak adlandırılır, bu noktalar tam olarak optimal hiper düzleme en yakın veri noktalarıdır [Haykin, 2001]. Sonra, destek vektör x^* dan optimal hiper düzleme karşılık gelen geometrik uzaklık r^* şu şekilde ifade edilmektedir.

$$r^* = \frac{g(x^*)}{\|w\|} = \begin{cases} \frac{1}{\|w\|}, & y^* = +1 \\ \frac{-1}{\|w\|}, & y^* = -1 \end{cases} \quad (5.60)$$

Şekil 5.9'den de anlaşılacağı gibi, ayırma düzlemi $p = 2r^* = 2/\|w\|$ şeklinde ifade edilebilir. Maksimum marjlı hiper düzlemi bulunabileceğinden emin olmak için, sınıflayıcı w ve b ye göre p 'yi maksimize etmek için çalışmaktadır.

$$\max_{w,b} \frac{2}{\|w\|}, \quad y_i(w^T x_i + b) \geq 1, \quad i = 1, 2, \dots, n \quad (5.61)$$

$$\min_{w,b} \frac{1}{2} \|w\|^2, \quad y_i(w^T x_i + b) \geq 1, \quad i = 1, 2, \dots, n \quad (5.62)$$

Eş.5.61 ve Eş.5.62 sonucunda, sonraki optimizasyon basamaklarını kolaylıkla gerçekleştirmek için çoğu zaman $\|w\|$ yerine $\|w\|^2$ kullanılır [Kuzey, 2012]. Genellikle, primal problem olarak bilinen Eş.5.62 denkleminde kısıtlara sahip optimizasyon

problemini Lagrange çarpanları metodu kullanılarak çözülür. a_i i. eşitsizliğe göre Lagrange çarpanını göstermek üzere;

$$L(w, b, a) = \frac{1}{2} w^T w - \sum_{i=1}^n a_i [y_i (w^T x_i + b) - 1] \quad (5.63)$$

şeklinde gösterilir. $L(w, b, a)$ 'nın w ve b ye göre diferansiyelini alınırsa ve sonuçları sıfıra eşitlersek, aşağıdaki iki optimal olma koşulu elde edilir.

$$\begin{aligned} w &= \sum_{i=1}^n a_i x_i y_i \\ \sum_{i=1}^n a_i y_i &= 0 \end{aligned} \quad (5.64)$$

Eş. 5.64'de elde edilen denklemi Eş. 5.63'da Lagrange fonksiyonunda yerine koyarsak, bir dual problemi elde ederiz.

$$\begin{aligned} L(w, b, a) &= \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j (x_i^T x_j) \\ \sum_{i=1}^n a_i y_i &= 0 \quad a_i \geq 0 \quad i = 1, 2, \dots, n \end{aligned} \quad (5.65)$$

Karush-Kuhn-Tucker tamamlayıcı koşulu;

$$a_i [y_i (w^T x_i + b) - 1] = 0, \quad i = 1, \dots, n \quad (5.66)$$

Sonuçta yalnız optimal aşırı düzleme en yakın veri noktaları ve maksimal marjı sınırını belirleyen destek vektörleri olan (x_i, y_i) sıfır olmayan i değerlerine karşılık olarak gelmektedir. Diğer tüm a_i değerleri sıfıra eşit olmaktadır [Kuzey, 2012].

Eş. 5.65'deki dual problem bir konveks kuadratik programlama optimizasyonu problemidir. Genellikle sıralı minimal optimizasyon (sequential minimal optimization

algorithm) gibi bazı uygun optimizasyon metotlarının benimsenmesi ile verimli bir şekilde global optimuma yakınsar [Christianini, 2000]. Lagrange çarpanları(optimal olan) olan a_i^* ve optimal ağırlık vektörü olan w^* yı Eş. 5.64’de yerine koyarak hesaplama yapabilmektedir [Kuzey, 2012].

$$w^* = \sum_{i=1}^n a_i^* x_i y_i \quad (5.67)$$

5.4.5. Maksimal marjlı sınıflandırıcı ve optimizasyon

Maksimal marjlı destek vektör sınıflandırıcı, ileride tanımlanacak destek vektör regresyonunda eklenmesi birlikte destek vektör makineleri(DVM) algoritmalarının orijinal başlama noktasını temsil etmektedir. Ancak gerçek dünya problemlerinde, tüm noktaların lineer olarak ayrılabilir olma gerekliliği çok katı olabilmektedir. Özellikle birçok kompleks lineer olmayan sınıflandırma durumlarında örneklerin tamamen lineer olarak ayrılabilir olamadığı zaman, marjlar negatif değerli olabilmektedir. Bu gibi durumlarda, primal problemin uygun çözüm bölgesi boştur ve bu duruma uygun düşen ikilik(dual) problem ise sınırsız bir hedef fonksiyonudur. Bu durum ise en uygun biçime sokma problemini çözmeyi imkânsız yapmaktadır [Christianini, 2000].

Bu tür ayrılamaz verileri çözmek için, genellikle iki tür yaklaşım tercih edilmektedir. İlk yöntem Eş.5.62 no’lu denklemdeki katı eşitsizlikleri çözmek gevşetmektir. Bu şekilde “*soft marj optimizasyon*”olarak adlandırılan yöntem elde edilmektedir. İkinci yöntem ise lineer olmayan o problemlere “*kernel trick*” yani çekirdek hilesi uygulayarak bunları doğrusal hale getirmektir [Kuzey, 2012].

Giriş uzayında yer alan verilerde karşı sınıflara dahil olmuş birkaç noktanın olduğu durumları düşünecek olursak, bu noktalar maksimum marjlı aşırı düzlem için bile var olan eğitim hatasını temsil etmektedir. Soft marjin fikri DVC algoritmasını genişletmeyi amaçlar bu şekilde aşırı düzlem böyle gürültülü verilerin var olmasına

izin vermektedir. Özellikle, gevşek yapay değişken(slack) ξ_i sınıflandırıcı tarafından, sınıflandırma ihlalinin miktarını açıklamak için verilmektedir [Kuzey, 2012].

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (5.68)$$

$$y_i (w^T x_i + b) \geq 1 - \xi_i \quad \xi_i > 0 \quad i = 1, \dots, n$$

Eş.5.68'deki C parametresi makinenin karmaşıklığı ve lineer olarak ayrılmayan noktaların sayısı arasındaki bir nevi dengeyi sağlamaktadır. Bu parametre literatürde “düzenleştirme” parametresi(regularized parameter) olarak bilinmektedir. C parametresi uzman tarafından, analitik veya deney yolu ile seçilebilmektedir.

Gevşek yapay değişken olan ξ_i 'nin yanlış sınıflandırılmış bir veri örneğinin aşırı düzleme olan uzaklık yolunun, direkt olarak bir geometrik yorumudur. Bu parametre, ideal durumdan bir örneğin sapmasını ifade etmektedir. Lagrange çarpanları metodu kullanılarak, oluşan dual problemi şu şekilde ifade edebiliriz;

$$\max_a W(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j x_i^T x_j \quad (5.69)$$

$$\sum_{i=1}^n a_i y_i = 0 \quad 0 \leq a_i \leq C \quad i = 1, \dots, n \quad (5.70)$$

Eş.5.65 ile Eş.5.69 no'lu denklemler kıyaslandığında, ξ_i gevşek yapay değişkeninin dual problemde görünmediği önemli bir ayrıntıdır. Doğrusal olarak ayrılabilen ve ayrılamayan durumlar arasındaki önemli fark $a_i \geq 0$ kısıtından daha sıkı bir kısıt olan $0 \leq a_i \leq C$ kısıt ile yer değiştirmesinden kaynaklanmaktadır. Aksi takdirde, bu iki durum birbirinin benzeri yapıdadır [Christianini, 2000; Haykin, 2001].

Veri noktalarının düzlem üzerinde ayrılmaz(inseparable) durumlarda Karush-Kuhn-Tucker tamamlayıcı koşulu Eş.5.71'deki gibi ifade edilmektedir.

$$a_i[y_i(w^T x_i + b) - 1 + \xi_i] = 0 \quad (5.71)$$

$$\gamma_i \xi_i = 0 \quad i = 1, 2, \dots, n$$

Eş. 5.71'de tanımlanan γ_i 'ler ξ_i 'nin pozitifliğini uygulatmak için verilen ξ_i 'e karşılık gelen Lagrange çarpanlarıdır [Haykin,2001]. Primal problem için Lagrange fonksiyonunun ξ_i 'ye görevi türevi sıfırdır, türevlerin hesaplamalarından aşağıdaki sonuç elde edilir.

$$a_i + \gamma_i = C \quad (5.72)$$

Eş.5.71 ve Eş.5.72 denklemleri beraber düşünüldüğünde ve $\xi_i = 0$ şayet $a_i < C$ ise, optimal ağırlık w^* Eş.5.73'deki gibi verilir.

$$w^* = \sum_{i=1}^n a_i * y_i x_i \quad (5.73)$$

5.4.6. Çekirdek hilesi(kernel trick)

Lineer olarak ayıramayan problemleri çözmek için kullanılan metotlardan birisi de çekirdek hilesidir. Problem verilen giriş verileri arasında iç çarpıma dayalı uygun bir çekirdek fonksiyonu tanımlamak, problemleri doğrusal olarak ayrılabilir yapmak için giriş uzayından, yüksek boyutlu (sonsuz da olabilir) öznitelik uzayına verinin lineer olmayan dönüşümünü yapmaktır. Kompleks bir örüntüye(patern) sahip bir sınıflandırma problemi yüksek boyutlu bir uzayda lineer olmayacak bir biçimde oluşmuşsa, düşük boyutlu uzaydakine oranla büyük ihtimalle lineer olarak ayrılabilir [Haykin,2001].

$\Phi : \mathbf{X} \rightarrow \mathbf{H}$ giriş uzayından $\mathbf{X} \subset \mathbf{R}_m$ öznitelik uzayına $\mathbf{H}$ doğrusal olmayan dönüşümü gösterdiğini farz edersek, problem $\mathbf{H}'$ 'de lineer olarak ayrılabilir. Buna karşılık gelen en uygun hiper düzlem Eş. 5.74'deki şekilde ifade edilebilir.

$$W^{\phi^T} \phi(x) + b = 0 \quad (5.74)$$

öznitelik uzayında hesaplanan optimal hiper düzlem ise;

$$\sum_{i=1}^n a_i^* y_i W^{\phi^T}(x_i) \phi(x) = 0 \quad (5.75)$$

Eş. 5.75’de yer alan $W^{\phi^T}(x_i) \phi(x) = 0$ terimi $\phi(x_i)$ ve $\phi(x)$ vektörlerinin iç çarpımını göstermektedir. Bu yüzden de burada iç çarpım çekirdek fonksiyonunu kullanmak gerekmektedir. Çekirdek(kernel) fonksiyonu Eş.5.76’deki gibi bir fonksiyondur.

$$K(x, x') = \phi^T(x) \phi(x') \quad (5.76)$$

Eş. 5.76’daki ϕ giriş uzayı(input space) olan $\mathbf{X}$ ’dan öznitelik uzayı olan $\mathbf{H}$ ’ye olan dönüşüm fonksiyonunu göstermektedir. Optimal öznitelik uzayında aşırı düzlem oluşturmak için ϕ dönüşümünün somutlaştırılmış biçimini gözetmeksizin çekirdek fonksiyonunu kullanabilmektedir. Bu sebeple, destek vektör makinaları için kernel fonksiyonun önemi çok büyüktür [Christianini, 2000].

Çekirdek fonksiyonunun uygulanması geçerli algoritmanın boyuta bağıllığını ortadan kaldırmaktadır. Bununla birlikte lineer olarak ayrılamaz veri problemlerinin etkili çözümü ile yüksek boyutlu bir uzayda lineer bir sınıflandırıcıyı eğitmek amacıyla da tercih edilmektedir. Bahsedilen bu durum Eş.5.75’de $\phi^T(x) \phi(x')$ yerine $K(x_i, x)$ kullanarak yapılabilir ve optimal hiper düzlem Eş. 5.77’deki biçimde verilir [Christianini, 2000].

$$\sum_{i=1}^n a_i^* y_i K(x_i, x) = 0 \quad (5.77)$$

Çekirdek hilesi hesaplamayı basitleştirmek için öncelikli tercih edilen yöntemlerden biridir. Bu yöntem sayesinde karmaşık öznitelik uzayını hesaplama karmaşıklığından


sakınılmış olunabilir. Çekirdek hilesini uygulamadan önce, çekirdek fonksiyonunun nasıl seçileceği, hangi karakteristik özellikleri taşıyacağı oldukça önemlidir. Yani bir çekirdek fonksiyonu hangi karakteristikleri sağlamalıdır. Gerçek bir çekirdek fonksiyonu olarak kabul gören kernel fonksiyonunun özelliğini karakterize eden “*Mercer teoreminin*” iyi bilinmesi de çekirdek fonksiyonun özelliklerinin anlaşılması için oldukça önemlidir [Christianini, 2000].

Destek Vektör Makinelerinde çekirdek fonksiyonu seçimi genellikle “*Mercer Teoremini*” sağlamak içindir. Bundan dolayı, yaygın kullanılan çekirdek fonksiyonları olarak: *sigmoid*, *polinom*, ve *radyal tabanlı* fonksiyonlar sayılabilir. Bu fonksiyonlar bazı zamanlar kernel trick uygulanmasını sınırlandırabilmektedir. [Kuzey, 2012].

5.4.7. Destek vektör regresyon

Daha önce bahsedilen konularda destek vektör makinelerinin sınıflandırma boyutu ile ilgilendik. Bu kısımda ise; Destek Vektör Makinelerini kullanarak, doğrusal olmayan regresyon problemlerini çözümü üzerine odaklanılmıştır. Ve metod destek vektör regresyon olarak isimlendirilmektedir.

Destek vektör regresyonda da, sınıflandırma algoritmasında olduğu gibi, doğrusal öğrenme metotlarını ve çekirdek hilesi (kernel trick) kullanılarak elde edilen lineer olmayan fonksiyonlar kullanılarak maksimum marj metodunun temel özelliklerinin bulunması amaçlanmaktadır. Regresyon problemleri için, gürültünün (additive noise) ardındaki dağılım uzun bir uzantıya sahip olduğu durumlarda regresörde meydana gelen kötü performansa sahip olan aykırı verilerin var olması ile birlikte geleneksel en küçük kareler tahmin edicisi (least-square estimator) uygulanamayabilir [Haykin, 2001]. Bu sebeptendir ki, tasarlanan model içinde ufak farklılıklara karşın ϵ duyarsızlık kayıp fonksiyonu tanımlanmıştır. Duyarsızlık kayıp fonksiyonunun regresyon doğru üzerindeki lokasyonu Şekil 5.9’da gösterilmektedir.



Şekil 5.10. Lineer DVM ε kayıp fonksiyonu

Varsayalım ki; f fonksiyonu X 'de tanımlı reel değerlikli bir fonksiyon olsun. ε duyarsızlık kayıp fonksiyonu $L^\varepsilon = (x, y, f)$ Eş 5.78'deki gibi ifade edilmektedir.

$$L^\varepsilon = (x, y, f) = |y - f(x)|_\varepsilon = \max(0, |y - f(x) - \varepsilon|) \quad (5.78)$$

Şayet arzu edilen sistem çıkışı olan y değeri ile tahmin edicinin çıktısı $f(x)$ arasındaki farkın mutlak değeri ε 'dan küçük veya sıfıra eşit ise, $L^\varepsilon = (x, y, f) = 0$ Aksi halde, sapmanın mutlak değerinden ε değerinin farkına eşit olmaktadır. Doğrusal olmayan bir regresyon modeli;

$$y = g(x) + v \quad (5.79)$$

Şeklinde tanımlanacak olursa; v yani toplanır gürültü(additive noise) terimi, çıktı vektör olan $\mathbf{x}$ dan bağımsızdır. Fonksiyon $g(\cdot)$ 'nin ve toplanır gürültü terimi v 'nin istatistiğinin bilinmesi oldukça zordur. Eğitim verilerinin bir kümesi olan $S = \{(x_1, y_1), \dots, (x_n, y_n)\}$ ve Eş. 5.80'deki fonksiyon sınıfı ise modelimizde var olan bilgilerdir [Christianini, 2000].

$$F = \{f(x) = w^T x + b, w \in R^m, b \in R\} \quad (5.80)$$

Destek vektör regresyonunda hedef uygun w ve b parametrelerini belirleyerek $f(x)$, bilinmeyen hedef fonksiyon $g(x)$ 'e yaklaşımdır. Optimizasyonda primal problem aşağıdaki gibi ifade edilir.

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i') \quad \xi_i, \xi_i' \geq 0 \quad i = 1, \dots, n \quad (5.81)$$

$$(w^T x_i + b) - y_i \leq \varepsilon + \xi_i \quad i = 1, 2, \dots, n \quad (5.82)$$

$$y_i - (w^T x_i + b) \leq \varepsilon + \xi_i' \quad i = 1, 2, \dots, n \quad (5.83)$$

Lagrange çarpanları ile dual problem aşağıdaki gibi tanımlanmaktadır.

$$\max_{a, \hat{a}} W(a, \hat{a}) = \sum_{i=1}^n y_i (\hat{a}_i - a_i) - \varepsilon \sum_{i=1}^n (\hat{a}_i + a_i) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\hat{a}_i - a_i)(\hat{a}_j - a_j) x_i^T x_j \quad (5.84)$$

$$\sum_{i=1}^n (\hat{a}_i - a_i) = 0 \quad 0 \leq \hat{a}_i, a_i \leq C \quad i = 1, 2, \dots, n \quad (5.85)$$

Eş. 5.85 bir optimizasyon problemidir ve bunun için çarpım çekirdeği gösterilebilir ve lineer olmayan fonksiyonlar, çekirdek uzayında doğrusal öğrenme makineleri yolu ile elde edilebilmesi amacıyla regresyon algoritması öznitelik uzayına genişletilebilir [Christianini, 2000].

Destek vektör makinaları uygulamalarında regresyon ve sınıflama işlemleri karşılaştırıldığında, destek vektör regresyon ε gibi ilave bir serbest parametreye sahiptir. İki parametre olan ε ve C Vapnik Chervonenkis boyutunu bias sıfır olduğu durumlarda kontrol etmektedirler

$$f(x) = w^T x = \sum_{i=1}^n (\hat{a}_i - a_i) K(x_i, x) \quad (5.86)$$

Eş. 5.86'da destek vektör regresyon fonksiyonun genel denklemi görülmektedir. Burada α lagrange çarpanlarını göstermektedir. ε ve C kullanıcı tarafından seçilmelidirler ve regresyon uygulamasında karmaşıklığın kontrolünü etkilemekte öncüdürler. Optimal bir yaklaşım fonksiyonu elde etmek için ε ve C değerlerinin senkronize olarak nasıl seçilmesi gerektiği konusu farklı hipotezler ortaya çıkmasına rağmen, henüz netleşmemiş bir araştırma sorunudur [Christianini, 2000].

5.4.8. En küçük kareler destek vektör regresyon

En küçük kareler destek vektör makineleri(least square support vector machines) 1999 yılında Suykens ve Vandewalle tarafından önerilmiştir [Suykens ve Vandewalle, 1999]. Bir destek vektör makinesi çeşidi olan en küçük kareler destek vektör makinasının(least square support vector machine) teorik temelleri yine standart destek vektör sınıflandırıcılarında olduğu gibi iki sınıflı sınıflandırma düşünülerek oluşturulmaktadır. Destek vektör makine sınıflandırıcılarındaki kullanılan ikinci dereceden programlama yöntemleri en küçük kareler destek vektör makinelerinde kullanılmamaktadır. Model kurulumunda, bu tür ikinci derece programlama yöntemi yerine lineer eşitlik kümesi tercih edilmektedir.

$$\frac{1}{2} \|w\|^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2 \quad (5.87)$$

$$y_i [(w \cdot x_i) + w_0] = 1 - \xi_i \quad i = 1, 2, \dots, n \quad (5.88)$$

Eş.5.87'de verilen formül Eş.5.88'de ifade edilen koşula bağlı olarak en küçüklenmesi gerekmektedir. EKK-DVM için verilen Eş. 5.88'deki eşitlik durumuna dikkat edilecek olursa, destek vektör makine sınıflandırıcılarda Eş. 5.88'deki bu denklem eşitsizlik durumundadır. EKK-DVM'da standart destek vektör makine sınıflandırıcılarda olduğu gibi Eş.5.87'deki ana denklem Eş. 5.89'daki gibi dual probleme dönüştürülmektedir [Suykens ve Vandewalle, 1999]. Daha sonra optimizasyon çözümü bu dual problem eşiğinde çözülmelidir.

$$Q(w, b, a, \xi) = \frac{1}{2} \|w\|^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2 - \sum_{i=1}^n a_i \{y_i [(wx_i) + w_0] - 1 + \xi_i\} \quad (5.89)$$

Eş. 5.89’da ifade edilen formülün standart destek vektör makine sınıflandırıcılarda kullanılan formülden bir farkı yoktur. Tek fark “ a ” çoğullayıcılarının standart destek vektör makine sınıflandırıcılarda pozitif olması gerekirken, en küçük kareler destek vektör makinelerinde ise pozitif veya negatif olabilmesidir [Tsujinishi ve Abe, 2003]. Bu formüsel fark ile birlikte eğitim zamanı avantajı gibi nedenlerle en küçük kareler destek vektör makine regressörleri standart destek vektör makine regresörlerinden ayrılmaktadır.

Daha önce teorik açıklamasını yaptığımız destek vektör regresyonu (ε -DVR olarak da bilinmektedir.) ile en küçük kareler destek vektör regresyonu yukarıda ifade edildiği gibi benzer matematiksel eşitsizliklerden oluşmakla birlikte farklı optimizasyon çözümleri ile açıklanmaktadır. Bunun sonucunda iki regresyon metodu arasındaki temel fark; ε -DVR’de eğitim için, hata çıkışlarının kontrolünün ε , C ve σ ile yapılırken, EKK-DVR’de eğitimin sadece iki değişken γ ve σ kullanılarak yapılmasıdır.

Destek vektör sınıflandırma uygulamalarında performans; bazı uygulamalarda standart DVM öğrenme metoduna yaklaşıp bile düşük çıkma ihtimalide oldukça fazladır. Bunun nedeni eğitime aşamasında daha kuvvetli ama zaman alan ikinci dereceden programlama yerine daha basit ama kısa sürede uygulanabilen doğrusal(lineer) programlamayı kullanmasındandır.

6. YÖNTEMLERİN UYGULANMASI VE SAYISAL SONUÇLAR

6.1. Giriş Verilerinin Belirlenmesi

Son yıllarda bilimsel literatürde elektrik tüketim tahmini için birçok yöntem geliştirilmiş ve değişik algoritmalar kullanılmıştır. Yine bu çalışmalarda girdi olarak birçok farklı bağımsız değişken ve farklı modeller tercih edildiği görülmektedir. Bölüm 5.1’de de ifade edildiği üzere elektrik tüketimini etkileyen en önemli faktörler(parametreler) arasında; nüfus ve demografik göstergeler, toplam tüketici sayısı, ortalama hane halkı büyüklüğü, elektrikli hane sayısı, köy oranı, çok odalı konut yüzdesi, brüt elektrik üretimi, kurulu güç şehirleşme oranı, istihdam verileri ve elektrik fiyatı, gayri safi yurt içi hâsıla(GSYİH) ve endüstriyel planlar gösterilebilir. Bu etkenlerden bazıları elde edilecek tahminler üzerinde doğrudan ve büyük oranda etkiye sahipken, bazıları ise dolaylı şekilde ve daha zayıf etki göstermektedir. Talebi etkilediği saptanan faktörler, etki derecelerine bağlı olarak elektrik tüketim tahmin modellerinde bağımsız değişken olarak kullanılmaktadır.

Chen ve arkadaşları tarafından yapılan çalışmada elektrik tüketimi ile ekonomik büyüme arasında nedensellik ilişkisinin olmadığı, yani elektrik tüketiminin ekonomik büyüme ile ilişkili olmadığını analizlerle ortaya koymuşlardır[Chen ve ark., 2007]. Elektrik tüketimi ile ekonomik bir gösterge olan gayri safi yurt içi hâsılanın(GSYİH) birbirini etkileme yönünün ne yönde olduğu, yani elektrik tüketimindeki artışın mı GSYİH’ı yoksa GSYİH’nın mı elektrik tüketimini etkilediği hususunda tartışmalar halen devam etmektedir. Özellikle bu tür bir ilişkinin ülkelere göre farklılıklar gösterdiği görülmektedir. Özellikle Türkiye’de gayri safi yurt içi hâsılanın(GSYİH) düşük olduğu dönemlerde dahi elektrik enerjisi tüketiminde artışlar görülmektedir. Türkiye’de elektrik tüketiminin yıllar itibari ile seyri incelendiğinde özellikle ekonomik krizlerden etkilendiği görülmektedir. Ekonomik krizler ise önceden tahminlemesi zor veya saptanması güç süreçlerdir. Çalışmamızda yukarıda bahsi edilen bu nedenlerle GSYİH’ye bağımsız değişken(etkileyici) olarak hiçbir modelde yer verilmemiştir.

Çalışmamızda kullanılacak bağımsız değişken seçimi için bir sonraki bölümde çoklu lineer regresyon sonuçları ile de verilecek, üç farklı model kurulmuştur. Bu modeller üzerinde yapılan korelasyon ve regresyon sonuçları ile bağımsız değişkenlerin, bağımlı değişken üzerindeki etkisi incelenmiştir. Bu modeller arasında “*Model 3*” olarak isimlendirilen model en uygun model olarak seçilmiştir.

Çalışmamızdaki tüm analizlerde kullanacağımız “*Model 3*” içerisinde yer alan bağımsız değişkenler; *kurulu güç*(installed power), *brüt elektrik üretimi*(gross electricity generation), *nüfus*(population) ve *toplam abone sayısı*(total subscribership) verileri olacaktır.

Yine çalışmamızda modellerin eğitiminde kullanacağımız bağımsız değişkenlerin geçmiş bilgilerinin elde edilmesi için; Türkiye toplam kurulu güç ve brüt elektrik üretimi verileri için TEİAŞ istatistik veri tabanı, nüfus bilgileri için ise TÜİK veri tabanı kullanılmıştır. Türkiye’deki toplam elektrik abone sayısının elde edilmesi için ise bir kamu kuruluşu olan TEDAŞ ve diğer özel elektrik dağıtım şirketlerinin geçmiş istatistiksel bilgilerinden faydalanılmıştır.

Türkiye’de özellikle 1970 öncesi toplam abone sayısı ve nüfus bilgilerinin doğru ve sağlıklı olmaması nedeniyle çalışmamızda geçmiş verisi olarak 1970-2009 yılı verileri kullanılmıştır. Bilindiği üzere; 1970-2009 yılları arası dönemde Türkiye’de nüfus sayımının 5 yılda bir yapıldığı göz önüne alındığında, ara değerler TÜİK kayıtlarında mevcut değildir. Bu ara değerlerin bulunması için *ara değer hesabı* (interpolation) uygulanmıştır. Modeller kurulduktan sonra gelecek tüketimleri tahmin edebilmemiz için gerekli olan gelecek giriş verilerinden; kurulu güç ve brüt üretim için gelecek öngörüler, EPDK tarafından lisans verilmiş ve önümüzdeki beş yıl içerisinde üretime başlayacak santraller de göz önüne alınarak belirlenen TEİAŞ 2011-2020 yılı projeksiyon bilgileri kullanılacaktır. Türkiye nüfusu için gelecek tahmin bilgilerinin elde edilmesinde ise DPT ve TÜİK tarafından yapılan öngörülerden faydalanılmıştır. Türkiye’de hiçbir resmi kurum tarafından elektrik abone sayısı ile ilgili olarak herhangi bir gelecek öngörüsü yapılmadığından, çalışmamızda *dış değer hesabı*(extrapolasyon) uygulanmıştır.

Çalışmamızda tasarımı yapılan tüm tahmin modellerinde giriş verilerinin 2/3'ü eğitim ve 1/3'ü test için kullanılacaktır. 2010 yılı verisi ise doğrulama(validation) amacıyla kullanılmıştır.¹

Çizelge 6.1 ve Çizelge 6.2'de sırasıyla tasarım modellerinde kullanılacak eğitim ve test kümeleri verilmektedir.

Çizelge 6.1. Model eğitimleri için giriş verileri.


Yıl	Kurulu güç(GW)	Brüt Elektrik Üretimi(TWh)	Nüfus(Milyon)	Abone Sayısı(Milyon)	Net Elektrik Tüketimi(TWh)
1970	2,235	8,623	35,32	4,43	7,31
1971	2,578	9,781	36,22	4,78	8,29
1973	3,193	12,43	38,07	5,52	10,53
1974	3,732	13,48	39,04	5,92	11,36
1976	4,36	18,28	40,92	6,79	16,08
1977	4,73	20,56	41,77	7,22	17,97
1979	5,12	22,52	43,53	8,32	19,63
1980	5,12	23,28	44,44	8,75	20,4
1982	6,64	26,55	46,69	10,01	23,59
1983	6,94	27,35	47,86	10,62	24,47
1985	9,12	34,22	50,31	11,85	29,71
1986	10,12	39,69	51,48	12,53	32,21
1988	14,52	48,05	53,27	13,95	39,72
1989	15,81	52,04	54,19	14,69	43,12
1991	17,21	60,25	56,06	16,28	49,28
1992	18,72	67,34	56,99	16,97	53,99
1994	20,86	78,32	58,84	18,7	61,4
1995	20,95	86,25	59,76	19,47	67,39
1997	21,89	103,3	61,58	21,12	81,88
1998	23,35	111,02	62,46	21,99	87,71
2000	27,26	124,92	64,26	24,02	98,3
2001	28,33	122,72	65,14	24,81	97,07
2003	35,59	140,58	66,87	26,62	111,77
2004	36,82	150,7	67,73	27,71	121,14
2006	40,56	176,3	69,42	29,37	144,09
2007	40,84	191,56	70,26	30,02	155,14
2009	43,49	216,46	71,9	31,85	158,06

¹ 2010 yılı istatistiki bilgilerinin, ilgili kurumlarca yayınlanması geciktüğinden, 2010 yılı verileri tasarlanan modellerde ancak doğrulama amacıyla kullanılabilmiştir.


Çizelge 6.2. Model eğitimleri için test verileri

Yıl	Kurulu güç(GW)	Brüt Elektrik Üretimi(TWh)	Nüfus(Milyon)	Abone Sayısı(Milyon)	Net Elektrik Tüketimi(TWh)
1972	2,711	11,24	37,13	5,14	9,53
1975	4,19	15,62	40,03	6,35	13,49
1978	4,87	21,73	42,64	7,81	18,93
1981	5,54	24,67	45,54	9,43	22,03
1984	8,46	30,61	49,07	11,19	27,64
1987	12,5	44,35	52,37	13,22	36,7
1990	16,32	57,54	55,12	15,54	46,82
1993	20,34	73,81	57,91	17,77	59,24
1996	21,25	94,86	60,67	20,58	74,16
1999	26,12	116,44	63,37	22,94	91,2
2002	31,85	129,4	66,01	25,68	102,95
2005	38,84	161,96	68,58	28,44	130,26
2008	41,82	198,42	71,08	31,01	161,95


Modellerimizde kullanılacak giriş değişkenlerinin(bağımsız değişkenlerin) yıllar itibari ile gelecek öngörü noktalarını da içeren gelişimi Şekil 6.1, Şekil 6.2, Şekil 6.3, ve Şekil 6.4’de gösterilmektedir. Bu şekillerden görüleceği üzere özellikle Türkiye nüfus sayıları ve toplam elektrik abone sayılarının yıllar içerisinde gelişimi düzgün lineer(doğrusal) bir gelişim seyrederken, Türkiye kurulu gücü ile brüt elektrik üretimindeki gelişim her ne kadar doğrusal bir trend gösterse de belli yıllarda trend doğrusundan sapmalar göstermiştir.




Şekil 6.1. Türkiye brüt üretiminin yıllar itibari ile gelişimi



Şekil 6.2. Türkiye’de nüfusun yıllar itibari ile gelişimi.



Şekil 6.3. Türkiye’de kurulu gücün yıllar itibari ile gelişimi.



Şekil 6.4. Türkiye’de toplam abonenin sayısının yıllar itibari ile gelişimi.

6.2. Ön ve Son Verilerin İşlenmesi

Veri normalizasyonu, özellikle yapay sinir ağları gibi işlemci elemanlarından oluşan sistemlerde, aşırı değerlenmiş kümülatif toplamaların oluşturacağı olumsuzlukların engellenmesi için önemlidir. Eğitimden önce giriş verilerinin belirli bir aralığa transferi ile ölçeklenme, diğer bir deyişle normalizasyon yapılmış olur.

Çalışmamızda her bir giriş uzayı $[-1,+1]$ aralığına aşağıda Eş. 6.1’de verilen formül ile ölçeklendirilmiştir.(Matlab programında aynı işlem için *premnmx(p,t)* komutuda kullanılmıştır.)

$$X_{yeni} = 2 \frac{X - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (6.1)$$

Ölçeklendirilmiş veriler tahmin modelleri ile işlendikten sonra çıkan sonuçlar tekrar denormalize edilerek orijinal boyutlarına dönüştürülmesi gereklidir. Bu kapsamda da çalışmamızda denormalize işlemi Matlab2009R programında “*postmnmx(an, mint, maxt)*” komutu kullanılarak yapılmıştır.(Aynı işlem Eş.6.1’deki formülasyonun yeniden kullanılması ile de yapılabilmektedir.)

6.3. Performans Fonksiyonları

Çalışmamızda farklı algoritmalarla tasarımını yapacağımız tahmin modellerinin performansını değerlendirmek için bilimsel literatürde kabul görmüş, tipik performans fonksiyonlarından hemen hemen tümünden faydalanılmaktadır. Bunlar maksimum hata(*MaxError*), ortalama mutlak yüzde hata(*mean absolute percent error-MAPE*), ortalama kare hata(*mean square error-MSE*), ortalama kare hatanın karekökü(*root mean square error-RMSE*) ve toplam karesel hata(*sum square error-SSE*) olarak ifade edilebilir. Bu performans kriterlerinin matematiksel gösterimi aşağıdaki eşitliklerde verilmektedir.

$$MaxError = \max |y_{tahmin} - y_{gerçek}| \quad (6.2)$$

$$MAPE(\%) = 100 \times \frac{\sum_{k=1}^N \left| \frac{y_{gerçek} - y_{tahmin}}{y_{gerçek}} \right|}{N} \quad (6.3)$$

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2 \quad (6.4)$$

$$RMSE = \sqrt{\frac{\sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2}{N}} \quad (6.5)$$

$$SSE = \sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2 \quad (6.6)$$

6.4. Çoklu Lineer Regresyon çözümü

Bilindiği gibi Y bağımlı değişkeni, çok sayıda bağımsız X değişkeni ile ifade ediliyor ise bu analize “Çoklu Regresyon Analizi(Multiple Regression Analysis) denilmektedir.

Bu bölümde, daha önce teorik kapsamı anlatılan çoklu doğrusal(lineer) regresyon modelinin Türkiye elektrik tüketim modellemesi çalışması yapılmıştır. Bağımsız değişkenlerin, bağımlı değişkeni üzerindeki etkisini incelemek ve en iyi regresyon sonucunu bulmak için üç farklı model üzerinde çalışma yapılmıştır. Bu modeller aşağıdaki eşitliklerde ve görsel olarak Şekil 6.5’de gösterilmiştir.

x_1 :Kurulu Güç(Installed Capacity)

x_2 :Brüt Elektrik Üretimi(Gross Electricity Generation)

x_3 :Nüfus(Population)

x_4 :Toplam Abone sayısı(Total Subscribership)


x_5 :İhracat(Export)

x_6 :İthalat(Import)

Model 1: $y = b_1x_2 + c_1x_3 + f_1$

Model 2: $y = a_1x_1 + b_2x_2 + c_2x_3 + d_1x_4 + e_1x_5 + g_1x_6 + f_2$

Model 3: $y = a_2x_1 + b_3x_2 + c_3x_3 + d_2x_4 + f_2$



Şekil 6.5. Tüketim modeli seçimi

Bu modellerde bağımlı değişken parametresi olarak; x_1 :Kurulu Güç(Installed Capacity), x_2 :Brüt Elektrik Üretimi(Gross Electricity Generation), x_3 :Nüfus(Population), x_4 :Toplam Abone sayısı(Total Subscribership), x_5 :İhracat(Export), x_6 :İthalat(Import) şeklinde gösterilmiştir.

Regresyon katsayılarının bulunması ve modeller üzerindeki performansların analiz edilmesi için MATLAB2009 araç kutusu kullanılmıştır.

Çizelge 6.3. Regresyon katsayıları

	a	b	c	d	e	g	f
<i>Model 1</i>	-	1,78801	0.027973	-	-	-	-49567
<i>Model 2</i>	0.00522	0.004977	1,57688	0.99865	0.27655	0.04896	-29233
<i>Model 3</i>	0,41689	0,58500	-0,56730	1,42719	-	-	16,24841

Çizelge 6.4. Regresyon parametreleri

	Adjusted R ²	Test Hatası(RMSE)	Eğitim Hatası(RMSE)
<i>Model 1</i>	0.988	7,88	1,40
<i>Model 2</i>	0.996	4,04	1,09
<i>Model 3</i>	0.997	2,54	2,46

Sonuçlar dikkatle incelendiğinde Model 1 ve Model 2’de eğitim hataları çok düşük çıkmasına rağmen test hataları çok yüksek bulunmuştur. Model 3 de ise eğitim hatası Model 1 ve Model 2’ye göre biraz yüksek çıkmasına rağmen test hatası RMSE’de 2.54 gibi optimal bir değeri yakalamıştır. Yine R² katsayısının yüksek olması da model 3’ün daha optimal olduğunu göstermektedir. Bu nedenlerle regresyon sonuçları kapsamında ve ileride çalışmamızda analizi yapılacak YSA ve EKK-DVM uygulamasında Model 3’de yer alan regresyon denklemi esas alınacaktır. Sonuç olarak; Model 3 üzerinde, çoklu lineer regresyon çalışmasına ait performans kriterleri sonuçları Çizelge 6.5’de verilmektedir.

Çizelge 6.5. Model 3 regresyon kalite parametreleri

	MAPE	MaxError	MSE	RMSE	SSE
Eğitim	4,01	7,62	6,06	2,46	163,69
Test	3,34	8,25	6,45	2,54	83,79

6.5. Yapay Sinir Ağı Analizi

Çalışmamızda, Türkiye elektrik tüketim tahmini için çok katmanlı ileri beslemeli-geri yayımlı yapay sinir ağı tercih edilmiştir. Ağ tasarımı; giriş verileri olarak çalışmamızda baz alınan Model 3 verileri esas alınmıştır.

Ağ tasarımı için MATLAB2009 programı kullanılmış, m-file üzerinde kod yazılarak 1970 yılından 2009 yılına kadar olan verilerin 2/3'ü eğitim ve 1/3'ü test için kullanılmıştır. Çalışmamızda verilerimize en uygun ağ yapısının bulunması için birçok ağ yapısı üzerinde çalışmalar yapılmıştır. Yine çok sayıda öğrenme algoritması kullanılarak; ağın çıkışlarının, hata oranı en düşük cevabı verecek öğrenme metodunu bulması için çalışılmıştır. Katman sayıları ve katmanlardaki nöron sayıları belli bir seviyeden başlanarak artırma ve eksiltme yöntemleri ile en uygun çözüme ulaşılmaya çalışılmıştır. Bu kapsamda Çizelge 6.6.'da Gradient descent öğrenme algoritmali çeşitli ağ yapılarında eğitim ve test araştırma sonuçları verilmiştir. Yine devamında Çizelge 6.7'de Levenberg- Marquart öğrenme ve Çizelge 6.8'de Resilient backpropagation öğrenmeli çeşitli ağ yapılarının sonuçları sunulmuştur.

Çizelge 6.6. Gradient descent öğrenme tabanlı tasarım

Öğrenme Algoritması	Kod	Katman sayısı	Aktivasyon fonksiyonu	Eğitim hatası(%)	Test Hatası(%)	Epoch sayısı
Gradient Descent	traingdx	[10 9 1]	tansig-tansig-purelin	1,86	4,18	89
		[10 5 1]	tansig-tansig-purelin	3,58	3,41	185
		[10 5 1]	purelin-purelin-purelin	4,52	3,77	319
		[10 5 1]	purelin-tansig-purelin	3,49	3,47	278
		[5 5 1]	tansig-tansig-purelin	4,68	4,53	164
		[5 5 1]	purelin-tansig-purelin	3,7	3,78	133
		[10 1]	tansig-purelin	5,11	3,49	58
		[10 1]	purelin-purelin	4,22	4,25	87


Çizelge 6.7. Levenberg-Marquart öğrenme tabanlı tasarım

Öğrenme Algoritması	Kod	Katman sayısı	Aktivasyon fonksiyonu	Eğitim hatası (%)	Test Hatası (%)	Epoch sayısı
Levenberg-Marquart	trainlm	[10 9 1]	tansig-tansig-purelin	1,02	3,77	34
		[10 5 1]	tansig-tansig-purelin	2,66	3,33	23
		[10 5 1]	purelin-purelin-purelin	3,01	4,31	51
		[10 9 1]	purelin-tansig-purelin	0,11	3,31	43
		[5 5 1]	tansig-tansig-purelin	4,12	3,64	12
		[5 5 1]	purelin-tansig-purelin	4,29	3,35	5
		[10 1]	tansig-purelin	3,87	3,75	27
		[10 1]	purelin-purelin	4,06	3,56	46

Çizelge 6.8. Resilient backpropagation öğrenme tabanlı tasarım

Öğrenme Algoritması	Kod	Katman sayısı	Aktivasyon fonksiyonu	Eğitim hatası (%)	Test Hatası (%)	Epoch
Resilient Backpropagation	trainrp	[10 9 1]	tansig-tansig-purelin	2,55	3,44	163
		[10 5 1]	tansig-tansig-purelin	3,33	4,8	194
		[10 5 1]	purelin-purelin-purelin	3,87	4,03	159
		[10 9 1]	purelin-tansig-purelin	2,09	4,51	105
		[5 5 1]	tansig-tansig-purelin	3,29	3,32	166
		[5 5 1]	purelin-tansig-purelin	4,87	3,88	123
		[10 1]	tansig-purelin	3,5	4,24	79
		[10 1]	purelin-purelin	3,56	4,72	97

Sonuçlar ışığında çalışmamızda; en düşük test ve eğitim hatası çıkışı üreten Levenberg-Marquart öğrenmeli çok katmanlı ileri beslemeli-geri yayımlı bir yapay sinir ağı tercih edilmiştir. Şekil 6.6'da gösterildiği gibi birinci gizli katmanda 10 nöron, ikinci gizli katmanda 9 nöron, çıkış katmanında ise bir nöron şeklinde bir ağ konfigürasyonu kullanılmıştır.




Şekil 6.6. Oluşturulan YSA gizli katman mimarisi

MATLAB2009 programında, oluşturulan ağ nesnesi için aşağıda ifade edilen yapı oluşturulmuştur.


```
net = newff([-1 1;-1 1;-1 1;-1 1],[10 9 1],{'purelin','tansig','purelin'},'trainlm')
```

Bu nesne yapısı üzerinden de görüleceği üzere; 1. gizli katmandaki nöronlarda “*purelin*”, 2. gizli katmandaki nöronlarda “*tansig*” ve çıkış katmanında ise yine “*purelin*” aktivasyon fonksiyonları kullanılmıştır. Ayrıca öğrenme oranı 0,1($\text{net.trainParam.lr}=0.1$), moment katsayısı olarak 0,9($\text{net.trainParam.mc}=0.9$) ve performans fonksiyonu olarak ise ortalama kare hata($\text{net.performFcn} = \text{'mse'}$) kullanılmıştır.

Çalışmamızda modellenen yapay sinir ağının, Şekil 6.7.’de eğitim sürecinde giriş verilerini öğrenebilmesinde uyum ve Şekil 6.8’de ise eğitim sürecinden sonra ağın hedef çıkışlara olan uyumunu gösteren ağ çıkışları verilmiştir.



Şekil 6.7. Eğitim hedef performans eğrisi



Şekil 6.8. YSA çıkışlarını hedef performans uyum eğrisi

Çalışmamızda tercih ettiğimiz en düşük test ve eğitim hatası çıkışı üreten Levenberg-Marquart öğrenme algoritmali çok katmanlı ileri beslemeli-geri yayımlı bir yapay sinir ağı eğitim ve test sonuçlarının performans kriter sonuçları Çizelge 6.9’da sunulmuştur.

Çizelge 6.9. YSA eğitim ve test performans kriterleri sonuçları

Eğitim				
<i>MAPE</i> (%)	<i>MaxError</i>	<i>MSE</i>	<i>RMSE</i>	<i>SSE</i>
0,906	0,84	0,11	0,319	2,75

Test				
<i>MAPE</i> (%)	<i>MaxError</i>	<i>MSE</i>	<i>RMSE</i>	<i>SSE</i>
1,19	5,92	3,3	1,82	42,85

6.6. Öz örgütlenmeli harita(SOM) analizi

Çalışmamızda SOM ağının tasarımı için, MATLAB7.9 programı kullanılmıştır. Ağın kurulumu için program içerisinde yer alan “*newsom*” ağ nesnesi içerisinde, bir SOM ağı tasarımı için tüm bileşenler tanımlanmıştır. Bahse konu ağ tasarımında öncelikle giriş verilerinin dağılımı ve birimsel farklılıkları nedeni ile -1 ve +1 aralığında normalize edilerek, matris formunda ağ nesnesine bu şekilde tanımlaması yapılmıştır.

İkinci adımda, çıkış katmanının boyutları belirlenmesi gerekmektedir. Program içerisinde mevcut ağ nesnesinde hâlihazırda [5,8] boyutu tanımlıdır. Bu boyut en ve boy olarak artırma eksiltme yolu diğer bir ifade ile deneme yanılma yöntemi ile değiştirilerek, optimum model arayışları gerçekleştirilmiştir.


Üçüncü adımda, SOM ağının topolojik fonksiyonun seçimi yapılmalıdır. Bunun için ağ nesnesinde üç farklı yapıdan söz edilebilir. Bunlar ‘*hextop*’, ‘*gridtop*’ veya ‘*randtop*’dur. Mesafe fonksiyonu olarak ise ‘*linkdist*’, ‘*dist*’ veya ‘*mandist*’ fonksiyonlarının ayrı ayrı uygulaması gerçekleştirilmiştir.

Dördüncü adımda, derecelendirme öğrenme oranı(ordering phase learning rate-OLR), adım değeri(ordering phase steps-OSTEPS), ayarlama öğrenme oranı(tuning phase learning rate-TLR) ve komşuluk mesafesi(TND) oranları ağ nesnesinde sırası ile “*default*” olarak yani hazır olarak bulunan değerlerden başlatılmıştır. (OLR: 0,9, OSTEPS:1000, TLR:0,02, TND:1)

Ağ için ‘*hextop*’ topolojisi ve “*dist*” mesafe fonksiyonu kullanarak, çıkış katmanı 9x9 boyutunda bir harita üzerine yapılandırılmıştır. Öz örgütlenmeli haritalar, danışmansız(unsupervised) öğrenme stratejisine göre çalıştığından çıkış verileri ağa gösterilmemiştir.

p=[input1;input2;input3;input4]


`net=train(net,p)` fonksiyonu ile ağ eğitimi yapılmıştır. Eğitilen SOM ağı ile birlikte özellikle eğitim verilerinin az olması nedeni ile, ileriye dönük öngörü yapılabilecek bir öbekleme olmadığı (Şekil 6.9) ve dolayısıyla Türkiye net elektrik tüketiminin uzun dönemli tahmininde, mevcut bilgi yapısıyla SOM ağının yeni girişlere cevap vermesinin elde olan mevcut mümkün gözükmediği değerlendirilmiştir.



Şekil 6.9. SOM ağı komşu ağırlık mesafeleri ve pozisyonları

6.7. En Küçük Kareler Destek Vektör Makineleri Analizi

Daha önce teorik temellerini Bölüm 5.4’de verdiğimiz destek vektör makinelerinin iki ayrı normda incelendiğini bunların sınıflandırma ve regresyon temelli olduğunu belirtmiştik. Temelde destek vektör regresyonu(ε -DVR) ile en küçük kareler destek vektör regresyonu(EKK-DVR) benzer matematiksel eşitsizliklerden oluşmakla birlikte farklı ve karmaşık optimizasyon çözümleri içerir. Optimizasyon çözümleri sonucunda iki regresyon modeli arasındaki temel fark; ε -DVR’de eğitim için, hata çıkışlarının kontrolünün ε , C ve σ ile yapılırken, EKK-DVR’de eğitimin daha basit, sade ve çözüme sadece iki değişken C ve σ kullanılarak yapılmasıdır. Şekil 6.10’da basit bir regresyon doğrusu gösterilmektedir.



Şekil 6.10. Destek vektör regresyon doğrusu


Burada ε çıkışta izin verilebilir maksimum hata, C düzenlileştirme parametresi(regularization parameter), σ kernel fonksiyonu band genişliği(spread of the function) olarak ifade edilebilmektedir.

Özellikle kernel fonksiyonuna özgü parametrelerin çok küçük ve çok büyük seçilmesi optimum regresyon doğrusunun oluşmasında ciddi değişiklikler meydana getirecektir. Özetle uygun parametre seçimi EKK-DVR’nin performansını direkt olarak etkileyen bir faktördür. Çalışmamızda EKK-DVM eğitimi için

MATLAB2009b programı kullanılmıştır. Çalışmada, Belçikalı bilim insanları grubunun yayınladığı (<http://www.esat.kuleuven.be/sista/lssvmlab>), internet adreslerinden indirilebilen kullanıma açık “*LS-SVMlab1.8 araç kutusu*” ve araç kutusunun iyi anlaşılabilmesi için “*LS-SVMlab Toolbox User’s Guide version 1.8*” çalışmada rehber olarak kullanılmıştır. Çalışmamızda MATLAB programında kullanılan en küçük kareler destek vektör makinası kurulum nesnesi aşağıdaki şekilde oluşturulmuştur.

```
[alpha, b]=trainlssvm({X,Y,type,gam,sig2,"RBF_kernel"})
```

Kurulum nesnesinden de görüleceği üzere; kernel fonksiyonu olarak radyal tabanlı fonksiyon(Radial Basis Function-RBF) kullanılmıştır. C(regularization) ve σ^2 parametrelerinin belirlenmesi ve değiştirilmesi süreçlerini gösterir algoritma Şekil 6.11’da verilmektedir.



Şekil 6.11. Sigma2 ve gama parametrelerini belirleme algoritması

Algoritma sonucunda tüketim tahmin modelimizin en iyi hata oranına sahip bir regresyon makinesi özelliğine sahip olması için; deneylerle elde edilen optimum Gama(γ)(veya C) ve sig2(σ^2) parametreleri Çizelge 6.10'da verilmiştir. Çizelge 6.10'da da görüleceği üzere; tüketim tahmin modelimizde oluşturacağımız en küçük kareler destek vektör makinesi, eğitimde en düşük ortalama kare hatayı(MSE) $\gamma=50$ ve $\sigma^2=0,3$ olduğu durumda yakaladığı görülecektir. Çizelge 6.10'da Gama(γ) ve sig2(σ^2) için belirlenen [30-200] ve [0,1-1] aralıkları dışında kalan üst ve alt değerlerde büyük değişiklikler olmamıştır.

Çizelge 6.10. sigma2 ve gama parametre MSE hata değişimi.


Sima2/gama(veyaC)		C(veya gama)				
		30	50	100	150	200
σ^2	0,1	0,287	0,1822	0,265	0,312	0,342
	0,3	0,1967	0,1699	0,1743	0,1769	0,4895
	0,5	0,288	0,198	0,222	0,344	0,385
	0,7	0,313	0,212	0,342	0,505	3,18
	1	0,464	0,233	2,1	2,85	3,01

En küçük kareler destek vektör makinesinin optimal parametre seçimi ile birlikte eğitim süreci tamamlandıktan sonra eğitim ve test verimiz üzerinde oluşan tüm performans kriterler sonuçları aşağıda Çizelge 6.11'de verilmektedir.

Çizelge 6.11. EKK-DVM eğitim ve test sonuçları

EKK-DVM Eğitim				
MAPE(%)	MaxError	MSE	RMSE	SSE
0,876	1,05	0,1699	0,412	4,59
EKK-DVM Test				
MAPE(%)	MaxError	MSE	RMSE	SSE
1,004	4,40	2,060	1,435	26,782

Şekil 6.12'de En küçük kareler destek vektör makinesinin(EKK-DVM) parametre seçimi ile birlikte eğitim sürecinin tamamlanması sonucu elde edilmiş regresyon eğrisi görülmektedir.



Şekil 6.12. EKK-DVM eğitim sonucu elde edilen regresyon doğrusu.

6.8. Sayısal Sonuçların Değerlendirilmesi

Çalışmamızdaki uygulanan tüm analizlerde bağımsız değişkenler olarak; *kurulu güç*(installed power), *brüt elektrik üretimi*(gross electricity generation), *nüfus*(population) ve *toplam abone sayısı*(total subscribership) verilerinin 1970-2009 yılı arası veri temini yapılmış ve objektif bir değerlendirme olması açısından tüm verilerin 2/3'ü eğitim ve 1/3'ü test amacıyla kullanılmıştır. Giriş verileri öncelikle normalize edilerek, tasarımı yapılan sistemlere sunulmuş ve ağ veya sistem çıkışları tekrar denormalize edilerek sonuçlar raporlanmıştır. Daha önceki bölümlerde çoklu doğrusal regresyon analizi, yapay sinir ağları analizi ve en küçük kareler destek vektör makinesi performans sonuçları verilmişti. Bu bölümde özellikle eğitim ve test verileri üzerinde sonuçların birlikte irdelenmesi önemli bir kriter

gösterge olan yüzde mutlak hata ile gösterilecektir. Çizelge 6.12’de tasarımılanan algoritmalarda eğitim sürecindeki ve Çizelge 6.13’de test sürecindeki yüzde mutlak hatalar verilmiştir.

Çizelge 6.12. Eğitim grubu için denormalize edilmiş eğitim grupları

Gerçek Elektrik Tüketimi	ÇLR	YSA	EKK-DVM	ÇLR %Hata	YSA %Hata	EKK-DVM %Hata
7,31	8,5101293	7,16	7,2	16,41760	2,05198	1,50478
8,29	9,3195044	8,44	8,18	12,41860	1,80941	1,3269
10,53	11,132184	10,69	10,48	5,71875	1,51947	0,47483
11,36	11,991738	11,81	11,64	5,56107	3,96127	2,46479
16,08	15,236695	15,72	15,71	5,24443	2,23880	2,30099
17,97	16,856239	17,63	17,62	6,19789	1,89204	1,94769
19,63	18,736897	19,75	19,4	4,54968	0,61131	1,17167
20,4	19,27895	20,44	20,52	5,49534	0,19608	0,58824
23,59	22,347421	23,57	23,48	5,26739	0,08478	0,46629
24,47	23,147337	24,39	24,43	5,40524	0,32693	0,16346
29,71	28,440692	29,23	30,11	4,27232	1,61561	1,34635
32,21	32,364299	33,05	31,35	0,47904	2,60789	2,66997
39,72	40,100386	39,93	39,54	0,95767	0,52870	0,45317
43,12	43,506543	42,96	43,33	0,89644	0,37105	0,48701
49,28	50,101449	48,77	49,72	1,66690	1,03490	0,89286
53,99	55,335799	53,61	54,22	2,49268	0,70383	0,426
61,4	64,070814	61,78	60,87	4,34986	0,61889	0,86319
67,39	69,324432	67,71	67,88	2,87050	0,47485	0,72711
81,88	81,012993	81,55	81,48	1,05887	0,40302	0,48852
87,71	86,880309	87,57	87,52	0,94594	0,15961	0,21662
98,3	98,51795	98,77	97,94	0,22172	0,47813	0,36622
97,07	98,305273	96,85	98,12	1,27256	0,22664	1,08169
111,77	113,38184	112,01	112,44	1,44210	0,21473	0,59945
121,14	120,8826	120,84	121,22	0,21248	0,24764	0,06604
144,09	138,82825	144,02	144,18	3,65171	0,04858	0,06246
155,14	148,32327	155,19	155,07	4,39392	0,03223	0,04512
158,06	165,676	158,07	158,77	4,81842	0,00633	0,4492

Çizelge 6.13. Test grubu için denormalize edilmiş test grupları


Gerçek Elektrik Tüketimi	ÇLR	YSA	EKK-DVM	ÇLR %Hata	YSA %Hata	EKK-DVM %Hata
9,53	10,226017	9,49	9,58	7,30343	0,41972	0,0052
13,49	13,486647	13,65	13,3	0,02485	1,18606	0,0141
18,93	17,94755	18,84	18,87	5,18991	0,47543	0,0032
22,03	20,613659	21,95	22,12	6,42914	0,36314	0,0041
27,64	25,815188	26,69	27,1	6,60206	3,43704	0,0195
36,7	36,562477	36,75	36,86	0,37472	0,13624	0,0044
46,82	47,622198	46,84	46,77	1,71337	0,04272	0,0011
59,24	60,415968	58,45	58,53	1,98509	1,33355	0,0120
74,16	75,554315	75,5	73,19	1,88014	1,80690	0,0131
91,2	92,0454	91,24	91,5	0,92697	0,04386	0,0033
102,95	104,42865	101,31	103,59	1,43628	1,59300	0,0062
130,26	128,8715	131,58	128	1,06594	1,01336	0,0173
161,95	153,69268	156,03	157,55	5,09868	3,65544	0,0272

Çoklu doğrusal(lineer) regresyon analizi, yapay sinir ağları analizi ve en küçük kareler destek vektör makinesi sonuçlarının tüm performans kriterleri ile birlikte gösterimi Çizelge 6.14’de verilmiştir.

Çizelge 6.14. Performans sonuçları.

Performans kriteri	Eğitim			Test		
	ÇLR	YSA	EKK-DVM	ÇLR	YSA	EKK-DVM
MAPE(%)	4,01	0,906	0,876	3,34	1,19	1,004
MaxError	7,62	0,84	1,05	8,25	5,92	4,40
MSE	6,06	0,11	0,1699	6,45	3,3	2,060
RMSE	2,46	0,319	0,412	2,54	1,82	1,435
SSE	163,69	2,75	4,59	83,79	42,85	26,782

Yine ÇLR, yapay sinir ağları (YSA) ve EKK-DVM (LS-SVM) analizi ile yapılan tahmin sonuçlarının Türkiye'nin gerçek net elektrik tüketimi zaman serisi üzerinde gösterimi aşağıda Şekil 6.13'de verilmiştir.



Şekil 6.13. Tahmin model sonuçlarının gerçek tüketim eğrisi ile kıyaslanması

Sonuçlar incelendiğinde en dikkat çekici noktanın EKK-DVM modelinin YSA ve ÇLR modeline göre test başarısının daha iyi olduğu görülmektedir. Eğitim hata oranları dikkate alındığında ise EKK-DVM ile YSA sonuçlarının birbirine yakın olduğu görülecektir. Yine dikkat çekici bir nokta ise; özellikle kriz dönemlerinde düşen tüketimin YSA ve EKK-DVM yöntemlerince başarılı algılandığı görülmektedir.

6.8.1. ROC(Receiver Operating Characteristic) eğrisi analizi

Özellikle Sinyal algılamada, algılayıcı işleyiş karakteristiği orijinal ismi ile ROC(Receiver Operating Characteristic) eğrisi ikili bir sınıflayıcı sistemin performansını gösteren ve belli eşik seviyeleri kullanan grafiksel bir çizimdir. Bu grafiksel çizim ile değişik eşik(threshold) ayarlarında pozitif değerlerin gerçek pozitif bölümleri(TPR, True Positive Rate) ile negatif değerlerin yanlış pozitif bölümleri(FPR, Yanlış Positive Rate) oluşturulur. Burada; TPR duyarlılık(sensitivity), FPR ise özgüllük(specificity) olarak bilinir.

ROC analizi, en uygun modelleri seçmek sınıfsal dağıtım problemlerinde bağımsız alt optimal alanları atmak için araçlar sağlar. ROC analizinin, özellikle bio-istatistik çalışmalarda hastalık tanı karar aşamasındaki maliyet/fayda analizinde, doğrudan ve doğal bir şekilde ilişkisi olduğu söylenebilir. ROC analizi tıp, radyoloji, biometri, makine öğrenmesi ve veri madenciliği araştırmalarında artan bir şekilde kullanılmaya devam etmektedir.

Bir sınıflama modelini, bazı sınıflar ve gruplar arasında örnekleri eşleme olarak ifade edebiliriz. Bir sınıflandırıcı veya tanı sonucu gerçek bir değer olabilir. Sınıfların sınırları arasında bir eşik değeri ile sınıflar belirlenmelidir. Sınıflandırma problemlerinde, ROC eğrisi belirli bir eşik(threshold) değerlerine göre doğru pozitiflerin sayısının, yanlış pozitiflerin bir fonksiyonu olarak elde edilmesi ile meydana gelmektedir.

Örneğin iki sınıflı bir tahmin probleminde pozitif(p) ve negatif(n) etiketli çıkışlarımız olduğunda, ikili tahminde dört farklı olasılıktan söz edilebilir. Eğer tahmin çıkışımız pozitif(p) olduğunda, gerçek çıkışımız pozitif(p) ise; bu durum *gerçek pozitif*(True Positive-TP), gerçek çıkışımız negatif(n) ise; bu durum *yanlış pozitif*(False Positive-FP) tanımlanabilir. Yine tahmin çıkışı negatif(n) olduğunda; gerçek çıkış negatif(n) ise gerçek negatif(True Negative-TN), gerçek çıkış pozitif(p) ise yanlış negatif(False Negative-FN) olarak ifade edilebilir. P tane pozitif örnek ve N tane negatif örnek için dört farklı çıkış ihtimali söz konusudur. Bu durum Şekil

6.14’de verilen tablo ile özetlenebilir. Bu tablo genellikle, 2x2’lik ihtimal tablosu(contingency table), veya bozulma tablosu(confusion table) olarak isimlendirilmektedir. Bu ihtimaller matrisi, birçok ortak ölçümler için temel oluşturmaktadır [Fawcett, 2006].

		Doğru sınıf	
		p	n
Hipotez sınıfı	Y	TP	FP
	N	FN	TN
Sütun toplamı		P	N

Şekil. 6.14. İhtimal tablosu

Eş. 6.7’de verilen gerçek pozitif oran(TPR) modelin duyarlılık ölçüsü olarak bilinmektedir. Bir diğer ifade ile doğru şekilde sınıflanmış pozitiflerin, topla pozitiflere oranı olarak ifade edilebilir. Yine Eş. 6.8’deki yanlış pozitif oran(FPR) hatalı şekilde sınıflandırılmış negatiflerin, toplam negatiflere oranı olarak açıklanabilir. Eş. 6.9’da verilen ACC(accuracy) ise modelin doğruluğunu veren bir ölçüttür. ROC eğrisi analizinde bir diğer önemli parametre ise sistemin belirliliği veya özgüllüğüdür. Sistem belirliliği(specificity) SPC Eş. 6.10’da verilmektedir.


$$TPR \approx \frac{TP}{P} = \frac{TP}{(TP + FN)} \quad (6.7)$$

$$FPR \approx \frac{FP}{N} = \frac{FP}{(FP + TN)} \quad (6.8)$$

$$ACC = \frac{(TP + TN)}{(P + N)} \quad (6.9)$$

$$SPC = \frac{TN}{N} = \frac{TN}{(FP + TN)} = 1 - FPR \quad (6.10)$$

ROC grafikleri x ekseninde yanlış pozitif oran(FP oran), y ekseninde ise gerçek pozitif oran(TP oran) çizilen iki boyutlu grafiklerdir. Bir ROC grafiği, doğru pozitifler ve yanlış pozitiflerin göreceli bir karşılaştırmasını(ödüneleşimini) verir. Gerçek pozitif değerler “duyarlılık”, yanlış pozitif değerler ise “özgüllük” olarak da bilinmektedir. Yanlış değerlere sahip olmayan ideal bir testte ROC eğrisi (0,0) (0,1) ve (1,1) noktalarını birleştirmektedir. ROC çizimi $y=x$ fonksiyonuna yaklaştıkça başarısız bir test ortaya çıkmaktadır.




Şekil 6.15. Beş ayrı sınıflayıcı gösteren basit bir ROC grafiği

Bir ayırık sınıflandırıcı, yalnızca bir sınıf etiketi çıkışlarından birisidir. Yani her bir ayırık sınıflandırıcı ROC uzayında bir noktaya karşılık gelen TPR ve FPR çiftini ifade eder. Örnek ayırık sınıflandırıcılar Şekil 7.2’de gösterilmektedir. ROC uzayında en düşük (0,0) noktası pozitif bir sınıflama stratejisi vermez. (0,1) noktası ise mükemmel bir sınıflama sunar. Şekil 6.15’de verilen D’nin performansı mükemmel gözükmemektedir. Diagonal hat $y=x$ rastgele bir sınıf tahmin stratejisini temsil eder.

C'nin performansı ise gerçekte rastgeledir(random) ve (0,7-0,7) noktasında %70 pozitif tahmin olacağı söylenebilir [Fawcett, 2006]. E ise rastgele bir durumdan daha kötüdür ve B noktasının olumsuzluğu olarak görülebilir.


Bir ROC eğrisi sınıflandırıcı performansının iki boyutlu anlatımıdır. Sınıflandırıcıları karşılaştırmak için; beklediğimiz performansı temsil eden tek bir skaler değer için ROC performansını azaltmak isteyebiliriz. Bunun için yaygın bir yöntem, ROC eğrisi altında kalan alanı hesaplamaktır. ROC eğrisi altında kalan alan kısaca AUC olarak gösterilir. AUC birimi kare alanın belirli bir bölümü olduğundan, mutlaka 0 ile 1,0 değeri arasında bir değer alacaktır. Diagonal hat yani rastgele tahmin noktaları altında kalan alan 0,5 olacağından, hiçbir gerçek sınıflandırıcının alanı 0,5'in altında olmamalıdır.



Şekil 6.16. ROC eğrisi AUC yaklaşımları

Örnek olarak ROC eğrisi altında kalan alanların, alansal olarak büyüklük gösterimi Şekil 6.16’de verilmektedir. Burada $0 < AUC(C) < AUC(B) < AUC(A) = 1$ olduğu için, en iyi sınıflayıcı performansının A eğrisi üzerinde olduğu görülecektir.

Analiz: Çalışmamızda tasarlanan modellerin tahmin performansı en genel bir ifade ile gerçek elektrik tüketimine olan yakınlığı ile ölçülür. Özellikle test verileri üzerinde modellerin duyarlılık ve belirlilik(özgüllük) testlerinin yapılması performans kıyaslamasında büyük önem taşımaktadır. Bu amaçla gerçek tüketim eğrisi üzerinde belirli bir eşik(threshold) aralığı tanımlanarak, bu aralığın içerisinde kalan model tahminlerini “*sınıf-1*”, bu aralığın dışında kalan alanlara ise “*sınıf-0*” etiketlemesi yaparsak ROC analizi için gerekli olan 2x2’lik ihtimal tablosu oluşturulabilir. Bu durumun sembolik gösterimi Şekil 6.17’de verilmektedir. Şekil 6.17’den de anlaşılacağı gibi, çalışmamızda sınıf eşik aralığı olarak $[-1,30 +1,30]$ aralığı sınıf etiketlemesi için kullanılmaktadır.



Şekil 6.17. Tüketim değişimi üzerinde sınıf etiketleri gösterimi

Çalışma sonucunda tasarlanan üç farklı model için oluşturulan ihtimal matrisleri(confusion matrix) aşağıda yer alan Çizelge 6.15, Çizelge 6.16 ve Çizelge 6.17’de düzenlenmiştir.

Çizelge 6.15. Çoklu lineer regresyon modeli için ihtimal matrisi

ÇLR	Gerçek "0"	Gerçek "1"	Toplam
Sınıflanmış "0"	4	1	5
Sınıflanmış "1"	2	6	8
Total	6	7	13
TPR	0,6667	0,8571	
FPR	0,1429	0,3333	
TNR	0,8571	0,6667	
FNR	0,3333	0,1429	
Duyarlılık	66,67%	85,71%	
Belirlilik	85,71%	66,67%	

Çizelge 6.15’de yer alan çoklu lineer regresyon modeli ihtimal matrisi tablosu incelendiğinde hassas ölçüm sınıfı olan sınıf-1’de %85,71 duyarlılık ve %66,67 belirlilik oranı ile modelin kabul edilebilir seviyede olduğu genel itibari ile normalüstü bir performans sergilediği söylenebilir.

Çizelge 6.16. Yapay sinir ağı modeli için ihtimal matrisi

YSA	Actual "0"	Actual "1"	Total
Sınıflanmış "0"	4	1	5
Sınıflanmış "1"	0	8	8
Total	4	9	13
TPR	1	0,8889	
FPR	0,1111	0	
TNR	0,8889	1	
FNR	0	0,1111	
Duyarlılık	100,00%	88,89%	
Belirlilik	88,89%	100,00%	

Çizelge 6.16’da çok katmanlı ileri beslemeli bir YSA modeli için ihtimaller tablosu(matrisi) incelendiğinde, hassas ölçüm sınıfı olan sınıf-1’de %88,89 duyarlılık ve %100 belirlilik oranı ile modelin performansı yüksek bir model olduğu görülmektedir.

Çizelge 6.17’de ise en küçük kareler destek vektör makinesi modeli için oluşturulan ihtimaller tablosunda ise, sınıf-1’de %100 duyarlılık ve belirliliğe ulaştığı görülmektedir. Bu durum EKK-DVM modelinin ise literatürde mükemmel diye tanımlanabilecek bir performans sergilediği görülmektedir.


Çizelge 6.17. EKK-DVM modeli için ihtimal matrisi

EKK-DVM	Gerçek "0"	Gerçek "1"	Toplam
Sınıflanmış "0"	2	0	2
Sınıflanmış "1"	0	11	11
Total	2	11	13
TPR	1	1	
FPR	0	0	
TNR	1	1	
FNR	0	0	
Duyarlılık	100,00%	100,00%	
Belirlilik	100,00%	100,00%	

Çizelge 6.18. Modellerin hassaslık ve özgüllük performansı

Model	Duyarlılık(%)	Belirlilik(%)	AUC(%)
ÇLR	85,71	66,67	92,86
YSA	88,89	100,00	97,22
EKK-DVM	100,00	100,00	100,00

Çalışmada kullanılan tüm modellerin karşılaştırmalı olarak; duyarlılık(%), belirlilik(%) ve eğri altında kalan alan(%) ölçüleri Çizelge 6.18’de gösterilmektedir.



Şekil 6.18. Elektrik tüketim değişiminin ROC eğrileri (a) YSA (b) ÇLR (c) EKK-DVM

6.8.2. ETKB projeksiyonları ile EKK-DVM model sonuçlarının karşılaştırması

Ülkemiz enerji planlamaları çalışmaları için 1984 yılından başlayarak günümüze kadar olan süreçte Enerji ve Tabii Kaynaklar Bakanlığı, “Model for Analysis of Energy Demand” (MAED) talep modelini kullanmış ve gelecek yıllar için ülkemiz enerji ihtiyacını (tahminlerini) bu model tabanında belirlemiştir. MAED talep modeli, Uluslararası Atom Enerjisi Ajansı’nca (UAEA) geliştirilen ülkenin orta ve uzun dönemli genel enerji ve elektrik enerjisi talebini değerlendiren bir simülasyon

modelidir. Bu modelde çok geniş bir bağımsız değişken grubu (ekonomik, sosyal ve teknik birçok yapı) model girdisi olarak kullanılmaktadır. Bu çalışmaların önemli bir kısmını oluşturan elektrik enerjisi üretim planlaması çalışmaları ise TEİAŞ tarafından yapılmakta ve bu amaç için “Wienn Automatic System Planning Package” (WASP) yazılım modeli tercih edilmektedir [Yoldaş, 2006].

Türkiye’de elektrik dağıtım şirketlerinin özelleştirilmesi ile birlikte yaşanan verilerin elde edilmesi, bilgilerin geç toplanması ve birleştirilmesi gibi sorunları sebebiyle; ETKB ve TEİAŞ ekonomik krizin etkileri dikkate alınarak revize edilmiş olan “yüksek talep” ve “düşük talep” serilerini kullanmaktadır. TEİAŞ tarafından yapılan üretim kapasite projeksiyonu periyodu 10 yıllık dönemler halinde belirlenmektedir. Çalışmamızda da baz alınan “2009 yılı Türkiye elektrik enerjisi 10 yıllık üretim kapasite projeksiyonu” raporlarında; Mevcut, inşası devam eden ve Enerji Piyasası Düzenleme Kurumu’nca (EPDK) Ocak 2009 dönemi İlerleme Raporlarına göre iki ayrı senaryo halinde (Senaryo 1 ve Senaryo 2) hazırlanan 2009 – 2013 yılları arasında işletmeye gireceği öngörülen (varsayılan) projelerin bu periyotdaki üretim kapasiteleri ve güçleri dikkate alınarak iki talep serisine göre arz-talep dengeleri, güç ve enerjileri dikkate alınarak işlemler tesis edilmektedir [TEİAŞ, 2010].

2009 – 2018 dönemini kapsayan üretim kapasite projeksiyonu (tahmini) çalışması ile elektrik enerjisi brüt tüketiminin mevcut, inşası devam eden, lisans almış ve öngörülen tarihlerde devreye girmesi beklenen kapasite ile güvenilir bir şekilde nasıl sağlanacağına analizi yapılmaktadır. Söz konusu bu üretim tesislerinin yapabilecekleri üretim miktarları proje ve güvenilir üretim kapasitesi olarak çalışmaya dâhil edilmektedir [TEİAŞ, 2010]. Tez çalışmamızda optimum sonuç üreten EKK-DVM modeli ile ileriye dönük tahminlemede giriş verileri olacak kurulu güç ve brüt elektrik üretim verileri (inşası devam eden, lisans almış ve öngörülen tarihlerde devreye girecek santral verileri dikkate alınarak) 2009 yılı TEİAŞ projeksiyon raporlarından elde edilmektedir.


ETKB projeksiyonlarında, Türkiye elektrik enerjisi talebini brüt tüketim (Türkiye brüt üretimi+dış alım-dış satım) üzerinden yapmakta ve bu tahminler net tüketim (iç

tüketim, şebeke kaybı ve kaçaklar) tahminleri olmadığı için gerçek fiili talebi (Elektrik dağıtım şirketlerinden alınan değerleri) tam olarak yansıtmamaktadır. Yine ETKB tarafından yapılan projeksiyonlarda; tahmin edilen brüt değerlerin, gerçekleşen brüt tüketim değerlerinden oldukça yüksek olduğu yani sapma miktarının kabul edilebilir sınırlar içerisinde olmadığı görülmektedir. Bu durum Çizelge 6.19'da da gösterilmektedir.

Çizelge 6.19. Geçmiş yıllar için ETKB brüt tüketim projeksiyonu ve sapmalar


Yıllar	Brüt tüketim gerçekleşme (milyar kWh)	Önceki yıla göre artış (%)	ETKB tarafından yapılan (2000 yılı) brüt tüketim projeksiyonu (milyar kWh)	Sapma (%)
1999	118,49	3,9	118,50	0,0
2000	128,28	8,3	126,80	-1,2
2001	126,87	-1,1	138,80	9,4
2002	132,55	4,5	151,40	14,2
2003	141,15	6,5	165,20	17,0
2004	150,02	6,3	180,20	20,1
2005	160,79	7,2	196,60	22,3
2006	174,64	8,6	213,20	22,1
2007	190,00	8,8	231,10	21,6
2008	198,09	4,2	250,60	26,6

ETKB tarafından uygulanan MAED model sonuçlarının, gerçekleşen brüt tüketim ve net tüketim sonuçlarına olan niceliksel uzaklığı ile çalışmamızda tasarlanan EKK-DVM model sonuçlarının hedeflenen ve gerçekleşme değeri olan net tüketim oranına yakınlığı Şekil 6.19'da gösterilmektedir.



Şekil 6.19. Model sonuçlarının gerçekleşme değerlerine yakınlığı

ETKB tarafından MAED modeli kullanılarak yapılan yüksek talep ve düşük talep projeksiyonları ve bu taleplerde yer alan (gelecek öngörüsünde bulunulmuş) kurulu güç ve brüt elektrik tüketimi verilerinin giriş verileri olarak kullanıldığı EKK-DVM modeli sonuçları Şekil 6.20 ve Çizelge 6.20’de kıyaslanmaktadır.



Şekil 6.20. 2010-2018 yılları arası uzun dönem gelecek projeksiyonları

Çizelge 6.20. Modellerin uzun dönem gelecek projeksiyonları.

Yıllar	ETKB (MAED modeli) tüketim talep tahmini		EKK-DVM modeli tüketim talep tahmini	
	Yüksek talep(TWh)	Düşük talep (TWh)	Yüksek talep(TWh)	Düşük talep (TWh)
2009	194,00	194,00	Eğitim verisi	Eğitim verisi
2010	202,73	202,73	174,98	169,85
2011	215,91	213,88	191,75	184,86
2012	232,10	228,21	202,26	199,14
2013	249,52	243,50	228,68	220,49
2014	268,22	259,82	247,77	240,12
2015	288,34	277,22	260,08	252,18
2016	309,68	295,52	270,44	265,82
2017	332,59	315,02	278,56	274,07
2018	357,20	335,82	303,23	298,26

7. SONUÇLAR VE ÖNERİLER

Dünyamızda ve ülkemizde enerji tüketimindeki pay sürekli yükselerek artmaya devam etmektedir. Oluşan talebin kesintisiz olarak en düşük maliyetle ve en kaliteli biçimde karşılanması, arz ve çevre güvenliğinin sağlanması, günümüz yeni nesil elektrik sistemleri tasarım, kaynak planlamalarında ve liberal bir elektrik piyasasında temel hedefler haline gelmiştir. Bu sebeple kesintisiz bir elektrik enerjisi için gerekli olan üretim, iletim ve dağıtım planlamaları yapabilmek amacıyla tüketim tahmininde bulunmak kaçınılmazdır.

Yıllardır değişik metotlar kullanılarak elektrik tüketim veya yük talep tahmin çalışmaları çeşitli metotlar kullanılarak yapılmıştır. Talep tahmin çalışmalarında önemli olan tahmin edilen sonucun gerçeğe en yakın olmasıdır. Bunun için kullanılan yöntem, yöntemlerde girdi olarak kullanılacak olan bağımsız değişkenlerin iyi ve eksiksiz tespit edilmesi kaçınılmaz olmuştur. Yine tahmin çalışmalarında geçmişe ait olarak ne kadar çok veri elde edilebilirse, geçmişteki gidişata göre önümüzdeki yıllarda, gerçeğe yakın ve hata oranı daha düşük tahmin sonuçlarına ulaşmak mümkün olabilir.

Çalışmamızda sağlıklı ve gerçeğe yakın tahminler yapabilmek için öncelikle hangi verilerin girdi olarak kullanılacağı ve hangi yöntemlerin kullanılacağı tespit edilmiştir. Bu tespit için, geçmişte yapılan tahmin çalışmalarında kullanılan bağımsız değişkenler incelenmiş ve incelenen değişkenlere korelasyon ve regresyon analizleri yapılarak bağımlı değişken üzerindeki etkileri araştırılarak, en uygun model tespit edilmiştir. Geçmiş verilerin iyi analiz edilerek, geleceğe yönelik iyi tahminlerde bulunabilmek için; 1970-2009 yılları arası bir veri seti oluşturulmuştur. Bu yıllar arası veri setinin 2/3'ü eğitim ve 1/3'ü ise test verisi olarak iki gruba ayrılmıştır. Türkiye'nin gelecekteki elektrik tüketimi ÇLR, YSA ve EKK-DVM yöntemleri kullanılarak hesaplandığında eğitimde %0,876, testte %1,004 ortalama mutlak hata veren EKK-DVM modeli en iyi sonucu üretmiştir. Ancak tasarlanan YSA modelinin de eğitimde %0,906 ve testte %1,19 ortalama mutlak hata üretmesi de YSA modelinin iyi eğitildiği ve tüketim tahminlerinde daima güçlü bir alternatif olduğu

gerçeğini görmemizi sağlamaktadır. Geleneksel ÇLR modeli ise eğitimde %4,01, testte %3,34 gibi ortalama mutlak hata üretmesi incelenen bu üç model arasında hata oranı en yüksek model olmuştur. Çizelge 7.1 ve Çizelge 7.2’de 2010 yılı için validasyon sonuçlarına bakıldığında ÇLR modelinin hem yüksek talep durumu, hemde düşük talep durumlarında yüzdesel hatasının çok yüksek olmasına karşın, YSA modelinin daha başarılı sonuçlar verdiği görülmektedir. 2010 yılı validasyon sonuçlarında yüksek ve düşük talep durumunda EKK-DVM modelinin ÇLR ve YSA modellerine göre sırasıyla %1,70 ve %1,28 ile daha başarılı sonuçlar verdiği ve modelimizin başarılı bir şekilde tahmin yapabildiğini göstermektedir.

Çizelge 7.1. 2010 yılı yüksek talep durumu validasyon sonuçları

Gerçek Elektrik Tüketimi	ÇLR	YSA	EKK-DVM	ÇLR %Hata	YSA %Hata	EKK-DVM %Hata
172,05	188,22	175,57	174,98	9,39843	2,04592	1,70299

Çizelge 7.2. 2010 yılı düşük talep durumu validasyon sonuçları

Gerçek Elektrik Tüketimi	ÇLR	YSA	EKK-DVM	ÇLR %Hata	YSA %Hata	EKK-DVM %Hata
172,05	165,52	168,34	169,85	3,79541	2,15635	1,2787

Özellikle sonuçlar tüketimde meydana gelen ani pik noktalarını yakalamada EKK-DVM eğitiminin daha etkin olduğunu göstermektedir. Yine çalışmamızda kullanılan bağımsız değişkenler ve bağımlı değişkenin zaman serisi lineer bir forma yapısına yakın olduğu düşünüldüğünde EKK-DVM yönteminin daha başarılı olduğu değerlendirilebilir. Bu nedenle iyi öğrenme yaptığı tespit edilen en küçük kareler destek vektör makineleri(EKK-DVM) ile yapılan tüketim tahminlerinin, ülkedeki normal koşullar dâhilinde gerçek tüketim değerlerine daha yakın olacağı değerlendirilmektedir. EKK-DVM yöntemi ile elde edilen tahminlere göre Türkiye’nin 2018 yılında net elektrik tüketimi 298,26TWh olacağı tahmin edilmiştir (Çizelge 7.3). Bu çalışmada gelecek giriş verileri belirlenirken, TEİAŞ tarafından belirlenen 10 yıllık üretim kapasite projeksiyonu, ETKB ve EPDK verileri baz

alınarak, yüksek talep ve düşük talep durumları ayrı ayrı dikkate alınarak gelecek öngörülerinde bulunulmuştur.

Çizelge 7.3. EKK-DVM metodu ile tüketim tahmini

Yıllar	Düşük talep durumu(TWh)	Yüksek talep durumu(TWh)
2012	199,14	202,26
2013	220,49	228,68
2014	240,12	247,77
2015	252,18	260,08
2016	265,82	270,44
2017	274,07	278,56
2018	298,26	303,23

Çalışmamızda kullandığımız EKK-DVM yöntemi; özellikle Türkiye elektrik piyasasında yer alan elektrik dağıtım şirketlerinin, enerji talep tahminlerini bildirme (kısa ve uzun dönemli) sorumluluğu olması nedeniyle, ilgili kuruluşlar tarafından tercih edilebilir. Yine ETKB tarafından uzun ve orta dönemli yük ve tüketim talep tahmin hesaplamalarında kullanılan MAED model sonuçlarının gerçekleşme değerlerinden çok yüksek olmasıda Türkiye’de daha hassas tahmin çalışmalarının yapılmasının faydalı olacağını göstermektedir. Bundan sonra yapılacak çalışmalarda; özellikle kısa dönemli yük tahmini ve elektrik fiyat analizi konularında EKK-DVM yönteminin başarı performansı yeni bir araştırma konusu olacaktır.

KAYNAKLAR

- Akay, D., Atak, M., “Grey prediction with rolling mechanism for electricity demand forecasting of Turkey”, *Energy*, 32 : 1670-1675 (2007).
- Alpaydın E., “Yapay öğrenme”, *Boğaziçi Üniversitesi Yayınevi*, İstanbul, 235-242 (2010).
- Arıcı, H., “İstatistik Yöntemler ve Uygulamalar 16. Baskı”, *Meteksan*, Ankara, 131-159 (2006).
- Bağdadioglu, N., Odyakmaz, N., “Turkish Electricity Reform”, *Utilities Policy*, 17 : 144-152 (2009).
- Bradley, A.P., “The use of the area under the ROC curve in the evaluation of machine learning algorithms”, *Pattern Recognition*, 30 (7) : 1145-1159 (1997).
- Canyurt, O.E., Ceylan, H., Ozturk, H.K., Hepbasli A., “Energy demand estimation based on two-different genetic algorithm approaches”, *Energy Sources*, 26 : 1313-1320 (2004).
- Ceylan G., Demirören A., “Yapay Sinir Ağı ile Gölbaşı Bölgesinin Kısa Dönem Yük Tahmini”, *İstanbul Teknik Üniversitesi Elektrik-Elektronik Fakültesi Yayınları*, İstanbul, 1-2 (2004).
- Chen, S.T., Kuo, H., Chen, C.C., “The Relationship Between GDP and Electricity Consumption in 10 Asian Countries”, *Energy Policy*, 35 : 2611-2621 (2007).
- Christianini, N., Shawe T. J., “An Introduction to Support Vector Machines and Other Kernel -Based Learning Methods”, *Cambridge University Press*, Cambridge 96 (2000).
- Coelho, L.D.S., Klein, C.E., “Power demand forecast using least-squares support vector machines”, *Intelligent System Applications to Power Systems ISAP 15th International Conference*, Brezilya, 1-5 (2009).
- Cortes, C., Vapnik V.N., “Support Vector Networks”, *Machine Learning*, 20 : 273-297 (1995).
- Dong, B., Cao, C., Lee, S.E., “Applying support vector machines to predict building energy consumption in tropical region”, *Energy and Buildings*, 37 : 545-553 (2005).
- Ekonomou L., “Grek long-term energy consumption prediction using artificial neural network”, *Energy*, 35 : 512-517 (2010).
- Elmas, Ç., “Yapay Sinir Ağları”, *Seçkin Yayıncılık*, Ankara, 22-170 (2003).

Fawcett, T., “An introduction to ROC analysis”, *Pattern recognition letters*, 27 : 861-874 (2006).

Geem, Z.W., Roper, W.E., “Energy demand estimation of South Korea using artificial neural network”, *Energy Policy*, 10: 6379-6380 (2010).

Hamel, L., “Knowledge Discovery With Support Vector Machines”, *John Wiley & Sons Inc*, New Jersey, 177 (2009).

Hamzacebi C., “Forecasting of Turkey’s net electricity energy consumption on sectoral bases”, *Energy Policy*, 35 : 2009-2016 (2007).

Hanley, J.A., McNeil, B.J., “The meaning and use of the area under a receiver operating characteristic (ROC) curve”, *Radiology*, 143 : 29-36 (1982).

Hastie, T., Tibshirani, R., Friedman, J., “The Elements of Statistical Learning: Data Mining, Inference, and Prediction 2nd.Edition”, *Springer Science+Business Media LLC*, New York, 238 (2009).

Haykin, S., “Neural Networks: A Comprehensive Foundation”, *Tsinghua University Press*, 344 (2001).

Hepbaşlı, A., “Development and Structuring of Turkey’s Electricity Sector: A Review, *Renewable and Sustainable Energy Reviews*”, 9 : 311-343 (2005).

İnternet: Enerji ve Tabii Kaynaklar Bakanlığı(ETKB) “Yayınlar/Raporlar” <http://www.enerji.gov.tr> (2010).

İnternet: Türkiye Elektrik Dağıtım A.Ş. Genel Müdürlüğü “Türkiye 2009 Dağıtım İstatistikleri” www.tedas.gov.tr/istatistik (2009).

İnternet: Türkiye Elektrik İletim A.Ş. Genel Müdürlüğü “Türkiye Elektrik 10 yıllık üretim kapasite projeksiyonu” www.teias.gov.tr/projeksiyon/index (2011).

İnternet: Türkiye Elektrik İletim A.Ş. Genel Müdürlüğü “Türkiye elektrik üretim/iletim istatistikleri” <http://www.teias.gov.tr/istatistik2010> (2010).

İnternet: Türkiye Elektrik İletim A.Ş. Genel Müdürlüğü “2011-2015 dönemi stratejik plan” http://www.teias.gov.tr/TEIAS_Strtj_2011.pdf (2011).

Kavaklioglu, K., “Modeling and prediction of Turkey’s electricity consumption using support vector regression”, *Applied Energy*, 88 : 368-375 (2011).

Kuzey, C., “Veri Madenciliğinde Destek Vektör Makineleri ve Karar Ağaçları Yöntemlerini kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama”, Doktora Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, 34-120 (2012).

Makridakis, S., Wheelwright, S.C., Hyndman R.J., “Forecasting methods and Applications 3rd Edition”, **John Wiley&Sons**, New York, 187-201 (1998).

Mohamed, Z., Bodger, P., “Forecasting electricity consumption in New Zealand using economic and demographic variables”, **Energy**, 30 : 1833-1843 (2005).

Ogulata, R.T., “Energy sector and wind energy potential in Turkey”, **Renewable&Sustainable Energy Reviews**, 7 : 469-484 (2003).

Oğurlu, H., “Matematiksel Modelleme Kullanılarak Türkiye’nin Uzun Dönem Elektrik Yük Tahmini” Yüksek Lisans Tezi, **Selçuk Üniversitesi Fen Bilimleri Enstitüsü**, Konya, 1-27(2011).

Öztemel, E., “Yapay Sinir Ağları”, **Papatya Yayıncılık**, İstanbul, 22-144 (2006).

Pao, H.T., “Comparing linear and nonlinear forecasts for Taiwan’s electricity consumption”, **Energy**, 31 : 2129-2141 (2006).

Rumelhart, D.E., Hinton, G.E., Willams, R.J., “Learning internal representations by error propagation”, **MIT Press**, Cambridge, 318-362 (1986).

Samsudin, R., Shabri, A., Saad, P., “A comparison of time series forecasting using support vector machine and artificial neural network model”, **Journal of Applied Sciences**, 10 (11) : 950-958 (2010).

Sargın Ş., “Üretimden Tüketime Elektrik Enerjisi Sistemlerinde Meydana Gelen Kayıplar ve Giderilmesine Yönelik Çalışmalar”, Yüksek Lisans Tezi, **Marmara Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, 241 (2006).

Schölkopf, B., Burges, C.J.C., Smola A.J., “Advances in Kernel Methods: Support Vector Learning”, **MIT Press**, Cambridge, 216-218 (1999).

Sözen, A., Arcaklioglu, E., “Prospects for future projections of the basic energy sources in Turkey”, **Energy Sources**, 2: 183-201 (2007).

Sözen A., Akcayol M.A., Arcaklioğlu E., “Forecasting net energy consumption using artificial neural network”, **Energy Sources B:Econ, Plan Policy**, 1 : 147-155 (2006).

Suykens, J.A.K., Vandewalle, J., “Least squares support vector machine classifiers”, **Neural Processing Letters**, 293-300 (1999).

Tsujinishi, D., Abe, S., “Fuzzy least squares support vector machines for multi-class problems”, **Neural Networks Field**, 16 : 785-792 (2003).

Ünler, A., “Improvement of energy demand forecasts using swarm intelligence: the case of Turkey with projections to 2025”, **Energy Policy**, 36 : 1937-1944 (2008).

Vapnik, V.V., “Estimation of Dependences Based on Emprical Data”, **Springer-Verlag**, New York, 27-29 (1982).

Yamaçlı, M., “Türkiye’nin Uzun Dönem Elektrik Yük Tahmini”, Yüksek Lisans Tezi, **Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü**, Kütahya, 12-45 (2010).


Yoldaş U.C., “Elektrik Enerjisinde Yük Tahmin Yöntemleri ve Türkiye’nin 2005-2020 Yılları Arasındaki Elektrik Enerjisi Talep Gelişimi ve Arz Planlaması”, Yüksek Lisans Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara, 5-35 (2006).

EKLER

EK-1. Türkiye tüketim istatistikleri

Çizelge 1.1. Türkiye net tüketiminin(MWh) 2009 yılı için tüketici gruplara göre dağılımı

	Tüketici Grupları	TEDAŞ *	ÖZEL	Diğer	Toplam
		D.Şirketi.	D.Şirketi.		
1-a	Tarımsal Sulama	3 355 346	306 458		3 661 805
1-b	Orman.,Avcılık,Balıkçılık,Hayvancılık	831 020	384 400	1 444	1 216 864
2	Maden Kömürü ve Linyit Üretim Tesisleri	352 415	370 646		723 061
3	Maden Kömürü ve Linyit Dışı Üretim Tesisleri	485 850	119 978	39 811	645 639
4	Gıda, Meşrubat, İçki ve Tütün Sanayii	3 264 513	609 868	1 041 756	4 916 138
5	Tekstil, Deri ve Giyim Sanayii	8 928 321	1 267 599	1 812 437	12 008 357
6	Ağaç işleri ve Kağıt Sanayii	1 678 567	740 935	1 052 421	3 471 923
7	Kauçuk, Lastik ve Plastik Sanayii	1 729 211	351 436	381 335	2 461 983
8	Kimya Sanayii	1 379 726	399 175	2 701 442	4 480 344
9	Toprak ve Çimento Sanayii	6 242 111	1 220 447	2 210 149	9 672 708
10	Demir-Çelik Üretimi ve İşleme Sanayii	7 521 546	1 611 183	6 867 565	16 000 294
11	Demir Dışı Metal Üretimi ve İşleme Sanayii	879 579	348 563	696 268	1 924 409
12	Makine, Elektrikli Aletler ve Ulaşım	1 435 777	1 698 042	863 729	3 997 547
13	Organize ve Diğer Fabrikasyon Sanayii	5 763 193	1 418 677	1 065 838	8 247 707
14	İnşaat, Bayındırlık	1 495 684	277 972	146 311	1 919 967
15-a	Resmi Daire	4 992 165	1 853 746	143 730	6 989 641
15-b	Hastane, Banka, Vakıf, Okul, Kooperatif vb.	580 816	45 158	281 575	907 548
15-c	Köy ve Diğer Halk Hizmetleri	3 858 240	654 873	20 999	4 534 113
16	Ticarethane, Yazıhane, Turizm	18 086 466	4 593 040	1 815 354	24 494 860
17-a	Ulaşım, Taşımacılık	430 990	8 068	220 419	659 476
17-b	Haberleşme	681 228	209 491	76 628	967 347
18	Aydınlatma	3 134 889	709 944		3 844 834
19	Mesken İçi Hizmetler	31 363 978	7 783 032	495	39 147 505
	Toplam	108 471 633	26 982 730	21 439 707	156 894 070



Şekil 1.1. Türkiye net tüketiminin genel dağılımı

EK-2. TEİAŞ 2010-2020 yılları arası üretim kapasite projeksiyonları

Çizelge 2.1. Yüksek talep projeksiyonu

Yıl	Kurulu Güç(GW)	Brüt Elektrik Üretimi(TWh)	Nüfus(Milyon)	Toplam Abonelik(Million)
2010	45,01	253,50	72,70	32,34
2011	48,18	263,62	73,50	33,22
2012	53,13	287,25	74,28	34,09
2013	55,18	311,63	75,07	34,97
2014	55,18	313,93	75,84	35,84
2015	55,18	314,75	76,60	36,71
2016	56,38	320,00	77,36	37,59
2017	56,38	318,78	78,10	38,46
2018	56,38	315,00	78,83	39,34

Çizelge 2.2. Düşük talep projeksiyonu

Yıl	Kurulu Güç(GW)	Brüt Elektrik Üretimi(TWh)	Nüfus(Milyon)	Toplam Abonelik(Million)
2010	45,01	214,70	72,70	32,34
2011	48,18	223,37	73,50	33,22
2012	53,13	244,96	74,28	34,09
2013	55,18	275,00	75,07	34,97
2014	55,18	276,00	75,84	35,84
2015	55,18	278,13	76,60	36,71
2016	56,38	281,48	77,36	37,59
2017	56,38	280,78	78,10	38,46
2018	56,38	277,00	78,83	39,34

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KAYTEZ, Fazıl
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 27.08.1977, Çankırı
 Medeni hali : Evli
 Telefon : 0 (312) 3607784
 Faks : 0 (312) 5735030
 e-mail : fazilkaytez@hotmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Yüksek lisans	Gazi Üniversitesi	
	Elektrik-Elektronik Müh. Bölümü	2005
Lisans	Niğde Üniversitesi	
	Elektrik-Elektronik Müh. Bölümü	2000
Lise	Eldivan Sağlık Meslek Lisesi	1995

İş Deneyimi

Yıl	Yer	Görev
2012-	Enerji ve Tabii Kay. Bakanlığı	Yüksek Mühendis
2009-2012	EnerjiSA	Enerji Uzmanı
2008-2009	BEDAS	Mühendis
2004-2008	TREDAS	Mühendis
2003-2004	Çevre ve Orman Bakanlığı	Mühendis
2003-2004	Metropol Denetim	Yrd.Denetmen

Yabancı Dil

İngilizce