İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ÜRETİM VE FİYAT TAHMİN YÖNTEMLERİYLE ELEKTRİK PİYASASINDAKİ DENGESİZLİK MALİYETLERİNİN OPTİMİZASYONU

YÜKSEK LİSANS TEZİ

Sait YAZICI

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

HAZİRAN 2020

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ÜRETİM VE FİYAT TAHMİN YÖNTEMLERİYLE ELEKTRİK PİYASASINDAKİ DENGESİZLİK MALİYETLERİNİN OPTİMİZASYONU

YÜKSEK LİSANS TEZİ

Sait YAZICI
(507171149)

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Nizamettin BAYYURT
Eş Danışman: Doç. Dr. Mehmet Güray GÜLER

HAZİRAN 2020

İTÜ Fen Bilimleri Enstitüsü'nün 507171149 numaralı Yüksek Lisans Öğrencisi Sait YAZICI, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "ELEKTRİK ÜRETİM VE FİYAT TAHMİN YÖNTEMLERİYLE ELEKTRİK PİYASASINDAKİ DENGESİZLİK MALİYETLERİNİN OPTİMİZASYONU" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı :	**Prof. Dr. Nizamettin BAYYURT** İstanbul Teknik Üniversitesi	.....
Eş Danışman :	**Doç. Dr. Mehmet Güray GÜLER** Yıldız Teknik Üniversitesi	.....
Jüri Üyeleri :	**Dr. Öğr. Üyesi Ömer Faruk Beyca** İstanbul Teknik Üniversitesi	.....
	Prof. Dr. Ramazan Evren İstanbul Teknik Üniversitesi	.....
	Doç. Dr. Enes Eryarsoy İstanbul Şehir Üniversitesi	.....

Teslim Tarihi : 7 Mayıs 2020
Savunma Tarihi : 18 Haziran 2020

ÖNSÖZ

Güneş enerjisinden elektrik üreten firmaların maliyetlerini düşürmek ve yatırımlarını planlamak için gelecekte ne kadar elektrik üretimi yapabileceklerini tahmin etmeleri gerekmektedir. Güneş enerjisi üretiminin hava şartlarına bağlı olarak gerçekleşmesinden dolayı ne kadar üretim yapılacağının öngörülmesinde zorluklarla karşılaşılmaktadır. Bu nedenle bir gün sonraki üretim miktarının düşük hata oranıyla tahmin edilmesi bu sektördeki önemli problemlerden birisidir. Bu çalışmada güneş enerjisinden elektrik üretiminin tahmin edilmesi ve tahmindeki sapmalardan kaynaklanan dengesizlik maliyetleri azaltmaya yönelik optimizasyon çalışmalarıyla firmaların karşılaştığı problemlere çözüm önerileri sunulmuştur. Yenilenebilir enerji üretiminin yaygınlaşması ve yeni yatırımların teşvik edilmesine katkı sağlanması amaçlanmıştır. Tez çalışması süresince çalışmalarımı düzenli olarak takip eden, bilgi, fikir ve tecrübelerini benimle paylaşarak yol gösteren danışman hocam Prof. Dr. Nizamettin BAYYURT ile eş danışmanım Doç. Dr. Mehmet Güray GÜLER'e ve hayatım boyunca hep yanımda olan, desteğini benden hiç esirgemeyen aileme teşekkürlerimi sunarım.

Mayıs 2020 Sait YAZICI
(Endüstri Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **v**
İÇİNDEKİLER ..... **vii**
KISALTMALAR ..... **ix**
SEMBOLLER ..... **xi**
ÇİZELGE LİSTESİ ..... **xiii**
ŞEKİL LİSTESİ ..... **xv**
ÖZET ..... **xvii**
SUMMARY ..... **xix**
1. GİRİŞ **1**
1.1 Tezin Amacı 1
1.2 Literatür Özeti 1
1.2.1 Güneş enerjisi üretim tahmini 1
1.2.2 Elektrik fiyatı tahmini 5
1.2.3 Elektrik piyasasında gazeteci çocuk yaklaşımı 7
1.3 Hipotez 10
2. YAPAY SİNİR AĞLARI **11**
2.1 Yapay Sinir Ağlarının Yapısı ve Elemanları 11
2.2 Yapay Sinir Ağlarında Öğrenme Stratejileri 12
2.2.1 Denetimli öğrenme 12
2.2.2 Denetimsiz öğrenme 13
2.2.3 Takviyeli öğrenme 13
2.3 Yapay Sinir Ağı Mimarileri 13
2.4 Yapay Sinir Ağlarının Kullanım Alanları 14
2.5 Tek Katmanlı Algılayıcılar 15
2.6 Çok Katmanlı Algılayıcılar 17
2.7 Ağın Eğitimi ve Test Edilmesi 20
2.8 Verilerin Normalize Edilmesi 22
2.9 Ağın Performans Kriterleri 23
2.10 Ağı Oluşturan Parametreler 24
2.10.1 Başlangıç ağırlıklarının belirlenmesi 24
2.10.2 Öğrenme oranı ve momentum katsayısı 25
2.10.3 Gizli katman ve nöron sayısı 26
2.10.4 Aktivasyon fonksiyonu 27
3. GÜNEŞ ENERJİSİ ÜRETİM TAHMİNİ **29**
3.1 Güneş Işınımı Hesaplanması 29
3.1.1 Atmosferin güneş ışınımına etkisi 30
3.1.2 Bulutların güneş ışınımına etkisi 31
3.2 Verilerin Hazırlanması ve Değişken Seçimi 32
3.3 Doğrusal Regresyon ile Elektrik Üretim Tahmini 34
3.4 Yapay Sinir Ağları ile Elektrik Üretim Tahmini 36

3.5 Bulutluluk Durumunun Tahmin Performansına Etkisi 43
4. ELEKTRİK FİYATI TAHMİNİ 47
4.1 Elektrik Piyasasında Serbestleşme Süreci 47
4.1.1 Gün öncesi piyasası 49
4.1.2 Dengeleme güç piyasası 50
4.2 Verilerin Hazırlanması ve Değişken Seçimi 51
4.3 Piyasa Takas Fiyatının (PTF) Tahmini 56
4.3.1 Doğrusal regresyon ile PTF tahmini 56
4.3.2 Yapay sinir ağları ile PTF tahmini 59
4.4 Sistem Marjinal Fiyatının (SMF) Tahmini 64
4.4.1 Doğrusal regresyon ile SMF tahmini 64
4.4.2 Yapay sinir ağları ile SMF tahmini 67
5. ELEKTRİK PİYASASINDA GAZETECİ ÇOCUK YAKLAŞIMI 73
5.1 Önerilen Optimizasyon Modeli 75
5.2 Modelin Simülasyonu 81
5.2.1 Gerçek fiyatların bilindiği durum 83
5.2.2 Tahmin edilen fiyatların kullanıldığı durum 84
5.3 Standart Sapma Değerinin Sonuca Etkisi 86
6. SONUÇ VE DEĞERLENDİRMELER 89
KAYNAKLAR 95
ÖZGEÇMİŞ 101

KISALTMALAR

TEK : Türkiye Elektrik Kurumu
TEAŞ : Türkiye Elektrik Üretim İletim A.Ş.
TEDAŞ : Türkiye Elektrik Dağıtım A.Ş.
TEİAŞ : Türkiye Elektrik İletim A.Ş
EÜAŞ : Elektrik Üretim A.Ş
TETAŞ : Türkiye Elektrik Ticaret ve Taahhüt A.Ş
EPDK : Elektrik Piyasası Düzenleme Kurumu
DUY : Dengeleme ve Uzlaştırma Yönetmeliği
EPİAŞ : Enerji Piyasaları İşletme Anonim Şirketi
PTF : Piyasa Takas Fiyatı
SMF : Sistem Marjinal Fiyatı
MYTM : Milli Yük Tevzi Merkezi
MSE : Hata Kareleri Ortalaması
MAPE : Ortalama Mutlak Hata Yüzdesi
SVM : Destek Vektör Makineleri
ARIMA : Otoregresif Entegre Hareketli Ortalama
YSA : Yapay Sinir Ağları
MLP : Çok Katmanlı Algılayıcı
PD : Pozitif Dengesizlik Fiyatı
ND : Negatif Dengesizlik Fiyatı
PDM : Pozitif Dengesizlik Maliyeti
NDM : Negatif Dengesizlik Maliyeti

SEMBOLLER

x_i : Sinir ağı girdileri

w_i : Sinir ağı ağırlıkları

y_m : Sinir ağı hedef değeri

O_m : Sinir ağı çıktı değeri

α : Öğrenme katsayısı

λ : Momentum katsayısı

Δw_{jm} : Sinir ağı ağırlık değişim miktarı

μ : Ortalama

σ : Standart sapma

G_{sc} : Güneş sabiti

G_0 : Atmosfere dik gelen güneş ışınımı

δ : Deklinasyon açısı

h : Saat açısı

$\emptyset$: Enlem açısı

ε : Düzeltme faktörü

θ : Zenit açısı

I : Yeryüzüne ulaşan ışınım

I_c : Açık bir günde gelen toplam ışınım

R^2 : Korelasyon katsayısı

$\Phi(z)$: Kümülatif olasılık dağılım fonksiyonu

π : Gelir fonksiyonu

$E[\pi]$: Beklenen gelir fonksiyonu

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: Biyolojik ve yapay sinir ağları arasındaki benzerlikler **11**
Çizelge 2.2: Yapay sinir ağlarının başarılı oldukları alanlar **15**
Çizelge 2.3: AND fonksiyonun girdi ve çıktı değerleri..... **16**
Çizelge 2.4: XOR probleminin girdi ve çıktı değerleri **16**
Çizelge 3.1: Meteorolojik değişkenlerin tanımlayıcı istatistik bilgileri **33**
Çizelge 3.2: Kategorik değişkenlere ait veri sayıları **33**
Çizelge 3.3: Değişkenlerin korelasyon değerleri **34**
Çizelge 3.4: Regresyon modeli özeti..... **34**
Çizelge 3.5: Regresyon modeli ANOVA tablosu **34**
Çizelge 3.6: Regresyon modeli değişken katsayıları ve güven aralıkları..... **35**
Çizelge 3.7: Aktivasyon fonksiyonlarına göre model performansları **38**
Çizelge 3.8: Öğrenme algoritmalarına göre model performansları..... **38**
Çizelge 3.9: Gizli nöron sayılarına göre model performansları..... **39**
Çizelge 3.10: Öğrenme oranına göre model performansları..... **40**
Çizelge 3.11: Bulutluluk durumlarına göre tahmin performansları **45**
Çizelge 4.1: Fiyat tahmini için kullanılan girdi değişkenleri..... **53**
Çizelge 4.2: Elektrik fiyatlarının tanımlayıcı istatistik bilgileri **53**
Çizelge 4.3: Piyasa takas fiyatının frekans değerleri **54**
Çizelge 4.4: Piyasa takas fiyatı değişkenlerinin korelasyon değerleri **56**
Çizelge 4.5: Doğrusal regresyon PTF modeli özeti **57**
Çizelge 4.6: Doğrusal regresyon PTF modeli ANOVA tablosu **57**
Çizelge 4.7: Doğrusal regresyon PTF modeli katsayıları ve güven aralıkları **57**
Çizelge 4.8: Aktivasyon fonksiyonlarına göre PTF tahmin performans sonuçları ... **60**
Çizelge 4.9: Öğrenme algoritmasına göre PTF tahmin performans sonuçları..... **60**
Çizelge 4.10: Gizli nöron sayısına göre PTF tahmin performans sonuçları **61**
Çizelge 4.11: Öğrenme oranına göre PTF tahmin performans sonuçları **61**
Çizelge 4.12: Doğrusal regresyon SMF modeli değişkenlerinin korelasyonları **65**
Çizelge 4.13: Doğrusal regresyon SMF model özeti **65**
Çizelge 4.14: Doğrusal regresyon SMF modeli ANOVA tablosu **65**
Çizelge 4.15: Doğrusal regresyon SMF modeli katsayıları ve güven aralıkları **66**
Çizelge 4.16: Aktivasyon fonksiyonuna göre SMF tahmin performanları..... **67**
Çizelge 4.17: Öğrenme algoritmasına göre SMF tahmin performanları **68**
Çizelge 4.18: Gizli nöron sayısına göre SMF tahmin performanları **68**
Çizelge 4.19: Öğrenme oranına göre SMF tahmin performanları **69**
Çizelge 5.1: Gerçekleşen ve tahmin edilen değerler **77**
Çizelge 5.2: Mevcut ve optimum durum karşılaştırması..... **80**
Çizelge 5.3: 05.11.2016 tarihli verilerdeki kritik oranın hesaplanması **80**
Çizelge 5.4: 05.11.2016 tarihli verilerdeki gelir ve maliyetler..... **81**
Çizelge 5.5: Mevcut durumdaki gelir ve maliyetler..... **82**

Çizelge 5.6: Gerçek fiyatlar bilindiği durumda gelir ve maliyetler **84**
Çizelge 5.7: Mevcut ve optimum durum karşılaştırması (Gerçek fiyatlar)..... **84**
Çizelge 5.8: Tahmin edilen fiyatların kullanıldığı durumda gelir ve maliyetler **85**
Çizelge 5.9: Mevcut ve optimum durum karşılaştırması (Tahmini fiyatlar)..... **85**
Çizelge 5.10: Farklı sapma değerlerine göre elde edilen sonuçlar **87**

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Yapay sinir hücresinin temel elemanları **12**
Şekil 2.2: İleri beslemeli yapay sinir ağı mimarisi **14**
Şekil 2.3: Geri beslemeli yapay sinir ağı mimarisi **14**
Şekil 2.4: Tek katmanlı algılayıcı örneği **15**
Şekil 2.5: AND fonksiyonunun şekilsel ve grafiksel gösterimi **16**
Şekil 2.6: XOR probleminin grafiksel gösterimi **17**
Şekil 2.7: Çok katmanlı algılayıcı örneği **18**
Şekil 2.8: XOR probleminin ÇKA ile çözümü **18**
Şekil 2.9: Öğrenmenin hata uzayında gösterimi **21**
Şekil 2.10: Çok boyutlu hata uzayı **21**
Şekil 2.11: Yapay sinir ağının ezberlemesinin grafiksel gösterimi **22**
Şekil 2.12: Yerel ve global minimum noktalarının grafiksel gösterimi **26**
Şekil 2.13: Aktivasyon fonksiyonlarının grafiksel gösterimi **28**
Şekil 3.1: Deklinasyon açısının yıl boyunca değişimi **30**
Şekil 3.2: Bulutluluk indeksi değerine göre güneş ışıması **31**
Şekil 3.3: Regresyon modeli gerçek ve çıktı değerleri serpilme diyagramı **35**
Şekil 3.4: Regresyon modeli gerçek ve çıktı değerleri ilişkisi **36**
Şekil 3.5: Regresyon modeli tahmin hatalarının grafiksel gösterimi **36**
Şekil 3.6: Aktivasyon fonksiyonlarına göre MSE değerleri **38**
Şekil 3.7: Öğrenme algoritmalarına göre MSE değerleri **39**
Şekil 3.8: Gizli nöron sayılarına göre MSE değerleri **40**
Şekil 3.9: Öğrenme oranına göre MSE değerleri **40**
Şekil 3.10: YSA modeli öğrenme eğrisi **41**
Şekil 3.11: YSA modeli hata dağılım histogramı **41**
Şekil 3.12: YSA modeli gerçek ve çıktı değerleri serpilme diyagramı **42**
Şekil 3.13: YSA modeli gerçek ve çıktı değerlerinin ilişkisi **42**
Şekil 3.14: YSA modeli tahmin hatalarının grafiksel gösterimi **42**
Şekil 3.15: Bulutluluk durumlarına göre saatlik ortalama elektrik üretimi **43**
Şekil 3.16: Açık havalardaki gerçek ve çıktı değerleri **44**
Şekil 3.17: Parçalı bulutlu havalardaki gerçek ve çıktı değerleri **44**
Şekil 3.18: Çok bulutlu havalardaki gerçek ve çıktı değerleri **44**
Şekil 3.19: Kapalı havalardaki gerçek ve çıktı değerleri **45**
Şekil 4.1: Geçmiş fiyat verilerine ait otokorelasyon fonksiyonu **52**
Şekil 4.2: Elektrik fiyatlarındaki uç değerler **54**
Şekil 4.3: Piyasa takas fiyatının frekans histogramı **55**
Şekil 4.4: Piyasa takas fiyatının kümülatif frekans histogramı **55**
Şekil 4.5: Doğrusal regresyon PTF modeli gerçek ve çıktı değerleri ilişkisi **58**
Şekil 4.6: Doğrusal regresyon PTF modeli hatalarının grafiksel gösterimi **58**
Şekil 4.7: Doğrusal regresyon PTF modelinin serpilme diyagramı **58**

Şekil 4.8: Gizli nöron sayısına göre hatanın değişimi **61**
Şekil 4.9: Öğrenme oranına göre hatanın değişimi **62**
Şekil 4.10: YSA PTF modelinin öğrenme eğrisi **62**
Şekil 4.11: YSA PTF modelinin hata dağılım histogramı **63**
Şekil 4.12: YSA PTF modelinin gerçek ve çıktı değerlerinin serpilme diyagramı .. **63**
Şekil 4.13: YSA PTF modelinin gerçek ve çıktı değerleri arasındaki ilişki **64**
Şekil 4.14: YSA PTF modeli hatalarının grafiksel gösterimi **64**
Şekil 4.15: Doğrusal regresyon SMF modelinin gerçek ve çıktı değerleri ilişkisi ... **66**
Şekil 4.16: Doğrusal regresyon SMF modeli hatalarının grafiksel gösterimi **67**
Şekil 4.17: Doğrusal regresyon SMF modelinin serpilme diyagramı **67**
Şekil 4.18: Gizli nöron sayısına göre SMF tahmin hatasının değişimi **69**
Şekil 4.19: Öğrenme oranına göre SMF tahmin hatasının değişimi **69**
Şekil 4.20: YSA SMF modelinin öğrenme eğrisi **70**
Şekil 4.21: YSA SMF modelinin hatalarının dağılım histogramı **71**
Şekil 4.22: YSA SMF modelinin serpilme diyagramı **71**
Şekil 4.23: YSA SMF modelinin gerçek ve çıktı değerlerinin ilişkisi **72**
Şekil 4.24: YSA SMF modeli hatalarının grafiksel gösterimi **72**
Şekil 5.1: Saatlere göre hata değerleri **74**
Şekil 5.2: Hataların olasılık yoğunluk dağılımı **74**
Şekil 5.3: Kritik oranın standart normal dağılım eğrisinde gösterimi **77**
Şekil 5.4: Kritik oran ve z değerinin grafiksel gösterimi **79**
Şekil 5.5: Günlere göre pozitif ve negatif dengesizlik maliyetleri **83**
Şekil 5.6: Farklı standart sapma değerlerine sahip normal dağılım eğrileri **86**
Şekil 5.7: Farklı sapma değerlerine göre maliyet azalış oranındaki değişim **87**

ELEKTRİK ÜRETİM VE FİYAT TAHMİN YÖNTEMLERİYLE ELEKTRİK PİYASASINDAKİ DENGESİZLİK MALİYETLERİNİN OPTİMİZASYONU

ÖZET

Elektrik üreten firmalar bir gün sonraki üretim tekliflerini elektrik piyasaları işletmecisi olan EPİAŞ'a bildirmektedir. Bu tekliflerin değerlendirilmesiyle oluşan arz ve talebe göre elektrik fiyatları belirlenerek elektrik ticareti gerçekleşmektedir. Ancak yenilenebilir enerjiden elektrik üretiminin hava şartlarına bağlı olarak gerçekleşmesinden dolayı ne kadar üretim yapılacağının tahmin edilmesinde hatalarla karşılaşılmaktadır. Tahmin edilen üretimin gerçekleşen üretimden az olması durumunda üretici firmalar negatif dengesizliğe düşmektedir ve piyasa işletmecisi tarafından belirlenen kurallara göre ceza ödemek durumunda kalmaktadır. Aynı şekilde tahmin edilen üretimin gerçekleşen üretimden fazla olması durumunda ise firmalar pozitif dengesizliğe düşmektedirler. Bu durumda üretim fazlası olan kısım EPİAŞ tarafından daha düşük bir fiyata satın alınmakta ve firmalar fırsat maliyeti ile karşılaşmaktadır. Bu nedenle elektrik üretiminin düşük hatayla tahmin edilmesi elektrik üreticileri açısından önem arz etmektedir.

Bu tezin 2. bölümünde literatürdeki güneş enerjisi üretim tahmini çalışmalarında en çok kullanılan yöntem olan yapay sinir ağları hakkında genel bilgilere yer verilmiştir. Tezin 3. bölümünde ise doğrusal regresyon ve yapay sinir ağları kullanılarak güneş enerjisi üretim tahmini için modeller kurulmuş ve en düşük hatayı veren model tespit edilmiştir.

En iyi tahmin modelleri kurulsa bile tam isabetli tahminler gerçekleştirmek mümkün değildir. Bu nedenle dengesizlik maliyetleri firmalar için kaçınılmaz olmaktadır. Tahmin edilen üretimin gerçekleşenden az veya fazla olması ihtimalleri durumunda negatif ve pozitif dengesizlik maliyetlerinin beklenen değerleri hesaplanmıştır. Bu maliyetlerin toplamını minimize edecek olan optimum teklifin belirlenmesinin, üretici firmaların gelirini arttırmaya katkı sağlayacağı düşünülmüştür. Ancak üretimde dengesizliğe düşüldüğünde uygulanacak olan cezalar elektrik fiyatlarına bağlı olarak belirlenmektedir. Elektrik fiyatları ise üretim tekliflerinin EPİAŞ'a bildirilmesinden sonra belirlenmektedir. Bu nedenle dengesizlik maliyetlerini minimize edecek olan optimum teklifin belirlenebilmesi için bir gün sonraki elektrik fiyatlarının da tahmin edilmesi gerekmektedir.

Tezin 4. bölümünde ise bir gün sonrasının Piyasa Takas Fiyatı ve Sistem Marjinal Fiyatı tahmin edilmiştir. Doğrusal regresyon ve yapay sinir ağları yöntemleri kullanılarak çok sayıda model kurulmuş ve en düşük hataya ulaşılan model tespit edilmiştir. Bu model kullanılarak çıktı değerleri elde edilmiştir.

Tezin 5. bölümünde ise firmaların maruz kaldıkları bu cezalar gazeteci çocuk problemi olarak ele alınmıştır. Dengesizlik maliyetleri göz önüne alınarak gelir fonksiyonu oluşturulmuştur. Beklenen geliri maksimize edecek olan gazeteci çocuk modeli kurulmuştur. Güneş enerjisi üretim tahmini çıktı değerleri ve elektrik fiyatı tahmini

çıktı değerleri gazeteci çocuk modelinde kullanılarak optimum teklif değeri belirlenmiştir. Öncelikle tahmin edilen üretim değerine göre elde edilecek gelir ve dengesizlik maliyetleri hesaplanmıştır. Daha sonra geliri maksimize eden optimum teklif değerine göre elde edilecek gelir ve dengesizlik maliyetleri hesaplanarak sonuçlar karşılaştırılmıştır. Optimum teklif değeri kullanıldığında ne kadar iyileştirme yapıldığı gözlemlenmiştir. Bu işlemler tahmin edilen elektrik fiyatları ve gerçek elektrik fiyatları için ayrı ayrı yapılarak elektrik fiyatı tahmin performansının gelir artışına etkisi araştırılmıştır.

Anahtar Kelimeler: Güneş enerjisi, elektrik fiyatı, tahmin, yapay sinir ağları, doğrusal regresyon, optimizasyon, gazeteci çocuk problemi

OPTIMIZATION OF IMBALANCE COSTS IN ELECTRICITY MARKET BY USING ELECTRICITY GENERATION AND PRICE FORECASTING METHODS

SUMMARY

Companies generating electricity report their electricity generation forecasts of the following day to EPIAS, which is the operator of electricity markets. Electricity prices are determined according to the supply and demand that is formed by evaluating these bids. Electricity trading takes place at these prices. If the forecasted generation is less than the actual generation, the producer firms are in negative imbalance and have to pay penalty according to the rules determined by EPIAS. In the same way, if the forecasted generation is more than the actual generation, the firms are in positive imbalance. In this case, the part with generation surplus is purchased by EPIAS with a lower price and a different penalty is applied to the firm. For this reason, accurate forecast of electricity generation is significant for electricity producers.

In the second chapter of this thesis, general information about artificial neural networks, which is the most used method in solar energy generation forecast studies in the literature, is given. In the third part of the thesis, models for forecasting solar energy generation using linear regression and artificial neural networks are set up and the model with the lowest error is determined. 4-months electricity generation data, measured at half hour intervals, were obtained from the manufacturer. Input variables that will affect the amount of electricity generation have been determined by reference to other studies in the literature. It is possible to divide these input variables in two ways: The variables used to calculate the solar radiation coming out of the atmosphere from the sun and the variables used to estimate how much of the sunlight coming out of the atmosphere has reached the earth. Theoretical solar radiation coming out of the atmosphere can be calculated using the zenith angle. At the same date interval of generation data, the current zenith angle was calculated for each half-hour period and these values were used as the input variable. Meteorological factors such as air temperature, humidity, wind velocity, air pressure and cloudiness are considered to have a significant effect in order to predict how much of the sunlight coming out of the atmosphere reaches the earth. Historical weather data of the region where the relevant solar panels are located are provided. Data related to the cloudiness were obtained as categorical variables. Six different categorical variables were used: clear, partly cloudy, mostly cloudy, overcast, snowy and rainy. Then, during the preprocessing of the data, the data when the zenith angle has negative values, namely between the time of sunset and sunrise, were removed from the dataset. The inclusion of these data in the forecast model, which we know that the generation is already zero and the zenith angle is negative, will cause the model to be trained incorrectly.

Linear regression model was set up after data preprocessing and determination of variables. The equation of the model is obtained and the forecasting performance is calculated. Then, lots of multi layer perceptron models were set up which is an

artificial neural network architecture that is frequently used in regression problems. Appropriate values of some parameters such as activation function, number of hidden neuron, learning algorithm and learning rate, required for training an artificial neural network model were searched. Firstly, default values are assigned for these parameters and output value is obtained. Then, the model which has the lowest error was determined by trying different values for all parameters. The error rate of the test data was reported and the results were compared with linear regression.

It is concluded that the cloudiness has a high impact on the electricity generation forecast. In cases that the weather is clear or partly cloudy, it can be predicted with low error, but in cases that the weather is mostly cloudy or overcast, the error rate increases. Similar studies were encountered in other references, and the reasons of this high error rate were examined in this study. In cases where the weather is mostly cloudy, this error rate is thought to be high due to the inhomogeneity of the clouds and the moving of the clouds constantly. There is some difficulties in determining when and how much the clouds block the sun. Some recommendations are provided to reduce this error rate. It was concluded that more comprehensive data on cloudiness should be collected. By using frequent technical solar radiation measurements or satellite images, it is possible to reduce the error rate of the forecasting in mostly cloudy and overcast weather conditions.

Even if the best forecast models are set up, it is not possible to make exact forecasts. For this reason, imbalance costs are inevitable for companies. The expected values of the negative and positive imbalance costs are calculated in the case of the probability of the forecasted generation being less or more than actual. It is thought that determining the optimum bid that will minimize the sum of these costs will contribute to increasing the revenue of the producer firms. However, the penalties for the imbalance in generation are determined by the electricity prices. Electricity prices are determined after the bids are reported to EPIAS. For this reason, it is necessary to forecast the electricity prices of the next day in order to determine the optimum bid which will minimize the imbalance costs.

In the fourth chapter of the thesis, the Market Clearing Price and the System Marginal Price of the next day are predicted hourly. Firstly, 1-year electricity prices were provided hourly from the website of EPIAS. During the preprocessing of the data, a cumulative frequency histogram of all data was created and it was noticed that there were extreme values in the electricity price. It has been determined that 99.3% of the data is between 0-250 and only 0.7% of all data is greater than 250. Thus, it is decided that the value of 250 should be the threshold. Input variables to be used in the forecast of electricity prices are decided by referring the other studies in the literature. According to these studies**,** it was learned that the electricity price at any hour is highly related to one day before, the adjacent hours of the day before, one week before, the adjacent hours of the week before, and electricity prices two weeks before. This information was also confirmed by drawing the autocorrelation function of electricity price data. Besides historical price data; it is thought that many social and economic factors such as weather conditions, exchange rates, electricity supply and demand, days of the week and holidays affect the electricity prices.

After determining the input variables, a linear regression model was set up for both Market Clearing Price and System Marginal Price forecast, then the forecasting performance was obtained. Later, during the training of the artificial neural network model, some parameter values are assigned by default. The model with the lowest error

rate was determined by trying different parameter values as in the electricity generation forecast study. The results of linear regression and artificial neural network performances were compared and reported. Although the mean of System Marginal Prices is lower than the Market Clearing Price, its standard deviation is higher. In addition, it has been calculated that the error rate of System Marginal Price forecast is higher than the Market Clearing Price. The reasons for this high error rate are investigated and some recommendations are also provided to reduce the error. System Marginal Price is occured as a result of rebalancing the deviations of supply and demands in the electricity market. Since these deviations can occur randomly, it is more difficult to predict the System Marginal Price rather than to predict the Market Clearing Price. In order to reduce this error rate, it is necessary to know the possible causes of the deviations in supply and demand. Only historical price data is not sufficient for forecasting of System Marginal Price. Circumstances of electricity producers and consumers, economic and political situation of the country may affect electricity generation and consumption. Obtaining comprehensive data on all factors that may affect electricity supply and demand, will be beneficial for better forcasting performance.

In the fifth chapter of the thesis, these penalties which companies are exposed to, are considered as the newsvendor problem. First of all, it is stated that how the costs which are occured in the cases of positive and negative imbalance, are calculated. In order to calculate these costs, it is necessary to know the Market Clearing Price and the System Marginal Price of the next day. Therefore, the predicted prices were used in the calculation of the imbalance costs. Actual electricity generation is considered as a random variable. The sum of revenue values corresponding to each value of electricity generation is defined as the expected revenue. The revenue function was created by means of the formulas which are used to calculate imbalance costs. To find the maximum value of this function, its derivative is equalized to zero. Thus, the revenue function has become a kind of newsvendor problem model. The critical ratio was calculated by solving the derivative. The critical ratio is equal to the cumulative probability density function of the optimum bid amount. By inversing this function, the optimum bid amount was calculated.

Then, if the optimum bid value is reported to EPIAS, the costs of imbalance are calculated what would be. The results compared with the current situation and it was observed that the costs decreased. This study was carried out twice, using both real prices and predicted prices. Thus, the effect of price forecasting performance on revenue growth was calculated. It was concluded that the revenue when the predicted prices are used is lower than the actual prices, but higher than the current situation. This result shows that even if the predicted prices are used, the newsvendor model works. Thus, it has been shown how much the improvements in price forecasting performance can increase revenue. In the last section, it is aimed to determine the normal distribution curve that best fits the distribution of the errors of electricity generation forecast. To find the standard deviation of this best fitted distribution curve, various values were tried and the standard deviation value that would maximize the revenue growth was calculated. When the standard deviation value changes, the critical ratio also changes. Then it makes optimum bid value be changed. The optimum bid value was revised and more revenue growth was achieved.

Keywords: Solar energy, electricity price, forecast, artificial neural networks, linear regression, optimization, newsvendor problem

1. GİRİŞ

1.1 Tezin Amacı

Güneş panellerinden elektrik üreten firmalar bir gün sonraki üretimlerini tahmin ederek elektrik piyasası işletmecisine üretim tekliflerini vermektedir. Verilen teklife göre elektrik fiyatları oluşmakta ve elektrik ticareti gerçekleşmektedir. Yapılan tahminlerde sapmalar olması durumunda ise üretici firmalara ceza uygulanmaktadır.

Bu tezin amacı çeşitli tahmin yöntemlerini kullanarak öncelikle güneş enerjisi üretimini tahmin ederek üretici firmaların piyasa işletmecisine mümkün olduğunca doğru teklifleri vermesini sağlamaktır. Sonrasında ise tahmindeki sapmalardan kaynaklanan maliyetleri minimize edecek olan optimum teklifi belirlemektir.

1.2 Literatür Özeti

1.2.1 Güneş enerjisi üretim tahmini

Ahmad vd. [1] yaptıkları çalışmada Yeni Zelanda'nın Auckland şehrinde 3 yıllık bir süre zarfında kaydedilen 9 farklı hava durumu değişkenini içeren saatlik verisetini kullanmıştır. Hibrit bir model olarak NARX, yapay sinir ağı modeli olarak çok katmanlı algılayıcılar (MLP) ve İstatistiksel bir yaklaşım olarak da otoregresif hareketli ortalamalar (ARMA) yöntemleri kullanılarak veriler eğitilmiş ve test edilmiştir. Saatlik global güneş ışınımının tahmini değerleri ölçülen değerlerle karşılaştırılmıştır. NARX yöntemi için hata kareleri ortalaması karekökü değeri (RMSE) 0.243 MJ/m2, MLP yöntemi için 0.484 MJ/m2, ARMA yöntemi için 0.315 MJ/m2 olarak bulunmuştur. NARX yönteminin bu öngörme yeteneği daha sonraki zamanlarda Yeni Zelanda'nın diğer şehirlerindeki çalışmalarda kullanılabileceği belirtilmiştir.

Leva vd. [2] fotovoltaik tesislerdeki enerji üretim tahmini için yapay sinir ağı modeli önermiştir. Yöntemin doğruluğunu eğitim veri setlerinin ve hata tanımlarının bir fonksiyonu olarak incelemiştir. Açık gökyüzü modeli ile gerçek bir fotovoltaik enerji santralinde yapılan deneysel faaliyetlere dayanarak 8 aylık verilerin analizi yapılmıştır

ve bir sonraki günün gündüz saatleri tahmin edilmiştir. Eğitim verisetinin hacminin ve iterasyon sayısını değiştirilmesiyle, modelin birçok defa uygulanmasıyla elde edilen farklı sonuçlar değerlendirilmiştir. Veriler havanın açık, kısmen bulutlu ve bulutlu olması şeklinde 3 kümeye ayrılarak hatalar değerlendirilmiştir. Modelin doğruluklarının güneşli günlerde daha yüksek, kısmen bulutlu ve bulutlu günlerde ise daha düşük olduğu sonucuna ulaşılmıştır.

Dolara vd. [3] fiziksel model ile hibritlenmiş yapay sinir ağları (PHANN) kullanarak 1-3 gün sonrasını tahmin etmiştir. Fiziksel tahmin modeli olarak bulutsuz havadaki teorik güneş ışıması değerinin dikkate alındığı Clear Sky Solar Radiation Model (CSRM) ve yapay sinir ağlarının özelliklerini birleştirerek "grey box" gibi davranan bir model önermişlerdir. CSRM modelinin amacını güneş doğuşu ve batışı arasındaki zamanı belirleyerek günlük maksimum güneş ışıması değerine sınır koymak olarak ifade etmişlerdir. Hatanın en az olduğu güneşli günlerde yapay sinir ağları modellerinde RMSE değeri %12.5 ve fiziksel hibritli yapay sinir ağları modelinde ise %4.98 olarak bulunmuştur.

Izgi vd. [4] 750W gücündeki güneş panelinden alınan verilere yapay sinir ağları yöntemini uygulamıştır. Bu çalışmada üretilen elektrik miktarı tahmininin en yüksek doğruluğa sahip olduğu tahmin aralığının belirlenmesi amaçlanmıştır. 5-35 dakikalık dönemde en iyi güneş enerjisi tahminine ulaşılmaıştır. 5 dakikadan az ve 35 dakikadan fazla tahminlerde varyasyonun arttığı görülmüştür. Eğitim ve test verisetlerinin Nisan ayındaki RMSE değeri 33-55 W, Ağustos ayında ise 37-63 W olarak hesaplanmıştır.

Hocaoğlu vd. [5] tarafından yapılan çalışmada, 1 Ağustos 2005 - 30 Temmuz 2006 döneminde güneş gözleminde toplanan saatlik güneş radyasyonu verilerini incelemiştir. Saatlik güneş radyasyonunun iki boyutlu gösterim modeli ile verilerin benzersiz bir şekilde görselleştirilerek doğru tahmin imkânı sağlanmıştır. Görüntü işleme yöntemleri kullanarak, sırasıyla günlere ve saatlere karşılık gelen satırlar ve sütunlarla görüntü modeli oluşturularak, iki boyutlu ve tek boyutlu modeller ileri beslemeli yapay sinir ağları ile test edilmiştir. Bulunan RMSE değerleri karşılaştırılmıştır. İki boyutlu modelde daha düşük hataya ulaşarak bu modelin belirgin avantajları olduğu gözlemlenmiştir.

Mellit vd. [6] büyük ölçekli fotovoltaik tesislerde üretilen enerjinin kısa vadede tahmini için basit ama neredeyse hatasız bir yaklaşımda bulunmuştur. Güneş ışıması, güneş paneli hücre sıcaklığı ve güç çıkışı verilerinden oluşan 1 yıllık veriler

kullanılmıştır. Havanın güneşli, parçalı bulutlu ve kapalı olması durumlarına uygulanmak üzere 3 farklı yapay sinir ağı modeli geliştirilmiştir. Güneşli, parçalı bulutlu ve kapalı günler için RMSE değeri 0.23kW - 0.27kW - 0.16kW, MAPE değeri ise %1.42 - %2.10 - %1.64 olarak bulunmuştur.

Wu vd. [7] 3 farklı yerdeki güneş panellerinden elde edilen enerji üretim verileri ile, atmosfer sıcaklığı, PV modül sıcaklığı ve güneş ışıması verileri kullanılarak 1 saat sonrasının enerji üretim miktarının tahminini yapmıştır. ARIMA, SVM, ANN, ANFIS ve Genetik algoritma kullanılarak bunların kombine edildiği hibrit bir model olmak üzere 5 farklı tahmin modeli geliştirilmiştir. Analiz sonuçları hibrit modelin en yüksek doğruluğa ulaştığını göstermiştir. 3 farklı tesis için %5.64, %3.43, %6.57 hata oranlarına ulaşılmıştır.

Yang vd. [8] hava şartlarına dayalı melez bir yöntem ile bir gün sonraki enerji üretimini saatlik olarak tahmin etmeye çalışmıştır. Önerdiği yaklaşım sınıflandırma, eğitim ve tahmin aşamalarından oluşmaktadır. Enerji üretimine ait tarihsel verileri sınıflandırma aşamasında self-organizing map (SOM) ve learning vector quantization (LVQ) ağları kullanılmıştır. Eğitim aşamasında sıcaklık, yağış ihtimali ve güneş ışıması verileri support vector regression (SVR) yöntemi kullanılarak eğitilmiştir. Tahmin aşamasında ise hava durumuna göre doğru tahmin için yeterli derecede eğitilmiş bir modeli seçmek için bulanık çıkarım yöntemi kullanılmıştır. Sayısal sonuçlar, önerilen yaklaşımın basit SVR ve geleneksel ANN yöntemlerinden daha iyi sonuçlar verdiğini göstermektedir.

Tao vd. [9] saatlik enerji üretimini tahmin etmek için hibrit bir model olan NARX tahmin modelini önermiştir. Eğimli bir yüzey üzerinde herhangi bir zamandaki açık gökyüzü güneş ışıma değerini hesaplamak için H. C. Hottel (1976)'in ışıma modelini uygulamıştır. Güneş ışıması, en yüksek sıcaklık, en düşük sıcaklık ve günlerin bulutluluk durumuna göre indeks değeri girdi değişkeni olarak kullanılmıştır. Önerilen yöntemin zamanla değişen girdi verilerine adaptasyonu sayesinde, hava durumu aniden değişse bile doğru olarak PV güç çıkışını yüksek doğrulukla öngörebildiği sonucuna ulaşmıştır.

Chen vd. [10] güneş ışıması, toplam bulut miktarı ve düşük bulut miktarı değişkenlerini kullanarak Self Organized Map (SOM) modeli geliştirmiştir ve güneşli, bulutlu ve yağmurlu havayı sınıflandırmıştır. Ön sınıflandırma sayesinde yapay sinir ağlarının radial basis functions (RBF) modeliyle verilerin daha iyi eğitilmesi

sağlanmıştır. Güneş ışıması, hava sıcaklığı, nem oranı, rüzgar hızı, rüzgar yönü, bulut, güneşlenme süresi hava basıncı değişkenleri yapay sinir ağının girdi değişkenleri olarak kullanılmıştır. Güneşli, bulutlu ve yağmurlu günler için hata değerleri (MAPE) sırasıyla %9.45, %9.88 ve %38.12 bulunmuştur.

Hocaoğlu, [11] güneş ışıması tahmin modellemesi için Gizli Markov Modellerinin kullanıldığı yeni bir yaklaşım önermiştir. Yapılan çalışmada, saatlik olarak ölçülen ortam sıcaklığı değerlerinin ortalamasının modelin gözlemleri olduğu kabul edilirken, saatlik güneş radyasyonu değerlerinin ortalaması ise matematiksel modelin sonuçlarını oluşturan gizli olaylar olarak düşünülmüştür. Tanımlanan durumların geçiş olasılık değerlerini oluşturan bir eğitim aşamasından sonra gizli Markov modeli parametreleri elde edilmiş ve test edilmiştir. Farklı özelliklere sahip modeller oluşturulup karşılaştırılmıştır. Farklı şehirlere ait verilerin analizini sonucu ulaşılan hatalar RMSE olarak 1.67 W/m2, 1.45 W/m2, 4.65 W/m2, 3.05 W/m2 ve MAPE olarak sırasıyla %5.79, %8.25, %12.06, %9.48 bulunmuştur.

Bouzerdoum vd. [12] mevsimsel otoregresif entegre hareketli ortalama (SARIMA) ve destek vektör makineleri (SVM) gibi iyi bilinen iki yöntemi birleştirerek yeni bir hibrit model önermiştir. 3 farklı model ile tesisin ürettiği gücün saatlik tahminleri birkaç gün boyunca gerçekleştirilmiştir. Hibrit modelin diğer iki modelden daha iyi tahminde bulunduğu sonucuna ulaşılmıştır. SARIMA modeli için RMSE hata değeri %9.56, SVM modeli için %9.62 ve SARIMA–SVM hibrit modeli için % 9.40 bulunmuştur.

Bracale vd. [13] bir fotovoltaik panel tarafından üretilen saatlik enerjinin olasılık yoğunluk fonksiyonunu tahmin etmek için kısa vadeli olasılık tahmin yöntemi önermiştir. Saatlik gökyüzü açıklık indeksinin olasılık yoğunluk fonksiyonu, Bayesian otoregresif zaman serisi modeli kullanılarak tahmin edilmiştir. Sonrasında ise Monte Carlo simülasyonu gökyüzü açıklık indeksi dağılımının rasgele örneklemesine uygulanarak, saatlik enerji üretimi tahmini yoğunluk fonksiyonu hesaplanmıştır. MARE değerleri yaz ayları için %18, kış ayları için %14.5 hesaplanmıştır. Gerçek ölçüm değerleri her zaman tahmin edilen değerlerin %5-95 yüzdelik dilimleri arasında olmuştur.

1.2.2 Elektrik fiyatı tahmini

Tayşi vd. [14] haftalık elektrik fiyat tahmini için ARIMA modeli ve ileri besleme yapay sinir ağı modeli olmak üzere iki ayrı yöntem kullanmışlardır. Takvim bilgisi ve geçmiş fiyat bilgileri girdi değişkeni olarak kullanılmıştır. Her iki yöntem için MATLAB yazılımı kullanılarak model oluşturulmuş ve 12 haftalık test verisi üzerinde her hafta için ayrı tahminler yapılmıştır. Mevsimsel ARIMA modelinin MAPE hata değeri %4,5 ile %14 arasında değişirken yapay sinir ağları modelinde ise %4 ile %11 arasında MAPE hata değeri elde edilmiştir.

Anbazhagan ve Kumarappan [15] tarafından yapılan çalışmada yinelemeli yapay sinir ağı modeli olan Elman ağları kullanılmıştır. Elman ağının sonuçları literatürde kullanılan ARIMA, en yakın komşu, bulanık yapay sinir ağları, uzman sistemler, radyal tabanlı fonksiyonlar ve parçacık sürü optimizasyonu gibi diğer yöntemlerin sonuçlarıyla kıyaslanmıştır. İspanya ve New York elektrik piyasası verileri üzerine yapılan çalışmada 4 ayrı mevsim için tahmin yapılmıştır. İspanya elektrik piyasası verilerinin MAPE hata değeri %4,11 - %9,09 arasında değişirken, New York piyasası verilerinin hatası %2,93 - %5,06 arasında değişmektedir. Kış ve ilkbahar mevsimlerinin hatasının yaz ve sonbahardan daha yüksek olduğu görülmüştür.

Kölmek ve Navruz [16] tarafından yapılan çalışmada tahmin edilen saatin bir gün ve bir hafta önceki fiyatlarının yanısıra, ortalama sıcaklık, tatil veya haftasonu olan günler, kapasite ve ikili anlaşmalar gibi toplam 12 girdi değişkeni kullanılmıştır. 342 günlük veri kullanılarak 3 haftalık tahminler yapılmıştır. 3 haftanın ortalama hata değeri yapay sinir ağı yönteminde %14,15 ve ARIMA yönteminde ise %15,60 olarak bulunmuştur.

Szkuta vd. [17] tarafından yapılan çalışmada ise geçmiş elektrik fiyatları, talep ve kapasite verileriyle birlikte gün tipi, mevsim ve tatil günleri bilgileri kullanılarak sistem marjinal fiyatının tahmini yapılmıştır. Geri yayılım algoritmasının kullanıldığı yapay sinir ağı modeli kurulmuş ve ardışık 7 günün tahmini gerçekleştirilmiştir. Günlere göre ortalama hata %4,16 ile %11,09 arasında değişmektedir.

Wang ve Ramsay [18] tarafından yapılan sistem marjinal fiyatı tahmini çalışması, literatürdeki ilk çalışmalarda birisidir. İngilterede enerji piyasasındaki üreticilerin üretim tekliflerini daha doğru yapabilmesi için gün için elektrik fiyatının tahmin ihtiyacı duyulmuştur. Fiyatın tahmin edileceğin günün 1 gün, 1 hafta ve 2 hafta öncesi aynı saatlerin ve bu saatlerin 1 saat önce ve sonrasının tahmin edilen fiyata etkisinin

fazla olduğu düşünülerek bu geçmiş değerler girdi değişkeni olarak kullanılmıştır. Geçmiş verilerin yanısıra, haftanın günleri ve günün saatleri de verilere girdi değişkeni olarak eklenmiştir. Haftaiçi günleri için ayrı tahminler yapılmış ve en yüksek hata değeri perşembe günü için %18,06 bulunmuştur. 5 günün ortalaması ise %12,86 olarak hesaplanmıştır.

Yamin vd. [19] yapay sinir ağları MLP mimarisini ve geri yayılım algoritması kullanarak fiyat tahmini çalışması yapmıştır. Geçmiş fiyat, geçmiş elektrik yükü ve yük tahmini bilgileri, gün saat ve sıcaklık değerlerini değişken olarak kullanmıştır. Tahminin daha gerçekçi olması için veri ön işleme aşamasında aykırı değerler çıkarılarak 56 günlük veri ile 1 haftalık tahmin yapılmıştır. Kurulan model ile ortalama %11-13 MAPE elde edilmiştir.

Biricik vd. [20] tatafından yapılan çalışmada ise elektrik fiyatı tahmininde kullanılan özelliklerin sonuca etkisi incelenmiştir. Takvim bilgisi, geçmiş fiyat bilgileri, yük tahmini, geçmiş yükler, döviz kurları ve hava durumu özelliklerinden kombinasyonlarından oluşan toplam 16 özellik kümesi oluşturulmuştur. Yapay sinir ağları kullanılarak oluşturulan model ile her bir özellik kümesi girdi değişkenleri olarak kullanılıp test edilmiştir. Takvim bilgisi - yük bilgisi - yük tahmini kombinasyonu %7,97 ve Takvim bilgisi - yük bilgisi kombinasyonu ise %8,92 hataya ulaşmıştır. Hava durumu, döviz kurları bilgileri ise sonuç üzerinde anlamlı bir etki göstermemiştir.

Panapakidis ve Dagoumas [21] yaptıkları çalışmada yapay sinir ağlarının tek başına uygulandığı modeller ve kümeleme algoritmalarıyla birlikte kullanıdığı hibrit modelleri incelemiştir. Eğitim verileri kümeleme yöntemleriyle benzer özellikte olanlar kümelenmiş ve her birisine yapay sinir ağı uygulanmıştır. Farklı değişkenlerin ve farklı yapay sinir ağı yapılarının kullanıldığı 6 farklı model oluşturulup performansları test edilmiştir. Modellerin MAE hata değerleri 5,8 – 7,18 arasında değişmektedir. Bu modeller literatürdeki ARMA ve GARCH modelleriyle kıyaslanmıştır.

Kaya vd. [22] tarafından yapılan çalışmada dalgacık dönüşümü (Wavelet Transformation–WT) ve destek vektör makinesinin (SVM) birleşimi olan hibrit bir yöntem önerilmiş ve gün öncesi elektrik fiyatlarının tahmini için kullanılmıştır. Elektrik fiyat verilerine dalgacık dönüşümü uygulanarak durağan olmayan verilerden daha iyi verim alınması sağlanmıştır. Daha sonra destek vektör makineleri ile kurulan

tahmin modelleri dört ayrı mevsim için uygulanmıştır. SVM yöntemi ortalama mutlak hata değeri 10,2 ve WT-SVM hibrit yöntem için 7,41 olarak hesaplanmıştır.

Özgüner [23] tarafından yapılan çalışmada piyasa takas fiyatı, sistem marjinal fiyatı ve saatlik yük verileri kullanılarak çok katmanlı yapay sinir ağı ve çoklu doğrusal regresyon yöntemleri kullanılarak fiyat tahmin modelleri geliştirilmiştir. 2011 yılı verileri kullanılarak yılın farklı dönemlerinde haftalık tahminler yapılmıştır. Yapay sinir ağı ile yapılan tahminde MAPE değeri %4,77 - %12,08 arasında değişirken, çoklu doğrusal regresyon ile yapılan tahminlerde ise MAPE, %5,32 - %12,88 arasında değerleri almıştır.

Pindoriya vd. [24] dalgacık dönüşümlü yapay sinir ağı (AWNN), radyal tabanlı fonksiyonlar (RBF), bulanık yapay sinir ağı (FNN) ve çok katmanlı algılayıcı (MLP) modellerini kullanarak dört mevsim için tahmin modelleri kurarak İspanya elektrik piyasasında fiyat tahmini yapmıştır. AWNN modeli %6,86 hata ile en düşük hataya ulaşan model olarak belirlenmştir. FNN modeli %7,8, RBF modeli %10,6 ve MLP modeli %10,97 hataya ulaşmıştır.

1.2.3 Elektrik piyasasında gazeteci çocuk yaklaşımı

Bhaskar ve Singh [25] yaptıkları çalışmada gün öncesi elektrik piyasasında rüzgar enerjisinin optimum teklifi için stokastik bir model önermektedir. Öncelikle ileri istatistiksel yöntemlerle noktasal tahminler gerçekleştirerek rüzgar enerjisi üretimi ve piyasa fiyatlarından kaynaklanan belirsizlikler nitelendirilmiş, daha sonra kernal yoğunluk tahmini yöntemi kullanılarak olası senaryolar üretilmiştir. Önerilen yaklaşımın etkinliği Avrupanın en büyük elektrik piyasası Nord pool'daki rüzgar enerjisi üreticileri üzerinde test edilmiştir. Analiz için 2011 ve 2012 yılı piyasa fiyatları dikkate alınmıştır. Test sonuçları, noktasal tahmin, stokastik optimizasyon ve hatasız tahmin yöntemleri ile elde edilen gelirlere göre karşılaştırılmıştır. Stokastik modelde hatasız tahmin durumunda elde edilen gelirin %93,9'u kadar gelir elde edilmiştir.

Matevosyan ve Soder [26] tarafından yapılan çalışmada dengesizlik maliyetlerinin en aza indirgenmesi için yeni bir yöntem geliştirilmiştir. Rüzgar enerjisi tahmin hatası stokastik bir süreç olarak gösterilmiştir ve Stokastik programlama ile kısa vadeli elektrik piyasası için optimum rüzgar enerjisi üretim teklifleri üretilmiştir. Geliştirilen yöntem Norveç, Finlandiya, İsveç ve Danimarka'yı kapsayan Nordic enerji piyasasında uygulanmıştır. Bu yöntemin kullanıldığı durumda ortaya çıkan

dengesizlik maliyetleri, rüzgar enerjisi üretim tekliflerinin doğrudan bir rüzgar hızı tahminine dayandığı durumda ortaya çıkan dengesizlik maliyetleri ile karşılaştırılmıştır. 1 aylık simülasyon sonucunda gelirde %5,44 oranında artış elde edildiği sonucuna ulaşılmıştır.

Herranz vd. [27] yaptıkları çalışmada kısa vadeli elektrik piyasasında son kullanıcılara elektrik sağlayan bir perakendeci firmanın optimum teklif verme stratejisini belirlemek için bir yöntem önermişlerdir. Gün öncesi ve gün içi piyasalarda enerji satın alma maliyetini minimize etmek amaçlanmıştır. En iyi satın alma stratejisini tanımlayan parametreleri optimize etmek için genetik algoritma modeli tasarlanmıştır. Önerilen yöntem, gün öncesi ve gün içi piyasada iki yıllık gerçek veriler kullanılarak test edilmiştir. Farklı elektrik piyasalarında yapılan uygulamalarda satın alınan birim elektrik başına 0,97–1,53 EUR/MWh arasında değişen tasarruf sağlanmıştır.

Gomes vd. [28] tarafından yapılan çalışmada ise rüzgar ve güneş enerjisi üretimindeki değişkenliği nedeniyle ortaya çıkan finansal cezaları azaltmak için rüzgar ve güneş enerji üretiminin bir araya getirilerek tek bir teklifle enerji ticaretinin yapılması önerilmiştir. En uygun teklif stratejisi doğrusal bir programlama problemi olarak ele alınmıştır. toplam kârı maksimize eden en uygun teklifi verme stratejisini elde etmek hedeflenmiştir. Rüzgar ve güneş enerjisi üretim sistemlerinin birlikte çalıştığı durumdaki elde edilen kar, bu sistemlerin ayrı ayrı elde ettiği kar ile karşılaştırılmıştır. Sistemlerin birlikte çalıştığı durumda %1,35 daha fazla kar elde edilmiştir.

Xue vd. [29] yaptıkları çalışmada hem yenilenebilir enerjiden elektrik üreten firmanın karını arttırmak hemde sistem operatörünün üretim dengesizliklerini dengelemek için daha az efor harcamasına katkı sağlamak için çok amaçlı bir optimal teklif verme stratejisi önermektedir. Bu strateji karışık tamsayılı doğrusal programlama problemi olarak ele alınmış ve bulanık optimizasyon teknikleri kullanılarak çözüm üretilmiştir. Geniş teklif aralığı belirlemenin daha riskli olduğu ama beklenen gelirin daha fazla arttığı sonucuna ulaşılmıştır.

Guo vd. [30] tarafından yapılan çalışmada rekabetçi bir elektrik piyasasına katılırken dengesizlik maliyetini düşürmek için bir enerji santralinin en uygun gerçek zamanlı çalışma stratejisi araştırılmıştır. Yenilenebilir enerji üretiminin ve elektrik fiyatlarının stokastik özelliklere sahip olması sebebiyle bu strateji stokastik bir problem olarak ele alınmıştır. Elektrik üretimi ve fiyatların oluşumu gibi rassal süreçlerin olasılık dağılımlarının bilinmesini gerektirmeyen bir “Lyapunov” optimizasyon tabanlı

algoritma önerilmiştir. Önerilen algoritmanın etkinliği elde edilen sayısal sonuçlarla gösterilmiştir.

Wan ve Fan [31] tarafından yapılan çalışmada elektrik üretimindeki belirsizliklerden kaynaklanan maliyetleri azaltmak için gün öncesi ve gerçek zamanlı piyasalarda uygulanan bir teklif stratejisi geliştirilmiştir. Bu strateji bir gazeteci çocuk problemi olarak ele alınmış ve iki aşamalı stratejik yöntem kullanılmıştır. Bu yöntem ile alıcının karar süreci ikiye bölünmüştür. Birinci aşamada elektrik perakendecisi ilk siparişi verir. İkinci aşamada ise değişen talep tahminine göre perakendeci ilk siparişini arttırarak ve azaltarak uygun değere ayarlayabilir.

Aksoy vd. [32] tarafından yapılan çalışmada rüzgar enerjisi üretimi için optimum teklif sistemi tasarlanmıştır. Üretim verileri kümeleme algoritmaları kullanılarak benzer özellikte olanlar kümelenmiş ve bunlara Yerel Yüzdelik Dilim Regresyonu yöntemi uygulanarak aralık tahminleri elde edilmiştir. Daha sonra elektrik fiyatlarını tahmin için zaman serisi yöntemleri kullanılmıştır. Üretim tekliflerinin optimum değerinin bulunması için stokastik programlama kullanılarak model geliştirilmiştir. Enerji üretimi ve fiyat tahminlerinin girdi değişkeni olarak kullanıldığı modelde, çıktı olarak beklenen gelirin maksimum değeri elde edilmiştir. Önceden kullanılan yaklaşımlarla kıyaslandığında gelir artışı elde edildiği gözlemlenmiştir.

Zhang vd. [33] tarafından yapılan çalışmada yenilenebilir enerji üretiminin tahmin hataları konusundaki belirsizliklerin üretim teklifini riskli hale getirdiğine değinilerek bu riskin ve dengesizlik maliyetlerinin azaltılması için gazeteci çocuk yaklaşımıyla üç farklı çözüm stratejisi oluşturulmuştur. Beklenen kâr maksimizasyon stratejisi (EPS), şans kısıtlı programlama tabanlı strateji (CPS) ve çok amaçlı teklif verme stratejisi (ECPS) uygulanarak sonuçları karşılaştırılmıştır. EPS kullanıldığı durumda teklifin, üretim tahmininin ortalama değeri ve standart sapmasına bağlı olduğu ve CPS kapsamındaki teklifin ise büyük oranda risk parametreleri ile ilişkili olduğu sonucuna ulaşılmıştır. EPS ve CPS'yi birleştiren ECPS ise iki teklifin arasında bir değer önererek bir uzlaşma eğilimi göstermiştir. Bu strateji riskten kaçınmak için iyi bir alternatif olarak önerilmiştir.

Çiğdem [34] yaptığı çalışmada ise gün öncesi elektrik piyasasındaki bir elektrik dağıtım firmasının karşılaştığı arz ve talep arasındaki enerji dengesizliği problemlemine çözüm aramıştır. Bu enerji dengesizliğinden dolayı elektrik dağıtım şirketlerine EPDK tarafından belirlenen bazı parametreleri içeren bir ceza

mekanizması uygulanır. Bu çalışmada ise gazeteci çocuk probleminin farklı bir modeli önerilerek elektrik piyasasına verilecek en iyi teklif belirlenmeye çalışılmıştır. Böylece firmanın karının maksimize edilmesi amaçlanmıştır. Çalışma sonucunda ise mevcut ceza parametrelerinin tahmin edilen enerji miktarından daha azının teklif olarak sunulmasının daha uygun olacağını belirlenmiştir. Bunun yanısıra ceza parametrelerinin etkisinin gün, saat ve bölgelere göre değişiklik gösterdiği sonucuna ulaşılmıştır.

1.3 Hipotez

Güneş enerjisinden elektrik üretiminin meteorolojik faktörlere bağlı olarak, elektrik fiyatlarının ise geçmiş fiyat bilgileri ve günlere bağlı olarak tahmin edilebileceği öne sürülmüştür. Yapay sinir ağları gibi doğrusal olmayan ve öğrenmeye dayalı yöntemlerin doğrusal yöntemlerden daha iyi tahmin performansına sahip olduğu gösterilmiştir.

Güneş enerjisi üretiminin ve elektrik fiyatlarının tahmin edilen değerleri elde edildiğinde, üretim tahminindeki sapmalardan kaynaklanan maliyetlerin minimize edilmesi için bir optimizasyon modelinin kurulabileceği ve optimum teklifin belirlenebileceği düşünülmektedir. Ayrıca elektrik fiyatı tahmin performansı yükseldikçe, dengesizlik maliyetlerinde daha fazla iyileştirme yapılabileceği düşünülmektedir.

2. YAPAY SİNİR AĞLARI

2.1 Yapay Sinir Ağlarının Yapısı ve Elemanları

İnsan beyninin öğrenmesi dışarıdan gelen bilgileri işlemesiyle mümkündür. Bir olayla karşılaştığında nasıl davranacağını öğrenen bir insan, aynı olayla daha sonra tekrar karşılaştığında nasıl davranacağını bilebilir. Bir çocuk sıcak bir nesneyi tutunca eli yandığı zaman bunu bir hata olarak kabul edip bu hatayı azalmak için başka bir zaman sıcak bir nesneye dokunmaması gerektiğini öğrenmiş olacaktır. Fakat hayatımız boyunca hiç karşılaşmadığımız bir vaka ile karşılaştığımızda ne tepki vereceğimizi bilemeyiz. Ne kadar çok olayla karşılaşır ne kadar çok veri işlersek beynimiz o kadar iyi eğitilmiş olacaktır.

İnsan beynini çok hızlı çalışan bir bilgisayar olarak kabul edebiliriz. İnsan beyninin kapasitesinin çok küçük bir kısmı kadar kapasiteyle bile çalışabilen bir bilgisayar yapılırsa olağanüstü seviyede bilgi işleme mekanizmaları geliştirmek mümkün olabilir. Bilgisayarların da tıpkı bir insanın karşılaştığı olay ve deneyimlerle bir bilgiyi öğrenebilmesi fikri araştırmacıların ilgisini çekmiştir [35].

Biyolojik sinir ağlarının yapısı ve çalışma prensibi dikkate alınarak insan beyninin öğrenme sürecinin bilgisayar ortamında matematiksel olarak modellenmesiyle yapay sinir ağları elde edilmiştir. Böylece insan beyninin öğrenme süreciyle benzer özellikler taşıyan yapay sinir ağları ile insan beynine ait bu yeteneğin makinelere kazandırılması amaçlanmaktadır [35].

Çizelge 2.1: Biyolojik ve yapay sinir ağları arasındaki benzerlikler [36].

Biyolojik Sinir Ağları	Yapay Sinir Ağları
Uyarıcı	Girdi
Reseptör	Girdi Katmanı
Sinir Ağı	İşleme Katmanları
Nöron	İşleme Elemanları
Efektör	Çıktı Katmanı
Sinapslar	Ağırlıklar
Dentritler	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıktı

Yapay sinir ağlarında da tıpkı biyolojik sinir ağlarını oluşturan sinir hücresi, sinaps, akson dentrit gibi yapıların fonksiyonunu üstlenen elemanlar bulunmaktadır. Yapay sinir ağlarını oluşturan temel elemanlar şunlardır:

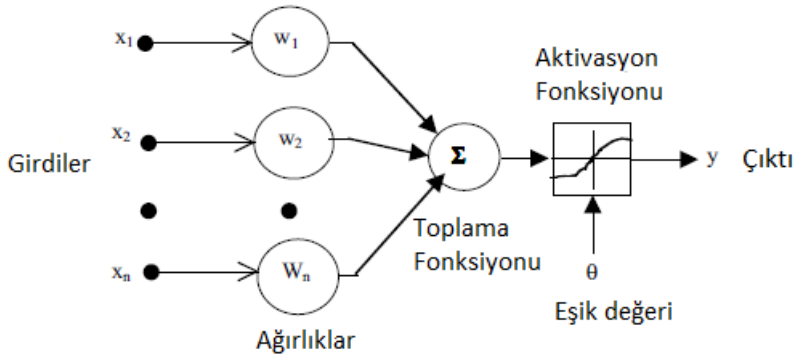
Girdiler: Dışarıdan veya başka bir sinir hücresinden gelen bilgilerin alınıp işlendiği elemandır.

Ağırlıklar: Bir hücreye gelen bilginin önemini ve sinir ağı üzerindeki etkisini gösteren değerlerdir. Ağırlıkların pozitif veya negatif olması etkinin de pozitif veya negatif yönlü olduğu, sıfır olması ise bir etkinin olmadığı anlamına gelir [35].

Toplama Fonksiyonu: Bir hücreye giren net bilgiyi hesaplamak için kullanılır. Bu amaçla kullanılan farklı formüller olsa da en sık kullanılan ağırlıklı toplama fonksiyonudur. Hücreye gelen her bilginin değeri ile ağırlıklarının çarpımlarının toplanmasıyla net değer bulunur. Toplama fonksiyonu şu formülle gösterilebilir [35].

$$net = \sum_{i}^{n} x_i . w_i \tag{2.1}$$

Çıktılar: Aktivasyon fonksiyonu ile hesaplanan sonuç değeri hücrenin çıktısıdır. Bu çıktı değeri dışarıya, başka bir hücreye yada hücrenin kendisine girdi olarak gönderilir.



Şekil 2.1: Yapay sinir hücresinin temel elemanları [37].

2.2 Yapay Sinir Ağlarında Öğrenme Stratejileri

2.2.1 Denetimli öğrenme

Bu tür stratejilerde bir sistemin olayı öğrenebilmesi için bir eğitmen gerekmektedir. Eğitmen öğrenilmesi gereken girdi ve çıktı verilerini sisteme verir. Sistem hangi girdi durumda hangi çıktının üretildiği bilgisinden yola çıkarak, girdi ve çıktılar arasında

bağlantıları öğrenir ve çıktının ne olması gerektiğini belirleyen kuralları oluşturur. Çok Katmanlı Algılayıcılar ve Radyal Tabanlı Fonksiyonlar Denetimli öğrenmenin kullanıldığı en bilinen yapay sinir ağı modelleridir.

2.2.2 Denetimsiz öğrenme

Denetimsiz öğrenmede sistemin olayı öğrenmesine destek olacak herhangi bir eğitmen yoktur. Sisteme sadece girdi verileri gösterilir. Denetimli öğrenmede olduğu gibi girdi ve çıktılar arsındaki bağlantının aksine, sadece girdi verilerinin birbirleriyle ilişkisini kendi kendine öğrenmesi istenir. Kümeleme problemleri için kullanılması uygun olan bir yöntemdir. Öğrenme işlemi tamamlandıktan sonra oluşan çıktı kümelerinin neyi ifade ettiği öğrenmeyi gerçekleştirenler tarafından etiketlenmesi gerekmektedir. Özdüzenleyici Haritalar (SOM) ve Adaptif Rezonans Teorisi Modelleri (ART) buna örnek olarak verilebilen sinir ağı modelleridir.

2.2.3 Takviyeli öğrenme

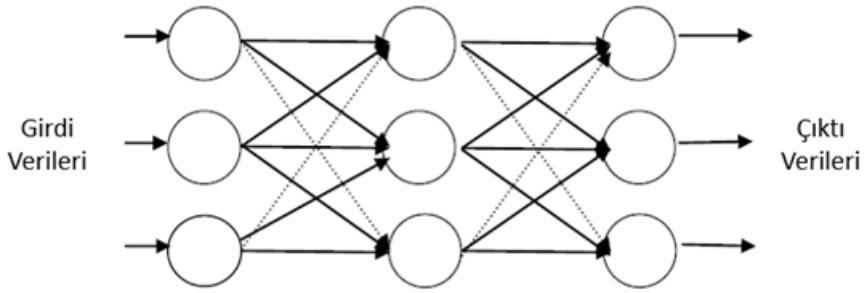
Takviyeli öğrenme kendi kendine kararlar alabilen bir sistemin sonuca ulaşmak için gereken doğru kararı nasıl öğreneceğini gösterir. Bu öğrenme stratejisinde sisteme bir eğitmen destek olur fakat denetimli öğrenmedeki gibi sisteme girdi ve çıktı arasındaki bağlantılar hakkında detay vermez. Bunun yerine sistem bir karar verdiğinde doğru olan kararlar için olumlu, yanlış olan kararlar için olumsuz bir sinyal üretir. Eğitmenden gelen bu sinyale göre öğrenmeye devam eder. Öğrenmeli Vektör Kuantalama modelleri (LVQ) bu stratejinin en yaygın kullanıldığı modellerden birisidir.

2.3 Yapay Sinir Ağı Mimarileri

İleri Beslemeli Ağlar: Katmanlar ardışık olarak bir araya getirilmiştir ve giriş katmanına uygulanan veriler katmanlar üzerinden çıkışa doğru ilerler. Çıktı değerleri hedef değerlerle karşılaştırılarak hata elde edilir. Bu hata değerine göre ise sinir ağının ağırlıkları güncellenir. Tek yönlü veri akışı vardır ve ileri yönlüdür [38].

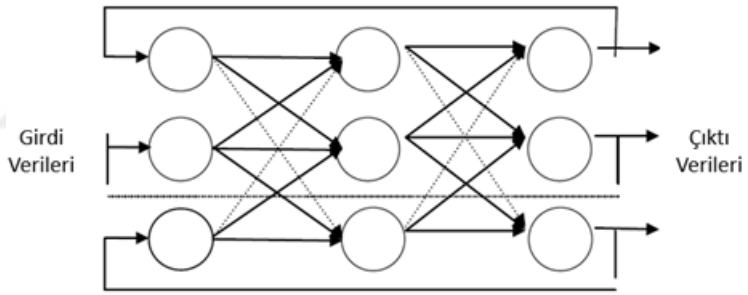
Bu ağ modellerinde türevi alınabilen bir aktivasyon fonksiyonunu olması önem arz etmektedir. Aksi halde geriye yayılım yöntemi kullanılamaz [39].

İleri beslemeli ağlara Çok Katmanlı Algılayıcılar (MLP) ve Öğrenmeli Vektör Kuantalama (LVQ) ağları örnek olarak gösterilebilir.



Şekil 2.2: İleri beslemeli yapay sinir ağı mimarisi [40].

Geri Beslemeli Ağlar: Bir sinir hücresinin çıktısı kendisine yada başka bir hücreye verilmektedir. Bu geri besleme işlemi genellikle bir geciktirme elemanı kullanılarak yapılmaktadır. Geri besleme aynı katmandaki sinir hücreleri arasında olabileceği gibi farklı katmanlar arasında da olabilmektedir. Bu özelliği sayesinde geri beslemeli ağlar doğrusal olmayan dinamik bir davranış gösterirler. Geri beslemeden dolayı hücreye gelen bilgiler arasında gecikmeler söz konusu olmaktadır. Ağın t anındaki çıktısı $O(t)$ ise $t + \Delta$ anındaki çıkışı $O(t + \Delta)$ olmaktadır. Δ değeri gecikme süresini ifade eder [39].



Şekil 2.3: Geri beslemeli yapay sinir ağı mimarisi [40].

2.4 Yapay Sinir Ağlarının Kullanım Alanları

Bir yapay sinir ağlarının tasarlanırken uygun ağ yapısının seçiminde problemin türü dikkate alınmalıdır. Hangi ağ yapılarının hangi problemlerde iyi sonuçlar verdiğinin bilinmesi tasarlanan sinir ağı modelinin performansını etkilemektedir. Uygun sinir ağına karar verilmesi kullanılması düşünülen öğrenme algoritmasına da bağlıdır. Örneğin geri yayılım algoritmasının kullanılması düşünülüyorsa bu algoritma ileri beslemeli ağ yapısının kullanımını zorunlu kılmaktadır. Yapay sinir ağları ve başarılı oldukları alanlar aşağıdaki çizelge'de gösterilmiştir [41].

Çizelge 2.2: Yapay sinir ağlarının başarılı oldukları alanlar [35].

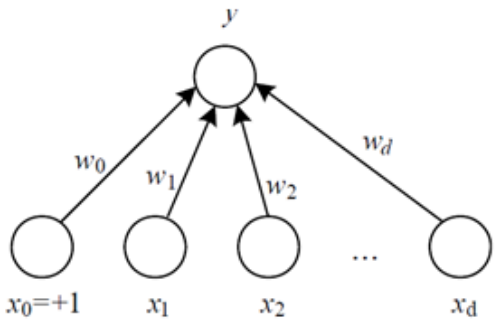
Problem Türü	Ağ Türü	Ağın Kullanımı
Tahmin	Çok Katmanlı Algılayıcılar (MLP)	Ağın girdilerinden çıktı değerinin tahmin edilmesi
Sınıflandırma	LVQ ART Olasılıklı Sinir Ağları (PNN)	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri İlişkilendirme	Hopfield Boltzman Makinesi	Girdilerin içindeki hatalı bilgilerin bulunması ve eksiklerin tamamlanması

2.5 Tek Katmanlı Algılayıcılar

Tek katmanlı sinir ağları sadece giriş ve çıkış katmanlarından oluşur. Ara katman bulunmadığı için sadece doğrusal problemleri çözebilme yeteneğine sahiptir. Çıktı nöronu bütün girdi nöronlarına bağlıdır ve her bağlantının bir ağırlık değeri vardır. Ağın çıktı değerinin sıfır olmasını önlemek içinse bir eşik değeri belirlenir. Ağırlıklar ile çarpılmış girdi değerlerinin eşik değeriyle toplanması ile ağın çıktısı hesaplanır. Bu işlem şu formülle gösterilebilir [35].

$$Y = f\left(\sum_{i=1}^{m} wi.xi + \Phi\right) \tag{2.2}$$

Ağırlık, sinir ağındaki hücrelerin birbiriyle olan bağlantısının gücünü göstermektedir. w_o değeri hata hücresi olan x_o hücresinin ağırlığını gösterir. x_o diğerlerinden farklı olarak +1 sabit değerini almaktadır [42].



Şekil 2.4: Tek katmanlı algılayıcı örneği [43].

Tek katmanlı algılayıcılarda ara katman bulunmadığı için çıktı fonksiyonu doğrusaldır. Ağa gösterilen veriler iki sınıfa ayrılır. Eşik fonksiyonu kullanılarak bu iki bölgeyi birbirinden ayıran doğru bulunmaya çalışılır. Ağın çıktısının aldığı 1 ve -1 değeri sınıfları temsil etmektedir.

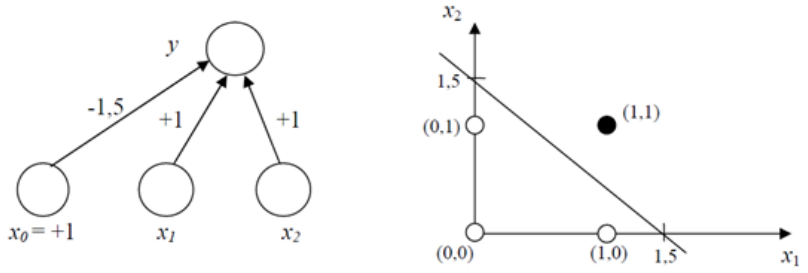
$$f(x) = \begin{cases} -1, & Y < 0 \\ 1, & Y \geq 0 \end{cases} \quad (2.3)$$

Bu formüle göre ağa gelen verilerin pozitif veya negatif olma durumuna göre çıktı 1 veya -1 değerini alır. Böylece veriler 2 sınıfa ayrılmış olur.

Tek katmanlı algılayıcıların en önemli eksikliği sadece doğrusal olan problemlerde kullanılabilmesidir. Örnek olarak girdi ve çıktıları 0 ve 1 olan AND fonksiyonu ele alındığında tek katmanlı algılayıcılarla ikili sınıflandırma problemi çözülebilmeltedir. AND fonksiyonunun girdi ve çıktı değerleri ile grafiksel çözümü şu şekildedir [43].

Çizelge 2.3: AND fonksiyonun girdi ve çıktı değerleri.

$x1$	$x2$	y
0	0	0
0	1	0
1	0	0
1	1	1



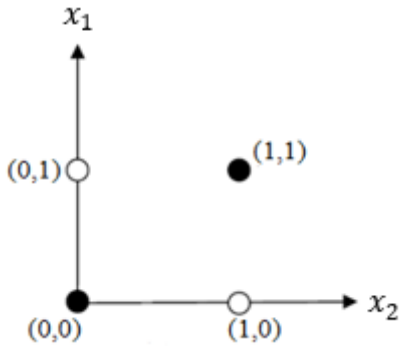
Şekil 2.5: AND fonksiyonunun şekilsel ve grafiksel gösterimi [43].

XOR Problemi

Tek katmanlı algılayıcılarda girdi ve çıktı arasında doğrusal bir ilişki vardı ve çıktı verilerinin bir doğruyla 2 sınıfa ayırmak mümkündü. Eğer girdi ve çıktı arasında doğrusal olmayan bir ilişki varsa bu olayları öğrenmek için tek katmanlı algılayıcılar ile mümkün değildir. Bu durumda ara katmanların kullanıldığı yeni modellere ihtiyaç duyulmuş ve çok katmanlı algılayıcı modelleri geliştirilmiştir. Değişkenler arasındaki doğrusal olmayan ilişkileri açıklamak için kullanılan en basit ve bilinen örnek XOR problemidir.

Çizelge 2.4: XOR probleminin girdi ve çıktı değerleri [43].

$\mathbf{x_1}$	$\mathbf{x_2}$	$\mathbf{y}$
0	0	0
0	1	1
1	0	1
1	1	0



Şekil 2.6: XOR probleminin grafiksel gösterimi [43].

Şekilde gösterilen siyah ve beyaz noktalar bir doğruyla iki ayrı sınıfa ayrılamaz. Grafiği matematiksel olarak modellediğimiz zaman aşağıdaki formülleri elde ederiz. Bu kısıtları sağlayan w_0, w_1, w_2 değerlerinin olmaması XOR probleminin doğrusal bir çözümünün mümkün olmadığını ispatlamaktadır.

$$w_0 \leq 0 \tag{2.4}$$

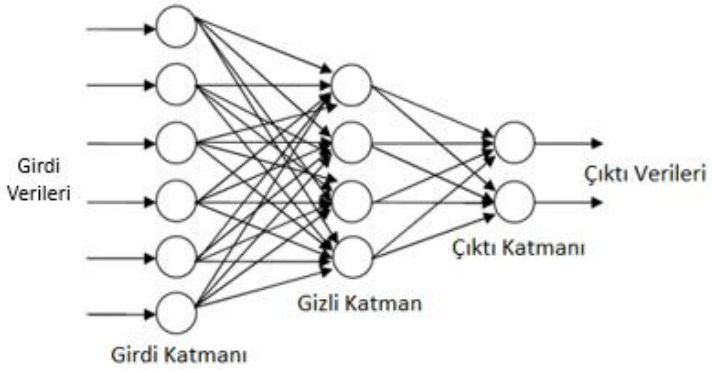
$$w_0 + w_2 > 0 \tag{2.5}$$

$$w_0 + w_1 > 0 \tag{2.6}$$

$$w_0 + w_1 + w_2 \leq 0 \tag{2.7}$$

2.6 Çok Katmanlı Algılayıcılar

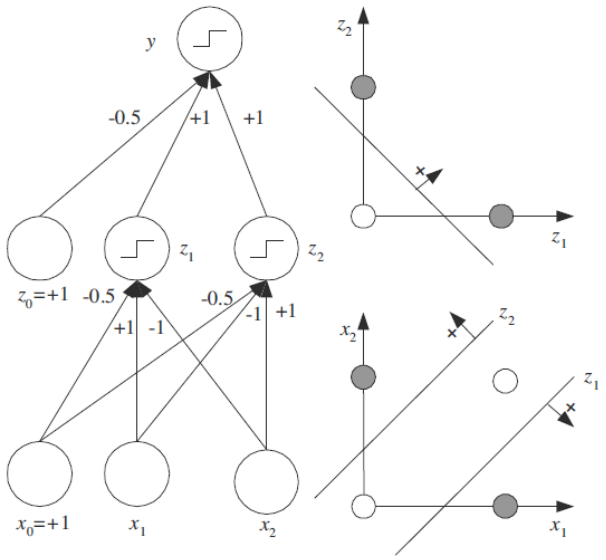
Tek Katmanlı algılayıcıların doğrusal olmayan problemleri çözmekte yetersiz olmaları sebebiyle yapılan araştırmalar sonucunda çok katmanlı algılayıcılar ve geri yayılım algoritması geliştirilmiştir. MLP'lerin doğrusal olmayan problemlerdeki başarısı ve özellikle tahmin problemlerinde iyi sonuçlar vermesi nedeniyle farklı alanlarda kullanımı hızla artmıştır. MLP'ler tek katmanlı algılayıcılardan farklı olarak bir veya birden fazla gizli katmana sahiptir. Geriye yayılım algoritması ile gizli katmanda yapılan işlemler sonucunda doğrusal olmayan bir sinir ağı yapısı oluşturulabilmektedir. Gizli katmandaki nöronlar doğrusal olmayan transfer fonsiyonları aracılığıyla ürettikleri çıktı değeri sonraki nöronun girdi değerini oluşturmaktadır. Sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu gibi doğrusal olmayan fonksiyonlar çok katmanlı algılayıcılarda sıklıkla kullanılan fonksiyonlardır.



Şekil 2.7: Çok katmanlı algılayıcı örneği [35].

XOR Probleminin Çözümü

Gizli katman ve çıkış katmanında eşik değeri 0 olan bir eşik aktivasyon fonksiyonu kullanılarak XOR problemi çözülebilmektedir [43].



Şekil 2.8: XOR probleminin ÇKA ile çözümü.

XOR probleminde $x_1 = 1$, $x_2 = 0$ iken $y = 1$ olması gerekmektedir. z_1 ve z_2 gizli sinir hücrelerine gelen net değere eşik fonksiyonu uygulandığında hücrelerin çıktısı şu değerleri alacaktır:

$$z_1 = f(-0{,}5 * 1 + 1 * 1 + (-1) * 0) = f(0{,}5) = 1 \quad (2.8)$$

$$z_2 = f(-0{,}5 * 1 + (-1) * 1 + 1 * 0) = f(-1{,}5) = 0 \quad (2.9)$$

z_1 ve z_2 gizli hücrelerinin çıktı değerleri, çıktı hücresinin girdi değeri olacaktır. Çıktı hücresinin değeri ise şöyle hesaplanır:

$$y = f(-0{,}5 * 1 + 1 * 1 + 1 * 0) = f(0{,}5) = 1 \quad (2.10)$$

Diğer x_1 ve x_2 girdi değerleri de ağa uygulandığında beklenen çıktı (y) değerlerinin hesaplandığı görülecektir. Böylece çok katmanlı algılayıcılar kullanılarak XOR probleminin çözülebildiği sonucuna varılmaktadır.

Geri Yayılım Algoritması

Geri yayılım algoritmasını temel mantığı her bir iterasyonda ağırlıkları güncelleyerek hatayı azaltmaktır. Öğrenme süreci, w ağırlık uzayınca E amaç fonksiyonunu (hata fonksiyonu) enküçüklemek olarak düşünülebilir. Hata değerini enküçükleyen çözüme ulaşmak için yapılması gereken ağırlıkları güncelleştirme işlemi sırasında gradyan inişi (gradient descent) yöntemi kullanılır [42].

Bulunan hata değeri pozitifse ağırlıklar azaltılarak, hata negatifse ağırlıklar arttırılarak güncelleme yapılır. Bu işlem son katmandan ilk katmana doğru hatayı yayarak yapılması sebebiyle geriye yayılım algoritması ismini almıştır.

Geriye yayılım algoritması en küçük kareler yöntemine dayalı delta öğrenme kuralına göre çalışır. Bu nedenle çok katmanlı algılayıcıların öğrenme kuralına Genelleştirilmiş Delta Kuralı denmektedir. Genelleştirilmiş Delta Kuralı ağın çıktısının hesaplandığı ve ağırlıkların değiştirildiği iki aşamadan oluşur. Gizli katmandaki nörona gelen net girdi değeri şu formülle bulunur [35].

$$net_j = \sum_{k=1}^{n} w_{kj}.O_k \tag{2.11}$$

w_{kj} değeri k. girdi katmanı hücresi ile j. gizli katmanı hücresi arasındaki bağlantının ağırlık değerini ifade eder. Gizli katman hücresinin çıktısı ise net girdi değerinin türevi alınabilir bir aktivasyon fonksiyonundan geçirilmesi sonucunda bulunur. Türevi alınabilir bir fonksiyon olan sigmoid fonksiyonunun kullanılması sonucunda oluşan çıktı değeri şu formülle hesaplanır:

$$O_j = \frac{1}{1 + e^{-(net_j + \beta_j)}} \tag{2.12}$$

Ağın çıktısı ile beklenen çıktı değerleri karşılatırılır. Aradaki fark hata olarak kabul edilir. Bu hata değeri geriye doğru yayılarak ağın ağırlık değerlerine dağıtılır. Böylece sonraki aşamalarda hatanın düşürülmesi amaçlanır. Çıktı katmanındaki m. hücrenin toplam hatası şu formülle hesaplanır:

$$E = \frac{1}{2}\sum_{m}(y_m - O_m)^2 \tag{2.13}$$

Gizli katmandaki j. hücre ile çıkış katmanı m. hücre arasındaki bağın ağırlığındaki değişim şu formülle bulunur:

$$\Delta w_{jm}(t) = \alpha.\delta_m.O_j + \lambda.\Delta w_{jm}(t-1) \tag{2.14}$$

Formüldeki α sembolü öğrenme katsayısını, λ ise momentum katsayısını göstermektedir. Öğrenme oranı ağırlıkların değişim hızını ayarlarken, momentum katsayısı ise, ağın öğrenme anında yerel optimum noktaya takılmaması için ağırlık değişiminin belli bir oranının bir sonraki değişime eklenmesini sağlar [35]. Formüldeki δ_m ifadesi hata değerini göstermektedir. δ_m değeri şu formülle hesaplanır:

$$\delta_m = f'(net).(y_m - O_m) \tag{2.15}$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyonunun kullanıması durumunda hata değeri şu hali alacaktır.

$$\delta_m = O_m.(1 - O_m).(y_m - O_m) \tag{2.16}$$

Değişim miktarı hesaplandıktan sonra mevcut ağırlık ile değişim miktarı toplanarak yeni ağırlık değeri bulunur. En düşük hataya ulaşana kadar ağırlık güncelleme işlemi her iterasyonda tekrar edilir.

$$w_{jm}(t) = w_{jm}(t-1) + \Delta w_{jm}(t) \tag{2.17}$$

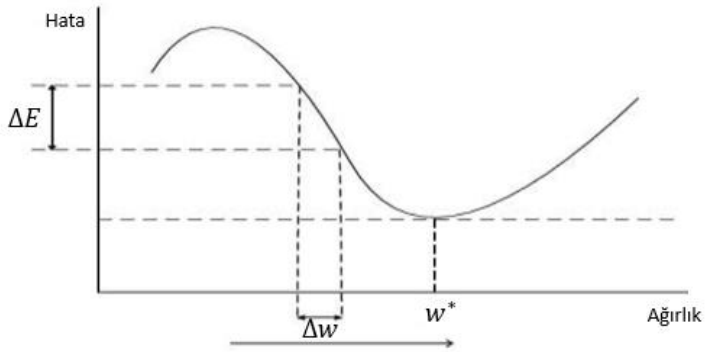
2.7 Ağın Eğitimi ve Test Edilmesi

Yapay sinir ağlarında nöronların bağlantılarının ağırlıklarının değiştirilerek en uygun ağırlığın bulunmasına ağın eğitilmesi denilmektedir. Bu ağırlıklar rastgele olarak atanır. Girdi ve çıktı verileri ağa gösterildikçe ağırlık değerleri güncellenir. Çıktı ile hedef değerleri arasındaki en düşük hatayı verecek ağırlık değerlerini bulmak amaçlanmaktadır. Sinir ağının en uygun ağırlık değerlerinin bulunması verilerin temsil ettiği olay hakkında genelleme yapabilme özelliğini kazanması anlamına gelmektedir. Bu özelliğin kazanılması işlemine ağın öğrenmesi denilmektedir [35].

Ağın öğrenmesi için uygun olan ağırlıkların ne olduğu bilinmemektedir. Bir yapay sinir ağı girdi değerinin çıktıya nasıl dönüştürüldüğü hakkında bilgi vermez. Yapay sinir ağlarının davranışlarını ve sonuca nasıl bir yol izleyerek ulaştığını açıklamak

mümkün olmamaktadır. Bu nedenle yapay sinir ağlarının çalışmasına kara kutu yakıştırması yapılmaktadır [35].

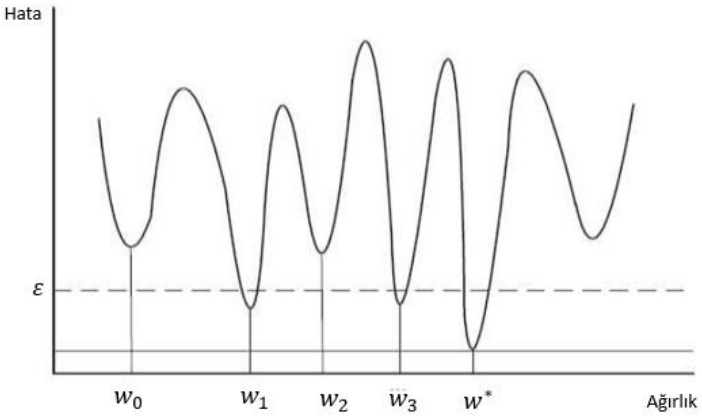
Ağın eğitimi sırasında her ağırlık güncelleme işleminde hatanın azalmasını ve en düşük hataya ulaşılan w* ağırlık değeri şu grafikle gösterilebilir.



Şekil 2.9: Öğrenmenin hata uzayında gösterimi.

Her itrasyonda ağırlık değeri Δw kadar değiştirilerek hata değeri ΔE kadar azaltılmaktadır. Bu problem için en düşük hatayı veren ağırlık değeri w^* olduğu biliniyor olsa da minimum hataya ulaşmak her zaman mümkün olmayabilir. Çünkü hata uzayı her zaman bu şekilde basit ve 2 boyutlu değil, bazı durumlarda daha karmaşık olabilmektedir.

Birden fazla çözümün olduğu ve sinir ağının en iyi olmayan çözümü bularak burada takılı kaldığı, performansı daha da iyileştirmenin mümkün olmadığı durumlar olabilmektedir. Bu durumda bulunan çözümlere yerel çözümler denilmektedir. Bu nedenle yapay sinir ağlarının her zaman en iyi çözümü buldukları söylenemez. Bulunan bir çözümün ise en iyi çözüm olup olmadığı bilinemez.

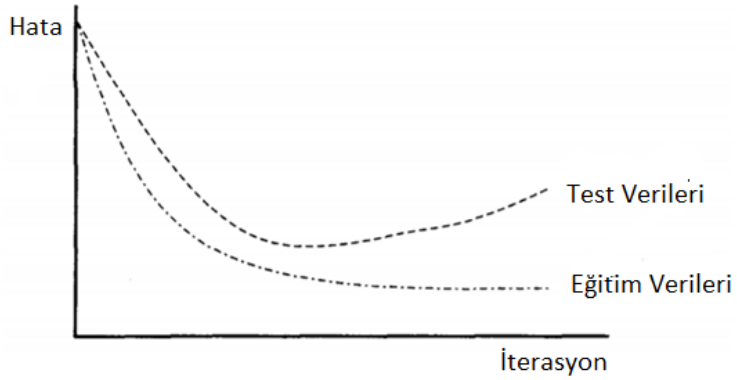


Şekil 2.10: Çok boyutlu hata uzayı.

Grafikte gösterilen w_1 ve w_3 noktaları kabul edilebilir seviyenin altında hataya sahip çözümleri, w_0 ve w_2 noktaları kabul edilemez çzöümleri, w^* ise optimum çözümü göstermektedir [35,41].

Ağın eğitiminden sonra öğrenip öğrenmediğinin denenmesi yani performansının ölçülmesine ağın test edilmesi denilmektedir. Ağın gerçekten öğrenip öğrenmediğini anlamak için eğitim sırasında görmediği örnekler gösterilerek bunları ne kadar hata ile tahmin ettiği belirlenmeye çalışılır. Böylelikle ağın genelleme yeteneğinin kazanıp kazanmadığı ve ele alınan olayı ne kadar iyi temsil ettiği test edilmiş olur.

Gizli katman ve nöron sayılarının gereğinden fazla olması ağın aşırı öğrenmesine yani ezberlemesine (overfitting) neden olur. Eğitim verilerindeki hata gittikçe düşse bile test hatası yükselmeye başladığı noktada ağın ezberlemeye başladığından söz edilebilir. Bu istenmeyen bir durumdur. Çünkü ağ eğitilirken genelleme yapabilme yeteneğini kazanması istenir. Gördüğü verileri çok iyi öğrenmesi değil, görmediği verileri iyi tahmin edebilmesi gerekmektedir. Bu nedenle eğitim ve test hatası ayrı ayrı değerlendirilerek ağın performans değerlendirmesi sırasında test hatasının dikkate alınması gerekmektedir. Ezberlemeye başlayan bir ağın eğitim ve test verilerinin hatasının değişimi grafikte gösterilmiştir [44].



Şekil 2.11: Yapay sinir ağının ezberlemesinin grafiksel gösterimi.

2.8 Verilerin Normalize Edilmesi

Yapay sinir ağlarında eğitimin daha verimli ve hızlı olabilmesi için verilerin ön işlemeden geçirilmesinin büyük etkisi vardır. Farklı kaynaklardan toplanan ve farklı birimlere sahip verilerin aynı ölçekte belirli bir aralığa indirgenmesine normalizasyon denmektedir. Veriler normalize edilerek aşırı büyük veya küçük değerlerin ağı yanlış yönlendirmesi engellenerek ağın performansının artmasına katkı sağlanabilir [40].

Min-Max Normalizasyonu: En düşük değer 0 en büyük değer 1 olacak şekilde verileri (0,1) aralığında doğrusal olarak normalize etmek için kullanılan formüldür [40].

$$x' = \frac{x_i - x_{max}}{x_{max} - x_{min}} \tag{2.18}$$

Sigmoid normalizasyonu: Verileri (0,1) veya (-1,1) arasında normalize etmek için kullanılan doğrusal olmayan bir yöntemdir [40].

$$x' = \frac{e^{xi} - e^{-xi}}{e^{xi} + e^{-xi}} \tag{2.19}$$

İstatistiksel normalizasyon: Aynı veriseti üzerindeki uç değerlerin sonuç üzerine çok fazla etkisi olacağı için her değişkenin aritmetik ortalaması ve standart sapması dikkate alınır ve böylece verideki uç değerlerin etkisi azalır [40].

$$x' = \frac{x_i - \mu_i}{\sigma_i} \tag{2.20}$$

2.9 Ağın Performans Kriterleri

Eğitim verileri ile eğitilen bir yapay sinir ağının kendisine daha önce hiç gösterilmeyen test verileriyle de tahmin performansının test edilmesi gerekmektedir. Girdi verileri eğitilmiş ağa verilerek çıktı üretmesi istenir. Girdi değerlerinin karşılığı olan ve zaten önceden bilinen gerçek çıktı değerleriyle karşılaştırılır. Aradaki fark ağın hatası olarak yorumlanır. Hatanın ölçümü için kullanılan farklı formüller vardır. Yapay sinir ağlarında en fazla kullanılan formülün hata kareleri ortalaması (MSE) olduğu söylenebilir [42].

Hata kareleri ortalaması gerçek değerler ile ağın çıktılarının farklarının karesinin toplamının veri sayısına bölünmesiyle bulunur.

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - O_i)^2 \tag{2.21}$$

Hata kareleri ortalamasının karekökü (RMSE) formülü de sıklıkla tercih edilen bir performans kriteridir.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - O_i)^2} \quad (2.22)$$

Ortalama mutlak yüzde hata (MAPE) formülü ise birimsiz hata ölçümüne ihtiyaç duyulduğu durumlarda kullanılmaktadır.

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{|y_i - O_i|}{y_i} \quad (2.23)$$

Ortalama mutlak hata (MAE) ise şu şekilde formülize edilebilir;

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - O_i| \quad (2.24)$$

2.10 Ağı Oluşturan Parametreler

2.10.1 Başlangıç ağırlıklarının belirlenmesi

Bir yapay sinir ağını oluşturan hücreleri birbirine bağlayan bağlantıların ilk ağırlık değerlerinin belirlenmesi ağın performansını önemli ölçüde etkileyebilmektedir. Başlangıç ağırlıkları geniş tutulan bir değer aralığından belirlenirse ağın eğitimi kısa sürmektedir fakat global optimum değere ulaşabilme ihtimali daha düşük olmaktadır. Bu durumda ağ yerel çözüm noktaları arasında dolaşmaktadır. Aralığın küçük olması durumunda ise global optimuma ulaşma ihtimali daha yüksek olmaktadır fakat bu sefer de ağın eğitimi daha uzun zaman almaktadır.

En uygun ağırlık değerlerinin ne olması gerektiği konusundan standart bir formül yoktur. Bu nedenle ağırlık değerleri genellikle rastgele belirlenmektedir. Ağın her eğitilmesinde rastgele belirlenen ağırlık değerleri farklı olacağından dolayı ulaşılan sonucun da farklı olması beklenir. Bir yapay sinir ağının performansının net olarak belirlenebilmesi için çok sayıda deneme yapılarak ulaşılan sonuçların ortalamasının alınması daha doğru bir yaklaşım olacaktır [35].

Eğer aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılırsa, fonksiyonun türevinin alınabilir olması açısından başlangıç ağırlıklarının (-0,01; 0,01) gibi dar bir aralıkta seçilmesi önem arz etmektedir. Büyük değerlerle başlanırsa sigmoid

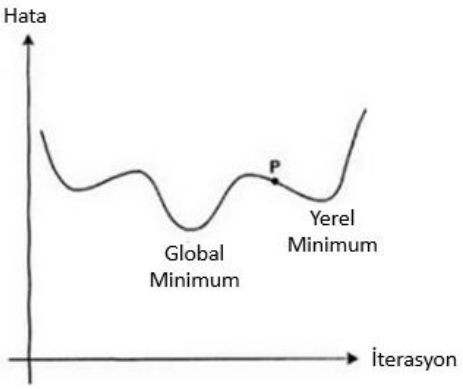
fonksiyonunun türevi 0'a çok yaklaşır ve bu durum öğrenmenin olmamasına sebep olabilir [43].

2.10.2 Öğrenme oranı ve momentum katsayısı

Bir ağın öğrenmesi belirlenen öğrenme algoritmasının kurallarına göre ağırlıkların güncellenerek en uygun ağırlığın bulunması demektir. Öğrenme oranı ise bu ağırlıkların her bir iterasyondaki güncellenme miktarını belirler. Bir başka ifadeyle öğrenme oranı öğrenmenin hızını belirlemeye imkan sağlar. Eğer büyük değer seçilirse, ağın eğitimi çok hızlı olmakta fakat yerel çözümler arasında gidip gelmesi ve osilasyon yaşanmasına sebep olmaktadır. Küçük değerlerin seçilmesi durumunda ise ağırlık değerlerinin değişim miktarı küçük olmaktadır yani ağın eğitimi için ince elenip sık dokunmaktadır. Bu durumda optimum değere ulaşma ihtimali artar fakat ağın eğitimi daha uzun zaman almaktadır [35].

Literatürdeki çalışmalara göre genellikle 0,2 - 0,4 arasındaki değerlerin kullanılabileceği sonucuna ulaşılmaktadır. Fakat bu genelleme her zaman doğru olmayabilir. Optimum değer problemin türüne ve verilere göre değişebilmektedir [35]. Öğrenme oranının büyük veya küçük olmasının avantaj ve dezavantajlarının olmasından dolayı optimum oranın hesaplanabilmesi için belirlenmiş bir yöntem yoktur. Genetik algoritmalar gibi evrimsel algoritmalar yardımıyla optimuma yakın değerler hesaplanabilir [45]. Yada farklı değerler denenerek elde edilen sonuçlar kıyaslanıp en düşük hatayı veren öğrenme oranı belirlenebilir.

Momentum katsayısı bir ağın eğitimi sırasında ağırlığındaki değişiminin belli bir oranının bir sonraki iterasyonda ağırlıklara eklenmesi sağlar. Bu sayede yerel çözümlere takılan sinir ağlarının bir sıçrama ile yerel sonuçlardan kurtulup daha düşük hataya ulaşmasını amacıyla kullanılabilir. Momentum katsayısı ise bu sıçrama mikrarını belirler. Bu değerin küçük olması sıçramanın yetersiz kalmasını sebep olarak yerel çözümden kurtulmayı zorlaştırabileceği gibi, çok büyük değerlerin kullanılması ise sıçramayı arttırarak sürekli farklı çözümler bulunmasına sebep olur ve global minimuma ulaşmayı zorlaştırabilir [35].



Şekil 2.12: Yerel ve global minimum noktalarının grafiksel gösterimi [46].

2.10.3 Gizli katman ve nöron sayısı

Bir yapay sinir ağını tasarlarken gizli katman sayısı ve bu katmanlardaki nöron sayısının ne olacağı belirlenmesi ağın ne düzeyde öğreneceğine doğrudan etki etmektedir. Dolayısıyla ağın performansı için önemli bir kriterdir. Fakat kaç tane gizli katman ve gizli nöron olması gerektiğine dair en iyi sonucu veren kesin bir yöntem bulunmamaktadır.

Literatürde bu konuda yapılmış bazı öneriler mevcutttur. Geometrik piramit kuralı adı verilen kurala göre birçok sinir ağında nöronların sayısının giriş katmanından çıkışa doğru azaldığı gözlemlenerek sinir ağının şekli piramite benzetilmiştir. Girdi nöron sayısı "n" ve çıkış nöron sayısı "m" olmak üzere bu kural gereğince gizli nöron sayısı $\sqrt{m.n}$ değerine eşittir [44].

Gruca ve Klenz [47], $\sqrt{2n+m}$ ile $(2n+1)$ arası bir değerin seçilmesini önermekte iken Hardgrave ve diğ.'e göre [48], $(n/2)$ ile $(2n+1)$ arasında bir değer seçilmesi gerekmektedir. Fakat bu formülleri genellemek doğru değildir. Her problem için en uygun gizli katman ve nöron sayısı farklılık gösterebilmektedir ve deneme yanılma yöntemiyle en uygun değeri bulmak daha doğru bir yaklaşımdır.

Kullanılan nöron sayısı azaldıkça sinir ağının problemlerin çözümüne yönelik genelleme yapabilme yeteneği artmaktadır fakat nöron sayısı gerekenden az olması durumunda ağın öğrenmesi yetersiz kalmaktadır. Nöron sayısı arttıkça sinir ağı daha fazla öğrenme gerçekleştirebilmektedir fakat nöron sayısının gereğinden fazla olması durumunda ise aşırı öğrenme yani ezberleme gerçekleşmektedir. Eğitim verilerinin hatası düşmeye devam ederken test verilerinin hatasının artmaya başladığı nokta ağın ezberlemeye başladığı noktadır. Ağın eğitimi tam da bu noktada durdurulmalıdır.

Deneme yanılma yoluyla optimum gizli nöron sayısının bulunması için 2 yöntem kullanılmaktadır. Az sayıda nöron ile eğitime başlayıp nöron sayısını sürekli arttırarak en düşük hataya ulaşılan nöron sayısını tespit etme yöntemine ağın büyütülmesi denir. Çok sayıda nöron ile başlayıp nöron sayısını sürekli azaltarak en uygun nöron sayısının bulunmasına ise ağın budanması adı verilmektedir [35].

Gizli katman sayısını belirlemek için de standart bir kural olmamakla beraber gerçek hayatta karşılaşılan problemlerde genellikle tek gizli katmanın yeterli olduğu gözlemlenmiştir. Genellikle sürekli olan ancak bazı durumlarda sürekliliğin bozulduğu durumlar varsa İkinci gizli katmana ihtiyaç olabilmektedir. Birden fazla gizli katman kullanmanın öğrenmeyi yavaşlatacağının da dikkate alınması gerekmektedir [49].

2.10.4 Aktivasyon fonksiyonu

Hücreye gelen net girdi değerini işleyerek çıktı değerine nasıl dönüştürüleceğini belirleyen formüllerdir. Kullanılan modele göre farklı fonksiyonlar kullanılabilir. Örneğin çok katmanlı algılayıcılarda sinir ağının yapısı gereği doğrusal olmayan ve türevi alınabilen fonksiyonların kullanılması gerekmektedir. Hangi durumlarda hangi fonksiyonun en uygun olduğunu belirleyen bir kural olmadığı için bu parametrenin seçimine deneme yanılma yoluyla karar verilmektedir.

Doğrusal Fonksiyon: Girdi değerlerinin olduğu gibi çıktı değerine dönüştürüldüğü aktivasyon fonksiyonudur.

$$f(net) = net \tag{2.25}$$

Parçalı Doğrusal Fonksiyon: Girdi değerlerinin (-1,1) arasında olduğunda doğrusal fonksiyon aksi durumda eşik fonksiyonun özelliğinin sahip olan aktivasyon fonksiyonudur.

$$f(net) = \begin{cases} 1, & net > 1 \\ net, & -1 < net < 1 \\ -1, & net < -1 \end{cases} \tag{2.26}$$

Eşik Fonksiyonu: Tüm girdi değerlerine karşılık iki farklı çıktı değerinin üretildiği fonksiyondur. Girdi değerinin sapma değerinden (Φ) küçük olması durumunda çıktı değeri α, büyük olması durumunda ise β değerini alır. α ve β değerleri tek kutuplu eşik fonksiyonunda [0,1], çift kutuplu eşik fonksiyonunda [-1,1] olarak seçilmektedir.

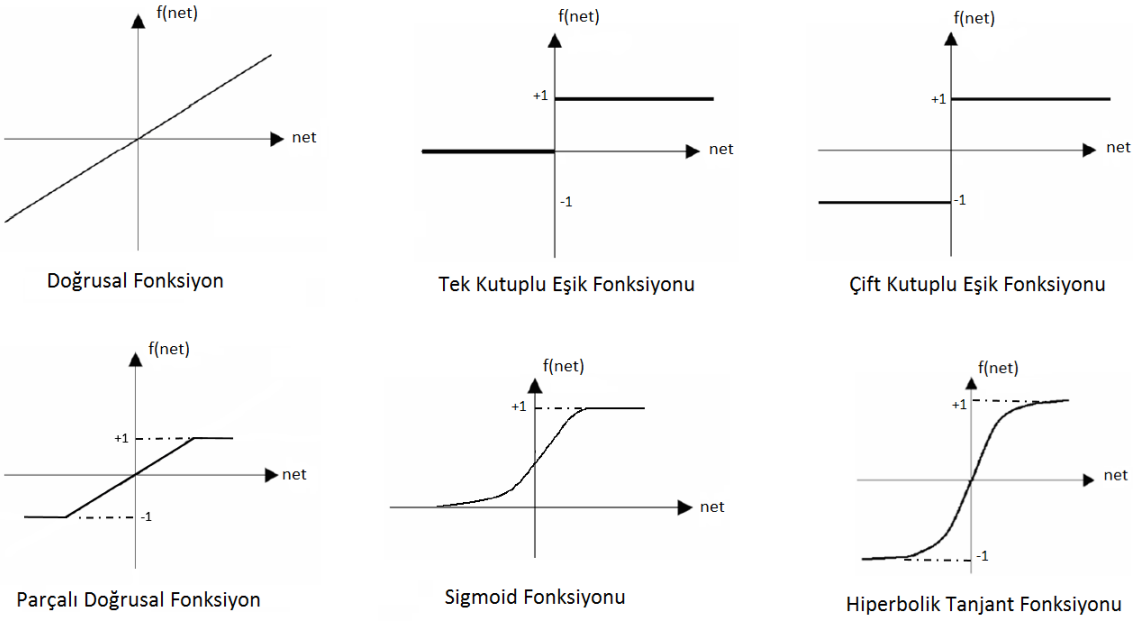
$$f(net) = \begin{cases} \alpha, & net < \Phi \\ \beta, & net \geq \Phi \end{cases} \quad (2.27)$$

Sigmoid Fonksiyonu: Sigmoid fonksiyonunun en önemli özelliği sürekli olduğu için türevinin alınabilmesidir. Aynı zamanda doğrusal olmayan yapısından dolayı yapay sinir ağlarında en fazla kullanılan aktivasyon fonksiyonu olmuştur. Sigmoid fonksiyonu [0,1] arasında değerler almaktadır.

$$f(net) = \frac{1}{1 + e^{-\alpha.net}} \quad (2.28)$$

Hiperbolik Tanjant Fonksiyon: Sigmoid fonksiyonunda olduğu gibi doğrusal olmaması ve türevinin alınabilmesi nedeniyle yapay sinir ağlarında sıklıkla kullanılmaktadır. Sigmoid foksiyonundan farklı olarak çift kutuplu bir fonksiyondur ve [-1,1] arasındaki değerleri alır. Matematiksel olarak şu şekilde formüle edilebilir:

$$f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}} \quad (2.29)$$



Şekil 2.13: Aktivasyon fonksiyonlarının grafiksel gösterimi [37,50].

3. GÜNEŞ ENERJİSİ ÜRETİM TAHMİNİ

3.1 Güneş Işınımı Hesaplanması

Güneşten atmosfer dışına, ortalama dünya–güneş mesafesinde birim alana birim zamanda dik gelen enerji miktarına güneş sabiti denir. Yapılan çalışmalarla ortalama güneş sabiti değeri $G_{sc} = 1367\mathrm{W}/m^2$ olarak hesaplanmıştır. Bu değer dünya meteoroloji örgütü tarafından da kabul edilmiştir [51].

Belli bir alana etki eden güneş ışıması, güneş ışınları ile dünya yüzeyinin normali arasındaki açıya bağlıdır. Bu açı değeri saate, belirlenen konumun enlem derecesine ve mevsime yani dünya güneş arası uzaklığa bağlı olarak değişiklik gösterir. Güneşten yayılan enerjideki değişimler ve dünya–güneş arası mesafenin mevsimsel değişimine göre ortalama $\pm\%3$ oranında değişiklik göstermektedir. Dünya ile güneş arasındaki mesafe değişiminin güneş ışımasına olan etkisi düzeltme faktörü ile hesaplanır. Düzeltme faktörü ise şu formülle hesaplanır:

$$\varepsilon = \left(1 + 0{,}033cos\left(\frac{360N}{365}\right)\right) \tag{3.1}$$

Düzeltme faktörünü dikkate aldığımız zaman güneş sabiti, yılın kaçıncı günü olduğuna bağlı olarak şu şekilde hesaplanır:

$$G'_{sc} = \varepsilon * G_{sc} \tag{3.2}$$

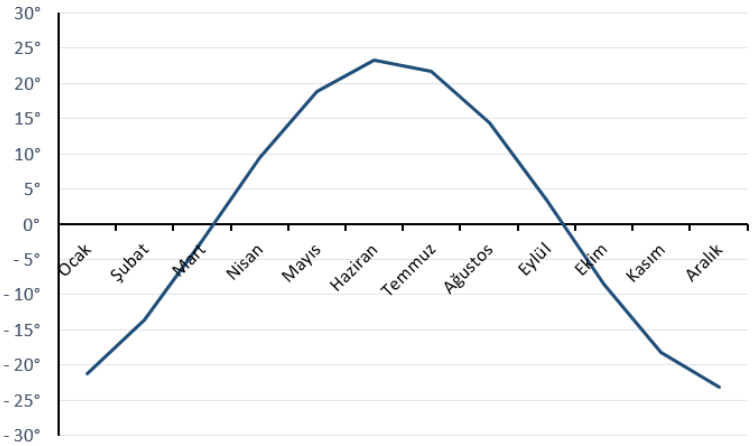
Herhangi bir andaki atmosfer dışına gelen güneş ışınımın hesaplanması için öncelikle güneş ışınları ile dünya yüzeyinin normali arasındaki açının yani zenit açısının bilinmesi gerekmektedir. Zenit açısının hesaplanması için; deklinasyon açısı (δ), saat açısı (h) ve bulunulan bölgenin enlem açısının $(\emptyset)$ bilinmesi gerekir. Herhangi bir andaki güneş ışınımı şu formülle hesaplanır [51]:

$$G_0 = \varepsilon . G_{sc} . cos\theta \tag{3.3}$$

Deklinasyon açısı (δ): Güneş ışınlarının ekvator düzlemi ile yaptığı açıdır. 21 Mart ve 22 Eylül gibi ekinoks günlerinde 0°dir. 21 haziranda maksimum değeri olan 23,45°, 21 Aralık'ta ise minimum değeri olan -23,45° değerini alır. Deklinasyon açısı şu

formülle hesaplanabilmektedir. Formüldeki n değeri 1 Ocaktan itibaren olmak üzere yılın kaçıncı günü olduğunu gösterir.

$$\delta = 23{,}45°.sin\left(360\frac{n+284}{365}\right) \tag{3.4}$$



Şekil 3.1: Deklinasyon açısının yıl boyunca değişimi.

Saat Açısı (h): Belirlenen herhangi bir yerin boylamı ile güneş ışınlarının belirttiği boylam arasındaki açıdır. Her 15° saat açısı 1 saate karşılık gelmektedir.

Zenit Açısı (θ): Güneş ışınlarının yatay düzlemin normali ile yaptığı açıdır. Güneş ışınlarının dik geldiği öğle saatinde $\theta = 0°$, güneşin doğuş ve batış saatlerinde $\theta = 90°$ değerini alır. Atmosfer dışına gelen anlık güneş enerjisi, o anki dünya güneş uzaklığına ve zenit açısına bağlıdır. Dünya güneş uzaklığı için ortalama bir değer kabul edildiği takdirde ise güneş ışınım değerini sadece zenit açısına bağlı olarak hesaplamak mümkündür.

$$\cos\theta = cos\emptyset.cos\delta\,.cosh + sin\emptyset.sin\delta \tag{3.5}$$

3.1.1 Atmosferin güneş ışınımına etkisi

Güneş ışınları atmosferde ilerlerken bulutların ve parçacıkların etkisiyle soğurulur, yansır ve saçılır. Bu sebeple güneşten gelen enerjinin tamamı yeryüzüne ulaşamamaktadır.

Güneş enerjisinin yaklaşık olarak [52];

- %31'i doğrudan yeryüzüne ulaşmaktadır.
- %23'u bulutlar ve atmosferdeki maddelerin etkisiyle geri yansır.
- %17'si atmosfer tarafından emilir.

- %0,6'sı toz parçacıklarının etkisiyle dağılır.
- %0,7'si topraktan yansır.

3.1.2 Bulutların güneş ışınımına etkisi

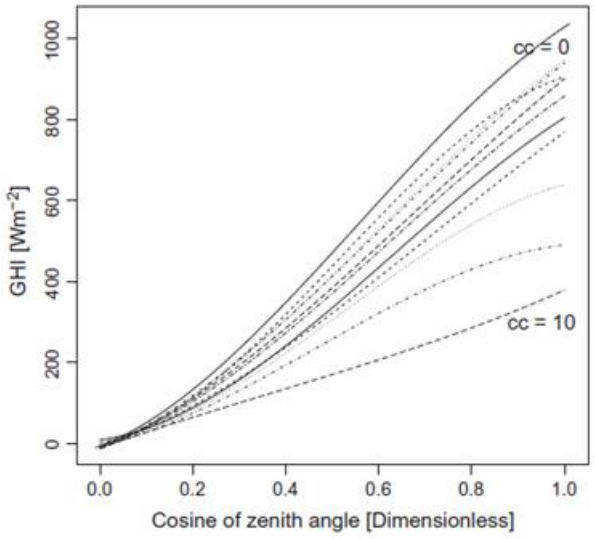
Bulutların soğurma, saçılma ve yansıtma etkileri, bulut tipi, güneşe göre konumlarına ve kapalılığına bağlı olarak değişiklik göstermektedir.

Güneşin örtülmediği parçalı bulutlu havalarda yeryüzüne ulaşan toplam güneş ışınımı, bulutsuz bir havada gelen ışınımdan daha fazla olabilmektedir. Böyle durumlarda doğrudan gelen ışınımın aynı kalmasının yanısıra yaygın ışınım etkisiyle buluttan yansıyan ışınların da tekrar yeryüzüne ulaşmasından dolayı ışınım artacaktır. Güneşi kapatan bulutluluk durumlarında ise ışımın açık havaya göre daima az olacaktır. Böyle durumlar haricinde bulutluluk arttıkça ışınım azalmaktadır [52].

Bulutların güneş ışınımını azaltmaları, geçirgenlikleri ile ifade edilir. Bulut geçirgenliği, bulutluluk indeksi ile hesaplanır. Buluttan yeryüzüne ulaşan toplam ışınımın açık bir günde gelen toplam ışınıma oranı bulutluluk indeksi olarak tanımlanır.

$$k = \frac{I}{I_c} \tag{3.6}$$

Farklı bulutluluk indeksi değerleri altında zenit açısının kosinüs değerine göre güneş ışımasındaki değişim grafikte verilmiştir [53].



Şekil 3.2: Bulutluluk indeksi değerine göre güneş ışıması.

3.2 Verilerin Hazırlanması ve Değişken Seçimi

Atmosfer dışına gelen güneş ışınımı, zenit açısına ve mevsime bağlı olarak hesaplanabilmektedir. Atmosfer dışına gelen teorik ışıma miktarı sadece bu bilgiler kullanılarak hesaplanabilmektedir. Fakat atmosfer dışından gelen ışınımın sadece belli bir miktarı yeryüzüne ulaşabilmektedir. Hava şartlarına ve bulutluluk duruma bağlı olarak yeryüzüne gelen ışınımın belli bir miktarı havadaki maddelerce soğurulmakta yada atmosfere geri yansıtılmaktadır. Bu nedenle hava sıcaklığı, nem oranı, hava basıncı, rüzgar ve havanın bulutluluk durumu gibi meteorolojik faktörlerin atmosfer dışı ışınım ile yeryüzüne ulaşan ışınım arasındaki farkın sebeplerini açıklayabileceği düşünülmektedir. Zenit açısının kosinüs değeri girdi değişkeni olarak kullanılarak herhangi bir gün ve saatteki güneşten atmosfere direkt gelen ışıma miktarı hesaplanabilir. Hava sıcaklığı, nem oranı, hava basıncı, rüzgar ve havanın bulutluluk durumu gibi bilgileri kullanılarak da atmosfere gelen ışınımın ne kadarının yeryüzüne ulaştığı tahmin edilebilir.

Bu çalışmada 1 Eylül 2016 – 31 Aralık 2016 tarihleri arasında ilgili güneş panellerinin bulunduğu bölgeye ait meteorolojik değerler temin edilmiştir. Hava sıcaklığı, nem oranı, hava basıncı, rüzgar ve havanın bulutluluk durumu bilgilerini içeren ve yarım saatlik ölçümlerden oluşan 122 günlük toplam 5856 veri bir araya getirilmiştir.

Literatürdeki bazı çalışmalarda bulutluluk durumu için teknik ölçümler yapılarak yada uydu görüntüleri kullanılarak 1-10 arasında değerler alan bulutluluk indeksi değerleri ölçülmüştür. Böylece bulutluluk durumu ifadesinin sayısal bir karşılığı elde edilmiştir. Ancak bu çalışma için temin edilen verilerde havanın durumunu ifade eden kategorik değerler elde edilmiştir. *Açık, Parçalı Bulutlu, Çok Bulutlu, Yağmurlu, Karlı, Kapalı* olmak üzere 6 farklı kategorik değişken, bulutluluk durumu ifade eden girdi değişkenleri olarak kullanılmıştır.

Verilerin elde edildiği tarih aralığında her yarım saat için o andaki zenit açısı değeri (3.5) formülü yardımıyla hesaplanmıştır.

Hesaplanan zenit açısı değeri herhangi bir andaki anlık gelen ışıma miktarını ifade etmektedir. Ancak enerji üretim değeri son yarım saatteki üretmi ifade etmektedir. Örneğin saat 9:00'daki enerji üretim değeri 8:30 ile 9:00 arasındaki üretimin toplamıdır. Bu nedenle zenit açısının da 8:30 - 9:00 arasındaki değişimi üretime etki etmektedir. Bu problemin pratik bir çözümü olarak iki ölçüm zamanının ortalaması

alınmıştır. Yani 8:45 deki zenit açısı hesaplanarak 8:30 - 9:00 arasındaki üretimi tahmin etmek için kullanılabilir. Bu nedenle her veri için 15 dakika öncesinin zenit açısı değerlerinin kosinüsü girdi değişkeni olarak kullanılmıştır.

Gece Saatlerinin Verisetinden Çıkarılması

Zenit açısının negatif değerler aldığı saatler güneşin batışı ile doğuşu arasında geçen gece saatleridir. Bu saatlerde üretim sıfırdır. Veri ön işleme aşamasında negatif değerler sıfıra eşitlenmiştir. Böylece zenit açısının sıfır olması güneş ışımasının olmaması ve üretimin sıfıra eşit olması anlamına gelmesi sağlanmıştır. Eğer bu verileri de analize dahil edersek tahmin modeli zaten sıfır olacağını bildiğimiz bir değeri tahmin etmeye çalışacaktır. Yapılan analizde gece saatleri için sıfıra çok yakın değerler tahmin edilmiştir. Gece değerleri için yapılan tahminlerin hatası, gün içindeki tahminlerin hatasından daha düşük çıkmaktadır. Bu durumda toplam hata artıyor olsa da hata kareleri ortalaması (MSE) değeri azalmaktadır. Tahmin modeli için olması gerekenden daha düşük bir hata hesaplanacaktır ve bu durum yanılgıya sebep olacaktır. Daha gerçekçi sonuçlar elde etmek için zenit açısının sıfır olduğu değerler tahmin uygulamalarına dahil edilmemiştir.

Gündüz verilerdeki meteorolojik değişkenlere ait tanımlayıcı istatistik bilgileri Çizelge 3.1'de, bulutluluk durumu kategorik değişkenlerine ait veri sayıları ise Çizelge 3.2'de verilmiştir.

Çizelge 3.1: Meteorolojik değişkenlerin tanımlayıcı istatistik bilgileri.

Değişken	Birim	Maksimum	Minimum	Ortalama	Standart Sapma
Sıcaklık	°C	33	-16,00	12,52	9,67
Nem Oranı	%	100	9	44,58	22,79
Basınç	hPa	1033	1005	1019,57	4,61
Rüzgar Hızı	km/sa	48,20	0,00	7,04	7,27

Çizelge 3.2: Kategorik değişkenlere ait veri sayıları.

Bulutluluk Durumu	Veri Sayısı
Açık	708
Az Bulutlu	488
Parçalı Bulutlu	480
Çok Bulutlu	753
Yağmurlu	61
Kapalı	39
Karlı	61

3.3 Doğrusal Regresyon ile Elektrik Üretim Tahmini

4 aylık elektrik üretim verilerinin eğitim seti için ayrılan kısmı kullanılarak SPSS programında çoklu regresyon analizi yapılmıştır. Bulutluluk durumunu ifade eden *Açık, Parçalı Bulutlu, Çok Bulutlu, Karlı, Yağmurlu* ve *Kapalı* değişkenleri kategorik değişkenler olarak tanımlanarak [0,1] değerlerini almıştır. Analiz sonucunda bağımsız değişkenlerin bağımlı değişken (Üretim Miktarı) ile korelasyonu çizelge 3.3'de verilmiştir.

Çizelge 3.3: Değişkenlerin korelasyon değerleri.

Değişken	Korelasyon
Sıcaklık	,367
Nem oranı	-,499
Basınç	,234
Rüzgar Hızı	-,194
cos Φ	,738
Açık	,134
Parçalı bulutlu	,246
Çok Bulutlu	-,260
Karlı	-,170
Yağmurlu	-,121
Kapalı	-,135

Zenit açısının kosinüs değeri (cos Φ) %73,8 korelasyon değeriyle üretim miktarı ile en alakalı olan değişken olmuştur. Sıcaklık değişkeninin (cos Φ) değişkeninden sonra üretim miktarıyla en çok ilişkili olan 2. değişken olduğu gözlemlenmiştir.

Modelin, Korelasyon katsayısı ve tahminin standart hatası değerleri Çizelge 3.4'de verilmiştir. Regresyon ve hataların kareleri toplamı, F değeri ve anlamlılık değerlerini içeren ANOVA tablosu ise Çizelge 3.5'te verilmiştir.

Çizelge 3.4: Regresyon modeli özeti.

R	R Square	Adjusted R Square	Std. Error of the Estimate
,851	,725	,72347	,3577737

Çizelge 3.5: Regresyon modeli ANOVA tablosu.

	Sum of Squares	df	Mean Square	F	Sig.
Regression	868,299	10	86,830	678,348	,000
Residual	330,117	2579	,12800		
Total	1198,417	2589			

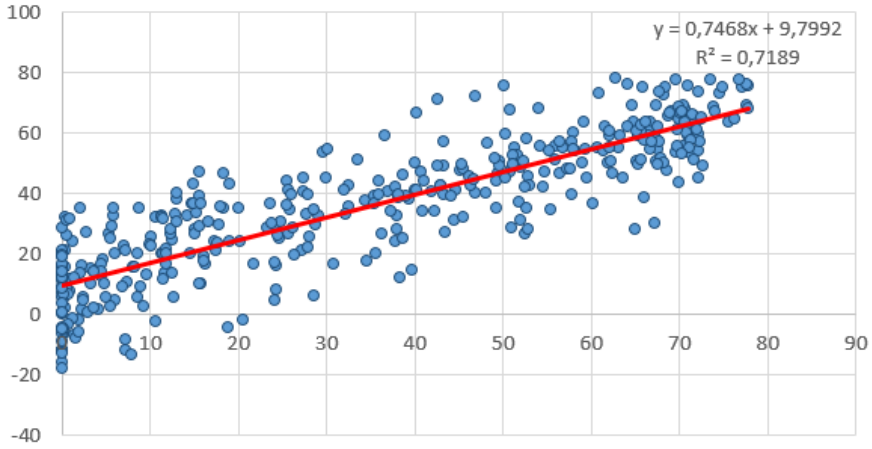
Model değişkenlerinin katsayıları, anlamlılık değerleri ve güven aralıkları Çizelge 3.6'da verilmiştir. Çizelgedeki ß katsayıları göz önüne alınarak oluşturulan regresyon denklemi şu şekilde gösterilebilir:

$$y = -0{,}583 - 0{,}251x_1 - 0{,}364x_2 + 0{,}401x_3 - 0{,}283x_4 + 0{,}969x_5 + 0{,}017x_6 - 0{,}094x_7 - 0{,}052x_8 - 0{,}104x_9 - 0{,}098x_{10} \quad (3.7)$$

Çizelge 3.6: Regresyon modeli değişken katsayıları ve güven aralıkları.

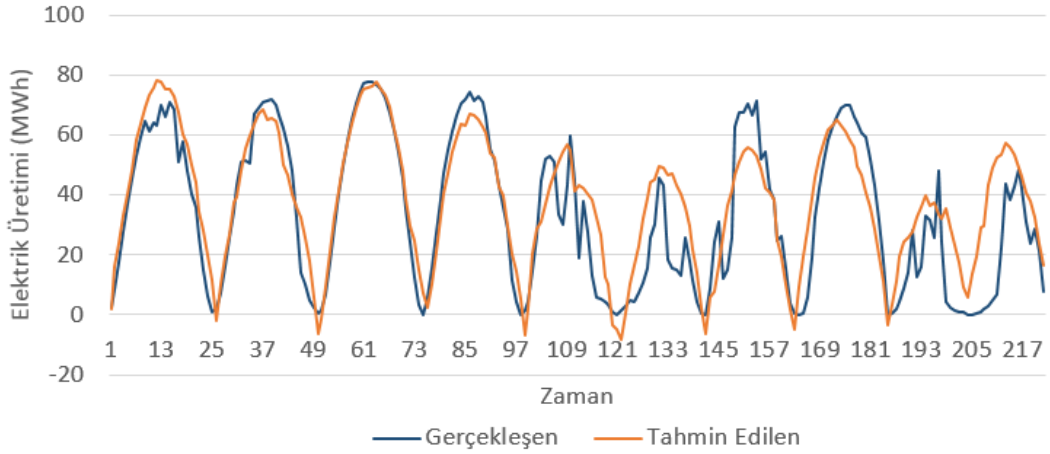
	Coefficients				95% Confidence Interval for B	
Model	B	Std. Error	t	Sig.	Lower Bound	Upper Bound
(Constant)	-,583	,055	-10,649	,000	-,691	-,476
Sıcaklık	-,251	,035	-7,230	,000	-,319	-,183
Nem oranı	-,364	,025	-14,663	,000	-,413	-,315
Basınç	,401	,028	14,351	,000	,346	,455
Rüzgar Hızı	-,283	,025	-11,189	,000	-,333	-,233
cos Φ	,969	,017	58,384	,000	,936	1,001
Açık	,017	,010	1,820	,009	-,001	,036
Çok Bulutlu	-,094	,009	-10,009	,000	-,112	-,075
Karlı	-,052	,027	-1,960	,050	-,104	,000
Yağmurlu	-,104	,025	-4,188	,000	-,152	-,055
Kapalı	-,098	,030	-3,227	,001	-,157	-,038

Üretim tahmini için belirlenen çoklu doğrusal regresyon modeli test verilerine uygulanmıştır. Modelin korelasyon katsayısı (R^2) = 0,7189 ve test verilerinin hata kareleri ortalaması (MSE) = 0,1340 olarak hesaplanmıştır. Gerçek değerler ile modelin çıktılarına ait serpilme diyagramı aşağıda verişmiştir.

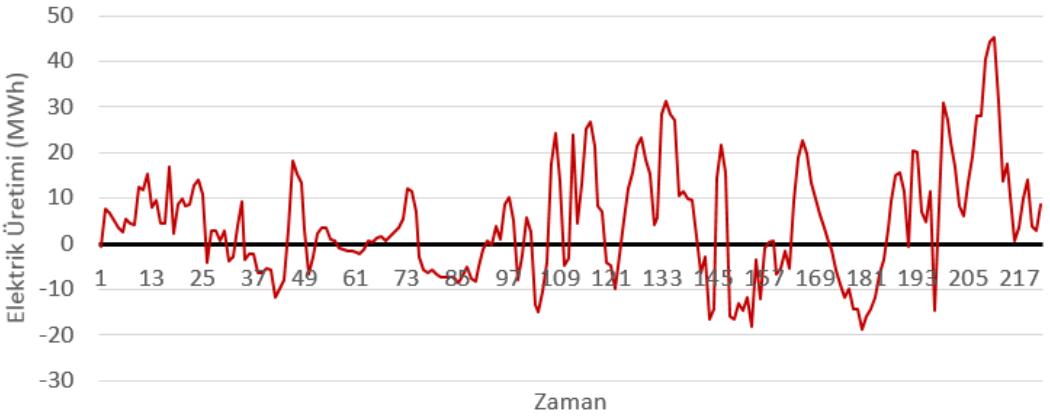


Şekil 3.3: Regresyon modeli gerçek ve çıktı değerleri serpilme diyagramı.

Regresyon modelinin gerçek ve çıktı değerleri Şekil 3.4'deki grafikte karşılaştırılmıştır. Modelin tahmin hataları ise Şekil 3.5'te verilmiştir.



Şekil 3.4: Regresyon modeli gerçek ve çıktı değerleri ilişkisi.



Şekil 3.5: Regresyon modeli tahmin hatalarının grafiksel gösterimi.

3.4 Yapay Sinir Ağları ile Elektrik Üretim Tahmini

Yapay sinir ağları ile elektrik üretim tahmini çalışması için MATLAB programı kullanılmıştır. Toplanan verilerdeki değişkenlerin her biri farklı özelliklerde olması ve farklı birimlere sahip olması nedeniyle verilerin aynı ölçekte belli bir aralığa indirgenerek normalize edilmesi gerekmektedir. Bu çalışmada *mapminmax* fonksiyonu kullanılarak veriler [-1,1] aralığında normalize edilmiştir. Bu fonksiyonun yaptığı işlem şu şekilde formüle edilebilir:

$$x_n = 2\frac{x - x_{min}}{x_{max} - x_{min}} - 1 \qquad (3.8)$$

Eğitim, Doğrulama Ve Test Verisetlerinin Belirlenmesi

Yapay sinir ağlarında verilerin eğitilmesiyle oluşturulan modelin gerçek performansının belirlenebilmesi için kurulan model, sistemin daha önce hiç görmediği veriler üzerinde uygulanarak çıktı değerlerinin hedefle karşılaştırması gerekmektedir.

Bu nedenle modelin kurulum öncesi eğitim amaçlı kullanılacak veriler, modeli test etme amaçlı kullanılacak veriler ve modelin parametrelerinin uygunluğunun doğrulanması için kullanılacak veriler kümelere ayrılır. Verilerin %70'i eğitim, %15'i doğrulama ve %15'i test kümelerine rassal olarak ayrılmıştır.

Çok Katmanlı Algılayıcı Model Seçimi

Bir yapay sinir ağı modelinin eğitilebilmesi için bazı parametre değerlerinin belirlenmiş olması gerekmektedir. Bu değerler modelin performansını doğrudan etkileyeceği için en uygun değerlerin seçilmesi önem arz etmektedir. Fakat bu değerlerin belirlenmesi için uygulanan standart kurallar yoktur. Literatürde önerilen bazı değerler veya değer aralıkları olsa da bunlar probleme özgü değişebilmektedir. Bundan dolayı bu kuralları genellemek doğru bir yaklaşım değildir. Bu çalışmada deneme yanılma yoluyla bu parametre değerleri belirlenmeye çalışılmıştır. Yapay sinir ağının eğitiminde şu parametrelerin uygun değerleri belirlenmiştir:

- Aktivasyon Fonksiyonu
- Gizli Nöron Sayısı
- Öğrenme Oranı
- Öğrenme Algoritması

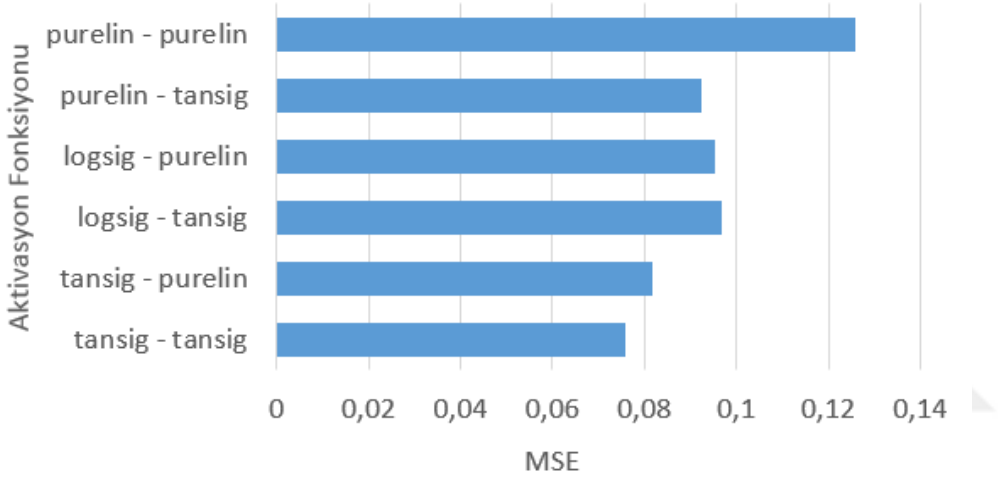
Uygun değerler aranırken aktivasyon fonksiyonu için 9, Gizli nöron sayısı için 15, öğrenme oranı için 8 ve öğrenme algoritması için 6 farklı seçenek denenmiştir. Tüm kombinasyonların denenmesi durumunda ise 9*15*8*6=6480 farklı model kurulması gerekmektedir. Bunun pratikte uygulanması çok zordur. Bu nedenle öncelikle parametrelere varsayılan değerler atanmış ve bu model eğitilerek performans sonuçları elde edilmiştir. Daha sonra aktivasyon foksiyonu için seçenekler denenerek en iyi sonucu veren aktivasyon fonksiyonu seçilmiştir. Gizli nöron sayısının belirlenmesi aşamasına gelindiğinde ise bütün aktivasyon fonksiyonlarını tekrar denemek yerine bir önceki aşamadaki belirlenen en iyi seçenek bu ve bundan sonraki aşamalarda kullanılmaya devam edilmiştir.

Aktivasyon Fonksiyonunun Belirlenmesi

Öğrenme algoritması: *trainlm,* gizli nöron sayısı: 10 ve öğrenme oranı: 0,1 olarak belirlenen sinir ağının gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları için farklı seçenekler denenmiştir. Gizli katman ve çıktı katmanında *tansig* fonksiyonunun kullanıldığı model en iyi performansa ulaşmıştır.

Çizelge 3.7: Aktivasyon fonksiyonlarına göre model performansları.

Gizli Katman Aktivasyon Fonksiyonu	Çıktı Katmanı Aktivasyon Fonksiyonu	MSE	R	R^2
tansig	**tansig**	**0,07596**	**0,90179**	**0,81322**
tansig	logsig		Ağ Eğitilemiyor	
tansig	purelin	0,08186	0,89897	0,80816
logsig	tansig	0,09684	0,89130	0,79442
logsig	logsig		Ağ Eğitilemiyor	
logsig	purelin	0,0954	0,89204	0,79574
purelin	tansig	0,0923	0,89485	0,80076
purelin	logsig		Ağ Eğitilemiyor	
purelin	purelin	0,1259	0,87604	0,76745



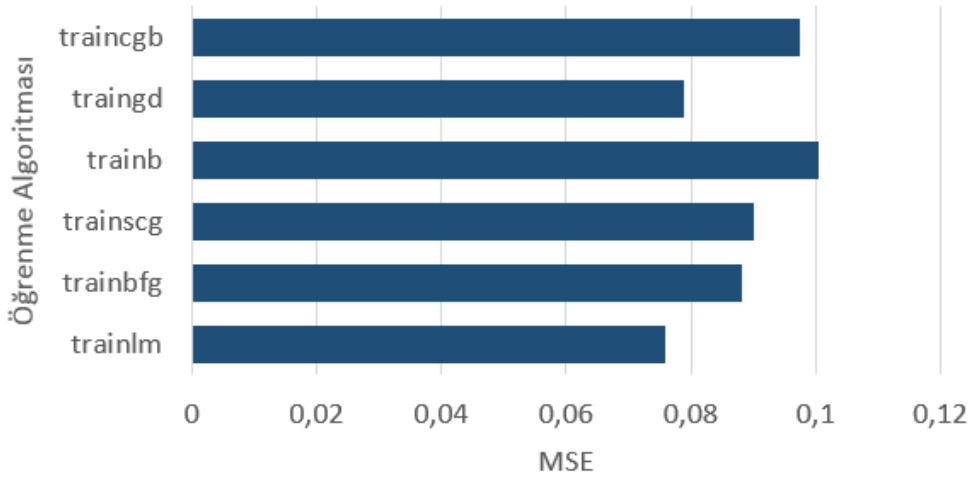
Şekil 3.6: Aktivasyon fonksiyonlarına göre MSE değerleri.

Öğrenme Algoritmasının Belirlenmesi

Aktivasyon fonksiyonu: *tansig* – *tansig*, gizli nöron sayısı: 10, öğrenme oranı: 0,1 olarak belirlenen sinir ağı için farklı öğrenme algoritmaları denenmiştir. En iyi sonuca varsayılan olarak seçilen trainlm algoritmasıyla ulaşılmıştır. Yani öğrenme algoritmasını değiştirerek daha iyi bir sonuca ulaşılamamıştır.

Çizelge 3.8: Öğrenme algoritmalarına göre model performansları.

Öğrenme Algoritması	MSE	R	R^2
trainlm	**0,07596**	**0,90178**	**0,81322**
trainbfg	0,08828	0,89566	0,80221
trainscg	0,09004	0,89064	0,79324
trainb	0,1005	0,88740	0,78748
traingd	0,07888	0,89980	0,80965
traincgb	0,09758	0,88676	0,78634



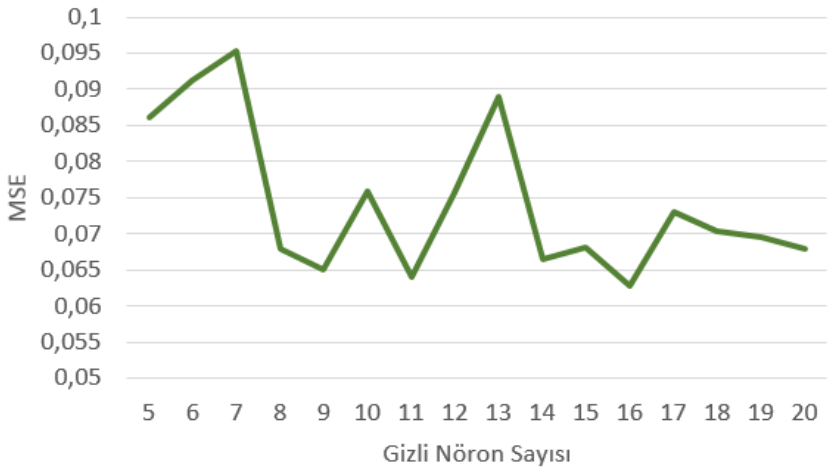
Şekil 3.7: Öğrenme algoritmalarına göre MSE değerleri.

Gizli Nöron Sayısının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – tansig*, öğrenme algoritması: trainlm ve öğrenme oranı: 0,1 olarak seçilen sinir ağı için gizli katmanda kaç adet nöron kullanılacağı belirlenmiştir. 5-20 arasında denemeler yapılmış ve 16 gizli nöron kullanılan modelde en düşük hataya ulaşılmıştır.

Çizelge 3.9: Gizli nöron sayılarına göre model performansları.

Gizli Nöron Sayısı	MSE	R	R^2
5	0,08616	0,89532	0,80160
6	0,0912	0,89126	0,79435
7	0,09532	0,88966	0,79150
8	0,06796	0,90772	0,82396
9	0,06512	0,91011	0,82830
10	0,07596	0,90178	0,81322
11	0,064	0,9083	0,82500
12	0,07572	0,90380	0,81686
13	0,08904	0,89376	0,79881
14	0,06654	0,90741	0,82339
15	0,06806	0,90448	0,81809
16	**0,06278**	**0,90714**	**0,82290**
17	0,07298	0,90102	0,81184
18	0,0704	0,90501	0,81905
19	0,06962	0,90465	0,81839
20	0,06792	0,90691	0,82249



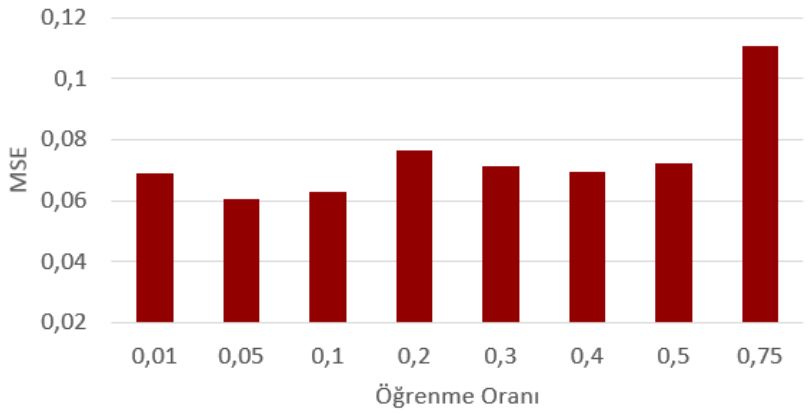
Şekil 3.8: Gizli nöron sayılarına göre MSE değerleri.

Öğrenme Oranının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – tansig*, öğrenme algoritması: trainlm ve gizli nöron sayısı: 16 olarak belirlenen sinir ağında öğrenme oranı için farklı değerler denenerek sinir ağı eğitilmiştir. Öğrenme oranının 0,05 olduğu modelde en düşük hataya ulaşılmıştır.

Çizelge 3.10: Öğrenme oranına göre model performansları.

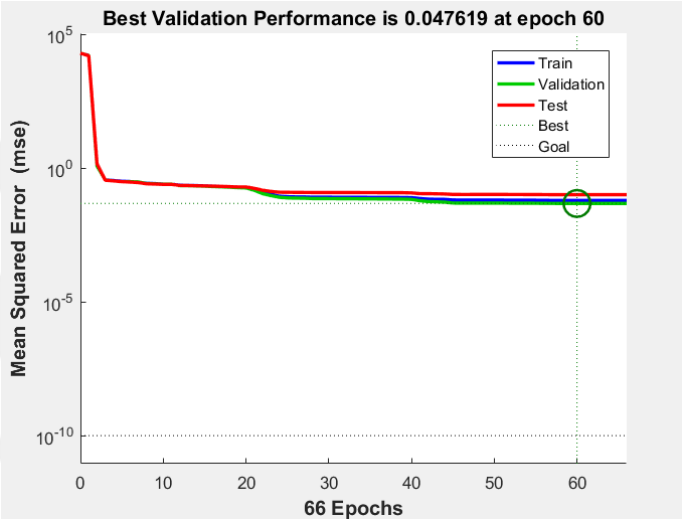
Öğrenme Oranı	MSE	R	R^2
0,01	0,06906	0,90755	0,82364
0,05	**0,06042**	**0,91042**	**0,83252**
0,1	0,06278	0,90714	0,82290
0,2	0,07644	0,90105	0,81190
0,3	0,0713	0,90349	0,81630
0,4	0,06964	0,90229	0,81413
0,5	0,07204	0,90187	0,81337
0,75	0,11044	0,88424	0,78189



Şekil 3.9: Öğrenme oranına göre MSE değerleri.

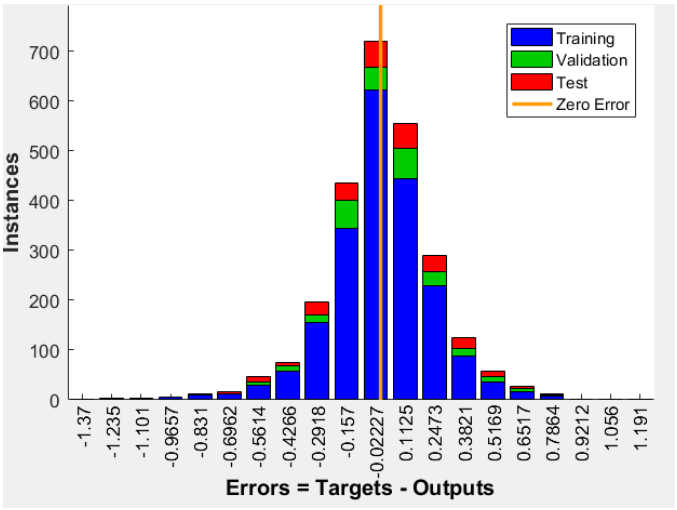
En İyi Modelin Belirlenmesi ve Sonuçlar

Aktivasyon fonksiyonu: *tansig – tansig,* öğrenme algoritması: trainlm ve gizli nöron sayısı: 16 ve Öğrenme oranının 0,05 olan Çok Katmanlı algılayıcı (MLP) modelinde en iyi sonuca ulaşılmıştır. Test verilerinin sonuçlarına göre modelin hata kareleri ortalaması (MSE) değeri 0,06042; R^2 değeri ise 0,83252 bulunmuştur. Levenberg-Marquardt (trainlm) algoritmasında durdurma kriteri olarak validasyon hatası dikkate alınır. 60 iterasyon sonunda validasyon hatasının en düşük olduğu noktaya ulaşılmış ve eğitim durdurulmuştur. Validasyon hatası MSE=0,04619 olarak hesaplanmıştır. Ağın öğrenme eğrisi aşağıda verilmiştir.



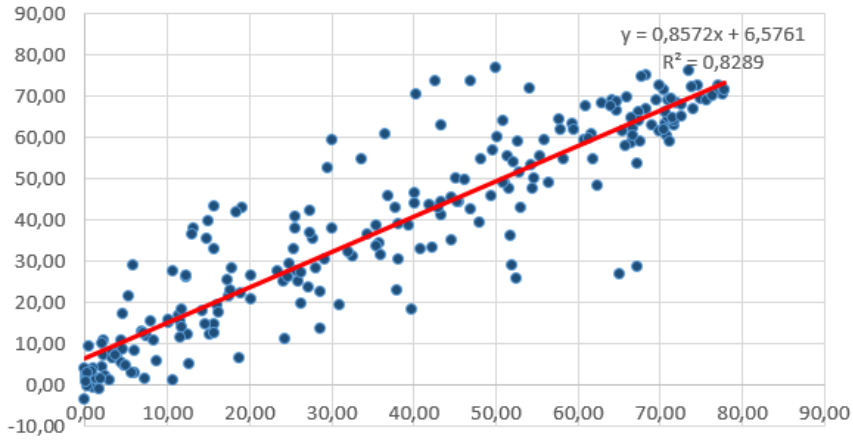
Şekil 3.10: YSA modeli öğrenme eğrisi.

Gerçek değerlerden tahmin edilen değerlerin çıkarılmasıyla hatalar hesaplanmıştır. Eğitim, validasyon ve test hatalarının dağılımına ait histogram Şekil 3.11'de verilmiştir.



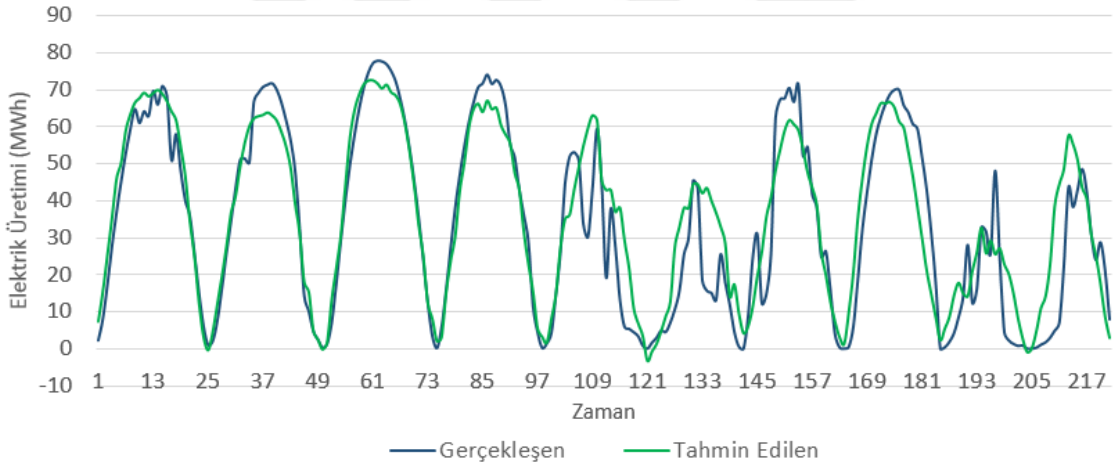
Şekil 3.11: YSA modeli hata dağılım histogramı.

Hataların dağılımı sıfır ortalamaya göre normal dağılıma uygun gerçekleşmiştir. Gerçek ve tahmin edilen verilerin serpilme diyagramı Şekil 3.12'de gösterilmiştir.

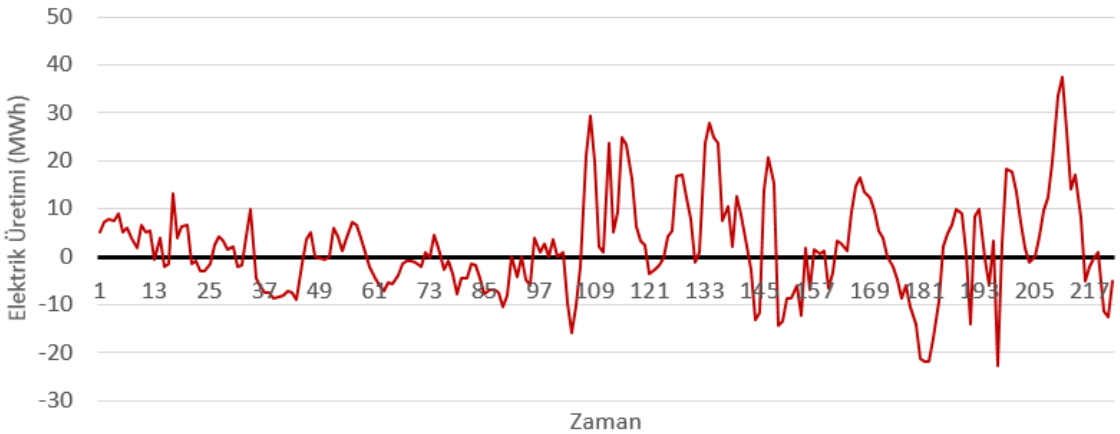


Şekil 3.12: YSA modeli gerçek ve çıktı değerleri serpilme diyagramı.

Test veriseti içinden seçilen 10 günlük bir kesitin gerçek ve tahmin edilen değerleri Şekil 3.13'de karşılaştırılmıştır. Tahmin hataları ise Şekil 3.14'de verilmiştir.



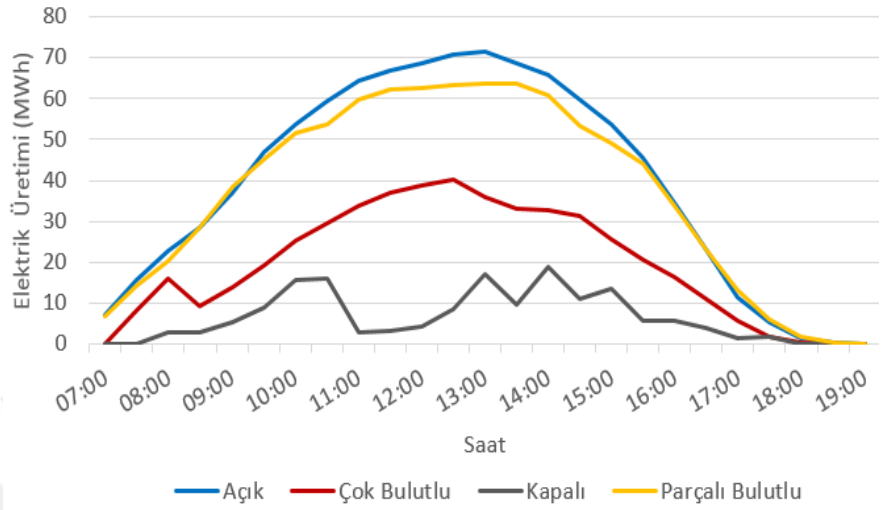
Şekil 3.13: YSA modeli gerçek ve çıktı değerlerinin ilişkisi.



Şekil 3.14: YSA modeli tahmin hatalarının grafiksel gösterimi.

3.5 Bulutluluk Durumunun Tahmin Performansına Etkisi

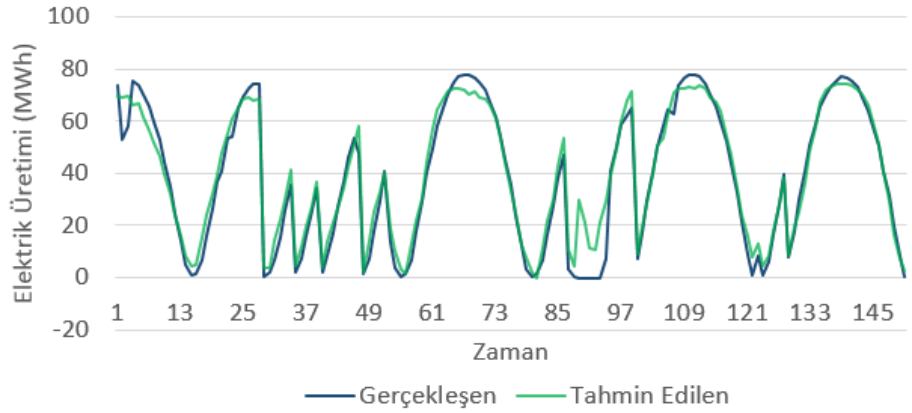
Gerçek elektrik üretim verilerinin bulutluluk durumlarına göre saatlik ortalamaları Şekil 3.15'te verilmiştir.



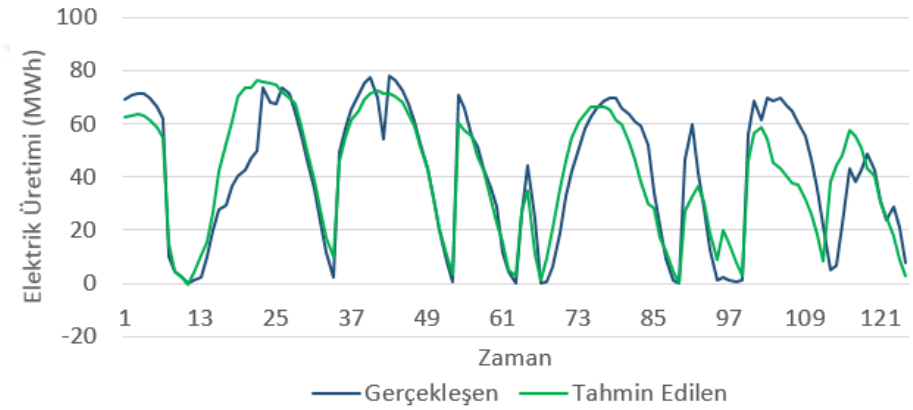
Şekil 3.15: Bulutluluk durumlarına göre saatlik ortalama elektrik üretimi.

Havanın açık ve parçalı bulutlu olduğu durumlarda üretimin fazla, çok bulutlu ve özellikle kapalı olduğu durumlarda üretimin azaldığı görülmektedir. Atmosfer dışından gelen güneş ışımasının tamamının yeryüzüne ulaştığı varsayılırsa elektrik üretim grafiği, kosinüs grafiği halini alacaktır. Çünkü atmosfer dışına gelen güneş ışıması zenit açısının kosinüs (cosΦ) değeriyle doğrudan ilişkilidir. Yeryüzüne ulaşan ışıma oranı arttıkça, örneğin havanın açık olduğu durumlarda üretim grafiği eğrisi kosinüs eğrisine yakınsayacaktır. Ancak havanın kapalı olduğu durumlarda üretim grafiği kosinüs eğrisinden uzaklaşmanın yanısıra eğri özelliğini de kaybetmekte ve rassal olarak hareket etmektedir. Zenit açısının daha büyük olduğu saatlerde üretimin daha küçük olduğu durumlarla karşılaşmak mümkün olmaktadır. Bu nedenle çok bulutlu ve özellikle kapalı havalarda üretim miktarını öngörmek zorlaşmakta ve tahmin hataları artmaktadır.

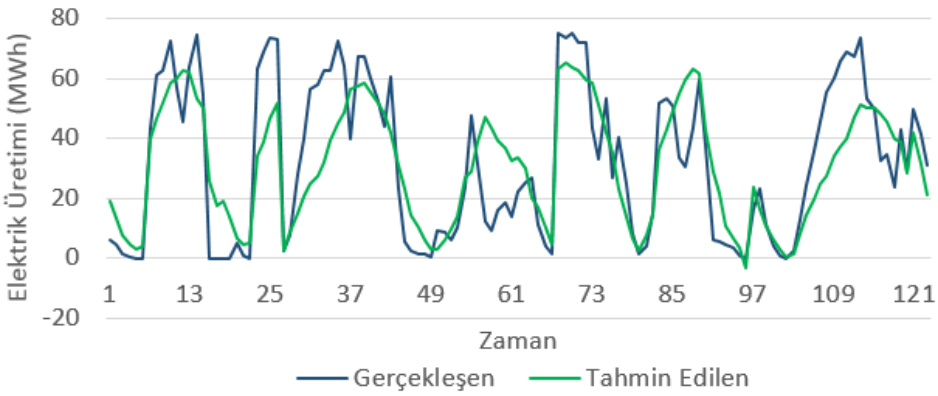
Bulutluluğa göre tahmin hatalarındaki değişimi gözlemleyebilmek için gerçek ve çıktı değerleri aşağıdaki grafiklerde karşılaştırılmıştır.



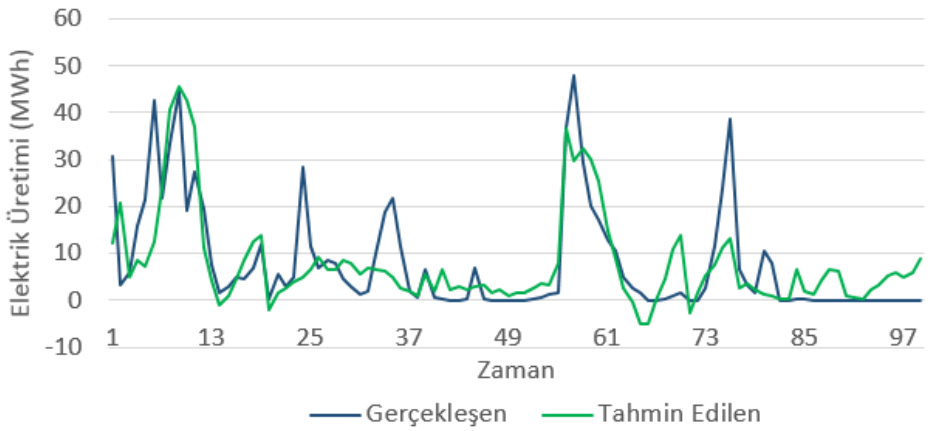
Şekil 3.16: Açık havalardaki gerçek ve çıktı değerleri.



Şekil 3.17: Parçalı bulutlu havalardaki gerçek ve çıktı değerleri.



Şekil 3.18: Çok bulutlu havalardaki gerçek ve çıktı değerleri.



Şekil 3.19: Kapalı havalardaki gerçek ve çıktı değerleri.

Bulutluluk durumlarına göre hata kareleri ortalamaları (MSE) ve korelasyon katsayısı değerleri çizelgede verilmiştir.

Çizelge 3.11: Bulutluluk durumlarına göre tahmin performansları.

	MSE	R	R^2
Açık	0,0362	0,9573	0,9164
Parçalı Bulutlu	0,0674	0,9024	0,8143
Çok Bulutlu	0,1168	0,8384	0,7029
Kapalı	0,3586	0,6793	0,4614

4. ELEKTRİK FİYATI TAHMİNİ

4.1 Elektrik Piyasasında Serbestleşme Süreci

1970'li yıllarda Türkiye'de sanayinin gelişmesiyle birlikte elektrik altyapısı yatırımları artmış ve yasal düzenlemeler yapılmaya başlanmıştır. Elektrik üretim, iletim, dağıtım ve ticaretinin tek çatı altında toplanarak devlet denetiminde olması amacıyla 1970 yılında Türkiye Elektrik Kurumu (TEK) kurulmuştur. Böylece ülke genelliğinde elektrik ağı altyapısının oluşturulması ve devlet kontrolünde merkezileştirilmesinin ilk adımları atılmış oldu. 1994 yılına gelindiğinde TEK, 2 ayrı kuruma ayrılmıştır. üretim ve iletim işlerini Türkiye Elektrik Üretim İletim A.Ş. (TEAŞ) ve dağımın işlerini ise Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) üstlenmiştir. 2000'li yıllara gelindiğinde ise elektriğe olan talep artışının ve devlet bütçesinin bunu karşılayamaması sebebiyle elektrik piyasasında serbestleşme yolunda önemli adımlar atılmıştır. 20 Şubat 2001 tarihinde 4628 Sayılı Elektrik Piyasası Kanunu kabul edilmiştir. Bu kanunla birlikte TEAŞ yeniden yapılandırılarak üç ayrı kuruma ayrılmıştır. Türkiye Elektrik İletim A.Ş (TEİAŞ), Elektrik Üretim A.Ş (EÜAŞ) ve Türkiye Elektrik Ticaret ve Taahhüt A.Ş (TETAŞ) kurumları TEAŞ'ın elektrik iletim, üretim ve ticaret yapılarını devralmışlardır. Bu kanunla ayrıca Elektrik Piyasası Düzenleme Kurumu (EPDK) kurulmuş ve piyasa kurallarını belirleme yetkisi verilmiştir.

Bu süreçte elektrik dağıtım sektöründe rekabete dayalı bir ortamın yaratılması amacıyla 2004 yılında TEDAŞ'ın özelleştirilmesi gündeme gelmiştir. Özelleştirme programı kapsamında Türkiye 21 dağıtım bölgesine ayrılmış ve bu bölgelerdeki elektrik dağıtım yetkisinin özel şirketlerine devredilmesi süreci başlamıştır. Elektrik dağıtımı özel şirketlere devredilmiştir ama bu şirketler TEDAŞ denetiminde faaliyetlerine devam edeceklerdir.

14 Nisan 2009 tarih 27200 sayılı Resmi Gazetede yayımlanan Dengeleme ve Uzlaştırma Yönetmeliği (DUY) doğrultusunda, 01 Aralık 2009 tarihinde; Sistem İşletmecisine dengeli bir sistem bırakılarak piyasa katılımcılarının yükümlülüklerini

gün öncesinden karşılayabilmelerine imkan veren bir ticaret alanı oluşturulmuştur. Bu ticaret alanı oluşturulurken gelişmiş piyasalarda sıklıkla uygulanan Gün Öncesi Piyasası mekanizmasının kurulması amaçlanmıştır. DUY'la birlikte Gün Öncesi ve Dengeleme Güç Piyasası'ndaki fiyatlar piyasa katılımcılarının teklifleri üzerinden belirlenmeye başlanmıştır. Böylece sistemdeki arz ve talebi bağlı, serbest piyasa koşullarında rekabete dayalı olarak fiyat belirleyen bir elektrik satış piyasasına geçilmesi amaçlanmıştır [54].

30 Mart 2013 tarihli 6446 sayılı Elektrik Piyasası Kanunu ile elektrik piyasalarının işletilmesi ve mali uzlaştırma işlemlerinden sorumlu olarak Enerji Piyasaları İşletme Anonim Şirketi (EPİAŞ) kurulmuştur [55].

Piyasa faaliyetleri EPİAŞ kurulmadan önce, TEİAŞ bünyesindeki Piyasa Mali Uzlaştırma Dairesi Başkanlığı tarafından yürütülmekteydi. 01.09.2015 tarihinde EPİAŞ'ın işletme lisansını alıp faaliyete geçmesiyle birlikte; Gün Öncesi Piyasası, Gün İçi Piyasası ve Uzlaştırma faaliyetleri EPİAŞ tarafından, Dengeleme Güç Piyasası ise TEİAŞ tarafından işletilmeye başlanmıştır. TEİAŞ hem iletim lisansına hem de Piyasa İşletim lisansına sahiptir. EPİAŞ'ın hisselerinin %30'u TEİAŞ, %30'u Borsa İstanbul ve %40'ı özel sektöre aittir [56].

EPİAŞ'ın başlıca amacı ve faaliyet konusu, "Piyasa işletim lisansında yer alan enerji piyasalarının etkin, şeffaf, güvenilir ve enerji piyasasının ihtiyaçlarını karşılayacak şekilde planlanması, kurulması, geliştirilmesi ve işletilmesidir. Eşit taraflar arasında ayrım gözetmeden güvenilir referans fiyat oluşumunun temin edilmesi ve artan piyasa katılımcı sayısı, ürün çeşitliliği ve işlem hacmiyle likiditenin en üst düzeye ulaştığı, piyasa birleşmeleri yoluyla ticaret yapılmasına imkan tanıyan bir enerji piyasası işletmecisi olmaktır" [56].

6446 sayılı kanunun 11. Maddesinde EPİAŞ'ın hak ve yükümlülükleri aşağıdaki şekilde tanımlanmıştır [55]:

- Piyasanın gelişimi doğrultusunda görev alanına giren organize toptan elektrik piyasalarında yeni piyasalar kurulmasına yönelik çalışmaları yapmak ve Enerji Piyasası Düzenleme Kurumuna sunmak.
- Bakanlıkça uygun görülmesi hâlinde; görev alanına giren organize toptan elektrik piyasalarının işletilmesi amacıyla oluşturulan veya ileride oluşturulabilecek uluslararası elektrik piyasalarına taraf olarak katılmak, bu

amaçla kurulan uluslararası elektrik piyasası işletmecisi kuruluşlara ortak veya üye olmak.

- Enerji Piyasası Düzenleme Kurumunun belirlediği usul ve esaslar çerçevesinde piyasa işletim tarifelerini belirleyerek Enerji Piyasası Düzenleme Kurumuna sunmak.

4.1.1 Gün öncesi piyasası

Gün Öncesi Piyasasındaki işlemler piyasa işletmecisi olan EPİAŞ tarafından yürütülmektedir. Piyasa katılımcısı olan tüm lisans sahibi tüzel kişiler piyasa katılımcılarının yükümlülüklerini içeren Gün Öncesi Piyasası Katılım Anlaşması'nı imzalayarak Gün Öncesi Piyasasına katılabilmektedir.

Piyasaya katılımcıları saatlik, blok veya esnek teklifler verebilirler veya ikili anlaşmalar yoluyla da elektrik ticareti yapabilirler. Gün öncesi piyasasında işlemler her gün, saat 00:00'dan başlayıp, ertesi gün 00:00'da sona erecek şekilde günlük olarak ve saatlik bazda gerçekleşir.

Piyasa katılımcıları gün öncesi piyasasındaki uzlaştırmaya ilişkin yükümlülüklerinin yerine getirmek için teminat vermeleri gerekmektedir. Teminat miktarı katılımcıların piyasadaki işlemlerinden kaynaklanan riskleri karşılamaya yetecek kadar olmaktadır. Böylece teminat mekanizması işletilerek piyasa katılımcıları güvence altına alınmıştır. Katılımcılar tekliflerini ertesi gün için veya en fazla 5 gün sonrasına kadar verebilirler.

Piyasa yönetim sisteme gönderilen tüm tekliflerin arz ve talebine göre gün öncesi fiyat her saat için ayrı ayrı belirlenir. Fiyatın belirlenmesi öncesinde optimizasyon aracı kullanılır ve üretim ve sistem kısıtları hesaba katılarak günün her saati için kabul edilecek olan teklifler belirlenir. Tekliflerin kabul ve red edilme kararı bu fiyata göre verilir. Belirlenen gün öncesi fiyata Piyasa Takas Fiyatı (PTF) adı verilir.

Gün Öncesi Piyasalarda süreç şu şekilde işlemektedir [57,58]:

00:00 – 16:00: İkili anlaşmalar piyasa işletmecisine bildirilir.

00:00 – 11:30: Gün öncesi piyasa katılımcıları saatlik tekliflerinin Piyasa Yönetim Sistemi aracılığıyla piyasa işletmecisine bildirir.

11:30 – 12:00: Katılımcıların teminat ödemeleri kontrol edildikten sonra bildirilen teklifler piyasa yöneticisi tarafından kabul veya red edilir.

12:00 – 13:00: Kabul edilen teklifler optimizasyon aracı kullanılarak değerlendirilir ve her saat için bir gün sonrasının Piyasa Takas Fiyatı belirlenir. Her katılımcının alım ve satış işlemlerinin onayı diğere katılımcılara bildirilir.

13:00 – 13:30: Onaylanan alış satış miktarları katılımcılara bildirilir. Eğer bir hata varsa itirazlar piyasa işletmecisine bildirilir.

14:00: Nihai fiyat katılımcılara açıklanır. Bir gün sonrasını piyasa takas fiyatı kesinleşir.

4.1.2 Dengeleme güç piyasası

Elektriğin fiziksel olarak aktarımı gün öncesi piyasada işlem gördükten bir gün sonra gerçekleştiği için bu süre içerisinde sistemde arz talep dengesizlikleri oluşabilmektedir. Bu dengesizlikler şu sebeplerden dolayı ortaya çıkabilir:

- Elektrik üreten bir santralin arıza sebebiyle devredışı kalması veya çok fazla elektrik tüketen bir tesisin öngörülemeyen bir zaman içinde birden çalışmaya başlaması ise talebin arzdan yüksek olmasına sebep olacaktır.
- Rüzgar veya güneş enerjisi gibi yenilenebilir enerji santrallerinin üretim tahmininin 1 gün öncesinden yapılmasındaki hata payının yüksek olması dengesizliklere neden olmaktadır.

Elektrik piyasası şebeke yönetmeliğine göre şebeke frekansı 50 Hz'dir. Frekans 50 Hz'nin altına düşmüşse üretim tüketimden azdır, 50 Hz'nin üstüne çıkmışsa üretim tüketimden fazladır demektir. Elektrik üretimi ve tüketimi arasında oluşan bu dengesizliğin azaltılması amacıyla oluşturulan piyasaya dengeleme güç piyasası veya gerçek zamanlı piyasa adı verilmektedir. Bu piyasa Milli Yük Tevzi Merkezi tarafından yönetilir [59].

Gün öncesi piyasa kapandıktan sonra üreticiler ellerinde kalan rezervi satmaları için veya elektrik tüketicilerin taleplerindeki beklenmeyen artışı karşılamaları için fiyat teklifi sunmaları dengeleme piyasasında gerçekleşmektedir. MYTM bu teklifleri dikkate alarak dengesizliği gidermeye çalışır. Üretim fazlaysa fiyat düşecek, tüketim fazlaysa fiyat artacaktır. Bu dengesizlik sonucunda ortaya çıkan arz ve talebin kesiştiği yerde yeni bir fiyat ortaya çıkmaktadır. Bu fiyata Sistem Marjinal Fiyatı (SMF) denmektedir.

Güç piyasasında fiyatlar marjinaldir ve anlık taleplerin karşılanmasının maliyeti de yüksek olmaktadır. Bu nedenle dengeleme güç piyasasının amacı gün öncesi piyasa gibi elektrik ticareti yapmak değil, sistem güvenliğini ve dengesini sağlamaktır [60].

4.2 Verilerin Hazırlanması ve Değişken Seçimi

Elektrik fiyatlarını tahmin edebilmek için literatürdeki çalışmalarda kullanılmış olan çok sayıda değişken bulunmaktadır. Aggarwal vd. [61] yaptıkları çalışmada elektrik fiyatı tahmini için kullanılan değişkenleri şu şekilde sınıflandırmıştır:

- Piyasa özellikler: Geçmiş yük değerleri, sistem yük oranı, ihracat, ithalat, kapasite fazlalığı - açığı, nükleer termal ve hidroelektrik üretimi
- Belirsizlikler: Yük tahmini, sıcaklık, hava şartları, petrol ve doğalgaz fiyatları
- Davranışsal göstergeler: Geçmiş fiyatlar, talep elastikiyeti, teklif stratejileri
- Geçici etkiler: Uzlaştırma periyodu, gün, ay, mevsimler, tatil günleri

Yapılan çalışmalarda çoğunlukla geçmiş fiyat verilerinin kullanıldığı ve tahmin üzerinde en fazla etkiye de bu değişkenin sahip olduğu görülmektedir. Zaman serisi yöntemleri kullanılarak elektrik fiyatı sadece geçmiş değerlerine bağlı olarak tahmin edilebilmektedir.

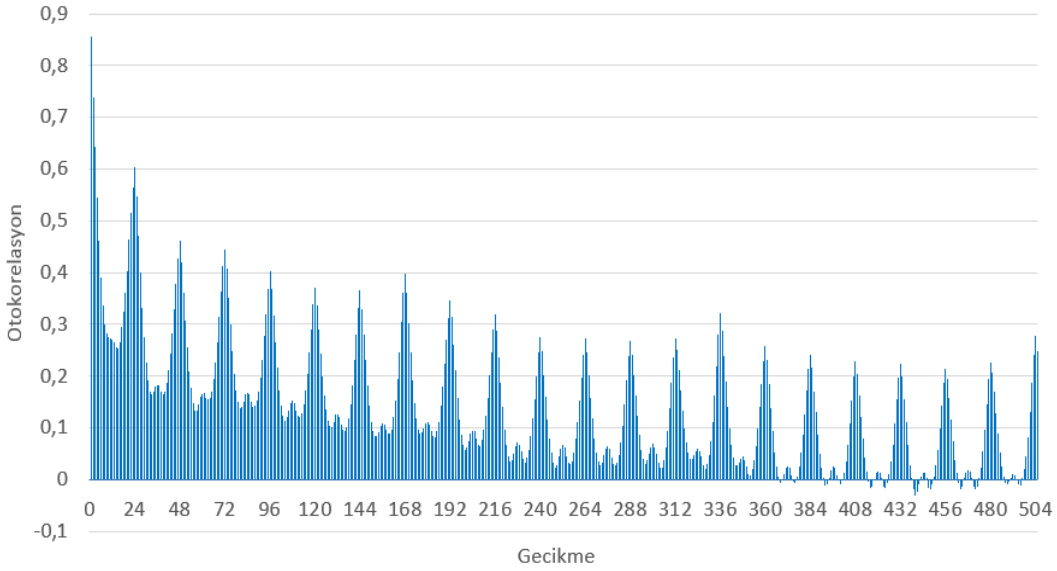
Wang ve Ramsay [18] yaptığı çalışmada elektrik fiyatının tahmin edileceği günden birkaç gün ve birkaç hafta önceki saatler ve bu saatlerin bir saat öncesi ve sonrasının tahmin üzerinde en fazla etkiye sahip olduğunu göstermiştir. Bu çalışmada da buna benzer geçmiş veri değişkenleri kullanılmıştır.

Tayşi vd. [14] yaptıkları çalışmada, elektrik fiyatlarının son 4 saate ait fiyatlar ve bir önceki gün aynı saatteki fiyatlarla ilişkisinin yüksek olduğunu belirtmiştir. Son 4 saate ait fiyat bilgileri bu çalışmada kullanılmamıştır. Çünkü bu çalışmada tahminler saatlik yapılmasına karşın tahmin aralığı bir günlüktür. Yani bir sonraki güne ait 24 saatlik tahmini aynı anda yapılmaktadır. Bu nedenle son 24 saate ait gerçek elektrik fiyatı verileri bilinmemektedir.

Geçmiş değerlerin yanısıra; sıcaklık, elektrik talebi, döviz kurları, haftanın günleri, resmi tatiller, sanayi üretim indekleri gibi değişkenler de elektrik fiyatı üzerine etkisi bulunmaktadır. Geçmiş fiyat verilerinden başka harici verilerin de kullanılmasının istenmesi durumda genellikle regresyon, yapay sinir ağları ve tahmin için kullanılabilen diğer veri madenciliği yöntemlerinden yararlanılmaktadır.

Bu çalışmada geçmiş elektrik fiyatları, verilerin haftanın hangi gününe ait olduğu, işgünü olup olmaması ve elektrik piyasası işlem hacmi girdi değişkenleri olarak kullanılmıştır. 1 Ocak 2016 – 31 Aralık 2016 tarihleri ait 1 yıllık elektrik fiyatı verileri (Piyasa Takas Fiyatı ve Sistem Marjinal Fiyatı) EPİAŞ'ın web sitesinden temin edilmiştir [62].

Geçmiş fiyat değerlerinden hangilerinin girdi değişkeni olarak kullanılacağına karar vermek için tahmin edilen fiyatı en iyi açıklayan değerlerinin bulunması gerekmektedir. Bunun için geçmiş fiyat değerlerinin otokorelasyon fonksiyonunu incelemekte fayda vardır. Geçmiş fiyat değerlerinin otokorelasyon fonksiyonunun 3 haftalık gecikmeye ait otokorelasyon değerleri Şekil 4.1'te grafikte verilmiştir.



Şekil 4.1: Geçmiş fiyat verilerine ait otokorelasyon fonksiyonu.

Grafiği incelediğimizde özellikle 24 saat ve katlarının ve bunlara komşu değerlerin yüksek otokorelasyona sahip olduğu görülmektedir. Buradan verilerin günlük olarak bir mevsimsellik gösterdiği anlaşılabilir. Ayrıca 168 ve katlarının da diğer noktalara göre daha yüksek değere sahip olduğu görülmektedir. Verilerin haftalık olarak da belli bir periyodu takip ettiği sonucuna varmak mümkündür.

Otokorelasyon fonksiyonunu ve buna benzer diğer çalışmalardaki değişken seçim kriterlerini dikkate alarak kullanılacak olan girdi değişkenleri belirlenmiştir. Bu çalışmada kullanılan girdi değişkenleri Çizelge 4.1'de verilmiştir.

Çizelge 4.1: Fiyat tahmini için kullanılan girdi değişkenleri.

Değişkenler	Açıklama
F_{t-23}	1 gün önce 1 saat sonraki fiyat
F_{t-24}	1 gün önceki fiyat
F_{t-25}	1 gün 1 saat önceki fiyat
F_{t-167}	7 gün önce 1 saat sonraki fiyat
F_{t-168}	7 gün önceki fiyat
F_{t-169}	7 gün 1 saat önceki fiyat
F_{t-335}	14 gün önce 1 saat sonraki fiyat
F_{t-336}	14 gün önceki fiyat
F_{t-337}	14 gün 1 saat önceki fiyat
F_{t-504}	21 gün önceki fiyat
Gün kodu	Haftanın günleri [1,7] numaralarıyla kodlanmıştır.
İşgünü	İşgünü durumu [1,0] numaralarıyla kodlanmıştır.
İşlem hacmi	Elektrik piyasası bir gün önceki saatlik işlem hacmi değeri

Verilerdeki Uç Noktaların Olumsuz Etkilerinin Azaltılması

Bazı durumlarda verilerin olağan seyrinin aksine uç değerler görülebilmektedir. Bunlar istisna durumlar olması sebebiyle, ne zaman bu şekilde uç noktaların görüleceği öngörülememektedir. Yani tahmin yöntemleri uç noktadaki değerleri tahmin edememektedir. Uç değerlerin eğitim seti içerisinde olması tahmin modellerinin değişkenler arasındaki ilişkiyi öğrenmesini zorlaştırmaktadır. Bu nedenle modelin test verileri üzerindeki performansı düşmektedir. İstisnaların kaideyi bozmayacağı düşüncesiyle tahmin modellerinin bu kuralları daha iyi öğrenmesi için bu şekildeki uç noktaların verisetinden kaldırılması veya belli bir eşik değere göre sınırlandırılması performansı olumlu etkilemektedir.

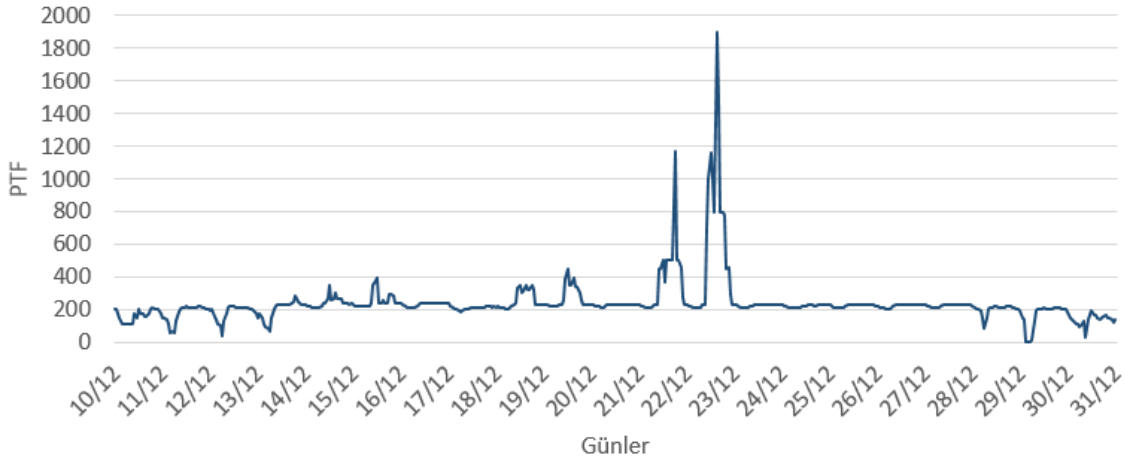
2016 yılına ait elektrik fiyatlarının tanımlayıcı istatistik bilgileri şu şekildedir:

Çizelge 4.2: Elektrik fiyatlarının tanımlayıcı istatistik bilgileri.

	PTF	SMF
Veri Sayısı	8784	8784
Minimum	0,000	0,000
Maksimum	1899,990	1899,990
1. Çeyrek	108,968	80,000
Medyan	140,000	130,000
3. Çeyrek	177,960	183,000
Ortalama	140,585	132,182
Varyans	4741,588	6919,441
Standart Sapma	68,859	83,183
Alt Sınır (95%)	139,145	130,442
Üst Sınır (95%)	142,026	133,922

Bilgileri incelediğimizde PTF ve SMF nin aynı minimum ve maksimum değerleri sahip olduğu, verilerin aynı aralıkta dağıldığı görülmektedir. SMF verilerinin ortalamasının PTF'den daha düşük ve varyansının ise daha yüksek olduğu sonucuna ulaşılabilir. 2016 yılı içerisinde fiyatların en yüksek noktaya ulaştığı 1899,99 TL/MWh değeri 23 Aralık 2016 günü saat 14:00'te doğalgaz arzındaki sıkıntıdan dolayı gerçekleşmiştir [59].

10 Aralık 2016 – 31 Aralık 2016 tarihleri arasındaki PTF değerleri grafikte verilmiştir. Grafik incelendiğinde 15/12, 16/12, 19/12, 20/12, 22/12 ve 23/12 tarihlerinde fiyatların olağan seyrinin aksine yükseldiği görülebilir.



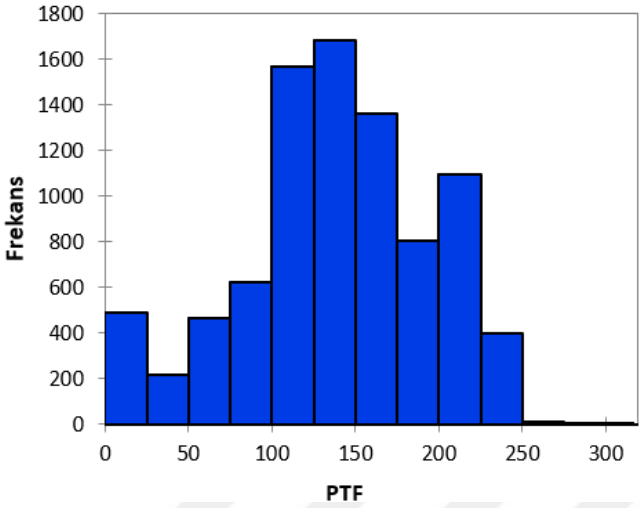
Şekil 4.2: Elektrik fiyatlarındaki uç değerler.

Hangi eşik noktasından sonra bir verinin uç değer olduğuna karar vermek için verilerin dağılım histogramını incelemekte fayda vardır. Piyasa Takas fiyatı verilerinin frekans değerleri Çizelge 4.3'de verilmiştir.

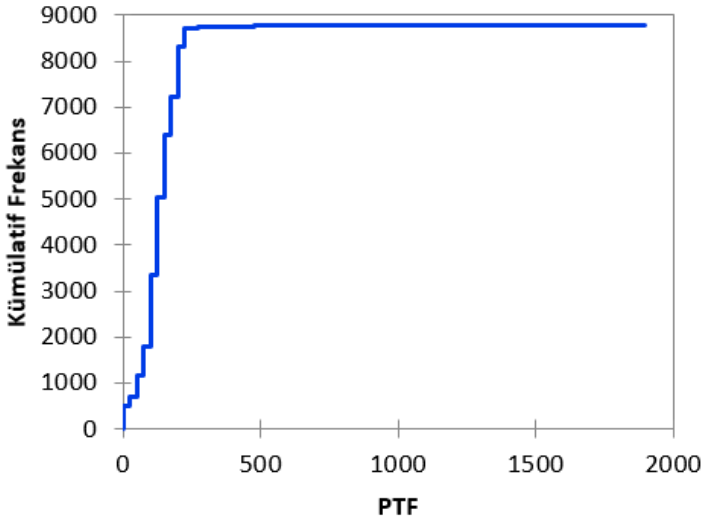
Çizelge 4.3: Piyasa takas fiyatının frekans değerleri.

Alt Sınır	Üst Sınır	Frekans	Relatif Frekans	Kümülatif Frekans
0	25	492	0,056	0,056
25	50	218	0,025	0,081
50	75	464	0,053	0,134
75	100	621	0,071	0,204
100	125	1570	0,179	0,383
125	150	1685	0,192	0,575
150	175	1364	0,155	0,730
175	200	805	0,092	0,822
200	225	1098	0,125	0,947
225	250	401	0,046	0,993
250	–	65	0,007	1,000

Piyasa Takas Fiyatının frakans histogramı Şekil 4.3'de, kümülatif frekans histogramı ise Şekil 4.4'de verilmiştir.



Şekil 4.3: Piyasa takas fiyatının frekans histogramı.



Şekil 4.4: Piyasa takas fiyatının kümülatif frekans histogramı.

Verilerin %99,3'u 0 - 250 arasında dağılmaktadır. %0,7'lik dilime giren 65 veri ise 250 - 1899 arasında dağılmaktadır. Bu veriler uç değer olarak değerlendirilebilir. Eşik değeri 250 olarak belirlemek uygun olacaktır. Eşik değeri belirledikten sonra verileri sınırlandırmak için iki yöntem kullanılabilir.

Özgüner'in [23] yaptığı çalışmada eşik değeri belirledikten sonra verileri sınırlandırmak için iki yöntem kullanmıştır. Eşik değerin üstündeki bütün değerlerin eşik değere eşitlenebilir veya aşağıdaki formül kullanılarak fiyatlara logaritma dönüşümü uygulanabilir.

$$F' = \begin{cases} F & F < E \\ E + E.log\left(\frac{F}{E}\right) & F \geq E \end{cases} \quad (4.1)$$

Birinci yöntem kullanılarak daha düşük hataya ulaşıldığı için 250'nin üstündeki bütün değerler 250'ye eşitlenerek uç değerlerin olumsuz etkisi azaltılmıştır.

4.3 Piyasa Takas Fiyatının (PTF) Tahmini

4.3.1 Doğrusal regresyon ile PTF tahmini

1 yıllık elektrik fiyatları verilerinin eğitim seti için ayrılan kısmı kullanılarak SPSS programında çoklu regresyon analizi yapılmıştır. Haftanın günleri ve iş günü değişkeni kategorik değişkenler olarak tanımlanarak [0,1] değerlerini almıştır. Analiz sonucunda bağımsız değişkenlerin bağımlı değişken (PTF) ile korelasyonu aşağıdaki çizelgede verilmiştir. PTF_{t-24} değişkeni %76,2 korelasyon değeriyle PTF ile en alakalı olan değişken olmuştur. 1 gün önceki PTF değerlerini ve 1 hafta önce aynı saatteki PTF değerleri de bağımlı değişken ile %60'ın üzerinde korelasyona sahiptir.

Çizelge 4.4: Piyasa takas fiyatı değişkenlerinin korelasyon değerleri.

Değişken	Korelasyon	Değişken	Korelasyon
PTF_{t-23}	,691	İşlem Hacmi	,676
PTF_{t-24}	,762	İş Günü	,114
PTF_{t-25}	,673	Pazartesi	-,003
PTF_{t-167}	,662	Salı	,036
PTF_{t-168}	,677	Çarşamba	,030
PTF_{t-169}	,575	Perşembe	,049
PTF_{t-335}	,606	Cuma	,036
PTF_{t-336}	,574	Cumartesi	-,003
PTF_{t-337}	,523	Pazar	-,146
PTF_{t-504}	,514		

Çoklu regresyon analizinde değişkenleri belirlemek için backward yöntemi kullanılmıştır. Anlamlılık değeri 0,1 den büyük olan PTF_{t-336}, PTF_{t-504}, *İşlem hacmi* ve *Cuma* değişkenleri modelden çıkarılmıştır. Modelin, Korelasyon katsayısı ve tahminin standart hatası değerleri Çizelge 4.5'da verilmiştir. Regresyon ve hataların kareleri toplamı, F değeri ve anlamlılık değerlerini içeren ANOVA tablosu ise Çizelge 4.6'de verilmiştir.

Çizelge 4.5: Doğrusal regresyon PTF modeli özeti.

R	R Square	Adjusted R Square	Std. Error of the Estimate
,868a	,754	,753	,19285

Çizelge 4.6: Doğrusal regresyon PTF modeli ANOVA tablosu.

	Sum of Squares	df	Mean Square	F	Sig.
Regression	997,446	17	58,673	1577,556	,000b
Residual	326,030	8766	0,037190		
Total	1323,476	8783			

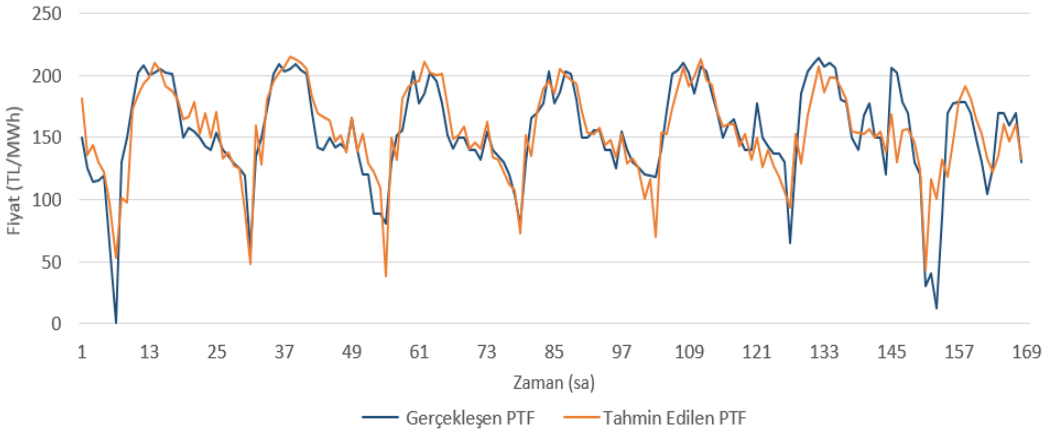
Model değişkenlerinin katsayıları, anlamlılık değerleri ve güven aralıkları Çizelge 4.7'de verilmiştir. Çizelgedeki ß katsayıları göz önüne alınarak oluşturulan regresyon denklemi şu şekilde gösterilebilir:

$$y = 0{,}101 + 0{,}323x_1 + 0{,}414x_2 - 0{,}049x_3 + 0{,}251x_4 + 0{,}1x_5 - 0{,}153x_6 + 0{,}235x_7 - 0{,}103x_8 + 0{,}035x_9 + 0{,}015x_{10} + 0{,}007x_{11} + 0{,}011x_{12} - 0{,}014x_{13} \quad (4.2)$$

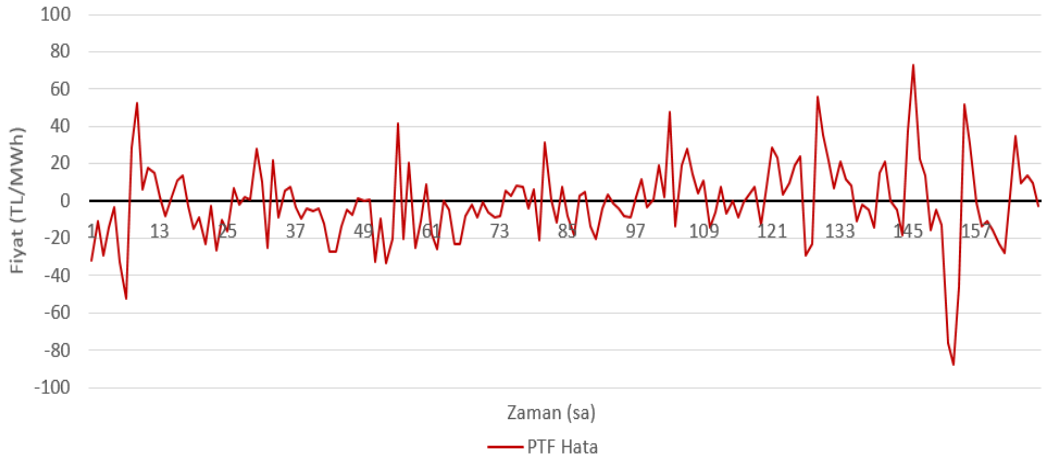
Çizelge 4.7: Doğrusal regresyon PTF modeli katsayıları ve güven aralıkları.

	Coefficients				95% Confidence Interval for ß	
	ß	Std. Error	t	Sig.	Lower Bound	Upper Bound
(Constant)	,101	,051	1,991	,046	,002	,201
PTF_{t-23}	,323	,016	19,633	,000	,291	,355
PTF_{t-24}	,414	,008	52,974	,000	,398	,429
PTF_{t-25}	-,049	,013	-3,885	,000	-,074	-,024
PTF_{t-167}	,251	,016	15,917	,000	,220	,282
PTF_{t-168}	,100	,012	8,191	,000	,076	,124
PTF_{t-169}	-,153	,013	-11,65	,000	-,179	-,127
PTF_{t-335}	,235	,015	15,248	,000	,204	,265
PTF_{t-337}	-,103	,013	-8,132	,000	-,128	-,078
Pazartesi	,035	,004	8,711	,000	,027	,042
Salı	,015	,004	3,814	,000	,007	,022
Çarşamba	,007	,004	1,723	,085	-,001	,014
Perşembe	,011	,004	2,921	,003	,004	,019
Pazar	-,014	,004	-3,608	,000	-,022	-,006

PTF tahmini için belirlenen çoklu doğrusal regresyon modeli test verilerine uygulanmıştır. Modelin korelasyon katsayısı (R^2) = 0,7185 ve test verilerinin hata kareleri ortalaması (MSE) = 0,0415 olarak hesaplanmıştır. Gerçek veriler ile modelin çıktı değerleri aşağıdaki grafikte karşılaştırılmıştır.

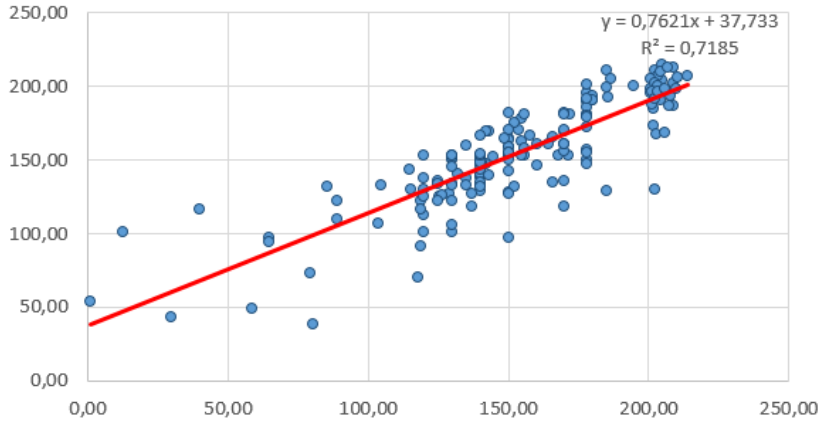


Şekil 4.5: Doğrusal regresyon PTF modeli gerçek ve çıktı değerleri ilişkisi.



Şekil 4.6: Doğrusal regresyon PTF modeli hatalarının grafiksel gösterimi.

Gerçek veriler ile modelin çıktı değerlerine ait serpilme diyagramı aşağıda verilmiştir.



Şekil 4.7: Doğrusal regresyon PTF modelinin serpilme diyagramı.

4.3.2 Yapay sinir ağları ile PTF tahmini

Yapay sinir ağları ile elektrik fiyatı tahmini yapmak için MATLAB programı kullanılmıştır. Modelin kurulup eğitimine başlanmadan önce verilerin normalize edilmesi gerekmektedir. *Mapminmax* fonksiyonu kullanılarak veriler [-1,1] aralığına indirgenmiştir. Normalize edilen verilerin %80'i eğitim %10'u doğrulama ve %10'u ise test verileri olarak ayrılmıştır.

Elektrik fiyatı tahmini için çok katmanlı algılayıcı (MLP) mimarisi kullanılmıştır. Çok katmanlı algılayıcıların performansını etkileyen bazı parametreler için farklı değerler denenerek çok sayıda model kurulmuştur. Bu modeller arasında en düşük hatayı veren model belirlenmiştir. Çok katmanlı algılayıcıların eğitiminde şu parametreler için uygun değerler aranmıştır:

- Aktivasyon Fonksiyonu
- Gizli Nöron Sayısı
- Öğrenme Oranı
- Öğrenme Algoritması

Uygun değerler aranırken aktivasyon fonksiyonu için 9, gizli nöron sayısı için 10, öğrenme oranı için 7 ve öğrenme algoritması için 6 farklı seçenek denenmiştir. Öncelikle parametrelere başlangıç değerleri atanmış ve bu model eğitilerek performans sonuçları elde edilmiştir. Daha sonra aktivasyon foksiyonu için seçenekler denenerek en iyi sonucu veren aktivasyon fonksiyonu seçilmiştir. Gizli nöron sayısının belirlenmesi aşamasına gelindiğinde ise bir önceki aşamadaki belirlenen en iyi seçenek bu ve bundan sonraki aşamalarda kullanılmaya devam edilmiştir.

Aktivasyon Fonksiyonunun Belirlenmesi

Öğrenme algoritması: *trainlm*, gizli nöron sayısı: 10 ve öğrenme oranı: 0,1 olarak belirlenen sinir ağının gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları için farklı seçenekler denenmiştir. Gizli katmanda *tansig* fonksiyonu ve çıktı katmanında ise *purelin* fonksiyonunun kullanıldığı model en iyi performansa ulaşmıştır.

Çizelge 4.8: Aktivasyon fonksiyonlarına göre PTF tahmin performans sonuçları.

Aktivasyon Fonksiyonu	MSE	R	R^2
tansig - tansig	0,03233	0,87129	0,75915
tansig - logsig		Ağ eğitilemiyor	
tansig - purelin	**0,03080**	**0,87891**	**0,77248**
logsig - tansig	0,03552	0,85944	0,73863
logsig - logsig		Ağ eğitilemiyor	
logsig - purelin	0,03535	0,85819	0,73648
purelin - tansig	0,03305	0,87229	0,76088
purelin - logsig		Ağ eğitilemiyor	
purelin - purelin	0,03802	0,85246	0,72669

Öğrenme Algoritmasının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – purelin,* gizli nöron sayısı: 10, öğrenme oranı: 0,1 olarak belirlenen sinir ağı için farklı öğrenme algoritmaları denenmiştir. En iyi sonuca başlangıçta seçilen *trainlm* algoritmasıyla ulaşılmıştır. Yani öğrenme algoritmasını değiştirerek daha iyi bir sonuca ulaşılamamıştır.

Çizelge 4.9: Öğrenme algoritmasına göre PTF tahmin performans sonuçları.

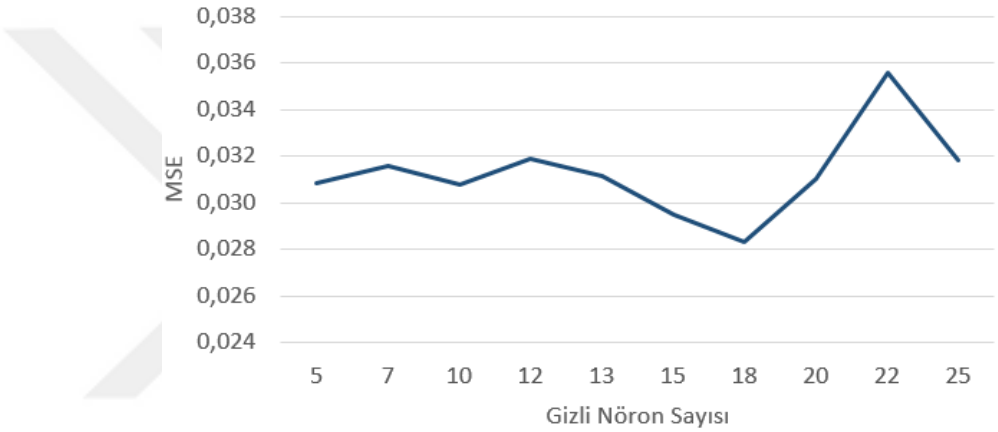
Öğrenme Algoritması	MSE	R	R^2
trainlm	**0,03080**	**0,87891**	**0,77248**
trainbfg	0,03200	0,87011	0,75710
trainscg	0,03299	0,86679	0,75133
trainb	0,03354	0,86007	0,73973
traingd	0,03090	0,87164	0,75976
traincgb	0,03463	0,86685	0,75142

Gizli Nöron Sayısının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – purelin,* öğrenme algoritması: *trainlm* ve öğrenme oranı: 0,1 olarak seçilen sinir ağı için gizli katmanda kaç adet nöron kullanılacağı belirlenmiştir. Yapılan denemelerde 18 gizli nöron kullanılan modelde en düşük hataya ulaşılmıştır.

Çizelge 4.10: Gizli nöron sayısına göre PTF tahmin performans sonuçları.

Gizli Nöron Sayısı	MSE	R	R^2
5	0,03082	0,87100	0,75864
7	0,03157	0,87699	0,76912
10	0,03080	0,87891	0,77248
12	0,03189	0,87135	0,75924
13	0,03113	0,88009	0,77457
15	0,02950	0,88448	0,78230
18	**0,02833**	**0,88535**	**0,78384**
20	0,03102	0,86901	0,75519
22	0,03555	0,86114	0,74156
25	0,03182	0,86891	0,75500



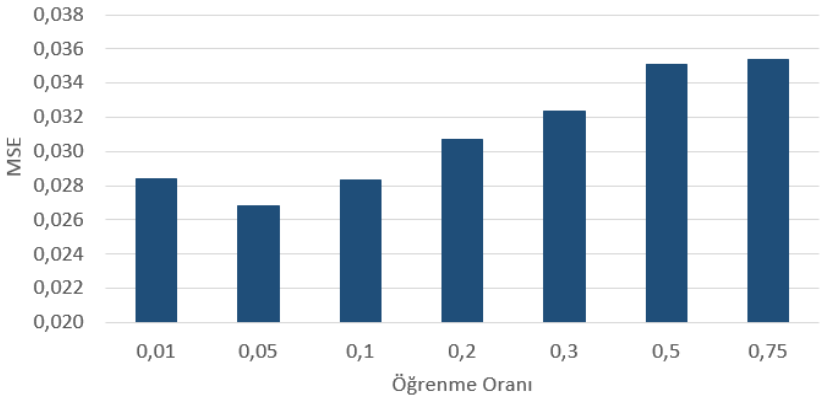
Şekil 4.8: Gizli nöron sayısına göre hatanın değişimi.

Öğrenme Oranının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – purelin*, öğrenme algoritması: *trainlm* ve gizli nöron sayısı: 18 olarak belirlenen sinir ağında öğrenme oranı için farklı değerler denenerek sinir ağı eğitilmiştir. Öğrenme oranının 0,05 olduğu modelde en düşük hataya ulaşılmıştır.

Çizelge 4.11: Öğrenme oranına göre PTF tahmin performans sonuçları.

Öğrenme Oranı	MSE	R	R^2
0,01	0,02838	0,87939	0,77333
0,05	**0,02679**	**0,89100**	**0,79388**
0,1	0,02833	0,88535	0,78384
0,2	0,03071	0,88126	0,77661
0,3	0,03233	0,86588	0,74976
0,5	0,03508	0,85575	0,73230
0,75	0,03535	0,85543	0,73176



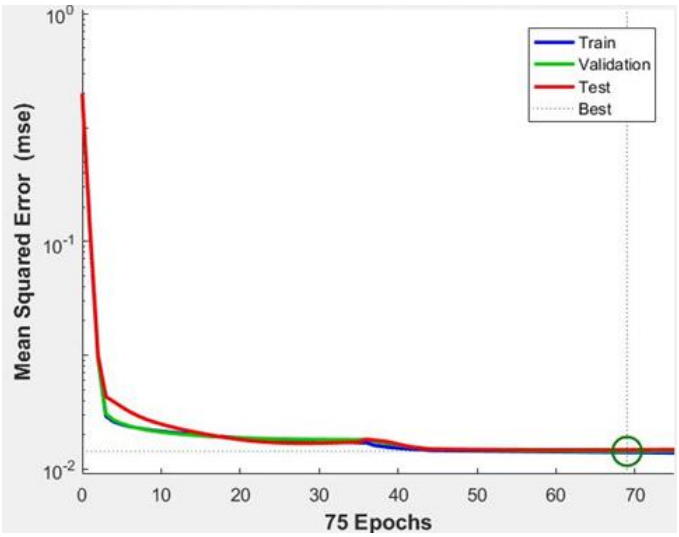
Şekil 4.9: Öğrenme oranına göre hatanın değişimi.

En İyi Modelin Belirlenmesi ve Sonuçlar

En düşük hataya ulaşılan modelin özellikleri şu şekildedir:

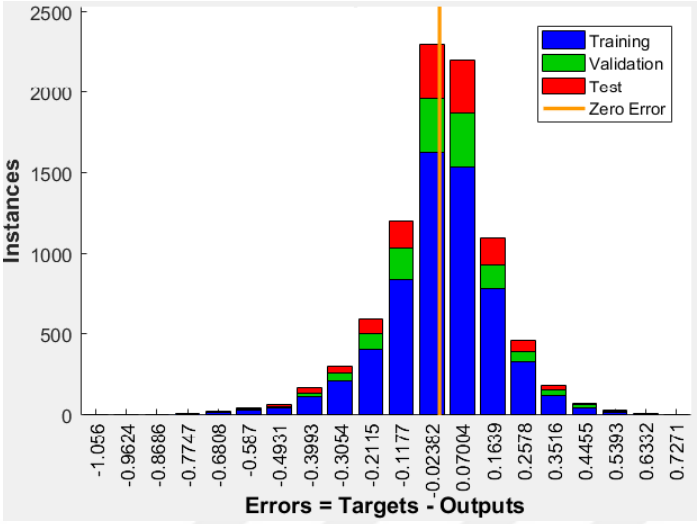
- Gizli katmanı aktivasyon fonksiyonu: Hiperbolik Tanjant (*tansig)*
- Çıktı katmanı aktivasyon fonksiyonu: Lineer (*purelin)*
- Öğrenme algoritması: *trainlm*
- Gizli katma nöron sayısı: 18
- Öğrenme oranı: 0,05
- Hata kareleri toplamı (MSE): 0,02679
- Korelasyon katsayısı (R^2): 0,79388
- Ortalama Mutlak Yüzde Hata (MAPE): %18,79

Yapay sinir ağının eğitimi 75 iterasyon sonunda durdurulmuştur. 69. iterasyonda validasyon hatası en düşük noktaya ulaşmıştır. Ağın öğrenme eğrisi grafikte verilmiştir.



Şekil 4.10: YSA PTF modelinin öğrenme eğrisi.

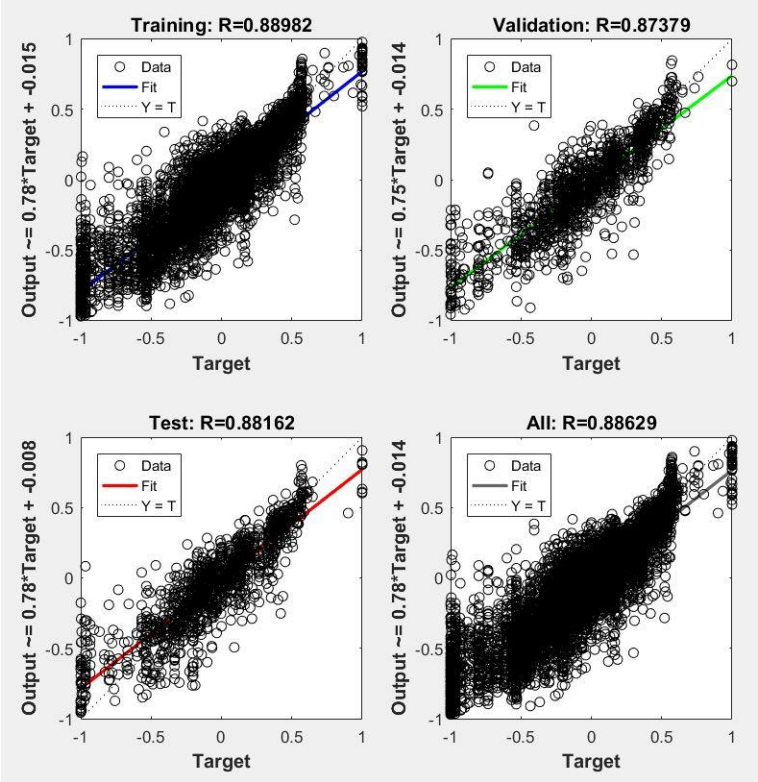
Eğitim, validasyon ve test verilerine ait hataların dağılım histogramı grafikte verilmiştir. Hataların normal dağılıma uygun dağıldığı gözlemlenmiştir.



Şekil 4.11: YSA PTF modelinin hata dağılım histogramı.

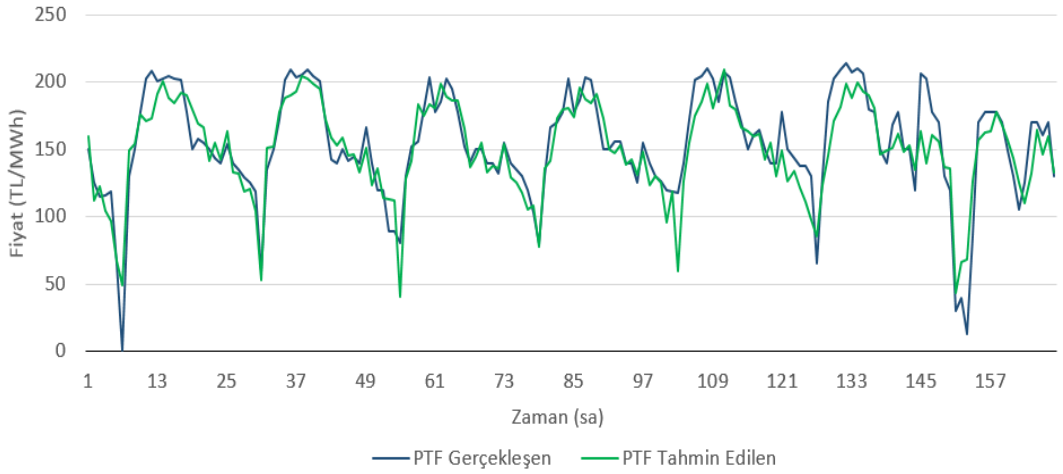
Eğitim, test, validasyon ve bütün verilerin gerçek değerler ile çıktı değerlerine ait serpilme diyagramı grafikte verilmiştir. Test verilerinin gerçek değerleri ile çıktı değerleri arasındaki ilişkinin regresyon denklemi ise şu şekilde gösterilebilir:

$$y' = 0{,}78 * y - 0{,}008 \tag{4.3}$$

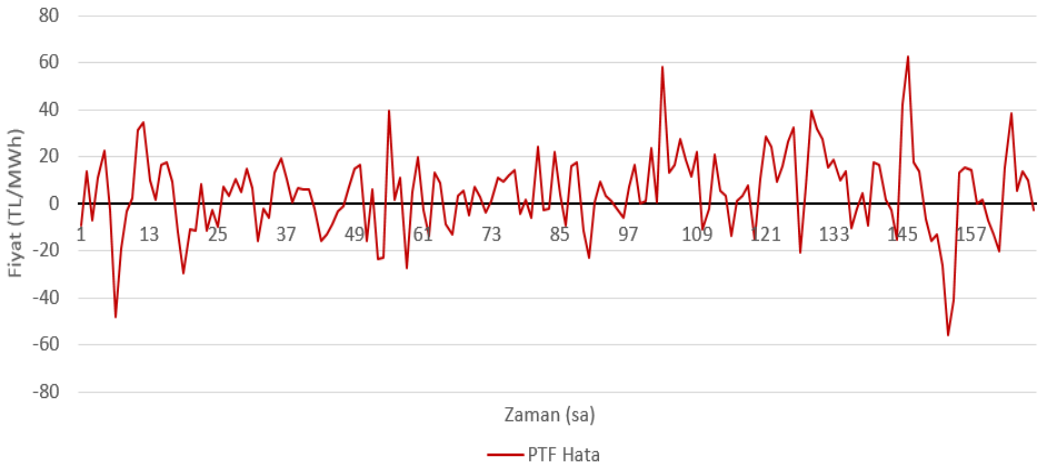


Şekil 4.12: YSA PTF modelinin gerçek ve çıktı değerlerinin serpilme diyagramı.

Gerçek değerler ile çıktı değerlerinin karşılaştırılması Şekil 4.13'de tahmin hataları ise Şekil 4.14'de verilmiştir.



Şekil 4.13: YSA PTF modelinin gerçek ve çıktı değerleri arasındaki ilişki.



Şekil 4.14: YSA PTF modeli hatalarının grafiksel gösterimi.

4.4 Sistem Marjinal Fiyatının (SMF) Tahmini

4.4.1 Doğrusal regresyon ile SMF tahmini

1 yıllık sistem marjinal fiyatı verilerinin eğitim seti için ayrılan kısmı kullanılarak SPSS programında çoklu regresyon analizi yapılmıştır. Analiz sonucunda bağımsız değişkenlerin bağımlı değişken (SMF) ile korelasyonu aşağıdaki çizelgede verilmiştir. 1 gün önceki SMF değeri %60,1 korelasyon değeriyle SMF ile en alakalı olan değişken olmuştur. 1 gün önceki SMF değerlerini, 1 hafta önce aynı saatteki SMF değeri ve 1 gün önceki işlem hacmi değeri de bağımlı değişken ile %50'ın üzerinde korelasyona sahiptir.

Çizelge 4.12: Doğrusal regresyon SMF modeli değişkenlerinin korelasyonları.

Değişken	Korelasyon	Değişken	Korelasyon
SMF_{t-23}	,488	İşlem Hacmi	,510
SMF_{t-24}	,601	İş Günü	,262
SMF_{t-25}	,535	Pazartesi	,161
SMF_{t-167}	,496	Salı	,053
SMF_{t-168}	,552	Çarşamba	,056
SMF_{t-169}	,446	Perşembe	,028
SMF_{t-335}	,432	Cuma	,005
SMF_{t-336}	,447	Cumartesi	-,033
SMF_{t-337}	,386	Pazar	-,134
SMF_{t-504}	,377		

Çoklu regresyon analizinde değişkenleri belirlemek için backward yöntemi kullanılmıştır. Anlamlılık değeri 0,1 den büyük olan SMF_{t-25}, SMF_{t-504} ve *Pazartesi* değişkenleri modelden çıkarılmıştır. Modelin, korelasyon katsayısı ve tahminin standart hatası değerleri Çizelge 4.13'te, modelin ANOVA tablosu ise Çizelge 4.14'te verilmiştir.

Çizelge 4.13: Doğrusal regresyon SMF model özeti.

R	R Square	Adjusted R Square	Std. Error of the Estimate
,736	,541	,540	,32134

Çizelge 4.14: Doğrusal regresyon SMF modeli ANOVA tablosu.

	Sum of Squares	df	Mean Square	F	Sig.
Regression	1067,093	19	56,163	543,885	,000
Residual	904,991	8764	0,103262		
Total	1972,084	8783			

Model değişkenlerinin katsayıları, anlamlılık değerleri ve güven aralıkları Çizelge 4.15'da verilmiştir. Çizelgedeki ß katsayıları göz önüne alınarak oluşturulan regresyon denklemi şu şekilde gösterilebilir:

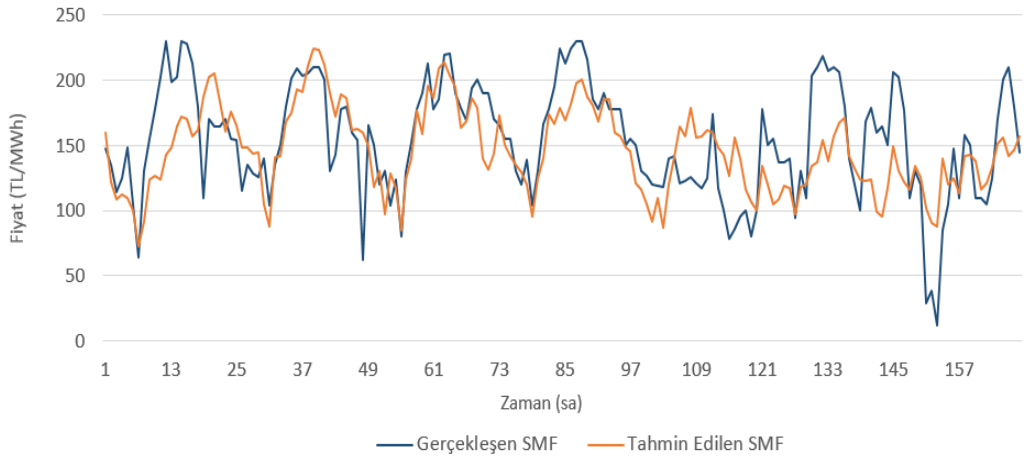
$$\begin{aligned} y = {} & 0{,}417 + 0{,}252x_1 + 0{,}297x_2 + 0{,}171x_3 + 0{,}094x_4 - 0{,}034x_5 + 0{,}176x_6 \\ & + 0{,}031x_7 - 0{,}033x_8 + 0{,}738x_9 - 0{,}038x_{10} - 0{,}033x_{11} \\ & - 0{,}038x_{12} - 0{,}046x_{13} - 0{,}050x_{14} - 0{,}058x_{15} - 0{,}067x_{16} \end{aligned} \quad (4.4)$$

Çizelge 4.15: Doğrusal regresyon SMF modeli katsayıları ve güven aralıkları.

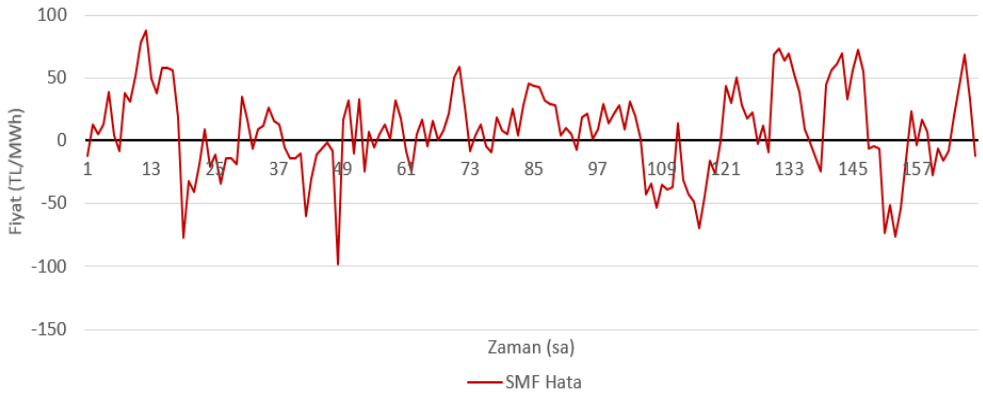
	Coefficients				95% Confidence Interval for B	
	B	Std. Error	t	Sig.	Lower Bound	Upper Bound
(Constant)	,417	,066	6,306	,000	,287	,546
SMF_{t-23}	,252	,018	14,008	,000	,217	,288
SMF_{t-24}	,297	,008	35,423	,000	,281	,314
SMF_{t-167}	,171	,018	9,507	,000	,136	,206
SMF_{t-168}	,094	,014	6,530	,000	,066	,122
SMF_{t-169}	-,034	,015	-2,305	,021	-,063	-,005
SMF_{t-335}	,176	,018	9,968	,000	,141	,211
SMF_{t-336}	,031	,015	2,102	,036	,002	,060
SMF_{t-337}	-,033	,014	-2,252	,024	-,061	-,004
İşlem Hacmi	,738	,069	10,640	,000	,602	,874
İş Günü	-,038	,012	-3,200	,001	-,062	-,015
Salı	-,033	,009	-3,736	,000	-,051	-,016
Çarşamba	-,038	,009	-4,308	,000	-,056	-,021
Perşembe	-,046	,009	-5,151	,000	-,063	-,028
Cuma	-,050	,009	-5,641	,000	-,067	-,032
Cumartesi	-,058	,009	-6,506	,000	-,075	-,040
Pazar	-,067	,009	-7,311	,000	-,085	-,049

SMF tahmini için belirlenen çoklu doğrusal regresyon modeli test verilerine uygulanmıştır. Modelin korelasyon katsayısı (R^2) = 0,5016 ve test verilerinin hata kareleri ortalaması (MSE) = 0,12644 olarak hesaplanmıştır.

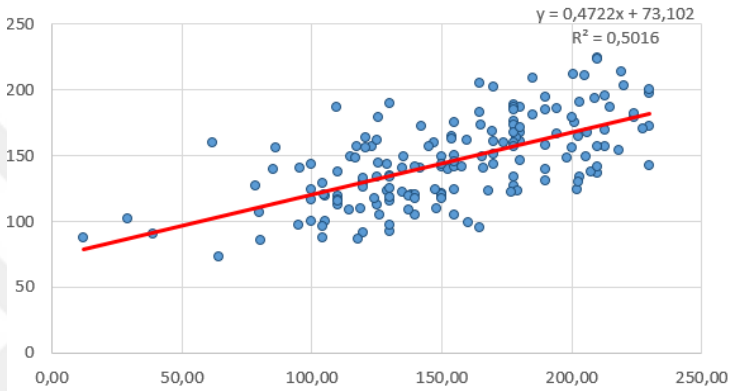
Gerçek değerler ile modelin çıktı değerleri Şekil 4.15'teki grafikte karşılaştırılmıştır. Modelin hataları ise Şekil 4.16'da verilmiştir. Gerçek değerler ile modelin çıktı değerlerine ait serpilme diyagramı ise Şekil 4.17'deki gibi gösterilebilir.



Şekil 4.15: Doğrusal regresyon SMF modelinin gerçek ve çıktı değerleri ilişkisi.



Şekil 4.16: Doğrusal regresyon SMF modeli hatalarının grafiksel gösterimi.



Şekil 4.17: Doğrusal regresyon SMF modelinin serpilme diyagramı.

4.4.2 Yapay sinir ağları ile SMF tahmini

Aktivasyon Fonksiyonunun Belirlenmesi

Öğrenme algoritması: *trainlm*, gizli nöron sayısı: 10 ve öğrenme oranı: 0,1 olarak belirlenen sinir ağının gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları için farklı seçenekler denenmiştir. Gizli katman ve çıktı katmanında *tansig* fonksiyonunun kullanıldığı model en iyi performansa ulaşmıştır.

Çizelge 4.16: Aktivasyon fonksiyonuna göre SMF tahmin performanları.

Aktivasyon Fonksiyonu	MSE	R	R^2
tansig - tansig	**0,0840**	**0,7556**	**0,5709**
tansig - logsig		Ağ eğitilemiyor	
tansig - purelin	0,0906	0,7486	0,5604
logsig - tansig	0,1044	0,7282	0,5303
logsig - logsig		Ağ eğitilemiyor	
logsig - purelin	0,0931	0,7452	0,5553
purelin - tansig	0,0973	0,7367	0,5427
purelin - logsig		Ağ eğitilemiyor	
purelin - purelin	0,1038	0,7269	0,5284

Öğrenme Algoritmasının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – tansig,* gizli nöron sayısı: 10, öğrenme oranı: 0,1 olarak belirlenen sinir ağı için farklı öğrenme algoritmaları denenmiştir. En iyi sonuca başlangıçta seçilen *trainlm* algoritmasıyla ulaşılmıştır. Yani öğrenme algoritmasını değiştirerek daha iyi bir sonuca ulaşılamamıştır.

Çizelge 4.17: Öğrenme algoritmasına göre SMF tahmin performanları.

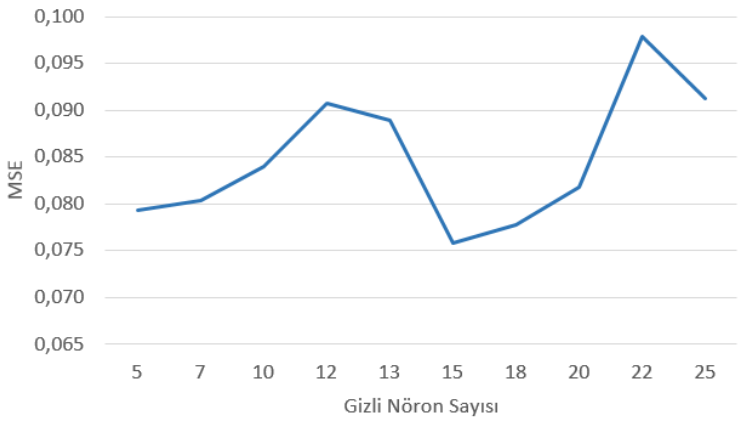
Öğrenme Algoritması	MSE	R	R^2
trainlm	**0,0840**	**0,7556**	**0,5709**
trainbfg	0,0860	0,7588	0,5758
trainscg	0,1003	0,7343	0,5392
trainb	0,1020	0,7303	0,5334
traingd	0,0861	0,7527	0,5665
traincgb	0,0948	0,7421	0,5508

Gizli Nöron Sayısının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – tansig,* öğrenme algoritması: *trainlm* ve öğrenme oranı: 0,1 olarak seçilen sinir ağı için gizli katmanda kullanılacak olan nöron sayısı belirlenmiştir. Yapılan denemelerde 15 gizli nöron kullanılan modelde en düşük hataya ulaşılmıştır.

Çizelge 4.18: Gizli nöron sayısına göre SMF tahmin performanları.

Gizli Nöron Sayısı	MSE	R	R^2
5	0,0793	0,7619	0,5805
7	0,0803	0,7633	0,5826
10	0,0840	0,7556	0,5709
12	0,0908	0,7463	0,5569
13	0,0889	0,7513	0,5645
15	**0,0758**	**0,7715**	**0,5952**
18	0,0778	0,7650	0,5852
20	0,0818	0,7607	0,5786
22	0,0978	0,7363	0,5422
25	0,0913	0,7453	0,5555



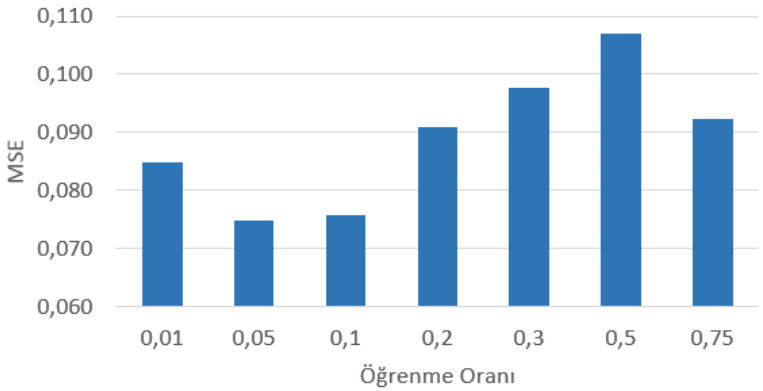
Şekil 4.18: Gizli nöron sayısına göre SMF tahmin hatasının değişimi.

Öğrenme Oranının Belirlenmesi

Aktivasyon fonksiyonu: *tansig – tansig*, öğrenme algoritması: *trainlm* ve gizli nöron sayısı: 15 olarak belirlenen sinir ağında öğrenme oranı için farklı değerler denenerek sinir ağı eğitilmiştir. Öğrenme oranının 0,05 olduğu modelde en düşük hataya ulaşılmıştır.

Çizelge 4.19: Öğrenme oranına göre SMF tahmin performanları.

Öğrenme Oranı	MSE	R	R^2
0,01	0,0849	0,7565	0,5723
0,05	**0,0749**	**0,7783**	**0,6057**
0,1	0,0758	0,7715	0,5952
0,2	0,0909	0,7454	0,5556
0,3	0,0976	0,7364	0,5422
0,5	0,1069	0,7234	0,5234
0,75	0,0923	0,7451	0,5551



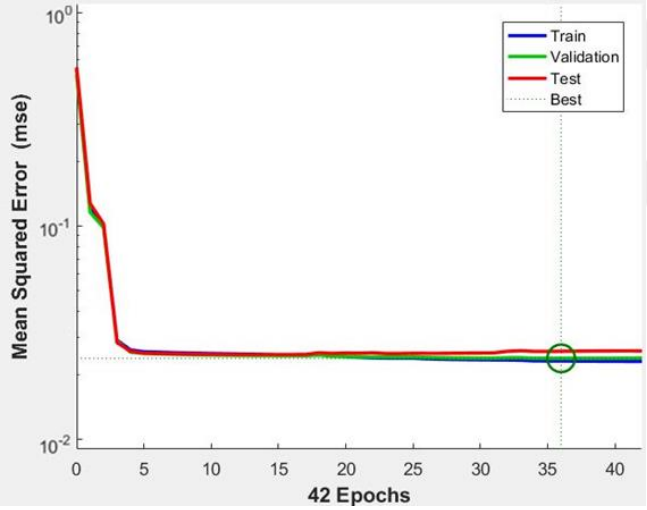
Şekil 4.19: Öğrenme oranına göre SMF tahmin hatasının değişimi.

En İyi Modelin Belirlenmesi ve Sonuçlar

En düşük hataya ulaşılan modelin özellikleri şu şekildedir:

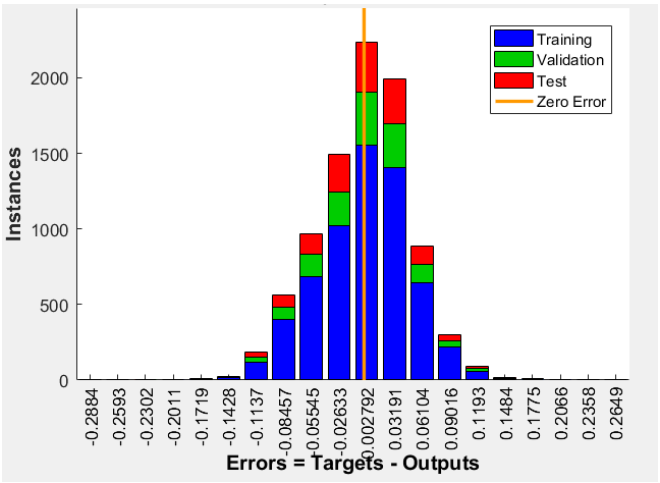
- Gizli katmanı aktivasyon fonksiyonu: Hiperbolik Tanjant (*tansig)*
- Çıktı katmanı aktivasyon fonksiyonu: Hiperbolik Tanjant (*tansig)*
- Öğrenme algoritması: Levenberg-Marquardt (*trainlm)*
- Gizli katma nöron sayısı: 15
- Öğrenme oranı: 0,05
- Hata kareleri toplamı (MSE): 0,0749
- Korelasyon katsayısı (R^2): 0,6057
- Ortalama Mutlak Yüzde Hata (MAPE): %29,54

Yapay sinir ağının eğitimi 42 iterasyon sonunda durdurulmuştur. 36. iterasyonda validasyon hatası en düşük noktaya ulaşmıştır. Ağın öğrenme eğrisi grafikte verilmiştir.



Şekil 4.20: YSA SMF modelinin öğrenme eğrisi.

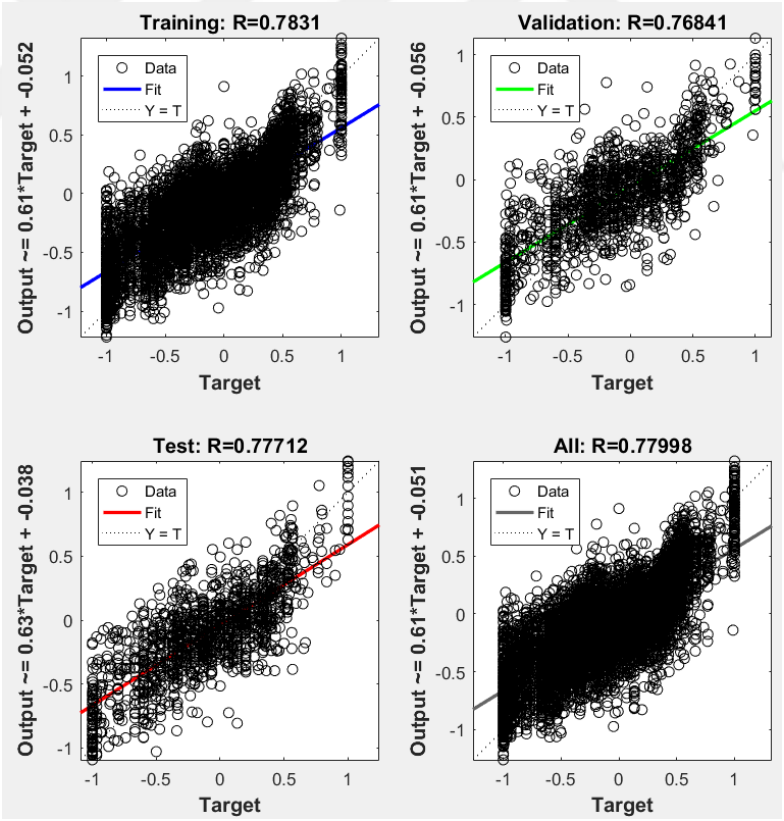
Eğitim, validasyon ve test verilerine ait hataların dağılım histogramı Şekil 4.21'de verilmiştir.



Şekil 4.21: YSA SMF modelinin hatalarının dağılım histogramı.

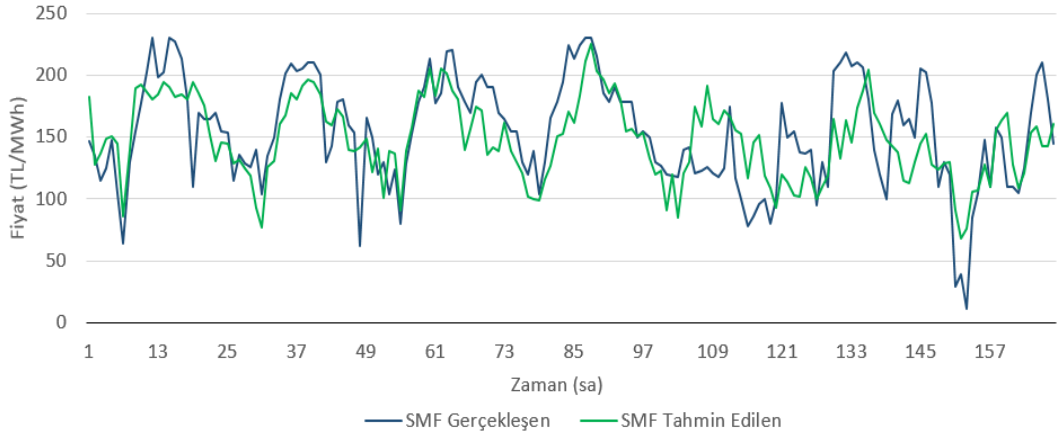
Eğitim, test, validasyon ve bütün verilerin gerçek değerler ile çıktı değerlerine ait serpilme diyagramı grafikte verilmiştir. Test verilerinin gerçek değerleri ile çıktı değerleri arasındaki ilişkinin regresyon denklemi ise şu şekilde gösterilebilir:

$$y' = 0{,}63 * y - 0{,}038 \tag{4.5}$$

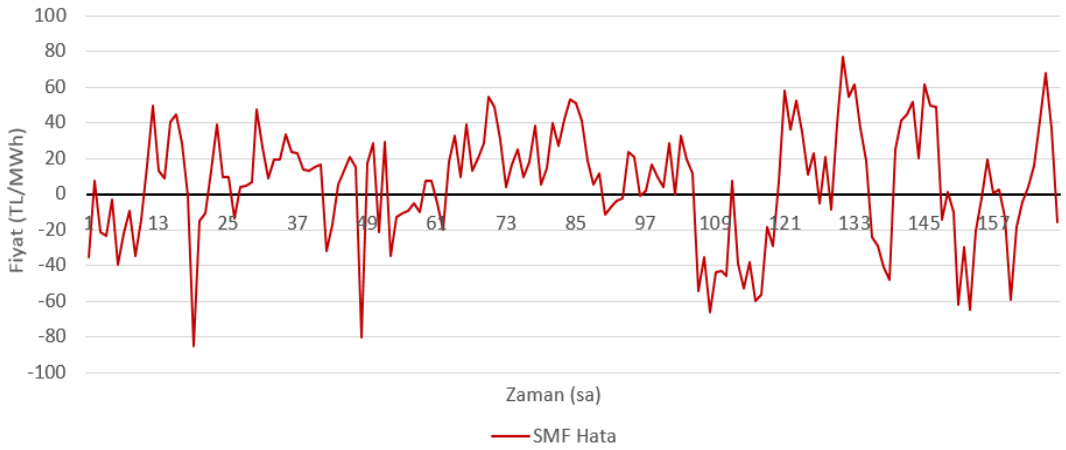


Şekil 4.22: YSA SMF modelinin serpilme diyagramı.

Gerçek değerler ile yapay sinir ağı modelinin ürettiği çıktı değerleri Şekil 4.23'te karşılaştırılmıştır. Gerçek ve çıktı değerleri arasındaki farklar ise Şekil 4.24'te gösterilmiştir.



Şekil 4.23: YSA SMF modelinin gerçek ve çıktı değerlerinin ilişkisi.



Şekil 4.24: YSA SMF modeli hatalarının grafiksel gösterimi.

5. ELEKTRİK PİYASASINDA GAZETECİ ÇOCUK YAKLAŞIMI

Elektrik piyasası gün öncesi piyasası ve dengeleme güç piyasası olmak üzere ikiye ayrılmaktadır. Elektrik üreticilerinin saatlik olarak verdikleri üretim miktarı ve fiyat teklifleri ile arz ve talep oluşur. Arz ve talebin kesiştiği yerde oluşan fiyata Piyasa Takas Fiyatı (PTF) denir. Arz ve talebin bir gün sonrasında planlandığı gibi olmaması durumunda oluşan dengesizlikten dengeleme güç piyasasında azaltılmaya çalışılır. Arz ve talebin tekrar kesiştirilmesiyle oluşan fiyata Sistem Marjinal Fiyatı (SMF) denir.

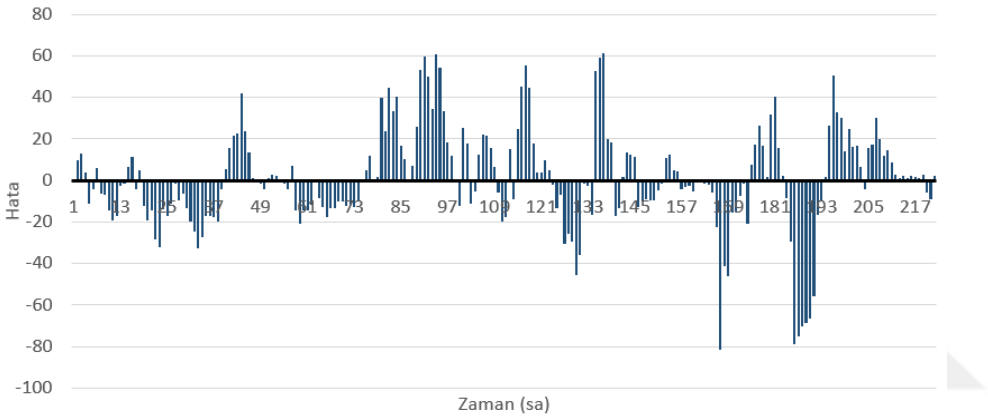
Güneş enerjisi gibi yenilenebilir enerjiden elektrik üreten firmalar hava şartlarından dolayı ne kadar üretim yapacakları kesin olarak tahmin edilememektedir. Ayrıca bir gün sonrası için yapılan tahminler de kısa dönemli saatlik tahminlere göre daha fazla hata içermektedir. Bu nedenle gerçekleşen üretimin tahmin edilenden farklı olması durumunda bu fark dengeleme güç fiyasasında dengelenmektedir ve aradaki fark için PTF'den farklı bir fiyat uygulanmaktadır. Eğer üretim tahminden fazla gerçekleşmişse EPİAŞ tarafından aradaki fark için PTF ve SMF'den düşük olan fiyat uygulanmakta ve ek olarak %3 ceza uygulanmaktadır. Yani dengesizlik durumunda fazla üretim EPİAŞ tarafından 0,97*min(PTF,SMF)'ye satın alınacaktır. Üretimin tahminden düşük olması durumunda ise EPİAŞ üretici firmaya aradaki fark için PTF ve SMF'den büyük olan fiyatı ve ek olarak %3 ceza uygulayacaktır. Yani EPİAŞ açığı bulunan üretici firmaya elektriği 1,03*max(PTF,SMF)'den satacaktır [63].

PTF ve SMF dikkate alındığında dengesizlik durumlarında ne kadarlık maliyetle karşılaşılacağı hesaplanabilmektedir. Fakat üretici firmanın ne zaman üretim fazlası veya üretim açığı vereceği bilinmemektedir. Tahmin hatalarının normal dağıldığı varsayıldığında üretim açığı ve üretim fazlası vermenin eşit olasılığa sahip olduğu kabul edilir. Ancak her iki durumda da karşılaşılacak dengesizlik maliyeti farklıdır. Bu durumda dengesizlik maliyetinin beklenen değeri hesaplanarak bu değeri enküçükleyecek olan veya beklenen geliri enbüyükleyecek olan teklifin bulunması üreticilerin gelirinin artmasına katkı sağlayacaktır.

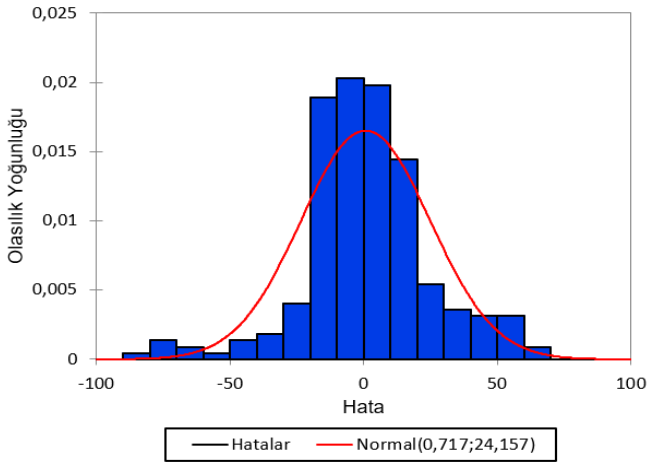
Bu optimizasyon probleminin çözümünde gazeteci çocuk yaklaşımı kullanılmıştır. Optimum teklifin belirlenmesi için elektrik fiyatlarına ihtiyaç vardır ancak bu fiyatlar

verilen teklife göre belirlendiği için teklif vermeden önce bir gün sonraki fiyatlar bilinmemektedir. Bu nedenle öncelikli olarak bir gün sonraki elektrik fiyatlarını tahmin çalışması yapılmıştır. Daha sonrasında tahmini elektrik fiyatları kullanılarak dengesizlik maliyetleri hesaplanmıştır. Bu değerler kullanılarak optimizasyon modeli kurulmuş ve optimum teklif belirlenmiştir.

Optimizasyon modeli kurulmadan önce bu çalışmada kullanılan 20 günlük verinin (elektrik üretiminin gerçekleştiği saatler dikkate alındığında toplam 222 saatlik verinin) tahmin hataları analiz edilmiştir. Hataların ortalaması (μ) 0,717 ve standart sapması (σ) 24,157 olarak hesaplanmıştır. Saatlere göre hata değerleri Şekil 5.1'de, hataların olasılık yoğunluk dağılım histogramı Şekil 5.2'de verilmiştir.



Şekil 5.1: Saatlere göre hata değerleri.



Şekil 5.2: Hataların olasılık yoğunluk dağılımı.

5.1 Önerilen Optimizasyon Modeli

Tahmin < Üretim olduğunda yani pozitif dengesizlik durumunda toplam gelir şu formülle hesaplanır:

$$Tahmin * PTF + 0{,}97(\text{Ü}retim - Tahmin) * \min(PTF, SMF) \tag{5.1}$$

Tahmin > Üretim olduğunda yani negatif dengesizlik durumunda ise toplam gelir şu formülle hesaplanır:

$$Tahmin * PTF - 1{,}03(Tahmin - \text{Ü}retim) * \max(PTF, SMF) \tag{5.2}$$

İki durum birleştirildiğinde gelir formülünü şu şekilde genelleştirmek mümkündür:

$$\begin{aligned} Gelir \; = \; & Tahmin * PTF + 0{,}97(\text{Ü}retim - Tahmin)^{+} * \min(PTF, SMF) \\ & - \; 1{,}03(Tahmin - \text{Ü}retim)^{+} * \max(PTF, SMF) \end{aligned} \tag{5.3}$$

Gelir fonksiyonundaki $(\text{Ü}retim - Tahmin)^{+}$ ve $(Tahmin - \text{Ü}retim)^{+}$ ifadelerinin karşılıkları aşağıda verilmiştir.

$$(\text{Ü}retim - Tahmin)^{+} = \begin{cases} \text{Ü}retim - Tahmin, & \text{Ü}retim \geq Tahmin \\ 0, & \text{Ü}retim < Tahmin \end{cases} \tag{5.4}$$

$$(Tahmin - \text{Ü}retim)^{+} = \begin{cases} Tahmin - \text{Ü}retim, & Tahmin \geq \text{Ü}retim \\ 0, & Tahmin < \text{Ü}retim \end{cases} \tag{5.5}$$

Pozitif dengesizlik fiyatı, negatif dengesizlik fiyatı, üretim ve tahmin için aşağıdaki tanımlamalar yapıldıktan sonra gelir fonksiyonu $\pi(p, x)$ şu şekilde gösterilebilir:

$$PD = 0{,}97 * \min(PTF, SMF) \tag{5.6}$$

$$ND = 1{,}03 * max(PTF, SMF) \tag{5.7}$$

$$x = \text{Ü}retim, \quad p = Tahmin \tag{5.8}$$

$$\pi(p, x) = p * PTF + PD(x - p)^{+} - ND(p - x)^{+} \tag{5.9}$$

Üretimin ne kadar olacağı kesin olarak bilinmemektedir, sadece belli bir hata ile tahmin edilebilir. Dolayısıyla gerçek üretim rassal bir değişken olarak tanımlanabilir. ortalaması μ, standart sapması σ ve dağılım fonksiyonu F olan bu değişkenin sürekli normal dağılıma uygun şekilde dağıldığı kabul edilebilir. O halde beklenen geliri sabit bir üretim miktarına göre değil, üretimin alabileceği bütün değerlere karşılık gelir

fonksiyonunun aldığı değerlerin toplamı şeklinde ifade etmek gerekir. Bu nedenle beklenen gelir fonksiyonunun şu şekilde genişletmek mümkündür:

$$E[\pi(p,x)] = \int_{-\infty}^{\infty} \pi(p,x).f(x).dx \tag{5.10}$$

$\pi(p,x)$ ifadesi tahmin edilen üretim p, ve gerçekleşen üretim x olduğunda elde edilecek geliri göstermektedir. x'in değeri bilinmemektedir fakat dağılım fonksiyonu bilinmektedir. x'in dağılım fonksiyonu kullanılarak x'in alabileceği bütün değerlerin olasılığına karşılık gelirin aldığı değerlerin toplamı bulunabilir. Böylece gelirin beklenen değeri bulunabilir.

$\pi(p,x)$ ifadesinin (5.9) formülünde verilen karşılığı, beklenen gelir fonksiyonundaki yerine yazılır:

$$E[\pi(p,x)] = \int_{-\infty}^{\infty} [p * PTF + PD(x-p)^{+} - ND(p-x)^{+}].f(x).dx \tag{5.11}$$

$$E[\pi(p,x)] = p * PTF + PD\int_{p}^{\infty}(x-p).f(x).dx - ND\int_{-\infty}^{p}(p-x).f(x).dx \tag{5.12}$$

Beklenen gelir fonksiyonunun optimal değerini bulmak için p'ye göre türev alınıp 0'a eşitlenir.

$$\frac{\partial}{\partial p} = PTF + PD\int_{p}^{\infty} -f(x).dx - ND\int_{-\infty}^{p} f(x).dx \tag{5.13}$$

$$\frac{\partial}{\partial p} = PTF - PD[1-F(p)] - ND.F(p) \tag{5.14}$$

$$\frac{\partial}{\partial p} = PTF - PD + PD.F(p) - ND.F(p) \tag{5.15}$$

$$\frac{\partial}{\partial p} = PTF - PD - F(p).(ND-PD) \tag{5.16}$$

Bu türevi 0'a eşitleyen p değeri optimal değerdir.

$$PTF - PD - F(p).(ND-PD) = 0 \tag{5.17}$$

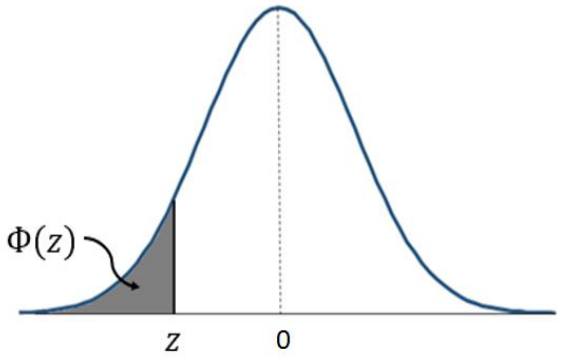
$$F(p) = \frac{PTF - PD}{ND - PD} \tag{5.18}$$

$F(p)$ değerinin eşit olduğu oran, kritik oran olarak adlandırılır ve α ile gösterilir.

$$\alpha = \frac{PTF - PD}{ND - PD} \tag{5.19}$$

F fonksiyonu x değerinin kümülatif olasılık dağılım fonksiyonu olarak tanımlanmıştır. $F(p)$, [0,1] arasında değerler almaktadır. x değişkeninin, ortalaması μ, standart sapması σ olan normal dağılıma uygun dağıldığını kabul edersek, $F(p)$ fonksiyonunun değeri şu şekilde hesaplanmaktadır.

$$F(p) = \Phi\left(\frac{x-\mu}{\sigma}\right) = \Phi(z) = \int_{-\infty}^{z} \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2}} . dx \tag{5.20}$$



Şekil 5.3: Kritik oranın standart normal dağılım eğrisinde gösterimi.

$F(p)$ fonksiyonunun tersi alınarak p değeri $F(p)$'ye bağlı bir fonkiyon olarak tanımlanabilir. Böylece p değeri yani geliri maksimize eden üretim tahmini değeri bulunabilir.

Önerilen Modelin Örnek Bir Veri Üzerinde Uygulanması

Elektrik üretim tahmini çalışması ile elektrik fiyatı tahmin çalışmasının test verileri arasından aynı tarih aynı saate ait bir veri seçilerek kurulan optimizasyon modeli uygulanmıştır. Gelir ve maliyetlerdeki değişimler hesaplanarak karşılaştırılmıştır. 18.09.2016 saat 09:00'daki veriye ait bilgiler Çizelge 5.1'de verilmiştir.

Çizelge 5.1: Gerçekleşen ve tahmin edilen değerler.

	Gerçekleşen	Tahmin Edilen
Üretim	69,35	63,53
PTF	120,00	148,90
SMF	56,00	124,90
Pozitif Dengesizlik Fiyatı (PD)	54,32	121,10
Negatif Dengesizlik Fiyatı (ND)	123,60	153,40

Gerçek üretim, tahmin edilen üretim ve gerçek elektrik fiyatları kullanılarak mevcut durumdaki gelir ve dengesizlik maliyetleri hesaplanmıştır. İkinci kısımda ise elektrik fiyat tahminleri kullanılarak kritik oran belirlenerek, kritik orana göre üretim tahmininin optimum değeri hesaplanmıştır. Daha sonra gelir ve dengesizlik maliyetleri optimum tahmin değerine göre tekrar hesaplanarak karşılaştırılmıştır. Çizelge 5.1'deki bilgilere göre gerçekleşen üretim, tahmin edilenden daha büyük olduğundan dolayı pozitif dengesizlik vardır. Gelir, (5.9) formülünde belirtildiği gibi şu şekilde hesaplanabilir:

$$\pi(p,x) = Tahmin * PTF + 0{,}97(\text{Ü}retim - Tahmin) * \min(PTF, SMF) \quad (5.21)$$

$$\pi(p,x) = Tahmin * PTF + PD * (\text{Ü}retim - Tahmin) \quad (5.22)$$

$$\pi(p,x) = 63{,}53 * 120 + 54{,}32 * (69{,}35 - 63{,}53) \quad (5.23)$$

$$\pi(p,x) = 7940{,}23 \quad (5.24)$$

Pozitif dengesizliğe düşmenin maliyeti ise şu şekilde hesaplanır:

$$PDM = (\text{Ü}retim - Tahmin) * (PTF - PD) \quad (5.25)$$

$$PDM = (69{,}35 - 63{,}53) * (120 - 54{,}32) \quad (5.26)$$

$$PDM = 381{,}76 \quad (5.27)$$

(5.19) formülü yardımıyla kritik oran şu şekilde hesaplanabilir:

$$\alpha = \frac{PTF - PD}{ND - PD} \quad (5.28)$$

$$\alpha = \frac{148{,}91 - 121{,}13}{153{,}38 - 121{,}13} \quad (5.29)$$

$$\alpha = 0{,}8613 \quad (5.30)$$

Excel programındaki *NORM.INV(probability;mean;standart_dev)* formülü kullanılarak kümülatif normal dağılım fonksiyonunun tersi alınabilir. Kritik oran, hataların ortalaması ve standart sapması değerleri formülde yerine yazıldığı zaman $p = 23{,}62$ bulunur.

$$NORM.INV(0{,}8613; 0{,}72; 24{,}16) = 23{,}62 \quad (5.31)$$

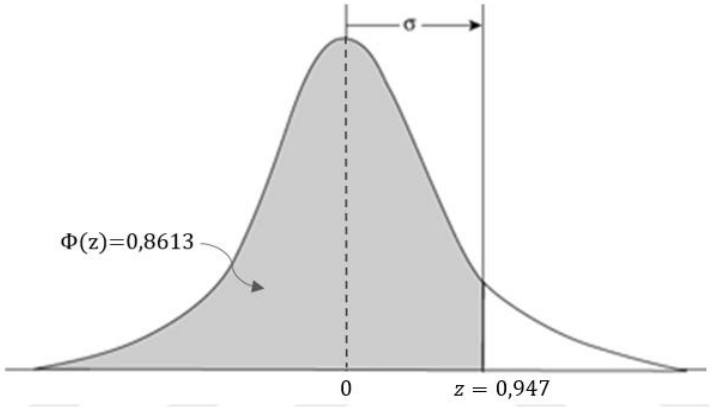
p değerini standart sapma cinsinden bulmak için aşağıdaki formül kullanıldığında $z = 0{,}947$ bulunur.

$$p = z.\sigma + \mu \tag{5.32}$$

Mevcut tahmin değeri ortalama değer (μ) kabul edildiğinde optimum tahmin değeri (p') (5.32) formülüyle şu şekilde hesaplanır:

$$p' = 0{,}947 * 24{,}16 + 63{,}53 = 86{,}41 \tag{5.33}$$

Kritik oran ve z değeri standart normal dağılım eğrisi üzerinde Şekil 5.4'de gösterilmiştir.



Şekil 5.4: Kritik oran ve z değerinin grafiksel gösterimi.

Üretim tahmininin optimum değeri belirlendikten sonra gerçekleşen elektrik fiyatları kullanılarak gelir ve dengesizlik maliyetleri tekrar hesaplanır. Optimum tahmin değeri gerçekleşen üretimden daha büyük olduğu için bu sefer negatif dengesizlik durumu sözkonusudur. Maksimize edilen gelir şu şekilde hesaplanır:

$$\pi'(p', x) = Tahmin * PTF - 1{,}03(Tahmin - \text{Ü}retim) * \max(PTF, SMF) \tag{5.34}$$

$$\pi'(p', x) = Tahmin * PTF - ND * (Tahmin - \text{Ü}retim) \tag{5.35}$$

$$\pi'(p', x) = 86{,}41 * 120 - 123{,}6 * (86{,}41 - 69{,}35) \tag{5.36}$$

$$\pi'(p', x) = 8260{,}58 \tag{5.37}$$

Negatif dengesizliğe düşmenin maliyeti ise şu şekilde hesaplanır:

$$NDM = (Tahmin - Üretim) * (ND - PDF) \quad (5.38)$$

$$NDM = (86{,}41 - 69{,}35) * (123{,}6 - 120) \quad (5.39)$$

$$NDM = 61{,}42 \quad (5.40)$$

Mevcut durumdaki gelir ve dengesizlik maliyeti ile üretim tahmini değeri optimize edildikten sonraki gelir ve dengesizlik maliyetindeki değişim Çizelge 5.2'de verilmiştir. Gelir %4 artış gösterirken dengesizlik maliyetleri %83 oranında azalmaktadır.

Çizelge 5.2: Mevcut ve optimum durum karşılaştırması.

	Mevcut Durum	Optimum Durum
Gelir	7.940,23	8.260,58
Maliyet	381,76	61,42

Ancak her zaman maliyetler bu şekilde iyileştirme yapılması mümkün olmayabilir. Bazı durumlarda tahmin değeri optimize edildikten sonra maliyetlerde artış gözlenebilir. Bu durumu görebilmek için sadece bir saatlik veriye değil farklı saatlerdeki verileri de incelemek gerekmektedir. 05.11.2016 tarihinde üretimin olduğu bütün saatlere ait veriler aşağıda verilmiştir.

Çizelge 5.3: 05.11.2016 tarihli verilerdeki kritik oranın hesaplanması.

Saat	Üretim	Tahmin	PTF	PTF Tahmin	SMF Tahmin	Kritik Oran	Optimum Tahmin
08:00	0,00	4,23	150,99	136,26	128,57	0,74	17,09
09:00	6,45	16,95	166,56	168,55	144,84	0,85	39,08
10:00	51,43	56,86	175,11	181,23	140,94	0,89	83,98
11:00	93,30	91,55	185,1	182,94	157,85	0,84	113,41
12:00	120,58	108,16	169,96	159,30	136,33	0,85	130,56
13:00	134,90	128,33	162,97	153,86	126,19	0,87	153,13
14:00	139,90	112,23	158,05	167,08	148,88	0,82	131,63
15:00	129,68	106,20	115,96	163,46	153,02	0,75	120,23
16:00	120,15	93,07	115,49	160,45	148,63	0,77	108,48
17:00	95,00	53,35	133	154,88	173,24	0,16	27,48
18:00	49,38	16,72	185,1	176,26	191,78	0,20	0,00

Çizelge 5.4: 05.11.2016 tarihli verilerdeki gelir ve maliyetler.

Saat	PTF	SMF	Mevcut Durum		Optimum Durum		Gelir Artışı
			Gelir	Maliyet	Gelir	Maliyet	
08:00	150,99	161,00	-62,78	62,78	-253,66	253,66	-190,88
09:00	166,56	166,56	1.021,84	52,47	911,25	163,06	-110,59
10:00	175,11	110,00	8.976,49	28,54	8.834,02	171,01	-142,47
11:00	185,10	185,10	17.260,13	9,70	17.158,15	111,68	-101,99
12:00	169,96	145,00	20.128,94	363,98	20.442,02	50,90	313,08
13:00	162,97	162,97	21.952,55	32,10	21.895,51	89,15	-57,05
14:00	158,05	90,00	20.153,47	1.957,72	21.526,21	584,98	1.372,74
15:00	115,96	133,00	14.955,44	81,67	15.004,24	32,87	48,80
16:00	115,49	140,00	13.782,31	93,82	13.835,69	40,44	53,38
17:00	133,00	140,00	12.468,80	166,20	12.365,59	269,41	-103,21
18:00	185,10	195,00	8.957,97	181,35	8.865,13	274,18	-92,83
Toplam			**139.595,16**	**3.030,33**	**140.584,16**	**2.041,34**	**988,99**

Kritik oran hesaplama formülünden ve çizelgeden da görüleceği üzere tahmin edilen PTF değerinin tahmin edilen SMF'den büyük olması durumunda kritik oran 0,5'den büyük olmaktadır. Kritik oranın 0,5 ten büyük olması tahmindeki sapmanın pozitif yönde olması yani normal dağılım eğrisinde sağa doğru yönelim olması demektir. Dolayısıyla üretim tahmininin optimum değeri, mevcut tahmin değerinden daha büyük olmaktadır.

Örneğin, saat 09:00 daki gibi kritik oranını 0,5 ten büyük olduğu ve aynı zamanda üretim tahmininin gerçek üretimden büyük olduğu bir durumda, optimum tahmin değeri ile gerçek üretim arasındaki fark daha fazla açılacaktır ve aradaki hata artacaktır. Bu durumda maliyetlerin azaltılması amaçlanırken aksine artacaktır. Ancak bu istisna bir durum olarak değerlendirilebilir. Çünkü üretimin ne zaman tahminden fazla veya az olup olmayacağı bilinmemektedir. Tahmin değişkeni normal dağılıma uygun olduğu kabul edildiği için üretim ile tahmin arasındaki farkın pozitif veya negatif olma ihtimalleri eşit kabul edilmektedir. Bu nedenle ne kadar geliş artışı elde edildiğini görebilmek için sadece saatlik verilere bakmak yerine uzun süreli simülasyonlar yapmak gerekmektedir.

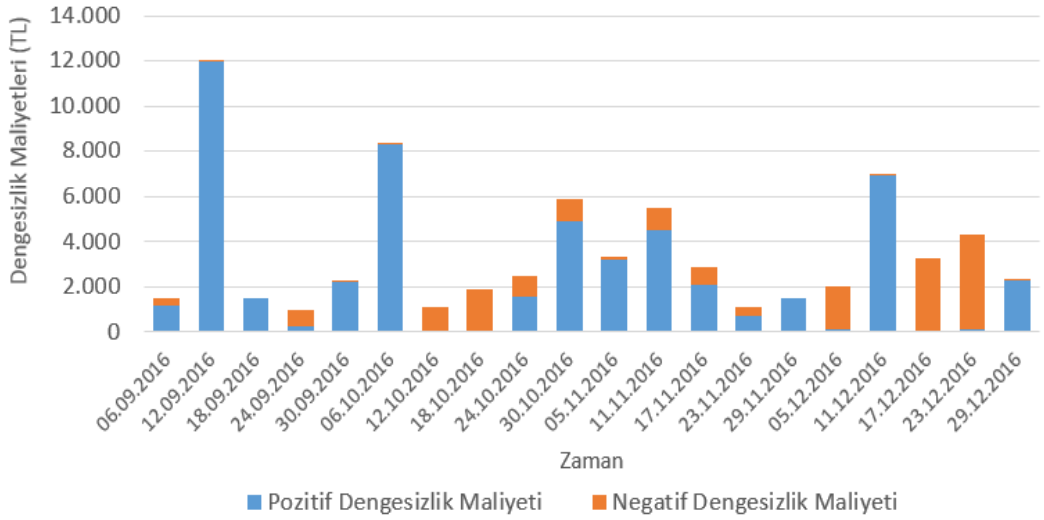
5.2 Modelin Simülasyonu

Üretim tahmini ve fiyat tahmini çalışmalarında eğitim, doğrulama ve test verileri rassal olarak seçilerek en iyi model belirlendikten sonra, bu çalışmada kullanabilmek amacıyla modelin çıktı değerlerini elde etmek için eğitim, doğrulama ve test verileri günlük olarak ayrılmıştır. 1 Eylül 2016 – 31 Aralık 2016 tarihleri arasındaki veriler 4

gün eğitim, 1 gün doğrulama ve 1 gün test verisi olarak ayrılmıştır. Bu sayede verilerin dengeli dağılması sağlanarak farklı tarihlerdeki farklı özelliklere sahip verilerin de test verisetine dahil edilmesi sağlanmıştır. Bu şekilde belirlenen 20 günlük test verileriyle gelir maksimizasyonu amaçlı simülasyon çalışması yapılarak ne kadar gelir artışı elde edileceği hesaplanmıştır. Mevcut durumda yapılan üretim tahminiyle günlük olarak elde edilen gelir, pozitif dengesizlik maliyeti ve negatif dengesizlik maliyetine ilişkin bilgiler Çizelge 5.5'te verilmiştir. Günlere göre pozitif ve negatif dengesizlik maliyetlerindeki değişimler ise Şekil 5.5'te karşılaştırılmıştır.

Çizelge 5.5: Mevcut durumdaki gelir ve maliyetler.

Tarih	Gelir	Pozitif Dengesizlik Maliyeti	Negatif Dengesizlik Maliyeti	Toplam Dengesizlik Maliyeti
06.09.2016	206.119,48	1.189,23	280,21	1.469,44
12.09.2016	84.073,31	11.961,86	81,77	12.043,63
18.09.2016	177.967,19	1.493,34	0,00	1.493,34
24.09.2016	136.919,49	255,55	720,99	976,54
30.09.2016	194.839,93	2.222,01	60,91	2.282,92
06.10.2016	202.405,26	8.330,67	2,50	8.333,17
12.10.2016	93.011,24	0,00	1.102,30	1.102,30
18.10.2016	42.561,05	0,00	1.882,04	1.882,04
24.10.2016	119.741,16	1.545,64	960,41	2.506,05
30.10.2016	71.016,21	4.906,22	951,77	5.857,98
05.11.2016	139.320,89	3.175,19	129,42	3.304,61
11.11.2016	57.286,95	4.493,24	1.019,98	5.513,23
17.11.2016	166.222,99	2.080,60	812,64	2.893,24
23.11.2016	181.640,56	698,10	376,69	1.074,79
29.11.2016	54.568,92	1.480,49	0,00	1.480,49
05.12.2016	51.654,72	143,90	1.866,13	2.010,03
11.12.2016	141.064,47	6.903,72	12,19	6.915,90
17.12.2016	85.152,54	71,01	3.163,87	3.234,88
23.12.2016	21.727,30	132,75	4.185,68	4.318,43
29.12.2016	-1.846,43	2.279,41	90,93	2.370,33
Toplam	**2.225.447,22**	**53.362,91**	**17.700,42**	**71.063,32**



Şekil 5.5: Günlere göre pozitif ve negatif dengesizlik maliyetleri.

5.2.1 Gerçek fiyatların bilindiği durum

Gerçek elektrik fiyatları bilindiği durumda yani elektrik fiyatları %100 doğrulukla tahmin edildiği varsayıldığında elde edilecek gelir artışının hesaplanması için gerçek fiyatlar dikkate alınarak kritik oran belirlenmiş ve bu kritik orana göre optimum teklif değeri belirlenerek gelir ve maliyetler heaplanmıştır. Gerçek hayatta teklif vermeden önce fiyatlar belli olmadığı için tahmin edilen fiyatlara göre kritik oranın belirlendiği çalışmanın sonuçları dikkate alınacaktır. Ancak bu çalışmada fiyat tahmin performansının önemini ve sonuca etkisini de görebilmek için hem gerçek hemde tahmin edilen fiyatlara göre iki ayrı simülasyon yapılmış ve sonuçlar karşılaştırılmıştır. Elektrik fiyatlarının %100 doğrulukla tahmin edildiği varsayıldığında (gerçek fiyatlar kullanıldığında) elde edilen gelir, dengesizlik maliyetleri ve gelir artışına ilişkin bilgiler Çizelge 5.6'da verilmiştir.

Gerçek fiyatlar kullanıldığında elde edilen sonuçlar ile mevcut durum karşılaştırılmıştır. Gelirde 1,48% artış gözlenirken, dengesizlik maliyetlerinde 46,48% oranında azalma gözlenmiştir. 33.029,84 TL kar elde edilmiştir. Bu sonuçlara ilişkin bilgiler Çizelge 5.7'de verilmiştir.

Çizelge 5.6: Gerçek fiyatlar bilindiği durumda gelir ve maliyetler.

Tarih	Gelir	Pozitif Dengesizlik Maliyeti	Negatif Dengesizlik Maliyeti	Toplam Dengesizlik Maliyeti	Gelir Artışı
06.09.2016	206.836,89	606,34	145,70	752,04	717,40
12.09.2016	94.791,63	11,64	1.313,66	1.325,30	10.718,32
18.09.2016	177.328,06	1.970,31	162,15	2.132,47	-639,13
24.09.2016	135.728,01	11,06	2.156,95	2.168,01	-1.191,48
30.09.2016	196.552,41	164,90	405,54	570,44	1.712,48
06.10.2016	209.544,87	82,02	1.111,55	1.193,57	7.139,60
12.10.2016	91.388,56	15,62	2.709,36	2.724,98	-1.622,68
18.10.2016	41.578,73	0,00	2.864,36	2.864,36	-982,31
24.10.2016	120.555,10	130,18	1.561,92	1.692,11	813,94
30.10.2016	74.696,82	0,00	2.177,37	2.177,37	3.680,61
05.11.2016	141.329,39	964,66	331,44	1.296,11	2.008,50
11.11.2016	60.250,41	0,00	2.549,77	2.549,77	2.963,46
17.11.2016	168.153,41	557,53	405,28	962,81	1.930,43
23.11.2016	181.890,83	260,11	564,41	824,53	250,26
29.11.2016	54.367,93	1.681,48	0,00	1.681,48	-201,00
05.12.2016	52.805,73	120,86	738,15	859,02	1.151,01
11.12.2016	143.230,93	4.560,91	188,53	4.749,44	2.166,46
17.12.2016	86.922,92	59,01	1.405,49	1.464,50	1.770,38
23.12.2016	22.055,64	7,50	3.982,59	3.990,09	328,34
29.12.2016	-1.531,21	0,00	2.055,11	2.055,11	315,22
Toplam	**2.258.477,06**	**11.204,15**	**26.829,34**	**38.033,48**	**33.029,84**

Çizelge 5.7: Mevcut ve optimum durum karşılaştırması (Gerçek fiyatlar).

	Mevcut Durum	Optimum Durum	Değişim Oranı	Kar
Gelir	2.225.447,22	2.258.477,06	1,48%	33.029,84
Maliyet	71.063,32	38.033,48	-46,48%	

5.2.2 Tahmin edilen fiyatların kullanıldığı durum

Tahmin edilen fiyatlar dikkate alınarak kritik oran belirlenmiş ve bu kritik orana göre optimum teklif değeri belirlenerek gelir, dengesizlik maliyetleri ve gelir artışı hesaplanmıştır. Elde edilen sonuçlar Çizelge 5.8'de verilmiştir.

Tahmin edilen fiyatlar kullanıldığında elde edilen sonuçlar ile mevcut durum karşılaştırılmıştır. Gelirde 0,82% artış gözlenirken, dengesizlik maliyetlerinde 25,72% oranında azalma gözlenmiştir. 18.274,42 TL kar elde edilmiştir. Bu sonuçlara ilişkin bilgiler Çizelge 5.9'da verilmiştir.

Çizelge 5.8: Tahmin edilen fiyatların kullanıldığı durumda gelir ve maliyetler.

Tarih	Gelir	Pozitif Dengesizlik Maliyeti	Negatif Dengesizlik Maliyeti	Toplam Dengesizlik Maliyeti	Gelir Artışı
06.09.2016	205.317,77	1.506,00	765,16	2.271,15	-801,71
12.09.2016	93.261,91	2.363,86	491,17	2.855,03	9.188,60
18.09.2016	177.857,93	196,62	1.405,98	1.602,60	-109,26
24.09.2016	136.327,37	192,92	1.375,73	1.568,65	-592,11
30.09.2016	194.465,85	1.837,89	819,10	2.657,00	-374,08
06.10.2016	208.077,79	2.308,96	351,68	2.660,65	5.672,52
12.10.2016	91.660,98	0,00	2.452,56	2.452,56	-1.350,26
18.10.2016	41.174,12	0,00	3.268,97	3.268,97	-1.386,92
24.10.2016	119.847,56	6,74	2.392,91	2.399,65	106,40
30.10.2016	75.179,19	54,99	1.640,01	1.695,00	4.162,98
05.11.2016	140.453,69	1.282,40	889,40	2.171,81	1.132,80
11.11.2016	60.317,71	0,00	2.482,46	2.482,46	3.030,77
17.11.2016	164.788,36	2.560,39	1.767,47	4.327,86	-1.434,63
23.11.2016	181.137,96	382,35	1.195,04	1.577,39	-502,60
29.11.2016	54.651,55	1.323,23	74,63	1.397,86	82,63
05.12.2016	52.921,79	160,45	582,50	742,95	1.267,07
11.12.2016	139.419,41	8.542,37	18,60	8.560,97	-1.645,06
17.12.2016	82.005,80	0,00	6.381,62	6.381,62	-3.146,74
23.12.2016	24.688,96	750,17	606,59	1.356,76	2.961,67
29.12.2016	165,93	322,10	35,87	357,97	2.012,36
Toplam	**2.243.721,64**	**23.791,45**	**28.997,45**	**52.788,90**	**18.274,43**

Çizelge 5.9: Mevcut ve optimum durum karşılaştırması (Tahmini fiyatlar).

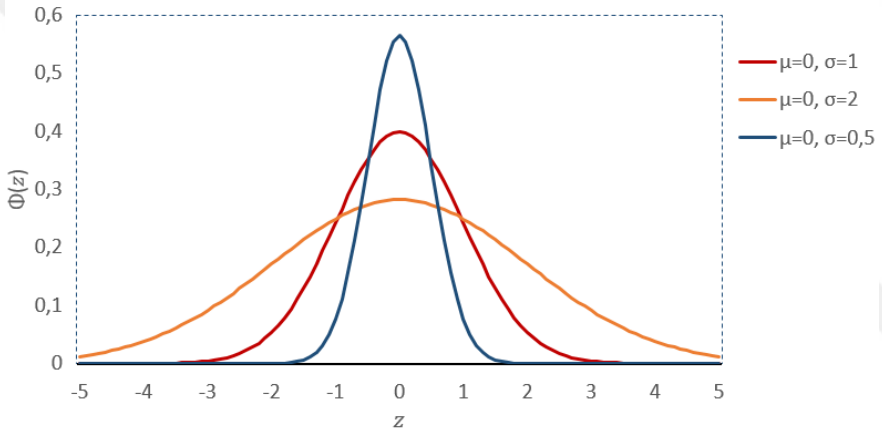
	Mevcut Durum	Optimum Durum	Değişim Oranı	Kar
Gelir	2.225.447,22	2.243.721,64	0,82%	18.274,42
Maliyetler	71.063,32	52.788,90	-25,72%	

Üretim tahmini ve fiyat tahmini çalışmaları sonucunda elde edilen tahmin değerleri ile gelir %0,82 oranında arttırılarak 18.274,42 TL kar elde edilmiştir. Eğer fiyatlar %100 doğru tahmin edilmiş olsaydı gelir %1,48 oranında artış göstererek 33.029,84 TL kar elde edebilmek mümkün olacaktı. Eğer üretim %100 doğru tahmin edilebilmiş olsaydı mevcut durumdaki 71.063,32 TL'lik dengesizlik maliyeti hiç ortaya çıkmayacağı için elde edilen gelir %3,19 oranında artış göstererek mevcut üretim kapasitesiyle mümkün olan en yüksek gelir elde edilebilecekti.

5.3 Standart Sapma Değerinin Sonuca Etkisi

Üretim tahmini değerlerinin hatalarının hesaplanan standart sapma değerleri ($\sigma = 24{,}157$) kullanılarak kritik oran hesaplanmış ve hataların dağılımının normal dağılıma uyduğu varsayılmıştır. Bu çalışmada standart sapma (σ) dışında yeni bir sapma ölçüsü (k) tanımlanarak bu ölçünün aldığı farklı değerleri göre elde edilen sonuçlardaki değişim incelenerek en yüksek geliri artışını veren sapma değeri bulunmuştur.

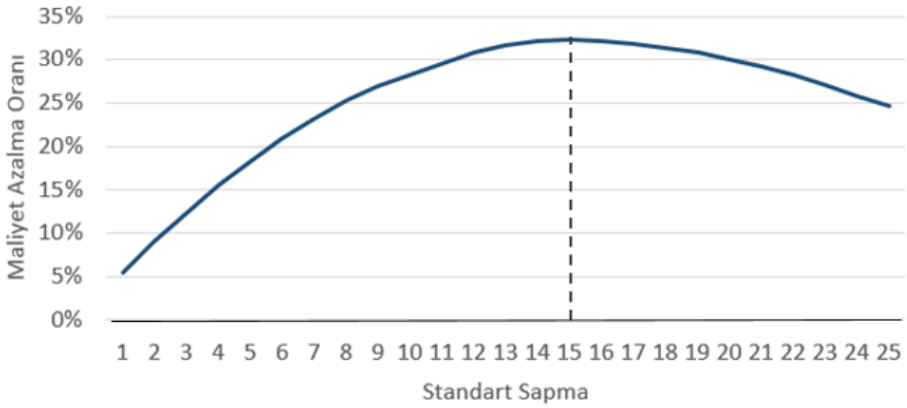
Ortalaması (μ) 0, standart sapması (σ) 1 olan normal dağılıma standart normal dağılım denir. Standart normal dağılımın standart sapmasının 1'den farklı değerler alması durumunda standart normal dağılım eğrisindeki değişimler Şekil 5.6'de verilmiştir.



Şekil 5.6: Farklı standart sapma değerlerine sahip normal dağılım eğrileri.

Örneğin; yeni sapma ölçüsü olan k, standart sapmanın yarısı olarak tanımlanırsa ($k = \sigma/2$), $k = 12{,}08$ değerini alacaktır. Ortalaması μ, sapma değeri k olan normal dağılım eğrisi ise Şekil 5.6'da gösterilen $\sigma = 0{,}5$ olan standart normal dağılım eğrisine benzeyecektir. k için 1 ile 25 arasında değerler verilerek sonuçlardaki değişim incelenmiştir. $k = 15$ olduğu durumda elde edilen gelirin en yüksek olduğu gözlemlenmiştir.

k değerlerine göre elde edilen sonuçlar Çizelge 5.10'da, maliyet azalış oranındaki değişimin grafiği ise Şekil 5.7'de verilmiştir.



Şekil 5.7: Farklı sapma değerlerine göre maliyet azalış oranındaki değişim.

Çizelge 5.10: Farklı sapma değerlerine göre elde edilen sonuçlar.

Standart Sapma	Gelir	Maliyet	Gelir Artış Oranı	Maliyet Azalış Oranı
1	2.229.328,57	67.181,97	0,17%	5,46%
2	2.231.878,41	64.632,13	0,28%	9,05%
3	2.234.198,98	62.311,56	0,39%	12,31%
4	2.236.467,93	60.042,61	0,49%	15,50%
5	2.238.478,16	58.032,38	0,58%	18,33%
6	2.240.279,34	56.231,20	0,66%	20,87%
7	2.241.928,01	54.582,53	0,74%	23,19%
8	2.243.379,88	53.130,66	0,80%	25,23%
9	2.244.599,22	51.911,32	0,86%	26,95%
10	2.245.558,47	50.952,07	0,90%	28,30%
11	2.246.461,47	50.049,07	0,94%	29,57%
12	2.247.322,39	49.188,15	0,98%	30,78%
13	2.247.957,31	48.553,23	1,01%	31,67%
14	2.248.346,00	48.164,54	1,02%	32,22%
15	**2.248.447,32**	**48.063,22**	**1,03%**	**32,36%**
16	2.248.340,76	48.169,78	1,02%	32,21%
17	2.248.057,85	48.452,69	1,01%	31,81%
18	2.247.737,37	48.773,17	1,00%	31,36%
19	2.247.321,69	49.188,85	0,98%	30,78%
20	2.246.780,97	49.729,57	0,95%	30,02%
21	2.246.225,90	50.284,64	0,93%	29,24%
22	2.245.552,24	50.958,30	0,90%	28,29%
23	2.244.704,59	51.805,95	0,86%	27,09%
24	2.243.814,49	52.696,05	0,82%	25,84%
25	2.242.908,83	53.601,71	0,78%	24,57%

$\sigma = 24{,}157$ olduğu durumda gelir %0,82 oranında artmış, maliyetler ise %25,72 oranında azalmış ve 18.274,42 TL kar elde edilmiştir. $k = 15$ seçildiği durumda ise gelir %1,03 oranında artmış, maliyetler ise %32,36 oranında azalmış ve 23.000,10 TL kar elde edilmiştir. Yani 4.725,68 TL daha fazla kar edilmiştir.

6. SONUÇ VE DEĞERLENDİRMELER

Enerji ihtiyacının karşılanmasına yönelik olarak hem güvenli hemde çevre dostu olması açısından yenilenebilir enerji yatırımları son zamanlarda artmaya başlamıştır. Ülkemiz yıllık güneşlenme süresinin uzun olması nedeniyle güneş enerjisi üretim santrali yatırımlarına uygun potansiyele sahiptir.

Güneş panellerinden elektrik üreten firmaların yatırımlarını planlamak ve maliyetlerini düşürmek için gelecekte ne kadar elektrik üretimi yapabileceklerinin tahmin edilmesi önem arz etmektedir. Literatürdeki uygulanan tahmin çalışmaları uzun ve kısa vadeli tahminler olarak ikiye ayrılabilir. Güneş enerjisi yatırımlarına karar verilmesi süreçlerinde yıllık güneş ışıması tahminleri yapılmaktadır.

Kısa vadeli tahminler ise saatlik ve günlük olarak yapılmaktadır. Günlük tahminler ise genellikle gün öncesi elektrik piyasasına üretim teklifleri vermek için yapılmaktadır. Elektrik üreten firmalar bir gün sonraki üretim miktarlarını saatlik olarak EPİAŞ'a bildirmektedirler ve elektrik fiyatları bu tekliflere göre oluşmaktadır. Güneş enerjisi üretimi hava şartlarına ve güneş ışımasına bağlı olarak gerçekleştiği için üretim her zaman planlandığı gibi olamamaktadır.

Tahmin edilen üretimin gerçekleşen üretimden az olması durumunda üretici firmalar negatif dengesizliğe düşmektedir. Bu durumda EPİAŞ tarafından belirlenen kurallara göre elektrik fiyatlarına bağlı olarak hesaplanan cezayı ödemek durumunda kalmaktadır. Aynı şekilde tahmin edilen üretimin gerçekleşen üretimden fazla olması durumunda ise firmalar pozitif dengesizliğe düşmektedirler. Bu durumda üretim fazlası olan kısım EPİAŞ tarafından daha düşük bir fiyata satın alınarak firmalar farklı bir şekilde cezalandırılmaktadır. Bu nedenle düşük hatayla üretim tahmini yapmak enerji üreten firmalar için önemli bir ihtiyaç olmaya başlamıştır.

Tezin 3. bölümünde ise kısa vadeli güneş enerjisi üretim tahmini uygulamasına yer verilmiştir. Geçmiş veriler kullanılarak meteorolojik faktörlerin güneşten gelen ışınımının yeryüzüne ulaşmasının ne derecede etkilediği kurulan tahmin modelleriyle öğrenilmeye çalışılmıştır. Daha sonrasında ise bir gün sonrasının üretim miktarı yarım saatlik aralıklarla tahmin edilmiştir. Çalışma kapsamında en çok bilinen ve yaygın

kullanılan tahmin yöntemlerinden olan doğrusal regresyon yönteminin yanısıra güneş enerjisi üretim tahmini literatüründe en çok kullanılan ve doğrusal olmayan tahmin problemlerinde iyi sonuçlar veren yapay sinir ağlarının çok katmanlı algılayıcı mimarisi kullanılmıştır. Bir yapay sinir ağını oluşturan, aktivasyon fonksiyonu, öğrenme algoritması, gizli nöron sayısı ve öğrenme oranı parametreleri için farklı seçenekler denenerek çok sayıda model kurulmuştur. İki yöntemin sonuçları kıyaslanarak en iyi sonucu veren tahmin modeli seçilmiştir.

Aktivasyon fonksiyonu *tansig*, öğrenme algoritması *trainlm*, gizli nöron sayısı 16 ve öğrenme oranı 0,05 olan çok katmanlı algılayıcı modeli en düşük hataya ulaşılan model olarak tespit edilmiştir. Test verilerinin sonuçlarına göre en düşük hataya ulaşılan modelin hata kareleri ortalaması (MSE) değeri 0,06042; R^2 değeri ise 0,83252 bulunmuştur. Havanın açık ve parçalı bulutlu olduğu durumlarda elektrik üretiminin fazla, çok bulutlu ve kapalı durumlarla ise üretimin önemli derecede azaldığı ve tahmin hatasının da yükseldiği gözlemlenmiştir.

Bu konuda yapılacak olan diğer çalışmalara katkı sağlamak ve daha iyi sonuçlara ulaşmak için atılacak adımlar şu şekilde özetlenebilir:

Bulutluluk durumunu ifade eden kategorik değişkenler yerine bulutluluk indeksi değerleri temin edilerek girdi değişkeni olarak kullanılırsa bulutluluk durumu sayısal olarak ifade edilebilecek ve üretime etkisi daha iyi ölçülebilecektir.

Havanın çok bulutlu ve kapalı olduğu durumlarda bulutlar güneş ile paneller arasındaki güneş ışımasını kapattığında üretim azalırken yada sıfıra inerken, bulutların hareket etmesiyle üretim tekrar artmaktadır. Bu nedenle böyle hava koşullarında üretim miktarının öngörülmesinde zorluk yaşanmaktadır. Havanın çok bulutlu veya kapalı olduğu bilgisinin yanısıra bulutların hareketi ve anlık konumu, ne kadar süreyle güneşin kapandığı bilgilerine de ihtiyaç duyulmaktadır. Bunun için veri kaynağı olarak sadece meteorojik değerler değil, sık aralıklarla yapılan güneş ışıması teknik ölçümleri veya uydu görüntülerinin kullanılması tahmin hatalarını ciddi derecede düşürecektir.

Tezin 4. bölümünde öncelikle elektrik piyasasının gelişim süreci özetlenmiştir. Daha sonrasında ise dengesizlik maliyetlerini minimize edecek olan teklif miktarının bulunması amacıyla elektrik fiyatı tahmin çalışması yapılmıştır.

1970 yılında Türkiye Elektrik Kurumunun kuruluşundan günümüze kadar elektrik piyasası serbestleşme yolunda sürekli gelişim göstermiştir. Gün öncesi ve gerçek

zamanlı piyasalar kurularak elektrik alım ve satım tekliflerinin saatlik olarak verildiği yeni bir yapıya geçilmiştir. Arz ve talebin saatlik olarak dengelenmesiyle her iki taraf için de uygun olan fiyatlarının belirlenmesi mümkün olmuştur. Bu sayede elektrik ticaretinin etkin ve verimli bir biçimde gerçekleşmesi sağlanmıştır. EPİAŞ'ın kurulmasıyla birlikte elektrik ticareti borsası oluşturulması yönünde önemli bir adım atılarak elektrik piyasası rekabete dayalı olarak etkin şekilde çalışan serbest piyasa özelliğini kazanmıştır.

Elektrik fiyatlarını tahmini için geçmiş fiyat verilerinin girdi değişkeni olduğu bir yapay sinir ağı modeli kullanılmıştır. Böylece en çok kullanılan yöntemlerden olan zaman serileri ve yapay sinir ağlarının özellikleri birleştirilmiştir. Bunun yanısıra en sık kullanılan tahmin yöntemlerinden olan doğrusal regresyon yöntemi de kullanılarak performans sonuçları karşılaştırılmıştır. Yapay sinir ağı modellerinin özellikle doğrusal olmayan problemlerde, doğrusal regresyon ve zaman serileri yöntemlerine kıyasla değişkenler arası ilişkileri daha iyi öğrendiği ve fiyat tahmini sürecinde genellikle daha iyi performansa sahip olduğu yapılan diğer çalışmalarda gözlemlenmiştir. Bu çalışmada da yapay sinir ağlarının doğrusal regresyondan daha iyi sonuç verdiği yapılan analizlerle gösterilmiştir. Uç değerlerin olumsuz etkilerinin azaltılması için yapılan veri ön işleme çalışması her iki yöntem için de sonuca olumlu katkısı olmuştur.

Yapay sinir ağı mimarisi seçimi aşamasında ise, tahmin problemlerinde iyi sonuçlar alınan ve sıklıkla kullanılan çok katmanlı algılayıcıların seçilmesine karar verilmiştir. En uygun modelin bulunması aşamasında ise aktivasyon fonksiyonu, öğrenme algoritması, öğrenme oranı ve gizli nöron sayılarının belirlenmesi için farklı değerler denenerek çok sayıda model oluşturulmuştur. En düşük hataya sahip olan PTF ve SMF tahmin modeli belirlenmiştir. Gizli katman aktivasyon fonksiyonu Hiperbolik Tanjant (tansig), öğrenme algoritması Levenberg- Marquardt (trainlm) ve öğrenme oranı 0,05 olan model ile hem PTF hem de SMF tahmininde en düşük hataya ulaşılmıştır. PTF modelinin çıktı katmanında Lineer (purelin) aktivasyon fonksiyonu ve 18 gizli nöron kullanılırken SMF modelinin çıktı katmanında Hiperbolik Tanjant (tansig) aktivasyon fonksiyonu ve 15 gizli nöron kullanılmıştır.

PTF değerinin gece düştüğü ve sabahtan itibaren tekrar yükselerek gün içinde küçük dalgalanmalar sonrasında geceden itibaren tekrar düşecek şekilde günlük olarak belli bir periyodu takip ettiği gözlemlenmiştir. SMF verileri de gece ve gündüz benzer bir

değişim göstermektedir fakat PTF kadar belirgin bir periyoda sahip değildir. SMF verilerinde ani düşüş ve yükselişler gibi öngörülemeyen rassal değişiklikler olabilmektedir. PTF verileri ortalaması 140, standart sapması 68 iken SMF ortalaması 132 ve standart sapmasını 83 olması SMF'nin daha çok sapma göstermesinin bir sonucudur. Bu nedenle SMF tahmininde daha çok zorluklarla karşılaşılmakta ve tahmin hataları daha yüksek olmaktadır.

SMF'yi tahmin etmek için sadece geçmiş verilerin yeterli olmayacağı çıkarımı yapılmıştır. Elektrik piyasasındaki üretici ve tüketicilerin durumu ile ilgili daha fazla veri toplanması, elektrik arz ve talebindeki sapmaların sebeplerinin belirlenmesi, ülkenin sosyal, ekonomik, siyasi durumu gibi makro düzeyde verilerin bilinmesi SMF tahmin performansını arttıracaktır.

Tezin 5. bölümünde firmaların maruz kaldıkları bu cezalar gazeteci çocuk problemi olarak ele alınmış ve dengesizlik maliyetleri göz önüne alınarak gelir fonksiyonu oluşturulmuştur. Bu fonksiyonun türevi sıfıra eşitlenerek, fonksiyonu maksimize eden kritik oranın bulunması hedeflenmiştir. Kritik oran bulunduktan sonra ilgili verilerin ortalama ve standart sapma bilgileri kullanılarak optimum teklif değeri hesaplanmıştır. Öncelikle mevcut durumdaki yani tahmin edilen üretim değerine göre dengesizlik maliyetleri ve elde edilen gelir hesaplanmıştır. Daha sonra optimum teklif değerine göre dengesizlik maliyetleri ve gelir tekrar hesaplanarak iki durum karşılaştırılmış ve ne kadar iyileştirme yapıldığı gözlemlenmiştir. Bu karşılaştırma işlemi fiyatların tahmin edildiği durum ve gerçek fiyatların bilindiği durum için ayrı ayrı yapılmıştır.

Fiyatların tahmin edildiği durum ile gerçek fiyatların bilindiği yani fiyatların hatasız tahmin edildiği durumdaki elde edilen gelir karşılaştırılarak fiyat tahmin performansının elde edilen gelire etkisi gözlemlenebilmiştir. Fiyatların tahmin edildiği durumda gelir %0,82 oranında artarak 18.274,42 TL kar elde edilirken eğer fiyatlar sıfır hata ile tahmin edilmiş olsaydı gelir %1,48 oranında artarak 33.029,84 TL kar elde edebileceği hesaplanmıştır. Böylece fiyat tahmin performansının sonuca etkisi görülebilmiştir.

Eğer üretim hatasız bir şekilde tahmin edilmiş olsaydı mevcut durumdaki 71.063,32 TL'lik dengesizlik maliyeti hiç ortaya çıkmayacağı için elde edilen gelir %3,19 oranında artarak mevcut üretim kapasitesiyle mümkün olan en yüksek gelir elde edilebilecekti. Üretim tahmin performansının sonuca ne kadar etki ettiği de bu şekilde görülebilmiştir. Bütün bu çalışmalar $\sigma = 24{,}157$ olarak hesaplanan standart sapma

değerine göre yapılmıştır. Standart sapmanın sonuca etkisinin görülebilmesi için yeni bir sapma ölçüsü (k) tanımlanarak farklı sapma değerlerinin kullanılması durumunda gelirin ne kadar artabileceği hesaplanmıştır. k değeri 15 alındığında 4.725,68 TL daha fazla gelir elde edilebileceği görülmüştür.

KAYNAKLAR

[1] **Ahmad, A., Anderson, T. N., & Lie, T. T.** (2015). Hourly global solar irradiation forecasting for New Zealand. Solar Energy, 122, 1398-1408.

[2] **Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., & Ogliari, E.** (2017). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. *Mathematics and Computers in Simulation*, 131, 88-100.

[3] **Dolara, A., Grimaccia, F., Leva, S., Mussetta, M., & Ogliari, E.** (2015). A physical hybrid artificial neural network for short term forecasting of PV plant power output. Energies, 8(2), 1138-1153.

[4] **Izgi, E., Öztopal, A., Yerli, B., Kaymak, M. K., & Şahin, A. D. (2012).** Short–mid-term solar power prediction by using artificial neural networks. Solar Energy, 86(2), 725-733.

[5] **Hocaoğlu, F. O., Gerek, Ö. N., & Kurban, M.** (2008). Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward neural networks. Solar energy, 82(8), 714-726.

[6] **Mellit, A., Pavan, A. M., & Lughi, V.** (2014). Short-term forecasting of power production in a large-scale photovoltaic plant. Solar Energy, 105, 401-413.

[7] **Wu, Y. K., Chen, C. R., & Abdul Rahman, H.** (2014). A novel hybrid model for short-term forecasting in PV power generation. International Journal of Photoenergy, 2014.

[8] **Yang, H. T., Huang, C. M., Huang, Y. C., & Pai, Y. S.** (2014). A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output. IEEE transactions on sustainable energy, 5(3), 917-926.

[9] **Tao, C., Shanxu, D., & Changsong, C.** (2010). Forecasting power output for grid-connected photovoltaic power system without using solar radiation measurement. In Power Electronics for Distributed Generation Systems (PEDG), 2010 2nd IEEE International Symposium on (pp. 773-777). IEEE.

[10] **Chen, C., Duan, S., Cai, T., & Liu, B.** (2011). Online 24-h solar power forecasting based on weather type classification using artificial neural network. Solar Energy, 85(11), 2856-2870.

[11] **Hocaoğlu, F. O.** (2011). Stochastic approach for daily solar radiation modeling. Solar Energy, 85(2), 278-287.

[12] **Bouzerdoum, M., Mellit, A., & Pavan, A. M.** (2013). A hybrid model (SARIMA–SVM) for short-term power forecasting of a small-scale grid-connected photovoltaic plant. Solar Energy, 98, 226-235.

[13] **Bracale, A., Caramia, P., Carpinelli, G., Di Fazio, A. R., & Ferruzzi, G.** (2013). A Bayesian method for short-term probabilistic forecasting of photovoltaic generation in smart grid operation and control. Energies, 6(2), 733-747.

[14] **Tayşi, Z. C., Biricik, G., & Bozkurt, Ö. Ö.** (2015). Evaluation of price forecast systems for Turkish Electric Market. In Signal Processing and Communications Applications Conference (SIU), 2015 23th (pp. 620-623). IEEE.

[15] **Anbazhagan, S., & Kumarappan, N.** (2013). Day-ahead deregulated electricity market price forecasting using recurrent neural network. IEEE Systems Journal, 7(4), 866-872.

[16] **Kölmek, M. A., & Navruz, İ.** (2015). Forecasting the day-ahead price in electricity balancing and settlement market of Turkey by using artificial neural networks. Turkish Journal of Electrical Engineering & Computer Sciences, 23(3), 841-852.

[17] **Szkuta, B. R., Sanabria, L. A., & Dillon, T. S.** (1999). Electricity price short-term forecasting using artificial neural networks. IEEE transactions on power systems, 14(3), 851-857.

[18] **Wang, A., & Ramsay, B.** (1997). Prediction of system marginal price in the UK Power Pool using neural networks. In Neural Networks, 1997., International Conference on (Vol. 4, pp. 2116-2120). IEEE.

[19] **Yamin, H. Y., Shahidehpour, S. M., & Li, Z.** (2004). Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets. International journal of electrical power & energy systems, 26(8), 571-581.

[20] **Biricik, G., Bozkurt, Ö. Ö., & Tayşi, Z. C.** (2015). Analysis of features used in short-term electricity price forecasting for deregulated markets. In Signal Processing and Communications Applications Conference (SIU), 2015 23th (pp. 600-603). IEEE.

[21] **Panapakidis, I. P., & Dagoumas, A. S.** (2016). Day-ahead electricity price forecasting via the application of artificial neural network based models. Applied Energy, 172, 132-151.

[22] **Kaya, G. O., Demirel, O. F., Zaim, S., & Gorener, R**. (2015). Day-ahead Electricity Price Forecasting Using a Wavelet-Support Vector Machine Conjunction Model. In Conference on Engineering And Technology Management GCETM-2015 (p. 179).

[23] **Özgüner, E.** (2012). Short Term Electricity Price Forecasting In Turkish Electricity Market, Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara .

[24] **Pindoriya, N. M., Singh, S. N., & Singh, S. K.** (2008). An adaptive wavelet neural network-based energy price forecasting in electricity markets. IEEE Transactions on Power Systems, 23(3), 1423-1432.

[25] **Bhaskar, K., & Singh, S. N.** (2014). Wind power bidding strategy in a day-ahead electricity market. In PES General Meeting| Conference & Exposition, 2014 IEEE (pp. 1-5). IEEE.

[26] **Matevosyan, J., & Soder, L**. (2006). Minimization of imbalance cost trading wind power on the short-term power market. IEEE Transactions on Power Systems, 21(3), 1396-1404.

[27] **Herranz, R., San Roque, A. M., Villar, J., & Campos, F. A.** (2012). Optimal demand-side bidding strategies in electricity spot markets. IEEE Transactions on power systems, 27(3), 1204-1213.

[28] **Gomes, I., Pousinho, H., Melício, R., & Mendes, V.** (2016). Bidding and optimization strategies for wind-PV systems in electricity markets.

[29] **Xue, Y., Venkatesh, B., & Chang, L**. (2008). Bidding wind power in short-term electricity market based on multiple-objective fuzzy optimization. In Electrical and Computer Engineering, 2008. CCECE 2008. Canadian Conference on (pp. 001135-001138). IEEE.

[30] **Guo, Y., Gong, Y., Fang, Y., & Khargonekar, P. P**. (2014). Stochastic minimization of imbalance cost for a virtual power plant in electricity markets. In Innovative Smart Grid Technologies Conference (ISGT), 2014 IEEE PES (pp. 1-5). IEEE.

[31] **Wan, Z., & Fan, H**. (2010). Bidding strategy for day-ahead and real-time markets based on newsvendor method in electricity markets. In Information Science and Management Engineering (ISME), 2010 International Conference of (Vol. 2, pp. 310-313). IEEE.

[32] **Aksoy, S. A., Eryiğit, E., Hashimova, N., İşbilir, M., Avşar, Z. M., Köksal, G., & Terciyanli, E.** (2013). Rüzgâr gücü üretimi için tahmin ve teklif sistemi tasarımı. Journal of Industrial Engineering (Turkish Chamber of Mechanical Engineers), 24.

[33] **Zhang, H., Gao, F., Wu, J., Liu, K., & Liu, X.** (2012). Optimal bidding strategies for wind power producers in the day-ahead electricity market. Energies, 5(11), 4804-4823.

[34] **Çiğdem, E.** (2017). A newsvendor approach to energy imbalance mechanism in a day ahead electricity market (Master dissertation, Bilkent University).

[35] **Öztemel, E.** (2003). Yapay Sinir Ağlari. Papatya Yayıncılık, İstanbul.

[36] **Guresen, E., & Kayakutlu, G.** (2011). Definition of artificial neural networks with comparison to other networks. Procedia Computer Science, 3, 426-433.

[37] **Zilouchian, A., & Jamshidi, M.** (2000). Intelligent control systems using soft computing methodologies. CRC Press, Inc..

[38] **Elmas, Ç.** (2003). Yapay Sinir Ağları. Seçkin Yayıncılık, Ankara, 27-37.

[39] **Yüksek, A. G.** (2007). Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.

[40] **Deveci, M. ve Yavuz, S.** (2012). İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi, Erciyes Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi, 40, (s.167-187).

[41] **Ballı, M. T.** (2014). Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul

[42] **Şahin, Ş.** (2002). Yapay Sinir Ağları Yardımı İle Dinamik Bir Senaryo Analizi, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

[43] **Alpaydin, E.** (2014). Introduction to machine learning. MIT press.

[44] **Masters, T.** (1993). Practical neural network recipes in C++. Morgan Kaufmann

[45] **Çınar, D.** (2015). Hidroelektrik enerji üretiminin hibrid bir model ile tahmini, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

[46] **Gurney, K.** (1997). An introduction to neural networks. CRC press.

[47] **Gruca, T. S. ve Klemz, B. R.** (1997). Using Neural Networks To Identify Competitive Market Structures From Aggregate Market Response Data, Omega, 26(1), (s.49-62).

[48] **Hardgrave, B. C., Wilson, R. L. ve Walstrom, K. A.** (1994). Predicting Graduate Student Success: A Comparison Of Neural Networks And Traditional Techniques, Computers Operationals Research, 21 (3), (s.249-263).

[49] **Welstead, S. T.** (1994). Neural Network and Fuzzy Logic Applications in C-C++. John Wiley & Sons, Inc..

[50] **Anderson, D. ve McNeill, G.,** (1992). Artificial Neural Networks Technology, A DACS State of Art Report, New York

[51] **Rusen, S. E.** (2013). Linking satellite imagery to bright sunshine hours for the estimation of global solar irradiaiton, Doktora Tezi, Ortadoğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

[52] **Özdemir, Y.** (2012). Uydu Tabanlı Kuadratik Model İle Türkiye'de Güneş Radyasyonu Dağılımının Belirlenmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

[53] **Yang, D., Jirutitijaroen, P., & Walsh, W. M.** (2012). Hourly solar irradiance time series forecasting using cloud cover index. Solar Energy, 86(12), 3531-3543

[54] **TEİAŞ,** 2016 Yılı Türkiye Elektrik İletimi Sektör Raporu

[55] **T.C Resmi Gazete,** Elektrik Piyasası Kanunu. (6446), 30.03.2013

[56] **EPİAŞ,** Kurumsal Bilgiler, https://www.epias.com.tr/kurumsal/, 21 Ekim 2017

[57] **T.C Resmi Gazete,** Elektrik Piyasası Dengeleme ve Uzlaştırma Yönetmeliği. (27200), 14.04.2009

[58] **Bicil, İ. M.** (2015). Elektrik piyasasında fiyatlandırma ve Türkiye elektrik piyasasında fiyat tahmini, Doktora Tezi, Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü, Balıkesir.

[59] **TEİAŞ,** Türkiye Elektrik Piyasası, https://www.teias.gov.tr/tr/yayinlar-raporlar/piyasa-raporlari, 21 Ekim 2017

[60] **Taşpınar, M.** (2011). Enerji yönetim sistemlerinde optimizasyon teknikleri, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul

[61] **Aggarwal, S. K., Saini, L. M., & Kumar, A.** (2009). Electricity price forecasting in deregulated markets: A review and evaluation. International Journal of Electrical Power & Energy Systems, 31(1), 13-22.

[62] **EPİAŞ,** Günlük Raporlar, https://rapor.epias.com.tr/rapor/, 21 Ekim 2017

[63] **Sitti, K.,** Gün Öncesi Piyasası ve Gün İçi Piyasası Karşılaştırması, (2015), http://www.tenva.org/gun-oncesi-piyasasi-ve-gun-ici-piyasasi-karsilastirmasi/, 27 Ekim 2017

ÖZGEÇMİŞ



Ad Soyad : Sait YAZICI

Doğum Tarihi ve Yeri : 06.01.1989 - Nevşehir

E-posta : saityazici@gmail.com

ÖĞRENİM DURUMU:

- **Lisans :** 2012, Kocaeli Üniversitesi, Endüstri Mühendisliği Bölümü

MESLEKİ DENEYİM:

- 2013-2017, Arete Danışmanlık, SAP İş Zekası Danışmanı