

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI KULLANILARAK
TÜRKİYE GÜN ÖNCESİ PİYASASI ELEKTRİK FİYAT TAHMİNİ**

YÜKSEK LİSANS TEZİ

Aslıhan DALGIN

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

EYLÜL 2017

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI KULLANILARAK
TÜRKİYE GÜN ÖNCESİ PİYASASI ELEKTRİK FİYAT TAHMİNİ**

YÜKSEK LİSANS TEZİ

Aslıhan DALGIN

(301061028)

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Doç. Dr. Gülgün KAYAKUTLU

EYLÜL 2017

İTÜ, Enerji Enstitüsü'nün 301061028 numaralı Yüksek Lisans Öğrencisi Aslıhan DALGIN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “YAPAY SİNİR AĞLARI KULLANILARAK TÜRKİYE GÜN ÖNCESİ PİYASASI ELEKTRİK FİYAT TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gülgün KAYAKUTLU**
İstanbul Teknik Üniversitesi


Jüri Üyeleri : **Prof. Dr. Sermin ONAYGİL**
İstanbul Teknik Üniversitesi

Prof. Dr. Gülçin BÜYÜKÖZKAN FEYZİOĞLU
Galatasaray Üniversitesi

Teslim Tarihi : 24 Ağustos 2017

Savunma Tarihi : 18 Eylül 2017





***Bu çalışma,
Eğitim hayatım boyunca desteği ve ilgisi ile hep yanımda olan
Aileme ithaf edilmiştir...***



ÖNSÖZ

Bu çalışmada öncelikle desteğini benden esirgemediği, paylaştığı birikimi ve yönlendirmeleriyle çalışmama olan katkıları için Tez Danışmanım Sayın Doç. Dr. Gülgün Kayakutlu'ya en içten teşekkürlerimi sunarım.

Çalışmamın gelişimine olan katkılarından dolayı Sayın Prof. Dr. Sermin Onaygil ve Sayın Prof. Dr. Gülçin Büyükozkkan Feyzioğlu'na da teşekkürlerimi sunarım.

Gama Enerji'deki yöneticilerim ve çalışma arkadaşlarım ile gerek Matlab kullanımı konusundaki yardımları ve ayırdığı zamandan dolayı, gerekse görüşleriyle verdiği katkılardan dolayı arkadaşım Uğur Kurban'a çok teşekkür ederim.

Her zaman yanımda olan çok değerli sevgili aileme teşekkür ederim.

Eylül 2017

Aslıhan Özkan Dalgın
Elektrik Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
1. GİRİŞ.....	1
1.1 Tezin Amacı	2
1.2 Literatür Araştırması.....	2
2. TÜRKİYE ELEKTRİK PİYASASI	15
2.1 Gün Öncesi Piyasası Katılımcıları	16
2.2 Gün Öncesi Piyasası Teklif Süreci	17
2.3 Gün Öncesi Piyasası Fiyat Oluşumu	17
2.4 Gün Öncesi Piyasası Teklif Tipleri	18
2.4.1 Saatlik tekliflerin yapısı	18
2.4.2 Blok tekliflerin yapısı	19
2.4.3 Esnek tekliflerin yapısı	19
3. YAPAY SİNİR AĞLARI.....	21
3.1 Yapay Sinir Ağları ve Sinir Sistemi	21
3.2 Yapay Sinir Ağları Gelişimi.....	21
3.3 Yapay Sinir Ağlarının Genel Özellikleri.....	22
3.4 Yapay Sinir Ağı Modeli Yapısı.....	24
3.4.1 Aktivasyon (transfer) fonksiyonu türleri	25
3.4.2 Kavrama türleri	29

4. TÜRKİYE ELEKTRİK PİYASASI FİYAT TAHMİNİ UYGULAMASI.....	33
4.1 Uygulama Modeli Veri Grupları	34
4.2 Kullanılan YSA Özellikleri	39
4.3 Uygulama Aşamaları	41
4.4 YSA Modeli Tahmin Performans Faktörü	41
4.5 Gizli Katman Eniyilemesi İçin Denenen Seçenekler	42
4.5.1 Gizli katmanı 7 nöronlu YSA modeli sonuçları	43
4.5.2 Gizli katmanı 10 nöronlu YSA modeli sonuçları	45
4.5.3 Gizli katmanı 20 nöronlu YSA modeli sonuçları	47
4.5.4 Gizli katmanı 22 nöronlu YSA modeli sonuçları	49
4.5.5 Gizli katmanı 25 nöronlu YSA modeli sonuçları	51
4.5.6 Gizli katman eniyilemesi sonuçları.....	53
4.6 Girdi Setinin İyileştirme Çalışması	53
4.6.1 Gizli katmanı 7 nöronlu YSA modeli sonuçları	54
4.6.2 Gizli katmanı 10 nöronlu YSA modeli sonuçları	56
4.6.3 Gizli katmanı 20 nöronlu YSA modeli sonuçları	58
4.6.4 Gizli katmanı 22 nöronlu YSA modeli sonuçları	60
4.6.5 Gizli katmanı 25 nöronlu YSA modeli sonuçları	62
4.6.6 Girdi setini iyileştirme çalışması sonuçları.....	64
4.7 Gizli Katman ve Girdi Seti İyileştirmesi Sonuçlarının Karşılaştırılması	65
4.8 Tarihsel PTF'lerin YSA Modeline Etkileri	65
4.9 Optimum YSA Modelinin Eğitilmediği Günlerde Test Edilmesi	69
4.10 Ağırlıklandırma Değerlerinin Bulunması	74
4.11 Uygulama Çıkarımları ve Tartışmalar	81
5. SONUÇ VE ÖNERİLER	85
KAYNAKLAR.....	89
ÖZGEÇMİŞ	95

KISALTMALAR

APE	: Mutlak Yüzde Hata
AR	: Oto Regresif (Auto Regressive)
ARIMA	: Otoregresif Bütünlesik Hareketli Ortalama (Autoregressive Integrated Moving Average)
ARMA	: Otoregresif Hareketli Ortalama (Autoregressive Moving Average)
BOTAŞ	: Boru Hatları İle Petrol Taşıma Anonim Şirketi
CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Network)
ÇKA	: Çok Katmanlı Algılayıcı
DSM	: Talep Tarafı Yönetimi (Demand Side Management)
EPDK	: Enerji Piyasası Düzenleme Kurumu
EPEX	: Avrupa Enerji Borsası (European Power Exchange)
EPİAŞ	: Enerji Piyasaları İşletme Anonim Şirketi
EPSO	: Evrimsel Parçacık Sürü Optimizasyonu (Evolutionary Particle Swarm Optimization)
ESA	: Enerji Satış Anlaşmaları
EÜAŞ	: Elektrik Üretim Anonim Şirketi
EXIST	: Energy Exchange İstanbul (İstanbul Enerji Borsası)
FNN	: İleri Beslemeli Sinir Ağları (Feedforward Neural Network)
GARCH	: Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (Generalized Autoregressive Conditional Heteroscedasticity)
GÖP	: Gün Öncesi Piyasası
GP	: Gauss Süreci (Gaussian Process)
GRNN	: Genel Regresyonlu Sinir Ağları (General Regression Neural Networks)
HMM	: Hidden Markov Model (Saklı Markov Modeli)
LM	: Levenberg-Marquardt
MAPE	: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
OSB	: Organize Sanayi Bölgesi
Pİ	: Piyasa İşletmecisi
PTF	: Piyasa Takas Fiyatı
PYS	: Piyasa Yönetim Sistemi
RES	: Rüzgâr Enerji Santrali

RF	: Rastgele Orman (Random Forest)
RF	: Referans Fiyat
RNN	: Tekrarlayan Sinir Ağları (Recurrent Neural Network)
SCG	: Ölçeklenmiş Konjüge Gradyen (Scaled Conjugate Gradient)
SVR	: Destek Vektör Regresyon (Support Vector Regression)
TETAŞ	: Türkiye Elektrik Ticaret ve Taahhüt A.Ş.
TTY	: Talep Tarafı Yönetimi
YSA	: Yapay Sinir Ağları



SEMBOLLER

- B** : Bayram günlerine denk gelen gün tipi
- DG** : Bir gün öncesinin doğalgaz birim maliyeti
- GT** : Haftanın gün tipi; Pazartesi, Salı, Çarşamba, Perşembe, Cuma, Cumartesi, Pazar
- H_i** : Bir hafta öncesinin aynı saati için gerçekleşmiş PTF verisi
- i** : Saat sayısı
- NTM_i** : Bir gün öncesinin aynı saati için gerçekleşmiş net enerji talep miktarı
- P_i** : Bir gün öncesinin aynı saati için gerçekleşmiş PTF verisi
- R** : Ramazan ayına denk gelen gün tipi
- RM_i** : Bir gün öncesinin aynı saati için gerçekleşmiş rüzgar enerjisi üretim miktarı
- S_{girdi}** : Girdi seti; $[P_i, H_i, GT, R, B, TM_i, DG, S_i]$
- S_{girdi} *** : Girdi seti; $[P_i, H_i, GT, R, B, NTM_i, DG, S_i]$
- S_i** : Bir gün öncesinin aynı saati için gerçekleşmiş Türkiye geneli sıcaklık verisi
- TM_i** : Bir gün öncesinin aynı saati için gerçekleşmiş talep miktarı (ön işleme tabi tutulmuş şekilde)
- X_{gerçek}** : Gerçek PTF değeri
- X_{tahmin}** : Tahmin edilen PTF değeri



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 1.1: Literatür araştırması.	4
Çizelge 1.1 (devam): Literatür araştırması.	5
Çizelge 1.1 (devam): Literatür araştırması.	6
Çizelge 1.1 (devam): Literatür araştırması.	7
Çizelge 1.2 : Gün tipine göre yük kümelerinin kapsadığı saat periyotlar çizelgesi	8
Çizelge 2.1: Lisans türüne göre mevcut katılımcı sayısı	16
Çizelge 2.2 : Türkiye gün öncesi piyasası mevcut durumda uygulanan süreçler.....	17
Çizelge 3.1 : Biyolojik sinir ağları ile yapay sinir ağları arasındaki eşleştirme	21
Çizelge 4.1: 1 gün öncesine ait PTF'lere ilişkin örnek girdi seti kesiti	35
Çizelge 4.2: 7 gün öncesine ait PTF'lere ilişkin örnek girdi seti kesiti.....	36
Çizelge 4.3: Gün tiplerine ilişkin örnek girdi seti kesiti.....	36
Çizelge 4.4: Ramazan ayına ait gün tiplerine ilişkin örnek girdi seti kesiti.	37
Çizelge 4.5: Bayram gün tiplerine ilişkin örnek girdi seti kesiti.	37
Çizelge 4.6: Bir gün öncesi toplam talep miktarına ilişkin örnek girdi seti kesiti.....	38
Çizelge 4.7: Doğal gaz maliyetine ilişkin örnek girdi seti kesiti	38
Çizelge 4.8: Ülke geneli ortalama sıcaklık değerleri ilişkin örnek girdi seti kesiti... ..	39
Çizelge 4.9: 7 Nöronlu YSA modelinde günlük bazda fiyat tahmini performansı. ..	43
Çizelge 4.10: 10 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	45
Çizelge 4.11: 20 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	47
Çizelge 4.12: 22 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	49
Çizelge 4.13: 25 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	51
Çizelge 4.14 : 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde seçilen 15 günlük test veri grubunda ortalama MAPE değerleri.....	53
Çizelge 4.15: Bir gün öncesi net enerji talep miktarına ilişkin örnek girdi kesiti	54

Çizelge 4.16: NTM _i girdi verilerini içeren S _{girdi} * setinin kullanıldığı 7 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	56
Çizelge 4.17: NTM _i girdi verilerini içeren S _{girdi} * setinin kullanıldığı 10 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	58
Çizelge 4.18: NTM _i girdi verilerini içeren S _{girdi} * setinin kullanıldığı 20 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	60
Çizelge 4.19: NTM _i girdi verilerini içeren S _{girdi} * setinin kullanıldığı 22 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	62
Çizelge 4.20: NTM _i girdi verilerini içeren S _{girdi} * setinin kullanıldığı 25 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	64
Çizelge 4.21 : S _{girdi} * setinin kullanıldığı 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde seçilen 15 günlük test veri grubunda ortalama MAPE değerleri.	65
Çizelge 4.22: S ₁ setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	66
Çizelge 4.23: S ₃ setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	67
Çizelge 4.24: S ₄ setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	67
Çizelge 4.25: S ₅ setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.	68
Çizelge 4.26: 29 Kasım 2016 günü 24 saatlik bazda PTF tahmini performansı.	69
Çizelge 4.27: 29 Kasım 2016 günü 24 saatlik bazda PTF tahmini performansı.	70
Çizelge 4.28: 29 Mart 2017 günü 24 saatlik bazda PTF tahmini performansı.	71
Çizelge 4.29: 29 Haziran 2017 günü 24 saatlik bazda PTF tahmini performansı.	72
Çizelge 4.30: En iyi performansı gösteren YSA modelinde gizli katmandaki 20 nörona ilişkin sapma değerleri.	76
Çizelge 4.31: En iyi performansı gösteren YSA modelinde çıktı katmanındaki 24 saate ilişkin sapma değerleri.	77
Çizelge 4.32: 8 adet girdi değişkeni ile gizli katmandaki 20 nöron arasındaki bağlantıların girdi ağırlık matrisi.	77

Çizelge 4.33: DG girdisi girdi setinden çıkartıldığında seçilen YSA modeli 15 günlük performansı.....	78
Çizelge 4.34: Gizli katmandaki 20 nöron ile 24 saatlik çıktı değeri arasındaki bağlantının çıktı ağırlık matrisi.	79
Çizelge 4.35: Her saate ilişkin en büyük ağırlık değerinin ait olduğu nöron.	80
Çizelge 4.36: Saat bazında en büyük ağırlık değerinin yaratan her nörona ilişkin yüzdesel oran.	81





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Alış ve satış teklifleri ile arz-talep eğrisini oluşturulması	18
Şekil 3.1: Yapay sinir ağı modeli yapısı	25
Şekil 3.2 : YSA modelinde doğrusal transfer fonksiyonu	26
Şekil 3.3 : YSA modelinde basamak transfer fonksiyonu	27
Şekil 3.4 : YSA modelinde kutuplama değerli transfer fonksiyonu	27
Şekil 3.5 : YSA modelinde parçalı doğrusal transfer fonksiyonu	28
Şekil 3.6 : YSA modelinde sigmoid transfer fonksiyonu	28
Şekil 3.7 : YSA modelinde tanjant hiperbolik transfer fonksiyonu	29
Şekil 3.8 : YSA modelinde sinüs transfer fonksiyonu	29
Şekil 4.1: Elektrik fiyatı tahmin modellerinin sınıflandırılması	33
Şekil 4.2: YSA fiyat tahmini modelleri akış diyagramı.	41
Şekil 4.3: Uygulanan YSA modeli yapısı.....	42
Şekil 4.4: 7 Nöronlu YSA modelinde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	44
Şekil 4.5: 10 Nöronlu YSA modelinde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	46
Şekil 4.6: 20 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.....	48
Şekil 4.7: 22 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.....	50
Şekil 4.8: 25 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.....	52
Şekil 4.9: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 7 nöronlu YSA modelinde eğitimin son 15 gününde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	55
Şekil 4.10: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 10 nöronlu YSA modelinde eğitimin son 15 gününde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	57

Şekil 4.11: NTM _i girdi verilerini içeren S _{girdi*} setinin kullanıldığı 20 nöronlu YSA modelinde eğitimin son 15 gününde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	59
Şekil 4.12: NTM _i girdi verilerini içeren S _{girdi*} setinin kullanıldığı 22 nöronlu YSA modelinde eğitimin son 15 gününde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	61
Şekil 4.13: NTM _i girdi verilerini içeren S _{girdi*} setinin kullanıldığı 25 nöronlu YSA modelinde eğitimin son 15 gününde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.	63
Şekil 4.14: Gizli katman ve girdi seti iyileştirmesi sonuçlarının karşılaştırılması. ...	65
Şekil 4.15: Gizli katman ve girdi seti iyileştirmesi sonuçlarının karşılaştırılması. ...	68
Şekil 4.16: 29 Kasım 2016 günü saatlik performans sonuçlarının karşılaştırılması..	70
Şekil 4.17: 29 Aralık 2016 günü saatlik performans sonuçlarının karşılaştırılması..	71
Şekil 4.18: 29 Mart 2017 günü saatlik performans sonuçlarının karşılaştırılması. ...	72
Şekil 4.19: 29 Haziran 2017 günü saatlik performans sonuçlarının karşılaştırılması	73
Şekil 4.20: 4 farklı günde YSA modeli tahmin sonuçlarının karşılaştırılması.	73
Şekil 4.21: YSA çalışma modelinde ağırlıkların ayarlanması	74
Şekil 4.22: İleri beslemeli YSA modeli katmanlar arası ağırlıklar.	75
Şekil 4.23: Önerilen 20 nöronlu YSA modelinin katmanlar arası ağırlıkların yapısı	75

YAPAY SİNİR AĞLARI KULLANILARAK TÜRKİYE ELEKTRİK PIYASASI GÜN ÖNCESİ FİYAT TAHMİNİ

ÖZET

Dünya genelinde ülke ekonomilerine olan ciddi etkileri dikkate alındığında uygun enerji politikaları ile enerji sektörünün planlı gelişmesinin önemi bilinmektedir.

2001 yılında yürürlüğe giren 4628 sayılı Elektrik Piyasası Kanunu ile hız kazanmaya başlayan Türkiye Elektrik Piyasası serbestleşme süreci, 2013 yılında yürürlüğe giren 6446 sayılı Elektrik Piyasası Kanunu kapsamında devam etmektedir. 6446 sayılı Kanununun amacı “elektriğin yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde tüketicilerin kullanımına sunulması için, rekabet ortamında özel hukuk hükümlerine göre faaliyet gösteren, mali açıdan güçlü, istikrarlı ve şeffaf bir elektrik enerjisi piyasasının oluşturulması ve bu piyasada bağımsız bir düzenleme ve denetimin yapılmasının sağlanması” olarak ifade edilmiştir [25].

Türkiye Elektrik Piyasası kamu santrallerinin baskın olduğu durumdan günümüze kadar gerek arz ve talep bileşenleri açısından, gerekse regülasyonlar ve modelleme açısından piyasa çeşitli dönüşüm süreçlerinden geçmiştir. Tüm bu süreçlerde Elektrik Piyasasında saatlik oluşarak enerjiyi fiyatlayan rakamlar sektördeki paydaşların ve yatırımcıların yakından takip ettiği ve çeşitli yöntemlerle tahmin etmeye çalıştığı en belirleyici gösterge niteliği taşımaktadır.

Çalışmada veri olarak kullanılan geçmiş tarihli fiyatlar piyasa işletme görevini yürüten Enerji Piyasaları İşletme Anonim Şirketi (EPIAŞ) tarafından şeffaflık platformunda kamuya açık bir şekilde paylaşılmakta olan Piyasa Takas Fiyatları (PTF)’dir. Piyasadaki saatlik elektrik arzı ve talebinin takası sonucu oluşan Piyasa Takas Fiyatları (PTF) elektriğin diğer ticari platformlardaki işlemleri için referans unsuru olduğu için literatürde de Referans Fiyat kavramına karşılık gelmektedir.

Bu tez çalışması kapsamında tek gizli katmanında farklı nöron sayıları içeren Levenberg-Marquardt geriye yayımlı öğrenen Yapay Sinir Ağları algoritması kullanılarak, Türkiye Elektrik Piyasası kısa dönemli Referans Fiyat tahmini çalışması gerçekleştirilmiştir. Türkiye’de bir çok fiyat tahmini çalışması yapılmıştır ancak, bu çalışmada modelde ele alınan girdilerin etkileri ve hangi girdiler ele alındığında en yakın sonuçların elde edildiği çalışılmıştır. Girdiler, farklı zamana bağlı fiyat serileri kadar, yerel pazarın özelliklerini de taşımak zorundadır.

Türkiye elektrik piyasasında mevcut ve olası elektrik piyasası aktörlerinin faydalanabilecekleri düşünülerek yapılan bu tez çalışmasında, zamanın koşullarına göre iyileştirilen/geliştirilen YSA modelleri ile gerçekleştirilecek PTF’lere sinyal verecek düzeyde tahminler yapılabileceği gösterilmektedir.



TURKISH DAY AHEAD MARKET ELECTRICITY CLEARING PRICE FORECASTING USING ARTIFICIAL NEURAL NETWORK

SUMMARY

Electricity is a different type of commodity regarding that it cannot be stored in considerable quantities yet. Thus bringing supply together with the needed demand in a grid environment is the main system requirement. Supply side consisting of energy generation companies, show better results in a deregulated market structure.

Liberalization of the energy markets has started during the end of eighties however, it is still an ongoing process in some countries like Turkey. Turkish Electricity Market started its liberalization process in 2001 by the Law no. 4628 and continues the process under the Law no. 6446 released in 2013.

The main mission of deregulation is to enable the generation activities more effective and minimize electricity costs. With the less regulated energy market structure, the market becomes more competitive. In a day-ahead market, participants submit their bids for selling and buying electricity for the next 24 hours and market is cleared at the prices where demand meets supply for every single hour ahead for 24 hours. The clearing prices achieved for the day-ahead market are accepted as reference prices and gives valuation signals for the upcoming decisions through the other trading mediums such as intra-day, futures and forward markets.

It is a known fact that in a more competitive market environment price forecasting has become a critical factor for the decision-makers amongst the market participants. Market participants have to forecast day-ahead prices to decide on their bidding strategies in the right way in order to maximize their profits in the spot markets. Trading companies also require price forecasts in different time horizons in order to negotiate and trade bilateral contracts. Risk managers need price forecasts to assess market risks and decide on hedging strategies timely. Investors require long term price forecasts to take feasible decisions of investing in energy sector. Therefore, well-performing forecast configurations for day-ahead electricity prices have a great importance from all perspectives and matter that much for electricity market participants of all kind.

By focusing on this issue, this study is designed with the motivation of generating the most performant ANN model serving for day-ahead electricity price forecasting for the Turkish power market. Non-linearity and high volatility features of the electricity prices make forecasting a very complex task.

In recent years, artificial intelligent methods are mostly used for price forecasting instead of traditional price forecasting methods. Among modern techniques such as

ANN and Fuzzy logic, ANN method is a powerful tool for forecasting. The reason is that following a training process with an optimum input set, ANN method is capable of learning complicated input-output relationships.

The performance of an ANN model is extensively based on the selected input set. Therefore the goal of input selection in this study is to configure an optimum set of inputs. Putting optimal inputs would result a smaller ANN model. Thus, the network would have a higher convergence speed.

There are too many factors that have an impact on electricity prices. Some of those factors such as the strategical bidding/offering behaviors of the buyers/sellers are unknown and unpredictable parameters. Besides those unknown parameters, there are other parameters which are affecting the electricity prices in some extent. Some of those factors have a greater role than the others. To be more practical, only those factors which are relatively more significant are considered in this study.

At first the historic prices are selected to involve in the input set. Historic prices gives an effective insight to the model for future predictions. Previous day's realized market prices and realized market prices seven day ago at the same day type are the historic prices included in the input data set.

It is a known fact that electricity prices are affected by electricity demand amount which is also defined as system load. Electricity demand is depended on the weather conditions such as temperature and the extent of both industrial and commercial business operations. Generation from renewable energies especially wind energy resources in Turkish case, are compensating the demand amount in the grid. Thus, while preparing the demand inputs for the model, the residual demand after the wind energy generation amount is deducted is considered.

Parameters which are related to the price forecasting can be categorized into day type. One of the day type parameters is the day of the week. Thus the model could also distinguish the weekdays from weekends. The other day type parameter is the indicator if the day is in the Ramadan month or not. The demand profile in Ramadan month differs from regular days. The other day type parameter is the indicator if the day is in the Eid period or not. The demand decreases in Eid days compared to the regular days.

Since conventional energy resources have a cost-based selling strategy, the cost of the resource is directly affecting the electricity prices. For this reason, another input parameter is selected as the cost of natural gas. When the demand rises up, the market price is cleared with the offered prices of natural gas based generation power plants. Thus the cost based offer prices constitute the marginal prices in the merit order according to the efficiency of the power plant technology. In the natural gas price input set there exists a %10 discount for natural gas price starting from 1st October 2016. Hence the network is trained by taking the discount into consideration.

Another parameter is selected as hourly temperature meterings. In cases when the temperature rises and falls in other words out of the mild season, electricity demand increases correspondingly. Therefore the electricity prices rise consequently. For teaching the correlation between temperature and prices, temperature meterings are included into the input set.

The input set initial date is starting from 1st June 2016. The reason behind is the displacement of the algorithm stating electricity prices at that date. For eliminating algorithm effect, the network is not trained with the inputs before 1st June 2016. Since June 2016 this optimization model originating by local developers is being used in day-ahead market operated by Energy Exchange Istanbul (EXIST).

The ANN model is constructed as a single hidden layer model that has nonlinear log-sigmoid (logsig) transfer function. The selected training function for the studied ANN model is Levenberg-Marquard back propagation which is faster compared to conventional back propagation methods. That function updates weights and bias values. Throughout training, the weights and biases of the model are calibrated due to minimise the network performance function.

In order to maximize the performance of the model, the hidden layer is tested with five different neuron cases; which have 7, 10, 20, 22 and 25 neurons. The time series of prices are tested for different time lags. Furthermore, local electricity market influencers are altered as to taking the total demand or net wind effect. Best performance result with 7.9% of MAPE is achieved when the ANN model has 20 neurons in its hidden layer with the most performant input set indicated as:

- Price from the same hour of the previous day
- Price from the same hour and same day of the previous week
- Day of the week (1-7)
- Day of the Ramadan month indicator (0 or 1)
- Day of the Eid-holiday indicator (0 or 1)
- Dry bulb temperature
- Natural gas price
- Net system load which is defined by considering wind generation effect on total energy demand

It is noted that the wind energy generation in the input set decreased the MAPE by 1.01%. Whereas, time lags for 14, 21 and 28 days had negative effects on prediction.

Besides, if the time series of historic prices is extended more, i.e., including prices of 14, 21 and 28 days ahead prices to the input set respectively, it is noted that the forecast performance is effected negatively with increasing MAPE indicators.

Additionally, weight and bias matrices between the input layer and the hidden layer, as well as the weights between the hidden layer and output layer are investigated in

this study. It is noted that the most influential input parameters are day type indicators consisting of Eid-holiday, Ramadan and day of the week. Moreover, natural gas cost is also a notable influencer due to the input weights.

There are quite a few studies on electricity price forecasting in Turkey. However, this study will be supporting the forecasting people in combining the time series of prices and other local market influencers as input. The proposed model is designed to perform better by ranking the input weights and changing the hidden layer design.



1. GİRİŞ

Bilgi toplumuna geiş ile birlikte makine ğrenmesine dayalı teknolojilerin gelişimi hızlanmıştır. 1950’li yıllarda yapay zekanın öncüleri olarak kullanılan Yapay Sinir Ağları (YSA) matematiksel olarak formüle edilemeyen kompleks problemlerin bilgisayarlar aracılığıyla sezgisel olarak özümüne yardımcı olmuştur. 1980’li yıllardan itibaren ok katmanlı yapay sinir ağları tanımı daha geniş kullanım alanı yaratmış ve günümüzün tercih edilen tahmin aracı olmasını sağlamıştır.

Sekiz yıl süren müzakerelerden sonra 1996’da Avrupa Birliği’nde elektrik piyasasını liberalleşmesi için karar alınmasının ardından Avrupa lkelerinde elektrik borsaları kurulmaya başlamıştır. Elektrik piyasalarının serbestleşmesinin temel amacı elektrik üretiminin ve tüketiminin verimli yapılması ile elektrik fiyatlarının düşmesini sağlamaktır.

Son 20 yılda diğerk pek ok lkede olduğı gibi Türkiye Elektrik Piyasası da özelleşme, serbestleşme ve dikey ayrıştırılma süreçlerinden geçmektedir. Bunun sonucunda piyasa giderek daha rekabet yoğun bir konuma gelmiştir. Rekabetin artması ile birlikte piyasa dinamiklerini doğru modelleyip, analiz etmek ve en az hata ile tahmin etmek fark yaratmaktadır.

Bunun yanı sıra özellikle orta ve uzun dönemde piyasada oluşacak fiyatlara maruz kalmanın getireceğı fiyat risklerinin ölçülerek risk yönetimi yapılması aşamasında da yine iyi tahminlere ihtiyaç duyulmaktadır.

Elektrik büyük hacimlerlerde depolanması mümkün olmayan bir emtia olduğı için diğerk emitalardan ayrılmaktadır. Bu doğrultuda elektrik fiyatının kısa dönemli tahmini, özellikle de bir gün sonrasına ilişkin fiyatı doğru tahmin etmek rekabetçi piyasa koşullarında büyük avantaj sağlamaktadır. Gerek üretim, gerek tüketim, gerekse ticaret amacıyla piyasaya katılan tüm oyuncuların ekonomik optimizasyon stratejileri geliştirerek karlarını en oklanması için oluşacak fiyatları en az hata ile tahmin etmeye alışmaları gerekmektedir. Enerji piyasası dinamiklerinin değışkenliğı nedeniyle fiyat tahmini modellerinin güncel duruma adapte edilmesi de gerekecektir.

Bu çalışmanın bölümlerinin içerikleri şu şekildedir:

Birinci bölümde; tezin amacı, gün öncesi piyasası fiyat tahmininin piyasa katılımcıları açısından öneminin oluşturduğu motivasyon nedeniyle konu olarak ele alındığından bahsedilmiştir. Literatür araştırmaları da yine bu bölümde incelenmiştir.

İkinci bölümde, mevcut Türkiye gün öncesi piyasası yapısı, teklif yapısı ve bileşenlerine değinilmiştir.

Üçüncü bölümde, YSA modellemesi hakkında açıklayıcı bilgilendirmelerde bulunulmuştur.

Dördüncü bölümde, Türkiye gün öncesi piyasası fiyat tahmini için en iyi sonuçları veren YSA modeli oluşturulmaya çalışılmıştır. Bu amaçla girdi setinde ve nöron sayılarında yapılan testlere göre modelin performansının artırılması hedeflenmiştir.

Son bölüm ise sonuçların ve önerilerin paylaşılmasına ayrılmıştır.

1.1 Tezin Amacı

Serbestleşen diğer elektrik piyasalarında olduğu gibi Türkiye Elektrik Piyasası'ndaki mevcut piyasa katılımcılarının gün geçtikçe artmakta olan rekabet koşullarında optimum işlemler gerçekleştirerek fayda maksimizasyonu yapmaları ve sürdürülebilir işletmeler olmaları için en önemli gereksinimlerinin performansı yüksek fiyat tahmini araçlarının kullanılmasıdır. Bu tez çalışmasında yerel piyasayı en fazla etkileyen girdi değişkenleri bulunarak, en az hata oranlarına sahip kısa dönemli saatlik referans fiyat tahmini yapabilen bir YSA modeli konfigürasyonu yapılması amaçlanmıştır.

1.2 Literatür Araştırması

YSA, makine öğrenmesi çerçevesinde geliştirilen yapay zekanın bir alt birimidir. Bilgisayarların öğrenmesini sağlayan YSA teknolojisinde özellikle 1990'lı yıllardan itibaren ivmelenen bir gelişme süreci görülmüştür. Kısa zamanda araştırmacıların dikkatini çeken bu teknoloji laboratuvarlardan çıkarak günlük hayatın ihtiyaçlarını karşılayacak uygulamalarda kullanılmaya başlanılmıştır. Endüstriyel sistemler, tıp bilimi, askeri sistemler gibi pek çok sektörde kullanılmasının yanı sıra finansal hayatta da kullanım alanı bulmuştur.

Son 20 yılda elektrik piyasalarının serbestleşme süreçlerinden geçmesiyle birlikte rekabetçi ortamda oyuncuların ekonomik optimizasyon yaparak en çok fayda elde etmeyi hedeflemeleri sonucunda spot piyasa fiyatının tahmini büyük önem kazanmıştır. Bunun etkisiyle 2000'lerin başlarından itibaren YSA modelleri kullanılarak fiyat tahminleri yapılması ve çeşitli ülkelerin spot piyasa fiyatları ile modelin test edilmesi akademik çalışmalara konu olmaktadır.

Literatür taramasında bu zamana kadar makine öğrenmesine dayalı kısa vadeli elektrik fiyat tahmin modellerini inceleyen 2006-2016 yılları arasında yayınlanmış çalışmalar incelenmiş ve aşağıdaki Çizelge 1.1'de sunulmuştur.

Fan ve diğ. çalışmalarında iki makine öğrenmesi teknolojisini birleştirerek model oluşturmuşlardır: Dinamik Bayesyen Kümeleme (Bayesian Clustering by Dynamics) ve Destek Vektör Makinası (Support Vector Machine). Modeldeki Bayesyen kümeler, fiyatın durumuna göre öğreticisiz şekilde kendiliğinden çeşitli gruplar yaratmaktadır. Model İngiltere piyasa fiyatları ile eğitilip test edilmiş ve yüksek derecede verimli çalıştığı görülmüştür [1].

Ranjbar ve diğ., iki ara katmanlı YSA modelini, geleneksel geri yayılma metodu yerine Levenberg-Marquardt (LM) geri yayılma metodu ile eğiterek daha hızlı çözmüşlerdir. (LM) geri yayılma metodu ile YSA eğitiminde ağ elemanlarının bağlantılarının ağırlık değerlerinin LM optimizasyonuna göre güncellenmesi sağlanmıştır. Tek ara katmana kıyasla iki adet ara katmanla daha iyi performans alındığı gözlenmiştir. Ayrıca bu çalışmada, diğer fiyatlara göre çok yüksek olan girdi fiyatlarının elimine edilmesi için iki yöntemden bahsedilmiştir. Bunlardan biri bu fiyatları veri setinden hariç tutmak, diğeri ise bu fiyatların yerine kullanılacak bir fiyat tavanı belirlemektir. İlgili çalışmada 200\$/MWh tavan fiyat olarak kabul edilerek, girdi seti ön işleme tabi tutulmuştur. Ön işleme tabi tutularak bulunan tahmini fiyat ardından tekrar son bir işleme daha tutularak son haline getirilmektedir. Veri setinin bu iki aşamalı eşik ayarlama fonksiyonlarından geçirilmesiyle aşırı yüksek fiyatların model sonuçlarını bozması engellenmektedir [2].

Li ve diğ. makalesinde akıllı sistem olarak bulanık mantık sistemi ve regresyon modeli olarak en küçük kareler kestirimi kullanılarak fiyat tahmini yapılmıştır. Sonuçlar sinir ağlarına ve ARMA ve GARCH zaman serilerine göre daha iyi gerçekleşmiştir [3].

Çizelge 1.1: Literatür araştırması.

No	Yıl	Yazarlar	Kaynak	Amaç	Kullanılan yöntem	Sonuç ve katkısı
[1]	2006	Fan, S., Liao, J. R., Kaneko, K., Chen, L.	An integrated machine learning model for day-ahead electricity price forecasting	İki makine öğrenmesi teknolojisini birleştiren bir model oluşturmak	Dinamik Bayesyan Sınıflandırma ve Destek Vektör Regresyon	Modeldeki Dinamik Bayesyan sınıflandırıcısı fiyatın durumuna göre öğreticisiz şekilde kendiliğinden çeşitli kümelendirmeler yaparak verimli çalıştığı görülmüştür.
[2]	2006	Ranjbar, M., Soleymani, S., Sadati, N., & Ranjbar, A. M.	Electricity price forecasting using artificial neural network	Konvansiyonel BP methodu yerine Levenberg-Marquardt BP ile daha hızlı sonuç almak	Yapay Sinir Ağları	Tahminlerdeki ani yükselişlerin elimine edilmesi için bir ön işleme tabi tutularak kırılması ve daha sonra tekrar işleme tabi tutularak düzeltilmesiyle daha hassas sonuçlar elde edilmiştir.
[3]	2007	Li, G., Liu, C. C., Mattson, C., Lawarree, J.	Day-ahead electricity price forecasting in a grid environment	Bulanık mantık ve regresyon modeli olarak en küçük kareler kestirimiyle tahmini yapmak	Bulanık Mantık Sistemi	Sonuçlar sinir ağlar ve ARMA ve GARCH zaman serilerine göre daha iyi gerçekleşmiştir.
[4]	2008	Cui, H., & Song, X.	Research on electricity price forecasting based on chaos theory	Elektirik fiyatının kaotik karakteristiğinin Lyapunov katsayısı ile tanımlanması	Kaos Teorisi	Elektirik fiyatlarındaki küçük değişikliklerin zaman ilerledikçe üstel bir etkiyle değişeceği görülmüştür. Dolayısıyla tahminler, fiyatların başlangıç değerlerine LM algoritması ile eğitilen YSA sonuçları; dinamik regresyon (DR), ARIMA ve dalgacık modeli ile ARIMA karma modelleri ile karşılaştırılmıştır.
[5]	2008	Vahidinasab, V., Jadid, S., Kazemi, A.	Day-ahead price forecasting in restructured power systems using artificial neural networks	Bulanık c-kümeleme algoritması ile YSA'da daha iyi sonuç almak	YSA, dinamik regresyon, ARIMA ve dalgacık modeli	YSA modelinin geleneksel ARIMA modeline göre daha doğru sonuçlar çıkarmıştır.
[6]	2008	Zhang J., & Cheng C.	Day-ahead electricity price forecasting using artificial intelligence	YSA modeli ile geleneksel ARIMA modelini karşılaştırmak	Yapay Sinir Ağları ve ARIMA	Sonraki günün fiyat tahmini için 3-n-1 modeli, 72-n-24 modeline göre daha iyi performans göstermektedir.
[7]	2009	Tang Q., & Gu D.	Day-ahead electricity prices forecasting using artificial neural networks	Farklı modeller ve methodlarla analiz ederek tahmini için en uygun mimariyi elde etmek	Yapay Sinir Ağları	

Çizelge 1.1 (devam): Literatür araştırması.

No	Yıl	Yazarlar	Kaynak	Amaç	Kullanılan yöntem	Sonuç ve katkısı
[8]	2010	Yan, X., Chowdhury, N. A.	Electricity market clearing price forecasting in a deregulated electricity market	Puant tahmini ile orta vadeli fiyat tahmini yapmak için iki adet YSA modellenmesi	Yapay Sinir Ağları	Talebin yüksek olduğu puant saatlerde tahmin performansının düştüğü görülmüştür.
[9]	2011	Singhal, D. & Swarup, K. S.	Electricity price forecasting using artificial neural networks	Gün tipine göre az hata ile tahmin yapabilen bir model oluşturmak	Yapay Sinir Ağları	İki ara katmanlı bir YSA modeliyle hafta içi günlerde %16'dan az, hafta sonu günlerde ise %20'den az hata ile tahmin yapabilen bir model oluşturulmuştur.
[10]	2012	Özgüner, E.	Short term electricity price forecasting in turkish electricity market	Gün öncesi fiyatı ve sistem marjinal fiyatlarının tahminlemek	Çoklu Doğrusal Regresyon ve Yapay Sinir Ağları	Kış mevsiminde seçilen hafta için %6,13, Bahar mevsiminde seçilen hafta için %5,96 ve Yaz mevsiminde seçilen hafta için %7,97 ortalama MAPE değerlerine ulaşılmıştır.
[11]	2013	Anbazhagan, S., & Kumarappan, N.	Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT	Ayrık kosinüs dönüşümü ile fiyat serilerini değiştirmeyen sinyallere dönüştürme işlemiyle öğrenme verimini arttırmak	Yapay Sinir Ağları	Ayrık kosinüs dönüşümü ile FNN modeli, hibrit modellerden daha hassas sonuçlar vermemele birlikte, hibrit modellere göre daha kısa sürede tahmin yapılabilmektedir.
[12]	2013	Geidel C., & Zareipour H.	Price forecasting in the spanish day-ahead electricity market using preconditioned wind power information	Önceden tanımlanmış durumlardaki rüzgar gücü tahminleri kullanılarak daha iyi fiyat tahmini yapmak	Hibrit iki SVM Regresyon Modeli	Rüzgarın fiyat düşürücü etkisi özellikle öğle saatlerinde etkisini göstermektedir.
[13]	2013	Kölmek, M.A. & Navruz, İ.	Forecasting the day-ahead price in electricity balancing and settlement market of Turkey by using artificial neural networks	Gün öncesi fiyatı tahmininde YSA modeli uygulamasına öncülük edip, YSA modeli ile ARIMA modelinin performanslarını karşılaştırmak	Yapay Sinir Ağları, ARIMA	YSA ile yapılan haftalık tahminlerde %14,15 MAPE değerine ulaşıırken, ARIMA modeli ile yapılan tahminlerde %15,60 MAPE değerine ulaşılmıştır. YSA ile yapılan tahminlerin daha yüksek performans gösterdiği sonucuna ulaşılmıştır.

Çizelge 1.1 (devam): Literatür araştırması.

No	Yıl	Yazarlar	Kaynak	Amaç	Kullanılan yöntem	Sonuç ve katkısı
[14]	2014	Sahay, K. B., & Tripathi, M. M.	An analysis of short-term price forecasting of power market by using ANN	Fiyat oynaklığının yüksek olduğu piyasada YSA ile kısa vadeli fiyat tahmini yapmak	Yapay Sinir Ağları	Fiyat oynaklığının yüksek olduğunda bile hassas tahminler alınmıştır. Sonuçlar talebin fiyatı etkileyen en önemli faktörlerden olduğunu göstermiştir.
[15]	2014	Weron, R.	Electricity price forecasting: A review of the state-of-the-art with a look into the future	Fiyat tahmininde kullanılan modellerin güçlü ve zayıf taraflarını karşılaştırmak	Bilgisayar Zekasına dayanan modeller ve diğer modeller	Son 15 yılda yapılan çalışmalar ışığında elektrik tahmininde kullanılan modellerin karşılaştırılması yapılmıştır.
[16]	2015	Bicil, İ. M.	Elektirik piyasasında fiyatlandırma ve Türkiye elektrik piyasasında fiyat tahmini	Fiyat tahmininde ARMA ile YSA modellerinin performanslarını karşılaştırmak	Yapay Sinir Ağları, ARMA	%8,2 MAPE ile sigmoid aktivasyon fonksiyonu ve LM algoritmasıyla eğitilen YSA'nın ARMA modeline göre daha iyi performans sağladığı görülmüştür.
[17]	2015	Yıldız, S.	Türkiye elektrik piyasası kısa dönemli referans fiyat tahmini	Piyasadaki mevsimsel etkileri gözleterek kısa vadeli referans fiyat tahmini yapmak	Yapay Sinir Ağları	Ocak 2012-Temmuz 2014 dönem aralığının eğitim ve test veri seti olarak kullanıldığı çalışmada, yaz ve kış döneminde ayrı ayrı performans ölçülmüştür.
[18]	2016	Keles, D., Scelle, J., Parascviv, F., Fichtner, W.	Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks	Çeşitli algoritmaları kümeleyerek ve optimum girdi değişkenleriyle performanslı ağ konfigürasyonu oluşturmak	Yapay Sinir Ağları, ARIMA	Gereksiz girdi kullanılmaması YSA'yı geliştireceği görülmüştür. Kısa dönemli fiyat tahmininde YSA modeli, mevsimsel ARIMA zaman serileri modelinden daha iyi performans göstermektedir.
[19]	2016	Kotur, D., & Žarković, M.	Neural network models for electricity prices and loads short and long-term prediction	Yenilenebilir kaynakların olduğu piyasada talep ve fiyat tahmini yapmak	ARFIMA ve Yapay Sinir Ağları hibrit modeli	Yenilenebilir kaynakların sürekli olmayan doğası nedeniyle verilerin düzenlenmesi tahminleri iyileştirmektedir.

Cizelge 1.1 (devam): Literatür araştırması.

No	Yıl	Yazarlar	Kaynak	Amaç	Kullanılan yöntem	Sonuç ve katkısı
[20]	2016	Lahouar, A., Slama, J. B. H.	Comparative study of learning machine predictors for half-hour and day-ahead electricity price forecast in deregulated markets	Üç tahmin modeli aynı değişkenler kullanılarak birbirleriyle karşılaştırmak	YSA, SVR ve RF	Avustralya piyasasında yarım saat öncesi fiyat tahmini için YSA daha iyi sonuç verirken, gün öncesi fiyat tahmini için RF'in özellikle aşırı artan fiyatlarda daha iyi sonuç verdiği görülmüştür.
[21]	2016	Moreira, R., Bessa, R., Gama, J.	Probabilistic forecasting of day-ahead electricity prices for the Iberian electricity market	Piyasa fiyatlarını regresyon tekniğine dayalı modelde, %5'er adımlarla %95'e kadar olasılıklı olarak tahmin etmek	Yüzdesel Regresyon	Piyasa fiyatlarını olasılıklı olarak tahmin etmek için regresyon tekniğine dayalı model makul sonuçlar vermektedir.
[22]	2016	Moria, H., Nakanob, K.	An efficient hybrid intelligent method for electricity price forecasting	Bulanık c-kümelenen girdilerin EPSO ile daha iyi bağlantılar kurarak GP'nin eğitilmesi	GP, EPSO, fuzzy c-means kullanılarak oluşturulan hibrit	Kullanılan hibrit model ile çok katmanlı YSA ve konvansiyonel GP'ye göre daha iyi sonuçlar elde edilmiştir.
[23]	2016	Nargale, K. K., Patil, S. B.	Day ahead price forecasting in deregulated electricity market using artificial neural network	Fiyat oynaklığının düşük olduğu dönemde Hindistan piyasasında YSA ile kısa vadeli fiyat tahmini yapmak	Yapay Sinir Ağları	Fiyatların fazla dalgalanma göstermediği 2008-2010 arası Hindistan piyasasında model tatmin edici sonuçlar vermiştir. SVM modeli kullanılarak sonuçların geliştirilebileceği belirtilmiştir.
[24]	2016	Özözen, A., Kayakutlu, G., Ketterer, M., Kayalca, Ö.	A combined seasonal ARIMA and ANN model for improved results in electricity spot price forecasting: Case study in Turkey	Fiyatın doğrusal trendi SARIMA ile tahmin ederken, geriye kalan doğrusal olmayan kısmın YSA ile tahmin edilerek tahmin performansını arttırmak	SARIMA ve Yapay Sinir Ağları Hibrit Modeli	Eğitilen hibrit modelin %4,08 MAPE ile performans sağladığı görülmüştür. Hibrit model kullanılarak ileri tarihlerdeki 5 günlük fiyat tahminleri test edildiğinde %10,2 MAPE ile performans elde edilmiştir.

Cui ve Song (2008) makalelerinde kaos teorisi ile fiyat tahmini modellemişlerdir. Fiyatları zaman serileri olarak ele almışlardır. Kaos sistemi, sistemin başlangıçta sahip olduğu değerlere oldukça bağlıdır. Kaos belirlilik ve rassallık arasında gittiğinden uzun vadede belirsizlik hakim olacaktır. Bununla birlikte, kısa vadede Lyapunov katsayısı ile fiyatların kaotik yapısını tanımlamışlardır. Katsayının küçük olması durumunda kısa vadeli tahminler için kullanılabileceği belirtilmektedir [4].

Vahidinasab ve diğ. çalışmasında duyarlılık analizi ile YSA'nın optimum girdileri seçilmiş ve bulanık c-kümeleme algoritması ile çeşitli kümelemeler yapılarak Amerika Birleşik Devletleri'nin Pennsylvania–New Jersey–Maryland (PJM) piyasasında tahmin yapılmıştır. Yük dağılımına göre günler üç kümeye ayrılmıştır: puant, orta-puant (normal), puant dışı. Gün tipine göre ikinci bir kümeleme daha uygulanmıştır: hafta içi, cumartesi, pazar. Ayrıca gün tipine göre yük dağılımı değiştiğinden bu kümelerin saatleri de Çizelge 1.2'de verildiği gibi değiştirilmektedir. LM algoritması ile eğitilen YSA sonuçları; na'ive (NA'IVE), dinamik regresyon (DR), transfer fonksiyonu (TF), ARIMA ve literatürde “wavelet modeli (WL)” ismiyle anılan dalgacık modeli ile ARIMA karma modelleri ile karşılaştırılmıştır. YSA sonuçlarının yanı sıra bazı durumlarda NA'IVE tekniğinin de iyi sonuç verdiği görülmüştür [5].

Çizelge 1.2 : Gün tipine göre yük kümelerinin kapsadığı saat periyotlar çizelgesi [5].

Gün Tipi	Puant	Normal	Puant Dışı
Hafta İçi	8-22	7, 23, 24	1-6
Cumartesi	10-22	8, 9, 23, 24	1-7
Pazar	10-23	1, 9, 24	2-8

Zhang ve Cheng'in çalışmasında çok katmanlı YSA modeli kurularak dünyanın en başarılı elektrik piyasalarından olan Nord Pool spot piyasasında fiyat tahmini yapılmıştır. Deneme-yanılma yöntemi ile hatayı minimize eden en uygun ağ yapısı belirlenmiştir. Ağın eğitilme sürecinin daha verimli olması için modelde kullanılan geriye yayılma algoritmasının, adaptif öğrenme hızı ve adaptif momentum katsayısı algoritmasıyla geliştirilmesi sağlanmıştır. Çalışmanın sonucunda YSA modelinde geleneksel ARIMA modeline göre daha doğru tahminler elde edilmiştir [6].

Tang ve Gu'nun çalışmasında doğrusal olmayan, oldukça karmaşık yapıdaki spot piyasa RF tahmini yapmak için yeterli veri ile eğitilmiş YSA modelinin etkili olduğu gösterilmektedir. Değişik girdi setleri ve değişik eğitim metotlarının etkileri ölçülerek

optimum YSA modeli belirlenmiştir. Aynı girdi değerlerini farklı mimarilerle kullanmak farklı sonuçlar doğurmaktadır. Geleneksel zaman serileri modellerine dayanan ARIMA, AR ve GARCH metotları doğrusal teknikler olduklarından doğrusal olmayan nitelikteki RF tahmini için yetersiz kalmaktadır. Bu nedenle üç katmanlı ağın RF tahminine uygun olduğu ifade edilmiştir. Uygun eğitim metodunu belirleme aşamasında geriye yayılma algoritmasının çok yavaş olmasından ötürü Levenberg-Marquardt (LM) ve scaled conjugate gradient (SCG) algoritmaları önerilmektedir. Ayrıca ara katmandaki nöron sayısı da sonucu etkilediğinden optimum sonuca ulaşmak için nöron sayısı da dikkate alınmalıdır. Çalışmanın sonucunda birer saatlik girdilerin kullanıldığı 3 - n - 1 ağ mimarisinin, 24 saatlik girdilerin kullanıldığı 72 - n - 24 mimarisinden daha iyi tahmin çıkardığı görülmüştür. Bunun yanı sıra 3 - n - 1 ağ mimarisinde ara katmanda yaklaşık 20 adet nöron bulunduğu en az hatalı sonuç elde edildiği görülmüştür [7].

Yan, X., Chowdhury, N. A. makalesinde günlük puant zamanda fiyat tahmini ile orta vadeli saatlik fiyat tahmini yapmak amacıyla iki adet YSA modellenmesi kurulmuştur. Çalışmada talebin yüksek olduğu puant saatlerde tahmin performansının düştüğü görülmüştür [8].

Singhal ve Swarup çalışmasında iki ara katmanlı bir YSA modeli kullanılarak hafta içi günlerde %16'dan az, hafta sonu günlerde ise %20'den az hata ile tahmin yapabilen bir model oluşturulmuştur. Ara katmanlardan ilki 10 nöron ve tansig transfer fonksiyonuna, ikincisinin ise 5 nöron ve tansig transfer fonksiyonu sahiptir. Modeli iyileştirmek için YSA'nın bulanık mantık ve dinamik kümelenme ile birlikte denenebileceği önerilmektedir [9].

Özgüner'in çalışmasında, Türkiye elektrik piyasası için, sistem gün öncesi fiyatı ve sistem marjinal fiyatlarının tahmin edilmesi için çoklu doğrusal regresyon modelleri ile birlikte YSA modelleri geliştirilmiştir. Kış mevsiminde seçilen hafta için %6,13, Bahar mevsiminde seçilen hafta için %5,96 ve Yaz mevsiminde seçilen hafta için %7,97 MAPE değerlerine ulaşılmıştır [10].

Anbazhagan ve Kumarappan'ın makalesinin orijinalitesi girdi parametrelerini discrete cosine transform (DCT) tekniği ile bir ön işleme tabi tutarak değişmeyen, olduğu gibi kalan bir sinyale dönüştürmenin sonuca etkilerini ölçmektedir. İleri doğru hesaplamalı YSA modeli kullanılan çalışma sonucunda aşırılık gösteren fiyat tahminlerinde iyi

sonular alınmıřtır. Yine de karma modellerden daha iyi sonu alınamadıėı grlmřtr [11].

Geidel ve Zareipour alıřmasında iki adet Destek Vektr Makinası (SVM) regresyon modeli kullanılarak oluřturulan fiyat tahmini modeli İřpanyol spot piyasasında uygulanmıřtır. Bu alıřmanın orijinalitesi veri setinden kaynaklanmaktadır. Veri setinde hem toplam talep yer almaktadır, hem de toplam talepten tahmini yenilenebilir enerji retiminin ıkarılmıř hali yer almaktadır. zellikle rzgar enerjisi yaygın kullanımda olduėundan ve gelecekte de kurulu gcnn artacaėı beklendiėinden sz konusu alıřmada temel alınan yenilenebilir kaynak rzgar enerjisi olmuřtur. SVM modellerinden biri toplam elektrik talebi ile eėitilirken, diėer SVM modeli ise toplam elektrik talebinden rzgar retiminin ıkarılmıř hali ile eėitilmiřtir. Ortaya ıkan iki fiyat tahmini birleřtirilerek nihai tahmine ulařılmıřtır. alıřma gstermektedir ki, İřpanya’da zellikle gn ortasında artmakta olan rzgar retiminin toplam talebe oranının fiyatlar zerinde nemli etkisi bulunmaktadır, bu nedenle toplam talepten rzgar retimi etkisinin elimine edilerek arta kalan talebin de girdi alınarak tahmin yapılmasının daha saėlıklı sonular ıkardıėı grlmřtr [12].

Klmek’in alıřmasında, Trkiye elektrik piyasasında 01/12/2009 ile 31/12/2010 dnemine iliřkin gn ncesi piyasa fiyatı YSA ve ARIMA modelleri ile tahmin edilmiřtir. alıřmada YSA ile yapılan haftalık tahminlerde %14,15 MAPE deėerine ulařılırken, ARIMA modeli ile yapılan tahminlerde %15,60 MAPE deėerine ulařılmıřtır. YSA ile yapılan tahminlerin daha yksek performans gsterdiėi sonucuna ulařılmıřtır [13].

Sahay ve Tripathi’nin alıřmasında bulanık mantık, bulanık mantık-yapay sinir ve YSA modelleri gibi eřitli yapay zeka tekniklerinin fiyat tahmini iin kullanıldıėı belirtilmiřtir. Fakat bu deėiřik teknikler arasında son yıllarda en fazla dikkat ekenin, geleneksel tekniklerin bařaramadıėı doėrusal olmayan karmařık iliřkileri ėrenme yeterliėi sayesinde YSA ile mmkn olduėu belirtilmiřtir. Bu nedenle alıřmada YSA modellemesi kullanılarak İngiltere piyasasındaki fiyatlar tahmin edilmek amalanmıřtır. Oynaklıėın yksek olduėu ve hızlı hava deėiřimlerinin yařandıėı durumlarda bile iyi tahminler elde edilmiřtir. Fiyat tahminini etkileyen en nemli faktrn talep miktarı olduėu tespit edilmiřtir. Bu alıřmada girdi katmanı ařaėıdaki deėiřkenleri iermektedir [14].

- Termometre sıcaklığı
- Nemin yoğunlaşma sıcaklığı
- Günün saatleri (0-24)
- Haftanın gün tipi (1-7)
- Resmi tatil veya hafta sonu gün tipi (0-1)
- Sistem Yüğü
- Önceki günün ortalama yüğü
- Önceki günün aynı saatine ilişkin yüğü
- Önceki haftanın aynı gününün aynı saatine ilişkin yüğü
- Önceki günün ortalama fiyatı
- Önceki günün aynı saatine ilişkin fiyatı
- Önceki haftanın aynı gününün aynı saatine ilişkin fiyatı
- Önceki günün doğal gaz fiyatı
- Önceki haftanın ortalama doğal gaz fiyatı

Weron, R. makalesinde son 15 yılda elektrik fiyat tahmininde kullanılan modellerin güçlü ve zayıf tarafları karşılaştırılmıştır [15].

Bicil'in çalışmasında elektrik fiyatlarının tahmininde tek değişkenli doğrusal zaman serisi tekniğı olan otoregresif hareketli ortalama modelleri (ARMA) ile YSA modellerinden Ocak 2012- Nisan 2014 dönemi için Türkiye elektrik piyasası gün öncesi fiyatlarının öngörüsü konusundaki performansları karşılaştırılmıştır. Fiyat tahmin performansları incelendiğinde, %8,2 MAPE ile sigmoid aktivasyon fonksiyonu ve Levenberg-Marquardt algoritması ile eğitilen YSA modelinin piyasa takas fiyatı tahmininde ARMA modeline göre daha iyi performans sağladığı görülmüştür [16].

Yıldız'ın çalışmasında Türkiye elektrik piyasasında gün öncesi fiyat tahmini için uygulanan YSA modelinde Kış dönemi için saatlik %4,9, Yaz dönemi için saatlik %6,4 MAPE değerleri hesaplanmıştır [17].

Keles ve diğ. çalışmasında yeterli değişken seçimi ve uygun konfigürasyona sahip YSA modeli ile EPEX piyasasında fiyat tahmini modellemektir. Modelin iyi sonuç vermesi için girdi parametrelerinin deneme yanılma tekniğı ile seçilmek zorunda kalınması oldukça zaman harcanmasına sebep olmaktadır. Girdi parametrelerinin birbirlerinden etkilendiğı durumların model sonuçları üzerindeki etkisi büyük olmaktadır. Bu nedenle değişik parametre kombinasyonları denemek zaman kaybettirici olsa da iyi tahminler elde etmek için önemlidir [18].

Kotur ve Žarković'in çalışmasında ARFIMA ve YSA hibrit modeli Sırbistan elektrik piyasasında kısa ve uzun dönemli fiyat tahminlerinde kullanılmıştır. Yenilenebilir kaynaklara dayalı üretimin sürekli emre amade olmayan doğası yüzünden konvansiyonel kaynaklara olan ihtiyaç değişeceğinden, sistem daha stokastik ve tahmini zor bir hal aldığı söylenebilir [19].

Lahouar ve Slama makalesinde üç tahmin modeli aynı değişkenler kullanılarak karşılaştırılmıştır. Bunlar YSA, SVR ve RF' tir. Avustralya piyasasında yarım saat öncesi fiyat tahmini için YSA daha iyi sonuç verirken, gün öncesi fiyat tahmini için RF'in özellikle aşırı artan fiyatlarda daha iyi sonuç verdiği görülmüştür [20].

Moreira ve diğ. çalışmasında piyasa fiyatları regresyon tekniğine dayalı modelde, %5'er adımlarla artarak %5'ten %95'e kadar olasılıklı olarak tahmin edilmiştir [21].

Moria, H., ve Nakanob, K.'nin çalışmasında bulanık mantık c-kümeleme (fuzzy c-means) algoritması ile kümelere ayrılan girdi setinin devamında EPSO (Evolutionary Particle Swarm Optimization) ile daha iyi bağlantılar kurarak GP'nin (Gaussian Process) eğitilmesi amaçlanmıştır [22].

Nargale ve Patil'in makalelerinde ileri doğru hesaplama ile öğrenen iki ara katmanlı YSA modeli ile Hindistan piyasasında fiyat tahmini modellemektir. İki yıllık girdi seti kullanılarak çok fazla salınım olmayan saatlerin tahminlerinde iyi tahminler elde edilmekle birlikte, Matlab' taki SVM aracı kullanılarak istatistiksel öğrenme sağlanmasının modeli daha fazla geliştireceği ifade edilmiştir [23].

Özözen ve diğ. çalışmasında SARIMA ile YSA hibrit modelini kullanarak Türkiye gün öncesi piyasasında fiyat tahmini uygulaması yapılmıştır. Hibrit modelin amacı kullanılan verinin doğrusal trendini SARIMA ile elde ederken, doğrusal olmayan kalanını YSA ile tahmin edilmesidir. Hibrit modelin %4,08 MAPE ile performans sağladığı görülmüştür. Hibrit model kullanılarak ileri tarihlerdeki 5 günlük fiyat tahminleri test edildiğinde %10,2 MAPE ile performans elde edilmiştir [24].

İncelenen çalışmaların ortak noktası spot piyasa RF tahmininin içerdiği çok sayıda belirsizlik nedeniyle oldukça karmaşık bir yapıda olduğunun ifade edilmesidir. Talep veya yük ile arz, diğer bir deyişle üretimi etkileyen bütün faktörler belirsizliği arttırmaktadır. Bu belirsizlikler arasında; sıcaklık, nem, yağış, rüzgar hızı gibi hava şartlarındaki değişiklikler, yenilenebilir üretim miktarı, hidroelektrik kapasite durumu, doğal gaz, kömür gibi yakıt maliyetleri, arızalanan üretim santralleri, iletim hattı

sorunları, diğ er katılımcıların davranışlarındaki değış meler; daha uzun vadede piyasa kurallarındaki değış iklikler, mevzuat değış iklikleri, sanayinin geliş mesi gibi  lkenin ekonomik değış kenleri, yatırım planlamaları, n fus artışı bulunmaktadır.

Zaman serileri ve regresyon analizi gibi eski y ntemler karmaşı  girdi- ıktı ilişkilerini   zmede g  s z kalmaktadır. Doğru veri seti ile optimum model kurularak eğitilen YSA modelleri ise daha hassas tahminler  retilabileceğinden kullanımları yaygınlaşmıştır.





2. TÜRKİYE ELEKTRİK PİYASASI

Türkiye’de elektrik enerjisinin arz ve talep taraflarının dengelenmesi iki temel organize mekanizmadan oluşmaktadır. Bu mekanizmalar, Gün öncesi piyasası ve dengeleme güç piyasasıdır.

EPİAŞ sahip olduğu piyasa işletim lisansı kapsamında organize toptan elektrik piyasalarının işletilmesi ve bu piyasalarda gerçekleştirilen faaliyetlerin mali uzlaştırma işlemlerinin yürütülmesinden sorumludur [25].

Gün öncesi piyasasının işletme görevi de EPİAŞ’a ait yükümlülükler arasındadır. EPİAŞ faaliyetlerini eşit taraflar arasında ayırım gözetmeksizin, şeffaflık ve sorumluluk ilkeleri çerçevesinde yürütür [26]. EPİAŞ’ın vizyonu Türkiye’nin bölgesel enerji ticaret merkezi olmasına katkı sağlamaktır [27].

Gün öncesi piyasası bir gün sonra teslim edilecek saatlik bazda elektrik enerjisi alış-satış işlemleri için kurulan organize toptan elektrik piyasası olarak tanımlanmaktadır. Gün öncesi piyasası arz ve tahmini talebin bir araya gelerek, teslim günü öncesinde alış-satış taahhütlerinin gerçekleşerek saatlik dengeleme faaliyetlerinin planlamasını sağlayan piyasadır.

Piyasa katılımcıları, bir sonraki günün her bir saatine ilişkin olarak alış/satış yönlü fiyat-miktar tekliflerini vererek arz-talep eğrilerini oluştururlar. Bu eğrilerin kesiştirilmesiyle gün öncesi fiyatı belirlenir. Oluşan gün öncesi fiyatı ilerleyen süreçte diğer piyasalar için referans fiyat niteliği taşımaktadır.

Gün öncesi piyasasının amacı, elektrik arz ve talebinin gerçek zamanlı dengelenmesinden önce gün öncesinden yapılan tahmini talebe göre dengelemektir. Böylece sistem işletmecisi olan TEİAŞ’a bir gün öncesinden yapılan güncel tahminlere göre piyasa oyuncularının dengelendiği bir sistem hazırlanmış olunur. Böylelikle piyasa katılımcılarının kendi aralarında özel hukuk hükümlerine tabi olarak yaptığı ikili anlaşmalarının yanı sıra bir sonraki gün için enerji alış-satışı yapmaları için bir taahhüt ortamı sağlanarak, sistemin dengelendiği noktada elektrik enerjisi referans fiyatı belirlenmiş olur.

Elektrik arz ve talebinin gerçek zamanlı dengelenmesi ise dengeleme güç piyasası aracılığıyla gerçekleştirilmektedir. Dengeleme güç piyasası on beş dakika içerisinde gerçekleştirilebilen çıkış gücü değişimi ile elde edilen yedek kapasitenin alış-satışının gerçekleştiği organize toptan elektrik piyasasıdır.

2.1 Gün Öncesi Piyasası Katılımcıları

Faaliyet alanlarına göre Enerji Piyasası Düzenleme Kurumu (EPDK)’ndan aldığı lisans çerçevesinde piyasada işlem yapmaya hak kazanan tüzel kişilikler piyasa katılımcısı olarak anılmaktadır. Lisans, 6446 sayılı Kanun hükümleri uyarınca üzerinde kayıtlı piyasa faaliyetlerinin yapılabilmesi için tüzel kişilere verilen izin belgesidir [25]. Piyasa katılımcıları;

- a) Üretim lisansı sahibi
- b) Tedarik lisansı sahibi
- c) OSB üretim lisansı sahibi
- ç) Dağıtım lisansı sahibi
- d) İletim lisansı sahibi

tüzel kişilerinden oluşur. Üretim lisansı ve OSB üretim lisansı sahibi şirketler elektrik enerjisi üretimi yapmaya yetkili, tedarik lisansı şirketler ise toptan ve perakende satış yapmaya yetkilidir. 21 dağıtım bölgesine ayrılmış olan dağıtım sistemlerinin işletme hakkına sahip olan şirketler dağıtım lisansları ile yetkilendirilmektedir. İletim sisteminin işletilmesine ilişkin iletim lisansı kamu kuruluşu olan TEİAŞ’a aittir. Bu katılımcıların ve ilgili mevzuat hükümleri çerçevesinde gerçekleştirdikleri faaliyetlerini piyasa işletimine zarar vermeme esasına göre hareket etmeleri gerekmektedir [26]. Lisans türüne göre katılımcı dağılımı Çizelge 2.1’de gösterilmiştir.

Çizelge 2.1: Lisans türüne göre mevcut katılımcı sayısı [28].

Lisans Tipi	Kamu Kuruluşu Katılımcı Sayısı	Özel Sektör Katılımcı Sayısı
Üretim	4	758
Toptan	1	149
Dağıtım	0	21
OSB Üretim	0	1
İletim	1	0
Görevli Perakende	0	21

2.2 Gün Öncesi Piyasası Teklif Süreci

1 Aralık 2011 tarihinden itibaren işlerlik kazanmış olan Gün öncesi piyasasında mevcut durumda piyasadaki alış-satış tekliflerinin bildirimine ve piyasada oluşan fiyatların belirlenip yayınlanmasına ilişkin kapı açılış ve kapanış saatleri Çizelge 2.2’de gösterilmiştir.

Çizelge 2.2 : Türkiye gün öncesi piyasası mevcut durumda uygulanan süreçler [29].

Süreçler	Açılış	Kapanış
Teklif Bildirimi	00:01	12:30
Teklif Doğrulama	12:30	13:00
Fiyat Belirleme	13:00	13:30
İtiraz Etme	13:30	13:50
Nihai sonuç	13:50	14:00
İkili Anlaşma Bildirimi	00:01	17:00

2.3 Gün Öncesi Piyasası Fiyat Oluşumu


Sistem gün öncesi fiyatı diğer adıyla piyasa takas fiyatı (PTF) enerji arzı ve talebinin dengelenmesi amacıyla kabul edilmiş olan son sistem alış ya da satış teklifinin fiyatı olarak belirlenmektedir. İhale sisteminde gerçekleştirilen ihale sistemindeki fiyat belirleme yöntemi marjinal fiyatlandırma olarak adlandırılmaktadır. Diğer bir ifadeyle, dengelemeye konu son teklifin fiyatı referans fiyat olan PTF’yi oluşturmaktadır.

Doğrusal Olmayan bir matematiksel optimizasyon modelinde tam sayı değişkenler ve kısıtlar ile karma tam sayılı ikinci dereceden bir matematiksel model ile çözülür. 1 Haziran 2016’dan itibaren Gün Öncesi Piyasasında kullanılmaya başlanan yeni GÖP optimizasyon modelinde kullanılan algoritmanın çözümü bu yöntemle olmaktadır. Kısıtların sayısının çok olması ve içeriklerinin karmaşıklığı nedeniyle algoritmanın çözüm süresi diğer problemlere göre daha uzundur [30].

Elektrik piyasası için bahsettiğimiz Referans Fiyat kavramına denk gelen PTF birim enerjinin ulusal para birimi cinsinden değeri olarak tarif edilebilir. Türkiye piyasası için PTF’ler TL/MWh birimi ile ifade edilmektedir.

2.4 Gün Öncesi Piyasası Teklif Tipleri

Mevcut piyasada saatlik, blok ve esnek olmak üzere üç farklı teklif tipi vardır. Gün öncesi piyasası teklifleri gün öncesi piyasasına katılan piyasa katılımcılarının sundukları saatlik alış-satış teklifleri, blok alış-satış teklifleri ve esnek satış tekliflerini içermektedir. Piyasa Yönetim Sistemi (PYS) yazılım arayüzü aracılığıyla gün öncesi piyasasına sunulmuş olan bütün alış-satış teklifleri değerlendirilerek birbirleri ile eşleştirme işlemi gerçekleştirilir. Şekil 2.1’de saatlik bazda örnek bir arz-talep eğrisi gösterilmiştir.



Şekil 2.1: Alış ve satış teklifleri ile arz-talep eğrisini oluşturulması.

2.4.1 Saatlik tekliflerin yapısı

Gün öncesi piyasasına katılan piyasa katılımcıları, bir sonraki günün her saati için, saatlik aktif elektrik enerjisi alış-satışına ilişkin tekliflerini, Piyasa Yönetim Sistemi (PYS) yazılım arayüzü aracılığıyla Piyasa İşletmecisi (Pİ) olan EPIAŞ'a bildirirler. Bir saatlik teklifte; alış yönündeki her bir fiyat-miktar ikilisi, piyasa katılımcısının ilgili miktardaki elektrik enerjisini satın almak için teklif ettiği fiyatı, satış yönündeki her bir fiyat-miktar ikilisi ise piyasa katılımcısının ilgili miktardaki elektrik enerjisini satmak için piyasaya teklif ettiği fiyatı belirtir. Her katılımcının her bir saatlik alış-satış teklifi, alış ve satış yönünde ayrı ayrı olmak üzere en fazla 32 fiyat-miktar ikilisinden oluşturulabilir. Gün öncesi piyasasına katılan bir piyasa katılımcısı aynı fiyat seviyesi için ya saatlik alış miktarı ya da saatlik satış miktarı bulundurabilir. Eşleşmenin saatlik teklifteki fiyat-miktar ikilileri arasında kalan kısım optimizasyon modeli tarafından lineer interpolasyon kullanılarak doldurulur [31].

2.4.2 Blok tekliflerin yapısı

Gün öncesi piyasasına katılan piyasa katılımcıları, blok teklif tipi sayesinde birden fazla ardışık saat için geçerli elektrik enerjisi alış ya da satışına ilişkin blok alış-satış tekliflerini bildirebilirler. Blok teklifin kapsadığı zaman dilimi en az ardışık 4 saatlik olmalıdır. Her bir blok teklif ya kapsadığı tüm zaman dilimi için kabul edilir ya da kapsadığı tüm zaman dilimi için reddedilir. Her katılımcı tarafından en fazla üç adet blok teklif için geçerli olmak üzere blok teklifler arasında şartlı bağlantılar kurulabilir [31]. Piyasa işletmecisi EPIAŞ'ın blok teklifleri arasında kurulabilecek ilişki sayısını arttırma ve profil blok yapısını da gün öncesi piyasasında kullanımı için altyapı hazırlamakta olduğu bilinmektedir. Çalışmaların tamamlanması ve Gün Öncesi Piyasası Tekliflerinin Yapısı ve Tekliflerin Değerlendirilmesine İlişkin Usul ve Esaslar'ın revize edilmesiyle yakın zamanda yeni blok teklif yapıları yürürlüğe girecektir.

2.4.3 Esnek tekliflerin yapısı

Esnek satış teklifleri, belirli bir saat ile ilişkili olmayan, herhangi bir saat için sunulan saatlik satış teklifleridir. Esnek satış teklifi ya tamamen reddedilir ya da herhangi bir saat için tamamen kabul edilir [31]. Bu sayede talebin diğer bir deyişle alışın en yüksek olduğu saatlerde esnek satış teklifleri ile eşleşme sağlanabilmektedir.



3. YAPAY SİNİR AĞLARI

3.1 Yapay Sinir Ağları ve Sinir Sistemi

Yapay sinir ağları (YSA), biyolojik sinir sisteminin çalışma şekline benzer bir yapı ile kurgulanarak makine öğrenmesini sağlayan matematiksel modellerdir. Bu sistemlerde, geçmiş olaylara bakılmakta, geçmiş olaylar hakkında ağırlık kümeleri aracılığıyla genellemeler yapılmakta ve daha sonra farklı bir olay ile karşılaşıldığında, tüm öğrenmelerin ışığında bir çıktı oluşturulması amaçlanmaktadır.

Yapay sinir ağlarını anlatan literatürdeki çalışmaların birçoğunun biyolojik sinir ağları ile yapay sinir ağlarının karşılaştırılmasına dayanmaktadır. Efektörlerin ve reseptörlerin matematiksel olarak tanımı ile oluşturulmuş olan modelde aktivasyon fonksiyonu sayesinde sinir uçlarının birbiri ile haberleşmesine benzer işlemler kullanılmaktadır. Biyolojik sinir ağlarının yapay sinir ağlarında hangi elemana karşılık geldiği Çizelge 3.1’de gösterilmiştir.

Çizelge 3.1 : Biyolojik sinir ağları ile yapay sinir ağları arasındaki eşleştirme [32].

Biyolojik Sinir Ağları	Yapay sinir Ağları
Uyarı	Girdi
Reseptörler	Girdi katmanı
Sinir ağı	İşlem katmanı
Nöron	İşlem elemanı
Efektörler	Çıktı katmanı
Cevap	Çıktı

3.2 Yapay Sinir Ağları Gelişimi

1940’larda bilgisayar teknolojisinin gelişmeye başlamasının ardından, ilk defa 1950’li yıllarda Perceptron (Algılayıcı) kavramı ile Yapay Sinir Ağları (YSA) terimi ortaya atılmıştır. Bilgisayar mühendisliğinde Kesin VEYA (Extreme OR) XOR kapısının çözümünden sonra ise çok katmanlı YSA’ya geçilmiştir. 1970’lerde çözülmüş olan bu sorun iki aşamalı işlem gerektiren bir mantık yapısı kullanır. XOR çözümünden sonra

en iyi modeli oluşturarak öğrenmeye yönelik YSA çalışmaları, kestirim işlemlerinin vazgeçilmez çözüm aracı olmuştur [32].

3.3 Yapay Sinir Ağlarının Genel Özellikleri

Her modelin kendisine özgü özelliklerinin olmasının dışında yapay sinir ağlarının genel özellikleri Öztemel'e göre aşağıdaki gibi sıralanabilir [33]:

a) Makine öğrenmesini sağlarlar: YSA'ların temel işlevi bilgisayarların örnek olayları öğrenerek benzer olaylar karşısında benzer kararlar vermesini sağlamaktır.

b) Bilginin saklanması : Yapay sinir ağlarını birbirlerine bağlayan bağlantıların değerlerine ağırlık değerleri olarak tanımlanmaktadır. Bilgi ağın bağlantılarının sahip olduğu ağırlık değerleri ile ölçülmekte ve yine bu bağlantılarda saklanmaktadır. Ağın sahip olduğu ağırlık değerleri ne kadar doğru ise ağın performansı da o ölçüde doğru olur. Diğer bir ifadeyle ağın zekası ağın bağlantılarındaki ağırlık değerlerinde saklıdır. Ağın eğitilmesinin anlamı bu ağırlıkların bulunması işlemidir. Bu ağırlıklar başlangıçta rastgele atanır, daha sonra eğitim sırasında ağa gösterilen her örnekle birlikte ağın öğrenme kuralına göre ağırlıklar değiştirilir. Ağ eğitim setindeki örneklerin hepsi için doğru çıktılar üretinceye kadar ağırlıklar değiştirilmeye devam edilir. Eğitim seti için doğru çıktılar alındıktan sonra test setindeki örnekler ağa gösterilir. Eğer ağ test setindeki verilere de doğru çıktılar verirse ağ eğitimi tamamlamış olur. Ağın zekası sayılabilecek ağırlıklar tek başına bir anlam ifade etmemektedir. Bu nedenle “kara kutu” benzetmesi yapılan ağın bilgilerinin ulaşılabilirliği ve yorumlanması mümkün olmamaktadır.

c) Örnekleri kullanarak öğrenme: YSA'lar gerçekleşmiş olaylardan oluşan örnekler ile eğitilerek genelleme yapabilecek duruma getirilir. Problem ağa bütün yönleri ile gösterilmez ise YSA modelinden başarılı sonuçlar elde edilemeyecektir. Bu nedenle problemi etkileyen faktörlerin mümkün mertebe ağa gösterilmesi ile ağın eğitimi sağlanırsa modelin daha az hatalı sonuçlar çıkarması beklenebilir.

d) Test edilme gerekliliği: Ağın eğitiminin ardından problem çözümünde kullanılmasından önce performansının test edilmesi gerekmektedir. Ağın

eđitimi optimum rneklerden oluřan eđitim seti ile tamamlandıktan sonra test seti ile ađın performansı llr. Ađ test setindeki verileri eđitim srecinde grmemektedir. Ađ daha nce hi grmediđi bu rnelere kabul edilebilir bir aralıktta cevap veriyorsa ađın performansının iyi olduđu sonucu ıkarılır. Bundan sonra ađın grmediđi olaylar iin de uygulanabileceđi anlamı ıkarılabilir. Eđer ađın performansı tatmin edici dzeyde deđilse, ađın yeniden yeni bir eđitim seti ile eđitilmesi yoluna gidilmesi gerekecektir.

e) Eksik bilgi ile alıřabilme: Geleneksel sistemler eksik bilgiler ile alıřtırılmazlar. YSA ise eksik bilgiler ile alıřmaya devam edebilirler. Eđer eksik bilgiler nemli sayılabilecek bir nitelikte deđilse ađın performansını ciddi řekilde dřrmeyecektir. Problemin zm iin fazla sayıda bilgi gereken durumlarda sadece nemli bilgiler ile model kurularak iyi sonular elde edilebilecektir.

f) Hata toleransına sahip olma: Ađın bazı hcrelerinde bozulma olması ve alıřmaması durumunda ađ yine alıřmaya devam eder. Sz konusu bozuk hcrelerin nemine gre ađın performansı etkilenebilir. Hangi hcrelerin nemli olduđu ađın kendisi karar verdiđinden kullanıcı tarafından durumun farkına varılması ve deđerlendirilmesi de mmkn olmamaktadır.

g) Zamanla bozulma: Ađlar anında deđil fakat zaman iinde yavaş bir řekilde bozulurlar. Bunun nedeni eksik olan bilgiler veya hcre yapısının bozulmasıdır.

h) Dađıtık belleđe sahip olma: Yapay sinir ađlarında bilgi tm ađa yayılmış haldedir. Ađın bilgi durumu hcrelerin birbirleri ile olan bađlantılarının deđerleri ile llr. Ađın belleđi dađıtık vaziyette olduđundan ayrıkt tek bir bađlantının bir anlamı yoktur. đrenilen olayın tamamı ađın tamamına dađıtılmış haldedir. Ađ dađıtık bir bellek yapısına sahip olduđu iin ađın bilgilerinin kullanıcıya aıklanması anlamını yitirmektedir.

i) Sadece sayısal girdiler ile alıřabilme: Yapay sinir ađları sadece nmerik bilgiler ile alıřabilmektedir. Sezgisel bilgiler, ikili ya da tamsayılı olarak kodlanarak sayısal hale getirilir.

3.4 Yapay Sinir Ağı Modeli Yapısı

Bir yapay sinir ağının modeli aşağıda yer alan bilgiler doğrultusunda karakterize edilmektedir:

- Ağın topolojisi
- Toplama fonksiyonu
- Aktivasyon fonksiyonu (Transfer fonksiyonu)
- Öğrenme stratejisi
- Öğrenme kuralı

YSA yapısı tek katmanlı (Perceptron) yapı veya çok katmanlı (gizli katmanı olan) yapıdan oluşur. YSA'nın öğrenmesi istenen olayın girdi ve çıktıları arasında doğrusal olmayan ilişkiler bulunuyorsa ağın öğrenmesi için çok katmanlı algılayıcı (Multi-Layer Perceptron) modeli ile mümkün olmaktadır. Çok katmanlı algılayıcılar (ÇKA) girdi ve çıktı katmanları arasında en az bir tane gizli katman olarak adlandırılan ara katman bulunan modellerdir.


Genel olarak YSA topolojik yapısı; girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere üç kısımdan oluşmaktadır:

Girdi katmanı dış dünyadan gelen girdileri toplayarak hiçbir işleme tabi tutmadan doğrudan gizli katmana iletir.

Gizli katmanlar girdi katmanından gelen bilgilerin işlendiği katmanlardır. YSA'da birden çok gizli katman ve her katmanda birden çok proses elemanı olabilir. Ara katmanlardaki her proses elemanı kendinden sonraki ara katmanın her proses elemanına bağlıdır.

Çıktı katmanında, gizli katmandan gelen işlenmiş girdi setine karşılık modelin ürettiği çıktılar oluşturularak dış dünyaya gönderilir. Çıktı katmanında bir veya birden çok proses elemanı olabilir.

Şekil 3.1'de temel olarak yapay sinir ağı modeli yapısı gösterilmektedir.



Şekil 3.1: Yapay sinir ağı modeli yapısı [34].

Her proses elemanının sadece bir tane girdisi ve bir tane çıktısı bulunmaktadır. Her proses elemanının çıktısı bir sonraki katmandaki bütün proses elemanlarına gönderilir.

“Bir yapay sinir ağına asıl amaç bağımlı değişken veya değişkenlerin gerçek değerleriyle hesaplanan değerleri arasındaki farkın kareler toplamının en küçüklenmesidir. Bu bağlamda en küçük kareler regresyonunun amaç fonksiyonu ile benzerlik gösterir. Ancak klasik doğrusal regresyon analizinden farklı olarak bağımlı değişkenlerin sayısı birden fazla olabilir. Geri yayılım ifadesi ağı oluşturan parametrelerin her bir iterasyonda hatayı azaltacak şekilde yeniden düzenlenmesinden ötürü kullanılmaktadır. Hatanın en küçüklenmesi için parametrelerde yapılan değişikliklerin hangi kurala göre yapılacağı öğrenme algoritmasıyla ilişkilidir. Öğrenme algoritması olarak Back-Propagation (Geri Yayılım) algoritmasının kullanıldığı sıklıkla görülmekle birlikte parçacık sürü optimizasyonu ve genetik algoritmalar da öğrenme algoritması olarak kullanılabilir” [33].

3.4.1 Aktivasyon (transfer) fonksiyonu türleri


Başlangıç elemanları girdi setinden bir değer alıp yapay sinir ağına bir akım başlatırlar. İşlem elemanları ve bitiş elemanları ise kendilerine gelen akışların ağırlıklı toplamını alarak bir transfer fonksiyonundan geçirirler. Literatürde rastlanan transfer fonksiyonu türleri şu şekilde sıralanmaktadır [35]:

- Doğrusal transfer fonksiyonu
- Basamak transfer fonksiyonu

- Kutuplamalı basamak transfer fonksiyonu
- Parçalı doğrusal transfer fonksiyon
- Sigmoid transfer fonksiyonu
- Tanjant hiperbolik transfer fonksiyonu
- Sinüs transfer fonksiyonu

Doğrusal transfer fonksiyonuna gelen girdiler olduğu gibi çıktı olarak alınır. Doğrusal transfer fonksiyonun formülü ve grafiği Şekil 3.2’de verilmiştir:

$$x_j = \varphi(v_j, b_j) = v_j + b_j = \sum_{i=1}^n w_{ji} x_i + b_j \quad (3.1)$$




Şekil 3.2 : YSA modelinde doğrusal transfer fonksiyonu [32].

Tek kutuplu basamak transfer fonksiyonuna gelen girdi değerleri belirlenen eşik değerinin altında ise çıktı 0, belirlenen eşik değerinin üstünde ise çıktı 1 değerini alır. Çift kutuplu basamak transfer fonksiyonuna gelen girdi değerleri belirlenen eşik değerinin altında ise çıktı -1, belirlenen eşik değerinin üstünde ise çıktı 1 değerini alır. Sırasıyla tek kutuplu ve çift kutuplu basamak transfer fonksiyonun formülü ve Şekil 3.3’de grafikleri verilmiştir:

$$x_j = \varphi(v_j, b_j) = \begin{cases} 1 & v_j + b_j \geq 0 \\ 0 & v_j + b_j < 0 \end{cases} \quad (3.2)$$

$$x_j = \varphi(v_j, b_j) = \begin{cases} +1 & v_j + b_j \geq 0 \\ -1 & v_j + b_j < 0 \end{cases} \quad (3.3)$$




Şekil 3.3 : YSA modelinde basamak transfer fonksiyonu [32].

Sırasıyla tek kutuplu ve çift kutuplu basamak transfer fonksiyonlarının kutuplama değeri ile ifadesi ve Şekil 3.4’de grafikleri verilmiştir:

$$x_j = \varphi(v_j, b_j) = \begin{cases} 1 & v_j + b_j \geq \theta \\ 0 & v_j + b_j < \theta \end{cases} \quad (3.4)$$


$$x_j = \varphi(v_j, b_j) = \begin{cases} +1 & v_j + b_j \geq \theta \\ -1 & v_j + b_j < \theta \end{cases} \quad (3.5)$$



Şekil 3.4 : YSA modelinde kutuplama değerli transfer fonksiyonu [32].

Parçalı doğrusal transfer fonksiyonunda belirli bir sınır (teta) ile belirlenmiştir ve bu sınıra göre parçalama yapılır. Bu tür aktivasyonun formülü ve Şekil 3.5’de grafiği verilmiştir:


$$x_j = \varphi(v_j, b_j) = \begin{cases} 1 & v_j + b_j \geq \theta \\ \theta(v_j + b_j) + \frac{1}{2} & |v_j + b_j| < \frac{1}{2\theta} \\ 0 & v_j + b_j \leq -\frac{1}{2\theta} \end{cases} \quad (3.6)$$



Şekil 3.5 : YSA modelinde parçalı doğrusal transfer fonksiyonu [32].

Doğrusal olmayan, kompleks işlemlerde doğrusal olmayan fonksiyonlar kullanılır. En yaygın olarak Sigmoid (Lojistik fonksiyon olarak da adlandırılır), tanjant hiperbolik ve Gauss (normal dağılım fonksiyonu) kompleks problem çözümlerinde tercih edilmektedir. Sigmoid transfer fonksiyonun formülü ve Şekil 3.6'de grafiği verilmiştir:


$$x_j = \varphi(v_j, b_j) = \frac{1}{1 + \exp(-\theta(v_j + b_j))} \quad (3.7)$$



Şekil 3.6 : YSA modelinde sigmoid transfer fonksiyonu [32].

Tanjant hiperbolik transfer fonksiyonu kullanıldığında gelen girdi değerleri bu fonksiyondan geçirilerek kullanılır. Tanjant hiperbolik transfer fonksiyonun formülü ve Şekil 3.7’de grafiği verilmiştir:


$$x_j = \varphi(v_j, b_j) = \tanh(v_j + b_j) \quad (3.8)$$



Şekil 3.7 : YSA modelinde tanjant hiperbolik transfer fonksiyonu [32].

Sinüs transfer fonksiyonu öğrenilmesi istenilen örneklerin sinüs fonksiyonuna uygun bir dağılım gösterdiği durumlarda kullanılır. Sinüs transfer fonksiyonun formülü ve Şekil 3.8’de grafiği verilmiştir:

$$x_j = \varphi(v_j, b_j) = \sin(v_j + b_j) \quad (3.9)$$



Şekil 3.8 : YSA modelinde sinüs transfer fonksiyonu [32].

3.4.2 Kavrama türleri

Yapay sinir ağlarında bilgi birikimi yapay sinir ağındaki ağırlıklar ile gerçekleştirilmektedir. Yapay sinir ağının bilgi birikimini arttırmak ve istenilen

performansa ulaşmak için kavrama (knowledge accumulation) yapan algoritmalar ağırlıklar üzerinde değişiklik yaparlar.

Yapay sinir ağlarında kavrama yapan algoritmalar istenilen sonuçların bilinip bilinmemesine göre aşağıdaki üç türe ayrılırlar [32]:

- Gözetimli (supervised) kavrama
- Gözetimsiz (unsupervised) kavrama
- Takviyeli (reinforced) kavrama

Eğitim kümesi üzerindeki bütün örnekler için yapay sinir ağının ağırlıklarını bir kez güncellenmesi işlemine devir (epoch) denilmektedir [36]. Bu işlem sırasında ağırlıkların her örnek için güncellenmesine veya toplu olarak bir defada güncellenmesine göre kavrama yapan algoritmalar iki grupta incelenebilir:

- Çevrimiçi (online) kavrama
- Toplu (batch) kavrama

3.4.2.1 Gözetimli (supervised) kavrama

Yapay sinir ağlarında gözetimli kavrama yaygın olarak kullanılır. Gözetimli kavramanın uygulanabilmesi için çözülmesi amaçlanan problemdeki her bir gözlemde verilen girdilere karşılık hangi sonuçların alınması gerektiği biliniyor olmalıdır. Gözetimli kavramada amaç belirli örnek gözlem girdileri için beklenen çıktılar ile yapay sinir ağının ürettiği çıktı değerlerinin karşılaştırılarak hatanın azaltılmasıdır. Bir başka deyişle, çok değişkenli regresyon işleminde olduğu gibi çıktı için tarihsel verilerin elde bulunma halidir ve bu değerler gözetmen olarak görülür.

Bu kavrama türünde yapay sinir ağının hata miktarı en küçüklenmeye çalışılır. En küçükleme işleminde her adımda hatanın biraz daha azaltılması hedeflenir. İstenilen hata seviyesine düşüldüğünde veya önceden tanımlanmış belli sayıdaki adım sonucunda hata seviyesinde ciddi bir düşüş meydana gelmediyse kavrama algoritması durdurulur.

3.4.2.2 Gözetimsiz (unsupervised) kavrama

Gözetimsiz (danışmansız) kavrama türünde ise istenilen çıktıların hiçbirisi için tarihsel değer yoktur bu nedenle genellikle kümeleme problemleri için kullanılması tercih edilmektedir. Yapay sinir ağının kavrama işlemi bittikten sonra kümeleme

yöntemlerinde olduğu gibi elde edilen çıktıların ne anlama geldiğinin yorumlanması kullanıcı tarafından yapılmaktadır.

Çok değişkenli istatistiksel analizler yöntemi olan kümeleme (cluster) analizinden farklı olarak, gözetimsiz kavramada, herhangi bir ön kabul yapılmaksızın girdi örnekleri içerisindeki örüntülerin dışarıdan bir hamle olmadan, kendisi tarafından bulunması amaçlanmaktadır [37].

Gözetimsiz kavramada, örneklerdeki parametreler arasındaki ilişkilerin yapay sinir ağı tarafından kavrama algoritmasıyla kendi kendine dışarıya ile bir etkileşim olmadan tespit etmesi beklenir. Bu kavramada yapay sinir ağları, teker teker mevcut yapısındaki bağlantıların ağırlıklarını sahip olduğu mevcut örneklerle göre günceller. Bu sayede benzer örüntüler için benzer çıktılar üretebilir.

Sonuç olarak gözetimsiz kavrama, ulaşılması beklenen çıktılarının bilinmemesini ve/veya verilmemesi durumlarında kullanılan bir kavrama yöntemidir. Yapay sinir ağları bu kavrama türünde yalnızca girdi değerlerini kullanırlar. Bu kavrama türünde yapay sinir ağına yaptığı hatayı bildirerek ağı öğrenmesine katkı sağlayacak herhangi bir etmen yoktur.

Bu noktada, beklenen çıktılarının verilmediği gözetimsiz kavramada ağı performansının hangi şekilde ölçüleceği meselesine değinilecektir. Gözetimsiz kavramada yapay sinir ağları, performanslarını kendi içlerindeki parametrelerini kullanarak değerlendirirler. Bu öğrenmede yapay sinir ağına hiçbir şekilde bir ürettiği çıktının doğruluğu veya yanlışlığı hakkında bilgi verilmeyerek, bulunan çıktılarının ağı kendi yapısı ve kavrama yöntemi kuralları dahilinde kendisinin bulması beklenir [38].

3.4.2.3 Takviyeli (reinforced) kavrama

Bu kavrama türü gözetimli kavrama ile gözetimsiz kavramanın karması şeklinde bir yöntemdir. Çıktıların bazıları için geçmiş değerler bulunmakta ama diğerleri için bilinmemektedir.

“Kavrama için kullanılan örneklerde istenilen çıktı değerleri yer almaz ya da bu değerler kullanılmaz. Ancak gözetimsiz kavramadan farklı olarak algoritmanın performansı dışarıdan belirlenen bir ölçüte göre yapay sinir ağına bilgi olarak verilir. Kısaca belli girdi değerleri için elde edilen çıktı değerlerinin iyiliğini belirten bir geri bildirim kullanılır. Gözetimli

kavramadaki gibi direkt olarak yapay sinir ağına hata miktarı geri bildirim olarak verilmez [32].”


Bu kavrama yönteminde her düğüme bağlanan girdilerin ağırlıklı değerleri arasında yarışma açılır ve kazananın düğüme bağlanmaya hakkı olur. Geri dönüşümlü (recursive) yöntem de bu tür kavramaya girer ve elde edilen çıktıyı her geri bildirimde düzeltir.



4. TÜRKİYE ELEKTRİK PİYASASI FİYAT TAHMİNİ UYGULAMASI

Türkiye Elektrik Piyasası Referans Fiyatı (RF) olan PTF'ler Piyasa İşleticisi olan EPIAŞ tarafından işletilen Gün Öncesi Piyasasında ertesi günün her saati için alış ve satış tekliflerinin dengelenmesi ve değerlendirilmesi sonucu oluşturulan fiyatlardır.

Literatürdeki elektrik fiyat tahmini modelleri incelendiğinde, veri madenciliğine dayanan modelleme, simülasyon bazlı modelleme ve zaman serilerine dayanan modelleme olarak üç ana sınıfa ayrıştırıldığı Şekil 4.1'de gösterilmektedir.



Şekil 4.1: Elektrik fiyatı tahmin modellerinin sınıflandırılması [39].

Yukarıdaki tanıma göre çalışmamızda fiyat tahmini uygulaması yapılırken doğrusal olmayan, sezgisel zaman serileri yöntemi kullanılmıştır. Türkiye Elektrik Piyasasından alınan bir kesit veri grubu kullanılarak Levenberg-Marquardt geriye yayılma algoritması ile eğitilmiş tek gizli katmanlı YSA modeli kullanılarak farklı nöron sayılarında spot elektrik piyasası için 24 saatlik Referans Fiyat (RF) tahminini en doğruya yakın veren model oluşturulmuştur. gerçekleştirilmiştir.

Bu uygulamanın diğer tahmin çalışmalarından önemli farkı, seçilen girdi kümesinin fiyat zaman serilerine ek olarak kaynak maliyetini, günün ısını, Ramazan veya bayram günlerini içermesidir.

4.1 Uygulama Modeli Veri Grupları

Günlük PTF fiyat tahmini için oluşturulan YSA modelinin eğitim veri seti 01.06.2016 ile 28.11.2016 tarihleri arasındaki değerler kullanılarak oluşturulmuştur.

Piyasa İşleticisi olan EPIAŞ, 01.06.2016 tarihinden itibaren Gün Öncesi Piyasasında sosyal fayda ençoklamasını amaçlayan yerli bir algoritma çalıştırarak saatlik bazda PTF'lerin belirlenmesini sağlamaktadır. 01.06.2016 tarihinden önce farklı bir algoritma ile piyasadaki fiyatlar belirlendiğinden algoritma etkisini elimine etmek amacıyla YSA modelinin eğitim veri seti 01.06.2016 tarihinde başlatılmıştır.

Kış mevsiminde elektrik enerjisi talep artışının yanı sıra, yaşanan doğalgaz yetersizliği nedeniyle doğalgaz ile enerji üreten santrallerin üretimlerinde kısıntı yapılmasının arzı düşürücü etkisiyle PTF'ler yüksek bir eğilim takip ettiğinden YSA modelinin eğitim veri seti 28.11.2016 tarihinde sonlandırılmıştır. Böylelikle modelin eğitim sürecinde doğalgaz kısıntısının gerçekleştiği ve aykırı yüksek PTF'lerin olduğu saatlere maruz kalmaması sağlanmıştır.

Kısa vadeli PTF tahmini uygulamasında test veri grubu olarak 29.11.2016 tarihine ilişkin gerçekleşmiş saatlik PTF'ler seçilmiştir. Uygulama sonucunda 29.11.2016 gününe ilişkin tahmin edilen PTF değerleri ile gerçekleşen PTF değerleri arasındaki saatlik ve günlük Ortalama Mutlak Yüzde Hata (MAPE) oranları hesaplanmıştır.

Uygulama için hazırlanan YSA modelinde girdi seti olarak 7 adet veri tipi seçilmiştir. Bu veriler:

- a) P: Bir gün öncesinin aynı saati için gerçekleşmiş PTF verisi (24 girdi değeri)
- b) H: Bir hafta öncesinin aynı saati için gerçekleşmiş PTF verisi (24 girdi değeri)
- c) GT: Haftanın gün tipi [1,7]; Pazartesi, Salı, Çarşamba, Perşembe, Cuma, Cumartesi, Pazar
- d) R: Ramazan ayına denk gelen gün tipi [0-1]
- e) B: Bayram günlerine denk gelen gün tipi [0-1]

f) TM: Bir gün öncesinin aynı saati için gerçekleşmiş toplam talep miktarı (24 girdi değeri)

g) DG: Bir gün öncesinin doğalgaz birim maliyeti (TL/Sm³)

h) S: Bir gün öncesinin aynı saati için gerçekleşmiş Türkiye geneli sıcaklık verisi (24 girdi değeri)

Girdi seti verileri seçilirken öncelikle bir gün önce gerçekleşmiş fiyatlar ve bir hafta önce aynı gün tipinde gerçekleşmiş PTF değerleri dikkate alınmıştır. Çizelge 4.1 ve Çizelge 4.2’de örnek girdi seti kesiti gösterilen bu değerler Piyasa İşleticisi olan EPİAŞ tarafından kamuya açık bir şekilde paylaşılmakta olan platformdan alınmıştır.

Çizelge 4.1: 1 gün öncesine ait PTF’lere ilişkin örnek girdi seti kesiti [40].

Girdiler ile Eğitilen Günler								
Girdi Adı	Saat	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
1 Gün Öncesinin PTF Verileri	0	196,1	170,9	169,93	169,95	210,14	169,99	210,15
	1	149,98	144,98	144,85	148,48	169,95	146,98	186,13
	2	123,96	123,95	120,55	128	141,99	130,25	169,95
	3	12,59	5,1	18,07	40	3,5	29,99	123,95
	4	7	20,14	18,36	13,61	4,33	5,02	69,99
	5	49,92	69,99	39,99	69,99	5	5,09	60
	6	49,91	40	39,99	69,99	2,85	1,88	70
	7	130,01	121,16	100,06	89,62	39,99	69,99	99,92
	8	145	140,01	119,96	39,99	19,99	164,16	138,24
	9	180,89	210,14	191,99	179,99	116,82	179,99	175
	10	219,91	200,15	200,15	200,14	142,85	199,92	200,14
	11	219,92	210,14	204,98	220,01	175	225,24	220,01
	12	126,31	119,99	119,98	169,94	169,97	169,95	169,92
	13	161,25	140	100,04	174,94	174,99	175	169,97
	14	188,63	184,99	184,99	179,98	169,9	204,96	185,05
	15	185,06	184,99	175	140,01	158,6	194,99	169,93
	16	169,68	158,04	169,91	100,05	147,43	174,99	119,91
	17	169,91	164,16	123,96	123,96	88,99	169,9	40
	18	102,04	100,06	119,98	70	69,99	140,01	123,96
	19	40	89	119,98	130,24	115	120	123,95
	20	143,25	129,99	155,62	179,98	175,01	146,92	127,99
	21	115,48	123,96	152,01	148,48	185,06	127,99	120
	22	126,31	114,99	150	148,12	185,05	146,98	119,99
	23	114,99	70	119,98	114,99	140	119,99	69,99

Çizelge 4.2: 7 gün öncesine ait PTF'lere ilişkin örnek girdi seti kesiti [40].

Girdiler ile Eğitilen Günler								
Girdi Adı	Saat	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
7 Gün Öncesinin PTF Verileri	0	154,99	161,99	161,98	140	49,97	100,02	196,1
	1	134,99	135	134,97	102,05	30	40	149,98
	2	123,95	102,04	100,06	98,76	29,99	32,95	123,96
	3	50,01	49,94	39,99	3,01	0,46	0,76	12,59
	4	50	43,56	34,14	3,01	0,25	0,65	7
	5	74,98	53,96	29,99	5,06	0,8	0,6	49,92
	6	100,04	53,97	39,99	5,03	1,09	5,08	49,91
	7	134,99	100,01	40	5,1	20,15	39,99	130,01
	8	169,67	100,01	45,66	5,02	109,99	123,96	145
	9	210,15	186,34	159,73	100,04	190,53	190,34	180,89
	10	225,11	190,54	169,93	117,83	200,14	174,93	219,91
	11	225,73	190,54	169,95	120,78	210,14	190,34	219,92
	12	134,99	100	53,97	120,12	149,42	100,01	126,31
	13	137,48	53,97	119,99	109,99	175	109,99	161,25
	14	163,09	119,98	100,04	104,98	190,55	153,73	188,63
	15	175	110	100	107,31	190,55	175	185,06
	16	168,65	110	53,97	120,77	135,24	163,04	169,68
	17	123,96	100,05	40	70	146,22	147,46	169,91
	18	123,95	100	51,1	99,92	100,03	115	102,04
	19	123	53,97	90,1	120,77	40	115	40
	20	154,99	102,92	160,89	169,93	174,67	163,07	143,25
	21	153,31	100,03	148,99	169,91	154,99	146,04	115,48
	22	115	105	123,96	140	154,75	115	126,31
	23	123,95	80,02	77,54	119,93	123,96	120	114,99

Fiyat tahmini uygulamasının yapılacağı güne ilişkin karakteristik özellikler saatlik bazda fiyatların oluşumunu etkilediği için girdi veri setinde gün tipleri çeşitli şekillerde ayrıştırılmıştır. Bunlardan ilki haftanın günlerine göre ayrıştırma değildir. Çizelge 4.3'te gösterildiği üzere, haftanın günleri için 1'den 7'ye kadar etiketleme yapılarak Pazartesi-Pazar olmak üzere tüm gün tiplerinin ve özellikle hafta sonu günlerinin belirlenmesi sağlanmıştır.

Çizelge 4.3: Gün tiplerine ilişkin örnek girdi seti kesiti.

Girdiler ile Eğitilen Günler							
Girdi Adı	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
Gün Tipi	5	6	7	1	2	3	4

Günleri ayrıştırmakta kullanılan diğer bir girdi seti puant dışı saatlerde talebin nispeten artış gösterdiği Ramazan ayına denk gelen günleri belirlemek amacıyla oluşturulmuştur. Çizelge 4.4'teki örnek kesitte de gösterildiği üzere, 6 Haziran-5

Temmuz 2016 arasındaki günler 1, diğer günler 0 olarak işaretlenmek üzere girdi seti hazırlanmıştır.

Çizelge 4.4: Ramazan ayına ait gün tiplerine ilişkin örnek girdi seti kesiti.

Girdiler ile Eğitilen Günler							
Girdi Adı	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
Ramazan Ayı Gün Tipi	0	0	0	0	1	1	1

Gün tipleri için hazırlanan diğer girdi seti ise talebin aykırı düşüş gösterdiği bayram veya resmi tatillere denk gelen günleri belirlemek için kullanılmıştır. Çizelge 4.5'teki örnek kesitte gösterildiği üzere, 5-8 Temmuz 2016 Şeker Bayramı ve 12-16 Eylül 2016 Kurban Bayramı günleri 1, diğer günler 0 olarak işaretlenmek üzere girdi seti hazırlanmıştır.

Çizelge 4.5: Bayram gün tiplerine ilişkin örnek girdi seti kesiti.

Girdiler ile Eğitilen Günler							
Girdi Adı	10.09.2016	11.09.2016	12.09.2016	13.09.2016	14.09.2016	15.09.2016	16.09.2016
Bayram Gün Tipi	0	0	1	1	1	1	0

YSA modeline girdi seti olarak seçilen bir diğer parametre bir gün öncesinin aynı saati için gerçekleşmiş toplam enerji talep miktarıdır. Ağın eğitim sürecindeki toplam talep 17.797MW'tan 44.341MW'a kadar değişmektedir. Çizelge 4.6'da örnek girdi seti kesiti gösterilen bu veriler EPIAŞ tarafından kamuya açık bir şekilde paylaşılmakta olan platformdan alınmıştır [41].

Girdi seti olarak seçilen bir diğer parametre doğalgaz kaynaklı üretim yapan santrallerin yakıt maliyetidir. Enerji üretim santralleri değişken üretim maliyetlerini baz alarak oluşturdukları enerji satış tekliflere göre sıralanarak her saat için ayrı arz talep eğrileri oluşturulmaktadır. Mevcut piyasa koşullarında talebin yükseldiği saatlerde arz eğrisinde yer alan doğalgaz kaynaklı enerji üretim santrallerinin teklifleri marjinal teklif olarak ilgili saatteki fiyatı belirleyecektir. Talebin yükselmesi durumuyla birlikte arz eğrisindeki daha düşük verimli doğalgaz santrallerinin yüksek maliyetlerine dayanan teklifleri marjinal teklif olacak ve ilgili saatte ait PTF daha yüksek bir arz-talep kesişim değerinde belirlenecektir. Bu açıdan bakıldığında doğalgaz maliyeti dikkate alınması gereken girdi elemanlarından bir tanesidir.

Çizelge 4.6: Bir gün öncesi toplam talep miktarına ilişkin örnek girdi seti kesiti [41].

Girdiler ile Eğitilen Günler								
Girdi Adı	Saat	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
Toplam Talep Miktarı (MW)	0	28.635	28.965	28.487	27.424	27.231	29.224	29.396
	1	26.978	27.152	26.999	25.775	26.151	28.367	28.369
	2	26.061	26.109	26.003	24.569	25.849	27.556	27.873
	3	25.249	25.354	25.198	23.735	24.770	26.652	27.015
	4	24.993	25.122	24.874	23.428	23.621	25.570	25.815
	5	24.413	24.465	24.105	22.267	22.173	24.139	24.302
	6	24.654	24.726	23.957	21.843	22.280	23.923	23.922
	7	27.139	26.896	25.323	22.350	24.482	25.430	25.473
	8	31.025	31.410	29.420	23.931	29.478	29.380	29.691
	9	34.532	34.243	32.121	25.793	32.362	31.704	32.066
	10	35.299	35.409	33.180	27.414	33.620	32.939	33.010
	11	35.958	35.775	34.038	27.971	34.771	33.709	33.881
	12	34.544	34.173	32.823	27.864	33.520	32.565	32.913
	13	35.144	33.469	32.806	28.034	34.255	33.113	33.262
	14	35.964	35.388	32.725	27.883	35.001	33.851	33.994
	15	35.466	34.976	31.858	27.438	34.724	33.428	33.707
	16	35.167	34.440	31.210	27.178	34.294	33.131	33.180
	17	34.107	32.966	30.188	26.779	33.377	32.142	32.461
	18	32.726	31.058	29.709	26.991	32.341	31.456	32.032
	19	32.416	30.766	29.795	27.698	32.236	31.495	31.898
	20	33.378	32.082	31.214	29.464	31.477	31.037	31.317
	21	33.620	32.513	31.363	30.313	31.939	31.732	31.915
	22	32.819	32.115	30.954	29.893	32.104	32.052	32.254
	23	31.329	30.582	29.508	28.622	30.842	30.051	30.765

TEP'teki doğalgaz santralleri yakıt tedariklerini büyük oranla BOTAŞ'tan sağladıklarından, girdi grubunda da yine BOTAŞ'ın büyük serbest tüketicilere uyguladığı aylık doğalgaz satış tarifesi kullanılmıştır. 01.06.2016 ile 30.09.2016 arasında 0,782383 TL/Sm³ olan gaz maliyetinin 01.10.2016 itibarıyla 0,704145 TL/Sm³ e düşürülerek %10 indirim yapılmasının PTF'ler üzerindeki etkisi YSA modelinin eğitilmesinde kullanılmıştır. Çizelge 4.7'de örnek girdi seti kesiti gösterilmiştir.

Çizelge 4.7: Doğal gaz maliyetine ilişkin örnek girdi seti kesiti [42].

Girdiler ile Eğitilen Günler							
Girdi Adı	28.09.2016	29.09.2016	30.09.2016	1.10.2016	2.10.2016	3.10.2016	4.10.2016
BOTAŞ'ın Kademe-2 Serbest Tüketicilere Uyguladığı Doğalgaz Satış Tarifesi (TL/Sm³)	0,782383	0,782383	0,782383	0,704145	0,704145	0,704145	0,704145

Son girdi grubu olarak mevsimsel dalgalanmanın etkilerini fiyat tahmini uygulamasına da yansıtılabilmek amacıyla ülke geneli ortalama sıcaklık değerleri hazırlanmıştır. Ağın eğitim sürecindeki sıcaklıklar 3.65 °C ile 33.35 °C arasında değişmektedir. Böylelikle sıcaklık artışı veya düşüşü yaşanan saatlerde enerji talebinde beklenen artışın sonucu olarak, fiyatların ne ölçüde yükseldiği modele tanıtılmıştır. Çizelge 4.8’de örnek girdi seti kesiti gösterilmiştir.

Çizelge 4.8: Ülke geneli ortalama sıcaklık değerleri ilişkin örnek girdi seti kesiti.

Girdiler ile Eğitilen Günler								
Girdi Adı	Saat	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
Türkiye Geneli Ortalama Sıcaklık (°C)	0	19,3	19,5	18,1	17,9	17,6	18,3	16,6
	1	19,0	19,2	17,7	17,5	17,3	18,0	16,2
	2	18,7	18,7	17,3	17,1	16,9	17,7	15,8
	3	18,3	18,1	16,8	16,7	16,5	17,3	15,4
	4	18,1	17,8	16,6	16,4	16,3	17,0	15,2
	5	18,5	18,2	17,0	16,7	16,7	17,2	15,3
	6	19,6	19,4	18,0	17,7	17,9	17,8	16,1
	7	21,2	21,1	19,5	19,1	19,6	18,7	17,2
	8	22,8	22,9	21,1	20,6	21,2	19,8	18,3
	9	24,3	24,2	22,3	21,7	22,3	20,7	19,1
	10	25,3	25,1	23,1	22,6	23,2	21,3	19,7
	11	26,2	25,6	23,6	23,2	23,7	21,6	20,1
	12	26,8	25,8	23,8	23,7	24,1	21,6	20,3
	13	27,1	25,8	23,8	24,2	24,5	21,6	20,4
	14	27,3	25,5	23,8	24,4	24,6	21,5	20,5
	15	27,2	25,2	23,8	24,4	24,5	21,4	20,4
	16	26,7	24,6	23,7	24,1	24,0	21,2	20,1
	17	25,9	23,7	23,3	23,4	23,4	20,9	19,7
	18	24,8	22,6	22,3	22,3	22,4	20,2	18,9
	19	23,4	21,4	21,2	21,1	21,4	19,4	18,1
	20	22,1	20,3	20,1	19,9	20,4	18,6	17,3
	21	21,1	19,5	19,2	19,0	19,6	18,0	16,6
	22	20,4	18,9	18,6	18,4	19,0	17,4	16,0
	23	19,9	18,5	18,2	17,9	18,6	17,0	15,5

4.2 Kullanılan YSA Özellikleri

Bu çalışmada YSA simulatörü olarak MATLAB (R2015b)-Neural Network Tool Box kullanılmıştır. YSA simulatörü 8 GB RAM ve Intel® Core™ i5 2.3 GHz işlemcinin kullanıldığı 64 bit Windows 10 Enterprise işletim sistemi ortamında çalıştırılmıştır. Uygulamada oluşturulan YSA şu özelliklerle hazırlanmıştır:

- Uygulanan YSA modelinde ağın eğitilme sürecinin daha verimli olması amacıyla geriye yayılma algoritması kullanılmıştır. Model geleneksel Scaled Conjugate Gradient (SCG) geri yayılma metodu yerine Levenberg-Marquardt


(LM) geri yayılma metodu ile eğitilerek daha hızlı çözüme ulaşılması sağlanmıştır. Modeli Levenberg-Marquardt (LM) algoritması ile eğitmek daha fazla bellek gerektirmekle birlikte eğitimin daha hızlı tamamlanmasını sağlamaktadır. LM algoritması kullanıldığında eğitim sürecinde genelleştirmenin iyileşmediği noktada eğitim otomatik olarak sonlandırılmaktadır. Genelleştirmenin iyileşmediği ise doğrulama örneklerinin ortalama karesel hatasında (MSE) artış olması ile tespit edilmiştir. Bunun için modelin eğitilmesinde performans fonksiyonu olarak MSE tercih edilmiştir.

MSE, çıktı değerleri ile hedef katmanı arasındaki farkın karelerinin ortalamasıdır. Ortalama karesel hatanın düşük olması modelin tahmin performansının yüksek olduğunu göstermektedir.

- b) Regresyon değerleri çıktı değerleri ile hedef katmanı arasındaki korelasyonu ölçmektedir. R değerinin 1'e yakın olması çıktı değerleri ile hedef katmanı arasındaki yakın ilişki olduğuna işaret etmektedir.
- c) YSA modelindeki verilerin %70'i eğitim için, %15'i doğrulama için ve geriye kalan %15'i de test için kullanılacak şekilde yapılandırılmıştır.
- d) Evrensel Yaklaşımlar Teorisine (*Universal Approximation Theorem*) göre tek gizli katmanlı yapıdaki bir ağ; eğer gizli katmanında yeterince sayıda nörona sahip olursa, girdi-çıkı ilişkilerinin verimli bir şekilde yorumlanmasını sağlayabilir [43]. Model tek gizli katmanlı olacak şekilde dizayn edilmiştir. Gizli ara katmandaki nöron sayısı çıktı katmanından alınacak sonuçları etkileyeceğinden, optimum sonuca ulaşmak için ara katmandaki nöron sayısı değiştirilerek duyarlılık analizi yapılmıştır. Tek gizli katmanında 7, 10, 20, 22 ve 25 olmak üzere farklı nöron sayıları ile olmak üzere beş farklı deneme yapılarak en iyi performansa ulaşılmaya çalışılmıştır.
- e) Bu çalışmada oluşturulan tek gizli katmanlı YSA modelinin doğrusal olmayan karakteristiği dolayısıyla Log-sigmoid transfer fonksiyonu (Logsig) kullanılmıştır. Bu transfer fonksiyonu artı sonsuzdan eksi sonsuza kadar olan girdi verilerini aldıktan sonra çıktı verilerini 0 ile 1 arasına sıkıştırarak sonuçlandırmaktadır.

4.3 Uygulama Aşamaları

Bu çalışmada uygulanacak YSA fiyat tahmini modelleme adımlarına ilişkin akış diyagramı Şekil 4.2’de gösterilmektedir.



Şekil 4.2: YSA fiyat tahmini modelleri akış diyagramı.

4.4 YSA Modeli Tahmin Performans Faktörü

Uygulanan bu çalışmada yapılan tahminlerin performansı hesaplanan Ortalama Mutlak Yüzde Hata (MAPE) değerlerinin karşılaştırılarak yorumlanması ile değerlendirilecektir. Hesaplanan MAPE değerleri tahmin edilen değerlerinin gerçekleşmiş değerlere yüzdesel olarak yakınlığını ifade etmektedir. MAPE yüzdesinin olabildiğince 0’a yakın olması tahmin performansının yüksek olduğunu göstermektedir. MAPE değerleri şu şekilde hesaplanmaktadır:

$$PE = \frac{y_{tahmin} - y_{gerçek}}{y_{gerçek}} \% \quad (4.1)$$

$$APE = |PE| \quad (4.2)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N APE_i \quad (4.3)$$


y_{tahmin} : tahmin edilen PTF değeri

$y_{gerçek}$: gerçek PTF değeri

N : veri adeti

4.5 Gizli Katman Eniyilemesi İçin Denenen Seçenekler

Tek gizli katmanda 7, 10, 20, 22 ve 25 nöron sayıları ile beş farklı deneme yapılarak model sonuçları karşılaştırılmış ve en iyi performansa ulaşılmaya çalışılmıştır. Şekil 4.3'te uygulanan YSA yapısı gösterilmektedir.



Şekil 4.3: Uygulanan YSA modeli yapısı.

$$S_{girdi} = [P_i, H_i, GT, R, B, TM_i, DG, S_i] \quad (4.4)$$

i : Saat sayısı; 1-24

Uygulaması yapılan YSA modelinine ilişkin öğrenme girdi veri grubu Bölüm 4.1.2'de belirtilen sekiz tip veriden oluşmaktadır. P_i , H_i , TM_i ve S_i saatlik girdiler olduğundan 24'er adetten 96 adet olduğundan; GT , R , B , DG ile birlikte toplam 100 adet girdi değeri bulunmaktadır.

1 Haziran 2016 ile 28 Kasım 2016 aralığındaki S_{girdi} öğrenme veri seti ağa gösterilerek ağın öğrenme aşaması tamamlanmıştır.

Öğrenme aşamasının tamamlanmasının ardından ağın performansının ölçülüp değerlendirilmesine geçilmiştir. Burada öncelikle öğrenme veri setinde yer alan son 15 günün tahmin performansı test edilmiştir. Ardından öğrenme veri setinde yer almayan, ağın hiç görmediği bir günün PTF'leri için ağın tahmin performansı ölçülmüştür.

14 Kasım 2016 ile 28 Kasım 2016 aralığındaki 15 günlük periyottaki ağın çıktı değerleri test veri seti olarak kullanılmıştır. Bu aşamada, ağda gerçekleşen çıktılar beklenen çıktılar ile karşılaştırılarak ağın ürettiği hata değerleri hesaplanmıştır. Ağın performans ölçümü için MAPE değerleri hesaplanarak karşılaştırmalar yapılmıştır.


4.5.1 Gizli katmanı 7 nöronlu YSA modeli sonuçları

YSA modelinin gizli katmanı içerisindeki nöron sayısı 7 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin} 'lere ilişkin Şekil 4.4'deki sonuçlar elde edilmiştir.

YSA modelinin gizli katmanı içerisindeki nöron sayısı 7 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.9'da görülmektedir.

Çizelge 4.9: 7 Nöronlu YSA modelinde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	150,44	14,27
15.11.2016	142,66	143,22	7,13
16.11.2016	151,70	147,90	5,75
17.11.2016	157,95	166,76	9,55
18.11.2016	167,70	164,22	6,97
19.11.2016	150,00	153,22	7,63
20.11.2016	131,36	136,11	12,70
21.11.2016	159,52	165,49	14,94
22.11.2016	157,51	169,88	11,25
23.11.2016	163,83	162,40	5,75
24.11.2016	168,87	172,29	8,19
25.11.2016	186,17	174,21	7,30
26.11.2016	178,49	167,62	7,90
27.11.2016	129,32	139,04	20,38
28.11.2016	163,48	158,18	8,75
Ortalama	157,07	158,07	9,90



Şekil 4.4: 7 Nöronlu YSA modelinde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


4.5.2 Gizli katmanı 10 nöronlu YSA modeli sonuçları

YSA modelinin gizli katmanı içerisindeki nöron sayısı 10 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin} 'lere ilişkin Şekil 4.5'deki sonuçlar elde edilmiştir.

YSA modelinin gizli katmanı içerisindeki nöron sayısı 10 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.10'da görülmektedir.

Çizelge 4.10: 10 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	143,01	19,07
15.11.2016	142,66	131,72	13,84
16.11.2016	151,70	140,81	11,72
17.11.2016	157,95	154,07	15,50
18.11.2016	167,70	150,22	12,93
19.11.2016	150,00	141,10	14,54
20.11.2016	131,36	130,48	13,50
21.11.2016	159,52	147,65	29,13
22.11.2016	157,51	145,23	13,42
23.11.2016	163,83	154,08	13,05
24.11.2016	168,87	152,30	12,69
25.11.2016	186,17	163,79	13,05
26.11.2016	178,49	157,56	12,75
27.11.2016	129,32	133,12	23,50
28.11.2016	163,48	147,67	12,50
Ortalama	157,07	146,19	15,41



Şekil 4.5: 10 Nöronlu YSA modelinde tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


4.5.3 Gizli katmanı 20 nöronlu YSA modeli sonuçları

YSA modelinin gizli katmanı içerisindeki nöron sayısı 20 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin} 'lere ilişkin Şekil 4.6'deki sonuçlar elde edilmiştir.

YSA modelinin gizli katmanı içerisindeki nöron sayısı 20 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.11'da görülmektedir.

Çizelge 4.11: 20 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	154,26	13,25
15.11.2016	142,66	149,77	7,31
16.11.2016	151,70	153,34	5,16
17.11.2016	157,95	161,99	4,38
18.11.2016	167,70	168,15	2,98
19.11.2016	150,00	150,99	5,85
20.11.2016	131,36	134,43	9,44
21.11.2016	159,52	170,90	17,28
22.11.2016	157,51	160,94	5,17
23.11.2016	163,83	165,07	3,63
24.11.2016	168,87	165,13	5,99
25.11.2016	186,17	168,54	10,73
26.11.2016	178,49	153,80	15,50
27.11.2016	129,32	141,72	23,21
28.11.2016	163,48	164,96	3,73
Ortalama	157,07	157,60	8,91



Şekil 4.6: 20 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.


4.5.4 Gizli katmanı 22 nöronlu YSA modeli sonuçları

YSA modelinin gizli katmanı içerisindeki nöron sayısı 22 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin} 'lere ilişkin Şekil 4.7'deki sonuçlar elde edilmiştir.

YSA modelinin gizli katmanı içerisindeki nöron sayısı 22 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.12'da görülmektedir.

Çizelge 4.12: 22 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	140,83	22,48
15.11.2016	142,66	151,10	10,40
16.11.2016	151,70	142,62	8,51
17.11.2016	157,95	159,86	3,31
18.11.2016	167,70	167,04	2,51
19.11.2016	150,00	149,74	4,10
20.11.2016	131,36	135,23	7,39
21.11.2016	159,52	165,35	13,72
22.11.2016	157,51	160,90	7,27
23.11.2016	163,83	165,63	4,44
24.11.2016	168,87	169,04	3,43
25.11.2016	186,17	182,13	7,51
26.11.2016	178,49	175,95	4,17
27.11.2016	129,32	138,29	19,80
28.11.2016	163,48	165,29	4,41
Ortalama	157,07	157,93	8,23



Şekil 4.7: 22 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.


4.5.5 Gizli katmanı 25 nöronlu YSA modeli sonuçları

YSA modelinin gizli katmanı içerisindeki nöron sayısı 25 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin} 'lere ilişkin Şekil 4.8'deki sonuçlar elde edilmiştir.

YSA modelinin gizli katmanı içerisindeki nöron sayısı 25 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.13'da görülmektedir.

Çizelge 4.13: 25 Nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	142,51	17,21
15.11.2016	142,66	139,97	9,32
16.11.2016	151,70	143,92	7,56
17.11.2016	157,95	152,11	8,08
18.11.2016	167,70	163,08	6,64
19.11.2016	150,00	145,26	8,94
20.11.2016	131,36	139,84	19,12
21.11.2016	159,52	159,89	16,98
22.11.2016	157,51	154,18	8,76
23.11.2016	163,83	156,10	7,76
24.11.2016	168,87	162,97	7,89
25.11.2016	186,17	167,41	10,98
26.11.2016	178,49	162,71	10,58
27.11.2016	129,32	143,02	33,72
28.11.2016	163,48	143,03	13,30
Ortalama	157,07	151,73	12,45



Şekil 4.8: 25 Nöronlu YSA modelinde eğitimin Son 15 gününde günlük bazda fiyat tahmini performansı.

4.5.6 Gizli katman eniyilemesi sonuçları

Bölüm 4.4.1 ile 4.4.5 arasında 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde elde edilen PTF tahmini performans sonuçları karşılaştırmaları elde edilen MAPE değerleri üzerinden Çizelge 4.14'te karşılaştırılarak gösterilmektedir. Buna göre en iyi performans, en düşük MAPE değerine ulaşılan 22 nöronlu YSA modelinde gösterilmiştir.

Çizelge 4.14 : 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde seçilen 15 günlük test veri grubunda ortalama MAPE değerleri.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performans Testi Sonuçları					
	7 Nöron	10 Nöron	20 Nöron	22 Nöron	25 Nöron
MAPE %	9,90	15,41	8,91	8,23	12,45

4.6 Girdi Setinin İyileştirme Çalışması

Ağın en iyi performansını gizli katmanında 22 nöron bulunan topoloji ile elde edildiğine göre girdi elemanlarının değişimi bu modelde denenecektir.

Girdi setinde toplam talep miktarlarının doğrudan kullanılması yerine bir ön işleme tabi tutularak daha sağlıklı girdiler elde edilmeye çalışılmıştır. Bu amaçla sürekli olmayan yenilenebilir enerji arzı içinde önemli oranda etkili olan rüzgar enerjisi kaynaklı üretim miktarı ilgili saate ilişkin talep miktarından çıkartılarak, geriye kalan net talebe göre girdi seti hazırlanmasına karar verilmiştir [12]. Ağın eğitim sürecindeki net talep 15.413MW'tan 43.294MW'a kadar değişmektedir. Saatlik talep ve rüzgâr üretimlerine ait veriler EPIAŞ tarafından kamuya açık bir şekilde paylaşılmakta olan platformlardan alınmıştır [41,44].

$$NTM_i = TM_i - RM_i \quad (4.5)$$

NTM_i : Bir gün öncesinin aynı saati için gerçekleşmiş net enerji talep miktarı

RM_i : Bir gün öncesinin aynı saati için gerçekleşmiş rüzgar enerjisi üretim miktarı

$$S_{girdi*} = [P_i, H_i, GT, R, B, NTM_i, DG, S_i] \quad (4.6)$$

i : Saat sayısı; 1-24

TM_i girdileri yerine NTM_i girdi verilerini içeren yeni S_{girdi}* seti kullanılmasının Bölüm 4.4'te uygulanan 7, 10, 20, 22 ve 25 nöron sayıları YSA modelleri denemelerinin performans sonuçlarına etkileri ölçülecektir.


NTM_i girdi verilerine ilişkin örnek girdi seti kesiti Çizelge 4.15'te gösterilmiştir.

Çizelge 4.15: Bir gün öncesi net enerji talep miktarına ilişkin örnek girdi seti kesiti [41,44].

Girdiler ile Eğitilen Günler								
Girdi Adı	Saat	2.06.2016	3.06.2016	4.06.2016	5.06.2016	6.06.2016	7.06.2016	8.06.2016
Net Enerji Talep Miktarı (MW)	0	28.152	28.126	27.917	26.779	26.560	28.572	26.121
	1	26.494	26.491	26.499	25.182	25.608	27.752	25.331
	2	25.585	25.552	25.598	23.957	25.340	26.999	24.905
	3	24.702	24.823	24.859	23.065	24.281	26.090	24.029
	4	24.408	24.628	24.584	22.724	23.152	24.822	22.780
	5	23.807	23.996	23.860	21.602	21.723	23.206	21.295
	6	24.043	24.330	23.740	21.297	21.800	23.006	21.032
	7	26.543	26.484	25.166	21.943	24.082	24.458	22.659
	8	30.477	30.903	29.311	23.658	29.140	28.313	26.793
	9	34.136	33.704	32.036	25.586	32.046	30.532	29.113
	10	34.851	34.768	33.085	27.159	33.294	31.606	30.077
	11	35.358	35.029	33.845	27.529	34.387	32.297	30.963
	12	33.777	33.176	32.469	27.387	33.035	30.990	29.979
	13	34.150	31.992	32.236	27.470	33.583	31.308	30.393
	14	34.807	33.381	31.923	27.163	34.102	31.725	30.875
	15	34.181	32.875	30.960	26.541	33.683	31.096	30.540
	16	33.795	32.296	30.359	26.134	33.186	30.272	29.883
	17	32.719	30.850	29.396	25.657	32.272	28.988	29.062
	18	31.534	29.478	28.956	25.884	31.359	28.198	28.591
	19	31.286	29.590	29.086	26.635	31.247	28.113	28.461
	20	32.233	31.150	30.493	28.333	30.386	27.656	27.906
	21	32.533	31.782	30.609	29.235	31.005	28.372	28.698
	22	31.826	31.458	30.277	28.953	31.402	28.762	29.122
	23	30.477	29.982	28.844	27.872	30.213	26.837	27.923

4.6.1 Gizli katmanı 7 nöronlu YSA modeli sonuçları

NTM_i girdi verilerini içeren yeni S_{girdi}* setinin kullanıldığı YSA modelinin gizli katmanı içerisindeki nöron sayısı 7 olarak belirlendiğinde, eğitimin son 15 günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin}'lere ilişkin Şekil 4.9'deki sonuçlar elde edilmiştir.



Şekil 4.9: NTM₁ girdi verilerini içeren S_{girdi}* setinin kullanıldığı 7 nöronlu YSA modelinde eğitimin son 15 gününde

(14.11.2016 - 28.11.2016) tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modelinde, gizli katman içerisindeki nöron sayısı 7 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.16'da görülmektedir.

Çizelge 4.16: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 7 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	134,24	20,92
15.11.2016	142,66	130,89	13,47
16.11.2016	151,70	130,85	14,89
17.11.2016	157,95	151,61	9,52
18.11.2016	167,70	154,73	9,94
19.11.2016	150,00	142,81	10,42
20.11.2016	131,36	128,27	12,26
21.11.2016	159,52	151,90	19,10
22.11.2016	157,51	137,29	16,38
23.11.2016	163,83	155,20	10,24
24.11.2016	168,87	155,80	13,72
25.11.2016	186,17	170,63	12,20
26.11.2016	178,49	157,47	14,37
27.11.2016	129,32	128,48	22,09
28.11.2016	163,48	157,60	12,45
Ortalama	157,07	145,85	14,13

4.6.2 Gizli katmanı 10 nöronlu YSA modeli sonuçları

NTM_i girdi verilerini içeren yeni S_{girdi*} setinin kullanıldığı YSA modelinin gizli katmanı içerisindeki nöron sayısı 10 olarak belirlendiğinde, eğitimin son 15 günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin}'lere ilişkin Şekil 4.10'daki sonuçlar elde edilmiştir.



Şekil 4.10: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 10 nöronlu YSA modelinde eğitimin son 15 gününde (14.11.2016 - 28.11.2016) tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modelinde, gizli katman içerisindeki nöron sayısı 10 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.17'da görülmektedir.

Çizelge 4.17: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 10 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	151,22	14,18
15.11.2016	142,66	142,06	9,03
16.11.2016	151,70	149,08	9,25
17.11.2016	157,95	172,33	13,29
18.11.2016	167,70	166,95	6,59
19.11.2016	150,00	149,36	6,56
20.11.2016	131,36	133,71	10,63
21.11.2016	159,52	164,83	18,95
22.11.2016	157,51	156,43	10,34
23.11.2016	163,83	143,07	17,60
24.11.2016	168,87	166,57	6,42
25.11.2016	186,17	174,16	8,45
26.11.2016	178,49	171,56	9,15
27.11.2016	129,32	132,48	18,94
28.11.2016	163,48	162,03	9,62
Ortalama	157,07	155,72	11,27

4.6.3 Gizli katmanı 20 nöronlu YSA modeli sonuçları

NTM_i girdi verilerini içeren yeni S_{girdi*} setinin kullanıldığı YSA modelinin gizli katmanı içerisindeki nöron sayısı 20 olarak belirlendiğinde, eğitimin son 15 günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin}'lere ilişkin Şekil 4.11'daki sonuçlar elde edilmiştir.



Şekil 4.11: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 20 nöronlu YSA modelinde eğitimin son 15 gününde (14.11.2016 - 28.11.2016) tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modelinde, gizli katman içerisindeki nöron sayısı 20 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.18'da görülmektedir.

Çizelge 4.18: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 20 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	150,90	11,79
15.11.2016	142,66	145,71	5,35
16.11.2016	151,70	150,40	4,09
17.11.2016	157,95	158,94	5,16
18.11.2016	167,70	165,82	4,21
19.11.2016	150,00	151,52	7,72
20.11.2016	131,36	134,36	7,94
21.11.2016	159,52	150,50	19,58
22.11.2016	157,51	159,75	5,49
23.11.2016	163,83	168,12	5,47
24.11.2016	168,87	174,48	8,72
25.11.2016	186,17	178,46	4,92
26.11.2016	178,49	174,82	4,32
27.11.2016	129,32	137,94	19,38
28.11.2016	163,48	161,42	4,27
Ortalama	157,07	157,54	7,90

4.6.4 Gizli katmanı 22 nöronlu YSA modeli sonuçları

NTM_i girdi verilerini içeren yeni S_{girdi*} setinin kullanıldığı YSA modelinin gizli katmanı içerisindeki nöron sayısı 22 olarak belirlendiğinde, eğitimin son 15 günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin}'lere ilişkin Şekil 4.12'deki sonuçlar elde edilmiştir.



Şekil 4.12: NTM_i girdi verilerini içeren S_{girdi} * setinin kullanıldığı 22 nöronlu YSA modelinde eğitimin son 15 gününde (14.11.2016 - 28.11.2016) tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.


NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modelinde, gizli katman içerisindeki nöron sayısı 22 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.19'da görülmektedir.

Çizelge 4.19: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 22 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	136,72	25,72
15.11.2016	142,66	126,12	20,66
16.11.2016	151,70	134,83	21,05
17.11.2016	157,95	135,07	20,63
18.11.2016	167,70	135,23	21,10
19.11.2016	150,00	127,15	19,07
20.11.2016	131,36	130,52	18,63
21.11.2016	159,52	139,27	29,73
22.11.2016	157,51	137,83	22,85
23.11.2016	163,83	138,31	20,93
24.11.2016	168,87	139,00	22,03
25.11.2016	186,17	141,56	26,51
26.11.2016	178,49	135,46	27,38
27.11.2016	129,32	127,73	28,98
28.11.2016	163,48	138,77	22,61
Ortalama	157,07	134,91	23,19

4.6.5 Gizli katmanı 25 nöronlu YSA modeli sonuçları

NTM_i girdi verilerini içeren yeni S_{girdi*} setinin kullanıldığı YSA modelinin gizli katmanı içerisindeki nöron sayısı 25 olarak belirlendiğinde, eğitimin son 15 günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen saatlik bazda PTF'lerin oluşturduğu y_{tahmin}'lere ilişkin Şekil 4.13'daki sonuçlar elde edilmiştir.



Şekil 4.13: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 25 nöronlu YSA modelinde eğitimin son 15 gününde (14.11.2016 - 28.11.2016) tahmin edilen PTF'ler ile gerçekleşen PTF'lerin saatlik bazda karşılaştırılması.

NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modelinde, gizli katman içerisindeki nöron sayısı 25 olarak belirlendiğinde, eğitimin son 15 Günü olan 14.11.2016 ile 28.11.2016 günleri arasında tahmin edilen günlük bazda ortalama PTF'ler ve günlük tahmin performanslarını belirten MAPE'ler Çizelge 4.20'da görülmektedir.

Çizelge 4.20: NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı 25 nöronlu YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	150,46	29,80
15.11.2016	142,66	150,46	25,18
16.11.2016	151,70	157,60	25,77
17.11.2016	157,95	153,86	25,15
18.11.2016	167,70	157,96	22,64
19.11.2016	150,00	154,26	23,84
20.11.2016	131,36	150,46	31,35
21.11.2016	159,52	154,17	32,37
22.11.2016	157,51	154,50	25,25
23.11.2016	163,83	154,26	24,90
24.11.2016	168,87	154,26	24,07
25.11.2016	186,17	158,00	23,31
26.11.2016	178,49	150,46	25,33
27.11.2016	129,32	148,24	40,25
28.11.2016	163,48	158,94	27,78
Ortalama	157,07	153,86	27,13

4.6.6 Girdi setini iyileştirme çalışması sonuçları

NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı Bölüm 4.5.1 ile 4.5.5 arasında 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde elde edilen PTF tahmini performans sonuçları Çizelge 4.21'de özet şeklinde gösterilmektedir.

Buna göre en iyi performans, %7,90 ile en düşük MAPE değerine ulaşılan 20 nöronlu YSA modelinde gösterilmiştir.


Çizelge 4.21 : S_{girdi^*} setinin kullanıldığı 7, 10, 20, 22 ve 25 nöronlu ağ modellerinde seçilen 15 günlük test veri grubunda ortalama MAPE değerleri.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performans Testi Sonuçları					
	7 Nöron	10 Nöron	20 Nöron	22 Nöron	25 Nöron
MAPE %	14,13	11,27	7,90	23,19	27,13

4.7 Gizli Katman ve Girdi Seti İyileştirmesi Sonuçlarının Karşılaştırılması

Gizli katman ve girdi seti iyileştirmesi sonuçlarının karşılaştırıldığında en düşük MAPE değerine gizli katmanında 20 nöron bulunan NTM_i girdi verilerini içeren S_{girdi^*} setinin kullanıldığı YSA modelinde elde edildiği Şekil 4.14’de görülmektedir.

Diğer değişkenler sabit kaldığında rüzgar enerjisine dayalı üretiminin fiyat tahmini performansını yaklaşık %1 oranında iyileştirdiği görülmektedir.



Şekil 4.14: Gizli katman ve girdi seti iyileştirmesi sonuçlarının karşılaştırılması.

4.8 Tarihsel PTF’lerin YSA Modeline Etkileri

Ulaşılan en iyi model olan gizli katmanında 20 nöron bulunan, NTM_i girdi verilerini içeren S_{girdi^*} setinin kullanıldığı YSA modeli ele alındığında; bir gün öncesinin ve yedi gün öncesinin PTF fiyatlarının girdi olarak kullanılarak modelleme yapılmıştır.

Bu YSA modelinde tarihsel PTF fiyatlarından sadece 1 gün öncesi kullanıldığında veya yedi günden haftalık periyotlar halinde daha önce gerçekleşmiş fiyatlarda girdi setine dahil edildiğinde modelin performansını hangi yönde etkileyeceği incelenmiştir.

$$S_1 = [P_i, GT, R, B, NTM_i, DG, S_i] \quad (4.7)$$

$$S_2 = S_{girdi*} = [P_i, H_i, GT, R, B, NTM_i, DG, S_i] \quad (4.8)$$

$$S_3 = [P_i, H_i, H_{D_{14,i}}, GT, R, B, NTM_i, DG, S_i] \quad (4.9)$$

$$S_4 = [P_i, H_i, H_{D_{14,i}}, H_{D_{21,i}}, GT, R, B, NTM_i, DG, S_i] \quad (4.10)$$

$$S_5 = [P_i, H_i, H_{D_{14,i}}, H_{D_{21,i}}, H_{D_{28,i}}, GT, R, B, NTM_i, DG, S_i] \quad (4.11)$$

a) $H_{D_{14,i}}$: 14 gün öncesinin aynı saati için gerçekleşmiş PTF verisi (24 girdi değeri)

b) $H_{D_{21,i}}$: 21 gün öncesinin aynı saati için gerçekleşmiş PTF verisi (24 girdi değeri)

c) $H_{D_{28,i}}$: 28 gün öncesinin aynı saati için gerçekleşmiş PTF verisi (24 girdi değeri)

olarak ilaveten tanımlanmıştır.

S_1 girdi seti kullanıldığında elde edilen sonuçlar Çizelge 4.22’de görülmektedir.

Çizelge 4.22: S_1 setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	147,80	21,38
15.11.2016	142,66	139,47	14,80
16.11.2016	151,70	149,51	15,51
17.11.2016	157,95	157,86	17,40
18.11.2016	167,70	151,58	17,60
19.11.2016	150,00	143,08	14,73
20.11.2016	131,36	129,44	15,62
21.11.2016	159,52	153,67	25,76
22.11.2016	157,51	158,03	13,09
23.11.2016	163,83	161,47	14,38
24.11.2016	168,87	171,18	13,88
25.11.2016	186,17	166,79	19,21
26.11.2016	178,49	157,57	17,52
27.11.2016	129,32	132,95	21,97
28.11.2016	163,48	162,31	14,63
Ortalama	157,07	152,18	17,16

S₂, diğer ifadeyle S_{girdi*} seti kullanıldığında elde edilen sonuçlar Bölüm 4.6.6’te Çizelge 4.21’de gösterildiği gibi %7,9 MAPE ile sonuç vermiştir.

S₃ girdi seti kullanıldığında elde edilen sonuçlar Çizelge 4.23’de görülmektedir.

Çizelge 4.23: S3 setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	151,07	16,50
15.11.2016	142,66	153,65	18,28
16.11.2016	151,70	155,06	15,57
17.11.2016	157,95	164,56	15,88
18.11.2016	167,70	165,82	12,87
19.11.2016	150,00	148,52	13,84
20.11.2016	131,36	147,00	17,10
21.11.2016	159,52	159,10	16,20
22.11.2016	157,51	153,41	16,54
23.11.2016	163,83	157,80	16,62
24.11.2016	168,87	166,74	14,32
25.11.2016	186,17	166,97	10,74
26.11.2016	178,49	143,08	21,43
27.11.2016	129,32	148,77	26,84
28.11.2016	163,48	164,06	14,81
Ortalama	157,07	156,37	16,50

S₄ girdi seti kullanıldığında elde edilen sonuçlar Çizelge 4.24’de görülmektedir.

Çizelge 4.24: S4 setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.


Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	153,08	17,13
15.11.2016	142,66	146,63	13,59
16.11.2016	151,70	150,41	11,60
17.11.2016	157,95	149,99	14,94
18.11.2016	167,70	155,22	16,56
19.11.2016	150,00	145,21	15,71
20.11.2016	131,36	142,60	17,03
21.11.2016	159,52	149,55	14,19
22.11.2016	157,51	144,98	17,46
23.11.2016	163,83	149,86	13,71
24.11.2016	168,87	157,19	15,20
25.11.2016	186,17	154,55	16,72
26.11.2016	178,49	150,42	17,46
27.11.2016	129,32	145,18	33,78
28.11.2016	163,48	154,99	14,21
Ortalama	157,07	149,99	16,62

S₅ girdi seti kullanıldığında elde edilen sonuçlar Çizelge 4.25’de görülmektedir.

Çizelge 4.25: S5 setinin kullanıldığı YSA modelinde eğitimin son 15 gününde günlük bazda fiyat tahmini performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	151,21	19,44
15.11.2016	142,66	153,31	16,31
16.11.2016	151,70	156,18	13,88
17.11.2016	157,95	156,29	11,49
18.11.2016	167,70	156,29	11,71
19.11.2016	150,00	152,56	16,29
20.11.2016	131,36	145,29	17,06
21.11.2016	159,52	162,53	16,76
22.11.2016	157,51	158,15	16,64
23.11.2016	163,83	157,69	12,84
24.11.2016	168,87	158,30	12,54
25.11.2016	186,17	158,30	16,22
26.11.2016	178,49	157,69	15,03
27.11.2016	129,32	141,63	29,36
28.11.2016	163,48	162,66	15,70
Ortalama	157,07	155,21	16,08

S₁ , S₂ , S₃ , S₄ ve S₅ olmak üzere beş farklı zaman serisi girdi seti olarak kullanılarak oluşturulan YSA modellerinin sonuçları Şekil 4.15’te gösterilmiştir.



Şekil 4.15: Gizli katman ve girdi seti iyileştirmesi sonuçlarının karşılaştırılması.

S₁ , S₂ , S₃ , S₄ ve S₅ veri setleri kullanıldığında en iyi tahmin performansının %7,90 MAPE değeri ile yine S₂, yani S_{girdi*} girdi seti ile elde edildiği göze çarpmaktadır.

Bu bağlamda, 7 gün önce gerçekleşmiş fiyatları girdi setine ilave etmek MAPE oranını %17,16'dan %7,9'a düşürürken; 14, 21 ve 28 gün önce gerçekleşmiş PTF fiyatlarını girdi setine katmak hata performansını %16 seviyesinin üzerine çıkarmaktadır.

4.9 Optimum YSA Modelinin Eğitilmediği Günlerde Test Edilmesi


Bu bölümde eğitim sürecinde en iyi performansa sahip olan YSA modelinin eğitilmediği günlerde ileri yönlü test edilmesi amaçlanmaktadır. Bu sebeple S_{girdi*} girdi seti ile eğitilmiş gizli katmanı 20 nöron içeren MAPE performansı %7,90 olan model ile, seçilmiş 4 adet farklı günde 24 saatlik fiyat tahmini uygulaması yapılacaktır.

En iyi tahminleme yapan YSA modeli 29 Kasım 2016, 29 Aralık 2016, 29 Mart 2017, 29 Haziran 2017 günlerinde 24 saatlik bazda PTF tahmininde kullanılacaktır.

- a) 29 Kasım 2016 günü 24 saatlik bazda PTF tahmini performansı sonuçları Çizelge 4.26'da ve Şekil 4.16'te gösterilmiştir. 24 saatin ortalama MAPE değeri %5,21 olarak hesaplanmaktadır.

Çizelge 4.26: 29 Kasım 2016 günü 24 saatlik bazda PTF tahmini performansı.

Eğitilmemiş Bir Günde Saatlik Bazda Fiyat Tahmini Performansı			
29.11.2016	Gerçekleşen PTF (TL/MWh)	Tahmin Edilen PTF (TL/MWh)	APE %
29.11.2016 00:00	143,10	133,19	6,93
29.11.2016 01:00	110,00	107,47	2,30
29.11.2016 02:00	94,00	100,22	6,62
29.11.2016 03:00	90,10	90,29	0,21
29.11.2016 04:00	90,10	84,44	6,28
29.11.2016 05:00	94,00	108,92	15,87
29.11.2016 06:00	138,68	135,07	2,60
29.11.2016 07:00	143,11	166,62	16,43
29.11.2016 08:00	201,41	199,09	1,15
29.11.2016 09:00	210,00	215,37	2,56
29.11.2016 10:00	213,98	208,30	2,65
29.11.2016 11:00	215,26	217,47	1,03
29.11.2016 12:00	206,54	190,16	7,93
29.11.2016 13:00	203,50	218,68	7,46
29.11.2016 14:00	207,80	213,27	2,63
29.11.2016 15:00	205,48	204,07	0,68
29.11.2016 16:00	204,51	205,11	0,29
29.11.2016 17:00	209,97	216,31	3,02
29.11.2016 18:00	209,98	201,46	4,06
29.11.2016 19:00	206,51	200,05	3,13
29.11.2016 20:00	200,62	199,53	0,55
29.11.2016 21:00	167,16	153,24	8,33
29.11.2016 22:00	149,00	158,72	6,53
29.11.2016 23:00	145,00	122,24	15,70
MAPE			5,21




Şekil 4.16: 29 Kasım 2016 günü saatlik performans sonuçlarının karşılaştırılması.

- b) 29 Aralık 2016 günü 24 saatlik bazda PTF tahmini performansı sonuçları Çizelge 4.27’de ve Şekil 4.17’te gösterilmiştir. 24 saatin ortalama MAPE değeri %11,41 olarak hesaplanmaktadır.

Çizelge 4.27: 29 Kasım 2016 günü 24 saatlik bazda PTF tahmini performansı.

Eğitilmemiş Bir Günde Saatlik Bazda Fiyat Tahmini Performansı			
29.12.2016	Gerçekleşen PTF (TL/MWh)	Tahmin Edilen PTF (TL/MWh)	APE %
29.12.2016 00:00	209,79	188,07	10,35
29.12.2016 01:00	205,56	168,59	17,98
29.12.2016 02:00	202,16	155,18	23,24
29.12.2016 03:00	192,24	145,30	24,41
29.12.2016 04:00	145,00	144,16	0,58
29.12.2016 05:00	89,10	77,91	12,56
29.12.2016 06:00	145,00	179,54	23,82
29.12.2016 07:00	204,59	186,53	8,83
29.12.2016 08:00	211,23	171,61	18,76
29.12.2016 09:00	215,98	174,03	19,42
29.12.2016 10:00	217,67	183,79	15,56
29.12.2016 11:00	220,00	195,38	11,19
29.12.2016 12:00	214,36	219,46	2,38
29.12.2016 13:00	215,20	229,18	6,49
29.12.2016 14:00	216,82	214,13	1,24
29.12.2016 15:00	214,47	206,39	3,77
29.12.2016 16:00	220,10	186,58	15,23
29.12.2016 17:00	220,00	198,08	9,96
29.12.2016 18:00	219,02	195,12	10,91
29.12.2016 19:00	214,06	197,74	7,62
29.12.2016 20:00	209,83	212,14	1,10
29.12.2016 21:00	206,36	183,24	11,21
29.12.2016 22:00	202,75	188,72	6,92
29.12.2016 23:00	198,44	178,05	10,27
MAPE			11,41




Şekil 4.17: 29 Aralık 2016 günü saatlik performans sonuçlarının karşılaştırılması.

- c) 29 Mart 2017 günü 24 saatlik bazda PTF tahmini performansı sonuçları Çizelge 4.28’da ve Şekil 4.18’te gösterilmiştir. 24 saatin ortalama MAPE değeri %8,66 olarak hesaplanmaktadır.

Çizelge 4.28: 29 Mart 2017 günü 24 saatlik bazda PTF tahmini performansı.

Eğitilmemiş Bir Günde Saatlik Bazda Fiyat Tahmini Performansı			
29.03.2017	Gerçekleşen PTF (TL/MWh)	Tahmin Edilen PTF (TL/MWh)	APE %
29.3.2017 00:00	133,99	138,61	3,45
29.3.2017 01:00	130,95	135,95	3,82
29.3.2017 02:00	130,95	138,54	5,80
29.3.2017 03:00	111,49	125,43	12,50
29.3.2017 04:00	112,99	109,84	2,79
29.3.2017 05:00	115,00	107,14	6,83
29.3.2017 06:00	134,00	122,60	8,51
29.3.2017 07:00	125,00	114,08	8,73
29.3.2017 08:00	169,36	175,48	3,61
29.3.2017 09:00	200,08	188,74	5,67
29.3.2017 10:00	200,48	190,97	4,74
29.3.2017 11:00	200,64	210,28	4,80
29.3.2017 12:00	169,98	186,95	9,98
29.3.2017 13:00	174,68	188,95	8,17
29.3.2017 14:00	189,87	208,98	10,06
29.3.2017 15:00	159,98	175,25	9,54
29.3.2017 16:00	150,00	160,91	7,27
29.3.2017 17:00	134,00	144,18	7,60
29.3.2017 18:00	91,87	108,07	17,63
29.3.2017 19:00	114,35	134,14	17,31
29.3.2017 20:00	133,99	141,27	5,43
29.3.2017 21:00	114,99	133,24	15,87
29.3.2017 22:00	134,00	148,72	10,99
29.3.2017 23:00	133,99	156,44	16,75
MAPE			8,66




Şekil 4.18: 29 Mart 2017 günü saatlik performans sonuçlarının karşılaştırılması.

- d) 29 Haziran 2017 günü 24 saatlik bazda PTF tahmini performansı sonuçları Çizelge 4.29'da ve Şekil 4.19'te gösterilmiştir. 24 saatin ortalama MAPE değeri %6,96 olarak hesaplanmaktadır.


Çizelge 4.29: 29 Haziran 2017 günü 24 saatlik bazda PTF tahmini performansı.

Eğitilmemiş Bir Günde Saatlik Bazda Fiyat Tahmini Performansı			
29.06.2017	Gerçekleşen PTF (TL/MWh)	Tahmin Edilen PTF (TL/MWh)	APE %
29.6.2017 00:00	155,00	168,61	8,78
29.6.2017 01:00	155,01	132,95	14,23
29.6.2017 02:00	138,93	148,54	6,92
29.6.2017 03:00	138,94	154,43	11,15
29.6.2017 04:00	140,35	139,84	0,37
29.6.2017 05:00	100,00	87,14	12,86
29.6.2017 06:00	96,01	82,60	13,97
29.6.2017 07:00	180,15	144,08	20,02
29.6.2017 08:00	205,27	195,48	4,77
29.6.2017 09:00	207,98	198,74	4,44
29.6.2017 10:00	207,99	192,97	7,22
29.6.2017 11:00	207,98	210,28	1,10
29.6.2017 12:00	203,37	188,95	7,09
29.6.2017 13:00	206,73	210,95	2,04
29.6.2017 14:00	211,22	210,98	0,11
29.6.2017 15:00	210,10	225,25	7,21
29.6.2017 16:00	209,32	220,91	5,54
29.6.2017 17:00	205,79	224,18	8,94
29.6.2017 18:00	201,70	198,07	1,80
29.6.2017 19:00	201,25	184,14	8,50
29.6.2017 20:00	180,21	181,27	0,59
29.6.2017 21:00	161,88	153,24	5,34
29.6.2017 22:00	149,49	158,72	6,17
29.6.2017 23:00	144,95	156,44	7,93
MAPE			6,96



Şekil 4.19: 29 Haziran 2017 günü saatlik performans sonuçlarının karşılaştırılması.

En iyi tahminleme yapan YSA modeli 29 Kasım 2016, 29 Aralık 2016, 29 Mart 2017, 29 Haziran 2017 günlerinde 24 saatlik bazda PTF tahmininde kullanıldığında elde edilen günlük ortalama MAPE değerleri Şekil 4.20’de birlikte gösterilmektedir.




Şekil 4.20: 4 farklı günde YSA modeli tahmin sonuçlarının karşılaştırılması.

29 Aralık 2016 tarihi dışındaki diğer günlerde performans %10’un altında iken, 29 Aralık 2016 tarihinde %11,41 MAPE performansına ulaşılmıştır. 29 Aralık 2016 tarihinde hatanın artmasının sebebi doğal gaz krizi nedeniyle PTF fiyatlarının uç değerlere ulaşması ve bu aşırılıkların eğitim setine dahil edilmesi ile tahmin performansını olumsuz etkilemesidir.

4.10 Ağırlıklandırma Değerlerinin Bulunması

Ağırlıklar bir hücreye gelen bilginin önemini ve hücre üzerinde yaratacağı etkiyi gösterir. Ağırlık değerinin artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etki yaratmadığı anlamına gelmektedir [33].

Şekil 4.22’de YSA çalışma modelinde çıktı ve hedeflenen değerlerin karşılaştırılarak ağırlıkların ayarlanması gösterilmektedir.



Şekil 4.21: YSA çalışma modelinde ağırlıkların ayarlanması [14].

İleri beslemeli yapay sinir ağlarının matematiksel modeli olarak gösterimi Denklemler 4.2-4.9’da ve grafiksel olarak Şekil 4.22’de gösterilmektedir [17].

$$n_1 = F_1 (w_1 x_1 + b_1) \quad (4.12)$$

$$n_2 = F_2 (w_2 x_2 + b_2) \quad (4.13)$$

$$n_3 = F_2 (w_2 x_2 + b_2) \quad (4.14)$$


$$n_4 = F_3 (w_3 x_3 + b_3) \quad (4.15)$$

$$m_1 = F_4 (q_1 n_1 + q_2 n_2 + b_4) \quad (4.16)$$

$$m_2 = F_5 (q_3 n_3 + q_4 n_4 + b_5) \quad (4.17)$$


$$y = F_6 (r_1 m_1 + r_2 m_2 + b_6) \quad (4.18)$$

$$y = F_6 [r_1 (F_4 (q_1 F_1 (w_1 x_1 + b_1) + q_2 F_2 (w_2 x_2 + b_2) + b_4) + \dots + r_2 (F_5 (q_3 F_2 (w_2 x_2 + b_2) + q_4 F_3 (w_3 x_3 + b_3) + b_5) + b_6] \quad (4.19)$$



Şekil 4.22: İleri beslemeli YSA modeli katmanlar arası ağırlıklar [17].

Ulaşılan en iyi model olan gizli katmanında 20 nöron bulunan, S_{girdi^*} setinin kullanıldığı YSA modeli için ağırlıklandırmaların yapısı Şekil 4.23’de çizilmiştir.



Şekil 4.23: Önerilen 20 nöronlu YSA modelinin katmanları arası ağırlıkların yapısı.

i . girdi değişkeni ile gizli katmandaki j . nöron arasındaki bağlantının ağırlık vektörü Denklem 4.10'da belirtilmiştir.

$$w_{ij} = [w_{1,1}; w_{1,2}; \dots, w_{8,20}]^T \quad (4.20)$$

i : Girdi tipi; 1-8

j : Nöron sayısı; 1-20

Gizli katmandaki j . nöron ile k . çıktı değerleri arasındaki bağlantının ağırlık vektörü Denklem 4.11'de belirtilmiştir.

$$v_{jk} = [v_{1,1}; v_{1,2}; \dots, v_{20,24}]^T \quad (4.21)$$

k : Günün saati; 1-24

Gizli katmandaki nöronlar h_j terimi ile ifade edilmiştir. Gizli katmandaki j . nöronun sapma değeri ise $w_{0,j}$ terimi ile ifade edilmiştir. En iyi performansı gösteren YSA modelinde gizli katmandaki 20 nörona ilişkin sapma değerleri Çizelge 4.30'da gösterilmektedir.

Çizelge 4.30: En iyi performansı gösteren YSA modelinde gizli katmandaki 20 nörona ilişkin sapma değerleri.

	Sapma
w0,1	2,23
w0,2	-3,23
w0,3	-1,13
w0,4	2,45
w0,5	0,90
w0,6	0,44
w0,7	-0,94
w0,8	1,08
w0,9	1,05
w0,10	-1,89
w0,11	0,68
w0,12	-0,24
w0,13	2,15
w0,14	1,23
w0,15	1,72
w0,16	-2,48
w0,17	-3,00
w0,18	-1,69
w0,19	-3,81
w0,20	-2,57

Çıktı katmanı elemanları y_k terimi ile ifade edilmiştir. Çıktı katmanındaki k . saatin sapma ise $v_{0,k}$ terimi ile ifade edilmiştir. En iyi performansı gösteren YSA modelinde çıktı katmanındaki 24 saate ilişkin sapma değerleri Çizelge 4.31'da gösterilmektedir.

Çizelge 4.31: En iyi performansı gösteren YSA modelinde çıktı katmanındaki 24 saate ilişkin sapma değerleri.

Sapma	
v0,1	-6,10
v0,2	-6,05
v0,3	-10,62
v0,4	-9,49
v0,5	-7,21
v0,6	-4,97
v0,7	-6,72
v0,8	-1,53
v0,9	1,55
v0,10	4,26
v0,11	0,70
v0,12	2,60
v0,13	0,50
v0,14	0,70
v0,15	1,49
v0,16	1,76
v0,17	2,28
v0,18	1,27
v0,19	0,56
v0,20	-0,99
v0,21	0,22
v0,22	-0,27
v0,23	3,36
v0,24	-0,35

En iyi performansı gösteren 20 nöronlu modelde girdi değişkenleri ile gizli katmandaki *i.* nöron arasındaki bağlantının ağırlık matrisi Çizelge 4.32’de gösterilmiştir.

Çizelge 4.32: 8 adet girdi değişkeni ile gizli katmandaki 20 nöron arasındaki bağlantıların girdi ağırlık matrisi.

	P	H	GT	R	B	TM	S	DG
h1	0,17	- 0,01	- 0,00	- 0,06	0,92	0,19	0,04	0,15
h2	- 0,00	0,04	0,29	1,19	0,13	0,12	- 0,07	- 0,06
h3	- 0,18	- 0,00	0,29	- 0,65	- 0,21	0,01	0,01	1,30
h4	- 0,10	0,04	0,58	1,08	- 0,37	0,31	- 0,04	- 0,06
h5	0,21	0,41	- 0,53	- 0,12	1,49	0,04	0,03	- 0,66
h6	0,03	- 0,02	0,49	1,08	1,16	- 0,01	- 0,06	- 0,10
h7	0,00	- 0,01	0,32	1,49	1,93	- 0,02	- 0,05	2,37
h8	- 0,08	- 0,03	0,29	0,59	2,47	- 0,11	0,01	- 0,32
h9	- 0,06	- 0,02	- 0,69	- 1,17	0,52	- 0,08	0,01	0,53
h10	0,10	0,03	- 0,40	- 1,47	0,56	0,05	- 0,02	1,39
h11	- 0,19	- 0,07	0,21	0,40	0,11	0,11	0,02	- 0,65
h12	- 0,16	- 0,02	1,42	0,13	- 0,10	- 0,09	- 0,00	0,06
h13	- 0,05	- 0,03	0,10	1,62	1,61	- 0,11	0,01	- 0,15
h14	- 0,26	- 0,01	0,36	- 2,81	0,06	0,03	- 0,11	- 0,60
h15	- 0,13	- 0,01	- 0,28	- 0,32	- 0,18	- 0,01	0,02	- 1,28
h16	- 0,09	- 0,06	- 0,08	1,09	0,38	0,38	- 0,02	- 2,25
h17	0,08	0,15	- 0,07	- 0,54	- 0,65	- 0,08	0,03	- 1,88
h18	0,22	0,04	- 1,23	0,82	- 1,37	- 0,01	0,03	- 1,90
h19	- 0,17	0,05	- 0,65	- 2,40	0,48	- 0,09	- 0,00	- 1,59
h20	- 0,01	- 0,06	1,05	- 0,53	0,89	- 0,10	0,01	0,95

Çizelge 4.32 incelendiğinde gizli katmanda en fazla etkisi olan girdi değişkenlerinin GT ile temsil edilen gün tipi, R ile temsil edilen Ramazan ayı gün tipi, B ile temsil edilen Bayram günü tipinin yanı sıra DG ile temsil edilen doğal gaz maliyetinde olduğu görülmektedir.

O halde, en fazla etkisi olan girdilerden biri olan doğal gaz girdisinin girdi setinden çıkarılması durumunda YSA modelinin performansının kötüleşmesi ve MAPE değerinin artacağı tahmin edilmektedir. Model doğal gaz girdisi girdi setinden hariç tutularak tekrar çalıştırıldığında MAPE seviyesinin Çizelge 4.33’de görüldüğü üzere %7,9’dan %10,29’a yükseldiği görülebilmektedir.

Çizelge 4.33: DG girdisi girdi setinden çıkartıldığında seçilen YSA modeli 15 günlük performansı.

Eğitimin Son 15 Gününde Günlük Bazda Fiyat Tahmini Performansı			
Tarih	Gerçekleşen PTF'lerin Günlük Ortalaması (TL/MWh)	Tahmin Edilen PTF'lerin Günlük Ortalaması (TL/MWh)	MAPE %
14.11.2016	147,54	154,29	7,57
15.11.2016	142,66	147,15	7,53
16.11.2016	151,70	157,34	7,44
17.11.2016	157,95	163,69	5,12
18.11.2016	167,70	168,98	7,05
19.11.2016	150,00	155,04	6,49
20.11.2016	131,36	118,60	33,22
21.11.2016	159,52	151,56	16,11
22.11.2016	157,51	163,58	6,56
23.11.2016	163,83	161,78	4,16
24.11.2016	168,87	173,95	6,01
25.11.2016	186,17	183,99	5,17
26.11.2016	178,49	155,43	17,58
27.11.2016	129,32	138,21	18,65
28.11.2016	163,48	162,99	5,62
Ortalama	157,07	157,11	10,29

En iyi performansı gösteren 20 nöronlu model için; gizli katmandaki j . nöron ile k . çıktı değeri arasındaki bağlantının ağırlık matrisi Çizelge 4.34’de gösterilmiştir.

Çizelge 4.34: Gizli katmandaki 20 nöron ile 24 saatlik çıktı değeri arasındaki bağlantının çıktı ağırlık matrisi.

	h1	h2	h3	h4	h5	h6	h7	h8	h9	h10	h11	h12	h13	h14	h15	h16	h17	h18	h19	h20
1 . Saat	4,46	0,37	4,55	1,03	- 0,21	1,14	- 1,72	0,31	- 0,18	- 0,89	0,30	0,45	- 1,00	- 1,98	- 0,76	1,73	- 0,58	1,88	2,56	0,83
2 . Saat	3,68	1,62	3,45	0,35	0,34	0,49	- 0,13	- 1,24	0,50	- 1,51	1,41	- 1,95	0,63	- 0,35	- 0,83	0,24	- 0,41	2,43	1,54	0,93
3 . Saat	5,28	2,12	4,20	0,85	1,54	- 0,07	0,48	- 1,07	0,28	- 0,94	2,34	- 1,86	1,01	- 0,52	- 0,48	0,47	- 2,05	2,68	1,76	1,77
4 . Saat	3,24	- 0,06	2,91	0,67	1,20	0,39	0,35	- 0,71	- 1,41	1,86	- 1,21	- 5,50	- 1,29	0,73	1,60	1,49	- 2,17	2,86	1,42	2,89
5 . Saat	2,72	- 0,87	2,02	0,03	2,51	- 0,68	0,60	- 0,68	- 0,01	0,74	- 1,33	- 4,11	- 2,66	- 0,13	0,85	1,40	- 0,46	1,32	2,80	0,13
6 . Saat	2,47	0,47	- 0,37	- 2,03	1,68	- 1,10	- 0,08	- 4,54	4,81	3,39	- 6,99	- 3,66	- 0,83	1,39	0,14	1,26	- 1,57	- 2,47	3,04	0,52
7 . Saat	- 1,05	4,42	- 7,12	3,21	3,84	- 0,49	- 5,82	- 0,05	4,10	- 4,46	0,26	- 1,30	- 1,16	- 0,49	0,12	1,42	- 0,75	- 0,67	3,31	0,75
8 . Saat	- 0,75	- 1,55	- 2,15	6,00	- 0,16	- 3,70	- 2,03	- 1,40	0,57	- 1,24	- 1,36	0,24	- 3,00	0,30	- 2,60	1,57	- 3,06	- 0,07	1,79	2,43
9 . Saat	- 0,31	- 0,34	0,29	4,70	- 1,74	- 2,76	- 1,06	- 0,53	- 0,71	0,18	- 1,25	2,40	- 3,32	- 3,88	0,44	1,98	- 2,93	- 0,70	1,79	- 2,13
10 . Saat	- 0,22	- 0,69	- 0,38	0,98	- 1,07	- 2,31	- 0,15	- 2,13	- 0,28	0,32	- 0,99	2,98	- 3,81	- 2,59	- 0,70	1,39	- 4,13	0,26	2,06	1,03
11 . Saat	0,01	- 0,57	1,07	0,50	- 0,97	- 0,22	- 0,36	- 2,30	- 0,37	2,42	- 1,81	2,76	- 1,11	- 1,35	- 0,84	1,51	- 3,53	1,77	0,29	0,63
12 . Saat	- 0,16	- 0,03	1,60	1,74	- 1,20	- 0,43	- 0,09	- 0,21	- 0,58	- 0,86	- 1,63	0,45	- 3,16	- 1,62	- 0,75	1,28	- 2,48	1,51	- 3,09	2,82
13 . Saat	0,30	- 0,60	1,45	- 0,65	- 0,76	1,69	- 1,43	- 1,58	- 0,45	1,75	- 0,93	0,13	- 3,11	- 0,84	- 2,05	1,83	- 1,16	3,03	- 3,44	0,09
14 . Saat	- 0,93	0,29	1,16	- 2,15	0,34	- 0,10	1,23	- 2,46	1,89	2,29	2,96	- 0,18	- 3,29	- 1,41	- 3,13	1,12	1,35	1,97	- 3,74	- 1,34
15 . Saat	0,08	0,93	0,27	- 0,56	- 1,04	- 1,61	1,65	- 1,95	- 0,46	1,20	0,21	1,47	- 3,20	- 0,91	- 0,88	0,09	- 0,94	2,09	- 2,03	0,13
16 . Saat	0,12	1,87	0,94	- 0,48	- 1,64	- 2,05	0,55	- 2,05	- 2,31	1,79	- 0,63	1,13	- 2,61	- 1,34	- 0,18	0,41	- 0,58	2,84	- 2,15	0,03
17 . Saat	0,02	1,28	0,74	0,03	- 1,47	- 1,27	- 0,52	- 1,49	- 2,25	1,33	- 0,94	0,43	- 1,82	- 1,68	0,21	0,46	- 1,72	1,87	- 3,61	- 1,05
18 . Saat	- 1,13	- 0,06	1,46	3,18	- 0,70	- 2,68	- 2,70	- 1,90	- 3,34	2,63	- 1,50	1,16	0,76	- 4,07	0,20	2,57	- 4,37	0,47	- 2,10	- 0,79
19 . Saat	- 0,22	- 0,17	- 1,14	0,30	0,36	0,44	- 2,18	- 0,75	- 0,69	1,35	- 0,64	- 0,31	2,17	- 1,24	- 0,39	2,60	- 3,42	- 0,01	0,14	- 3,23
20 . Saat	0,03	- 0,78	- 2,00	- 0,24	0,84	- 1,25	- 0,33	- 0,10	0,84	2,07	- 0,69	- 0,70	2,71	- 0,95	- 1,61	2,84	- 4,93	0,96	- 0,80	- 0,72
21 . Saat	- 0,32	- 0,56	- 2,22	- 2,83	1,43	- 1,65	- 2,38	- 1,99	1,58	3,35	1,25	- 0,13	- 0,18	- 0,84	- 3,43	4,26	0,22	- 0,59	2,50	2,69
22 . Saat	- 4,79	- 1,81	- 0,71	- 5,00	- 2,17	- 0,14	- 1,80	- 0,91	- 2,92	- 4,38	- 2,34	- 5,94	- 0,84	- 5,87	- 2,88	- 2,36	1,15	- 3,30	- 1,51	1,19
23 . Saat	- 2,55	- 1,45	1,38	- 1,89	- 2,24	- 2,78	0,84	- 1,44	- 1,83	- 4,08	- 1,42	0,18	- 4,33	- 4,20	- 3,14	- 1,48	- 1,52	- 0,19	- 1,64	0,67
24 . Saat	2,33	0,32	- 1,82	- 3,67	1,26	1,59	- 0,80	- 1,42	- 3,47	3,68	- 0,64	- 1,52	2,49	- 0,64	- 1,35	5,54	2,29	- 1,99	- 1,13	0,92

Çizelge 4.34 incelendiğinde her saat için en büyük ağırlığa sahip olan nöronların birbirinden farklı olmasıyla birlikte, bazı nöronlarda yoğunlaşma olduğu farkedilmektedir. Çizelge 4.35'te çıktı matrisindeki her saate ilişkin en büyük ağırlık değerinin ait olduğu nöron gösterilmektedir.

Çizelge 4.35: Her saate ilişkin en büyük ağırlık değerinin ait olduğu nöron.

	Çıktı Matrisinde İlgili Saatteki En Büyük Ağırlık Değeri	En Büyük Ağırlık Değerine Karşılık Gelen İlgili Nöron
1 . Saat	4,55	h1
2 . Saat	3,68	h1
3 . Saat	5,28	h1
4 . Saat	3,24	h1
5 . Saat	2,80	h19
6 . Saat	4,81	h9
7 . Saat	4,42	h2
8 . Saat	6,00	h4
9 . Saat	4,70	h4
10 . Saat	2,98	h12
11 . Saat	2,76	h12
12 . Saat	2,82	h20
13 . Saat	3,03	h18
14 . Saat	2,96	h11
15 . Saat	2,09	h18
16 . Saat	2,84	h18
17 . Saat	1,87	h18
18 . Saat	3,18	h4
19 . Saat	2,60	h16
20 . Saat	2,84	h16
21 . Saat	4,26	h16
22 . Saat	1,19	h20
23 . Saat	1,38	h3
24 . Saat	5,54	h16

Çizelge 4.35 incelendiğinde h1 nöronunun 1., 2., 3. ve 4. saatlerde en büyük ağırlığa sahip olduğu görülmektedir. h2 nöronunun sadece 7. saatte en büyük ağırlığa sahip olduğu görülmektedir. Her saat için en büyük ağırlık değerinin yaratan tüm nöronlara ilişkin yüzdesel oranlar Çizelge 4.36'te gösterilmektedir. Buna göre, h1, h16, h18 ve h4 nöronlarının baskın olduğu çıkarılmaktadır.

Çizelge 4.36: Saat bazında en büyük ağırlık değerinin yaratan her nörona ilişkin yüzdesel oran.

Nöron	Nöronun En büyük Ağırlık Yarattığı Saat Sayısı	İlgili Saat Sayısına Karşılık Gelen Yüzde
h1	4	%16,67
h2	1	%4,17
h3	1	%4,17
h4	3	%12,50
h5	0	%0,00
h6	0	%0,00
h7	0	%0,00
h8	0	%0,00
h9	1	%4,17
h10	0	%0,00
h11	1	%4,17
h12	2	%8,33
h13	0	%0,00
h14	0	%0,00
h15	0	%0,00
h16	4	%16,67
h17	0	%0,00
h18	4	%16,67
h19	1	%4,17
h20	2	%8,33
Toplam	24	%100,00

4.11 Uygulama Çıkarımları ve Tartışmalar

Piyasa İşleticisi olan EPIAŞ, 01.06.2016 tarihinden itibaren Gün Öncesi Piyasasında sosyal fayda ençoklamasını amaçlayan yerli bir algoritma çalıştırarak saatlik bazda PTF'lerin belirlenmesini sağlamaya başladığından, algoritma etkisini elimine etmek amacıyla YSA modelinin eğitim veri seti 01.06.2016 tarihinde başlatılmış, daha eski tarihli örnekler modeli eğitime dahil edilmemiştir.

Önerilen YSA modelinde Levenberg-Marquardt (LM) geri yayılım algoritmasıyla eğitilmiş ileri beslemeli geri yayımlı (Feed-forward back propagation) öğrenme

modeli kullanılmıştır. Verilerin doğrusal olmayan örüntüsü nedeniyle Log-sigmoid transfer fonksiyonu (Logsig) tercih edilmiştir. Evrensel Yaklaşımlar Teorisi'ne (Universal Approximation Theorem) göre tek gizli katmanlı yapıdaki bir ağ; eğer gizli katmanında yeterince sayıda nörona sahip olursa, girdi-çıkı ilişkilerinin verimli bir şekilde yorumlanmasını sağlayabileceğinden çalışmadaki model tek gizli katmanlı olacak şekilde dizayn edilmiştir. Gizli ara katmandaki en iyi düğüm sayısını bulmak amacıyla 7, 10, 20, 22 ve 25 nöron sayıları ile beş farklı deneme yapılmıştır. Sonuçlar MAPE performans yöntemiyle karşılaştırılmış ve en iyi performansın 20 nöronda gerçekleştiği görülmüştür.

YSA kurulduktan sonra eğitimin son 15 günü temsil eden 14-28 Kasım 2016 periyodundaki veriler ise kurulan ağın testi için kullanılmıştır. Uygulamada kullanılan öğrenme girdi veri grubunda bir önceki gün fiyatları, 7 gün önceki fiyatlar, enerji talep miktarı ve sıcaklık verileri saatlik girdiler olmak üzere; gün tipi, Ramazan ayı gün tipi, Bayram gün tipi ve doğal gaz maliyeti ile birlikte oluşturulan girdi seti kullanılmıştır.

Problemi etkileyen faktörlerin mümkün mertebe ağa gösterilmesi ile ağın eğitimi sağlanırsa modelin daha az hatalı sonuçlar çıkarması beklenebilir. Bu nedenle Türkiye elektrik piyasasında fiyatları önemli ölçüde etkilemekte olan faktörler için yaşanmış örnekler toplanılarak yapay sinir ağının girdi seti oluşturulmuştur.

TM_i ile gösterilen toplam enerji talebinin girdi olarak alındığı bu bölümde en iyi performans, en düşük MAPE değerine ulaşılan 22 nöronlu YSA modelinde gösterilmiştir. Bölüm 4.5'de ise modelin performansını arttırmak için seçilen bir girdi elemanının ağın girdi setine etki etmesi ile sonuçlarda iyileşme olup olmayacağı denenmiştir. Bunun için girdi setinde toplam talep miktarlarının doğrudan kullanılması yerine bir ön işleme tabi tutularak daha sağlıklı girdiler elde edilmeye çalışılmıştır. Bu amaçla sürekli olmayan yenilenebilir enerji arzı içinde TEP'te önemli oranda etkili olan rüzgar enerjisi kaynaklı üretim miktarı ilgili saate ilişkin talep miktarından çıkartılması şeklinde tanımlanan ve NTM_i ile gösterilen net talebe göre girdi setinin tekrar hazırlanmasına karar verilmiştir. Benzer bir işlem Geidel ve diğ.'nin çalışmasında da uygulanmış ve İspanyol elektrik piyasasında toplam talepten rüzgar üretimin çıkarılmasıyla kalan net talep tanımlanmıştır [12]. Bu işlemin etkisiyle en iyi performans, %7,90 ile en düşük MAPE değerine ulaşılan 20 nöronlu YSA modelinde gösterilmiştir.

Çalışmanın ilerleyen bölümlerinde, ulaşılan en iyi model olan gizli katmanında 20 nöron bulunan, NTM_i girdi verilerini içeren S_{girdi*} setinin kullanıldığı YSA modeli ele alınarak devam edilmiştir. Bu YSA’da bir gün öncesinin ve yedi gün öncesinin PTF fiyatlarının girdi olarak kullanılarak modelleme yapılmıştır.

Bölüm 4.7’de YSA modelinde tarihsel PTF fiyatlarından sadece 1 gün öncesi kullanıldığında veya yedi günden haftalık periyotlar halinde daha önce gerçekleşmiş fiyatlarda girdi setine dahil edildiğinde modelin performansını hangi yönde etkileyeceği incelenmiştir. Bu bağlamda, 7 gün önce gerçekleşmiş fiyatları girdi setine ilave etmek MAPE oranını %17,16’dan %7,9’a düşürürken; 14, 21 ve 28 gün önce gerçekleşmiş PTF fiyatlarını girdi setine katmak hata performansını %16 seviyesinin üzerine çıkarmaktadır. Mevsimsellik nedeniyle 14, 21 ve 28 gün öncesinin fiyatlarını girdi setine dahil etmenin performansı bozucu etki yarattığı görülmektedir. Benzer bir sonuca Vahidinasab ve diğ.’nin makalesinde de ulaşılmıştır ve 7 gün önceki fiyatlardan haftalık periyotlarla geriye doğru genişletilmesinin belirgin bir fayda sağlamadığı belirtilmiştir [5].

Çizelge 4.21’de gizli katmanında 7, 10, 20, 22 ve 25 nöron sayıları ile yapılan beş farklı modelin sonuçları karşılaştırıldığında, 20 nörona kadar nöron sayısının artması MAPE oranını düşürüp performansı artırırken; 22 ve 25 nöron ile yapılan denemelerde performans düşmüştür. Bu durumda modeldeki nöron sayısının artırılmasının performansı daima arttırmayacağı sonucuna götürmektedir.

Ağırlık matrisleri incelendiğinde ise gizli katmanda etkisi en fazla olan girdi değişkenlerinin GT ile temsil edilen gün tipi, R ile temsil edilen Ramazan ayı gün tipi, B ile temsil edilen Bayram günü tipinin yanı sıra DG ile temsil edilen doğal gaz maliyetinde olduğu görülmektedir.

Türkiye elektrik piyasası PTF tahmini üzerine YSA modellemesi ile yapılmış daha önceki akademik çalışmalarında yine benzer MAPE değerlerine ulaşıldığı görülmektedir. Özgüner’in çalışmasında, Kış mevsiminde seçilen hafta için %6,13, Bahar mevsiminde seçilen hafta için %5,96 ve Yaz mevsiminde seçilen hafta için %7,97 MAPE değerlerine ulaşılmıştır [10]. Kölmek’in çalışmasında, YSA ile yapılan haftalık tahminlerde %14,15 MAPE değerine ulaşılmıştır [13]. Bicil’in çalışması incelendiğinde, modelin %8,2 MAPE performans sağladığı görülmüştür [16]. Yıldız’ın çalışmasında Türkiye elektrik piyasasında PTF tahmini için uygulanan

YSA modelinde Kış dönemi için saatlik %4,9, Yaz dönemi için saatlik %6,4 MAPE değerleri hesaplanmıştır [17]. Özözen ve diğ. çalışmasında SARIMA ile YSA hibrit modelini kullanarak Türkiye gün öncesi piyasasında fiyat tahmini uygulanmıştır. Hibrit modelin amacı kullanılan verinin doğrusal trendini SARIMA ile elde ederken, doğrusal olmayan kalanını YSA ile tahmin edilmesidir. Hibrit modelin %4,08 MAPE ile performans sağladığı görülmüştür. Hibrit model kullanılarak ileri tarihlerdeki 5 günlük fiyat tahminleri test edildiğinde %10,2 MAPE ile performans elde edilmiştir [24].

Sonuç olarak önerilen YSA modelinde en iyi sonucu veren girdi kümesinin şöyle oluştuğu görülmektedir:

- Bir önceki gün fiyatları
- 7 gün önceki fiyatlar
- Gün tipi
- Ramazan ayı gün tipi
- Bayram gün tipi
- Hava sıcaklığı
- Doğal gaz maliyeti
- Rüzgar enerjisi kaynaklı üretim miktarının toplam talep miktarından çıkartılması şeklinde tanımlanan net talep.

5. SONUÇ VE ÖNERİLER

Libelleşmenin artmasıyla birlikte daha rekabetçi şartların hakim olduğu enerji piyasalarında gerçekleşen ticari faaliyetlerin karlılığı ve sürdürülebilirliği açısından en önemli unsurunu elektrik enerjisinin belirli vadelerdeki değerinin gerçeğe en yakın şekilde tahmin edilmesi oluşturmaktadır.

Enerji piyasalarındaki üretici, tüketici, toptan ve perakende ticaret şirketleri olmak üzere tüm katılımcıların yanı sıra yerli/yabancı potansiyel yatırımcılar açısından da kritik öneme sahip olan elektrik fiyatının tahmini için, artık günün piyasa koşullarına uyarlanabilir yüksek performanslı modellere ihtiyaç duyulmaktadır. Özellikle orta ve uzun dönemde piyasada oluşacak fiyatlara maruz kalmanın getireceği fiyat risklerinin ölçülerek risk yönetimi yapılması aşamasında da yine düşük hatalı tahminlerin önemi ortaya çıkmaktadır.

Elektrik piyasasında fiyat tahmini yapılırken geleneksel olarak arz ve talebin oluşturan temel değişkenleri gözeten modeller kullanılmaktadır. Bu modellerin yerel piyasa kriterlerini de içermesi tahminin performansını artıracaktır. Çok sayıda veri kullanmak yerine fiyatı en fazla etkileme gücü olan en etkin girdi seti ile uyarlanabilir bir YSA modeli fiyat tahminini daha güçlü hale getirmektedir. Tahmin çalışmalarında YSA, uyarlanabilir olması ve doğrusal olmayan fonksiyonları analiz etme yeteneği ile oto regresif yöntemlerinin önüne geçmiştir. Özellikle geçmiş verileri, bugün tanımlanan bir model sayesinde geleceğe adapte ederek taşıması nedeniyle YSA ekonomik tahmin çalışmalarında son yıllarda tercih edilmektedir. Tüm YSA özelliklerini kullanan bir kompleks sistem enerji fiyatları oluşumunda da geçerli olacağından bu çalışmada özellikle YSA modeli kullanılmıştır.

Spot elektrik piyasalarındaki takas sonucu oluşan fiyatlar kendilerinden sonra yapılacak ticari işlemler için referans alınmakta olduğundan bu fiyatlar referans fiyat (RF) olarak anılmaktadır. Türkiye elektrik piyasasında referans fiyat kavramı gün öncesi piyasasında oluşan saatlik PTF'lere karşılık gelmektedir.

Bu çalışmada sadece önerilen YSA modelinin en iyi performansı veren topolojisi saptanmakla yetinilmemiş, girdi kümesindeki etkenler de detaylı olarak incelenmiştir. İlk olarak zamana bağlı geçmiş fiyatların etkisi 1, 7, 14, 21 ve 28 günlük tekrarlarla denenerek, bir gün ve bir haftalık tarihsel değerlerin birlikte alınması ile daha iyi sonuçlar alındığı görülmüştür.

İkinci olarak, toplam talep miktarlarının doğrudan kullanılması yerine rüzgar enerjisi kaynaklı üretim miktarının toplam talep miktarından çıkartılması şeklinde tanımlanan net talebin etkisi ele alınmış, rüzgar değerlerini dikkate alan bir YSA modelinin daha düşük hatalarla çalıştığı görülmüştür.

En düşük hata oranıyla önerilen modelde ağırlık değerleri incelenmiş ve gizli katmanda etkisi en fazla olan girdi değişkenlerinden biri olan doğal gaz maliyetinin modelden çıkarılması ile performansın nasıl düştüğü de gösterilmiştir.

Ayrıca, modelin değişik dönemlerde tahmin performansı da ölçülmüş ve kış dönemi için daha başarılı olduğu görülse de, hata oranlarının oldukça düşük ve yakın olduğu görülmüştür. İzleyen çalışmalarda modelin duyarlılık analizleri genişletilerek performans açısından güvenilirliği pekiştirilecektir.

Elektrik piyasası sürekli evrilen dinamik yapısı dolayısıyla zaman içindeki gelişmelerle birlikte farklı bir yöne doğru ilerleyecektir. Önümüzdeki yıllarda beklenen gelişmelerden öne çıkanlara kısaca şu şekilde değinilebilir:

Yap-İşlet-Devret modelleri ile işletilen santrallarda üretilen enerji, Enerji Satış Anlaşmaları (ESA) kapsamında Türkiye'nin kamu enerji toptan satış şirketi olan TETAŞ (Türkiye Elektrik Ticaret ve Taahhüt A.Ş.) tarafından satın alınmaktadır. Bu satış anlaşmalarının sürelerinin sona ermesi ile toplamda yaklaşık 7.500MW'lık güç kademeli olarak özel sektör üreticilerine geçerek serbestleşecektir. Bu etkiyle piyasada maliyet bazlı satış yapan üreticilerin oranı yükselecek ve bu durum oluşacak fiyatlara da yansıtacaktır.

Yapılması planlanan nükleer santrallerin devreye girmesiyle birlikte yine üretilen enerji, alım garantili anlaşmalarla TETAŞ tarafından satın alınacaktır. Böylece TETAŞ'ın üretim portföyü yine büyümüş olacaktır. EÜAŞ'a ait olup özelleştirme programına alınacak santrallerin de özelleştirilmesiyle serbest üretici portföyü büyüyecektir.

Doğal gaz piyasalarının serbestleşmesi ile kamu şirketi BOTAS'ın (Boru Hatları ile Petrol Taşıma A.Ş.) yanında özel gaz tedarikçilerinin sunduğu rekabetçi doğal gaz ürünlerinin yaygınlaşması sonucunda doğal gaz maliyetleri değişken hale gelmeye başlayacaktır. Bu durum doğal gaz kaynaklı üretim santrallerinin maliyetlerini ve dolayısıyla elektrik piyasası fiyatlarını etkileyecektir. Doğal gaz depolama tesislerinin artması da gaz tedariki güvenilirliğini artırarak gaz kısıntılarının önüne geçilmesini sağlayacaktır.

Yerli kaynağın desteklenmesi stratejisi ile birlikte ilerleyen süreçte yerli kömür üreticilerinin piyasaya katılımının teşvik edilmesinin etkileri görülmeye devam edilecektir.

İleriki dönemlerde ülkemizde güneş enerjisine dayalı santrallerinin da şebeke bağlantılarının artmasıyla yenilenebilir enerji profili değişeceği ve büyüyen toplam yenilenebilir enerji üretiminin belirsizliği artacağından fiyat tahmini modellemesinde bu etkilerin de modele dahil edilmesi gerekecektir.

Önümüzdeki dönemde kapasite piyasalarının da yürürlüğe girmesiyle maliyetleri nedeniyle çalışmayacak üretim santrallerinin emre amade tutulması sağlanarak arz güvenliğinin azalmasının önüne geçilmesi beklenmektedir. Böylece elektrik fiyatlarının aşırı yükselmesi engellenebilecektir.

Günümüzde Türkiye elektrik piyasası gündeminde yer alan konulardan biri de Talep Tarafı Yönetimi (TTY) kavramına ilişkin mevzuatın yayınlanması ve uygulama aşamasına geçilmesidir. Uluslararası literatürdeki karşılığı Demand Side Management (DSM) olan TTY, yeni yatırımlar yapılmadan tüketim talebinin gerçek zamanlı izlenmesi ve kontrol edilmesini esas almaktadır. Dolayısıyla piyasanın ilerleyen evrelerinde yapılacak fiyat tahmini çalışmalarında bu etkilerin de gözetilmesi gerekeceği öngörülmektedir. Şebeke teknolojilerindeki gelişmelerin de elektrik piyasalarında etkileri bilinmektedir ve Türkiye'de çalışılması gereken konular arasında görülmektedir.

Önerilen tahmin modelinin Türkiye elektrik piyasasında mevcut ve potansiyel elektrik piyasası aktörleri tarafından rahatlıkla yararlanılabileceği görülmektedir. Gerek bugün gösterdiği performans, gerekse zamanın koşullarına göre uyum sağlayacak bir YSA modelinin bir sonraki gün PTF'lerine ışık tutarak ekonomik kazanç sağlayacağı da görülmektedir.



KAYNAKLAR

- [1] **Fan, S., Liao, J. R., Kaneko, K., & Chen, L.** (2006). An integrated machine learning model for day-ahead electricity price forecasting. *IEEE PES Power Systems Conference and Exposition*, 1643 – 1649. doi:10.1109/PSCE.2006.296159
- [2] **Ranjbar, M., Soleymani, S., Sadati, N., & Ranjbar, A. M.** (2006). Electricity price forecasting using artificial neural network. *International Conference on Power Electronics, Drives and Energy Systems (PEDES '06)*. doi:10.1109/PEDES.2006.344294
- [3] **Li, G., Liu, C. C., Mattson, C., & Lawarree, J.** (2007). Day-ahead electricity price forecasting in a grid environment. *IEEE Transactions on Power Systems*, Volume: 22, Issue: 1, 266 – 274. doi:10.1109/TPWRS.2006.887893
- [4] **Cui, H., & Song, X.** (2008). Research on electricity price forecasting based on chaos theory. *International Seminar on Future Information Technology and Management Engineering (FITME '08)*, 398-401. doi:10.1109/FITME.2008.23
- [5] **Vahidinasab, V., Jadid, S., & Kazemi, A.** (2008). Day-ahead price forecasting in restructured power systems using artificial neural networks. *Electric Power Systems Research*, Volume 78, Issue 8, 1332-1342.
- [6] **Zhang, J., & Cheng, C.** (2008). Day-ahead electricity price forecasting using artificial intelligence. *IEEE Electrical Power & Energy Conference*.
- [7] **Tang, Q., & Gu, D.** (2009). Day-ahead electricity prices forecasting using artificial neural networks. *International Conference on Artificial Intelligence and Computational Intelligence*, 511-514. doi:10.1109/AICI.2009.184
- [8] **Yan, X., & Chowdhury, N. A.** (2010). Electricity market clearing price forecasting in a deregulated electricity market. *2010 IEEE 11th*

International Conference on Probabilistic Methods Applied to Power Systems, 36 – 41. doi: 10.1109/PMAPS.2010.5528949

- [9] **Singhal, D., & Swarup, K. S.** (2011). Electricity price forecasting using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, Volume 33, Issue 3, March 2011, 550-555. doi:10.1016/j.ijepes.2010.12.009
- [10] **Özgüner, E.** (2012). *Short term electricity price forecasting in turkish electricity market.* (Yüksek Lisans tezi), Orta Doğu Teknik Üniversitesi: Ankara.
- [11] **Anbazzhagan, S., & Kumarappan, N.** (2014). Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT. *Energy Conversion and Management*, Volume 78, February 2014, 711-719.
- [12] **Geidel, C., & Zareipour, H.** (2013). Price forecasting in the spanish day-ahead electricity market using preconditioned wind power information. *12th International Conference on Machine Learning and Applications*, 203-210. doi: 10.1109/ICMLA.2013.124
- [13] **Kölmek, M. A., & Navruz, İ.** (2013). 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*, Volume 23, 841-852. doi:10.3906/elk-1212-136
- [14] **Sahay, K. B., & Tripathi, M. M.** (2014). An analysis of short-term price forecasting of power market by using ANN. *6th IEEE Power India International Conference*. doi:10.1109/POWERI.2014.7117756
- [15] **Weron, R.** (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, Volume 30, Issue 4, October–December 2014, 1030-1081. <https://goo.gl/EbCHwa>
- [16] **Bicil, İ. M.** (2015). *Elektrik piyasasında fiyatlandırma ve türkiye elektrik piyasasında fiyat tahmini.* (Doktora tezi), Balıkesir Üniversitesi: Balıkesir.
- [17] **Yıldız, S.** (2015). *Türkiye elektrik piyasası kısa dönemli referans fiyat tahmini.* (Yüksek Lisans tezi), İstanbul Teknik Üniversitesi: İstanbul.

- [18] **Keles, D., Scelle, J., Paraschiv, F., & Fichtner, W.** (2016). Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks. *Applied Energy*, Volume 162, 15 January 2016, 218-230.
- [19] **Kotur, D., & Žarković, M.** (2016). Neural network models for electricity prices and loads short and long-term prediction. *Environment Friendly Energies and Applications (EFEA)*. doi: 10.1109/EFEA.2016.7748787
- [20] **Lahouar, A., & Slama, J. B. H.** (2016). Comparative study of learning machine predictors for half-hour and day-ahead electricity price forecast in deregulated markets. *7th International Renewable Energy Congress (IREC)*, 1-6. doi:10.1109/IREC.2016.7478870
- [21] **Moreira, R., Bessa, R., & Gama, J.** (2016). Probabilistic forecasting of day-ahead electricity prices for the Iberian electricity market. *13th International Conference on the European Energy Market (EEM)*, 1 – 5. doi:10.1109/EEM.2016.7521226
- [22] **Moria, H., & Nakanob, K.** (2016). An efficient hybrid intelligent method for electricity price forecasting. *Procedia Computer Science*, Volume 95, 2016, 287-296.
- [23] **Nargale, K. K., & Patil, S. B.** (2016). Day ahead price forecasting in deregulated electricity market using artificial neural network. *International Conference on Energy Efficient Technologies for Sustainability (ICEETS)*, 527-532. doi:10.1109/ICEETS.2016.7583810
- [24] **Özözen, A., Kayakutlu, G., Ketterer, M., & Kayalıca, Ö.** (2016). A combined seasonal ARIMA and ANN model for improved results in electricity spot price forecasting: Case study in Turkey. *Proceedings of PICMET '16: Technology Management for Social Innovation*, 2681-2690.
- [25] **Elektrik Piyasası Kanunu** (2013). T.C. Resmi Gazete, No: 28603, tarih: 30 Mart 2013.
- [26] **Elektrik Piyasası Dengeleme ve Uzlaştırma Yönetmeliği** (2009). T.C. Resmi Gazete, No: 27200, tarih: 14 Nisan 2009.
- [27] **EPİAŞ.** (2017). *Kurumsal Vizyon*. Erişim: 10 Mart, 2017, <https://goo.gl/ZTuike>

- [28] **EPIAŞ.** (2017). *Lisans Türüne Göre Katılımcı Sayısı*. Erişim: 10 Mart, 2017, <https://goo.gl/j0oEGd>
- [29] **EPIAŞ.** (2016). *2016 Yılı Elektrik Piyasası Özet Bilgiler Raporu*. Erişim: 09 Mart, 2017, <https://goo.gl/uF4U1j>
- [30] **EPIAŞ.** (2017). *Gün Öncesi Elektrik Piyasası Piyasa Takas Fiyatı Belirleme Yöntemi*. Erişim: 10 Mart, 2017, <https://goo.gl/3IGIEk>
- [31] **Gün Öncesi Piyasası Tekliflerinin Yapısı Ve Tekliflerin Değerlendirilmesine İlişkin Usul Ve Esaslar.** (2016). T.C. Resmi Gazete, No: 29725, tarih: 28 Mayıs 2016.
- [32] **Güreşen, E.** (2014). *Dinamik Yapay Sinir Ağları Sistemi Önerisi*. (Doktora tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [33] **Öztemel, E.** (2003). *Yapay Sinir Ağları* (1.Basım, 1-15). İstanbul: Papatya Yayıncılık
- [34] **Shahidehpour, M., Yamin, H., & Li, Z.** (2002). *Market Operations in Electric Power Systems: Forecasting, Scheduling, and Risk Management, Introduction to ANN* (Sf. 25). Wiley-IEEE Press.
- [35] **Yakut, E.** (2012). *Veri Madenciliği Tekniklerinden C5.0 Algoritması Ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama*. (Doktora tezi), Atatürk Üniversitesi: Erzurum.
- [36] **Munakata, T.** (2008). *Fundamentals of the New Artificial Intelligence: Neural, Evolutionary, Fuzzy and More*. Londra: Springer.
- [37] **Bose, N.K. & Liang, P.** (1996). *Neural Network Fundamentals with Graphs, Algorithms and Applications*. New York: McGraw-Hill International Editions.
- [38] **Vural, B.** (2007). *Yapay Sinir Ağları ile Finansal Tahmin*. (Yüksek lisans tezi). Ankara Üniversitesi, Ankara.
- [39] **Singh, N., Mohanty, S. N., & Shukla, R. D.** (2017). Short Term Electricity Price Forecast Based On Environmentally Adapted Generalized Neuron. *Energy* (2017), Volume 119. doi: 10.1016/j.energy.2017.02.094

- [40] **EPIAŞ**. Haziran 2016 - Kasım 2016 arası Piyasa Takas Fiyatları. Erişim: 10.03.2017, <https://goo.gl/SMg4B3>
- [41] **EPIAŞ**. Haziran 2016 - Kasım 2016 arası Tüketim Tahmini. Erişim: 10.03.2017, <https://goo.gl/uUWO94>
- [42] **BOTAŞ**. (2017). *Botaş Doğal Gaz Toptan Satış Tarifeleri Ve Satış Fiyatları*. Erişim: 09 Mart, 2017, <https://goo.gl/khEugn>
- [43] **Khani, A., & Nemati, A.** (2013). Modeling of Nitrate Removal Bynanosized Iron Oxide İmmobilized on Perlite Using Artificial Neural Network. *Asian Journal of Chemistry*, Volume 25, Issue 8, 4340–4346. doi: 10.14233/ajchem.2013.13974
- [44] **EPIAŞ**. Haziran 2016 - Kasım 2016 arası Gerçek Zamanlı Rüzgar Enerjisi Üretimi. Erişim: 10.03.2017, <https://goo.gl/eS5gpL>



ÖZGEÇMİŞ



Ad Soyad : Aslıhan ÖZKAN DALGIN
Doğum Yeri ve Tarihi : Ankara - 01.05.1984
E-Posta : ozkana@itu.edu.tr

ÖĞRENİM DURUMU:

- **Lisans** : 2007, İstanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektrik Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2005-2006 yılları arasında İTÜ Bilgi İşlem Daire Başkanlığı'nda yarı-zamanlı asistan öğrenci olarak çalışmıştır.
- 2008 yılında Elektrik Proje Mühendisi olarak başladığı Alarko Holding Enerji Grubu'ndan 2016 yılında Üretim Optimizasyonu ve Ticaret Müdürü olarak ayrıldı. 2011-2013 yılları arasında 'Alarko-MBA' Hizmet içi Yönetici Adayı Eğitim Programı'nı (Manager Training Program) tamamlamıştır.
- 2016'dan itibaren Gama Holding bünyesindeki Gates Enerji Ticaret A.Ş.'de Üretim Optimizasyonu ve Ticaret Yöneticisi olarak çalışmaktadır.