

**TÜRKİYE’DE GÜN ÖNCESİ PİYASASI İÇİN ELEKTRİK
FİYATLARININ TAHMİNİ**

**PREDICTION AND FORECASTING OF ELECTRICITY
PRICES FOR TURKISH DAY AHEAD MARKET**

SİNAN DEMİREZEN

PROF. DR. MERAL ÇETİN

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

İstatistik Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2020

Canım Aileme

ve

Canım Betüle

ÖZET

TÜRKİYE’ DE GÜN ÖNCESİ PİYASASI İÇİN ELEKTRİK FİYATLARININ TAHMİNİ

Sinan DEMİREZEN

Yüksek Lisans, İSTATİSTİK Bölümü

Tez Danışmanı: Prof. Dr. Meral ÇETİN

Eş Danışman: Prof. Dr. Kasırga YILDIRAK

Temmuz 2020, 129 sayfa

Elektrik, tarih öncesi çağlardan beri varlığı bilinse de özellikle aydınlatma amacıyla kullanılmaya başlanmasıyla birlikte insan hayatında vazgeçilmez bir yer edinmiştir. Devletler, elektriğin üretim, iletim ve dağıtımını vatandaşlarına herhangi bir ayırım gözetmeksizin gerçekleştirme amacı içerisinde olmuşlar ve bu aşamaları sağlayacak kurumlar meydana getirmişlerdir. Elektrik endüstrisinde 1940’lı yıllarda elektriğin devlet tekelinde olması yeğlenirken 1980’li yılların hemen başlarında bu düşünce yadsınır hale gelmiştir. Böylece devletin rolünün azaltılması hedeflenerek denetleyici ve düzenleyici bir konumda olması için endüstride düzenlemeler yapılmaya başlanmıştır. Başta Şili olmak üzere, İngiltere, İskandinav ülkeleri ve daha birçok ülke elektrik piyasasında düzenlemeye giderek özel kesimin piyasada etkin olmasını sağlamaya çalışmıştır. Türkiye’ de ise serbestleşme çalışmaları milenyumun ilk yıllarında başlamıştır. Bu tez çalışmasının amacı elektrik fiyatlarının tahmin edilmesi ve öngörülmeye çalışılması olarak belirlenmiştir. Çalışmanın kapsamını, Türkiye’ de faaliyet gösteren elektrik piyasalarından biri olan Gün Öncesi Piyasasında işlem gören Piyasa Takas Fiyatı (PTF)’nin tahmin edilmesi oluşturmaktadır. Tahmin yöntemi olarak, makine öğrenmesi yöntemlerinden Yapay Sinir Ağları, Destek Vektör Makineleri ve Rastgele Orman Yöntemi kullanılmıştır. Bu amaçla, uygulamada kullanılan girdiler ve yöntemlerle

birlikte altı farklı model kurulmuş olup PTF' nin en iyi tahmini Model 6 ile elde edilmiştir. En iyi tahmin eden yöntem ise Rastgele Orman Yöntemi olmuştur. Böylelikle, Model 6 ile PTF' nin 24 saatlik öngörüsü gerçekleştirilmiş ve sonuçlar özetlenmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Destek Vektör Makineleri, Rastgele Orman, Gün Öncesi Piyasası, Piyasa Takas Fiyatı

ABSTRACT

PREDICTION AND FORECASTING OF ELECTRICITY PRICES FOR TURKISH DAY AHEAD MARKET

Sinan DEMİREZEN

Master of Science, Department of STATISTICS

Supervisor: Prof. Dr. Meral ÇETİN

Co- Supervisor: Prof. Dr. Kasırga YILDIRAK

July 2020, 129 pages

Electricity, known as static electricity from ancient times to 1880's, take a indispensable place in human life especially down from it had been used as a lightening purpose. At the present time, there isn' t any substitute goods with it. So, electricity is one of the most important ones daily life. In the first periods of active using electricity, states undertook its production, transmission and distribution mechanism via establishing their institution. Particularly, while it was preferred electricity industry under the state monopoly in 1940's, it was began to refuse this thought due to the inefficiency and deactivation in the industry in 1980's. In this period, so that states had regulatory and supervisory position, in the electricity industry was began to regulate by reducing its authority. Primarily Chile, afterwards England, Nordic countries and many other countries regulated their industries in scope of liberalization. Therefore, electricity markets which is also involve private sector's agent was established. In Turkey, liberalization of electricity market was began at the beginning of 2000's. In the aim of this master' s thesis was designed as prediction and forecasting of electricity prices. In the scope of this thesis consist of Market Clearance Prices (MCP) which is defined as a result of making bid by market participant in Day Ahead Market. Artificial Neural Network, Support Vector Machine, Random Forest including among Machine Learning methods used for prediction and forecasting of the

prices. On the other hands, MCP was tackled with six different models consist of named as *Model 1*, *Model 2*, *Model 3*, *Model 4*, *Model 5* and *Model 6*. The method and model which is the best of prediction performance among aforementioned methods and models was used for forecasting electricity prices. As a result of the analysis, the best method and the best model to predict MCP is random forest and *Model 6*, respectively. From this point of wiew, twenty four hourly MCP was forecasted with *Model 6*. Therefore, forecasting results will give an idea (to market operator, market participant and individuals to study in this area) about prices and the methods using in this paper.

Keywords: Artificial Neural Networks, Support Vector Machine, Random Forest, Day Ahead Market, Market Clearing Price

TEŞEKKÜR

Yüksek lisans tez çalışmamda konu seçiminden son aşamaya kadar desteklerini ve bilgi birikimlerini esirgemeyen çok değerli tez danışman hocalarım Sayın Prof. Dr. Meral Çetin'e ve Sayın Prof. Dr. Kasırga Yıldırak'a,

Çok değerli jüri üyesi, Sayın Prof. Dr. Ali Karun Nemlioğlu'na, Sayın Doç. Dr. Ayten Yiğiter'e, Sayın Dr. Öğr. Üyesi Uğur Karabey'e ve Sayın Dr. Öğr. Üyesi Onur Toka'ya,

Tez çalışmam sürecinde desteklerini esirgemeyen İstanbul Üniversitesi İstatistik, Ekonometri ve Yöneylem kürsüsündeki çok değerli hocalarıma,

Binbir türlü özveri ile beni bu günlere getiren babam Mehmet Demirezen'e, annem İlknur Demirezen'e,

Birçok konuda görüşüne başvurarak yol gösteren abim Sami Demirezen'e ve kız kardeşim Sedanur Demirezen'e,

Hayatımı kendisine adamaktan bir an olsun kuşku duymayacağım canım Saime Betül Kaya'ya sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	16
2.1. Elektriğin Tarihi ve Elektrik Piyasaları.....	16
2.1.1. Türkiye’ de Elektrik Piyasası ve Tarihi.....	17
2.1.2. EPIAŞ (Enerji Piyasaları İşletme Anonim Şirketi).....	19
2.1.3. Gün Öncesi Piyasası	20
2.1.4. Elektrik Piyasalarında Reform Hareketleri	23
2.1.5. Dünya’da Bazı Önemli Elektrik Piyasaları.....	24
2.2. Makine Öğrenmesi Yöntemleri.....	27
2.2.1. Yapay Sinir Ağları	29
2.5.1.1 Biyolojik Sinir Ağları.....	32
2.5.1.2 Yapay Sinir Ağlarının Mantıksal Çerçevesi.....	34
2.5.1.3. Yapay Sinir Ağı Hücresi	38
2.5.1.4. Yapay Sinir Ağlarında Eğitim Süreci ve Özellikleri.....	43
2.5.1.5. Yapay Sinir Ağlarında Mimari Yapılar.....	46
2.2.2. Destek Vektör Makineleri	53
2.5.2.1. Destek Vektör Regresyonu.....	63
2.2.3. Rastgele Orman	67
3. UYGULAMA.....	72

3.1. Uygulamada Kullanılacak Değişkenlerin Tanımı.....	73
3.1. Yapay Sinir Ağı Uygulaması ve Sonuçları.....	78
3.2. Destek Vektör Regresyonu Uygulaması ve Sonuçları.....	89
3.3. Rastgele Orman Uygulaması ve Sonuçları	95
4. SONUÇLAR VE ÖNERİLER.....	106
5. KAYNAKLAR	109
EKLER.....	117
EK 1 - Tez Çalışması Orjinallik Raporu.....	117
ÖZGEÇMİŞ	118

ŞEKİLLER DİZİNİ

Şekil 1.1. GÖP' te PTF oluşum süreci [65].....	22
Şekil 2.1. Biyolojik sinir hücresi [45]	33
Şekil 2.2. BSA'da çok katmanlı yapı [45]	34
Şekil 2.3. Tek düğümden (node) oluşan basit model [87]	35
Şekil 2.4. Transfer fonksiyonu [87]	36
Şekil 2.5. Yapay sinir ağının genel yapısı [87]	37
Şekil 2.6. Yapay sinir hücresi.....	38
Şekil 2.7. Lojistik aktivasyon fonksiyonu [87]	40
Şekil 2.8. Lojistik aktivasyon fonksiyonunda β parametresinin etkisi [87].....	41
Şekil 2.9. Hiperbolik tanjant aktivasyon fonksiyonu [87]	42
Şekil 2.10. Hiperbolik tanjant fonksiyonu üzerinde β parametresinin etkisi [87].....	42
Şekil 2.11. Gauss aktivasyon fonksiyonu.....	43
Şekil 2.12. Doğrusal aktivasyon fonksiyonu.....	43
Şekil 2.13. Öğretmenli öğrenme sürecine ilişkin akış diyagramı [88].....	45
Şekil 2.14. Denetimsiz öğrenme akış diyagramı [88]	46
Şekil 2.15. Tek katmanlı ileri beslemeli sinir ağı örneği [87].....	47
Şekil 2.16. XOR mantık fonksiyonu	49
Şekil 2.17. Çok katmanlı ileri beslemeli sinir ağı örneği [87]	50
Şekil 2.18. Çok katmanlı perceptron ağı [87]	51
Şekil 2.19. İki gizli katmanlı geri yayılım algoritması [87]	52
Şekil 2.20. Yinelenen ağ mimarisi [87].....	53
Şekil 2.21. Optimal hiperdüzlemin belirlenmesi [104].....	55
Şekil 2.22. Hiperdüzlem örneği [48].....	58
Şekil 2.23. İki boyutlu bir uzayda hiperdüzlemin gösterilmesi [103].....	60
Şekil 2.24. Optimal hiperdüzlemin bulunması [103]	61
Şekil 2.25. Gözlemlerin maksimum marjlı hiperdüzleme ayrılması [103]	62
Şekil 2.26. Model karmaşıklığı ile bandın dışında kalan gözlemler arasında ilişki.....	65
Şekil 2.27. Bagging ve random forest arasındaki farkın resmedilmesi [113]	71
Şekil 3.1. Piyasa takas fiyatının (PTF) zamana göre grafiği	72
Şekil 3.2. Model 1 için en iyi gizli katman değerlerinin bulunması	81

Şekil 3.3. Model 1’de ki girdilerle gerçekleştirilen eğitim kümesinin tahmini	83
Şekil 3.4. Model 1’de ki girdilerle gerçekleştirilen test kümesinin tahmini.....	84
Şekil 3.5. Model 2 için gizli katman nöron denemelerinin tahmin performansı grafiği.	86
Şekil 3.6. Model 2’de ki girdilerle gerçekleştirilen eğitim kümesinin tahmin grafiği....	88
Şekil 3.7. Model 2’deki girdilerle gerçekleştirilen test kümesinin tahmin grafiği	89
Şekil 3.8. Model 3 için eğitim kümesinin tahmin grafiği	91
Şekil 3.9. Model 3 için test kümesinin tahmin grafiği.....	92
Şekil 3.10. Model 4 için eğitim kümesi tahmin grafiği	94
Şekil 3.11. Model 4 için test kümesi tahmin grafiği.....	95
Şekil 3.12. Model 5 için parametre değerlerinin tahmin performans grafiği	97
Şekil 3.13. Model 5’te PTF için değişkenlerin önemlilik grafiği	98
Şekil 3.14. Model 5 için eğitim kümesinin tahmin grafiği	99
Şekil 3.15. Model 5 için test kümesinin tahmin grafiği.....	100
Şekil 3.16. Model 6 için en iyi parametre değerlerinin tahmin performansı	102
Şekil 3.17. Model 6’ de PTF için değişkenlerin önemlilik grafiği	103
Şekil 3.18. Model 6 için eğitim kümesinin tahmin grafiği	104
Şekil 3.19. Model 6 için test kümesinin tahmin grafiği.....	105
Şekil 4.1. PTF’nin öngörüsü	108

ÇİZELGELER DİZİNİ

Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	4
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	5
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	6
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	7
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	8
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	9
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	10
Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar	11
Çizelge 3.1. Uygulamada kullanılan girdiler (değişkenler)	75
Çizelge 3.2. Model 1 için en iyi gizli katman nöron değerinin bulunması	80
Çizelge 3.3. Model 1 için eğitim kümesinin tahmini	82
Çizelge 3.4. Model 1 için test kümesinin tahmini	82
Çizelge 3.5. Model 2 için en iyi gizli katman nöron birleşiminin bulunması	85
Çizelge 3.6. Model 2 için eğitim kümesinin tahmini	87
Çizelge 3.7. Model 2 için test kümesinin tahmini	87
Çizelge 3.7. Model 3'te tahmin performansı sonuçları	90
Çizelge 3.8. Model 3'te test kümesinin tahmin performansı	91
Çizelge 3.9. Model 4'te test kümesine ait tahmin performansı sonuçları	93
Çizelge 3.10. Model 4'te test kümesine ait tahmin performansı sonuçları	93
Çizelge 3.11. Model 5 için en iyi parametrelerin belirlenmesi	96
Çizelge 3.12. Model 6 için en iyi parametre değerlerinin belirlenmesi	101
Çizelge 4.1. Eğitim kümesinde tahmin performansı sonuçları	106
Çizelge 4.2. Test kümesinde tahmin performansı sonuçları	107

SİMGELER VE KISALTMALAR

Simgeler

MWh	Megawatt saat
\$	ABD Doları

Kısaltmalar

BSA	Biyolojik Sinir Ağları
DVM	Destek Vektör Makinesi
DVR	Destek Vektör Regresyonu
DVS	Destek Vektör Sınıflandırması
EPIAŞ	Enerji Piyasaları İşletme Anonim Şirketi
ES	Eşleşme Miktarı
GZU	Lisanssız üretim dahil gerçek zamanlı üretim miktarı
GÖP	Gün Öncesi Piyasası
PTF	Piyasa Takas Fiyatı
RF	Rastgele Orman
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
YSA	Yapay Sinir Ağları

1. GİRİŞ

İnsanoğlunun hayatla mücadelesi daha ilk insanlardan beri süregelmiştir. Hayatını en iyi şekilde devam ettirme isteği bir arayışa yönlendirerek doğa da gizli olan henüz keşfedilmemiş olguların bir bir ortaya çıkarılmasına neden olmuştur. Doğa, birçok açıdan insanoğluna ilham kaynağı olmuş ve ilkel hayattan modern hayata geçişin aracısı olmuştur. Yapılan her icat, köklü bir değişime neden olmuştur. Bu icatlar günlük yaşama uyarlanarak en büyük fayda sağlanmaya çalışılmıştır.

Elektriğin doğada fark edilmesi de antik çağlara dayanmaktadır. Bu çağda yaşayan insanlar, kehribar olarak isimlendirdikleri taşları parlatırken saman gibi hafif cisimlerle etkileşim içerisine girdiğini görmüşlerdir. Elektrik kavramı da bu olguya dayandırılmış ve günümüzde statik elektrik olarak bilinen kavramın doğmasına neden olmuştur. Elektrik, 1880'li yıllara kadar statik yönü algılanmış, aydınlatmadan yararlanılmaya başlamasıyla bu algı değişmeye başlamış ve günümüzdeki anlamına dönüşmüştür. Günümüzde, elektrik, aydınlatmadan motorlu araçların çalıştırılmasına, iletişimden ısınmaya kadar birçok alanda kullanılmakta olup su, besin, barınma gibi neredeyse insanoğlunun vazgeçilmez bir yanı olmuştur.

Elektrik ihtiyacının karşılanabilmesi için elektriğin üretilmesi, iletilmesi ve dağıtılması konuları gündeme gelmiştir. Bu aşamalar ilk olarak devlet tekelindeki kurumlar vasıtasıyla gerçekleştirilmiş ve devlet tarafından kanunla çerçevesi belirlenmeye başlanmıştır. 1980'li yılların öncesinde elektrik piyasasında yaşanan sorunlar nedeniyle devlet tekeli sorgulanmaya başlamış ve ülkeler endüstrilerini düzenlemeye başlamıştır. Bu anlamda, 1980'li yıllarda Şili' den başlayan bu yolculuk hâlâ devam etmekte olup piyasalarını serbestleştirmeye çalışan ülkelerle devam etmektedir. Şili' nin hemen ardından İngiltere, İskandinav ülkeleri, Avustralya, Yeni Zelanda gibi ülkeler serbestleşmeye giderek elektrik piyasalarını yeniden yapılandırmaya başlamıştır. Böylelikle, devlet tekeli ortadan kaldırılmaya başlanmış ve özel yatırımlar piyasa içerisine dâhil edilmeye çalışılmıştır. Serbestleştirilmeye gidilmenin ana amacı ise piyasanın daha etkin ve verimli bir yapıya kavuşturulmak istenmesidir.

Elektrik piyasalarının çeşitlendirilmesi bu amaçların sağlanmasında bir aşama olmuştur. Türkiye 'de ise elektrik piyasalarında düzenleme 2000'li yılların henüz başlarında gerçekleşmeye başlamıştır. Nihayetinde 2013 yılında Enerji Piyasaları İşletim Anonim Şirketi (EPIAŞ)' nin kurulmasıyla serbestleşme anlamında önemli bir adım atılmıştır.

Piyasada oluşan fiyatlar katılımcıların stratejilerini belirlemeleri açısından büyük önem taşımaktadır. Bu piyasalardan biri olan Gün Öncesi Piyasası (GÖP), kabaca, bir sonraki günün elektrik fiyatlarının bugünden belirlendiği piyasa tipidir. Bu açıdan bakıldığında bir sonraki günün fiyatlarının bilinmesi katılımcılar açısından stratejilerini belirlemede önemli bir yol gösterici olacaktır. Ayrıca, bu fiyatların öngörülme çalışması çok daha bir öneme sahip olup henüz kesinleşmemiş fiyatlar hususunda bilgi verici nitelikte olup katılımcılara ve piyasa işletmecisine yol gösterici bir kaynak olacaktır.

İyi bir fiyat tahmini yapmak piyasa katılımcıları için avantaj sağlamakta olup risk yönetimi için önem arz etmektedir. Elektrik fiyat tahmini, nakit akış analizi, yatırım bütçeleri, finansal piyasalar, mevzuattaki gelişmeler, bütünlük kaynak planlaması için büyük önem taşımaktadır. Ayrıca, elektrik fiyat tahmini, üretim şirketleri için kısa dönemde spot piyasaya teklif veren, orta vadede politikasını belirleyen ve uzun dönemde ise yaptığı planlardaki gelişmeleri izleyen üretim şirketleri için büyük önem taşımaktadır [1].

Literatürde elektrik fiyatları zaman serilerinden makine öğrenmesi yöntemlerine, bulanık modellerden simülasyon yöntemlerine kadar geniş çerçevede teknikler kullanılarak analiz edilmeye çalışılmıştır. Ayrıca, bazı çalışmalarda bu yöntemler bir araya getirilerek hibrit modeller vasıtası ile de tahmin çalışmaları yapılmış ve kullanılan yöntemlerin tahmin performansları karşılaştırılarak en iyi yöntem belirlenmeye çalışılmıştır. Literatür incelendiğinde, Catalão ve diğerleri [2] çalışmalarında, İspanya elektrik piyasasında dört mevsim için saatlik elektrik fiyatları yapay sinir ağları yöntemleri ile tahmin edilmiştir. Analiz sonucunda, MAPE kriterine göre öngörü için en az ortalama hataya sahip mevsim ilkbahar iken en çok hata ise yaz mevsiminde tespit edilmiştir. Böylece, bu çalışma piyasada üreticiler ve tüketiciler açısından fiyat konusunda yapılacak anlaşmalarda mevsim dönemlerinin fikir vereceği sonucuna ulaşılmıştır. Tang ve Gu [3], California elektrik piyasasında piyasa takas fiyatı yapay sinir ağları ile öngörülme çalışılmıştır. Çalışmada aynı girdiler kullanılarak farklı mimarilere sahip iki model kullanılmıştır. Üç

girdi ve bir çıktılı model 3-n-1 ve 72 girdi 24 çıktıya sahip 72-n-24 modeli Levenberg-Marquardt (LM) ve Scaled Conjugate Gradient (SCG) algoritması kullanılarak fiyat öngörüsü yapılmıştır. Analiz sonucunda LM eğitim algoritması ile gerçekleşen öngöründe 3-n-1 modelinin daha iyi performansa sahip olduğu belirlenmiştir. Mandal ve diğerleri [4] PJM piyasasında benzer gün yaklaşımı çerçevesinde yapay sinir ağları kullanılarak piyasa takas fiyatı tahmin edilmeye çalışılmıştır. Çalışma sonucunda, önerilen benzer gün yaklaşımına dayanan YSA' nın normal benzer gün yaklaşımına göre piyasa takas fiyatını belirlemede daha etkin olduğu sonucuna ulaşılmıştır. Sun ve Zhang [5], Genetik algoritmalara dayalı yeni bir destek vektör makinesi yöntemi önerdikleri çalışmalarında elektrik fiyatlarını öngörerek yapay sinir ağları öngörüsü ile karşılaştırarak önerdikleri modelin sınıflama performansı belirlenmeye çalışılmıştır. MAPE kriterine göre önerilen modelin (GASVM) YSA' ya göre performansının daha iyi olduğu belirlenmiştir. Reddy ve diğerleri [6], PJM piyasasında saatlik bölgesel marjinal fiyatlarının kış ve ilkbahar için YSA ve önerilen ağırlıklı doğrusal en küçük kareler yöntemi kullanılarak öngörüsü gerçekleştirilmiştir. Yapılan simülasyon çalışmaları sonucunda önerilen modelin YSA'ya göre daha iyi olduğu belirlenmiştir. Mohandes [7], kısa dönemli elektrik yükü tahminini destek vektör makineleri ve otoregresif modeller ile yaparak bu iki modelin tahmin performansı karşılaştırılmıştır. DVM' nin otoregresif modele göre daha iyi öngörü performansına sahip olduğu tespit edilmiş ve DVM' nin eğitim verisi artırıldığında öngörü başarısının artacağı vurgulanmıştır. Catalão ve diğerleri [8], yapay sinir ağları kullanarak, talebin düşük olduğu ve yüksek olduğu iki mevsim dönemi belirlenerek fiyat öngörüsü yapılmıştır. Ortalama hata %8 civarında olduğu belirlenmiş ve MAPE değerinin yaz mevsimi öngörüsünde daha başarılı olduğu belirlenmiştir. Conteras ve ark. [9], İspanya ve California gün öncesi elektrik piyasasında iki adet ARIMA modeli kurularak açıklayıcı değişkenlerin olup olmasına bağlı olarak saatlik elektrik fiyatlarının öngörüsü yapılmıştır. Ortalama hata açıklayıcı değişkenler modelde yer almadığında İspanya piyasası için %10 civarında, California için ise %5 civarında olduğu belirlenmiştir. Ayrıca, İspanya modelinde ARIMA ile fiyat tahmini için 5 saat öncesindeki veriye ihtiyaç duyulurken, California modelinde iki saat öncesindeki veriye ihtiyaç duyulduğu tespit edilmiştir. Amjady [10], İspanya elektrik piyasasında, önerdiği Fuzzy ANN modeli ile kısa dönemli elektrik fiyatlarını öngörerek model performansını diğer modellerle karşılaştırmış ve ARIMA, Wawelet ARIMA, Dinamik regresyon, transfer fonksiyonu, çok katmanlı algılayıcı ve Radyal tabanlı sinir ağlarına göre öngörü performansının daha iyi olduğu sonucuna ulaşmıştır.

Çizelge 1.1’de, üstteki paragrafta ifade edilen çalışmalara ek olarak elektrik fiyat tahmini yapan ve elektrik fiyatlarını öngören çalışmalar özetlenmeye devam edilerek bir bakıma bu tez çalışmasının farklı yanları da ortaya konulmaya çalışılmıştır.

Çizelge 1.1. Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Szkuta ve ark. [11]	1999	Electricity Price Short Term Forecasting Using Artificial Neural Networks	Victorian Power System' daki gerçek veriler kullanılarak sistem marjinal fiyatının geri yayılım algoritması ile yapay sinir ağları kullanılarak kısa dönemli tahmininin elde edilmesi	Yapay sinir ağları	Çalışmada, Victorian Independent System Operator tarafından haftalık olarak yayınlanan ve regresyon analizi teknikleri kullanılarak öngörüsü yapılan sistem marjinal fiyatından, yapay sinir ağları ile gerçekleştirilen öngörünün daha iyi sonuçlar verdiğini gösterilmiştir.
Tay F., Cao L. [12]	2001	Application Of Support Vector Machine In Financial Time Series Forecasting	Bu çalışmada amaç, Chicago Ticaret Borsası' nda işlem gören beş vadeli sözleşmeye ilişkin finansal verilerin öngörüsünde destek vektör makinelerinin ile sinir ağlarının performansını karşılaştırmak ve finansal öngörülerde DVM' nin fonksiyonel özelliklerini belirlemek olarak şekillenmiştir.	Destek vektör makineleri, Geri yayımlı sinir ağları	Normalleştirilmiş ortalama kare hatalar (NMSE), Ortalama mutlak hata (MAE), yönelim simetrisi (DS) ve ağırlıklı yönelim simetrisi (WDS) kriterlerine göre DVM' nin sinir ağlarına göre öngörü performansının daha iyi olduğu bulgusu elde edilmiştir. Ayrıca, yapılan çalışmalar sonucunda DVM' nin finansal zaman serileri öngörüsünde başarılı olduğu vurgulanmıştır.
Sansom ve ark. [13]	2003	Evaluation of Support Vector Machine Based Forecasting Tool in Electricity Price Forecasting for Australian National Electricity Market Participants	Avustralya Milli Elektrik Piyasasında Ekim 1998 ile Aralık 1998 tarihleri arasında New South Wales bölgesine ait verilerden yararlanarak öngörü yapılan modellerin performansının karşılaştırılması	Destek vektör makineleri, Sinir ağları	Destek vektör makinesi ve sinir ağları ile gerçekleştirilen öngörü doğruluğu birbirine yakın sonuçlar verildiği sonucuna ulaşılmıştır.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Kim, K,J [14]	2003	Financial Time Series Forecasting Using Support Vector Machines	Hisse senedi fiyat endeksinin tahmin edilemesi ve öngörülmesi	Destek vektör makineleri, Geri yayımlı yapay sinir ağları sinir ağları, Durum tabanlı çıkarsama (Case-based reasoning)	Destek vektör makineleri, tahmin performansı olarak diğer iki yöntemle göre daha iyi olduğu belirlenmiştir.
Pai, F.,P., Lin, C.,S. [15]	2005	A Hybrid ARIMA And Support Vector Machines Model In Stock Price Forecasting	Çalışma kapsamında önerilen hibrit model ve diğer modeller ile on adet hisse senedi fiyatına ilişkin öngörü yapılarak performanslarının karşılaştırılması	Hibrit model (ARIMA+SVM), ARIMA,SVM	MAE, MAPE, MSE, RMSE kriterlerine göre hibrit modelin öngörü performansının daha iyi olduğu belirlenmiştir.
Gareta ve ark. [16]	2006	Forecasting of Electricity Prices with Neural Networks	Geçmiş ve tahmin verilerini kullanarak yapay sinir ağlarının elektrik fiyatları öngörüsü açısından uygunluğunun test edilmesi	Geri yayımlı yapay sinir ağları	Simülasyon çalışması sonucunda tespit edilen hesaplama zayıflıklarının yapay sinir ağı modelleriyle çözülebileceği tespit edilmiştir.
Catalão ve ark. [17]	2007	An Artificial Neural Network Approach for Short-Term Electricity Prices Forecasting	İspanya' da elektrik piyasasına ilişkin 168 saatlik fiyat tahminin yapıp kullanılan yöntemlerin performanslarının değerlendirilmesi	Levenberg-Marquardt algoritması ile yapay sinir ağları, ARIMA teknikleri	Çalışma sonucunda, yapay sinir ağları ile yapılan tahminin ARIMA tekniğine göre yapılan tahminden daha kısa sürmüş olduğu, MAPE kriterinin SSE ve SDE kriterine göre ilgili iki yöntemi daha iyi değerlendirebileceği sonucuna varılarak yapay sinir ağlarının tahmin açısından ARIMA tekniğine göre daha performanslı olduğu belirtilmiştir.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Catalão ve ark. [18]	2007	Short-Term Electricity Prices Forecasting In A Competitive Market: A Neural Network Approach	İspanya ve California elektrik piyasasında gelecek haftanın fiyat öngörüsünün gerçekleştirilmesi	Levenberg-Marquardt algoritmali üç katmanlı ileri beslemeli yapay sinir ağı	Ortalama hata İspanya piyasası için %9, California piyasası için %3 civarında belirlenmiştir. Yazarların [8] çalışmasına göre yapay sinir ağlarının daha iyi olduğu belirtilmiştir.
H. T. Pao [19]	2007	Forecasting Electricity Market Pricing Using Artificial Neural Networks	Avrupa Enerji Piyasasında (EEX), gün öncesi piyasası elektrik fiyatlarının yapay sinir ağları ile tahmin edilmesi ve örneklem dışı dönem performansının değerlendirilmesi	Yapay sinir ağları, otoregresif hata modelleri	RMSE, MAPE, MAE kriterine göre, yapay sinir ağlarının örneklem dışı öngörü performansı otoregresif hata modellerinkinden daha iyi olduğu öte yandan farklı öngörü dönemlerinde otoregresif modellere göre daha az örnekleme değişim etkisine sahip olduğu sonucuna ulaşılmıştır.
J Zung ve ark. [20]	2008	Day Ahead Electricity Price Forecasting Using Artificial Intelligence	Çalışmanın kapsamını, Dünyanın en başarılı elektrik piyasalarından biri olan Nord Pool Elektrik piyasasında gün öncesi piyasasına ilişkin fiyat tahminlerinin yapılması oluşturmaktadır.	Çok katmanlı yapay sinir ağları, ARIMA	Çalışma sonucunda, MAPE, MSRE, RMSE, kriterlerine göre önerilen modelin (çok katmanlı yapay sinir ağları) ARIMA modeline göre elektrik fiyatlarını daha iyi tahmin ettiği ve geleneksel ARIMA modelinden daha iyi olduğu sonucuna varılmıştır.
L. Jiying, L. Jinchao [21]	2008	Next-Day Electricity Prices Forecasting Based On Support Vector Machines and Data Mining Technology	Serbestleştirilen elektrik piyasasında, Piyasa Takas Fiyatının (MCP) destek vektör makineleri yapay sinir ağları ile tahmin edilmesi	Önerilen yeni tip destek vektör makineleri, geri beslemeli klasik yapay sinir ağları	Hem test hem de eğitim verisi için birer haftalık öngörü yapılarak ilgili yöntemlerin performansı değerlendirilmiştir. Buna göre, önerilen modelin (DM-SVM) klasik yapay sinir ağına göre daha düşük tahmin hatasına sahip olduğu belirlenmiştir.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Ruas ve ark. [22]	2008	Electrical Energy Demand Prediction Using Artificial Neural Networks And Support Vector Regression	Bu çalışmada, Brezilya elektrik piyasasında kısa dönemli elektrik talebinin tahmin edilmesi	Yapay sinir ağları, destek vektör regresyonu	Çalışma sonucunda, yapay sinir ağlarındaki eksikliğin destek vektör regresyonu kullanılarak giderileceği sonuna varılmıştır.
Amjady, N. ve Hemmati, M. [23]	2009	Day-Ahead Price Forecasting Of Electricity Markets By A Hybrid Intelligent System	Bu çalışmada, İspanya elektrik piyasasının spot elektrik piyasasındaki piyasa takas fiyatının önerilen hibrit yöntemin diğer yöntemlerle karşılaştırılması	Hibrit intelligent system, ARIMA, Wavelet ARIMA, Fuzzy NN, GARCH	Önerilen hibrit yöntemi gerçek Rçga ve yapay sinir ağlarının birleşiminden oluşmaktadır. Çalışma sonucunda, hibrit modelin çalışmada kullanılan diğer yöntemlere göre öngörü başarısının daha iyi olduğu sonucuna varılmıştır.
J.Che, J.wang [24]	2010	Short-term electricity prices forecasting based on support vector regression and Auto-regressive integrated moving average modeling	Bu çalışmada önerilen SVRARIMA modelinin Kaliforniya Elektrik Piyasasında gelecek hafta fiyatlarının öngörülmesi. Elektrik fiyatlarını oluşturulan hibrit model (SVRARIMA) nın SVR, ARIMA ve diğer birleşimleri ile performanslarını karşılaştırmak	SVR, SVRARIMA, ARIMA, NN, NNARIMA, ARIMASVR	RMSE ve MAPE kriterlerine göre, önerilen yöntemin (SVRARIMA) öngörü performansının diğer yöntemlere göre daha iyi sonuçlar verdiği sonucuna ulaşılmıştır.
Areekul ve ark. [25]	2010	A Hybrid ARIMA And Neural Network Model For Short-Term Price Forecasting In Deregulated Market	Avustralya elektrik piyasasında (NEM), New South Wales Bölgesinde, 2006 yılında ki veriler kullanarak önerilen hibrit model ile bir haftalık fiyat öngörüsünün gerçekleştirilmesi	ARIMA, yapay sinir ağları, hibrit model(ARIMA ve LM algoritmasına dayanan üç katmanlı ileri beslemeli YSA)	İki model bir araya getirilerek oluşturulmuş bu çalışmadaki hibrit modelin öngörü performansı kullanılan tüm kriterlere göre (MAPE, MAE, RMSE) ARIMA ve YSA dan daha iyi sonuç vermiştir.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
M.T. Tsai, C.H. Chen [26]	2011	An Artificial Neural Network Approach for Short-Term Electric Prices Forecasting	Bu çalışmada, elektrik fiyatlarındaki oynaklık nedeniyle oluşan riskten kaçınmak için kısa dönemde elektrik fiyatlarının tahmini için bir öngörü metodu önerilmiştir.	Geri yayımlı sinir ağları, ortogonal deney tasarımına (OED) dayalı yeni yapay sinir ağları yaklaşımı	RMSE kriterine göre, geri yayımlı sinir ağları yöntemine göre yeni öngörü metodunun daha güçlü, etkili ve doğru olduğu ve elektrik fiyatlarındaki oynaklığı belirlemede daha iyi sonuçlar verdiği bulgusu elde edilmiştir.
D. Singhal, K.S. Swarup [27]	2011	Electricity Prices Forecasting Using Artificial Neural Networks	Enerji Piyasasında günlük takas fiyatının(MCP) normal trendde, fiyattaki ufak ve büyük sıçramalarda 48 saatlik öngörü performansının değerlendirilmesi	Çok katmanlı geri beslemeli yapay sinir ağları	Yapay sinir ağları ile gerçekleştirilen elektrik fiyatları tahmininde, elektrik fiyatlarında trendin normal olduğu durumlarda tahmin değeri gerçek değerleri izlediği ve fiyat sıçramalarını doğru tahmin ettiği sonucuna varılmıştır.
Jakaša ve ark. [28]	2011	Electricity Price Forecasting – ARIMA Model Approach	Almanya elektrik piyasasında 2000-2011 döneminde gün öncesi piyasası günlük elektrik fiyatları kullanılarak öngörü yapılması	ARIMA	MAPE kriterine göre, ARIMA (3,0,3) (1,1,1) modeli kullanılarak fiyat öngörüsü gerçekleştirilmiştir.
Zhang ve ark. [29]	2012	Day-Ahead Electricity Price Forecasting By A New Hybrid Method	Avustralya Milli Elektrik Piyasasında New South Wales' e ait elektrik verileri kullanılarak önerilen hibrit modelin diğer öngörü yöntemlerine göre elektrik fiyatları tahmininin performansının değerlendirilmesi	Wavelet transform, ARIMA, parçacık sürüsü optimizasyonuna dayanan en küçük kareler destek vektör makineleri	Amprık test sonuçlarına göre önerilen hibrit modelin öngörü performansının diğer öngörü yöntemlerine göre performansının daha iyi olduğu sonucu elde edilmiştir.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Anbazhagan ve Kumarappan [30]	2012	A Neural Network Approach To Day-Ahead Deregulated Electricity Market Prices Classification	Bu çalışmada, İspanya ve New York' ta serbestleştirilen piyasalarda yapay sinir ağları modelleriyle gün öncesi piyasasında elektrik fiyatlarının sınıflandırılmaya çalışılmıştır.	Üç katmanlı ileri beslemeli sinir ağları (FFNN), LM algoritmasıyla eğitilmiş ardışık beslemeli sinir ağları (CFNN) ve genelleştirilmiş regresyon sinir ağları (GRNN)	Ortalama yüzde sınıflandırma hatası (MPCE) ve sınıflandırma yüzdesi doğruluğu (PCA) kriterleri doğrultusunda, önerilen ardışık beslemeli sinir ağları yönteminin fiyat sınıflandırması açısından daha iyi olduğu sonucuna ulaşılmıştır.
Sahay ve Tripathi [31]	2014	Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Network	ISO New England ve PJM piyasasında yapay sinir ağları yöntemiyle elektrik yük tahmininin yapılması ve piyasaların yapılan tahmin açısından karşılaştırılması	Yapay sinir ağları	YSA modellerinin, gün öncesi elektrik piyasasında yük tahmini açısından en az olası hata ile tahmin ettiği ve sıcaklık değerinin yük tahmininde önemli bir role sahip olduğu belirlenmiştir. Ayrıca, MAPE kriterine göre, ISO New England için yapılan yük tahmininin PJM için yapılan tahminden daha iyi olduğu sonucuna ulaşılmıştır.
Mei ve ark. [32]	2014	A Random Forest Method For Real-Time Price Forecasting In New York Electricity Market	New York elektrik piyasasında gerçek zamanlı elektrik fiyatlarının tahmin edilmesi	Rastgele orman, Yapay Sinir Ağları, ARMA	MAPE kriterine göre, en iyi tahmin performansına sahip yöntem rastgele orman yöntemidir.
Razak ve ark. [33]	2015	Support Vector Machine For Day Ahead Electricity Price Forecasting	Bu çalışmada, saatlik Ontario gün öncesi elektrik piyasasında saatlik fiyat tahmininin bir makine öğrenme yöntemi yaklaşımı olan en küçük Kareler Destek Vektör Makineleri ile tahmin edilmek istenmiştir. Bu yöntem kullanılarak Sinir ağları ile tahmin performansları karşılaştırılmak istenmiştir.	En küçük kareler destek vektör makineleri (LS-SVM) ve Sinir ağları (NN)	Bu çalışmada önerilen LS-SVM yönteminin sinir ağlarına göre hem MAPE hem de regresyon değeri (R) ölçütleriyle değerlendirildiğinde performansının daha iyi olduğu bulgusu elde edilmiştir.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Adalı [34]	2015	Gün Öncesi Piyasasında Saatlik ve Günlük Elektrik Fiyatlarının Tahmini	Türkiye' de gün öncesi piyasasında 2010-2013 dönemi kullanılarak 2014 yılına ait saatlik ve günlük elektrik fiyatlarının gerçek veriler kullanılarak tahmin edilmesi	Regresyon analizi, yapay sinir ağları	Tahmin hatası MAPE ve RMSE, tahmin başarısı ise NASH kriteri ile değerlendirilmiştir. Buna göre tahmin yöntemlerinin performansının, saatlik ve günlük tahminlerin günlük ve mevsimsel boyuta göre değiştiği ve bunun nedeninin ise sadece talep açısından kayanaktanmadığı ifade edilmiştir.
Saini ve ark. [35]	2016	Electricity Price Forecasting by Linear Regression and SVM	Kısa dönemde elektrik fiyatlarının destek vektör makinesi ve doğrusal regresyona dayalı yeni bir hibrit yöntemle tahmin edilmesi	Doğrusal Regresyon, Destek vektör makineleri	Yazar, referans aldığı iki kaynaktaki çalışmada elde edilen sonuçlarla kendi önerdiği yöntemi karşılaştırmıştır. Önerdiği sonucun bu iki yöntemle göre daha iyi performans gösterdiği sonucuna ulaşmıştır.
Davò ve ark. [36]	2016	Forecasting Italian Electricity Market Prices Using A Neural Network And A Support Vector Regression	Tekdüze alış fiyatları (PUN) ve bölgesel fiyatların saatlik tahminin gerçekleştirerek	Yapay sinir ağları ve destek vektör regresyonu	Hem PUN hem de bölgesel fiyat öngörüsünde RMSE ve MAE kriterlerine göre yapay sinir ağlarının daha iyi öngörü performansına sahip olduğu belirlenmiştir.
Dalgın [37]	2017	Yapay Sinir Ağları Kullanılarak Türkiye Gün Öncesi Piyasası Elektrik Fiyat Tahmini	Türkiye elektrik piyasasının gün öncesi piyasasında piyasa takas fiyatının kısa dönemli tahmin edilmesinde farklı girdilerin etkilerinin değerlendirilmesi	Levenberg-Marquardt ileri beslemeli geri yayımlı öğrenen yapay sinir ağları	Bu tez çalışmasında önerilen Yapay sinir ağı modelinde, en iyi sonucu veren girdi kümesi olarak, bir önceki gün fiyatları, yedi gün önceki fiyatlar, gün tipi, ramazan ayı gün tipi, bayram gün tipi, hava sıcaklığı, doğalgaz maliyeti, net talep miktarı değişkenleri ifade edilmiştir. Ayrıca, modelde nöron sayısının artırılması tahmin performansının daima artmayacağı sonucuna varılmıştır.

Çizelge 1.1. (devam) Elektrik fiyatları ve makine öğrenmesi ile ilgili yapılan çalışmalar

Yazar	Yıl	Çalışma	Konu	Yöntem	Bulgular
Pokora J. [38]	2017	Hybrid ARIMA and Support Vector Regression in Short Term Electricity Price Forecasting	Bu çalışmada amaç, Nordik Pool Piyasasında gün öncesi elektrik fiyatlarının tekil ve hibrid yöntemlerle tahmin edip en uygun modelin belirlenmesi şeklindedir.	Naive, ARIMA, DVM, DVMARIMA, ARIMADVM	RMSE kriterine göre, önerilen hibit ARIMADVM modelinin, MAE kriterine göre DVR' nin en iyi performansı gösterdiği sonucuna ulaşılmıştır.
Gao ve ark. [39]	2017	Comparison of ARIMA and ANN Models Used in Electricity Price Forecasting for Power Market	Bu çalışmadaki amaç, İngiltere elektrik piyasasında yarım saatlik, bir saatlik ve bir buçuk saatlik periyotlarda otoregresif bütünleşik hareketli ortalamalar yöntemi ile yapay sinir ağları yöntemi kullanılarak fiyat tahmini yapmak ve öngörü performanslarını karşılaştırmak olarak şekillenmiştir.	ARIMA, yapay sinir ağları	RMSE ile yapılan öngörü değerlendirmesi sonucunda ARIMA(4,1,2) modelinin YSA(20 Nöron, 4 gecikme) modeline göre öngörü performansının daha iyi olduğu sonucuna varılmıştır.
Sangrody ve ark. [40]	2018	Long Term Forecasting Using Machine Learning Methods	Çalışmanın konusunu, çeşitli makine öğrenmesi yöntemleri ile New England ağı çalışması için uzun dönemli elektrik yük tahmini performanslarının karşılaştırması oluşturmaktadır.	İleri beslemeli yapay sinir ağları, destek vektör makineleri, recurrent sinir ağları, genelleştirilmiş regresyon sinir ağları, k- en yakın komşu, Gauss süreci regresyon	Analiz sonucunda, MAPE kriterine göre değerlendirilen metotlardan en iyi öngörü performansına sahip yöntem ileri beslemeli yapay sinir ağı iken en kötü öngörü performansını genelleştirilmiş regresyon sinir ağları göstermiştir.
Gonzalez ve ark. [41]	2019	Machine Learning Models for Electricity Consumption Forecasting: A Review	Çalışmada, bir ayakkabı mağasından alınan bir yıllık veri ile elektrik tüketiminin makine öğrenmesi yöntemleri ile tahminini içermektedir.	Rastgele orman, karar ağaçları, K- en yakın komşu, Doğrusal regresyon, Destek vektör regresyonu	Destek vektör ve doğrusal regresyon yöntemleri elektrik tüketimini en iyi tahmin eden yöntemler olarak bulunurken rastgele orman yöntemi en başarısız yöntem olmuştur.

Literatürde, elektrik fiyat tahmini yapan çalışmalar daha çok katı ve esnek hesaplama yöntemleri çerçevesinde ele alınmıştır. Katı hesaplama yöntemleri, Otoresif Bütünleşik Hareketli Ortalamalar (ARIMA) ve Genelleştirilmiş Otoresif Koşullu Değişen Varyans (GARCH) gibi yöntemleri içeren zaman serisi yöntemleridir. Bu yöntemler, tahmin performansı açısından iyi olmasına rağmen çok bilgi gerektirmesi ve hesaplama süresinin uzun olması dezavantaj oluşturmaktadır. Esnek hesaplama yöntemlerine ise makine öğrenmesi, bulanık yöntemler, genetik algoritmalar örnek verilebilir. Katı hesaplama yöntemleri doğrusal tahmin edici iken esnek hesaplama yöntemleri doğrusal olmayan tahmin edicilerdir. Esnek hesaplama, katı hesaplama göre daha sağlam ve daha hızlı yöntemlerdir [42].

Bu tez çalışmasında, elektrik fiyatlarının genellikle doğrusal olmama özelliğinden dolayı, Gün Öncesi Piyasasında elektrik fiyatlarının tahmin edilmesinde esnek hesaplama yöntemlerinden makine öğrenmesi yöntemlerinin denetimli öğrenme (supervised learning) sınıfında yer alan Yapay Sinir Ağları (YSA), Destek Vektör Makinelerinin regresyon (DVR) kısmı ve Rastgele Orman yönteminin regresyon (RF) kısmı ele alınmıştır. Literatürde, elektrik fiyatını tahmin eden çalışmalarda YSA ve DVR, RF' ye göre daha çok kullanıldığı belirlenmiştir. Türkçe olarak sunulan tezler incelendiğinde ise elektrik fiyatının tahmin edilmesinde YSA ve DVR yöntemleri kullanılmasına rağmen RF yönteminin kullanıldığı bir tez çalışmasına rastlanılmamıştır. Bu tez çalışmasında, bu boşluğu doldurmak adına RF yöntemi ile elektrik fiyatları tahmin edilerek YSA ve DVR yöntemi ile gerçekleştirilen tahminle karşılaştırılmıştır. Bu yönüyle, Türkçe sunulan tezler arasında özgün bir çalışma olarak literatüre katkı yapması amaçlanmıştır.

Makine öğrenmesi ise verinin bilgiye dönüşmesi sürecine aracılık eden yöntemler bütünü olarak ifade edilmekte olup istatistik, yapay zekâ ve bilgisayar biliminin kesişiminden oluşan bir araştırma alanıdır. Ayrıca tahmine dayalı çözümlene veya istatistiksel öğrenme olarak bilinmektedir. Makine öğrenmesi yöntemleri, günlük hayatın birçok alanında yaygın bir şekilde kullanılmaya başlanmıştır. Hangi filmin izlenebileceği, hangi yemeğin sipariş edilebileceği hangi ürünün alınabileceği gibi karşımıza aniden çıkan otomatik reklam önerilerinden, kişiselleştirilmiş çevrimiçi radyoya, fotoğraflardaki yüzü tanıma kadar ve birçok web sitesi ve cihazın merkezinde makine öğrenmesi algoritmaları yer almaktadır. Ayrıca, ticari uygulamalar haricinde, DNA' nın analizi,

kişiyeye özel kanser tedavisi, uzak gezegenlerin bulunması, yıldızların tespit edilmesi gibi birçok bilimsel problemlerde de uygulanmaktadır [44].

Makine öğrenmesi yöntemleri, eğitim süreci esnasında aldıkları denetim türüne ve miktarına göre sınıflandırılmaktadır. Bu yöntemler, denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning), yarı denetimli öğrenme (semisupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) şeklinde dört ana gruba ayrılmaktadır. Denetimli öğrenmede, algoritmaya tanıtılan eğitim verileri etiket olarak adlandırılan hedef çıktıları içermektedir. Denetimsiz öğrenmede, eğitim verileri hedef çıktıları içermemekte olup sistem, öğretmensiz bir öğrenme süreci geçirmektedir [45].

Bu tez çalışmasında kullanılan yöntemlerden birisi olan **yapay sinir ağları (YSA)** kavramı geleneksel hesaplama yöntemlerine alternatif olan birbirine kuvvetli derecede bağlı basit işlem birimlerinin çeşitli yapılarını belirlemek için kullanılmaktadır. Biyolojik sinir ağlarından (BSA) etkilenecek oluşturulmuş hesaplama sistemleridir. YSA' nın genel yapısı, nöronlardan, ağırlıklardan ve sapma (bias) dan oluşmaktadır. YSA, birbirine bağlı nöronlardan oluşmaktadır. Benzer özelliklere sahip nöronlar aynı katman içerisinde yer almaktadır. Bir katman, bünyesinde bulunan nöronların birbirleriyle etkileşim içinde olmadığı ancak komşu katman veya dış çevreyle etkileşim içerisinde olduğu nöronlar topluluğudur. YSA' ya dayanan teknikler, geleneksel matematiksel modelin yetersiz kaldığı çok karmaşık problemlerde etkili bir şekilde uygulanmaktadır. Geleneksel yaklaşımlardan farkı, eğitim verisinden öğrenme gerçekleştirerek ilgili işlem birimlerini temsil etme kabiliyetidir [11, 46, 47].

Doksanlı yılların başlarında, sınıflandırma ve regresyon problemleri için doğrusal olmayan çözümler verebilen **destek vektör makineleri (DVM)** adında yeni bir makine öğrenmesi algoritması gündeme gelmiştir. DVM, eğitim verilerini daha yüksek boyuta dönüştürmek için doğrusal olmayan bire bir ve örten fonksiyondan yararlanmaktadır. Bu yeni boyut içerisinde, doğrusal en uygun şekilde ayrılacak hiper düzlem aranmaktadır. Yeterince yüksek boyuta uygun doğrusal olmayan bu fonksiyon ile iki sınıfa sahip veriler bir hiper düzlem tarafından her zaman ayrılabilir. DVM, destek vektörlerini ve bu destek vektörleri tarafından belirlenen marjları kullanarak bu hiper düzlemi bulmaktadır. DVM, adını aslında, destek vektör olarak adlandırılan nispeten daha az sayıda gözlem

tarafından belirlenen hiper düzlemden almaktadır. Sezgisel olarak, hiper düzelemin bu destek vektörler tarafından hareket ettirildiği düşünülebilmektedir. Destek vektörleri yer aldığı model açısından önem taşımaktadır. Destek vektörü olmayan gözlemler veriden çıkarıldığında modelde herhangi bir değişikliğe neden olmazken, eğer bu gözlemler destek vektörü ise hiper düzlem maksimum marjlı olma özelliğini yitirmektedir. DVM, genellikle sınıflandırma ve regresyon şeklinde iki kategoriye ayrılmaktadır. Destek vektör sınıflandırıcısı (DVS), eğitim verisindeki sınıflar arasında marjı maksimize eden hiper düzlem bulunarak veriyi sınıflandırmaktadır. DVS' nin kullanılma amacı test aşamasında iyi bir tahmin kabiliyeti ile henüz sınıflandırılmamış verileri düzgün bir şekilde ayırabilmek için bir sınıflandırma kriterinin bulunmasıdır. Destek vektör regresyonu (DVR) ise, regresyon ve zaman serisi tahmini için kullanılan DVM' ye dayanan bir makine öğrenmesi yöntemidir. DVM, özellikle doğrusal olmama halinde zaman serisi öngörüsünde kullanılmaktadır. DVM' nin gücü, girdi verilerini yüksek boyutlu uzaya eşlemesi (mapping into) ve bu yeni uzayda doğrusal kısıtlar oluşturmak için basit doğrusal fonksiyonların kullanılmasından gelmektedir [36, 48, 49, 50].

Rastgele orman (RF) yöntemi, gerçek bir ormanın tanımına benzer şekilde tekil ağaçların bir grubu oluşturmasıdır. RF, denetimli bir makine öğrenmesi olup hem sınıflandırma hem de regresyon için kullanılmaktadır. Leo Breiman ve Adele Cutler tarafından rastgele seçilen bir özellik alt uzayında yetişen ilişkisiz karar ağaçları grubuyla topluluk temelli bir tahmin edici oluşturmak için geliştirilmiştir. RF' nin selefi Breiman tarafından 1984 yılında önerilen Sınıflandırma ve regresyon ağaçları (CART) yöntemidir. Breiman, 1996 yılında Bagging olarak adlandırdığı RF yöntemi için bir diğer önemli kavramı tanıtmıştır. RF, sınıflandırma için bir topluluk öğrenme yöntemidir. CART ve Bagging olmak üzere üzere iki tekniğe dayanmaktadır. Rastgele orman regresyonu, rastgele orman sınıflandırıcısının kullandığı sınıf etiketlerinin aksine sayısal değerler almaktadır [32, 51, 52].

Literatür taraması kısmında bahsedildiği üzere, bugüne kadar, elektrik fiyatlarının tahmin edilmesinde ve öngörülmesinde birçok yöntemden yararlanılmıştır. Bu yöntemler çeşitli çalışmalarda karşılaştırılarak birbirine olan üstünlükleri belirlenmeye çalışılmıştır. Bu çalışmada da kullanılan üç yöntem (YSA, DVR ve RF) ile elektrik fiyatları tahmin edilerek tahmin performansı en iyi olan yöntem ile bir sonraki günün öngörüsü gerçekleştirilmiştir.

Bu tez çalışması kapsamında, giriş bölümünde anlatılanlara ek olarak ikinci bölümde elektrik piyasası ve makine öğrenmesi yöntemleri hakkında bilgiler verilmiştir. Üçüncü bölümde ise gün öncesi piyasasında elektrik fiyatının tahmin edildiği uygulama bölümüne yer verilmiştir. Dördüncü bölümde analiz sonuçları özetlenerek yorumlanmıştır.

2. GENEL BİLGİLER

İkinci bölüm iki alt başlık altında incelenmiş olup ilk alt başlıkta elektriğin tarihi, elektrik piyasaları, elektrik piyasalarında reform hareketleri, Türkiye’ de elektrik piyasası ve tarihi ve Dünya’ da bazı önemli elektrik piyasaları anlatılmıştır. İkinci alt başlıkta ise, bu tez çalışmasında PTF’ nin tahmininde kullanılan YSA, DVR, RF yöntemlerine ait detaylı bilgiler verilmiştir. Böylelikle, üçüncü bölümde sunulan uygulama kısmının alt yapısı oluşturulmuştur.

2.1. Elektriğin Tarihi ve Elektrik Piyasaları

Elektrik sözcüğü köken olarak Yunanca bir kelime olup adını “kehribar” veya “elektron” dan almaktadır. Kehribar, iki yüzden fazla çeşidi olan fosilleşmiş bir reçinedir. Mücevher yapımında kullanılan ve Baltık’ tan Adriyatik ve Akdeniz’ e uzanan “amber yolu” tarihin ilk ticaret yolları arasında yer almaktadır. Elektriğin isminin neden kehribara dayandırıldığı antik çağda yaşayan insanların, kehribarlarını parlattıkları ve bu parlatmadan kaynaklı kehribar etkisinden dolayı saman parçalarını çektiği düşüncesinden gelmektedir. Bu olgu günümüzde, statik elektrik olarak bilinmektedir. Kehribar, hafif cisimleri kendine çeken, samankapan anlamına da gelmektedir. Antik Yunanca’ da kökeni Güneş (elios) veya seçmen (elector) kelimesine dayanan “elektron” sözcüğünden türemiştir [53, 54].

Elektrik alanında sistematik çalışmalar, her ne kadar Kraliçe Birinci Elizabeth’ in ölümüyle (1603) sekteye uğrasada, 16. yy’ nin sonlarına doğru doktoru William Gilbert tarafından yapılan çalışmalarla başlamıştır. Yazdığı De Magnete isimli kitabında, antik çağdan beri bilinen bu kehribar etkisinin sadece kehribardan ve aynı zamanda sadece samandan kaynaklanmadığı göstermiştir. Gilbert, kehribar kelimesini değiştirerek elektrik çekimi, elektrikli durum gibi kelimeler kullanmıştır. Elektriksel, elektrik kavramları sırasıyla ilk kez 1618 ve 1646 yıllarında kullanılmıştır [53].

Elektrik ve manyetik olayların bilimsel ve niceliksel keşfi 17. yy. ve 18. yy’ de başlamıştır. Sabit elektrik yükleri arasındaki kuvvetler Coloumb yasası ile açıklanmıştır. Elektrostatik ve manyestostatik matematiksel olarak ifade edilmiş ve modellenmiştir. Elektrik ve

manyetik arasındaki ilişki ve zamanla değişen hareketleri 19. yy'da da araştırılmaya devam etmiştir. (Oersted, 1820 and 1826, Ampere, 1820, Faraday, 1831, Henry, 1831, Maxwell, 1856 and 1873, Hertz, 1893). Oersted, bir elektrik akımının manyetik alan oluşturduğunu gözlemlemiştir. Faraday, zamanla değişen bir manyetik alanın elektrik alanı oluşturduğunu kanıtlamıştır. Henry bir elektromıknatis geliştirmiş ve öz-indüktansı keşfetmiştir. Maxwell, yer değiştirme akımını tanıtarak, günümüzde Maxwell eşitlikleri olarak bilinen elektromanyetik alanlar ve dalgalar için bir matematiksel yapı geliştirmiştir. Hertz, Maxwell eşitlikleri tarafından tahmin edilen elektromanyetik dalgaların yayılımlarını deneysel olarak kanıtlamıştır. 1878'de İngiltere 'de akkor ampulü icat edilmiştir. Aynı yıl Paris Evrensel Fuarı'nın açılışını kutlamak için Opera caddesine (the Avenue de l'Opéra) ve zafer takları çevresine Pavel Yablochkov tarafından ark lambası olarak adlandırılan ve elektrikli mum olarak da ifade edilen ilk elektrikli sokak lambaları kurulmuştur. 1879'da ABD' de Edison ve Jehl tarafından akkor ampul icat edilmiştir. 1881'de İngiltere' de Godalming' de elektrik santrali açılmıştır. İzleyen yılda ABD' de Pearl Street' te elektrik santrali kurulmuştur. Aynı yıl Almanya' da 59 km uzunluğunda 2400 V ilk iletim hattı çekilmiştir. 1885'te William Stanley tarafından ticari amaçlı pratik bir transformator üretilmiştir. Aynı yılda Fransa' da hidroelektrik santrali faaliyete geçmiş ayrıca 56 km'lik iletim hattı çekilmiştir. Yine aynı yıl içerisinde Norveç'te kamu elektrik arzını sunmaya başlamıştır. 1887'de Londra'da yer alan Lloyd Bankası' nın iç aydınlatması gerçekleştirilmiştir. 1894'te Malezya' da ki madenlerde motor pompalarının tedarik edilmesi için jeneratörler kullanılmaya başlamıştır. 1920 ile 1950 arasında Avrupa'da ve Amerika'da birçok ev elektriğe kavuşmuştur [55, 56].

Elektriğin hemen hemen tüm yönlerinin odağında depolama konusu vardır. Çoğu mal, stoklarda tutularak üretim ve tüketim dengesini sağlarken elektrik kavramı için bu durum söz konusu olamamaktadır. Elektrik enerjisinde yaşam döngüsündeki temel aşamaları: enerji kaynağı, elektriğin üretilmesi, ulaştırma şebekesinde yüksek ve düşük voltaja çevrilmesi, tedarik yönetimi ve tüketim şeklinde gerçekleşmektedir. [55]

2.1.1. Türkiye' de Elektrik Piyasası ve Tarihi

Türkiye' de elektrik üretimi 1902 yılında Tarsus'ta bir yel değirmenine bağlanan 2 kW gücünde bir dinamo ile başlamıştır. Tam anlamıyla elektrik üretimi ise 1913'te 18 MW gücünde Silahtarğa Santralinin açılmasıyla başlamıştır. Devletin önceliğinde elektrik

iřletmecilięi 1935 yılında yayınlanan 2805 sayılı kanun kapsamında ETİBANK'ın kurulmasıyla başlamıřtır [57]

Birinci ve İkinci Beř Yıllık Kalkınma Planları kapsamında Türkiye'deki imtiyazlı řirketler ve belediye sınırları dıřındaki yerler hariç tüm yurttaki elektrięin üretim, iletim, daęıtım ve ticaretinin tek bir kamu kurumu çatısı altında birleřtirilmesi planlanmıřtır. Bu doęrultuda, 1312 sayılı kanunla bu hedeflerin gerçekteřtirilebilmesi adına 1970 yılında kamu iktisadi teřebbüsü statüsünde Türkiye Elektrik Kurumu (TEK) kurulmuřtur. Beřinci ve altıncı Beř Yıllık Kalkınma Planları ve Ekonomik Önlemler Uygulama Planı ile TEK'in özelleřtirilmesi gündeme gelmiřtir [57, 58].

TEK, 1970 yılında kurulmasıyla birlikte Türkiye'de elektrik sektöründeki daęınık yapı ortadan kaldırılmaya çalıřılmıřtır. Böylelikle, imtiyazlı řirketlerin ve belediye sınırları dıřında tüm yurttaki elektrik iletim, daęıtım ve satıř hizmetleri TEK bünyesi altında toplanmıřtır. 1993 yılında sektörün daha etkin, verimli ve çağdař bir şekilde sürdürülebilmesi amacıyla özelleřtirme politikaları çerçevesinde TEK, Türkiye Elektrik Üretim-İletim A.ř. (TEAř) ve Türkiye Elektrik Daęıtım A.ř. (TEDAř) adı altında iki ayrı İktisadi Devlet Teřekkülü olarak yeniden düzenlenmiřtir. Fiili olarak bölünme ise 1994 yılında gerçekteřmiřtir. Aynı yıl Anayasa Mahkemesi kararıyla TEK'in mülkiyet satıřıyla özelleřtirilmesini öngören kanunun temel hükümleri iptal edilerek kamu elektrik iřletmelerinin mülkiyet devri ile özelleřtirilme yolu kapatılmıř, öte yandan, 3096 ve 4046 sayılı kanunlar çerçevesinde iřletme hakkının devri ile özelleřtirme yolu açılmıř olup bu kapsamda ilk olarak Çayırhan Termik Santralleri iřletme devri ile özelleřtirilmiřtir [57, 58].

2000 yılında çıkarılan 4501 sayılı kanun çerçevesinde elektrik mevzuatının Avrupa Birlięi müktesebatına uyumlu hale getirilebilmesi için sektörde yeniden yapılandırma çalıřmaları başlamıřtır. Bu kapsamda, hükümet tarafından gündeme getirilen "Ekonomik İstikrar ve Enflasyonla Mücadele" çerçevesinde TEAř' ın yeniden yapılandırılarak özelleřtirilmesi öngörülmüřtür. Bu programın amacı, elektrik enerjisi sektörünün yeniden yapılandırılması, serbest piyasa sistemine geçilmesi, rekabet ortamının saęlanması, elektrikle ilgili üretim, iletim, toptan satıř ve daęıtım için ayrı ayrı kamu řirketleri kurulması ve son ařamada, üretim ve daęıtımla ilgili kamu elektrik řirketlerinin özelleřtirilmesidir [57].

2001 yılında yürürlüğe giren 4628 Sayılı Elektrik Piyasası Kanunu ile elektrik sektöründeki faaliyetlerin serbest piyasa koşullarında gerçekleşmesi amaçlanmıştır. Bu kapsamda Bakanlar Kurulu kararı ile TEAŞ, iletim, üretim ve ticaret faaliyetlerinin birbirinden ayrıştırılmasıyla söz konusu faaliyetlerden sorumlu olacak şekilde Türkiye Elektrik İletim A.Ş (TEİAŞ), Elektrik Üretim A.Ş (EÜAŞ) ve Türkiye Elektrik Ticaret ve Taahhüt A.Ş (TETAŞ) unvanlarında, anonim şirket statüsünde üç kamu iktisadi devlet teşekkülü şeklinde yapılandırılmıştır. Aynı yıl ve aynı kanun ile Enerji Piyasaları Düzenleme Kurulu (EPDK) kurulmuştur [57, 58].

2009 yılında Gün öncesi planlama mekanizması devreye girerek saatlik fiyatlandırma ve uzlaştırma başlamıştır. 2011 yılında Gün Öncesi Piyasası (GÖP) devreye girmiştir. 2013 yılında 6446 Sayılı Elektrik Piyasası Kanunu ile Enerji Piyasaları İşletme Anonim Şirketi (EPIAŞ)' nin kurulması hükme bağlanmıştır. 2015 yılında EPIAŞ resmen kurulmuştur. Aynı yıl içerisinde Gün İçi Piyasası kurulmuştur. 2017 yılında 6446 sayılı kanunda yapılan değişiklikle birlikte TETAŞ ve EÜAŞ, EÜAŞ bünyesinde birleştirilmiştir [59, 60].

Türkiye’de elektrik sektöründe yaşanan politika değişimleri üç ana başlıkta incelenmektedir. İlk olarak 1923-1984 dönemini kapsayan elektriğin ulusal ekonomi ve güvenlik açısından üretim, iletim, dağıtım ve ticareti kamu hizmeti olarak görülmüş ve devlet tekelinde gerçekleşmiştir. İkinci dönemde ise, 1984-2001 dönemini kapsamakta olup elektriğin bu aşamalarının devlet doğrudan kendisi yapmakta veya sözleşme yoluyla özel sektör eliyle yaptırmaktaydı. Üçüncü dönem ise 2001’den bu yana süregelen elektriğin üretim, iletim, dağıtım, ticaretinin serbest rekabet ortamında yapılması düşüncesine dayanmaktadır. Önemli bir kavram olmasından dolayı bu aşamalar bağımsız otorite veya otoritelerce denetlenme görüşünün benimsendiği ve uygulamaya geçirildiği dönemdir [57].

2.1.2. EPIAŞ (Enerji Piyasaları İşletme Anonim Şirketi)

EPIAŞ, 14 Mart 2013 tarihli 6446 Sayılı “Elektrik Piyasası Kanunu” ile 13 Ocak 2011 tarihli 6102 Sayılı Türk Ticaret Kanunu” ve özel hukuk hükümlerine tabi olarak, 18 Mart 2015 tarihinde tescil işlemlerinin tamamlanmasıyla birlikte kurulmuş olup 1 Eylül 2015

tarihinde, EPDK'dan piyasa işletim lisansı olarak faaliyete başlamıştır. EPİAŞ ilgili lisansı alana kadar piyasanın işletmeciliğini TEİAŞ yapmıştır [59].

EPİAŞ, piyasa işletim lisansı kapsamında, BİST ile TEİAŞ tarafından 6446 Sayılı kanun kapsamında işletilen piyasalar dışındaki organize toptan elektrik piyasalarının işletim faaliyetlerini yürütmektedir. Organize toptan elektrik piyasaları kavramı, elektrik enerjisi, kapasitesi veya perakende alış satışının gerçekleştirildiği ve piyasa işletim lisansına sahip merkezi bir aracı tüzel kişilik tarafından organize edilerek işletilen GÖP, GİP ve ileri tarihli fiziksel teslimat gerektiren diğer elektrik piyasaları ile sermaye piyasası aracı niteliğindeki standardize edilmiş elektrik sözleşmelerinin ve dayanağı elektrik enerjisi ve/veya kapasitesi olan türev ürünlerin işlem gördüğü ve BİST tarafından işletilen piyasaları ve TEİAŞ tarafından organize edilerek işletilen dengeleme güç piyasası ve yan hizmetler piyasası gibi elektrik piyasalarını ifade etmektedir. EPİAŞ, TEİAŞ tarafından piyasa işletim lisansı kapsamında işletilen organize toptan elektrik piyasalarının mali uzlaştırma işlemleriyle birlikte gerekli diğer mali işlemleri de yürütmektedir [60].

2.1.3. Gün Öncesi Piyasası

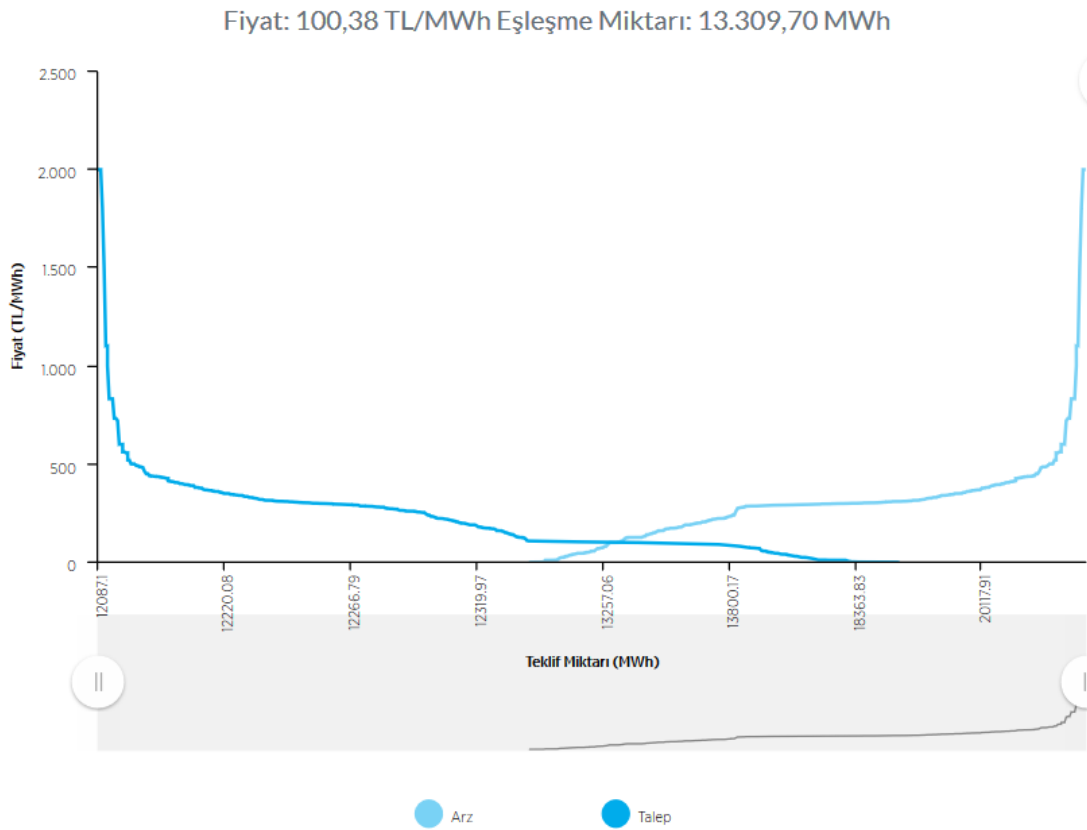
Gün öncesi piyasası, bir gün sonrası teslim edilecek uzlaştırma dönemi bazında elektrik enerjisi alış-satış işlemleri için kurulan ve piyasa işletmecisi tarafından işletilen organize toptan elektrik piyasası olarak tanımlanmaktadır. GÖP, sistemdeki arz ve talebin dengelenmesi ve piyasa katılımcılarının sözleşme taahhütleri ile üretim ve/veya tüketim planlarını gün öncesinden dengelemeleri amacıyla gerçekleştirilen faaliyetlerden oluşmaktadır. GÖP'te katılımcılar bir sonraki günün farklı saatleri için farklı tipte teklifler vermektedirler [61].

GÖP' te işlemler günlük olarak saatlik düzeyde gerçekleşmektedir. Piyasada bir günlük işlemler, 00:00 ile 23:59 arasında devam etmektedir. Piyasaya teklifler, bir sonraki günden itibaren ileri ki beş güne kadar verilebilmektedir. Gün öncesi piyasasındaki süreç, piyasada yer alan katılımcılar saat 12:30'a kadar bir sonraki güne ilişkin fiyat tekliflerini yerli gün öncesi piyasası vasıtasıyla piyasa işletmecisine sunmaktadır. Aslında, ilgili yönetmelik kapsamında saat 11:30 olarak ifade edilse de yaz- kış saati uygulamasının sonlandırılmasından dolayı bu saat 12:30 olarak belirlenmiştir. Teklif edilen her bir gün öncesi piyasası fiyat teklifleri piyasa işletmecisi tarafından 12:30 ile 13:00 saatleri

arasında değerlendirilerek doğrulanmaktadır. Kontrol edilen teklifler, saat 13:00 ile 13:30 arasında optimizasyon aracı ile değerlendirilmekte ve ilgili güne ait her bir saatin piyasa takas fiyatları ve miktarları belirlenmektedir. Onaylanan alış satış miktarlarına ilişkin ticari işlem onayları teklif veren piyasa katılımcısına bildirilmekte ve bu bildirimlerde hata olduğu takdirde katılımcıya 13.30 ile 13:50 arasında itiraz süresi tanınmaktadır. Yapılan itirazlar saat 14:00'a kadar değerlendirilerek sonuç katılımcıya bildirilmektedir. Saat 14:00'da bir sonraki günün 24 saatine ait nihai piyasa takas fiyatı ve eşleşmeler ilan edilmektedir. Nihai piyasa takas fiyatı (NPTF), belli bir saat ve belli bir teklif bölgesi için, teklif bölgeleri arasındaki iletim kısıtları dikkate alınarak GÖP' te belirlenen saatlik elektrik enerjisi alış- satış fiyatını belirtmektedir. Bu kavram, ilgili kanun çerçevesinde yapılan değişiklikle ortaya konulmuş olup fiyatların birden çok bölge için hesaplanacağı bir dönemin altyapısını hazırlamıştır. Ancak PTF, halihazırda, Türkiye' de tüm yurttan bir bölge (TR1) için hesaplandığından bu iki kavram şimdilik aynı ifadeyi temsil etmektedir [61, 62].

Tüm lisans sahibi tüzel kişiler Gün Öncesi Piyasası katılım anlaşmasını imzalayarak piyasa da katılımcı olarak yer alabilir. Piyasa katılımcıları, üretim lisansı sahibi, tedarik lisansı sahibi, organize sanayi bölgesi üretim lisansı sahibi, dağıtım lisansı sahibi ve iletim lisansı sahibi tüzel kişilerden oluşmaktadır. GÖP katılım anlaşması, piyasa katılımcısının GÖP'e katılımı ile Piyasa İşletmecisinin GÖP' ün işletimine yönelik koşul ve hükümlerin yer aldığı standart anlaşmayı tanımlamaktadır. Katılımcılar, GÖP' te belirli bir zaman dilimi için saatlik, blok ve esnek olarak teklif sunabilmektedirler. Her teklif, en az bir fiyat ve miktar ikilisinden oluşmaktadır. Bu teklifler farklı saatler için değişiklik gösterebilen fiyat ve miktar bilgilerinden meydana gelmektedir. Teklifler, alış ya da satış yönünde verilmektedir. Hangi yönde teklif verileceği teklif edilen miktarın önündeki işarete göre belirlenir. Katılımcılar, teklif miktarını Lot cinsinden tam sayı olarak vermektedir. Lot, gün öncesi piyasası ile gün içi piyasası kapsamında tekliflerin bildirilmesi amacıyla kullanılan ve 0,1 MWh'ye eşit olan enerji miktarını ifade etmektedir. Katılımcılar alış teklifini pozitif Lot değeri (75 Lot gibi), satış teklifi veriyor ise negatif Lot değeri (-50 Lot gibi) şeklinde vermektedir. Piyasa işletmecisi tarafından, asgari ve azami teklif miktarı saatlik ± 100.000 Lot, blok ± 6000 Lot ve esnek teklifte ise -6000 Lot şeklinde sınırlandırılmıştır. Öte yandan, yapılan teklifler Türk Lirası biriminden yapılmakta olup bildirilen tüm teklif fiyatları %1'lik hassasiyete sahiptir. Piyasa işletmecisi tarafından asgari fiyat teklifi 0 TL/MWh ile 2000 TL/MWh arasında

sınırlandırılmıştır. Saatlik tekliflerde, teklif veren katılımcılar, elektriği almak veya satmak için bir sonraki günün saatlerine ilişkin fiyat-miktar ikililerini (kırılım noktası) teklif etmektedirler. Teklifler, alış ve satış yönü ayrı ayrı 32 adet olmak üzere en fazla 64 seviyeden oluşmaktadır. Seviyelere ait fiyatlar artan şekilde belirlenmektedir. Hem alış hem de satış yönünde aynı fiyat seviyesinden fiyat teklifleri yapılamamaktadır. Ardışık iki fiyat veya miktar seviyesi arasında boş değerler mevcut ise arz ve talep eğrisi oluşturabilmek için boş değerler doğrusal interpolasyon yöntemi ile doldurulmaktadır. Bunun sonucunda parçalı doğrusal bir fonksiyon oluşmaktadır. Bir saatlik eşleşme miktarı parçalı doğrusal fonksiyon üzerinde PTF' ye karşılık değer olarak belirlenmektedir. Piyasa takas fiyatı (PTF), Gün Öncesi Piyasası kapsamında sunulan tekliflerin eşleştirilmesi sonucunda belirlenen saatlik elektrik enerjisi alış- satış fiyatıdır. Şekil 1.1' de PTF' nin oluşumu gösterilmektedir [61, 62, 63, 64].



Şekil 1.1. GÖP' te PTF oluşum süreci [65]

Blok teklifler ise, saatlik tekliflerin ardından piyasadaki ikinci en yaygın teklif çeşididir. Zaman ekseninde parçalanamayan ardışık saatlik teklifler olarak değerlendirilmektedir. Geçerli olduğu süre için sadece bir adet fiyat miktar ikilisi vardır. Bu durumda, teklif

edilen fiyat o miktarın tamamını almak veya satmak koşulu ile verilmektedir. Fiyat ve miktar bilgisine ek olarak bir sonraki gün için elektrik alımı veya satımı yapmak istenilen ardışık saatlerin sayısı da belirtilmektedir. Blok teklifler, fiyat, miktar ve kapsadığı zaman dilimi verilerini içermektedir. Blok teklifler tamamı bölünemez olarak işlem görüp her bir blok teklif kapsadığı aktif olduğu tüm zaman dilimi için ya kabul edilmekte ya da edilmemektedir. Teklifler en az 3 en fazla ise 24 saat için verilebilmektedir. Bir güne ait blok teklif sayısı 50 adet ile sınırlıdır. Blok teklifler arasında aynı teklif bölgesi için verilen, aynı işlem yönüne sahip (alış veya satış açısından) en fazla 6 adet blok teklif arasında (bağlı teklif) ilişki kurulmaktadır [63, 64].

Esnek tekliflerde, bir saat için sadece fiyat ve miktar bilgileri yer almaktadır. Teklifler sadece satış yönünde verilmektedir. Blok teklifte olduğu gibi, teklifler ya tamamen kabul edilmekte ya da tamamen reddedilmektedir. Esnek teklif, saatten bağımsız olarak verilerek günün herhangi tek bir saatinde kabul edilmektedir. Teklifin kabul edildiği saat en yüksek PTF' nin olduğu saat olmak zorunda değildir fakat teklif fiyatı en yüksek PTF' nin altında ise teklif uygun bir saat için kabul edilebilmektedir. Esnek teklif, en fazla 10 adetle sınırlandırılmıştır [63, 64].

2.1.4. Elektrik Piyasalarında Reform Hareketleri

1882'de New York'ta Pearl Street Power Station'da elektrik üretiminin gerçekleşmesiyle birlikte, elektrik endüstrisi ciddi bir dönüşüm içerisine girmiştir. 1980'li yılların başına kadar da elektriğin tedariki bir kamu hizmeti olarak görülmüş olup bu hizmet devlet tekelindeki şirketlerin üretim, iletim, dağıtım konusunda birleşerek düzenlenmiş ve dikey şekilde bütünleşerek organize edilen bir endüstri ile gerçekleşmiştir. 1980'li yıllardan itibaren birçok ülke elektrik endüstrisinde serbestleşmesinin (liberalization) yolunu açmak için adımlar atmaya başlamıştır. Bazı farklılıklara rağmen, Dünya genelinde endüstriler aynı fikir ve politika içerisinde serbestleştirilmeye başlanmıştır. Serbestleşme fikrinin ana düşüncesi, uzun dönemde, verimliliği artırmak, teknik açıdan yenilikleri teşvik etmek, verimli yatırımlarının önünü açmaktır [2,65]

Elektrik piyasasında yeniden yapılanma kavramı, geniş bir kavram olup, piyasa katılımcılarının ve düzenleyicinin piyasadaki rollerinin tekrar organize edildiği bir kavram olup serbestleşmenin (deregulation) olmazsa olmazı değildir. Kısıtların

kaldırıldığı serbestleşme kavramı olan (liberalization) kavramı, yeniden yapılanma kavramının eş anlamlısı olmayıp piyasanın kısmen veya tüm aşamalarında rekabeti artırmayı ve ticaret ve borsa engellerini kaldırma olarak tanımlanmaktadır. Deregülasyon kavramı ise, piyasada devlet tarafından belirlenen kısıtların kaldırılması veya azaltılması kavramıdır [66].

Elektrik piyasalarında serbestleşmenin ilk adımı Şili’ de atılmıştır. 1982 yılında başlayan bu reform üretim ve dağıtım şirketlerinin ayrılması fikrine dayanmaktaydı. Şili’ de büyük ölçekte özelleştirme ise 1986 yılında başlayarak sektör dikey olarak ayrılmaya başlamış ve toptan elektrik ticareti mekanizmasının oluşmasının yolunu açmıştır [65]

1990’lar boyunca, birçok ülke sektörün performansını artırmak amacıyla yönettikleri elektrik sektörünü yeniden yapılandırmaya başlamıştır. Bu ülkelerden birisi ve belki de en önemlisi olan İngiltere 1990 yılında elektrik sektörünü yeniden düzenleyerek Şili reformunu takip etmiştir. İngiltere, elektrik sektöründeki reformuyla üretim ve tedarikte mülkiyet ayrışmasının ve rekabetin önemini göstermiştir. Bu ülkeler arasında Latin Amerika ülkeleri de ciddi bir dönüşüm yaşamış ve bölgede öncelikli olarak the Central American Market, the Andean Market ve the Common Market of the Southern Cone piyasaları geliştirilmiştir. The Southern Cone piyasası Arjantin, Brezilya ve Şili’yi içeren bölgede en büyük piyasa olma özelliğine sahiptir. Meksika’ da ki elektrik piyasası ise henüz yeni gelişmiştir. 1992 yılında Nordik elektrik piyasası açılmıştır. Piyasaya öncelikle Norveç daha sonra İsveç, Finlandiya ve Danimarka katılmıştır. Avustralya’da 1994 yılında Victoria ve Yeni Güney Galler’deki piyasalar faaliyete geçmiş ve 1998 yılında Avustralya Milli Elektrik piyasası (NEM)’nin açılışı takip etmiştir. Yeni Zelanda da ise, aynı periyotta sektörde reform gerçekleştirerek 1996 yılında piyasayı fiili olarak açmıştır. 1990’ların sonunda Kuzey Amerika’da New England, New York, PJM gibi piyasalar kurulmuştur. 1998 yılında ise bu piyasaları California, Texas ve Alberta (Kanada) piyasaları takip etmiştir [65, 67].

2.1.5. Dünya’da Bazı Önemli Elektrik Piyasaları

Elektrik endüstrisindeki serbestleşme çabaları sonucunda elektrik piyasaları kurulmaya başlamıştır. Bu piyasalar arasında, bir ülkenin tek başına kurduğu piyasa olmakla birlikte, birden çok ülkenin bir araya gelip kurduğu piyasalar hatta bir ülke içerisinde birden çok

kurulan piyasalar da yer almaktadır. Bu tez kapsamında serbestleşme süreci sonunda kurulan piyasalardan bazıları aşağıda tanıtılmaya çalışılmıştır.

Avrupa’da elektrik piyasalarının 1990’lı yıllarda gelişmesine bağlı olarak İngiltere ve Galler’de piyasa öncelikle power pool olarak işlemeye başlamış, piyasa yapılandırıldıktan sonra 2003’ten 2015 yılına kadar Amsterdam Power Exchange (APX) tarafından işletilen elektrik borsasına dönüştürülmüştür. 2001 European Energy Exchange (EPEX), 2008 yılında Paris merkezli olarak Fransa’ da ki Powernext SA ve Almanya’ da ki EEX AG elektrik piyasalarının birleştirilmesi yoluyla kurulan piyasanın günümüzde Amsterdam, Bern, Brüksel, Leipzig, Londra ve Viyana’ da ofisleri bulunmaktadır. 2015 yılında EPEX SPOT, APX grubuyla birleşmiştir. Piyasa, Almanya, Fransa, Birleşik Krallık, Hollanda, Belçika, Avusturya, İsviçre ve Lüksemburg için kısa dönemli elektrik piyasalarını işletmektedir. Ayrıca Sırbistan, Macaristan, Slovakya, İrlanda ve Kuzey İrlanda’ ya elektrik borsası hizmeti verilmekte olup Avrupa tüketiminin %50’sini kapsamaktadır. GÖP’te bir sonraki günün her bir saati için EPEX SPOT, piyasa katılımcıları tarafından verilen teklifler neticesinde oluşan arz ve talep eğrilerini toplulaştırarak elde ettiği sonuçlardan PTF ve piyasa takas hacmini hesaplamaktadır. Eşleşme miktarı sonucu belirlenen elektrik miktarı bir sonraki gün için fiziksel olarak dağıtımı yapılmaktadır. GÖP’te saatlik elektrik fiyat teklifleri tüm ülkeler için yıl boyunca haftanın yedi günü öğlen vaktinde gerçekleşerek bir sonraki günün 24 saatine ilişkin fiyatlar belirlenmektedir. Yarım saatlik PTF’ler ise sadece Birleşik Krallık piyasası için gerçekleşmekte olup saatlik PTF’ den farkı tekliflerin 15:30’da gerçekleşmesi ve 48 adet yarım saatlik fiyatların oluşmasıdır [68, 69, 70]

Nordic Pool piyasası olarak bilinen Nordik Elektrik piyasası, elektrik ticaretinin yapıldığı Avrupa’ nın önde gelen ve endüstride devlet tekeli kaldırılan ilk elektrik piyasalarından biridir. Piyasa, İskandinav ülkeleri (Norveç, İsveç, Danimarka ve Finlandiya) tarafından enerji piyasasında gerçekleştirilen düzenlemeler sonucunda 1992 yılında kurulmuştur. Piyasa 1993 yılında resmi olarak Norveç’ in piyasaya girmesiyle işlemeye başlamıştır. Daha sonra, Haziran 1996 yılında İsveç ve Mart 1999’da Finlandiya tamamıyla katılım sağlamıştır. 2000’li yılların sonlarına kadar piyasada Norveç, İsveç, Finlandiya ve Danimarka yer alırken 2010 yılında Estonya, 2012 Litvanya ve 2013 yılında ise Letonya piyasaya dahil olmuştur [1, 38, 71, 72].

Piyasanın en önemli özelliği elektriğin yarısından biraz fazlasının hidroelektrik santrali kanalıyla üretilmesidir. Bu yönüyle fiyatlar daha düzgün bir seyir almasını sağlamaktadır. Nord Pool, Nordic and Baltic Transmission System Operators tarafından yönetilen üç farklı piyasadandır. Elspot, gün öncesi piyasa, Elbas ise gün içi piyasa, işlem gördüğü piyasadır. Ticarete konu olmayan piyasa ise düzenlenmiş güç piyasasıdır. TSO, elektrik yük üretimi dengede tutmak için düzenlenmiş enerjiyi satın almaktadır. Elbas, Elspot' taki gün içerisinde oluşan dengesizlikleri piyasa katılımcılarına düzenleme fırsatı sunarak piyasa tamamlayıcı bir niteliğe sahiptir. Piyasada yer alan ülkeler, saatlik tüketilen elektriğin %80'inden fazlasını Elspot piyasası olarak adlandırılan gün öncesi elektrik piyasasından karşılamaktadırlar. Piyasa da ticaretin yapıldığı en önemli bölüm gün öncesi piyasadır. Alıcılar ve satıcılar, bir sonraki günün her bir saatinde ilişkin fiyat ve miktar için tekliflerde bulunmaktadırlar. Piyasaya teklifler, Orta Avrupa saatine (CET) göre saat 08:00 ile 12:00 arasında yapılmaktadır. Saatlik fiyatlar 12:42 (CET)'de piyasaya duyurulup ve 13:00-15:00 saatlerinde alıcılar ve satıcılar arasında anlaşma gerçekleşmektedir [38, 71- 74].

İberian electricity market (IEL), İberya Yarımada'sının tamamını (İspanya ve Portekiz) kapsamaktadır. IEL, toptan satış piyasası olarak kurulmuş ve ikili anlaşmalardan, future sözleşmelerinden, GÖP ve GİP olmak üzere iki piyasadandır. Piyasa işletmecisi, OMIE (Operador del Mercado Ibérico de electricidad)'dir. Piyasa katılımcıları, yerel saatle 12:00'ye kadar tekliflerini sunmaktadır. Teklif ve talep eğrilerinin kesişmesiyle pool price olarak adlandırılan marjinal fiyatlar belirlenmektedir [75- 77].

Avustralya' da National Electricity Market (NEM), New South Wales, Queensland, Victoria, South Australia, the Australian Capital Territory ve 2005'ten itibaren Tasmania olmak üzere altı bölgede işlemektedir. Avustralya Energy Market Operator (AEMO) hem sistem hem de piyasa işletmecisi olduğundan elektrik ve dengeleme piyasasını işletmektedir. Piyasa sadece gerçek zamanlı ticaretin gerçekleştiği elektrik borsası olarak organize edilmiştir. Piyasaya teklifler, 12:30'a kadar verilmekte olup teklif süreleri Avrupa ve ABD piyasalarından farklı olarak 5 dakikalık aralıklarla yeniden verilmektedir [68, 78].

2.2. Makine Öğrenmesi Yöntemleri

Yapay Zekâ (YZ), 1950’li yıllarda keşfedildiğinden bu yana bilgisayarların düşünme eylemini gerçekleştirip gerçekleştirmeyeceği hakkındaki sorular bugün de devam etmektedir. YZ, temel anlamda insanoğlunun gerçekleştirdiği görevleri bilgisayarlar tarafından otomatik bir şekilde yapılması çabası olarak tanımlanmaktadır. YZ, makine öğrenmesi (ML) ve derin öğrenme (deep learning)’yi de kapsayan genel bir alandır. Makine öğrenmesi, 1990’larda gelişmeye başlamış ve kısa süre içerisinde yapay zekanın vazgeçilmez bir alt dalı olmuştur [79].

Makine öğrenmesini tanımlamadan önce, öğrenme kavramını tanımlamak daha doğru olacaktır. Bu anlamda öğrenme denildiğinde, basitçe, günlük hayatta elde edilen deneyimlerden bilgi edinme şeklinde tanımlanabilmektedir. Biraz daha derine inildiğinde, öğrenme, bireysel deneyimin sonucunda oluşan davranış değişikliğidir. Bir organizma, davranışı algılar ve onu değiştirirse öğrenmiş sayılmaktadır. Makine öğrenmesi ise veriden bilgi edinme çabasıyla kurulmuş olan modelleri elde edebilmek için algoritmaların kullanılması olarak tanımlanabilmektedir. Bu modeller bilinmeyen verilerin tahmininde kullanılmaktadır. Modeller, karar ağaçları, doğrusal regresyon ve yapay sinir ağı ağırlıkları şeklinde birçok şekle sahip olabilmektedir. Her model, bilinen veriden bilinmeyeni tahmin etmek için birbirinden farklı uygulama adımlarına sahiptir. Örneğin, karar ağaçları, ağaç yapısı şeklinde bir dizi uygulama adımı kurmaktadır. Doğrusal regresyon modelleri, girdi verilerini gösteren bir dizi parametre oluşturmaktadır. Yapay Sinir Ağları (YSA) ise ağıdaki nöronlar arasındaki bağlantılar üzerindeki ağırlıkları gösteren parametre vektörüne sahiptir [80, 81].

ML, bir başka tanımla, veriden öğrenmeyi gerçekleştiren sistemlerin tasarlanmasında kullanılan algoritma ve teknikler bütünüdür. The Samuel Checkers-Playing Programı, makine öğrenmesinin kurucularından biri olan Arthur Lee Samuel tarafından 1959 yılında geliştirilen öğrenen ilk bilgisayar programıdır. A. Samuel’e göre makine öğrenmesi, programlama olmaksızın bilgisayara öğrenme kabiliyeti veren çalışma alanı olarak tanımlanmıştır. Samuel’den sonra, ML’ nin bir diğer kurucusu olarak görülen, Ryszard S. Michalski, 1962-1970 yılları arasında J. Karpinski’yle birlikte çalışarak elle yazılmış alfasayısal karakterlerin tanınması için bir sistem ortaya koymuşlardır [48, 82,83].

ML, güçlü bir matematik ve istatistik altyapısına sahip olup, bilimsel programlama, matematik ve istatistik disiplinlerinden oluşmaktadır. ML, sınıflama alanında başarılı birçok algoritmaya sahiptir. Sınıflandırmada amaç, verideki bir gözlemin hangi sınıfta yer alacağı tahmin edilmesidir. Sınıflama yapılırken algoritmanın eğitilmesi için “train set” olarak adlandırılan eğitim kümesine ve “test set” olarak ifade edilen test kümesine ihtiyaç duyulmaktadır. Bir eğitim kümesi, makine öğrenmesi algoritmasını eğitmek için verinin bir kısmını oluşturan eğitim örneklerinin yer aldığı kümedir. Sınıflandırmada hedef değişken, nominal değerler alırken makine öğrenmesinin diğer bir uygulama alanı olan regresyonda ise sürekli değerler almaktadır. Bir eğitim kümesinde hedef değişken bilinmektedir. Makine, girdiler ile hedef değişken arasında bazı ilişkiler bularak öğrenmektedir. Sınıflandırma problemlerinde, hedef değişkenler sınıf sayısının sonlu olduğu varsayılan sınıflar (classes) olarak adlandırılmaktadır. Makine öğrenmesi algoritmalarını test etmek için öncelikle bir eğitim kümesine ve test kümesi olarak adlandırılan bölünmüş bir veri kümesine sahip olunmalıdır [44, 48, 84].

Makine öğrenmesi sistemleri, eğitim sürecinde elde edilen denetimin sayısına ve çeşidine göre kategorilere ayrılmaktadır. Denetimli öğrenme (Supervised learning), denetimsiz öğrenme (Unsupervised learning), yarı-denetimli öğrenme (Semisupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) olmak üzere dört sınıfa ayrılmaktadır. Denetimli (makine) öğrenme, en yaygın olarak kullanılan ve en başarılı öğrenme yöntemlerinden biridir. Sınıflandırma ve regresyon denetimli öğrenmenin bir örneğidir. Denetimsiz öğrenmede, sınıflandırma ve regresyonda olduğu gibi modelde hedef değişken yer almaz. Hedef değişkenin olmamasından dolayı, denetimsiz öğrenmede eğitim algoritması yer almamaktadır. Bu öğrenme şeklinde her şey test algoritmasında gerçekleşmektedir. Test algoritması aşamasında, denetimli öğrenmede algoritmanın başarısını değerlendirmek için eğitim kümesindeki bilgilerden yararlanılırken denetimsiz öğrenmede diğer ölçülerden yararlanılmaktadır [44,48,84].

Makine öğrenmesi, iş problemleri, dolandırıcılığın tespiti, müşteri hedeflemesi ve ürün önerileri, duygu analizi, tıbbi teşhisler ve eş zamanlı endüstrinin izlenmesi gibi birçok alanda uygulanabilmektedir. ML, büyük veri kümelerine uygulandığında, bazen zayıf ilişkiler bulabilmektedir. Ancak bu ilişkiler birleştirildiğinde güçlü tahminler elde edilebilmektedir. Veriden öğrenme ve gelecekte verilecek kararları yönlendirmek için edindiği bilgiyi kullanma sürecinde oldukça güçlü bir yöntemdir [85].

ML, regresyon problemlerinde, girdi verilerine dayanarak, her bir birime karşılık gelen çıktıyı tahmin etmektedir. Regresyona, borsa tahminleri, fiyat tahmini, talep tahmini, risk yönetimi, varlık yönetimi, hava tahmini gibi örnekler verilebilmektedir [85].

2.2.1. Yapay Sinir Ağları

Modern bilgisayarlar, karmaşık yapıda sayısal ve sembolik hesaplamaları çok kısa bir sürede hesaplayabilmektedir. Ancak bu performansları insan beyni tarafından dil ve fotoğraf tanıma gibi algılamaya yönelik konularda sayısal yetenekleri kadar başarılı olamamışlardır. İnsan beyni, görevleri dağınık ve paralel biçimde yaparken, bilgisayarlar doğru veriye ihtiyaç duymakta olup verilen talimatları belirli bir sırayı takip ederek yapmaktadırlar [86].

Yapay sinir ağları ya da kısaca sinir ağları, sayısal zekâ veya zeki sistemler olarak bilinmekte olup insan beyninin çalışma şeklini taklit ederek gelişen bir makine öğrenme yöntemidir. Biyolojik Sinir Ağlarını (BSA) temel alan yapay zekâdaki gelişmeler YSA'nın doğmasına neden olmuştur. YSA, insan beyni gibi biyolojik sinir hücresi (BSH) mimarisinden esinlenen sayısal yöntemlerdir. En önemli özelliği, öğrenme kabiliyetine sahip olmasıdır [86, 87].

YSA, birbirine eş dağılımlı yapısı, öğrenme ve genelleştirme kabiliyetinden dolayı güçlü bir sayısal hesaplamaya sahiptir. Burada genelleştirme kavramı, YSA'nın eğitim sürecinde karşılaşmadığı girdiler için mantıklı sonuçlar (çıktılar) üretmesidir. Bu iki bilgi sürecine sahip olması YSA'nın karmaşık problemlerin çözümünde iyi sonuçlar vermesine imkân vermektedir. YSA, doğrusal olmama özelliği ile bir yapay nöron, doğrusal veya doğrusal olmayan formda olabilmektedir. Bir YSA ise, doğrusal olmayan nöronların birbiriyle bağlantı kurmasıyla oluşmaktadır. Doğrusal olmama, özellikle, girdi sinyallerinin oluşumundan sorumlu olan fiziksel mekanizmanın doğrusal yapıya sahip olmadığı durumlarda son derece önemli bir özelliktir. Girdi-çıkı eşleştirmesi ile ilgili ağ, mevcut problem için girdi-çıkı eşleştirmesi yaparak örneklerden öğrenme gerçekleştirmektedir. Burada, akla parametrik olmayan yaklaşımlar gelmektedir. Parametrik olmayan yaklaşımlardan kasıt, girdi verileri için istatistiksel modelde önceden herhangi bir varsayıma dayanmamasını işaret etmektedir. Uyarlanabilirlik özelliğinde,

sinir ađları, evresindeki deđişimlere sinaptik ađırlıklarını uyarlama kabiliyetine sahiptir. zellikle, daha nceden eđitilmiş bir sinir ađı evresindeki deđişikliklerle kolayca başa ıkabilmesi iin tekrar eđitilebilmektedir. Bađlamsal bilgi' de ađdaki her nron, diđer nronların etkinliklerinden potansiyel olarak etkilenmektedir. Bilgi, sinir ađının yapısından ve aktivasyon fonksiyonu tarafından temsil edilmektedir [88].

YSA'nın tarihi, sinir ađlarının başlangı evresi, ilk altın ađı, duraklama dnemi ve toparlanma dnemi olmak zere drt dneme ayrılmaktadır. 1940'lı yıllarda bir yandan dnya ikinci savařını verirken bir yandan da bilim dnyasında yařanan geliřmelere sahne olmuřtur. Bu geliřmelerden bir tanesi de insan beyninin yapısı ve alıřma řeklinden etkilenerek keřfedilmiş olan yapay sinir ađlarıdır. Bu yıllar, sinir ađlarının başlangı dnemi olarak adlandırılmıřtır.1943 yılı, YSA'daki geliřmelerin başlangıcı olarak grlmektedir. İlk olarak, Walter Pitts ve McCulloch tarafından yayınlanan ve ok byk bir etki oluřturup geniř evrelerce okunan makalede sinir ađlarının en basit yapısını gstermiřlerdir. nerdikleri model, mantık iřlemlerinin uygulanması aısından gerekli tm elementlere sahip olmasına rađmen o zaman yaygın olarak kullanılan byk vakumlu tpler ile uygulanması mmkn deđildi. Norbert Wiener ve von Neuman beyin yapısından esinlenerek oluřturulan bilgisayarlar zerinde arařtırma yaparak nerilerde bulunmuřlardır. 1949'da Hebb, The Organization of Behaviour adını verdiđi bir kitap yazmıřtır. Bu kitabında, YSA'nın ilk đrenme yntemi olan ve kendi ismiyle anılan Hebb's kuralını nermiřtir. 1940 ile 1950 yılları arasında bu alanda birok alıřma yapılırsa da bu alıřmalar temel dzeyde olup sonra yapılan alıřmaların geliřmesine katkı sađlamıřtır [87, 89-91].

1950'ler ve 1960'lar sinir ađlarının altın ađı olarak adlandırılmasının nedeni bugn hayatımızın vazgeilmezi arasında yer alan bilgisayar teknolojisinin ilk adımları sayılabilecek nrobilgisayarların keřfedilmesine dayanmaktadır. Minsky ve Edmond 1951 yılında Harvard'da Hebb đrenme kuralını test etmek iin adına Snark denilen yapay beyine benzer bir nrobilgisayar retmiřlerdir. Bu makine 300 vakum tpnden ve 40 farklı direnten oluřmaktaydı. Snark, teknik aıdan bařarılı bir řekilde iřlese de hibir bilgi iřleme iřlevini fiilen gerekleřtirememiřtir. İlk bařarılı nrobilgisayar Rosenblatt, Charles Wightman ve diđerleri tarafından 1957-58 yılları srecinde Cornell Aeronautics Laboratory'de geliřtirilen Mark I perceptron'dur. Bugn bilinen řekliyle, Rosenblatt, nrobilgisayarların kurucusu olarak anılmaktadır. Onun YSA alanına en nemli katkısı

Perceptronun (algılayıcı) icadının yanı sıra örüntü tanımadır. Bugün hala kullanılmakta olan temel makine öğrenmesi algoritmalarının temelini oluşturmaktadır. Rosenblatt'ın buluşundan kısa bir süre sonra 1960 yılında Bernard Widrow yüksek lisans öğrencileriyle yaptığı çalışmada, Perceptron öğrenme kuralından farklı olarak Widrow- Hoff öğrenme kuralı olarak adlandırılan Güçlü Yeni Öğrenme kuralı olarak adlandırılan ADALINE (ADaptive LINEar combiner) adında yeni bir ağ geliştirmişlerdir. Bu kural örüntü sınıflamayla ilgili eğitim sürecinde toplam hata kareleri minimize etmeye çalışmaktadır. ADALINE ve uzantısı MADALINE (Multiple ADALINEs) tahmininde, örüntü tanımlamada kullanılmıştır. 1960'lı yılların sonunda Marwin Minsky ve Seymour Papert tarafından sinir ağları araştırmalarını itibarsızlaştırma ve bu araştırmaları yapay zekâya yönlendirilmeye çalışıldığı dönem olmuştur. Bu amaçla yazdıkları Perceptron hakkındaki kitapta sinir ağlarının, XOR gibi bazı özel tahminleri yeterince hesaplayamadıklarını göstermişlerdir. Böylelikle sinir ağı çalışmaları çıkmaza girdiği bir dönem başlamıştır [87, 89-91].

1970'ler sinir ağlarının sessiz geçen, durgun bir dönemi olmuştur. Minsky ve Papert' in perceptronların sınırlarını göstermelerine rağmen sinir ağları az sayıda bilim insanı tarafından çalışılmaya devam edilmiştir. Bu dönemdeki çalışmalar, uyarlanabilir sinyal işleme, örüntü tanıma ve biyolojik modelleme başlıklarını içermektedir. Amari, Fukushima, Grossberg ve Klopff ve Ghose gibi bilim insanları ve ardından on üç yıllık periyot zarfında gelen bilim insanları sinir ağları alanının sağlam temel üzerine oturmasına neden olmuş ve bu alanda rönesans döneminin yaşanmasını sağlamışlardır [90].

1980'li yıllar, sinir ağları çalışmalarının yeniden ilgi odağı haline gelmeye başladığı dönem olmuştur. Dünyaca ünlü fizikçi, John Hopfield, sinir ağları alanında, 1982 ve 1984 yıllarında çok rağbet gören iki adet makale yayınlamıştır. Bu çalışmalar, birçok bilim insanının bu alanda çalışmasına öncülük etmiştir. YSA, 1986 yılında sırasıyla Rumelhart ve McClland tarafından yazılan Parallel Distributed Processing kitabının iki sayısı ile birlikte patlama yaşamış olup 1987 yılında San Diego' da "IEEE International Conference on Neural Networks" adlı modern anlamda sinir ağlarıyla ilgili ilk kez uluslararası konferans düzenlenmiş ve Uluslararası Sinir Ağları Topluluğu (INNS) kurulmuştur [90].


2.5.1.1 Biyolojik Sinir Ağları

İnsan beyni, çok sayıda birbirine bağlı sinir hücresinden (nöron) oluşmaktadır. Her bir nöron, girdi sinyaline cevap verme gibi basit görevleri olan hücrelerdir. Ancak, nöronlar birbirleriyle ilişkili olduklarında daha karmaşık yapıda olan ses ve fotoğraf tanıma gibi görevleri şaşırtıcı derecede hızda ve doğrulukta gerçekleştirmektedirler. Bir sinir hücresi, birkaç milisaniyede hesaplama özelliğine sahipken, yüz tanıma gibi bir görevin tamamlanabilmesi için birkaç yüz milisaniye zaman almaktadır. Bu da gösteriyor ki, bilgisayar için bir görevin tamamlanabilmesi için milyonlarca adımdan oluşan bir hesaplama adımına karşılık insan beyni aynı görevi yüz adımda gerçekleştirebilmektedir. Bu kadar kısa işlem süresi, sinir hücreleri arasındaki bilgi akışının çok kısa olduğunu göstermektedir. Geleneksel bilgisayarların aksine, tüm veri bir nöronun diğer nörona geçmez ancak sinir ağlarının birbirleri arasında oluşturdukları karmaşık yapı içerisinde şifrelenmektedir. Beyin tarafından yürütülen bilgi işleme süreci, düşünme ve öğrenme gibi fonksiyonların düzgün bir şekilde yürütülebilmesi için, birbirine aynı doğrultuda çalışan biyolojik işlem birimleri tarafından gerçekleştirilmektedir [86, 87].

Merkezi sinir sisteminin ana hücresi, nöron olarak adlandırılan sinir hücresidir. Elektrik sinyalleri tarafından uyarılabilen bir sinir hücresi, sinir ağının en küçük birimidir. Sinir hücresi elektrik ve kimyasal sinyaller vasıtasıyla bilgiyi işleyebilmekte ve iletebilmektedir. Uyarılmış nöron durumu, transistör içinde 1 durumu eğer uyarılmamış ise 0 durumu olarak düşünülebilmektedir [82, 86].

Bir nöron dendritler (dendrites), bu dendritlerin bağlandığı bir hücre gövdesi (cell body) ve bu hücre gövdesinden çıkan aksondan (axon) meydana gelmektedir. Soma şeklinde de tabir edilen hücre gövdesi, diğer hücrelere benzer şekilde çekirdekten (Nucleus) oluşmaktadır. Şekil 2.1'de bir sinir hücresine ait yapı gösterilmektedir. Dendritler, bir ağacın dallarına benzer şekilde hücre gövdesinden çıkan çok sayıda ince liflerden oluşmaktadır. Dendritlerin temel amacı, komşu nöronlardan ve duyuşal nöron olarak adlandırılan çevreyle bağlantı kuran sinir hücrelerinden aldığı sürekli uyarıları hücre gövdesine iletmektir. Hücre gövdesi, kalıtsal özellikler hakkında bilgilerin saklandığı çekirdekten ve sinir hücresi tarafından ihtiyaç duyulan moleküler ekipmanların saklandığı ve mitokondri, lizozom, sentriyol gibi organelleri içinde bulunduran sitoplazmadan

oluşmaktadır. Hücre gövdesi, dendritlerden edindiği tüm veriyi işlemekle görevlidir [86,87].




Şekil 2.1. Biyolojik sinir hücresi [45]

Akson, komşu nöronlara ve kas dokusuyla direkt bağlantılı nöronlara (efferent neuron) hücre gövdesinden aldığı uyarıları diğer sinir hücrelerine iletmekten sorumlu hücre gövdesinden akson tepesi (axon hillock) ile çıkan tek ve uzun bir liften oluşmaktadır. Aksonun bitimine yakın, telodendria olarak adlandırılan birçok dal ve dalların ucunda yer alan komşu nöronların dendritleriyle bağlantı kuran sinaptik terminaller ya da basitçe sinaps olarak adlandırılan küçük yapılar yer almaktadır. Bir sinir hücresinin aksonu ile diğer bir sinir hücresinin dendriti arasında oluşan bağlantıyı sinaps kurmakta olup iki nöron arasındaki iletişim birimidir. Elektrokimyasal uyarılar sinaps üzerinden iletilmektedir. Bir nöronun aldığı toplam sinyal sinaps eşiğini aştığında nöronun ateşlenmesine neden olmaktadır. Böylece, komşu nöronlara elektrokimyasal sinyal gönderilmiş olur [45,86, 87].

Nöronlar arasında sinaptik terminallerin yapısı gereği fiziksel temas bulunmamaktadır. Uyarı sinaps terminallerine geldiğinde nörotransmitler adında kimyasal maddeler salgılanmaktadır. Bu maddeler, sinapsın yapısına bağlı olarak sinaptik boşluklar boyunca

yayılmaktadır. Bu yayılım bir nöronun diğerine olan iletimin gücünden sorumludur. Aslında, bir sinir hücresinin fonksiyonelliği, iletim gücü veya genliğine, dinamikliğine ve nörokimyasına bağlıdır [86].



Şekil 2.2. BSA'da çok katmanlı yapı [45]


İnsan beyni günümüzde hala esrarengiz yapısını korumakta olup bu konuda bilim insanları arasında henüz fikir birliği sağlanamamıştır. BSA'nın mimarisi hakkında, beynin bazı bölümleri gözlemlenebilse de araştırmacılar tarafından çalışmalar devam etmektedir. Şekil 2.2'de incelendiğinde nöronlar ardışık katmanlarda organize edildiği görülmektedir [45].

2.5.1.2 Yapay Sinir Ağlarının Mantıksal Çerçevesi

YSA, insanın sinir sistemindeki doğal sinir ağlarının oldukça basitleştirilmiş halidir. YSA'nın temelinde nöron ya da düğüm olarak adlandırılan birimler yer almaktadır. Yapay sinir hücresi olarak adlandırılan bu birim, BSH'nin basit halidir. Bu modeller bir nöronun hücre zarının elektrik uyarılarını nasıl üretip ilettiğinden esinlenmektedir. BSA'daki gibi sinir hücrelerine benzer birbirine bağlı düğümlerden oluşmaktadır. YSA'da kullanılan yapay nöronlar, doğrusal olmayan bir yapıda olup basit fonksiyonlar uygulayarak sürekli çıktılar sağlayan, girdileri üzerinde yer alan sinyalleri işlevsel fonksiyonlarına göre bir araya getirip aktivasyon fonksiyonlarını da dikkate alarak bir cevap oluşturmaktadırlar [86, 95].

Her sinir ağı, düğümün özelliği, ağın yapısı, öğrenme kuralı olmak üzere üç kritik boyuttan oluşmaktadır. Düğüm karakteri, düğümlerle ilişkili girdi ve çıktı sayıları, her bir

girdi ve çıktıyla alakalı ağırlık ve aktivasyon fonksiyonu gibi düğüm tarafından sinyalin nasıl işlendiğini belirlemektir. Ağın yapısında, düğümlerin birbirleri arasındaki işleyişin nasıl olacağı belirlenmektedir. Öğrenme kurallarında ise, ağırlığın başlangıç değerinin ne olacağı ve düğümler arasındaki dengenin nasıl sağlanacağı belirlenmektedir [87].



Şekil 2.3. Tek düğümden (node) oluşan basit model [87]


Şekil 2.3'te YSA'daki bir düğüm için en basit model şekilde gösterilmiştir. Bu modelde, her düğüm, sinapsın gücüne benzer şekilde diğer nöronlardan ağırlıklarıyla bağlantı kurarak çok sayıda girdi almaktadır. Girdilerin ağırlıkları toplamı düğümdeki eşik değerini aştığında girdiler transfer fonksiyonundan geçerek komşu düğümlere iletilmektedir. Bu durum matematiksel açıdan şu şekilde açıklanmaktadır.

$$y = f(\sum_{i=0}^n w_i x_i - T) \quad (2.1)$$

Burada, y nöronun çıktısını, f transfer fonksiyonunun, w_i , x_i girdisinin ağırlığını ve T ise eşik değeri göstermektedir. Transfer fonksiyonu birçok forma sahiptir. Doğrusal olmayan transfer fonksiyonu doğrusal olandan daha faydalıdır. En basit transfer fonksiyonu, adım fonksiyonudur:


$$y = \begin{cases} 0 & \text{eğer } \sum_{i=0}^n w_i x_i > T \\ 1 & \text{eğer } \sum_{i=0}^n w_i x_i < T \end{cases} \quad (2.2)$$

Fonksiyon ve türevleri sürekli olduğu için sigmoid fonksiyonu aktivasyon fonksiyonu olarak sıklıkla kullanılmaktadır. Şekil 2.4'te sigmoid fonksiyonu gösterilmektedir [86, 87].



Şekil 2.4. Transfer fonksiyonu [87]

Şekil 2.5'teki grafik bir yapay sinir ağının genel mimarisini göstermektedir. Düğümler, katman olarak adlandırılan doğrusal dizeler içerisinde yer almaktadır. Genellikle, YSA mimarisinde girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı (output layer) katmanından oluşmaktadır. Bazılarında gizli katman yer almamaktadır. Ağ yapısı, her katmandaki düğüm sayısı, ağdaki katmanların sayısı, düğümler arasındaki bağlantıların yönünün belirlenmesini tasarlamaktadır. Genellikle bu faktörler, başlangıçta sezgisel bir yolla kurulmakta ve çoklu deney döngüleri yoluyla optimize edilmektedir [87].



Şekil 2.5. Yapay sinir ağının genel yapısı [87]


Düğümlemler arasında bağlantı çeşidi iki tanedir. Bunlardan biri, geri döngüye girmeden ileriye doğru tek yönlü bağlantıdır. Diğeri ise, aynı düzeyde veya bir öncekinin girdisi olan düğüm çıktısında geriye döngü bağlantı oluşturabilir. Yukarıda bahsedilen bağlantı çeşitlerine dayanarak sinir ağları iki şekilde sınıflandırılabilir. Birincisi ileri beslemeli ağ (feedforward network) ve ikincisi ise geri beslemeli ağdır (feedback network). İleri beslemeli ağda bir girdi belirli bir çıktıyla ilişkili olup sinyalleri tek yönlü hareket ettiğinden dolayı durağandır (statik). Geri beslemeli ağ ise, dinamik bir yapıda olup bir girdi için bir denge noktasına ulaşmaya dek birçok döngüyü değiştirebilir. Böylelikle, bir girdi birden çok çıktı serisi üretebilir. Perceptron, ileri beslemeli ağda yaygınca kullanılmaktadır. Bilinen bazı geri beslemeli ağlar ise Kohonen- kendi kendini organize eden haritalar ve Hopfield ağını içermektedir [86, 87].

YSA, ağı eğitmek için bir öğrenme işlemi gerçekleştirir. Eğitim süresince, ağırlıklar istenilen düzeye göre ayarlanmaktadır. Bu öğrenme süreci, denetimli ve denetimsiz öğrenme olarak iki ana sınıfa ayrılabilir. Denetimli öğrenmede, girdi ve hedef çıktı örneklerinin yer aldığı eğitim kümesi bulunmaktadır. Ağdaki çıktı ile tahmin edilen çıktı arasındaki hatayı en azlayacak şekilde ağırlıklar belirlenmektedir. İdeal bir eğitim kümesi, modeli iyi yansıtabilecek düzeyde olmalıdır. Temsil yeteneği düşük olan bir eğitim kümesi güvenilir ve genel bir model üretmez. Denetimli öğrenmenin kullanıldığı ağlarda, ilk olarak ağ eğitilmelidir. Denetimli öğrenmenin

aksine, denetimsiz öğrenmede (unsupervised learning) eğitim kümesinden hedef çıktı değerleri kullanılmamaktadır. Ağ, sadece girdi verilerindeki temel örüntüyü veya eğilimi keşfetmeye çalışmaktadır [86, 87].

2.5.1.3. Yapay Sinir Ağı Hücresi

Günümüzde de farklı yapay sinir ağı mimarisinde en çok kullanılan ve BSA'nın temel özelliğini gösteren en basit sinir hücresi modeli ilk olarak nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından 1943 yılında yayınlanan "A Logical Calculus of Ideas Immanent in Nervous Activity," adlı çalışmada gündeme getirilmiştir. Bu çalışmada, sinir ağları için sayısal bir çerçeve oluşturulmuştur. Daha sonra sinir ağlarındaki gelişmeler sonucu biyolojik sistemler ve makine öğrenmesi olarak bölümlere ayrılmıştır [82, 86, 94].



Şekil 2.6. Yapay sinir hücresi

Bu modelde, bir ağdan her nörona süreç şekil 2.6'daki gösterildiği gibi uygulanabilir. Dış çevreden ağa gelen çoklu girdi sinyalleri, BSH'de dendritler tarafından toplanan dıştan gelen uyarılara benzer şekilde, $\{x_1, x_2, \dots, x_n\}$ şeklindeki kümeden oluşmaktadır. Ağdaki sinaps kavşakları (boşluk) tarafından gerçekleştirilen ağırlıklandırma işlemi $\{w_1, w_2, \dots, w_n\}$ şeklinde sinaps ağırlıklarını gösteren bir küme olarak yapay sinir hücresi üzerinde uygulanmaktadır.

Şekil 2.6 incelendiğinde bir sinir ağının yedi temel unsurdan oluştuğu görülmektedir. Bu unsurlar sırasıyla:

- a) Girdi sinyalleri (x_1, x_2, \dots, x_n) dış çevreden gelen sinyal veya örneklerdir. Genellikle, öğrenme algoritmasının sayısal etkinliğini artırmak için normalleştirilmektedir.
- b) Sinaps ağırlıkları (w_1, w_2, \dots, w_n) , girdi değişkenlerini her birini ağırlıklandırmada kullanılan değerlerdir. Bu ağırlıklar ilgili nöronun fonksiyonelliğini ölçmede kullanılmaktadır.
- c) Toplama fonksiyonu (Σ) ile bir aktivasyon gerilimi üretmek için sinaps ağırlıkları yoluyla ağırlıklandırılan tüm girdi sinyallerinin toplanması aşamasıdır.
- d) Aktivasyon eşiği veya sapması (θ), transfer fonksiyonunun sonuçlarına göre uygun bir eşik değerin belirlenmesinde kullanılan bir değişkendir.
- e) Aktivasyonun potansiyeli (u), doğrusal toplama ve aktivasyon eşiği arasında oluşan farktan meydana gelmektedir. Eğer bu değer pozitif ise, bir başka deyişle $u \geq 0$ ise bir uyarıcı potansiyel, değilse engelleyici potansiyel üretmektedir.
- f) Aktivasyon fonksiyonu (g) amacı sinir hücresi çıktısını kabul edilebilir bir değer aralığında sınırlandırmaktır. Bu fonksiyon, yapay sinir hücresinin hareketini yönetmektedir. Bir yapay sinir hücresi sıfır olmayan bir değer ile diğerine geçtiğinde aktif olduğu söylenebilmektedir.
- g) Çıktı sinyali (y) ise ilgili nöron tarafından üretilen son değeri içermekte olup komşu nöron için girdi olarak kullanılabilir [81, 86, 87].

Aktivasyon fonksiyonu, kısmi türevlenebilir fonksiyonlar ve tam türevlenebilir fonksiyonlar olmak üzere göz önüne alarak iki kategoriye ayrılabilir. Kısmi türevlenebilir fonksiyonlar, birinci mertebeden türevinin alınmadığı fonksiyonlardır. Bu kategorideki üç fonksiyon adım fonksiyonu (step function), iki kutuplu adım fonksiyonu veya sinyal fonksiyonu ve simetrik rampa fonksiyonudur. Adım fonksiyonu tarafından üretilen sonuçlar sinir hücresinin aktivasyon potansiyel (u) değerinin sıfıra eşit veya büyük olduğunda 1 değerini aldığını diğer durumlarda ise sıfır olduğunu varsaymaktadır [86, 87].


İki kutuplu adım fonksiyonu veya sinyal fonksiyonunda elde edilen sonuçlar nöron aktivasyon potansiyeli sıfırdan büyük ise 1 değerini, potansiyel sıfır ise sıfır değerini ve sıfırdan küçükse -1 değerini almaktadır. Simetrik rampa fonksiyonunda ise, bu fonksiyon tarafından elde edilen değerler, $[-a, a]$ olarak tanımlandığında aktivasyon potansiyel değerine (u) eşittir. Diğer durumlarda, u 'nun değerine göre limit değerlerini almaktadır [87].

Tam türevlenebilir aktivasyon fonksiyonunda, tanım kümesi içerisindeki tüm noktalarda birinci mertebeden türevleri alınabilmektedir. YSA' da bu kategoriden dört ana fonksiyon kullanılmaktadır. Bunlar, lojistik fonksiyon, hiperbolik tanjant fonksiyonu, Gauss fonksiyonu ve doğrusal fonksiyondur.


Lojistik fonksiyondan hesaplanan çıktı değerleri 0 ile 1 arasında değerler aldığı varsayılmaktadır. Matematiksel ifadesi aşağıdaki gibidir.

$$g(u) = \frac{1}{1+e^{-\beta*u}} \quad (2.3)$$

Burada β , fonksiyonun dönme noktalarındaki eğimi ile ilgili sabit bir değerdir. Şekil 2.7. de bu fonksiyonun hareketi gösterilmektedir. Şekil 2.8'de ise β eğim parametresinde değişme olduğunda lojistik fonksiyonun hareketindeki değişimler gösterilmektedir.



Şekil 2.7. Lojistik aktivasyon fonksiyonu [87]



Şekil 2.8. Lojistik aktivasyon fonksiyonunda β parametresinin etkisi [87]


Lojistik aktivasyon fonksiyonunda β değeri sonsuz bir değere eğilim gösterdiğinde adım fonksiyonuna benzemektedir. Ancak, adım fonksiyonunun aksine lojistik fonksiyon tanım aralığının her bir noktasında tam olarak türevlenebilmektedir.

Hiperbolik tanjant fonksiyonunda, çıktı sonuçları değerlerinin, lojistik fonksiyondaki durumdan farklı olarak aşağıda verilen matematiksel ifadeyi takiben -1 ile +1 değerleri arasında olduğu varsayılmaktadır.


$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (2.4)$$

Burada, β , hiperbolik tanjant fonksiyonunun eğim parametresidir. Hiperbolik tanjant fonksiyonunun gösterimi şekil 2.9'daki gibidir. β 'daki değişme hiperbolik tanjant fonksiyonunu nasıl etkilediği şekil 2.10'da gösterilmiştir.

β parametresi sonsuza eğilim gösterdiğinde, lojistik fonksiyondaki duruma benzer şekilde, iki kutuplu fonksiyona yaklaşmaktadır. Hem lojistik hem de hiperbolik tanjant fonksiyonları sigmoidal olarak adlandırılan fonksiyon ailesine aittir [86, 87].




Şekil 2.9. Hiperbolik tanjant aktivasyon fonksiyonu [87]



Şekil 2.10. Hiperbolik tanjant fonksiyonu üzerinde β parametresinin etkisi [87]

Gauss aktivasyon fonksiyonu durumunda, nöron çıktısı u 'nun merkezinden (ortalamasından) aynı uzaklıkta yer alan değerler için aynı sonuçları vermektedir. Gauss fonksiyonu aşağıda verilmekle birlikte, simetrik bir eğridir. Burada, c Gauss fonksiyonunun merkezini belirlemektedir. σ ise fonksiyonun standart hatasını göstermektedir. Gauss fonksiyonunun grafiği Şekil 2.11'de verilmektedir. Standart hata parametresi, Gauss fonksiyonundaki dönüm noktalarıyla direkt olarak ilişkilidir.




Şekil 2.11. Gauss aktivasyon fonksiyonu

Doğrusal aktivasyon fonksiyonu ya da birim fonksiyonda çıktıların sonuçları u ' ya eşittir. Matematiksel fonksiyon aşağıdaki gibidir.

$$g(u) = u$$

Grafik gösterimi de şekil 2.12'de ki gibidir [87].



Şekil 2.12. Doğrusal aktivasyon fonksiyonu

2.5.1.4. Yapay Sinir Ağlarında Eğitim Süreci ve Özellikleri

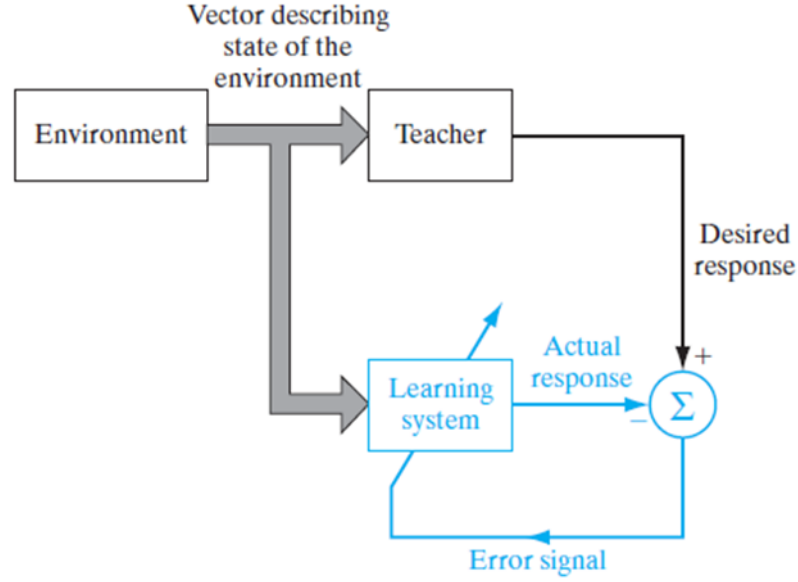
YSA' nın en önemli özelliğinden birisi, sistemin davranışını açıklayan örnekten(örüntü) öğrenme kabiliyetine sahip olmasıdır. Ağ, girdiler ve çıktılar arasındaki ilişkiyi öğrendikten sonra her girdi değerine karşılık beklenen çıktı değerine yakın çözümleri

genelleştirebilen bir çıktı üretmektedir. Bu nedenle bir sinir ağının eğitim süreci, çıktıları tarafından belirlenen çözümlerin genelleştirilmesi için sinir hücrelerinin sinaptik ağırlıkları ve eşik değerleri belirlenmesi için öğrenme algoritmasından oluşmaktadır. Sistemdeki tüm mümkün örneklerin oluşturduğu küme, eğitim kümesi ve test kümesi olarak iki alt kümeye bölünmektedir. Ağın öğrenme sürecinde kullanacağı eğitim kümesi, tam kümedeki rastgele örneklerin %60-90'ından oluşmaktadır. Test kümesi ise genelleştirilmiş çözümlerin kabul edilebilir bir düzeyde olup olmadığı doğrulamakta kullanılıp tam kümenin %10-40 düzeyine tekabül etmektedir. Yine de, tam kümenin bölümlere ayrılacağı zaman verinin istatistiksel açıdan özellikleri dikkate alınmalıdır [81, 87].

Çevremizdeki şeyleri öğrenmemizin birçok farklı yöntemi olduğu gibi sinir ağlarında da durum buna benzerdir. Daha geniş anlamda, sinir ağları fonksiyonlarıyla öğrenme sürecini öğretmenli öğrenme ve öğretmensiz öğrenme şeklinde sınıflandırılmaktadır. Ayrıca, ikinci öğrenme tipi denetimsiz öğrenme ve takviyeli öğrenme şeklinde iki kategoriye ayrılabilir. Sinir ağları üzerinde uygulanan bu farklı öğrenme formları, insan beyninin öğrenme formuna benzerlik göstermektedir [88].


Öğretmenli öğrenme, denetimli öğrenme (supervised learning) olarak da adlandırılmaktadır. Şekil 2.13'te bu öğrenme şeklinin tasvir edildiği akım şeması gösterilmektedir. Kavramsal olarak, çevredeki bilgilere hakim bir öğretmen düşünülebilir. Ancak bu çevre, sinir ağı tarafından bilinmemektedir. Bu öğretmenin ve sinir ağının aynı çevreden edindiği bir eğitim vektörüne (örneğine) sahip olduğu varsayalım. Sahip olduğu bilgi vasıtasıyla bu öğretmen, eğitim vektörü için istenilen çıktıyı sinir ağını verebilmektedir. Aslında, istenilen yanıt kavramı, sinir ağları tarafından uygulanan en uygun işlemi ifade etmektedir. Ağın parametreleri, eğitim vektörü ve hata sinyalinin birlikte etkisiyle belirlenmektedir. Burada hata sinyali, ağdaki istenilen çıktı ile gerçekleşen çıktı arasındaki fark olarak tanımlanmaktadır. Parametrelerin belirlenmesi, sinir ağının öğretmeni taklit ederek aynı düzey bilgiye sahip olana dek adım adım tekrarlanmaktadır. Böylece, öğretmen tarafından bilinen mevcut çevre bilgisi eğitim vasıtasıyla sinir ağına aktarılmaktadır ve uzun dönemli hafızayı temsil eden sabit sinaptik ağırlıklar şeklinde saklanmaktadır. Bu işlemin ardından sinir ağı, öğretmenden ayrılarak çevreyle kendisi ilişki kurmaya başlamaktadır. Şekil 2.13 incelendiğinde, denetimli

öğrenme sürecinin kapalı döngü geri beslemeli bir sistemi oluşturduğunu ancak bilinmeyen çevrenin döngü dışında kaldığı gözlenmektedir [88].



Şekil 2.13. Öğretmenli öğrenme sürecine ilişkin akış diyagramı [88]

Denetimli öğrenmede, öğrenme süreci bir öğretmenin gözetimi altında gerçekleşmektedir. Ancak, öğretmen olmadan öğrenme olarak bilinen denetimsiz öğrenme yaklaşımı, adından da anlaşılacağı üzere, öğrenme sürecini gözetleyecek bir öğretmen yoktur. Denetimsiz veya kendi kendini düzenleyen öğrenme sisteminde, öğrenme sürecini denetlemek için bir öğretmen bulunmamaktadır. Denetimsiz öğrenmenin uygulanabilmesi için, rekabetçi bir öğrenme kuralı (competitive learning rule) kullanılabilir. Örneğin, bir girdi katmanı ve rekabetçi katman (competitive layer) olarak adlandırılan ve girdi katmanına doğrudan bağlı bu katmanın yer aldığı bir sinir ağı kullanılabilir. Bu ağda, girdi katmanı mevcut veriyi almaktadır. Rekabetçi katmandaki nöronlar girdideki verilerde yer alan özelliklere en uygun yanıtı verebilmek için (öğrenme kuralına uygun olarak) birbirleriyle rekabet halindedir. En basit şekilde, ağ, kazanan her şeyi alır (winner all takes) stratejisine uygun olarak işlemektedir. Bu stratejide, en çok toplam girdiye sahip nöron yarışı kazanmakta olup etkinleşmektedir. Diğer nöronlar ise devre dışı kalmaktadır [88].



Şekil 2.14. Denetimsiz öğrenme akış diyagramı [88]

2.5.1.5. Yapay Sinir Ağlarında Mimari Yapılar


Genel olarak, bir yapay sinir ağı katman olarak adlandırılan üç kısma ayrılmaktadır:

- Girdi katmanı
- Gizli katman
- Çıktı katmanı

Girdi katmanı, dış çevreden gelen bilgileri, sinyalleri, özellikleri almakla görevlidir. Bu girdiler aktivasyon fonksiyonu tarafından belirlenen limit değerleri içerisinde normleştirilmektedir. Bu normleştirme, sinir hücresi tarafından uygulanan matematiksel işlemler için en iyi sayısal sonuçları vermektedir. Gizli (ara katman veya görülmez) katmanda, sürecin veya sistemin analiz edilebilmesi için örüntülerin çıkarılmasından sorumludur. Çıktı katmanı, bir önceki katmandaki düğümler tarafından gerçekleştirilen sürecin sonuçlarından oluşan düğümlerden oluşmaktadır. Bu düğümler, nihai ağ çıktısını üretmektedirler.

Bir yapay sinir ağı mimarisi nöronların nasıl konumlanacağı birbirleriyle olan ilişkilerini nasıl olacağını belirlemektedir. Bu belirleme ise sinir hücrelerinin sinaps bağlantıları (ağırlıklar) tarafından gerçekleştirilmektedir.

Tek katmanlı ileri beslemeli yapay sinir ağında, sadece bir girdi katmanına ve çıktı katmanının yer aldığı tek sinir katmanına sahiptir. Şekil 2.15'te n tane girdi ve m tane çıktıdan oluşan ağ yapısı gösterilmektedir ve görüldüğü üzere bu ağ yapısında gizli katman yer almamaktadır. Bilgi akışı girdi katmanından çıktı katmanına doğru tek yönde gerçekleşmektedir. Şekil 2.15'ten görüldüğü üzere, ağıdaki çıktı sayısı, sinir hücresinin sayısına eşittir. Bu ağlar genellikle, örüntü sınıflandırma ve doğrusal filtreleme problemlerinde kullanılmaktadır.



Şekil 2.15. Tek katmanlı ileri beslemeli sinir ağı örneği [87]

Tek katmanlı ileri beslemeli ağ mimarisine ait temel ağ çeşitleri, sırasıyla Hebb kuralı ve Delta kuralına dayalı öğrenme algoritmasına sahip Perceptron ve ADALINE' dir [87].

Perceptron, ikili sınıflandırma için kullanılan doğrusal modeldir. Sinir ağları alanında perceptron, basamaklı adım fonksiyonu kullanan bir yapay sinir hücresi olarak tanımlanmaktadır. Perceptron ilk hali, 1943 yılından McCulloch ve Pitts tarafından önerilen AND ve OR mantık fonksiyonlarını öğrenebilen Eşik Mantık Birimi (EMB)' dir. Perceptron eğitim algoritması, denetimli öğrenme algoritması çerçevesinde işlemektedir. Hem EMB hem de perceptron BSH' den esinlenmiştir. Perceptron, 1957 yılında Frank Rosenblatt tarafından Cornell Aeronautical Laboratory' de ortaya atılmıştır [81].

Perceptron, şekil 2.15'te gösterildiği gibi girdiler ve çıktılar arasındaki ilişkiyi ikili olarak sınıflandıran bir doğrusal modeldir. Şekilde kendi ağırlıklarıyla çarpılan n tane girdi değişkenin toplandığı ve daha sonra tanımlanmış bir eşik değere sahip basamak fonksiyonuna net girdi olarak gönderilmektedir. Genellikle algılayıcılar, 0,5 eşik değerine sahip birim basamak fonksiyonu (Heaviside or unit step function) şeklindedir. Bu fonksiyon girdiye bağlı olarak, 0 ve 1 değerleri alan çıktılar üretmektedir. Birim basamak fonksiyonu, matematiksel olarak şu şekilde tanımlanmaktadır:

$$f(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (2.5)$$

Basamak fonksiyonuna sahip aktivasyon fonksiyonunun çıktısı, perceptronun çıktısını verip girdi değişkenini sınıflandırmaktadır. Eğer sapma değeri negatif çıkarsa,

sınıflandırma çıktısında 1'i elde etmek için öğrenen ağırlıkların toplamının daha büyük değerlerde olmaya zorlar. Girdi değerleri, sapma terimini etkilememektedir ancak bu terim, perceptron öğrenme algoritması yoluyla bilinmektedir.

Yapay sinir ağı çalışmalarında perceptronlar, daha sonra önerilen çok katmanlı perceptronlardan kavram olarak ayırmak için, daha çok tek katmanlı perceptronlar olarak bilinmektedir.

Perceptron öğrenme algoritmasında, tüm girdi sonuçları doğru bir şekilde sınıflandırılana dek perceptron modelinde ağırlıklar değiştirilmektedir. Eğer girdi doğrusal olarak ayrılamazsa algoritma sonlandırılmamaktadır. Doğrusal olarak ayrılabilen bir veri kümesi, veriyi iki sınıfa ayıran bir hiper düzlemin değerlerinin hesaplanacağı bir veri kümesidir.

Perceptron öğrenme algoritması, eğitimin başlangıcında çok küçük rastgele değerlerle ağırlık vektörünü başlatmaktadır. Her girdiyi kayıt altına almakta olup gerçek sınıflandırma değerleriyle kıyaslayabilmek için çıktı sınıflandırma değerlerini hesaplamaktadır. İlk girdi değeri her zaman 1.0 değerine sahip sapma girdisidir. Çünkü, sapma girdisi değiştirilememektedir. İlk ağırlık ise diyagramdaki sapma değeridir. Eğer, sınıflandırma doğru ise, ağırlık değiştirilmemektedir. Ancak yanlış bir sınıflandırma durumunda ağırlıklar bu sebeple düzenlenmektedir. Bu döngü, girdilerin her biri doğru bir şekilde sınıflandırılana kadar devam etmektedir. Eğer veri kümesi doğrusal bir şekilde ayrılamazsa, eğitim algoritması sonlandırılmamaktadır. Şekil 2.16'da, XOR olarak adlandırılan bir mantık fonksiyonunda doğrusal olarak ayrılamayan bir veri kümesi gösterilmektedir. Tek katmanlı algılayıcılar, XOR mantıksal modelleme problemini çözememektedirler [81].

Adaptive Linear Element (ADALINE), 1960 yılında Widrow ve Hoff tarafından önerilmiştir. Temel uygulaması, yapay sinir ağlarını içeren ilk endüstri uygulaması olan telefon ağlarında devre anahtarı "Devre anahtarlama" uygulamasıdır. Basit bir ağ olsa da ADALINE, yapay sinir ağları alanında bazı önemli ilerlemelere neden olmuştur. Bunlar arasında;

- "Delta kuralı" öğrenme algoritmasının geliştirilmesi

- Analog sinyal sürecini içeren problemlerde uygulanması
- YSA'nın ilk endüstriyel uygulamaları

x_0	x_1	y
0	0	0
0	1	1
1	0	1
1	1	0


Şekil 2.16. XOR mantık fonksiyonu

Daha belirgin bir şekilde, ADALINE' nin en büyük katkısı, çok katmanlı perceptronların eğitilmesinde kullanılan geliştirilmiş Delta kuralının öncüsü olan delta kuralı olarak adlandırılan öğrenme algoritmasını bilime kazandırmış olmasıdır.

Perceptronun yapısına benzer şekilde ADALINE, tek gizli katmandan ve bu katmanı oluşturan tek yapay sinir hücresinden oluşmaktadır. N tane girdi sinyali ve sadece bir çıktıdan oluşmaktadır. ADALINE, tek katmanlı ileri beslemeli mimarisine sahip olup bilgi akışı girdilerden çıktıya doğru olacak şekilde gerçekleşmektedir. Perceptron gibi yapısının basitliği dolayısıyla sadece iki farklı sınıf içeren örüntü sınıflandırma problemlerinde büyük ölçüde kullanılmaktadır. Tek bir ağ içerisinde birden çok ADALINE' nin bir araya gelerek MADALINE'i oluşturmaktadır [81, 87].

Bir önceki yapay sinir ağı mimarisinden (tek katmanlı ileri beslemeli YSA) farklı olarak çok katmanlı ileri beslemeli yapay sinir ağında bir veya birden fazla gizli katmandan oluşmakta olup yakınsama, örüntü sınıflandırma, sistemin tanımlaması, süreç kontrolü, optimizasyon gibi problemlerin çözümünde kullanılmaktadır. İleri beslemeli çok katmanlı ağda, n adet sinyale sahip bir adet girdi katmanı, n adet sinir hücresine sahip n adet gizli katmandan, çıktı değerlerini gösteren m adet sinir hücresinden oluşan bir adet çıktı katmanından oluşmaktadır. Çok katmanlı Perceptron ve Radyal tabanlı fonksiyon

çok katmanlı ileri beslemeli sinir ağlarında kullanılan en temel ağlardır. Aşağıda bu ağ yapısına ilişkin şekil verilmiştir.



Şekil 2.17. Çok katmanlı ileri beslemeli sinir ağı örneği [87]

Çok katmanlı perceptron (ÇKA), girdi ve çıktı katmanları arasında yer alan en az bir gizli katmandan oluşmaktadır. ÇKA, en az iki sinir katmanından oluşmakta olup bu sinir hücreleri gizli ve çıktı katmanlar arasında dağıtılmaktadır.


ÇKA, birçok farklı alandaki problemlerde geniş bir uygulama aralığına sahiptir. Uygulanabilirlik konusunda en çok kullanılan çok yönlü mimarilerden biridir. Uygulanma alanlarından bazıları şu şekildedir:

- Evrensel yaklaşım teorisi
- Örüntü tanıma
- Sürecin tanımlanması ve kontrolü
- Zaman serileri tahmini ve öngörüsü
- Sistem optimizasyonu

ÇKA, çok katmanlı ileri beslemeli mimariye sahiptir. Eğitim süreci denetimli öğrenme şeklindedir. Ağ içerisindeki bilgi akışı, girdi katmanında başlamakta daha sonra gizli (ara) katmandan geçerek çıktı katmanıyla son bulmaktadır. Gizli ve çıktı katmanlarından geri

besleme yapılmamaktadır. Popüler olmaya başlaması ve geniş bir kullanım alanına kavuşması 1980’li yılların sonlarında doğru gerçekleşmiştir.


Perceptron ve ADALİNE ağlarından farklı olarak, şekil 2.18’den de görüldüğü üzere, çıktı katmanını birden fazla sinir hücresine sahip olduğu ÇKA ağ yapısında birden fazla gizli katmanın yanısıra çıktı katmanındaki sinir hücreleri, süreçteki çıktılardan bir tanesini temsil etmektedir. Özetlenecek olursa, ÇKA’yı içeren tüm nöronlar arasında sisteme dağıtılacak girdi-çıktıların hareketleriyle ilişkili olarak ADALİNE ve Perceptron, sürecin tamamında eşleştirmeleri gerçekleştirmektedir. Sinyaller, girdi katmanını üzerinden ağa tanıtılmaktadır. Gizli katmanlar, sistemin hareketine bağlı olarak bilgiyi elde ederek nöronlarındaki ağırlıkları ve eşik değerleri kullanarak edindiği bilgiyi kodlamaktadır. Son olarak, çıktı katmanındaki nöronlar en sonuncu gizli katmandan sinyali alarak ağ tarafından üretilen çıktı olacak bir tepki (yanıt) örüntüsü üretmektedir. ÇKA’nın eğitim süreci boyunca kullandığı öğrenme algoritması backpropagation (geri yayımlı) algoritmasıdır [81, 87].



Şekil 2.18. Çok katmanlı perceptron ağı [87]

Genelleştirilmiş Delta kuralı olarak da bilinen Geri yayılım algoritmasının kullanıldığı ÇKA ağının eğitim süreci, genellikle iki aşamanın birbiri ardına uygulanmasıyla tamamlanmaktadır. Şekilde, girdi katmanında n adet girdinin, birinci gizli katmanda n_1

tane nöron, ikinci gizli katmanda n_2 tane nörona sahip iki gizli katmandan, çıktı katmanında yer alan n_3 tane sinyalden oluştuğu görülmektedir.




Şekil 2.19. İki gizli katmanlı geri yayılım algoritması [87]

Şekil 2.19’da ilk aşama forward propagation olarak adlandırılan ileriye doğru yayılımdır, burada, eğitim kümesinden alınan örnekler girdi ağına yerleştirilmektedir. Bu girdilerden elde edilecek olan çıktı değerleri elde edilene kadar bir katmandan diğerine iletilmektedir. Böylece, bu aşama sadece, nöronlarının ağırlıkları ve eşik değerini de dikkate alan ağdan elde edilecek çıktıları içermektedir. Daha sonra, ağ çıktısı tarafından elde edilen cevap, daha önce denetimli öğrenme sürecinde bahsedildiği gibi, istenilen cevap ile karşılaştırılmaktadır. Buradan elde edilen hatalar, geriye doğru besleme olarak adlandırılan ikinci aşamada uygulanmaktadır. İlk aşamadan farklı olarak, ağırlıklar ve eşik değerleri değiştirilmemektedir. Özetle, her bir yinelemede (iteration) birbiri ardına gerçekleşen ileri ve geriye doğru aşamalar ağırlıkların ve eşik değerlerin düzenlenmesine izin verilerek hatalar azaltılmaktadır [87].

Recurrent (yinelenen) ağlarda ise sinir hücresinin çıktı değerleri, diğer sinir hücreleri için yinelemeli girdi olarak kullanılmaktadır. Zaman serisi tahminleri, sistemin belirlenmesi ve optimizasyonu, süreç kontrol gibi zaman değişkenli sistemlerde kullanılmaktadır. Temel geri beslemeli ağlar arasında Hopfield ve geri beslemeli Perceptron yer almaktadır.

Şekil 2.20’de çıktı sinyallerinden birisinin gizli katmanı beslediği, geri beslemeli perceptron ağı gösterilmektedir. Böylelikle, geri beslemeli ağın kullanılmasıyla bu mimarideki ağlar bir önceki çıktıyı dikkate alarak çıktı üretmektedirler [87].



Şekil 2.20. Yinelenen ağ mimarisi [87]

Mesh (Örgüsel) ağ mimarisinde, ağın ana özelliği, örüntü çıkarma problemi için sınır hücrelerinin sinaptik ağırlıkları ve eşik değeriyle doğrudan ilişkili olarak ağ yapısındaki konumuna bağlıdır. Veri kümelemesi, örüntü tanıma, sistemin optimizasyonu gibi geniş çaplı uygulama alanına sahiptir [87].

2.2.2. Destek Vektör Makineleri

Destek vektör makineleri (DVM), denetimli makine öğrenmesi tekniklerinden biri olup lojistik regresyona benzer modern makine öğrenmesinde kullanılan en önemli algoritmalarından biridir. Varlığı, 1992 yılında Boser, Guyon ve Vapnik tarafından fark edilmiş ve o zamandan bugüne büyük bir gelişme göstermiştir. Denetimli öğrenme yönteminin ana fikri, aynı dağılım fonksiyonundan bilinmeyen örüntüleri düzgün sınıflandırmak için eğitim kümesinden f fonksiyonu oluşturmaktır.

$$(x_i, y_i) \in X \times Y$$

$$x_i \in X, y \in \{\pm 1\}$$


Amprisk risk minimizasyonuna dayanan diğer istatistiksel öğrenme tekniklerine karşın, DVM, yapısal risk minimizasyonu prensiplerine dayanarak sınıflandırma yapmaktadır. Yapısal risk minimizasyonu, sınıflandırma hatası ile aşırı uyum arasında denge kuran bir mekanizma sağlamaktadır [95].

DVM, Geçtiğimiz kırk yılda Vapnik ve çalışma arkadaşları tarafından AT&T Bell Laboratuvarlarında geliştirilen istatistiksel öğrenme teorisi veya VC teori çerçevesinde temelleri atılmıştır. Genel olarak ifade edilirse, DVM, genelleştirme hatasının bir üst sınırını en azlayarak amprisk risk minimizasyonu yerine yapısal risk minimizasyonunu gerçekleştirmekte olup çok iyi bir genelleştirme performansı elde etmektedir. DVM, yapısal risk minimizasyonuna dayanan dışbükey bir optimizasyon problemi olarak formüle edilmiştir. DVM'nin bir diğer özelliği, indirgenmiş bir eğitim alt kümesini (destek vektörleri) kullanılarak veriyi sınıflandırma yeteneğidir [48, 95].

Destek vektör algoritması, Rusya'da 60'lı yıllarda (Vapnik ve Lerner 1963, Vapnik ve Chervonenkis 1964) ortaya atılan “genelleştirilmiş portre algoritması”nın doğrusal olmayan bir genellemesidir. İlk iş olarak optik karakter okumaya odaklanılmıştır. Kısa bir süre içerisinde ise, destek vektör sınıflandırıcısı hem optik karakter okuma hem de nesne tanıma konusunda mevcut en iyi sistemlerle rekabet içine girmeye başlamıştır. 1998 yılında Burges tarafından “A comprehensive tutorial on SV classifiers” adlı çalışma yayınlanmıştır. Bundan başka, regresyon ve zaman serileri tahmini uygulamalarında araştırmacılar tarafından çok iyi sonuçlar elde edilmiştir. DV öğrenimi, günümüzde aktif araştırma alanlarına evrilmiştir. Dahası, makine öğrenmesinin standart yöntemleri arasına girmiştir. Modern destek vektör araştırmaları gerçek dünya uygulamalarına yönelmiştir. VC teorisi, gözlenemeyen verilere kendisine iyi bir tahmin yapma imkânı veren öğrenme makinesinin özelliklerini karakterize etmektedir. Özellikle küçük çaplı örnek problemlerinin çözümü için uygundur. DVM, aslında örüntü tanıma için geliştirilmiştir. Ayrıca, sınıflandırma, regresyon ve zaman serileri tahmininde kullanılmaktadır. DVM'nin ardında yatan ana düşünce, iki veya daha çok sınıf arasında mümkün olan en iyi şekilde ayırım (çizgi ile ayrılması) yapabilmektir. Bir defa, sınıfları ayırmak için ayırıcı

çizginin belirlenmesinin ardından gelecekteki veriyi tahmin etmede kullanılmaktadır [96,97-101].

Sınıflandırma problemi, genelliği kaybetmeden iki sınıflı problemi ele alarak kısıtlandırılabilir. Bu problemlerde amaç, mevcut örneklerden tümevarılan bir fonksiyon yardımıyla iki sınıfa ayırmaktır. Amaç, görülmeyen örnekler üzerinde iyi işleyecek bir başka deyişle iyi bir tahmin yapacak sınıflandırıcı üretmektir. Şekil 2.21 incelendiğinde, veriyi ayırabilen birçok olası doğrusal sınıflandırıcı var olmasına rağmen sadece bir tanesi marjı (margin) ençoklamaktadır. Bu doğrusal sınıflandırıcıya, en uygun ayırıcı hiperdüzlem olarak adlandırılmaktadır. Karar sınırlarını tanımlayan tüm eğitim örneklerinin küçük alt kümeleri destek vektörleri olarak adlandırılmaktadır. Destek vektörünü belirleme tüm örnekleri ayırmaya denktir. DVM kavramı, en yakın vektör ve hiperdüzlem arasındaki uzaklığı en çoklayan ve örnekleri hatasız bir şekilde ayıran hiperdüzlem ilkesinden gelmektedir. Bir başka ifadeyle, DVM ismini, esasen destek vektör olarak adlandırılan görece küçük sayıda olan gözlemler tarafından belirlenen hiperdüzlemden almaktadır. Sezgisel olarak, hiper düzlemi bu destek vektörlerinin oluşturduğu düşünülebilir. Bu yüzden, destek vektörleri model için çok önemlidir. Eğer, veriden destek vektör olmayan bir gözlem çıkarılırsa model değişmemektedir. Ancak, bir destek vektör kaldırılırsa, hiperdüzlem maksimum marja sahip olamamaktadır. DVM'nin formülasyonu, yapay sinir ağlarındaki perceptronunkine benzer olup çıktı tüm gizli nöronların bir doğrusal kombinasyonudur. Gizli nöronların (düğüm de olabilir) her biri bir destek vektörüne eşlenmektedir. [48,101,102].



Şekil 2.21. Optimal hiperdüzlemin belirlenmesi [104]

DVM, veriyi iki sınıfa ayıran optimal hiperdüzlemi bulmaya çalışmaktadır. Bir başka deyişle, iki sınıfın en yakın noktaları arasındaki marjı en çoklayan optimal hiperdüzlemi bulmaktadır. Verinin doğrusal bir şekilde ayrılabilmesi için iki boyutlu basit bir hiperdüzlem aşağıdaki iki denklemlerle açıklanmaktadır:

$$\vec{w} \cdot \vec{x} + b = 1 \quad (2.6)$$

ve

$$\vec{w} \cdot \vec{x} + b = -1 \quad (2.7)$$

şeklinde.

Her gözlemin, hiperdüzlemin doğru tarafında yer alabilmesi için aşağıda verilen kısıt denkleminin bağlıdır.

$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1 \quad 1 \leq i \leq n \quad (2.8)$$

Eğer veriler hiperdüzlemin yanlış tarafında bulunuyorsa verinin etkisinin indirgenmesi için ağırlıklandırma yapılmaktadır. Bu durumu ele almak için Hinge kayıp fonksiyonu olarak ifade edilen aşağıda gösterilen denklemden yararlanılmaktadır.

$$\max(0, 1 - y_i(\vec{w} \cdot \vec{x}_i + b)). \quad (2.9)$$

Eğer doğru sınıflandırıcı bulunmazsa, gözlemler kernel fonksiyonu kullanılarak yüksek boyutlu uzayda gözlemlenir.

Destek vektör makinelerini anlamak için öncelikle hiperdüzlem kavramının anlaşılması gerekmektedir. Şeklen, bir hiperdüzlem n boyutlu bir uzayda n-1 tane düz bir afın alt uzaydır. Afın kavramı, orijinden geçme zorunluluğu olmayan alt uzayı göstermektedir. Hiperdüzlem kavramı karmaşık olsa da oldukça basittir. Örnek verilecek olursa, iki boyutlu bir uzay elde edilmek istenirse, bir boyutlu hiperdüzleme (tek boyutta çizgi şeklinde) ayrılmaktadır. Eğer üç boyutlu bir uzay elde edilmek istenirse bu durumda iki

boyutlu bir hiperdüzleme (bu boyutta da kağıt parçasını katlanması gibidir) ayrılmaktadır. Bu şekilde, hiperdüzlem n boyuta kadar genelleştirilebilmektedir. Destek vektör makineleri, eğitim kümesinde sınıflar arasında uzaklığı maksimum yapan hiperdüzlemi kullanarak veriyi sınıflandırmaktadır. Veriyi iki sınıfa ayırmada en geniş düz bant olarak bir hiperdüzlem düşünülebilir [48,103].

Bir hiperdüzlemin matematiksel ifadesi oldukça basittir. İki boyutlu bir hiperdüzleme ait eşitlik aşağıda gösterilmektedir:

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 = 0 \quad (2.10)$$

Burada, β_0, β_1 ve β_2 hiperdüzlemin parametreleridir. Hiperdüzlem tanımlanırken, her $X = (X_1, X_2)^T$ hiperdüzlem üzerindeki bir noktayı belirlemektedir. n boyutlu bir hiperdüzleme ait eşitlik,

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n = 0 \quad (2.11)$$

şeklindedir. Eğer, n boyutlu bir uzayda $X = (X_1, X_2, \dots, X_n)^T$ şeklinde bir nokta yukarıdaki eşitliği sağlarsa, X, hiperdüzlem üzerinde yer almaktadır. Eğer X, 2.11 de ki denklem sağlamazsa


$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n > 0 \quad (2.12)$$

Şeklindeki 2.12 denklemini sağlamaktadır. Bu X vektörünün hiperdüzlemin bir tarafında olduğu belirtilmektedir. Diğer taraftan, X, 2.13'te ki denlemi sağlarsa,

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n < 0 \quad (2.13)$$

Bu durumda hiperdüzlemin diğer kısmı üzerinde yer almaktadır. Bu yönüyle, hiperdüzlemi, n boyutlu bir uzayın iki yarı uzaya ayrılması olarak düşünülmektedir.

Denklem 2.13'ün sol tarafındaki işaretler hesaplanarak bir noktanın hiperdüzlemin hangi tarafında yer alacağı kolayca belirlenebilmektedir.



Şekil 2.22. Hiperdüzlem örneği [48]

Şekil 2.22 incelendiğinde 0 sınıfındaki tüm gözlemler siyahlar ve 1 sınıfı için açık grilerden oluşmaktadır. Hiperdüzlem, sınıflandırılacak yeni bir gözlemin hangi sınıfa düşeceğini belirleyen karar sınırı olarak da adlandırılmaktadır. Sınırın üzerinde olan her gözlem sıfır olarak sınıflandırılırken sınırın altında kalan gözlemler bir olarak sınıflandırılmaktadır. Destek vektörleri hakkında not edilecek birkaç maddeden birincisi, şekilde gösterildiği gibi iki sınıfa ayrılmış bir örnek vardır. Ancak, DVM, çok boyuta ayrılan örnekler içinde iyi bir sınıflandırıcıdır. İkincisi ise şekilde görüldüğü gibi hiperdüzlem doğası gereği doğrusaldır. Bu örnekte gözlemler doğrusal bir şekilde ayrılabilirdi için bu duruma uymaktadır. Ancak gerçek hayatta bu durumla nadir olarak karşılaşılır. Daha net bir ifadeyle, sınıflar tam anlamıyla ayrılamamaktadır. Bu gibi durumlarda hiperdüzlemin marjını en çoklayan ile yanlış sınıflandırmayı en aza indiren destek vektörleri arasında bir denge vardır. Maksimum marjlı hiperdüzlemin kullanımı, marj maksimize edildiğinde en aza indirilen olasılıklı test hatası sınırını sağlayan Vapnik- Chervonenskis teorisi tarafından önerilmiştir. Destek vektör sınıflandırıcısı, bir test gözlemini hiperdüzlemin hangi tarafında olduğunu belirler. Hiperdüzlem, eğitim örneklerinin birçoğu iki sınıfa doğru bir şekilde ayırmak için seçilmektedir. Ancak, geriye kalan örnekler yanlış sınıflandırılma ihtimali de olabilmektedir. Optimizasyon probleminin çözümü,

$$\max_{\beta_0, \beta_1, \dots, \beta_p, \epsilon_1, \dots, \epsilon_n} M \quad (2.14)$$


$$\text{kısıt } \sum_{j=1}^p \beta_j^2 = 1 \quad (2.15)$$

$$y_i(\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip}) \geq M(1 - \epsilon_i) \quad (2.16)$$

$$\epsilon_1 \geq 0 \quad \sum_{i=1}^n \epsilon_i \leq C, \quad (2.17)$$

Burada, C negatif olmayan bir düzenleme parametresidir. M, marjın genişliği olup bu miktar, mümkün olduğunca büyük yapılmaya çalışılmaktadır. $\epsilon_1, \dots, \epsilon_n$, gözlemlerin marjın veya hiperdüzlemin yanlış tarafta olmasına olanak sağlayan gevşeklik parametresini ifade etmektedir. ϵ_i değişkeni i. gözlemin hiperdüzleme ve marja göre nerede konumlandığı bilgisini vermektedir. Eğer $\epsilon_i = 0$ ise i. gözlem marjın doğru tarafındadır. Aksi takdirde ($\epsilon_i \geq 0$ durumunda) ilgili gözlem marjın yanlış tarafında olmaktadır. Bu gözlemin marjı bozduğu söylenebilmektedir. Eğer, $\epsilon_i \geq 1$ ise i. gözlem hiperdüzlemin yanlış tarafındadır.

DVM' de, C, bir gözlemi yanlış sınıflandırma cezasını belirleyen bir parametredir. Yanlış sınıflandırma, hataları cezalandıran C parametresi ile kontrol edilmektedir. C, destek vektör makinesinin öğrenme parametresi olup gözlemlerin yanlış sınıflandırılmasını cezalandırmaktadır. C, ϵ_i ' lerin toplamı olup marj ve hiperdüzlemdeki tolere edilebilecek bozukluğun derecesini belirlemektedir. $C > 0$ olduğunda en fazla C adet gözlem hiperdüzlemin yanlış tarafında olabilir. [48,103,104,105].



Şekil 2.23. İki boyutlu bir uzayda hiperdüzlemin gösterilmesi [103]


Şekil 2.23'te $1 + 2X_1 + 3X_2 = 0$ eşitliğine sahip iki boyutlu bir hiperdüzlem gösterilmektedir. Mavi bölge, $1 + 2X_1 + 3X_2 > 0$ denklemini sağlayan noktalar kümesini, mor bölge ise, $1 + 2X_1 + 3X_2 < 0$ denklemini sağlayan noktalar kümesini göstermektedir.

N boyutlu uzayda p tane eğitim gözleminde oluşan $n \times p$ boyutlu bir veri matrisi ele alındığında,

$$x_1 = \begin{pmatrix} x_{11} \\ \vdots \\ x_{1n} \end{pmatrix}, \dots, x_p = \begin{pmatrix} x_{p1} \\ \vdots \\ x_{pn} \end{pmatrix} \quad (2.18)$$

Bu gözlemler, iki sınıfa düşmektedir. Bir başka deyişle, $y_1, \dots, y_p \in \{-1, +1\}$ olup -1 ifadesi bir sınıfı, $+1$ ise diğer sınıfı temsil etmektedir. Burada amaç $x^* = (x_1^* \dots x_n^*)^T$ şeklinde n-boyutlu bir vektöre sahip test gözlemlerini özellik ölçümlerini kullanarak doğru bir şekilde sınıflandıracak eğitim verisine dayanan bir sınıflandırıcı geliştirmektir. Eğitim gözlemlerini etiketlerine (label) kusursuz bir şekilde ayrılabilir bir hiperdüzlem oluşturulması muhtemeldir. Şekil 2.24'ün sol kısmı incelendiğinde mavi bölgedeki gözlemler olarak ve mor bölgedeki gözlemler ise $y_i = -1$ olarak etiketlenmektedir. O halde, ayırıcı hiperdüzlem $y_i = 1$ olduğunda, $\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_n x_{ni} > 0$

şeklinde, $y_i = -1$ olduğunda $\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_n x_{ni} < 0$ özelliğe sahiptir. Ayrıca hiperdüzlem bu iki denklem dikkate alındığında $i = 1, \dots, n$ için $y_i(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_n x_{ni}) > 0$ olmaktadır.




Şekil 2.24. Optimal hiperdüzlemin bulunması [103]

Ayırıcı bir düzlemin varlığında, bir test gözlemine, hiperdüzlemin bulunduğu bölgeye göre, bir sınıf tayin edilmektedir. Şekil 2.24'ün sağ tarafında böyle bir örnekle karşılaşılmaktadır. x^* test gözlemi, $f(\beta_0 + \beta_1 x_{i1}^* + \beta_2 x_{i2}^* + \dots + \beta_n x_n^*)$ fonksiyonunun işaretine bağlı olarak sınıflandırılmaktadır. Eğer pozitif ise test gözlemi sınıf 1'e, eğer negatif ise sınıf -1'e atanmaktadır. Ayrıca, $f(x^*)$ ' in büyüklüğü kullanılarak hiperdüzleme olan konumu belirlenebilmektedir. Eğer, $f(x^*)$ sıfırdan oldukça uzak ise, hiperdüzlemden de uzak olduğu anlamına gelmekte olup kendisine atanan sınıfın doğru bir sınıf olma ihtimalini artırmaktadır. Öte yandan, $f(x^*)$ değeri sıfıra yakın bir değer alırsa hiperdüzleme yakın bir noktada konumlanmaktadır. Böylece sınıfı belli olan gözlemin doğru bir şekilde sınıflandırılmasına daha az güven duyulmaktadır.

Şeklin 2.24'ün sol kısmında üç adet muhtemel ayırıcı hiperdüzlem gösterilmektedir. Bir ayırıcı hiperdüzleme dayanan sınıflandırıcı oluşturmak için, sonsuz muhtemel ayırıcı hiperdüzlemlerden hangisinin kullanılacağına karar verilmesi gerekmektedir. Doğal bir karar olarak, eğitim gözlemlerinin hiperdüzlemden en uzakta konumlandırılacak olan optimal ayırıcı hiperdüzlem olarak adlandırılan azami marj hiperdüzlemidir. Her bir

eđitim gözleminde belirli bir ayırıcı hiperdüzleme olan uzaklıkları hesaplanabilmektedir. Bu uzaklıklardan en küçüğü, margin (marj) olarak adlandırılan gözlemlerden hiperdüzleme olan asgari uzaklıktır. Azami marj hiperdüzlemi, marjın en geniş olduđu hiperdüzlemdir. Maksimum marjın hiperdüzlemi diđer gözlemlere deđil, direkt olarak destek vektörlere bađlıdır. Diđer gözlemlerin marj tarafından belirlenen sınırları geçmemek kořulu ile gözlemlere yapılan bir harekette ayırıcı hiperdüzlem etkilenmeyecektir.

Őekil 2.25 incelendiđinde, maksimum marj hiperdüzlemine eŐit uzaklıkta ve marjın genişliđini gösteren kesikli çizgi üzerinde üç adet nokta (gözlem) yer almaktadır. Bu noktalara, n boyutlu uzayda vektör olduklarından dolayı “destek vektör” olarak ifade edilmektedir. Destek denilmesinin ardında yatan kavram ise, bu marjın üzerinde yer alan ve yukarıda tanımlanan destek vektörleri hareket ettirildiđinde maximum marjında hareket edeceđi anlamına gelerek bu marjı hareketi dođrultusunda destekleme kavramından gelmektedir.



Őekil 2.25. Gözlemlerin maksimum marjlı hiperdüzleme ayrılması [103]

Őekil 2.25 incelendiđinde, mavi ve mor renkle gösterilen iki gözlem sınıfı vardır. Maksimum marj hiperdüzlemi düz (kesintisiz) çizgi ile gösterilmektedir. Öte yandan marj ise kesikli çizgi ile gösterilmiŐ olup hiperdüzleme eŐit uzaklıkta ve paraleldir. Kesikli çizgi üzerinde yer alan iki mavi ve bir mor nokta destek vektörleridir. Mor ve mavi gridler, bu hiperdüzleme dayalı bir sınıflandırıcı tarafından oluŐturulan karar kuralını göstermektedir [48, 103].

2.5.2.1. Destek Vektör Regresyonu

Regresyon, basit tanımıyla istatistikten yoğun bir biçimde etkilenen ilk öğrenme algoritmalarından birisidir. Yıllar geçtikçe, regresyon yöntemlerindeki karmaşıklık ve farklılık yeni uygulamalarının ortaya çıkışıyla birlikte artış göstermiştir [12].

Destek vektör regresyonu (DVR), DVM nin presiplerine dayanmaktadır. Bağımlı değişkenin kategorik olmayıp sayısal biçime uyarlanmış bir DVM biçimidir. DVR'yi kullanmanın ana avantajlarından birisi de, parametrik olmayan bir yöntem olmasıdır. Model kurmak için DVR yöntemi Kernel fonksiyonlarından yararlanmaktadır. En yaygın kullanılan Kernel fonksiyonları ise şu şekildedir:

- ❖ Doğrusal (Linear)
- ❖ Polinom (Polynomial)
- ❖ Sigmoid
- ❖ Radyal temelli (Radial Base)

Bu yöntemde açıklayıcı değişkenler değiştirilmeden, doğrusal olmayan bir modelin tahmin edilmesine olanak sağlar [100, 106, 107].

DVM'nin regresyon şekli 1997 yılında Vapnik, Smola, Drucker tarafından literatüre Destek Vektör Regresyonu (DVR) olarak kazandırılmıştır. DVR'nin altında yatan düşünce, yüksek boyutlu bir girdi uzayında doğrusal olmayan birebir ve örten fonksiyon (mapping) kullanarak doğrusal regresyon fonksiyonunu tahmin etmektir. Girdi uzayı, kernel fonksiyonları vasıtasıyla daha yüksek boyutlu girdi uzayına (feature space) dönüşmektedir. Geleneksel regresyon süreçleri, verideki tüm gözlemlerle tahmin edilen ve gerçek değerlerle arasındaki sapmanın en aza indiren bir $f(x)$ fonksiyonu türeten süreçlerdir. DVR'nin en önemli özelliği ise, tahmin hatasını en aza indirmek yerine, geliştirilmiş performansı bulmak için geliştirilmiş hata sınırını en aza indirmeye çalışmasıdır. [38, 107].

DVS tarafından kurulan model sadece eğitim verisinin bir alt kümesine dayanmakta olup modelin maliyet fonksiyonu, marjın ötesinde olan gözlemleri dikkate almamaktadır.

Benzer şekilde, DVR tarafından kurulan model de eğitim verisinin bir alt kümesine dayanmakta olup modelin maliyet fonksiyonu, model tahminine yakın (ε eşiği içerisinde) her eğitim verisini dışlamaktadır. Vapnik tarafından önerilen- DVR' nin amacı, arka planda işleyen sürecin sabit bir ε değerinden daha büyük olmayan sapmaya sahip eğitim örneklerinden bir $f(x)$ fonksiyonu bulmaktır. Başka bir deyişle, ε 'dan daha düşük hatalar dikkate alınmamaktadır. Ancak, daha büyük hatalar da kabul edilmemektedir. Bu anlamda, hatalar, ε değerinin altında kayıp fonksiyonu (loss function) tarafından üretilmekte olup duyarsızlık bandı (ε - insensitive tube) olarak adlandırılan destek vektörleriyle çevrili bantlar içerisinde yer almakta olup karar yüzeyi (decision surface) olarak adlandırılan tahmin edilmiş değerin belirlenmesinde herhangi bir etkisi yoktur. f doğrusal fonksiyonu,

$$f(x) = \langle w, x \rangle + b \quad w \in X, b \in \mathbb{R} \quad (2.19)$$

şeklinde ifade edilmekte olup $\langle \cdot, \cdot \rangle$ x 'te iç çarpımı göstermektedir. Bu denklemdeki karmaşıklığı minimuma indirmek için w değerinin normunun minimize edilmesi gerekmektedir. Bir convex optimizasyon problemi olarak aşağıdaki eşitlikle doğrusal katı (hard) ε - bant DVR' si ifade edilmektedir:

$$\text{minimize } f(w) = \frac{1}{2} \|w\|^2 \quad (2.20)$$

$$\text{kısıtlar } y_i - \langle w, x_i \rangle - b \leq \varepsilon \quad (2.21)$$

$$\langle w, x_i \rangle + b - y_i \leq \varepsilon \quad (2.22)$$

DVS'deki gibi, optimizasyon problemlerinde düzensizliği kontrol edebilmek adına DVR formülasyonunda ξ, ξ_i^* şeklinde sembolize edilen yumuşak marjlı kayıp fonksiyonuna benzer ve Vapnik (1995) tarafından tanıtilan artık değişkenleri içermektedir. ξ değişkeni, eğitim verilerindeki hataların maliyetini ölçmektedir. Bant içerisindeki tüm noktalarda bu maliyet sıfır değerini almaktadır.


Ayrıca C sabiti, fonksiyon sonucunun karmaşıklığını ayarlamak ve ε 'den daha büyük uç değerlerin varlığını sınırlandırmak için kullanılmaktadır.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} (\xi_i + \xi_i^*) \quad (2.23)$$

$$\text{kısıtlar} \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (2.24)$$

DVR'nin bir başka özelliği ise gerçek ve öngörü değerleri arasındaki farkı ölçmede kullanılan, aşağıdaki formülde gösterildiği üzere, duyarsızlık bandının dışında kalan örüntüleri doğrusal şekilde cezalandıran ε - duyarsızlık kayıp fonksiyonudur [100,107,108].

$$|\xi|_{\varepsilon} = \begin{cases} 0 & \text{eğer } |y_i - f(x)| \leq \varepsilon \\ |y_i - f(x)| & \text{diğer durumlarda} \end{cases} \quad (2.25)$$



Şekil 2.26. Model karmaşıklığı ile bandın dışında kalan gözlemler arasındaki ilişki [100]

Şekilde 2.26' da bu kayıp fonksiyon durumu gösterilmiştir. Denklem primal fonksiyon, duali alınarak kolay bir şekilde çözülebilmektedir.

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} (\xi_i + \xi_i^*) - \sum_{i=1}^{\ell} \eta_i \xi_i + \eta_i^* \xi_i^* - \sum_{i=1}^{\ell} a_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) - \sum_{i=1}^{\ell} a_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b) \quad (2.26)$$

Burada L , Lagrange simgesi, $a_i, a_i^*, \eta_i, \eta_i^*$ ise Lagrange çapranıdır. Bu bakımdan, dual değişkenler, pozitif olma kısıtını sağlaması gerekmektedir.

$$a_i, a_i^*, \eta_i, \eta_i^* \geq 0$$

Optimalliğin sağlanabilmesi adına primal değişkenler olan w, b, ξ_i, ξ_i^* 'e göre Lagrange fonksiyonunda kısmi türevleri alınmalıdır. Buna göre,

$$\partial_b L = \sum_{i=1}^{\ell} (a_i^* - a_i) = 0 \quad (2.27)$$

$$\partial_w L = w - \sum_{i=1}^{\ell} (a_i^* - a_i) x_i = 0 \quad (2.28)$$

$$\partial_{\xi_i}^* L = C - a_i^* - \eta_i^* = 0 \quad (2.29)$$

Primal değişkenlere göre kısmi türevlerin alındığı bu denklemler Lagrange denklemi içerisinde ifade edilirse,

$$\text{maks} \begin{cases} -\frac{1}{2} \sum_{i,j=1}^{\ell} (a_i - a_i^*)(a_j - a_j^*) \langle x_i, x_j \rangle \\ -\varepsilon \sum_{i=1}^{\ell} (a_i + a_i^*) + \sum_{i=1}^{\ell} y_i (a_i - a_i^*) \end{cases} \quad (2.30)$$

$$\text{kısıtlar} \sum_{i=1}^{\ell} (a_i - a_i^*) = 0 \text{ ve } a_i, a_i^* \in [0, C] \quad (2.31)$$

Böylece, türev alınarak dual değişken olan η_i, η_i^* optimizasyon probleminden elimine edilmiştir [100,110,111].

Yukarıda ifade edilen dual problemde, regresyon problemleri sınıflandırma problemlerine dönüştüğünden doğrusal bir şekilde ayrılmaya dayanan doğrusal regresyon fonksiyonunu aramaktadır. Doğrusal regresyon fonksiyonunu elde etmek için doğrusal ayrılma yerine doğrusal olmayan ayrılma kullanılmasına ihtiyaç vardır. Bu problem için ilgili primal problemin aşağıdaki gibidir:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} (\xi_i + \xi_i^*), \quad (2.32)$$

$$\text{kısıtlar} ((w \cdot \Phi(x_i)) + b - y_i \leq \varepsilon + \xi_i, \quad i = 1, \dots, \ell) \quad (2.33)$$

$$y_i - ((w \cdot \Phi(x_i)) + b) \leq \varepsilon + \xi_i^* \quad i = 1, \dots, \ell \quad (2.34)$$

$$\xi_i^{(*)} \geq 0 \quad i = 1, \dots, \ell \quad (2.35)$$

Burada (*), * ve *'sız bir vektörün iki durumunu göstermektedir. Φ ise doğrusal olmayan ayrımın gerçekleştirilebilmesi için girdi uzayının Hilbert uzayına (\mathcal{H}) eşleyen operatördür. Dual problemi bulabilmek için Lagrange fonksiyonunda aşağıdaki gibidir.

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} (\xi_i + \xi_i^*) \quad (2.36)$$

$$- \sum_{i=1}^{\ell} (\eta_i \xi_i) + \eta_i^* \xi_i^* - \sum_{i=1}^{\ell} a_i (\varepsilon + \xi_i + y_i - (w * \Phi(x_i)) - b)$$

$$- \sum_{i=1}^{\ell} a_i^* (\varepsilon + \xi_i^* - y_i + (w * \Phi(x_i)) + b)$$

Burada, $a^{(*)} = (a_1, a_1^*, \dots, a_\ell, a_\ell^*)^T$ ve $\eta^{(*)} = (\eta_1, \eta_1^*, \dots, \eta_\ell, \eta_\ell^*)^T$ Lagrange çarpan vektörleridir [102,110-112].

2.2.3. Rastgele Orman

Makine öğrenmesi yöntemlerinin birçoğundaki gelişme Berkeley'deki California Üniversitesi'nden Leo Breiman ve Standford Üniversitesi'nden Jerry Friedman adında istatistikçilerin yaptıkları çalışmaları izlemektedir. Berkeley ve Standford daki diğer araştırmacılarla birlikte, 1984 yılında ağaç modellerini geliştirmeye başlamışlardır. 1990'larda Bagging ve Boosting gibi topluluk yöntemlerinin ortaya çıkması sonucu makine öğrenmesi adında bir alan meydana gelmeye başlamıştır [112].

Ağaç modelleri, karar ağaçları, sınıflandırma ve regresyon ağaçları (CART) ya da sadece ağaçlar, bu kavramlar aynı anlamlara gelmekte olup etkili, parametrik olmayan yapıda ve denetimli öğrenme şeklinde sınıflandırma ve regresyon alanında popüler bir yöntemdir. Karar ağaçları, Yirmi Soru oyununa (Twenty Questions Game) benzemektedir. Bu oyunda, bir oyuncu düşündüğü bir nesneyi rakiplerine çeşitli ipuçları vererek tahmin etmelerini istemektedir. Rakipler yapmış oldukları tahminlere göre evet veya hayır cevabı

almaktadır. Bu oyunda sadece 20 soruya izin verilmektedir. Oyun ismini bu kuraldan almaktadır. Soruyu yönlendiren kişi, çıkarımda bulunulan ifadeleri birbiri ardına sıralamaktadır. Tümdengelimci bir yaklaşım izlenmektedir. Cevabı doğru tahmin eden kişi oyunu kazanırken, hiçbir doğru cevap çıkmadıysa, cevabı bilen diğer bir ifadeyle soruyu soran kişi kazanmaktadır. Karar ağaçlarında, buna benzer şekilde birçok veri cevaplanarak dallara ayrılmaktadır. Bir karar ağacı, uygulaması ve anlaşılması kolay bir dizi eğer-öyleyse- değilse kuralıdır. Sonuçlar baş aşağı bir ağaca benzemekle birlikte en üstte ilk karar kuralı ardından gelen karar kuralları ise aşağı doğru dallanmaktadır. Karar ağacında, her karar kuralı yeni dallara ayrılan bir karar düğümünde oluşmaktadır. Karar ağacı soncunda karar kuralı olmayan dallara yaprak denilmektedir. Ağaç tabanlı modellerin bir özelliği de yorumlanabilirliğinden gelmektedir. Karar ağacı öğrencileri, bir düğümdeki heterojenliği en aza indirecek bir karar kuralı bulmaya çalışmaktadır. Bu heterojenliğin belirlenmesinde birçok ölçüm yöntemi bulunmaktadır. Bunlardan birisi de Gini Impurity dir. Bu kavram, Gini katsayısıyla karıştırılmakta olup farklı bir anlama gelmektedir. Konsept olarak benzer olsa da, Gini katsayısı, ikili sınıflandırma problemlerinde sınırlandırılmakta olup Eğri altında kalan alan (AUC) ölçümüyle ilgilidir. Gini impurity, çok sınıflı bir sınıflandırıcı kapsamında uygulanan yanlış sınıflandırmanın bir ölçüsüdür. Entropi kavramıyla benzer şekilde işlemekte olup hesaplanması daha kolay bir yöntemdir.

$$Gini = 1 - \sum_i p_i^2 \quad (2.37)$$

Burada, i sınıf sayısını göstermektedir. Entropi kavramı ise bilgi teorisinden gelmekte olup verideki heterojenliğin bir ölçüsüdür. Eğer örnek tamamen homojen ise entropi değeri sıfır, eğer örnek eşit bir şekilde bölünmüş ise 1 olacaktır. Karar ağaçlarında, heterojenliği en çok olan tahminci, verilerin sınıflandırılmasında kök düğüme en yakın olandır.

$$Entropi = - \sum_{i=1}^n p_i \log_b p_i \quad (2.38)$$

Burada, n sınıf sayısıdır. Entropi, orta noktada maksimum değere sahiptir. 0 ve 1 değerlerinde ise minimumdur. Daha iyi bir sınıflandırma için entropinin düşük olması istenir [84, 112-114].

Makine öğrenmesi alanında kullanılan karar ağaçları kavramı ile yöneylem alanında kullanılan karar ağaçları kavramı birbirinden farklıdır. Burada bahsedilen kavram, daha eski olup yöneylemde kullanılan karar ağacı kavramı insan kararlarının analiz süreci olarak tanımlanmaktadır [112].

Karar ağaçları, hesaplanması ve sonuçların anlaşılması açısından kolay, kayıp gözlemlerle de çalışabilen ve ilgili olmayan özelliklerle baş edebilen bir yöntem olmasına karşın veriye aşırı uyum göstermektedir. Sayısal ve nominal değerlerle çalışabilmektedir. Bir karar ağacının kurulabilmesi için ilk olarak verilerin bölünmesinde kullanılan özelliklerin belirlenmesi için veri kümesinde ilk kararın verilmesi gerekmektedir. Bunu belirlemek için, tüm özelliklerin denenmesi ve en iyi sonucu verecek bölünmenin ölçülmesi gerekmektedir. Bu gerçekleştirildikten sonra veri kümesi, alt kümelere ayrılmaktadır. Böylelikle, altkümeler ilk karar düğümünden dallanma gerçekleştirecektir. Dallardaki veriler aynı ise, doğru bir sınıflandırma yapılmış olup tekrar dallandırma yapılmasını gerektirmez. Eğer veriler aynı sınıfta ise, o halde bu altkümeden dallandırmanın devam edilmesi gerekmektedir. Alt kümelerde orijinal veri kümelerindeki gibi ayrılmaya devam etmektedir ve tüm veriler sınıflandırılincaya kadar bu işlem devam etmektedir. Karar ağaçları regresyonu ise, karar ağaçları sınıflandırmasına benzer şekilde çalışmaktadır. Ancak, Gini Impurity ve entropiyi azaltmak yerine Ortalama Hata Karenin (MSE) azaltılması amaçlanmaktadır [48, 84,113].

Karar ağaçlarında ortak problem, overfitting, yani eğitim verilerinin aşırı uyum eğilimi içerisinde olmalarıdır. Bu problem, Rastgele orman adı verilen yaygın şekilde kullanılan bir topluluk öğrenme yönteminin ortaya çıkışını güdülemiştir. Bir rastgele ormanda, birçok karar ağacı eğitilmekte ve her düğüm en iyi dallanmanın belirlendiği özellik alt kümesi dikkate alınmaktadır. Bu rastgele karar ağaçları ormanı, tahmin edilen sınıfı belirlemek için oy kullanmaktadır. Rastgele ormanda, her karar ağacı, yeniden örneklemeli gözlemlerin bir alt kümesi kullanılarak eğitilmektedir. Bu her ağaç için, o ağacı eğitmekte kullanılmayan ayrı bir gözlem altkümesi olduğu anlamına gelmektedir. Bunlara Out- of- bag gözlemleri denilmektedir. Out -of- Bag gözlemleri rastgele ormanın performansını değerlendirmek için bir test kümesi olarak kullanılmaktadır. Her gözlem için öğrenme algoritması gözlemin gerçek değerini, bu gözlem kullanılarak eğitilmeyen ağaçların bir alt kümesindeki tahminle karşılaştırmaktadır. Bu şekilde, toplam puanlar

hesaplanarak bir rastgele ormanın performansı ölçülmektedir. OOB skor tahmini çapraz doğrulamaya bir alternatif olmaktadır [48, 84,113].


Rastgele orman (RF) kavramı, bir ormanın sözlükteki tanımına benzer şekilde, her ağacın bir araya gelerek oluşturduğu bir orman topluluğudur. Rastgele orman, denetimli bir makine öğrenmesi yöntemi olup sınıflandırma ve regresyon alanında problemlere uygulanmaktadır. Tekil ağaçlar topluluğundan meydana gelmektedir. Bilim dünyası, milenyum heyecanı devam ederken yeni bir makine öğrenmesi olan rastgele ormanı (Random Forest) 2001 yılında Leo Breiman ve Adele Cutler aracılığıyla öğrenmiş olup bu yöntem rastgele seçilen girdilerin bir alt uzayında yetişen birbiriyle ilişkisiz karar ağaçları topluluğuna sahip tahmine dayalı bir topluluk (ensemble) oluşturmak için geliştirilmiştir. RF, $\{g(w, \phi_q), \forall q = 1, 2, 3, \dots\}$ ağaç şeklinde sınıflandırıcı topluluğundan oluşmaktadır. Burada, $\{\phi_q\}$ ifadesi, bağımsız ve özdeş dağılımlı tekil ağaçların oluşturduğu rastgele vektörü ifade etmektedir [51, 115].

RF, büyük veri setlerinin çözümlenmesinde ve yüksek boyutlu verilerin görselleştirilmesinde etkili bir yöntemdir. Çok sayıda girdi değişkenini herhangi bir eleme yapmaksızın iyi bir biçimde yönetebilmektedir. Faydalı tahmin edicileri kendiliğinden algılayabilmektedir. Hata tahminleri, korelasyon, dayanıklılık ve önemli değişkenleri saptamaktadır. Bir ormandaki ağaçlara benzer şekilde RF basitçe aynı hizaya getirilebilmektedir. Doğruluğunu etkilemeyecek şekilde, atılan verilerin büyük bir kısmı için bir tahmin bulabilen etkili bir yöntemdir. Değişkenler arasındaki etkileşimin tespitinde denemeye dayanan yaklaşım izlemektedir. RF gibi çoklu ağaç algoritmaları daha iyi bir tahmin performansı sağlamakla birlikte tek bir ağacın sahip olduğu özellikleri kaybetmektedir. Bu paragraf içerisinde bahsedilen RF yönteminin özelliklerine ek olarak çeşitli problemlerin çözümünde veri bilimi alanında sıklıkla kullanılan çok güçlü bir yöntemdir [48, 51, 84].

RF, karar ağaçlarından oluşan bir topluluktur. Bilindiği üzere, karar ağaçları, yüksek varyansa ve düşük sapmaya sahip olması özelliği karar ağaçlarını istikrarsız bir yapıya kavuşturmaktadır. Karar ağaçlarının ortalaması alınarak ideal bir modele sahip olabilmek için modelin varyans bileşeni minimize edilmeye çalışılmaktadır. RF, bağımsız karar ağaçları oluşturmak ve sınıflandırma problemlerinde en büyük oyu, regresyon

problemlerinde ise ortalama değeri almak için eğitim verisinde hem gözlemler hem de değişkenleri örnekleme çalışmaktadır. RF kullanılarak gerçekleştirilen örneklerin alt kümelerine seçilmesinde şu kurallar mevcut olup her ağaç, eğitim kümesinden yararlanılarak oluşturulan örnek veri üzerinde geliştirilmektedir. Her bir ağaç için eğitim verisinde gözlemlerin yaklaşık 2/3'sinin seçilmekte olup eğer p değişkeni, sınıflandırma problemlerinde kullanılıyorsa p nin karekökü, regresyon problemleri için ise p/3 değeri alınmaktadır. Bu değer, her bölünmede rastgele seçilen değişken sayısını ifade etmektedir. [48, 113, 116].

RF, bir durum haricinde bagging algoritmasına benzemektedir. Bagging algoritmasında, her bir örnek için tüm değişkenler veya sütunlar seçilirken, RF' de birden çok alt değişken seçilmektedir. Tüm değişkenleri seçmek yerine bazı değişkenlerin seçilmesindeki neden her bir bağımsız ağaç örnekleme süresince, bu bağımsız değişkenlerin tüm ağaçların aşağı yukarı benzer görünmesini sağlayan önemli değişkenler olmasıdır. RF, hem düşük sapmaya hem de varyans hatalarına sahiptir. Bagging algoritması ise, varyans hatasını en aza indirmek ve aynı zamanda sapmadan kaynaklı hata miktarını artırmamak için karar ağaçları mekanizmasına uygulanan bir topluluk tekniğidir. Bu algoritma da, gözlemlerin bir alt örneği ve tüm değişkenler için birden çok örnek seçilmektedir. Daha sonra bu örnekler her biri için ayrı ayrı karar ağaçları tahmin edilmektedir ve maksimum oy alınarak sonuçlar toplulaştırılır. Regresyon durumunda ise, hesaplanan çıktıların ortalaması alınmaktadır [48, 84].



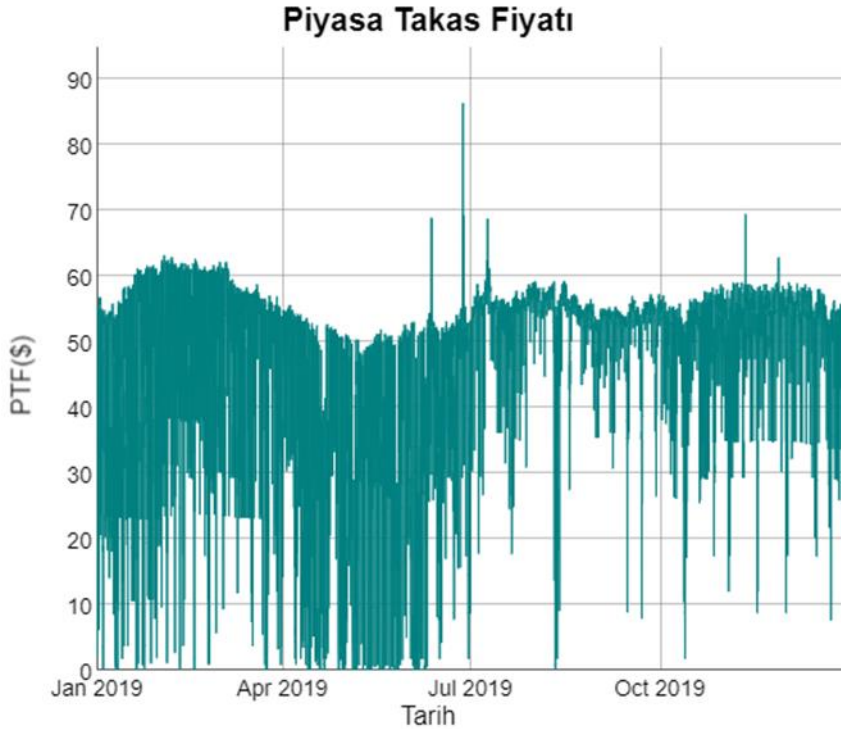
Şekil 2.27. Bagging ve random forest arasındaki farkın resmedilmesi [113]

Yukarıda verilen diyagramda mavi ve pembe renkle gösterilen iki örnek mevcuttur. Birbiriyle ilişkisiz tekil ağaçların oluşturulabilmesi için Bagging örneğinde tüm sütun ve bir miktar gözlem seçilirken, RF' de bu durum birkaç sütunun seçilmesine dayanmaktadır [113].

3. UYGULAMA

Bu tez çalışmasının uygulama kısmında, R programı kullanılarak, son dönemde literatürde yerini sağlamlaştırma çabasında emin adımlarla ilerleyen makine öğrenmesi yöntemlerinden Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM) ve Rastgele Orman (RF) yöntemi kullanılarak EPIAŞ tarafından işletilen Gün Öncesi Piyasasında (GÖP) Piyasa Takas Fiyatının (PTF) saatlik tahmini gerçekleştirilmiştir. Literatürde, Türkçe kaynaklar içinde elektrik piyasasında fiyat tahmini yapan çalışmalar incelendiğinde RF yöntemi ile PTF' yi tahmin eden bir tez çalışmasına rastlanılmamıştır. Bu yönüyle, Türkçe literatür için bir ilk olacak bu tez çalışması, bundan sonra yapılacak çalışmalarda ışık tutması beklenmektedir.

Uygulamada kullanılan 8760 gözlemlenmiş PTF verisinin zamana göre grafiği Şekil 3.1'de verilmiştir.



Şekil 3.1. Piyasa takas fiyatının (PTF) zamana göre grafiği

Şekil 3.1'de 1 Ocak 2019 saat 00:00 ile 31 Aralık 2019 saat 23:00 arasındaki saatlik PTF değerleri gösterilmektedir. Şekil incelendiğinde PTF, 0 ve 0 \$'a yakın seviyelere inmektedir.

genel olarak dalgalı bir seyir izlediği görülmektedir. Tez çalışmasında, PTF' nin Türk Lirası yerine Dolar olarak alınmasının nedeni döviz kurunda yaşanan dalgalanmaların etkilerini önleyerek tahmin başarısının düşürülmemesi amaçlanmıştır.

3.1. Uygulamada Kullanılacak Değişkenlerin Tanımı

Gerçek Zamanlı Üretim

Uygulamada, PTF'yi etkilediği düşünülen değişkenler ile gerek piyasa özelliklerinden gerekse de literatürden elde edilen bilgiler doğrultusunda PTF'nin tahmini gerçekleştirilmiştir. EPIAŞ tarafından Şeffaflık platformunda saatlik olarak ilan edilen gerçek zamanlı üretim miktarı ve lisanssız üretim miktarı PTF'nin tahmininde kullanılmıştır. Gerçek zamanlı üretim, elektrik üretiminde kullanılan kaynakların saatlik düzeyde gösterimidir. Bu kaynaklar arasında, doğalgaz, linyit, taş kömürü, akarsu, rüzgar, güneş, jeotermal, ithal kömür, fuel-oil, asfaltit kömürü, barajlı hidroelektrik santrali, biyokütle, nafta ve LNG gibi değişkenleri içermektedir. Lisanssız üretim miktarı ise YEKDEM (Yenilenebilir Enerji Kaynakları Destekleme Mekanizması) kapsamındaki lisanssız santrallerin kaynak düzeyinde saatlik elektrik üretim miktarı olup rüzgar, biyokütle, biyogaz ve güneş değişkenlerinden oluşmaktadır. Gerçek zamanlı üretim verisi içerisinde lisanssız elektrik üretim miktarı yer almadığından, bu iki veri toplanarak lisanssız elektrik üretimi dâhil gerçek zamanlı üretim (GZU) miktarı elde edilmiştir.

Eşleşme Miktarı

Öte yandan, EPIAŞ tarafından şeffaflık platformunda saatlik olarak ilan edilen eşleşme miktarı verisi kullanılarak PTF'nin tahmini gerçekleştirilmiştir. Eşleşme miktarı, GÖP' te eşleşen tekliflerin saatlik toplam miktarıdır. Eşleşen Alış Miktarı ve Eşleşen Satış Miktarı olarak iki alt başlıkta toplanmaktadır. Şekil 1.1'de gösterildiği üzere bu iki olgunun kesiştiği noktada saatlik PTF oluşmaktadır. Eşleşen alış miktarı verisi de PTF nin tahmininde kullanılan bir başka değişkendir.

PTF'nin Geçmiş Değerleri ve Mevsimler

PTF' nin tahmininde, yaygın olarak PTF'nin bir gün önceki, bir hafta önceki, iki hafta önceki, dört hafta ve bir yıl önceki geçmiş değerlerine yer verilerek günlük, haftalık, yıllık değişimleri yakalamak için kullanılmaktadır. Uygulamada, bu değerlere ek olarak

PTF'nin saatlik gecikmeli deęerlerinin de PTF'yi etkileyeceęinin dűşünűlmesi nedeniyle uygulamada, bir, iki ve űç saat ۆnceki deęerine ve yirmi iki ve yirmi űç saat ۆnceki deęerine yer verilmiřtir. Ayrıca mevsimsel kukla deęiřkenler tanımlanarak, PTF ۆzerindeki mevsim ۆzelliklerinin etkisi belirlenmek istenmiřtir [43].

Resmi Tatiller, Resmi ve Dini Bayram Gűnleri

Literatűrde, elektrik fiyat tahmini yapan alıřmalarda takvim ۆzelliklerine de yer verilmiřtir. Tatil ve bayram gűnleri, elektrik fiyatlarını etkilemektedir. Bu nedenle, uygulamada, resmi ve dini bayram tatil gűnlerine yer verilmiřtir. Ayrıca, uygulamada kullanılan bir dięer deęiřken olarak da haftaii ve haftasonu gűnleri belirten bir kukla deęiřken tanımlanmıřtır [36].

Elektrik fiyatını tahmin eden alıřmalar incelendięinde sıcaklık verisinin analize dāhil edildięi gűrűlműřtűr. Bu alıřmalarda, sıcaklık verisi, direkt bir bűlgenin sıcaklıęı veya űlke sıcaklık ortalaması gibi deęerler alınarak gerekleřtirilmiřtir. Gerek PTF' nin, Tűrkiye geneli fiyatı temsil etmesi (TR1), gerekse de iklim farklılıklarından dolayı bir bűlgenin veya bir řehrın sıcaklık deęerini almak daha sıcak veya daha soęuk bűlgenin etkisinin analizde yer verilmemesi, tahmin performansını dűřűrecek iin bu tez alıřması kapsamında sıcaklık deęerine yer verilmemiřtir. Ayrıca, bu gerekeye dayanarak dięer meteorolojik girdilerde modele dāhil edilmemiřtir.

Yapılan alıřmalarda, PTF tahmininde bir dięer girdi olarak da doęalgaz fiyatı kullanılmıřtır. Bu tez alıřmasında fiyat tahmininin saatlik frekansta gerekleřtirilecek olması, doęalgaz fiyatının saatlik dűzeyde verisinin olmaması ve aylık olarak aıklanan tarifenin saatlik dűzeyde kullanılması tahmin performansını dűřűrebilecek ii gerekesiyle modele dāhil edilmemiřtir.

PTF, gemiř ve gecikmeli deęerleri, eřleřme miktarı ve elektrik ۆretim miktarı verileri, piyasa iřletmecisi EPIAŐ'ın řeffaflık platformundan alınmıř olup veri seti 1 Ocak 2019 saat 00:00- 31 Aralık 2019 saat 23:00 dűneminin kapsayan saatlik frekansta toplam 8760 veriden oluřmaktadır. Uygulamada bir yılı kapsayan bir veri kullanılarak PTF'nin yıl ierisindeki seyirinin gűzlenmesi, mevsimler, hafta ii- haftasonu gűnler, tatil ve bayram gűnlerinin PTF ۆzerinde tam olarak etkisinin gűrűlebilmesi amalanmıřtır. Bu tez alıřmasında kullanılan deęiřkenler (girdiler) izelge 3.1'de verilmiřtir.

Çizelge 3.1. Uygulamada kullanılan girdiler (değişkenler)

Girdiler	Açıklama	Model 1,3,5	Model 2,4,6
ES	Eşleşme Miktarı (MWh)	○	●
GZU	Lisanssız elektrik üretim dahil gerçek zamanlı üretim (MWh)	●	○
D	Bir gün önceki aynı saate ilişkin PTF (\$)	●	●
W	Bir hafta önceki aynı saate ilişkin PTF (\$)	●	●
TW	İki hafta önceki aynı saate ilişkin PTF (\$)	●	●
M	Bir ay önceki aynı saate ilişkin PTF (\$)	●	●
Y	Bir yıl önceki aynı saate ilişkin PTF (\$)	●	●
H1	Bir saat önceki PTF (\$)	●	●
H2	İki saat önceki PTF (\$)	●	●
H3	Üç saat önceki PTF (\$)	●	●
H22	Yirmi iki saat önceki PTF (\$)	●	●
H23	Yirmi üç saat önceki PTF (\$)	●	●
Hafta	Hafta içi günler 1; hafta sonu günler 0	●	●
Tatil	Resmi ve dini tatil günleri 1; diğer günler 0	●	●
Kış	21 Aralık-20 Mart 1; diğer günler 0	●	●
İlkbahar	21 Mart- 20 Haziran 1; diğer günler 0	●	●
Yaz	21 Haziran-22 Eylül 1; diğer günler 0	●	●
Sonbahar	23 Eylül-20 Aralık 1; diğer günler 0	●	●

Çizelge 3.1 incelendiğinde, PTF'nin tahmininde kullanılan değişkenler ve oluşturulan modeller verilmiş olup tez kapsamında, altı farklı model kurulmuştur. Bu modeller, Model 1, Model 2, Model 3, Model 4, Model 5 ve Model 6 şeklinde isimlendirilmiştir. Modellere ilişkin açıklamalar şu şekildedir:

Model 1: GZU, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar girdileri kullanılarak YSA ile PTF'nin tahmin edildiği model,

Model 2: ES, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar girdileri kullanılarak YSA ile PTF'nin tahmin edildiği model,

Model 3: GZU, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar değişkenleri kullanılarak DVR ile PTF'nin tahmin edildiği model,

Model 4: ES, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar değişkenleri kullanılarak DVR ile PTF'nin tahmin edildiği model,

Model 5: GZU, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar değişkenleri kullanılarak RF ile PTF'nin tahmin edildiği model,

Model 6: ES, D, W, TW, M, Y, H1, H2, H3, H22, H23, Hafta, Tatil, Kış, İlkbahar, Yaz, Sonbahar değişkenleri kullanılarak RF ile PTF'nin tahmin edildiği model,

Veri seti

Uygulamada kullanılan veriler makine öğrenmesi yöntemlerinin bir geleneği olan eğitim ve test kümesi olmak üzere iki alt kümeye ayrılmıştır. Verinin %90'ı eğitim (train), %10'u ise test kümesine ayrılmıştır. 1 Ocak 2019 saat 00:00 ile 25 Kasım 2019 saat 11:00 arasındaki veriler eğitim kümesine ayrılırken, 25 Kasım 2019 saat 12:00 ile 31 Aralık 2020 saat 23:00 arasındaki veriler ise test kümesine ayrılmıştır. %90 gibi yüksek bir oranın eğitim kümesine ayrılmasının gerekçesi olarak eğitim sürecinde tüm mevsim etkilerinin modele tanıtılmak istemesi olarak belirlenmiştir. Böylelikle modelin tahmin performansının düşürülmemesi hedeflenmiştir. Davò ve arkadaşları [36] da çalışmalarında, takvim özelliklerinin tüm olasılıklarını kapsamak için bir yıllık bir dönemi eğitim kümesine ayırmışlardır. Öte yandan, %90 gibi bir oranın modelde oluşturabileceği olası aşırı öğrenme (overfitting) problemini önlemek adına çapraz doğrulama yönteminden yararlanılmıştır.

Çapraz doğrulama (CV), genellikle bir makine öğrenmesi yönteminin, eğitilmeyen veriler üzerinde tahmin performansını değerlendirmede kullanılan bir model değerlendirme yöntemidir. Modelin tahmin gücünü değerlendirmek için bağımsız bir veri kümesi kullanılmaktadır. CV, veri kümesinde algoritmayı eğitmek için veriyi belirli oranda bölerek eğitim kümesi oluşturmaktadır. Verinin geri kalan kısmı ise test kümesi olarak adlandırılmaktadır. CV, model oluştururken tüm verileri kullanmadığından, eğitim sırasında aşırı öğrenmeyi tespit etmek için yaygın şekilde kullanılan bir yöntemdir. Birçok CV tekniği kullanılmaktadır. Bunlardan en önemlileri k-katlı (k-fold) CV, leave one out CV'dir.

Bu çalışmada en yaygın olarak kullanılan k- katlı CV yöntemi kullanılmıştır. Burada k, 5 ya da 10 olarak önerilen bir sayı olup veri k bölüme ayrılmaktadır. N gözlem içeren bir veri kümesinde her kat yaklaşık N/k örneğine sahiptir. Bir alt küme doğrulama için kullanılırken, k-1 küme eğitim için kullanılmaktadır. Bu işlem k kez tekrarlanmaktadır. Böylelikle, her altküme doğrulama için bir kez kullanılmaktadır [114, 116].

Modellerin Karşılaştırılmasında Kullanılan Ölçütler

Tüm makine öğrenmesi algoritmalarının doğruluğu, problemin türüne göre ölçülmektedir. Sınıflandırma problemlerinde karışıklık matrisi kullanılırken, regresyon problemlerinde hata kareler ortalaması karekökü (RMSE), hata kareler ortalaması (MSE), ortalama mutlak hata (MAE), ortalama mutlak hata yüzdesi (MAPE) ve R^2 gibi ölçütler kullanılmaktadır. RMSE, tahmin edilen \hat{y}_i değerlerinde hata kareler ortalaması karekökü olup en önemli performans ölçütlerinden birisidir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3.1)$$

Denklem 3.1, modelin genel doğruluğunu ölçmekte olup makine öğrenmesi yöntemleri dahil modellerin tahmin performansının karşılaştırılmasında kullanılmaktadır.

Ortalama mutlak hata (MAE), bir modeli değerlendirmek için kullanılan en temel hata ölçütlerinden bir tanesidir. Direkt olarak artık hataların ilk farkından hesaplanmaktadır. MAE, mutlak hataların ortalamasıdır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.2)$$

Burada, f_i , tahmin, y_i ise gerçek değerdir. MAPE ise,

$$MAPE = \frac{\sum_{i=1}^N \frac{|e_t|}{Y_t}}{k} * 100 \quad (3.3)$$

formülü ile hesaplanmakta olup, tek tek yüzde hataların mutlak değerlerinin toplamı ile elde edilmektedir. e_t , t dönemindeki öngörü hatasını, Y_t , t dönemindeki gerçek değerler ve k tahmin dönemi içindeki öngörülen gözlemlerin sayısını göstermektedir [82, 112, 113, 118].

Verilerin Ölçeklendirilmesi

Ölçeklendirme, verilerde farklı birimler ortadan kaldırarak verilerin kolayca karşılaştırılmasına olanak sağlamaktadır. Birçok veri ölçeklendirme tekniği olmakla birlikte bunlardan bazıları şu şekildedir: Z-score normalleştirme, Min-Max normalleştirme, Sigmoidal veya Softmax normalleştirme ve temel bileşenler normalleştirme. Bu çalışmada iyi bir tahmin yapabilmek adına değişkenlere Min-Max normalleştirme tekniği uygulanarak [0,1] aralığında ölçeklendirilmiştir. Min-Max normalleştirme, verilerdeki tüm ilişkileri tam olarak koruma avantajına sahip olup herhangi bir sapma meydana getirmez. Ayrıca, ilgili değişkenin dağılım özellikleri de korunmaktadır. Min- Max normalleştirme ise şu şekildedir:

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.4)$$

Burada x_{min} ve x_{max} sırasıyla ilgili değişkenin aldığı en küçük ve en büyük değerleri göstermektedir. Kurulan modeller ile PTF'nin tahmin edilmesinin ardından tahmin değerlerinin gerçek değerlerle karşılaştırılması için veriler denormalize edilmiştir. [116, 119].

3.1. Yapay Sinir Ağı Uygulaması ve Sonuçları

YSA ile analiz gerçekleştirilirken R programında “neuralnet” paketinden yararlanılmıştır. “neuralnet”, bir çok uygulama için çok sayıda R kütüphanesi içeren “Comprehensive R Archive Network (CRAN)”ün bir parçasıdır. Neuralnet paketinin kullanılmasındaki amaç, öğrenme algoritması, aktivasyon ve çıktı aktivasyon fonksiyonu gibi kullanıcıya seçenek sunarak en iyi modelin belirlenmesinde katkı sağlamasıdır. [120].

Back-propagation (BP) algoritması, ileri beslemeli sinir ağlarını eğitmek için en sık kullanılan algoritmalarından biridir. Ancak, özellikle birden fazla gizli katmanı olan ağlar için yakınsama oranı yavaş ve aşırı öğrenmeye meyillidir. neuralnet paketinde üç gizli katmana kadar imkân tanınması dolayısıyla back-propagation algoritması kullanılmamıştır. Bu algoritma yerine, paket kapsamında yer alan öğrenme algoritması olarak 1993 yılında Martin Riedmiller ve Heinrich Braun tarafından önerilen resilient back-propagation (RPROP) algoritması kullanılmıştır. RPROP algoritması, ağırlık uzayının her bir boyutundaki kısmi türevlerin işaret sırasının davranışına göre her ağırlık için değerleri güncelleştiren uygulaması ve hesaplaması kolay bir yerel öğrenme algoritmasıdır. Riedmiller, RPOP algoritmasını tanıttıkları çalışmalarında, backpropagation algoritmasına göre yakınsama açısından 4 kat daha hızlı olduğu sonucuna ulaşmışlardır [121].

YSA'da en önemli aşamalardan birisi de gizli katmandaki nöron sayısının belirlenmesidir. “neuralnet” paketi kapsamında üç gizli katman seçeneği yer almaktadır. Literatür incelendiğinde, üçüncü gizli katmanın analize dahil edilmesinin model tahmin performansını azaltacağı ifade edildiğinden dolayı analizde yer verilmemiştir. Gizli katmandaki nöron sayısı belirlenmeden önce, girdi katmanındaki nöron sayısının belirlenmesi gerekmektedir. Bu anlamda, 3.1. başlığı altında ifade edildiği üzere, PTF'yi etkilediği düşünülen girdiler ve bu girdilerden oluşturulan modeller özetlenmiştir. YSA uygulamasında girdi katmanı olarak Model 1 ve Model 2 de yer alan girdiler ayrı ayrı olarak analiz edilmiştir. Buradan hareketle, çizelge 3.1 incelendiğinde her iki model içinde girdi katmanındaki nöron sayısı 17'dir. Öte yandan çıktı katmanı ise analizin amacına uygun olacak şekilde, bir başka deyişle PTF' nin saatlik tahmini olduğundan dolayı sadece PTF'den oluşmakta olup nöron sayısı 1 olarak belirlenmiştir. Her ne kadar girdi ve çıktı katmanı, gizli katman için önemli olsa da gizli katmandaki nöron sayısının belirlenmesinde kesinleşmiş bir kural bulunmamaktadır. Ancak, bazı çalışmalarda aşağıda verilen denklemden yararlanılarak gizli katmanda yer alabilecek en fazla nöron sayısı belirlenmektedir.

$$H_{max} = \sqrt{GKNS + ÇKNS} + 10 \quad (3.5)$$


Eşitlik 3.5’te, GKNS, gizli katmandaki nöron sayısını ve ÇKNS ise çıktı katmanındaki nöron sayısını temsil etmektedir. Ağı eğitirken kullanılacak olan gizli katmandaki en uygun nöron sayısını belirlemek için gizli katmanlarda 1’den H_{max} ’a kadar denemeler arasından en düşük RMSE değerine sahip gizli katman nöron ikilisi belirlenmiştir. Model 1 için ağı eğitimi için kullanılacak gizli katman nöron sayısı birleşimleri çizelge 3.2’de verilmiştir [122].

Çizelge 3.2. Model 1 için en iyi gizli katman nöron değerinin bulunması

Deneme No.	layer1	layer2	RMSE
1	1	0	0,081478
2	1	1	0,083973
3	1	2	0,083321
4	1	3	0,082496
5	1	4	0,083573
6	1	5	0,084776
7	1	6	0,082835
8	1	7	0,08359
9	1	8	0,084067
10	1	9	0,082654
		⋮	
97	7	0	0,082559
98*	7	1	0,080858
99	7	2	0,082292
100	7	3	0,083335
101	7	4	0,083369
102	7	5	0,083443
103	7	6	0,082359
104	7	7	0,083392
105	7	8	0,08268
106	7	9	0,083765
107	7	10	0,082701
108	7	11	0,082662
109	7	12	0,083243
110	7	13	0,083004
111	7	14	0,082454
112	7	15	0,082926

Çizelge 3.2’de Model 1 için ağı eğitmede kullanılacak gizli katmanlardaki en uygun nöron sayısı denemelerine ilişkin bir kısım gösterilmiştir. Eşitlik 3.5’ten hareketle gizli katmanda denenebilecek en fazla nöron sayısı belirlenmiş olup gizli katmanlarda en fazla 15 nörona kadar deneme gerçekleştirilmiştir. Bu kısımda özellikle ilk gizli katmanın 1’den 15’e kadar, ikinci gizli katmanın ise 0’dan 15 nörona kadar deneme yapılmasına

dikkat edilmiştir. Buradaki amaç ilgili katmanlardaki en uygun nöron sayısının belirlenmesinin yanı sıra ikinci gizli katmanın ağda yer verilip verilmemesinin belirlenmeye çalışılmasıdır. Toplamda $(15*16)=240$ farklı deneme yapılmış olup en iyi gizli katman ikilisi en düşük RMSE değerini veren ilk gizli katmanda 7 nöron, ikinci gizli katmanda ise 1 nöron yer alan denemede gerçekleşmiştir. Bu bakımdan dolayı, ikinci gizli katman Model 1'deki ağ yapısı için gerekli olup ağın eğitimi sürecine dahil edilmiştir. Şekil 3.2'de ise Çizelge 3.2'nin grafiksel gösterimi verilmiştir.



Şekil 3.2. Model 1 için en iyi gizli katman değerlerinin bulunması

Şekil 3.2, çizelge 3.2'nin grafiksel gösterimi olup yatay ekseninde ikinci gizli katman değerleri verilmektedir. Şekilde farklı renklerle ifade edilen çizgiler ise ilk gizli katmana aittir. Dikey ekseninde ise, RMSE değerleri yer almaktadır. Model 1 için en düşük RMSE değeri veren gizli katman nöron ikilisi (7,1) olarak belirlenmiştir.

Böylelikle Model 1 için ağ, 17 (Girdi katmanı)-7 (birinci gizli katman)-1 (ikinci gizli katman)-1 (çıkış katmanı) şeklinde iki gizli katmanlı ileri beslemeli ağ yapısı ele alınarak ilgili pakette sunulan farklı aktivasyon ve çıkış aktivasyon fonksiyon birleşimleri deneyerek eğitim kümesi tahmin edilmiştir. Sonuçlar, Çizelge 3.3'te özetlenmiştir.

Çizelge 3.3. Model 1 için eğitim kümesinin tahmini

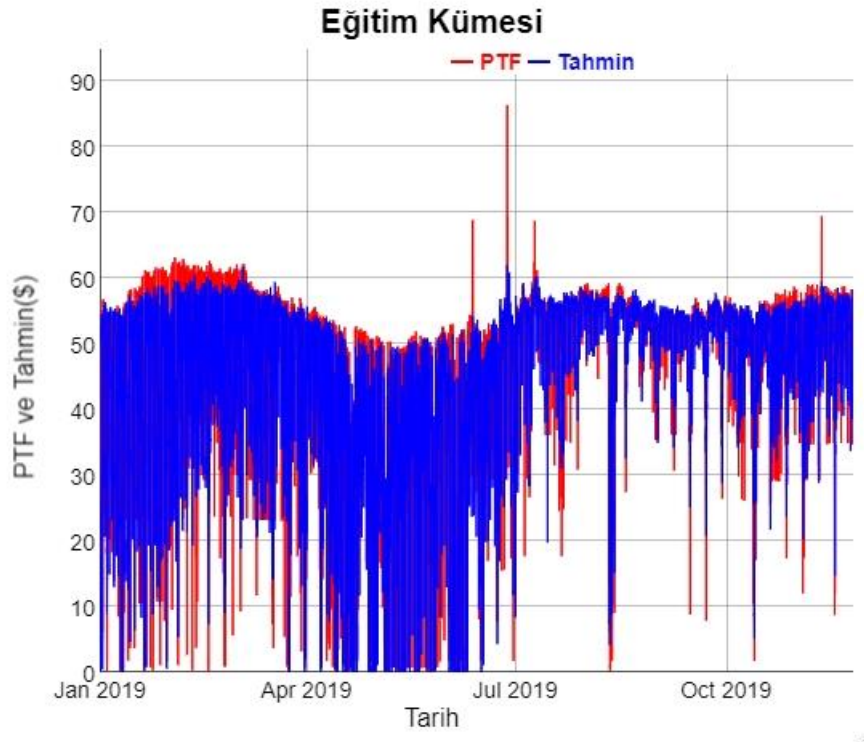
Algoritma	Aktivasyon	Çıktı akt. fonk.	MAE	MAPE	RMSE
rprop+	logistic	linear	0.05221	0.17561	0.08100
rprop+	logistic	non-linear	0.05307	0.15536	0.08076
rprop+	tanh	linear	0.05090	0.18391	0.07988
rprop+	tanh	non-linear	0.05150	0.16658	0.08031
rprop-	logistic	linear	0.05076	0.17406	0.07955
rprop-	logistic	non-linear	0.05336	0.15714	0.08120
rprop-	tanh	linear	0.05104	0.18820	0.07975
rprop-	tanh	non-linear	0.13756	0.26100	0.17740

Daha önceden ifade edildiği üzere, ağ “resilient propagation” algoritması ile eğitilmiş olup neuralnet paketi rprop+ ve rprop- şeklinde iki seçenek sunmaktadır. Öte yandan, aktivasyon fonksiyonu olarak lojistik fonksiyon (logistic) ve tanjant hiperbolik fonksiyonu, çıktı aktivasyon fonksiyonunda ise doğrusal ve doğrusal olmayan fonksiyon şeklinde seçenekler sunmaktadır. Nöron sayısının belirlenmesinin ardından tüm bu durumların farklı birleşimleri ile eğitim kümesi tahmin edilmiştir. Çizelge 3.3 incelendiğinde eğitim kümesinin tahmininde kullanılan farklı ağ yapısı denemelerinin tahmin performansları yer almaktadır. En iyi tahmin performansı, gizli katmanlarda en iyi nöron sayısının belirlenmesinde olduğu gibi RMSE kriterine göre belirlenmiştir. MAPE ve MAE kriterleri ise diğer modellerle tahmin performansının karşılaştırılmasında kullanılmıştır. Çizelge 3.3’ten eğitim kümesinde en iyi tahmin performansına sahip rprop- algoritmasıyla eğitilen ve lojistik aktivasyon fonksiyonu ve doğrusal çıktı aktivasyon fonksiyonuna sahip ağ yapısı olduğu belirlenmiştir. Çizelge 3.4’te test kümesinin tahmininde gerçekleştirilen farklı ağ yapısı denemelerin tahmin performansları yer almaktadır.

Çizelge 3.4. Model 1 için test kümesinin tahmini


Algoritma	Aktivasyon	Çıktı akt. fonk.	MAE	MAPE	RMSE
rprop+	logistic	linear	0.03132	0.06161	0.05397
rprop+	logistic	non-linear	0.03180	0.06295	0.05552
rprop+	tanh	linear	0.03145	0.06291	0.05445
rprop+	tanh	non-linear	0.03008	0.05969	0.05304
rprop-	logistic	linear	0.03004	0.05988	0.05262
rprop-	logistic	non-linear	0.03188	0.06213	0.05710
rprop-	tanh	linear	0.03146	0.06215	0.05371
rprop-	tanh	non-linear	0.11347	0.21528	0.12475

Çizelge 3.4 incelendiğinde eğitim kümesinde olduğu gibi en iyi tahmin performansına sahip ağ yapısı rprop-, lojistik aktivasyon fonksiyonu ve doğrusal aktivasyon çıktı fonksiyonu birleşimi vermiştir. Şekil 3.3'te Model 1'de en iyi ağ yapısı ile gerçekleştirilen eğitim kümesi tahmininin gerçek değerlerle karşılaştırılması grafiği verilmiştir.



Şekil 3.3. Model 1'de ki girdilerle gerçekleştirilen eğitim kümesinin tahmini

Şekil 3.3'te kırmızı çizgi ile gösterilen PTF değerleri, mavi çizgi ile gösterilen ise tahmin değerleridir. Şekilden, gerçek ve tahmin değerlerinin birbirine yakın olduğu gözlenmektedir. Ancak tahminin, kış mevsimi ve en düşük ve en yüksek değerlerde gerçek değerden uzak olduğu öte yandan ise dalgalanmaları iyi bir şekilde tahmin ettiği görülmektedir. Şekil 3.4'te Model 1'de en iyi ağ yapısı ile gerçekleştirilen test kümesinin tahmininin gerçek değerlerle karşılaştırılması grafiği verilmiştir.



Şekil 3.4. Model 1’de ki girdilerle gerçekleştirilen test kümesinin tahmini

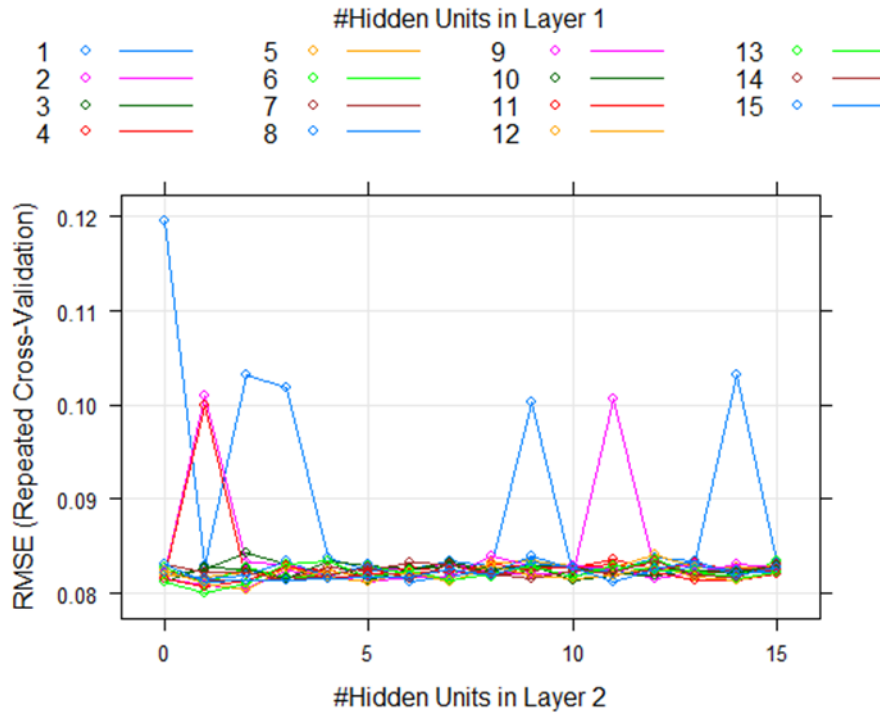
Şekil 3.4’te, kırmızı çizgi ile gösterilen PTF değerlerini, mavi çizgi ile gösterilen tahmin değerlerini göstermektedir. Şekilden, YSA ile gerçekleştirilen tahminin gerçek değerlerdeki dönüm noktalarını yakaladığı ve en düşük ve en yüksek gerçek değerler hariç tahmin hata miktarının düşük olduğu söylenebilir. Çizelge 3.5’te YSA ile gerçekleştirilen Model 2’nin ağ yapısındaki en iyi gizli katman nöron değerlerinin birleşimine ilişkin sonuçlar yer almaktadır.

Çizelge 3.5. Model 2 için en iyi gizli katman nöron birleşiminin bulunması

Deneme no.	layer1	layer2	RMSE
1	1	0	0,119582
2	1	1	0,08289
3	1	2	0,103218
4	1	3	0,101777
5	1	4	0,083784
6	1	5	0,082423
7	1	6	0,08266
8	1	7	0,083403
9	1	8	0,082944
10	1	9	0,100323
11	1	10	0,081905
12	1	11	0,082367
13	1	12	0,083701
14	1	13	0,08337
15	1	14	0,103273
16	1	15	0,083234
		⋮	
194*	13	1	0,080098
195	13	2	0,081047
196	13	3	0,08307
197	13	4	0,083511
198	13	5	0,081672
199	13	6	0,082391
200	13	7	0,081405
201	13	8	0,082032
202	13	9	0,082963
203	13	10	0,081798
204	13	11	0,082975
205	13	12	0,082377
206	13	13	0,082358
207	13	14	0,08163
208	13	15	0,08216

Çizelge 3.5'te Model 2 için ağı eğitmede kullanılacak gizli katmanlardaki en iyi nöron sayısının belirlenmesine ilişkin bir kısım gösterilmiştir. Eşitlik 3.5'ten yararlanarak gizli katmanda denenebilecek en fazla nöron sayısı belirlenmiş olup gizli katmanlarda en fazla 15 nörona kadar deneme gerçekleştirilmiştir. Bu kısımda özellikle ilk gizli katmanın 1'den 15'e kadar, ikinci gizli katmanın ise 0'dan 15 nörona kadar deneme yapılmasına dikkat edilmiştir. Buradaki amaç ilgili katmanlardaki en uygun nöron sayısının belirlenmesinin yanı sıra ikinci gizli katmanın modelde yer verilip verilmemesinin

belirlenmeye çalışılmıştır. Toplamda 240 (15*16) tane farklı deneme yapılmış olup en iyi gizli katman ikilisi en düşük RMSE değeri veren ilk gizli katmanda 13 nöron, ikinci gizli katmanda ise 1 nöron birleşimi vermiştir. Bu bakımdan dolayı, ikinci gizli katman Model 2’de ki ağ yapısı için gerekli olduğu belirlenmiş ve ağın eğitim sürecine dahil edilmiştir. Şekil 3.5’te ise Model 2’nin ağ yapısında nöron birleşimlerinin grafiği verilmiştir.



Şekil 3.5. Model 2 için gizli katman nöron denemelerinin tahmin performansı grafiği

Şekil 3.5, Çizelge 3.5’in grafiksel gösterimi olup yatay ekseninde ikinci gizli katman değerleri verilmektedir. Grafikte farklı renklerle ifade edilen çizgiler ise ilk gizli katman değerlerine aittir. Dikey ekseninde ise, RMSE değerleri yer almaktadır. Model 2 için en düşük RMSE değerini veren gizli katman nöron ikilisi (13,1) olarak belirlenmiştir.

Böylelikle Model 2 için 17-13-1-1 şeklinde iki gizli katmanlı ileri beslemeli ağ yapısı ele alınarak “neuralnet” paketinde sunulan farklı aktivasyon ve çıktı aktivasyon fonksiyonları ile eğitim kümesi tahmin edilmiştir.

Çizelge 3.6. Model 2 için eğitim kümesinin tahmini


Algoritma	Aktivasyon	Çıktı akt. fonk.	MAE	MAPE	RMSE
rprop+	logistic	linear	0,04825	0,1585	0,07673
rprop+	logistic	non-linear	0,05276	0,1555	0,08058
rprop+	tanh	linear	0.05109	0.1631	0.0791
rprop+	tanh	non-linear	0.13756	0.26098	0.17740
rprop-	logistic	linear	0.04699	0.15746	0.07564
rprop-	logistic	non-linear	0.05422	0.16374	0.08219
rprop-	tanh	linear	0.04885	0.15787	0.07640
rprop-	tanh	non-linear	0.13764	0.26124	0.17740

Çizelge 3.6’da Model 2 için eğitim kümesinde en iyi tahmin performansı ölçütüne sahip ağ yapısı rprop-, lojistik aktivasyon fonksiyonuna ve doğrusal aktivasyon çıktı fonksiyonunu oluşturan birleşim olmuştur. Çizelge 3.7’de test kümesinin tahmininde gerçekleştirilen farklı ağ yapısı denemelerin tahmin performansları yer almaktadır.

Çizelge 3.7. Model 2 için test kümesinin tahmini


Algoritma	Aktivasyon	Çıktı akt. fonk.	MAE	MAPE	RMSE
rprop+	logistic	linear	0,03033	0,06014	0,05219
rprop+	logistic	non-linear	0,02930	0,05840	0,05150
rprop+	tanh	linear	0.03165	0.06200	0.05502
rprop+	tanh	non-linear	0.11346	0.21526	0.12474
rprop-	logistic	linear	0.02993	0.05852	0.05122
rprop-	logistic	non-linear	0.03398	0.06768	0.06100
rprop-	tanh	linear	0.02938	0.05823	0.05188
rprop-	tanh	non-linear	0.11359	0.21560	0.12485

Çizelge 3.7 incelendiğinde, en iyi tahmin performans değerini en düşük RMSE değerine sahip rprop-, lojistik aktivasyon fonksiyonu ve doğrusal aktivasyon çıktı fonksiyonuna sahip birleşim vermiştir. Şekil 3.6’da en iyi ağ yapısı ile gerçekleştirilen eğitim kümesi tahmininin gerçek değerlerle karşılaştırılması grafiği verilmiştir.



Şekil 3.6. Model 2’de ki girdilerle gerekleřtirilen eđitim kúmesinin tahmin grafiđi

Şekil 3.6 incelendiđinde kırmızı ile PTF deđerleri, mavi ile tahmin deđerlerinin grafiđi gústerilmiřtir. Yapılan tahminin, gerek deđerlerdeki dalgalanma ve dúnúm noktalarıyla aynı yúnde gerekleřtiđi ve Model 1 ile gerekleřtirilen tahmine gúre daha bařarılı olduđu gúzlenmektedir. izelge 3.7’de ise Model 2’nin test kúmesinde gerekleřtirilen gerek ve tahmin deđerlerine ait grafik yer almaktadır.



Şekil 3.7. Model 2’deki girdilerle gerçekleştirilen test kümesinin tahmin grafiği

Şekil 3.7 incelendiğinde en iyi ağ yapısı ile gerçekleştirilen tahminin gerçek değerlere çok yakın olduğu ve çok yüksek ve çok düşük değerlerde Model 1’e göre hata miktarının azaldığı gözlenmektedir.

3.2. Destek Vektör Regresyonu Uygulaması ve Sonuçları

Bu tez çalışmasında, PTF’ nin tahmininde kullanılan yöntemlerden biri de uygulamalarda sıklıkla kullanılmakta olan “e1071” paketinden yararlanılarak gerçekleştirilen DVR yöntemidir. Uygulama regresyona dayandığı için paket kapsamında yer alan type seçeneği olarak “eps- regression” kullanılmıştır. Öte yandan, DVR için en iyi kernel tipinin belirlenmesi tahmin performansı açısından önem arz etmektedir. “e1071” paketinde doğrusal, radyal tabanlı, polinom ve sigmoid olmak üzere dört farklı kernel tipi seçeneği sunulmaktadır. En iyi kernel tipinin ve içeriğinde yer alan parametrelerin bulunabilmesi adına birçok deneme gerçekleştirilmiştir. Doğrusal kernelde cost ve epsilon parametreleri, radyal tabanlı kernelde cost, epsilon ve gamma parametreleri, sigmoid kernelinde cost, epsilon, gamma ve coef0 parametreleri, polinom kernelinde ise bu parametrelere ek olarak degree parametresi yer almaktadır. Her kernel, kendi

içerisinde en iyi parametrelerin belirlenmesi için farklı denemeler ile model eğitilmiştir. En iyi parametrelerin bulunması Bergsta ve Bengio tarafından önerilen rastgele arama (random search) yönteminin DVR' ye uygulanması ve 5-katlı çapraz doğrulama ile gerçekleştirilmiştir. cost parametresi 0.01 ile 100, epsilon parametresi 0.001 ile 1, gamma parametresi 0.001 ile 1, coef0 parametresi ise 0.001 ile 1 arasında değerlerle en iyi parametre değerleri bulunmaya çalışılmıştır. Model 3 ve Model 4'te Doğrusal kernel için 36, radyal tabanlı kernel için 180, sigmoid kerneli için 432, polinom kerneli için ise 880 farklı alt model denemesi gerçekleştirilmiştir. Bu şekilde, en iyi parametre değerleriyle model eğitilerek eğitim ve test kümesinin tahmini gerçekleştirilmiştir.

Model 3'te doğrusal kernel için cost=0.1 ve epsilon=0.25; radyal tabanlı kernel için cost=1, epsilon=0.1 ve polinom kerneli için cost=0.1, epsilon=0.1, gamma=0.1, degree=3 ve coef0=0.01 şeklinde ve sigmoid kernelinde ise cost=10, gamma=0.001, epsilon=0.25 ve c0=0.001 olacak şekilde en iyi parametre değerleri bulunmuştur. Çizelge 3.7'de bu parametre değerlerine sahip kernel tipleri ile eğitilen modelin eğitim kümesine ait tahmin performansları verilmiştir.

Çizelge 3.7. Model 3'te tahmin performansı sonuçları


Eğitim kümesi			
Kernel/Performans Kriteri	MAE	MAPE	RMSE
Radial (c=1, g=0,1, e=0,1)	0.03437	0.13787	0.06232
Linear(c=0.1,e=0.25)	0.05377	0.16555	0.08209
Polinom (c=0.1, g=0,1,e=0,1, d=3,c0=0.1)	0.04169	0.65457	0.07228
Sigmoid (c=10, g=0,001, e=0,25, c0=0,001)	0.05397	0.16346	0.08220
c=cost, e=epsilon, g=gamma, d=degree, c0=coef0			

Çizelge 3.7 incelendiğinde eğitilen modelin eğitim kümesinde en iyi tahmin performansına sahip kernel tipinin radyal tabanlı kernel olduğu görülmektedir. Çizelge 3.8'de test kümesinin tahmininde kernel tiplerinin tahmin performansları özetlenmiştir.

Çizelge 3.8. Model 3'te test kümesinin tahmin performansı


Test kümesi			
Kernel/Performans Kriteri	MAE	MAPE	RMSE
Radial (c=1, g=0,1, e=0,1)	0.03020	0.06092	0.05368
Linear(c=0.1,e=0.25)	0.03924	0.07388	0.05586
Polinom (c=0.1, g=0,1,e=0,1, d=3,c0=0.1)	0.02935	0.05968	0.05288
Sigmoid (c=10, g=0,001, e=0,25, c0=0,001)	0.03937	0.07410	0.05593
c=cost, e=epsilon, g=gamma, d=degree, c0=coef0			

Model 3'te ki girdiler ile eğitilen modelin test kümesinin tahmininde en iyi kernel tipinin eğitim kümesindeki aksine polinom kerneli olduğu tespit edilmiştir. Bu açıdan, eğitim kümesindeki tahmin performanslarının yanı sıra test kümesindeki tahmin performansının da araştırılması anlamlı olmuştur. Bu bakımdan test kümesinin tahmin performansı daha önemli olduğundan diğer yöntemlerle karşılaştırılırken polinom kernelinin tahmin performansı dikkate alınmıştır. Şekil 3.8'de Model 3 için polinom kerneli ile gerçekleştirilen eğitim kümesinin tahmin grafiği verilmiştir.



Şekil 3.8. Model 3 için eğitim kümesinin tahmin grafiği

Şekil 3.8 incelendiğinde PTF'nin gerçek değerleri kırmızı renk ile tahmini ise mavi renk ile gösterilmiştir. Tahmin değerlerinin gerçek değerlerdeki dalgalanmaları iyi bir şekilde tahmin ettiği ancak gerçek değerlerin aldıkları düşük değerleri tahmin etmede yetersiz kaldığı görülmektedir. Şekil 3.9'da ise Model 3 için test kümesine ilişkin gerçel ve tahmin değerleri karşılaştırılmıştır.



Şekil 3.9. Model 3 için test kümesinin tahmin grafiği

Şekil 3.9 incelendiğinde kırmızı ile PTF'nin gerçek değerleri mavi ile tahmin değerleri verilmiştir. Polinom kerneli ile gerçekleştirilen tahminin gerçek değerleri iyi bir şekilde tahmin ettiği ve dönüm noktalarını yakalamada başarılı olduğu ve böylelikle hata miktarının az olduğu görülmektedir. Çizelge 3.9'da Model 4 ile gerçekleştirilen en iyi kernel parametre değerleriyle yapılan tahmin performansları özetlenmiştir.

Çizelge 3.9. Model 4'te test kümesine ait tahmin performansı sonuçları


Eğitim kümesi			
Kernel/Performans Kriteri	MAE	MAPE	RMSE
Radial (c=100, g=0,01, e=0,125)	0.04001	0.15664	0.06884
Linear(c=0.1,e=0.25)	0.04990	0.21834	0.08515
Polinom (c=0.1, g=0,1,e=0,2, d=3,c0=0.1)	0.04453	0.23239	0.07168
Sigmoid (c=0.1, g=0,01, e=0,5, c0=0,001)	0.06236	0.17108	0.08670
c=cost, e=epsilon, g=gamma, d=degree, c0=coef0			

Çizelge 3.9 incelendiğinde en iyi parametre değerleri sahip kerneller ile eğitilen modelin eğitim kümesine ait tahmin performans değerleri yer almaktadır. En iyi tahmin performansına sahip kernel radyal tabanlı kernel olarak bulunmuştur. Çizelge 3.10'da en iyi kernel parametre değerleriyle yapılan tahmin performansları özetlenmiştir.

Çizelge 3.10. Model 4'te test kümesine ait tahmin performansı sonuçları


Test kümesi			
Kernel/Performans Kriteri	MAE	MAPE	RMSE
Radial (c=100, g=0,01, e=0,125)	0.02857	0.05730	0.05094
Linear(c=0.01,e=0.25)	0.02839	0.05979	0.05301
Polinom (c=0.1, g=0,1,e=0,2, d=3,c0=0.1)	0.03143	0.06311	0.05236
Sigmoid (c=0.1, g=0,01, e=0,5, c0=0,001)	0.04344	0.08058	0.05798
c=cost, e=epsilon, g=gamma, d=degree, c0=coef0			

Model 4'te en iyi parametre değerlerine sahip kerneller ile eğitilen modelin test kümesinin tahmininde en iyi tahmin performansına sahip kernel tipi radyal tabanlı kernel olduğu belirlenmiştir. Şekil 3.10'da ve Şekil 3.11'de sırasıyla eğitim ve test kümesinde radyal kerneli ile gerçekleştirilen tahmin değerlerinin gerçek değerler ile olan grafiği gösterilmektedir.



Şekil 3.10. Model 4 için eğitim kümesi tahmin grafiği

Şekil 3.10 incelendiğinde kırmızı ile PTF'nin gerçek değerleri, mavi ile tahmin değerleri gösterilmiştir. Tahmin değerlerinin PTF'deki dalgalanmaları iyi bir şekilde yakaladığı ancak düşük PTF değerlerini tahmin etmede yetersiz kaldığı görülmüştür. Şekil 3.12'de ise Model 4'ün test kümesinde gerçekleştirilen tahmin ve gerçek değerlerinin grafiği gösterilmiştir.



Şekil 3.11. Model 4 için test kümesi tahmin grafiği

Şekil 3.11 incelendiğinde Model 3’te yapılan test kümesinin tahminine göre PTF’yi daha iyi bir şekilde tahmin ettiği görülmektedir.

3.3. Rastgele Orman Uygulaması ve Sonuçları

RF yöntemi uygulaması için R programında “caret” ve “randomForest” paketlerinden yararlanılmıştır. Modellerin eğitiminde “caret” paketinden yararlanılmış olup 5- katlı çapraz doğrulama yöntemi ile doğrulaması gerçekleştirilmiştir. Böylelikle, aşırı öğrenme problemi önlenmesi hedeflenmiştir. PTF’yi en iyi açıklayan değişkenin grafiği çizdirilirken “randomForest” paketinden yararlanılmıştır.


RF yönteminin uygulandığı modelde en iyi parametrelerin belirlenmesi için birçok deneme gerçekleştirilmiştir. Bu modeller farklı mtry ve ntree parametrelerinin bileşiminden meydana gelmektedir. mtry parametresi, her bir düğümde rassal olarak örneklenen aday değişken sayısını ve ntree parametresi ise ormandaki ağaç sayısını göstermektedir. En iyi parametrelerin belirlenmesinde Grid Search yöntemiyle

gerçekleşmiştir. En iyi parametrelerinin elde edilmesiyle tahmin performansının hatasını en aza indirmek istenilmiştir. Bu nedenle, regresyon problemlerinde, mtry değeri, modelde girdi olarak kullanılan değişken sayısının üçte biri olarak belirlenmektedir. Uygulamada oluşturulan tüm modeller de girdi sayısı 17 olup mtry değeri normal şartlarda 5,67 değerine denk gelmektedir. Bu amaçla, mtry parametre değerinin belirlenmesi için 4 ile 6 arasında ntree parametresiyle denemeler oluşturularak alt modeller elde edilmiştir. ntree parametresi ise 400 ile 1000 arasında belirlenmiştir. Çizelge 3.11 incelendiğinde Model 5 için mtry ve ntree parametrelerinin birleşimlerinden oluşan tablo gösterilmektedir.

Çizelge 3.11. Model 5 için en iyi parametrelerin belirlenmesi

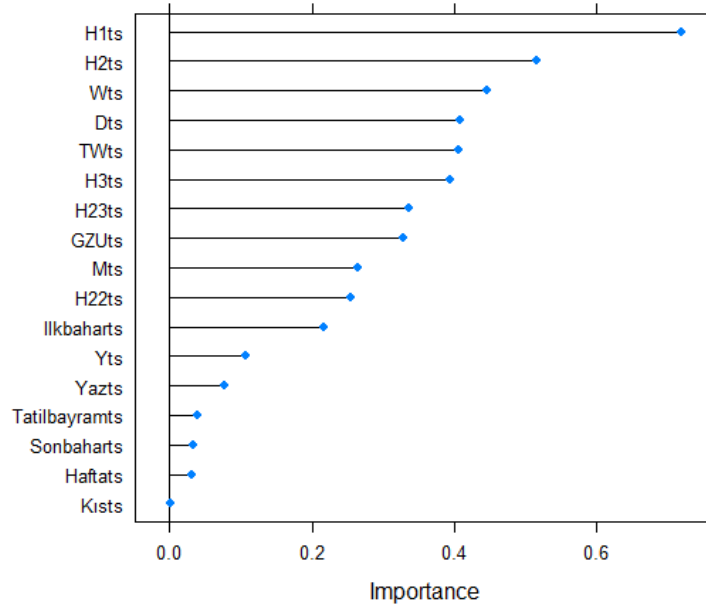
Deneme No.	mtry	ntree	RMSE
1	4	400	0,076046
2	4	500	0,076065
3*	4	600	0,075943
4	4	700	0,076013
5	4	800	0,076059
6	4	900	0,075977
7	4	1000	0,075967
8	5	400	0,076081
9	5	500	0,076015
10	5	600	0,07598
11	5	700	0,076007
12	5	800	0,075969
13	5	900	0,076038
14	5	1000	0,075994
15	6	400	0,076024
16	6	500	0,076139
17	6	600	0,076141
18	6	700	0,076078
19	6	800	0,076072
20	6	900	0,076097
21	6	1000	0,076088

Çizelge 3.11 incelendiğinde, en iyi parametrelerin belirlenmesinde RMSE kriterinden yararlanılmıştır. Burada, en düşük RMSE değerine sahip olan parametre birleşimi 3. denemede gerçekleşmiş olup mtry değeri 4, ntree değeri ise 600 olarak bulunmuştur. Şekil 3.12’de ise Çizelge 3.14’ün şekle dökülmüş hali gösterilmektedir.




Şekil 3.12. Model 5 için parametre değerlerinin tahmin performans grafiği

Şekil 3. 12’de görüldüğü üzere en iyi parametreler mtry için 4 ve ntree için ise 600 olduğu görülmektedir. Bu parametre değerleriyle eğitim kümesi ve test kümesi tahmin edilmiştir. Şekil 3.13’te Model 5’te PTF’yi açıklayan en önemli değişkenler sıralanmıştır.




Şekil 3.13. Model 5’te PTF için değişkenlerin önemlilik grafiği

Rastgele orman yöntemine özgü bir uygulama olan yanıt değişkenini en iyi açıklayan değişkenin gösterildiği Şekil 3.13’te PTF’yi en iyi açıklayan değişken bir saat önceki PTF değeridir. İkinci önemli değişken iki saat önceki PTF iken, PTF’yi en az açıklayan değişken ise Kış değişkenidir. Şekil 3.14 ve Şekil 3.15’te sırasıyla eğitim ve test kümelerinin tahmininin grafikleri yer almaktadır.



Şekil 3.14. Model 5 için eğitim kümesinin tahmin grafiği

Şekil 3.14 incelendiğinde, kırmızı ile PTF değerleri ve mavi ile tahmin değerlerinin grafiği verilmiştir. Model 5 ile gerçekleştirilen tahminin, PTF' yi iyi bir şekilde tahmin ettiği görülmektedir. Şekil 3.15'te ise test kümesinde Model 5 ile gerçekleştirilen tahminin grafiği verilmektedir.



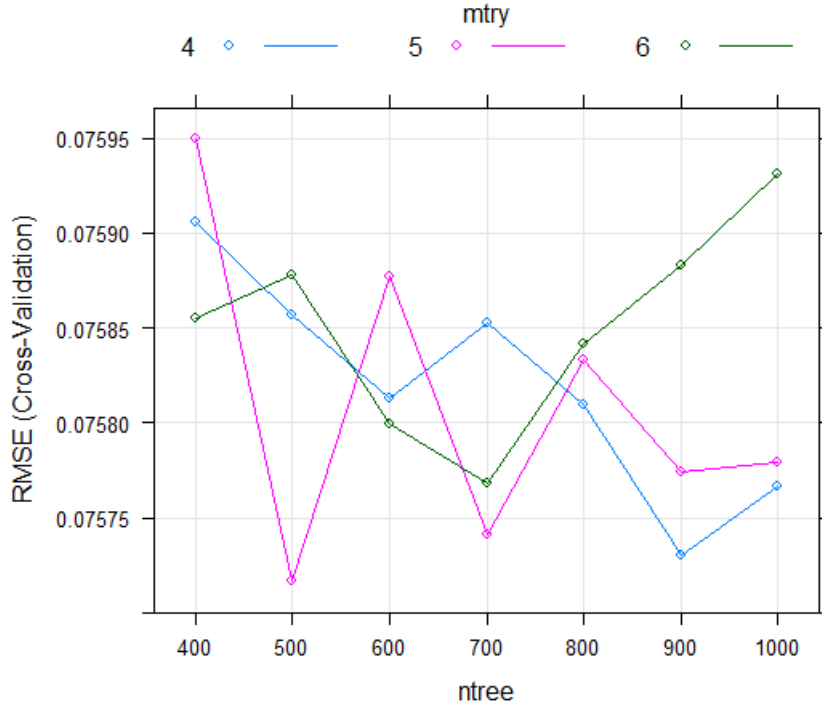
Şekil 3.15. Model 5 için test kümesinin tahmin grafiği

Şekil 3.15'te Model 5 ile gerçekleştirilen PTF'nin gerçek ve tahmin grafiği verilmektedir. Kırmızı ile PTF, mavi ile tahmin değerleri verilmiştir. Şekil incelendiğinde Model 5'in PTF'yi iyi bir şekilde tahmin ettiği görülmektedir. Çizelge 3.12'de ise Model 6 için model eğitiminde en iyi parametre değerlerinin belirlenmesinde farklı denemelerin performansları gösterilmiştir.

Çizelge 3.12. Model 6 için en iyi parametre değerlerinin belirlenmesi

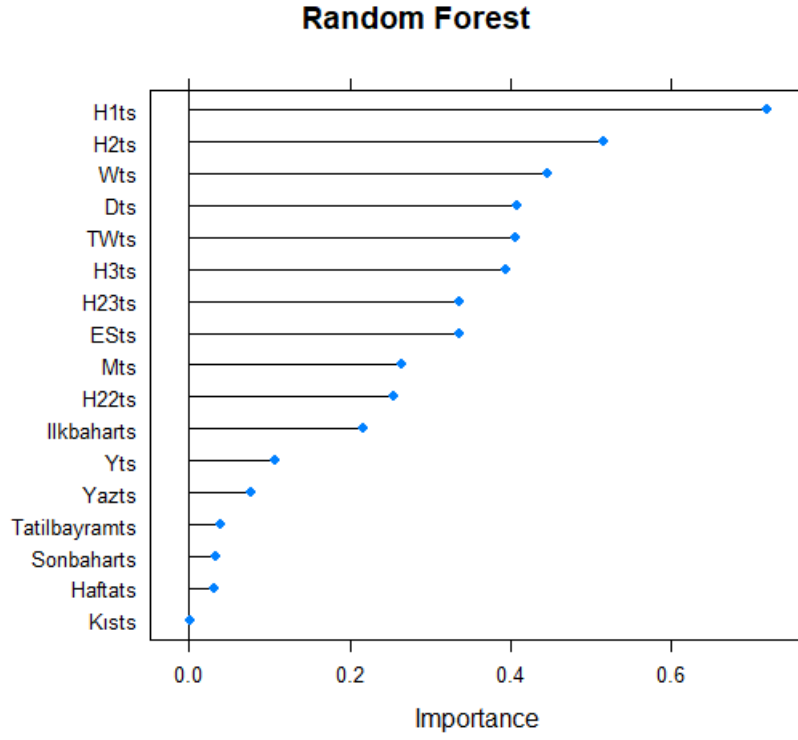
Deneme No.	mtry	ntree	RMSE
1	4	400	0,075906
2	4	500	0,075857
3	4	600	0,075813
4	4	700	0,075852
5	4	800	0,075809
6	4	900	0,07573
7	4	1000	0,075766
8	5	400	0,075949
9*	5	500	0,075716
10	5	600	0,075877
11	5	700	0,075742
12	5	800	0,075833
13	5	900	0,075774
14	5	1000	0,07578
15	6	400	0,075855
16	6	500	0,075878
17	6	600	0,0758
18	6	700	0,075768
19	6	800	0,075842
20	6	900	0,075883
21	6	1000	0,075931

Çizelge 3.12 incelendiğinde, model eğitmek için kullanılacak en iyi parametre değerlerini bulmak için RMSE kriterinden yararlanılmıştır. Burada, en düşük RMSE değerine sahip dokuzuncu deneme olup mtry değeri 5, ntree değeri ise 500 olarak bulunmuştur. Şekil 3.16’da çizelge 3.12’in şekle dökülmüş hali gösterilmektedir.




Şekil 3.16. Model 6 için en iyi parametre değerlerinin tahmin performansı

Şekil 3.16’da görüldüğü üzere en iyi parametreler mtry için 5 ve ntree için ise 500 olduğu görülmektedir. Bu parametre değerleriyle modelin eğitimi gerçekleştirilmiş ve eğitim ve test kümesi tahmin edilmiştir. Şekil 3.17’de Model 6’da PTF’ yi açıklayan en iyi girdiler gösterilmiştir




Şekil 3.17. Model 6’ de PTF için deęişkenlerin önemlilik grafięi

Şekil 3.17’de Model 6’da PTF’ yi en iyi açıklayan deęişken Model 1’de olduęu gibi bir saat önceki PTF deęeridir. İkinci önemli deęişken iki saat önceki PTF iken, PTF’yi en az açıklayan deęişken ise K1ş deęişkenidir. Şekil 3.18’de ve Şekil 3.19’da sırasıyla eğitim ve test kümelerinin tahmininin grafikleri yer almaktadır.



Şekil 3.18. Model 6 için eğitim kümesinin tahmin grafiđi

Şekil 3.18’de Model 6 ile gerçekleştirilen PTF’nin tahmin deđerleri ve gerçek deđerleri karşılaştırılmıştır. Kırmızı ile PTF ve mavi ile tahmin deđerleri gösterilmiştir. Şekil incelendiđinde Model 6’nın eğitim kümesini iyi bir şekilde tahmin ettiđi görölmektedir. Şekil 3.19’da ise Model 6 ile test kümesinin tahmin ve gerçek deđerlerinin karşılaştırılması grafiđi verilmiştir.



Şekil 3.19. Model 6 için test kümesinin tahmin grafiği

Şekil 3.19 incelendiğinde Model 6'nın test kümesini iyi bir şekilde tahmin ettiği ve PTF de ki dönüm noktalarını yakalamada başarılı olduğu görülmektedir.

4. SONUÇLAR VE ÖNERİLER

Son kırk yılda elektrik endüstrisinde büyük bir dönüşüm gerçekleşerek serbestleşmeye başlamıştır. Elektrik piyasasında varolan dikey bütünlük yapı ortadan kaldırılarak devletin rolü azaltılmaya çalışılmıştır. Piyasaya, özel sektör yatırımları dahil edilerek rekabetin artırılması ve piyasanın etkin olması amaçlanmıştır. Gün öncesi piyasasında, bir sonraki günün fiyatlarının bilinmesi, GÖP katılımcıları açısından büyük önem taşımaktadır. Katılımcılar, GÖP’te stratejilerini belirlemek için bir sonraki günün fiyatları bilmek isteyeceklerdir. Bu amaçla, doğru fiyat tahmini ve öngörüsü katılımcılar ve piyasa işletmecisine önemli bir gösterge olacaktır.

Bu tez çalışmasında, GÖP’te referans fiyat olarak kabul edilen PTF’nin makine öğrenmesi yöntemleriyle tahmini gerçekleştirilmiştir. Kullanılan yöntemler, öncelikle kendi içerisinde denemeler gerçekleştirilerek modelin eğitiminde en iyi parametre değerleri belirlenmiştir. Model eğitildikten sonra eğitim ve test kümesinin tahmini gerçekleştirilmiştir. PTF’yi tahmin eden yöntemlerin performansları MAE, MAPE ve RMSE ölçütleriyle değerlendirilmiştir. Çizelge 4.1 ve Çizelge 4.2’de sırasıyla eğitim ve test kümesinin tahmin performansları gösterilmiştir.

Çizelge 4.1. Eğitim kümesinde tahmin performansı sonuçları

Eğitim Kümesi						
Ölçüt/Model	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6**
MAE	0.05076	0.04699	0.04169	0.04001	0.01978	0.01924
MAPE	0.17406	0.15746	0.65457	0.15664	0.07911	0.07729
RMSE	0.07955	0.07564	0.07228	0.06884	0.03335	0.03271

Çizelge 4.1’de altı farklı model ile gerçekleştirilen eğitim kümesinin tahmin performansları karşılaştırılmıştır. Bu ölçütlerden her birinde en küçük değere sahip olan model tahmin performansı açısından en iyi model olduğu sonucuna varılmaktadır. Çizelge 4.1 incelendiğinde eğitim kümesi için en iyi tahmin, üç ölçüt içinde en düşük değere sahip Model 6 ile gerçekleştirilen tahmin olmuştur. Rastgele ormanın tahmin performansı bu çalışmada diğer kullanılan yöntemlere göre daha üstün olduğu belirlenmiştir. Eğitim kümesinde, PTF’ nin tahmininde en başarısız olan yöntem ise YSA


olmuştur. Özellikle ilk iki modelin tahmin başarısı da diğer modellere kıyasla düşüktür. Çizelge 4.2’de ise test kümesinin tahmin performansları verilmiştir.

Çizelge 4.2. Test kümesinde tahmin performansı sonuçları

Test Kümesi						
Ölçüt/Model	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6**
MAE	0.03004	0.02993	0.02935	0.02857	0.02754	0.02726
MAPE	0.05988	0.05852	0.05968	0.05730	0.05585	0.05545
RMSE	0.05262	0.05122	0.05288	0.05094	0.04967	0.00241

Çizelge 4.2’de, altı farklı model ile gerçekleştirilen test kümesinin tahmin performansları karşılaştırılmıştır. Çizelge 4.2 incelendiğinde, Model 6 ile gerçekleştirilen tahminin test kümesini en iyi tahmin eden model olduğu belirlenmiştir. Bir başka deyişle, eşleşme miktarının da girdi olarak içerisinde yer aldığı ve RF yöntemi ile gerçekleştirilen model PTF’yi diğer modellere göre daha iyi bir şekilde tahmin etmiştir.

Bu tez çalışmasının bir amacı da PTF’yi tahmin eden modellerden en iyi tahmin performansına sahip olan model ile PTF’nin 24 saatlik öngörüsünü yapmaktır. Elde edilen sonuçlardan hareketle PTF’yi açıklayan en iyi model, Model 6 olduğundan PTF nin öngörüsü bu model çerçevesinde gerçekleştirilmiştir. Şekil 4.1’de Model 6 ile gerçekleştirilen PTF’nin öngörü grafiği yer almaktadır.



Şekil 4.1. PTF'nin öngörüsü

Uygulamada, öngörü dönemi 1 Ocak 2020 tarihinde saat 00:00-23:00 saatleri arasında kapsamaktadır. Şekilde test kümesinin tahmini ve PTF'nin öngörüsü yer almaktadır. Şekilde boyalı bölge PTF'nin öngörü kısmını göstermektedir. Bu bölge incelendiğinde yapılan öngörünün test verisine uygunluğu dikkat çekmektedir. En düşük PTF öngörüsünün saat 04:00'de gerçekleştiği ve en yüksek PTF değeri öngörüsü ise saat 17:00'de gerçekleştiği gözlenmektedir. Yapılan öngörünün, tahmin değerlerine uyum gösterdiği ve bu anlamda yapılan öngörünün başarılı olduğu sonucuna varılmıştır.

Elektrik fiyat tahminine ilişkin çalışmalarda YSA yönteminin kullanıldığı görülmüştür. Bu tez çalışmasında da YSA yöntemine ek olarak DVR ve RF yöntemlerine de yer verilerek tahmin performansları birbirleriyle karşılaştırılmıştır. Böylelikle, hangi yöntemin PTF'yi daha iyi tahmin ettiği bulunmuştur. Özellikle, Türkçe literatürde, PTF tahmininde RF yöntemine rastlanılmaması bu tez çalışmasının literatüre önemli bir katkı yapacağını göstermektedir. Elde edilen bulgular dâhilinde, bundan sonra yapılacak çalışmalara ışık tutması beklenmektedir. Bu tez çalışması kapsamında yer almayıp, PTF'yi etkilediği düşünülen değişkenler ve farklı yöntemleri kullanılarak bu çalışma genişletilebilir.

5. KAYNAKLAR

- [1] S. Ben Amor, H. Boubaker, L. Belkacem, Forecasting electricity spot price for Nord Pool market with a hybrid k-factor GARMA–LLWNN model, *J. Forecast.* (2018).
- [2] J.P.S. Catalão, S.J.P.S. Mariano, V.M.F. Mendes, L.A.F.M. Ferreira, Application of neural networks on next-day electricity prices forecasting, in: 41st Int. Univ. Power Eng. Conf. UPEC 2006, Conf. Proceedings, 2006.
- [3] Q. Tang, D. Gu, Day-ahead electricity prices forecasting using artificial neural networks, in: 2009 Int. Conf. Artif. Intell. Comput. Intell. AICI 2009, 2009.
- [4] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, A.K. Srivastava, Electricity price forecasting for PJM day-ahead market, in: 2006 IEEE PES Power Syst. Conf. Expo. PSCE 2006 - Proc., 2006.
- [5] W. Sun, J. Zhang, Forecasting day ahead spot electricity prices based on GASVM, in: Proc. ICICSE 2008 - 2008 Int. Conf. Internet Comput. Sci. Eng., 2008.
- [6] S.S. Reddy, C.M. Jung, K.J. Seog, Day-ahead electricity price forecasting using back propagation neural networks and weighted least square technique, *Front. Energy.* (2016).
- [7] M. Mohandes, Support vector machines for short-term electrical load forecasting, *Int. J. Energy Res.* (2002).
- [8] J. Catalão, S. Mariano, V. Mendes, L. Ferreira, An artificial neural network approach for day-ahead electricity prices forecasting, *WSEAS Trans. Syst.* (2005).
- [9] J. Contreras, R. Espínola, F.J. Nogales, A.J. Conejo, ARIMA models to predict next-day electricity prices, *IEEE Trans. Power Syst.* (2003).
- [10] N. Amjady, Day-ahead price forecasting of electricity markets by a new fuzzy neural network, *IEEE Trans. Power Syst.* (2006).
- [11] B.R. Szkuta, Electricity price short-term forecasting using artificial neural networks, *IEEE Trans. Power Syst.* (1999).
- [12] F.E.H. Tay, L. Cao, Application of support vector machines in financial time series forecasting, *Omega.* (2001).
- [13] D.C. Sansom, T. Downs, T.K. Saha, Evaluation of support vector machine based forecasting tool in electricity price forecasting for Australian national electricity market participants, *J. Electr. Electron. Eng. Aust.* (2002).
- [14] K.J. Kim, Financial time series forecasting using support vector machines, *Neurocomputing.* (2003).
- [15] P.F. Pai, C.S. Lin, A hybrid ARIMA and support vector machines model in stock

- price forecasting, Omega. (2005).
- [16] R. Gareta, L.M. Romeo, A. Gil, Forecasting of electricity prices with neural networks, Energy Convers. Manag. (2006).
- [17] J.P.S. Catalão, S.J.P.S. Mariano, V.M.F. Mendes, L.A.F.M. Ferreira, An artificial neural network approach for short-term electricity prices forecasting, in: 2007 Int. Conf. Intell. Syst. Appl. to Power Syst. ISAP, 2007.
- [18] J.P.S. Catalão, S.J.P.S. Mariano, V.M.F. Mendes, L.A.F.M. Ferreira, Short-term electricity prices forecasting in a competitive market: A neural network approach, Electr. Power Syst. Res. (2007).
- [19] H.T. Pao, Forecasting electricity market pricing using artificial neural networks, Energy Convers. Manag. (2007).
- [20] J. Zhang, C. Cheng, Day-ahead electricity price forecasting using artificial intelligence, in: 2008 IEEE Electr. Power Energy Conf. - Energy Innov., 2008.
- [21] J. Li, J. Li, Next-day electricity price forecasting based on support vector machines and data mining technology, in: Proc. 27th Chinese Control Conf. CCC, 2008.
- [22] G.I.S. Ruas, T.A.C. Bragatto, M. V. Lamar, A.R. Aoki, S.M. De Rocco, Electrical energy demand prediction using artificial neural networks and support vector regression, in: 2008 3rd Int. Symp. Commun. Control. Signal Process. ISCCSP 2008, 2008.
- [23] N. Amjady, M. Hemmati, Day-ahead price forecasting of electricity markets by a hybrid intelligent system, Eur. Trans. Electr. Power. (2009).
- [24] J. Che, J. Wang, Short-term electricity prices forecasting based on support vector regression and Auto-regressive integrated moving average modeling, Energy Convers. Manag. (2010).
- [25] P. Areekul, T. Senjyu, H. Toyama, A. Yona, A hybrid ARIMA and neural network model for short-term price forecasting in deregulated market, IEEE Trans. Power Syst. (2010).
- [26] M.T. Tsai, C.H. Chen, An Artificial Neural Network Approach for short-term electric prices forecasting, in: Adv. Mater. Res., 2011.
- [27] D. Singhal, K.S. Swarup, Electricity price forecasting using artificial neural networks, Int. J. Electr. Power Energy Syst. (2011).
- [28] T. Jakaša, I. Andročec, P. Sprčić, Electricity price forecasting ARIMA model approach, in: 2011 8th Int. Conf. Eur. Energy Mark. EEM 11, 2011.
- [29] J. Zhang, Z. Tan, S. Yang, Day-ahead electricity price forecasting by a new hybrid method, Comput. Ind. Eng. (2012).
- [30] S. Anbazhagan, N. Kumarappan, A neural network approach to day-ahead deregulated electricity market prices classification, Electr. Power Syst. Res. (2012).

- [31] K.B. Sahay, M.M. Tripathi, Day ahead hourly load forecast of PJM electricity market and iso new england market by using artificial neural network, in: 2014 IEEE PES Innov. Smart Grid Technol. Conf. ISGT 2014, **2014**.
- [32] J. Mei, D. He, R. Harley, T. Habetler, G. Qu, A random forest method for real-time price forecasting in New York electricity market, in: IEEE Power Energy Soc. Gen. Meet., **2014**.
- [33] I.A.B.W.A. Razak, I.B.Z. Abidin, Y.K. Siah, T.K.B.A. Rahman, M.Y. Lada, A.N.B. Ramani, M.N.M. Nasir, A.B. Ahmad, Support vector machine for day ahead electricity price forecasting, in: AIP Conf. Proc., **2015**.
- [34] E. ADALI, Gün Öncesi Piyasasında Saatlik Ve Günlük Elektrik Fiyatları Tahmini, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Enerji Enstitüsü, İstanbul, **2015**
- [35] D. Saini, A. Saxena, R.C. Bansal, Electricity price forecasting by linear regression and SVM, in: 2016 Int. Conf. Recent Adv. Innov. Eng. ICRAIE 2016, **2016**.
- [36] F. Davò, M.T. Vespucci, A. Gelmini, P. Grisi, D. Ronzio, Forecasting Italian electricity market prices using a Neural Network and a Support Vector Regression, in: AEIT 2016 - Int. Annu. Conf. Sustain. Dev. Mediterr. Area, Energy ICT Networks Futur., **2016**
- [37] A. Dalgın, Yapay sinir ağları kullanılarak Türkiye gün öncesi piyasası elektrik fiyat tahmini, İstanbul Teknik Üniversitesi Enerji Enstitüsü, İstanbul, **2017**
- [38] J. Pokora, Hybrid arima and support vector regression in short-term electricity price forecasting, Acta Univ. Agric. Silvic. Mendelianae Brun. (**2017**).
- [39] G. Gao, K. Lo, F. Fan, Comparison of ARIMA and ANN Models Used in Electricity Price Forecasting for Power Market, Energy Power Eng. (**2017**).
- [40] H. Sangrody, N. Zhou, S. Tutun, B. Khorramdel, M. Motalleb, M. Sarailoo, Long term forecasting using machine learning methods, in: 2018 IEEE Power Energy Conf. Illinois, PECE 2018, **2018**.
- [41] A. González-Briones, G. Hernandez, J.M. Corchado, S. Omatu, M.S. Mohamad, Machine Learning Models for Electricity Consumption Forecasting: A Review, in: 2nd Int. Conf. Comput. Appl. Inf. Secur. ICCAIS 2019, **2019**.
- [42] X.S. Yang, Introduction to Algorithms for Data Mining and Machine Learning, **2019**.
- [43] C.C. Aggarwal, Data Mining: The Textbook, **2015**.
- [44] A.C. Müller, S. Guido, Introduction to Machine Learning with Python: a guide for data scientists, **2016**.
- [45] A. Géron, Hands-on machine learning with Scikit-Learn and TensorFlow : concepts, tools, and techniques to build intelligent systems, **2017**.
- [46] P.H. Kuo, C.J. Huang, A high precision artificial neural networks model for short-Term energy load forecasting, Energies. (**2018**).

- [47] K.C. Luk, J.E. Ball, A. Sharma, An application of artificial neural networks for rainfall forecasting, Math. Comput. Model. (2001).
- [48] C. Albon, Python Machine learning Cookbook: Practical Solutions from preprocessing to deep learning, 2018.
- [49] J. Han, M. Kamber, Data Mining: Concepts and Techniques (2nd edition), 2006.
- [50] R. Gholami, N. Fakhari, Support Vector Machine: Principles, Parameters, and Applications, in: Handb. Neural Comput., 2017.
- [51] O. E. Mojolaoluwa, Forecasting Electricity Prices In The Swedish Regulation Market Using Random Forest, Lappeenranta University of Technology School of Engineering Science, Yüksek Lisans Tezi, Lappeenranta, 2018
- [52] B. Singh, P. Sihag, K. Singh, Modelling of impact of water quality on infiltration rate of soil by random forest regression, Model. Earth Syst. Environ. (2017).
- [53] W. M. Saslow, Electricity, Magnetism, and Light, 2002.
- [54] TDK, Kehribarın anlamı, <https://sozluk.gov.tr/> (Erişim tarihi: 9 Mart 2020).
- [55] C. Harris, Electricity Markets: Pricing, Structures and Economics., 2006.
- [56] Anonim, EPEX About, 2018 annual report, <https://www.epexspot.com/en/downloads> (Erişim tarihi: 20 Mart 2020).
- [57] Anonim. TETAŞ 2014 yılı sektör raporu, Türkiye Elektrik Ticaret ve Taahhüt A.Ş. Genel Müdürlüğü, Mayıs 2015.
- [58] TEİAŞ, TEİAŞ kuruluş ve tarihçe <https://www.teias.gov.tr/tr-TR/kurulus-ve-tarihce> (Erişim Tarihi: 18 Mart 2020).
- [59] EPIAŞ, EPIAŞ hakkında, <https://www.epias.com.tr/epias> kurumsal/hakkimizda/ (Erişim Tarihi: 18 Mart 2020).
- [60] Resmi Gazete, Elektrik Piyasası Kanunu (2013), <https://www.resmigazete.gov.tr/> (Erişim Tarihi: 18 Mart 2020).
- [61] Mevzuat, Elektrik Piyasası Dengeleme Ve Uzlaştırma Yönetmeliği (2009), <https://www.epias.com.tr/mevzuat/dengeleme-ve-uzlastirma-yonetmeliği> (Erişim Tarihi: 19 Mart 2020).
- [62] EPIAŞ, GÖP süreci, <https://www.epias.com.tr/gun-oncesi-piyasasi/surecler/> (Erişim Tarihi: 19 Mart 2020).
- [63] EPIAŞ, GÖP kullanıcı kılavuzu, <https://www.epias.com.tr/gun-oncesi-piyasasi/gop-kullanici-kilavuzu/> (Erişim Tarihi: 19 Mart 2020).

- [64] EPIAŞ, Piyasa Takas Fiyatı Belirleme Yöntemi (2016), <https://www.epias.com.tr/gun-oncesi-piyasasi/eslestirme> (Erişim Tarihi: **29 Mart 2020**).
- [65] EPIAŞ, Piyasa Takas Fiyatının oluşumu, <https://seffaflik.epias.com.tr/transparency/piyasalar/gop/arz-talep.xhtml>, (Erişim Tarihi: **29 Mart 2020**).
- [65] R. Weron, Modeling and forecasting electricity loads and prices: A statistical approach, **2006**.
- [66] F.P. Sioshansi, W. Pfaffenberger, Why Restructure Electricity Markets?, in: Electr. Mark. Reform, **2006**.
- [67] D. Newbery, Electricity Liberalization in Britain and the Evolution of Market Design, in: Electr. Mark. Reform, **2006**.
- [68] K. Mayer, S. Trück, Electricity markets around the world, J. Commod. Mark. (**2018**).
- [69] EPEX, EPEX About, <https://www.epexspot.com/en/about> , (Erişim Tarihi: **20 Mart 2020**).
- [70] EPEX, EPEX About, Facts and Figures, <https://www.epexspot.com/en/downloads> (Erişim Tarihi: **20 Mart 2020**).
- [71] O. Knapik, Essays on econometric modeling and forecasting of electricity prices, Doktora Tezi, Aarhus University School Of Business and Social Science, Aarhus, **2016**.
- [72] A. Valenciano, M. Bozorg, F. Sossan, M. Paolone, An econometric model of the regulating power price for interconnected power systems: The case of the nord pool market, in: Int. Conf. Eur. Energy Mark. EEM, **2018**.
- [73] J. Korpiahkola, Forecasting Nord Pool's Day-ahead hourly spot prices in Finland, Degree Programme in Information and Communication Technology, Lisans Tezi, **2019**.
- [74] J.K. Kolberg, K. Waage, Artificial Intelligence and Nord Pool's Intraday Electricity Market Elbas: A Demonstration and Pragmatic Evaluation of Employing Deep Learning for Price Prediction, Norwegian School Of Economics, Economics and Business Administration, Yüksek Lisans Tezi, Bergen, **2018**.
- [75] J. Antonanzas, D. Pozo-Vázquez, L.A. Fernandez-Jimenez, F.J. Martinez-de-Pison, The value of day-ahead forecasting for photovoltaics in the Spanish electricity market, Sol. Energy. (**2017**).
- [76] MIBEL, İberya Elektrik Piyasası hakkında, https://www.mibel.com/en/home_en/ (Erişim Tarihi: **20 Mart 2020**).
- [77] C. Geidel, H. Zareipour, Price forecasting in the Spanish day-ahead electricity market using preconditioned wind power information, in: Proc. – 2013 12th Int. Conf. Mach. Learn. Appl. ICMLA 2013, **2013**.

- [78] I. Pavic, M. Beus, H. Pandzic, T. Capuder, I. Stritof, Electricity markets overview - Market participation possibilities for renewable and distributed energy resources, in: Int. Conf. Eur. Energy Mark. EEM, **2017**.
- [79] F. Chollet, Deep learning with R, Deep Learn. Using R. (2017).
- [80] The Editors of Encyclopaedia Britannica, Learning, <https://www.britannica.com/science/learning>, (Erişim tarihi: **21 Mart 2020**).
- [81] J. Patterson, A. Gibson, Deep learning: A practitioner's approach, **2017**.
- [82] K. Ramasubramanian, A. Singh, Machine Learning Using R: With Time Series and Industry-Based Use Cases in R, **2017**.
- [83] A. Geron, Hands-On Machine Learning With Scikit-Learn & Tensor Flow, **2017**.
- [84] P. Harrington, Machine Learning in Action, **2012**.
- [85] H. Brink, J.W. Richards, M. Fetherolf, Real-World Machine Learning, **2017**
- [86] D.J. Livingstone, Artificial neural networks. Methods and applications. Preface., Methods Mol. Biol. (**2008**).
- [87] I.N. da Silva, D.H. Spatti, R.A. Flauzino, L.H.B. Liboni, S.F. dos Reis Alves, Artificial neural networks: A practical course, **2016**.
- [88] S. Haykin, Neural Networks and Learning Machines, **2008**.
- [89] J.M. Zurada, Introduction to Artificial Neural systems, **1992**.
- [90] N. Yadav, A. Yadav, M. Kumar, An Introduction to Neural Network Methods for Differential Equations, SpringerBriefs Appl. Sci. Technol. (**2015**).
- [91] P. Metallurgy, Exploratory analysis of Metallurgical process data with neural networks and related methods, **2002**.
- [92] K. Ramasubramanian, A. Singh, Machine Learning Using R: With Time Series and Industry-Based Use Cases in R, **2017**.
- [93] A. Hajian, P. Styles, Application of Soft Computing and Intelligent Methods in Geophysics, **2018**.
- [94] A.K. Jain, J. Mao, K.M. Mohiuddin, Artificial neural networks: A tutorial, Computer (Long. Beach. Calif). (**1996**).
- [95] G. Santamaría-Bonfil, J. Frausto-Solís, I. Vázquez-Rodarte, Volatility Forecasting Using Support Vector Regression and a Hybrid Genetic Algorithm, Comput. Econ. (**2013**).
- [96] S. Marsland, Machine learning: An algorithmic perspective, **2014**.
- [97] W. Lee, Python® Machine Learning, **2019**.
- [98] G.Y. Wiederschain, Data mining techniques for the life sciences: (Olivero Carugo and Frank Eisenhaber (eds.), in Series "Springer Protocols. Methods in Molecular Biology", Vol. 609, Humana Press, 2010, 407 p., \$110), Biochem. (**2011**).

- [99] C. Gao, E. Bompard, R. Napoli, H. Cheng, Price forecast in the competitive electricity market by support vector machine, *Phys. A Stat. Mech. Its Appl.* (2007).
- [100] A.J. Smola, B. Schölkopf, A tutorial on support vector regression, *Stat. Comput.* (2004).
- [101] D. Wang, M. Wang, X. Qiao, Support vector machines regression and modeling of greenhouse environment, *Comput. Electron. Agric.* (2009).
- [102] S. R. Gunn, Support Vector Machines for Classification and Regression, Technical Report, University of Southampton, 1998.
- [103] G. James, D. Witten, T. Hastie, R. Tibshirani, An Introduction to Statistical Learning with Applications in R, 2013.
- [104] S. D. Sawarkar, A. A. Ghatol, A. P. Pande, Neural Network Aided Breast Cancer Detection and Diagnosis Using Support Vector Machine, Proceedings of the 7th WSEAS International Conference on Neural Networks, June 12-14, Cavtat, Croatia, (2006).
- [105] M. Akın, İstatistiksel Öğrenme Teknikleri, 2017.
- [106] S. Rajasekaran, S. Gayathri, T.L. Lee, Support vector regression methodology for storm surge predictions, *Ocean Eng.* (2008).
- [107] D. Basak, S. Pal, and C. Patranabis, Support Vector Regression: Neural Information Processing – Letters and Reviews, 11 (2007) 10,
- [108] G. Santamaría-Bonfil, J. Frausto-Solís, I. Vázquez-Rodarte, Volatility Forecasting Using Support Vector Regression and a Hybrid Genetic Algorithm, *Comput. Econ.* (2013).
- [109] N. Deng, Y. Tian, C. Zhang, Support vector machines: Optimization based theory, algorithms, and extensions, 2012.
- [110] B. Schölkopf, Learning with kernels, in: Proc. 2002 Int. Conf. Mach. Learn. Cybern., 2002.
- [111] N. Cristianini, J. Shawe-Taylor, An Introduction to Support Vector Machines and Other Kernel-based Learning Methods, 2000.
- [112] P.B. and A. Bruce, Practical Statistics for Data Scientists: 50 Essential Concepts, 2017.
- [113] P. Dangeti, Statistics for Machine Learning: Techniques for exploring supervised, unsupervised, and reinforcement learning models with Python and R, 2017.
- [114] The Editors of Encyclopaedia Britannica, Yirmi Soru oyunu, <https://www.britannica.com/topic/twenty-questions> (Erişim Tarihi:4 Nisan 2020)
- [115] L. Breiman, Random forests, *Mach. Learn.* (2001).
- [116] G. Ciaburro, Regression Analysis with R, 2018.
- [117] M. Beyeler, Machine Learning for OpenCV, 2017.

- [118] I. Akgül, Geleneksel Zaman Serisi Yöntemleri, **2003**.
- [119] K.L. Priddy, Artificial Neural Networks: An Introduction, **2005**.
- [120] S. Fritsch, F. Guenther, Package ‘neuralnet’, <https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>, (Erişim Tarihi:**13 Haziran 2020**).
- [121] M. Riedmiller, H. Braun, A direct adaptive method for faster backpropagation learning: The Rprop algorithm. In {IEEE} International Conference On Neural Networks, IEEE Int. Conf. Neural Networks. (1993).
- [122] N. M. Esenyel, Döviz Kurunun Tahmin Edilmesinde İstatistiksel Yöntemlerin Karşılaştırmalı Analizi, İstanbul Üniversitesi, Yüksek Lisans Tezi, İstanbul, **2016**.