T.C.
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

BAZI VERİ MADENCİLİĞİ YÖNTEMLERİ İLE ELEKTRİK TÜKETİM TAHMİNİ

Mustafa YILDIRIM

ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI

ŞANLIURFA
2021

Dr. Öğretim Üyesi Ahmet Sabri Öğütlü danışmanlığında, Mustafa YILDIRIM'ın hazırladığı "Bazı Veri Madenciliği Yöntemleri ile Elektrik Tüketim Tahmini" konulu bu çalışma 01/06/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile Harran Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS olarak kabul edilmiştir.

İmza

Danışman **: Dr. Ahmet Sabri Öğütlü**

Üye **: Doç. Dr. Engin TAŞ**

Üye **: Doç. Dr. Gencay Sarıışık**

Endüstri Mühendisliği Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.

Doç. Dr. İsmail HİLALİ
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

Sayfa No

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER VE KISALTMALAR DİZİNİ vi
1.GİRİŞ 1
2.ÖNCEKİ ÇALIŞMALAR 5
3.MATERYAL ve YÖNTEM 11
3.1. Materyal 11
3.1.1. Makine Öğrenme Algoritmaları ile Elektrik Tüketim Tahmini 11
3.1.2. Kullanılan Makine Öğrenme Algoritmaları 13
3.1.2.1. Yapay sinir ağları 13
3.1.2.1.1. Sinir hücrelerinin yapısı 14
3.1.2.1.1.1. Biyolojik sinir hücreleri 14
3.1.2.1.1.2. Yapay sinir hücreleri 15
3.1.2.1.2. Yapay sinir ağlarının yapısı 18
3.1.2.1.3. Yapay sinir ağlarında öğrenme stratejileri 20
3.1.2.1.4. Yapay sinir ağlarında öğrenme kuralları 22
3.1.2.1.4.1. Hebb öğrenme kuralı 22
3.1.2.1.4.2. Perceptron öğrenme kuralı 23
3.1.2.1.4.3. Delta öğrenme kuralı 23
3.1.2.1.4.4. Kohonen öğrenme kuralı 25
3.1.2.1.5. Yapay sinir ağı modelleri 25
3.1.2.1.5.1. Adaptif rezonans teorisi 26
3.1.2.1.5.2. Hopfield ağı 27
3.1.2.1.5.3. Kohenen ağı (SOM) 28
3.1.2.1.5.4. Sayaçlı yayılım ağı 29
3.1.2.1.5.5 Çok katmanlı algılayıcı 30
3.1.2.1.5.5.1. Genelleştirilmiş delta kuralının türetilmesi 30
3.1.2.1.5.5.2. Öğrenme katsayısı 33
3.1.2.1.5.5.3. Momentum terimi 34
3.1.2.2 Karar Ağacı 35
3.1.2.2.1 Bilgi Kazancı 37
3.1.2.2.2 Karar ağacı algoritma türleri 41
3.1.2.3 Destek Vektör Makineleri 43
3.1.2.3.1 Doğrusal destek vektör makineleri 44
3.1.2.3.1.1 Doğrusal ayrılabilme durumu 46
3.1.2.3.1.2 Doğrusal ayrılamama durumu 48
3.1.2.3.2 Doğrusal olmayan destek vektör makineleri 49
3.1.2.3.3 Çok sınıflı destek vektör makineleri 52
3.1.2.3.3.1 İkili sınıflar halinde sınıflandırmalarla çalıştırmak 52
3.1.3. Veri Madenciliği Algoritmalarında Performans Ölçümü 54
3.1.3.1. Ortalama Mutlak Hata (Mean Absolute Error [MAE]) 54

3.1.3.2. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error [MAPE]) ...55
3.1.3.3. Hata Kareler Ortalaması (Mean Squared Error [MSE])....56
3.1.3.4. Hata Kareler Ortalamasının Karekökü(Root Mean Square Error [RMSE])....56
3.2. Yöntem....57
3.2.1. Türkiye de Elektrik Tüketimini Etkileyen Faktörler....57
3.2.1.1. İhracat....58
3.2.1.2. İthalat....59
3.2.1.3. Türkiye Sanayi Üretim Endeksi....60
3.2.1.4. Nüfus....60
3.2.1.5. Sıcaklık....61
3.2.1.6. Yağış....62
3.2.1.7. Rastgele Değişkenler....63
3.2.1.8. Elektrik Tüketimi....63
3.2.2. Rapid Miner da Modelin hazırlanması süreci....65
3.2.3. Rapid Miner da Hazırlanan Modellere ait Parametrelerinin Belirlenmesi....67
3.2.3.1. Yapay Sinir Ağları (YSA)....67
3.2.3.2. Karar Ağacı (KA)....68
3.2.3.3. Destek Vektör Makineleri (DVM)....69
4.ARAŞTIRMA BULGULARI ve TARTIŞMA....70
4.1. Yapay Sinir Ağları (YSA) Algoritması ile Elektrik Tüketim Tahminlemesi....70
4.2. Karar Ağacı Algoritması (KA) ile Elektrik Tüketim Tahminlemesi....71
4.3. Destek Vektör Makineleri (DVM) Algoritması ile Elektrik Tüketim Tahminlemesi....71
4.4. 3 Algoritmaya ait Modellerin Değerlendirilmesi....72
5.SONUÇLAR ve ÖNERİLER....74
5.1. Sonuçlar....74
5.2. Öneriler....74
KAYNAKLAR....75
ÖZGEÇMİŞ....80

ÖZET

Yüksek Lisans Tezi

BAZI VERİ MADENCİLİĞİ YÖNTEMLERİ İLE ELEKTRİK TÜKETİM TAHMİNİ

Mustafa YILDIRIM

Harran Üniversitesi
Fen bilimleri Enstitüsü
Endüstri Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğretim Üyesi Ahmet Sabri ÖĞÜTLÜ
Yıl:2021, Sayfa: 80

Yıllar geçtikçe Türkiye de nüfus artmakta, sanayi gelişmekte ve yaşamın her alanında yüksek teknoloji araçlarının kullanımı enerji ihtiyacına olan talebi her geçen gün daha çok arttırmaktadır. Ülkemizde kullanılan başlıca enerji türü elektrik enerjisidir. Elektrik enerjisinin önemli bir kısmı fosil yakıtlardan elde edilmektedir. Fosil kökenli enerji kaynaklarının her geçen gün azaldığı dünyamızda elektriğin depolanamaması, elektriğin üretildiği an tüketilmesi gerekliliği gibi kısıtların olduğu gerçeği, arz talep dengesi dikkate alınarak elektrik üretim faaliyetlerinin yürütülmesi ve tüketim miktarına göre planlama yapılmasının önemini her geçen gün arttırmaktadır. Zira kullanılan elektriğin sürdürülebilirliği sağlıklı bir planlamaya o da dolayısıyla kaliteli bir tahmine bağlıdır. Bu çalışmada, Türkiye'nin elektrik tüketimi, ithalat, ihracat, Türkiye sanayi üretim endeksi gibi ekonomik değişkenler, nüfus, sıcaklık, yağış gibi parametreler bir arada kullanılarak aylık baz da tahmin edilmeye çalışılmıştır. Tahmin yöntemi olarak, yapay sinir ağları, karar ağacı ve destek vektör makineleri algoritmaları kullanılmıştır. Tezin ilk bölümünde elektrik tüketiminin tahminiyle ilgili literatür araştırılmış ve kullanılacak yöntemlerin detaylarına bu bilgiler ışığında karar verilmiştir. Sonrasında bazı veri madenciliği yöntemlerinin teorik altyapısı ve Türkiye'nin elektrik enerjisi tüketimini en çok etkileyen parametreler incelenmiştir. Uygulama kısmında her algoritma ile 10 farklı model eğitilmiştir. Eğitim için Türkiye'nin Ocak 2000 - Aralık 2017 dönemine ait 216 aylık veri kullanılmıştır. Daha sonra eğitilen modellerle Ocak 2018 - Aralık 2019 yılları arasındaki 24 aylık dönemin elektrik tüketimi tahmin edilmiştir. Tahmin sonucunda elde edilen değerler ile gerçek değerler göz önünde bulundurularak kullanılan algoritmalara ait modellerin performansları karşılaştırılmıştır.

ANAHTAR KELİMELER: Elektrik tüketimi, Karar ağacı, Yapay sinir ağları, Destek vektör makineleri, Makine Öğrenmesi

ABSTRACT

MSc Thesis

ELECTRICITY CONSUMPTION FORECASTING WITH SOME DATA MINING METHODS

Mustafa YILDIRIM

Harran University
Instıtude Of Science
Industrial Engineering Department

Advisor: Assist. Prof. Dr.Ahmet Sabri ÖĞÜTLÜ
Year: 2021, Page:80

Over the years, the population of Turkey is increasing, and demand for the industry evolving needs of high-tech tools in the field of energy use increases the life of its passing day more. The main type of energy used in our country is electrical energy. An important part of electrical energy is obtained from fossil fuels. In our world where fossil-based energy resources are decreasing day by day, the facts of existing constraints- such as the inability to store electricity and the necessity of consuming electricity when it is produced- increase the importance of carrying out production activities by taking care of supply-demand balance day by day and planning in accordance with the amount of consumption. Since, the sustainability of the electricity used depends on a healthy planning and a quality forecast. In this study, parameters such as Turkey's electricity consumption, imports, exports, economic variables like Turkey's industrial production index, population, temperature, rainfall has been used together to estimate on a monthly basis. As the prediction methods, artificial neural network, decision trees, and algorithm of support vector machines were used. In the first part of the thesis, the literature on estimation of electricity consumption was researched and the details of the methods to be used were decided in light of this information. After that, some theoretical foundation of data mining methods and parameters that affect Turkey's electricity consumption most were investigated. In the application part, 10 different models were trained with each algorithm. For the training, 216 months of data for Turkey's January 2000 - December 2017 period were used. Then, with the models trained, the electricity consumption for the 24-month period between January 2018 and December 2019 was estimated. The performances of the models of the algorithms used were compared with the values obtained as a result of the estimation and the actual values.

KEY WORDS: Electricity consumption, Decision trees, Artificial neural network, Support vector machines, Machine learning

TEŞEKKÜR

Tezin konusunun seçiminde, uygulamasında ve çalışmamda yardımlarını esirgemeyen danışmanım sayın Dr. Öğretim Üyesi Ahmet Sabri ÖĞÜTLÜ ve Dr. Öğretim Üyesi Serkan KAYA' ya

Manevi desteklerinden dolayı Babam İbrahim YILDIRIM ve Annem Fatma YILDIRIM 'a,

Tüm bu süreçte verdiği destek, gösterdiği ilgi ve sağlam sabrından ötürü sevgili eşim Ayşe YILDIRIM' a Teşekkür ederim.

Sevgili Kızım Firdevs Delal'e İthaf en...

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. 1. Veri madenciliği ve makine öğrenmesi ilişkisi 4
Şekil 3. 1. Biyolojik sinir hücresi. 15
Şekil 3. 2. Yapay sinir hücresi 16
Şekil 3. 3. Aktivasyon fonksiyonları. 18
Şekil 3. 4. Çok katmanlı bir sinir ağı yapısı. 19
Şekil 3. 5.YSA'da öğrenme stratejileri: a) gözetimli öğrenme, b) gözetimsiz öğrenme. 21
Şekil 3. 6. ART ağlarının genel yapısı. 26
Şekil 3. 7. Hopfield ağının yapısı. 27
Şekil 3. 8. Kohonen ağının (SOM) yapısı. 29
Şekil 3. 9. Geri yayılım ağının yapısı. 32
Şekil 3. 10. Hata fonksiyonunda yerel ve bütünsel minimum. 35
Şekil 3. 11. Oluşturulan karar ağacı. 39
Şekil 3. 12. Karar ağacı (İkinci adım). 40
Şekil 3. 13. DVM'nin Genel Yapısı. 43
Şekil 3. 14. Doğrusal DVM'de destek vektörler. 44
Şekil 3. 15. İki sınıflı veri setini ayıran farklı hiper düzlemler. 45
Şekil 3. 16. Doğrusal DVM için problem örneği. 46
Şekil 3. 17. Doğrusal ayrılabilen DVM. 47
Şekil 3. 18. Doğrusal ayrılamama durumu. 49
Şekil 3. 19. Doğrusal olmayan destek vektör makineleri. 50
Şekil 3. 20. İki boyutlu girdi uzayından çok boyutlu uzaya geçiş. 50
Şekil 3. 21. Doğrusal olmayan DVM'nin doğrusal DVM'ye dönüştürülmesi. 51
Şekil 3. 22. Çok sınıflı DVM. 52
Şekil 3. 23. Ocak 2000 - Aralık 2017 yılları arasındaki ihracat miktarının değişimi. 59
Şekil 3. 24. Ocak 2000 - Aralık 2017 yılları arasındaki ithalat miktarının değişimi. 59
Şekil 3. 25. Ocak 2000 - Aralık 2017 yılları arasındaki Türkiye sanayi üretim endeksinin değişimi. . 60
Şekil 3. 26. Ocak 2000 - Aralık 2017 yılları arasındaki nüfus miktarının değişimi. 61
Şekil 3. 27. Ocak 2000 - Aralık 2017 yılları arasındaki sıcaklık miktarının değişimi. 62
Şekil 3. 28. Ocak 2000 - Aralık 2017 yılları arasındaki yağış miktarının değişimi. 63
Şekil 3. 29. Ocak 2000 - Aralık 2017 yılları arasındaki elektrik tüketim miktarının değişimi. 64
Şekil 3. 30. Rapidminer'ın kullanıcı ara yüzü 65
Şekil 3. 31. Rapidminer programında hazırlanan model 66
Şekil 3. 32. Rapidminer programında hazırlanan çapraz geçerleme detayı 66
Şekil 4. 1. Eğitim tahmin performansı (Gerçekleşen-Tahmin) 72
Şekil 4. 2. Test tahmin performansı (Gerçekleşen-Tahmin) 73
Şekil 4. 3. YSA, KA, DVM Test tahmin performansı (Gerçekleşen-Tahmin) 73

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 3. 1. Örnek karar tablosu. 37
Çizelge 3. 2. Ayırt edici özellik bulunduktan sonra karar tablosu. 40
Çizelge 3. 3. Makine öğrenmesinde kullanılan performans ölçüleri 54
Çizelge 3. 4. Elektrik tüketimine etki eden değişkenler 58
Çizelge 3. 5. Yapay sinir ağı algoritması için hazırlanan modeller 67
Çizelge 3. 6. Karar ağacı algoritması için hazırlanan modeller 68
Çizelge 3. 7. Destek vektör makineleri algoritması için hazırlanan modeller 69
Çizelge 3. 8. YSA modeline ait RMSE değerleri 70
Çizelge 3. 9. KA modeline ait RMSE değerleri 71
Çizelge 3. 10. DVM modeline ait RMSE değerleri 71

SİMGELER VE KISALTMALAR DİZİNİ

°C	Santigrat (Celsius)
∑	Toplam Fonksiyonu
f(net)	Aktivasyon fonksiyonu
k(xn, x)	Komşulara Mesafe Durumu
Xn	Giriş Değerleri
Wn	Ağırlıklar
y	Çıkış Değerleri
YSA	Yapay Sinir Ağları
ART	Adaptif rezonans teorisi
Covid-19	Korona Virüs Hastalığı(Pandemi)
DVM	Destek Vektör Makineleri
EÜ	Elektrik Üretimi
ET	Elektrik Tüketimi
EVDS	Elektronik Veri Dağıtım Sistemi
GWh	Ciga Vat Saat
IHR	İhracat
ITH	İthalat
KVYT	Kısa Vadeli Yük Tahmin
KA	Karar Ağacı
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
Mm	Millimetre
MSE	Ortalama Kare Hata
N	Nüfus
OVYT	Orta Vadeli Yük Tahmini
RMSE	Kök Ortalama Kare Hata
S	Sıcaklık
SOM	Kendi kendini düzenleyen haritalar
TÜİK	Türkiye İstatistik Kurumu
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
UVYT	Uzun Vadeli Yük Tahmin

1.GİRİŞ

Günümüz dünyasında, geçmişte olduğu gibi gelecek on yıllarda da insanlığın en temel ihtiyacı enerji olacaktır. Geçmişte enerji ihtiyacını karşılamak için; odun, kömür, petrol gibi yakıtlar kullanılmıştır. Günümüzde ise enerji ihtiyacı temel olarak elektrik enerjisinden karşılanmaktadır. Elektrik enerjisinin üretiminde fosil yakıtlar önemli yer kaplamaktadır. Üretilen enerjinin depolanmasının mümkün olmaması, üretildiği anda tüketilmesi zorunluluğu gibi kısıtlar elektrik enerjisi üretiminin planlı ve ihtiyaca göre önceden gerçekçi tahminler yapılarak yapılmasını zorunlu kılmaktadır.

Günümüz dünyasında elektrik enerjisi üretimi için talep yönetimi 3 ana alana odaklanmaktadır:

1. Elektrik Üretim Miktarı Tahmini
2. Elektrik Tüketimi Miktarı Tahmini
3. Elektrik Birim Fiyat Tahmini

Bu 3 alanda doğru tahmin yapılması operasyonların ve güç sistemlerinin planlanmasında ciddi önem arz etmektedir. Doğru planlama yapıldığında elektrik üretiminde verimlilik ve sürdürülebilirlik sağlanabilmektedir.

Literatürdeki çalışmalara baktığımız zaman elektrik talep tahmini 3 farklı zaman dilimine göre ele alındığı görülmektedir.

1. Kısa Vadeli Yük Tahmin (KVYT), 24 saate kadar tahmin yapılması için kullanılır. Bu tahminle üretim sürecindeki saatlik değişim, üretim, taahhüt edilen elektriğin birim olarak takibi gibi konular planlanır ve sistemin düzenli şekilde çalışmasına dönük sistem güvenliği sağlanmış olur.
2. 1 günden 1 yıl sonrasına kadar tahmin etmeyi sağlayan zaman dilimine Orta Vadeli Yük Tahmini (OVYT) denir. Bu tahmin bakım planlama, yakıt planlama, günlük ve aylık bazda tüketim ihtiyacını belirlemede ve su depolama faaliyetleri için önemlidir. Ayrıca OVYT'ye, birincil enerji ihtiyacı ve pik dönem yük değerlerinin tahmini için ihtiyaç duyulur.

3. Uzun Vadeli Yük Tahmin (UVYT), 1 yıldan 10 yıl sonrasının tahminine kadar bir zaman dilimini içerir. Bu tahminle, iletim, dağıtım ve üretim faaliyetlerinin planlanması kontrol altına alınır. Ayrıca gelecekte oluşabilecek ihtiyaçlara göre yapılması gereken yatırımlar planlanır.

Bu çalışmada ise uygulanacak veri madenciliği metotların da UVYT zaman dilimini içerecek şekilde 2020 ve 2021 yılları için tahminleme çalışması yapılmıştır.

Literatür çalışmalarına bakıldığında elektrik tüketimin tahmininde birçok yöntem kullanılmıştır. Bunları aşağıda belirtilen başlıklar altında toplayabiliriz.

- Çoklu Regresyon Metodu,
- Üssel Düzeltme Metodu,
- Tekrarlı Ağırlıklandırmalı En Küçük Kareler Metodu,
- Stokastik Zaman Serileri Metodu,
- Adaptif Yük Tahmini Metodu,
- Bulanık Mantık Yöntemleri,
- Veri Madenciliği Uygulamaları,

Veri madenciliğinin geçmişi çok eski tarihlere dayanmamaktadır. Literatüre bakıldığında Veri Madenciliği (Data Mining) ile ilgili geniş bir tanımlama perspektifi ortaya çıkmaktadır.

Mevcut kavramsal bütünde ilk olarak bilinmesinde fayda görüldüğü üzere; veri madenciliği anlam olarak bilginin etkin bir şekilde kullanılabilmesi için disiplinler arasında takip edilen kuralların tamamını içerir (Witten ve Frank, 2000).

Bu kuram güncel gelişmelerin paralelinde gelişen bir ihtiyaç olarak gün yüzüne çıkmış gerek iş gerekse bilimsel çevrelerden toplanan çok büyük miktarlardaki bilginin değişik şekillerde analiz edilerek arkalarında sakladıkları ilişkilerin ortaya çıkarılması gerekliliği ile kendisi için gerekli motiveyi bulmuştur (Adriaans ve Zantinge, 1996).

İlk defa "Büyük Veri" ifadesini 1997 yılında Cox ve Ellswarth adlı 2 Nasa çalışanı kullanmıştır. Bu ifade her geçen gün boyutu büyüyen verilerin kontrolünün ve yorumlanmasının ortaya çıkaracağı sorunlara dikkat çekmek için kullanılmıştır (Bilim Teknik, Nisan 2015).

Büyük veriyi nitelemekte kullanılan üç faktörün ise verinin hacmi, karmaşıklığı ve çeşitliliği olarak nitelendirilebileceği değerlendirilmektedir ki veri madenciliği bu "kaos"un içerisinden anlamlı bilgiyi hizmete yönelik analiz etme ihtiyacından kaynaklanmaktadır (Hand vd., 2001).

Günümüz şartlarında günlük yaşama dair milyarlarca veri her gün çok büyük ölçekli veri depolarında "kontrollü" olarak kaydedilmektedir. Bu verilerin elde edilmesi, depolanması ve yönetimi genel olarak otomatik olarak yapılmaktadır. Veri madenciliği, her sektörde tahminlerden daha büyük boyutlu veri ambarlarının meydana çıkmasının bir sonucudur. Doksanlı yıllardan başlayarak veri tabanı sistemlerinin birçok alanda kullanım oranının yükselmesi aynı zamanda veri tabanları sistemlerinin hacimlerindeki bu olağandışı yükseliş, büyük kuruluşları elde biriken bu verilerden ne şekilde fayda elde edilebileceği sorunuyla baş başa bırakmıştır (Sarle, 1994).

Verilerin sanal alanlarda depolanmasıyla beraber, her 20 ayda 1 yeryüzündeki bilgi birikimi iki katına çıktığı bu zamanda veri tabanlarının adedi' de, daha fazla artmaktadır (Fayyad vd., 1996).

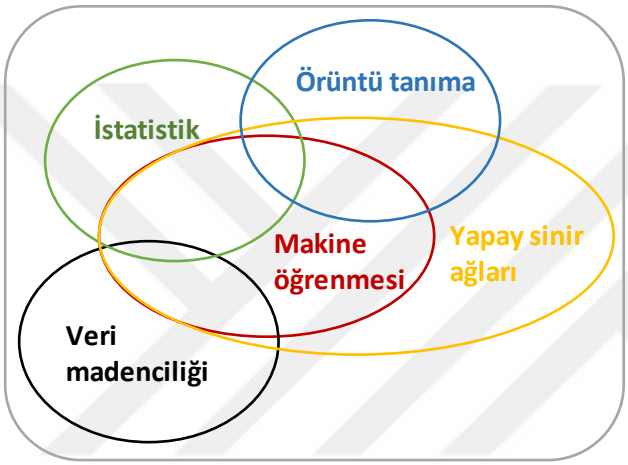
Yüksek boyutta işlem gerçekleştirme gücünün ucuzlamasıyla beraber, elde bulunan veriyi depolama hem daha basit hale gelmiş hem de verinin maliyeti düşmüştür.

Bu çerçeveden bakıldığında, kısacası veri madenciliği, elde bulundurulan verilerden üstü kapalı, belirgin olmayan, daha öncesinde bilinmeyen fakat kullanılabilme potansiyeli barındıran bilginin açığa çıkarılmasıdır (Schalkoff, 1992).

Bu da belirsiz verilerin kümelemesi, verilerdeki değişikliklerin analizi, veri özetleme, verilerdeki sapmaların bulunması gibi sınırlı sayıda teknik anlamdaki yöntemleri kapsar (Frawley, Piatetsky – Shapiro, Matheus, 2001).

Veri madenciliği temel olarak, veri setleri arasında yer alan desen ve örüntülerin ya da düzenin, verinin analiz edilmesi ve yazılım tekniklerinin uygulanması ile ilişkilidir. Teorik olarak incelendiğinde veri madenciliği bilginin keşfedilmesi sürecinin bir parçası olarak kabul edilir fakat gerçekte veri madenciliği ve bilgi keşfi aynı anlamda kullanılmaktadır. (Lee ve Stolfo, 1998).

Veri madenciliği çalışmalarında veriden bilgi çıkarma amacıyla çoğunlukla makine öğrenmesi algoritmaları kullanılmaktadır. Veri madenciliği ile makine öğrenmesi arasındaki ilişki aşağıda Şekil 1.1 de (Toward, 2021) görülmektedir.



Şekil 1. 1. Veri madenciliği ve makine öğrenmesi ilişkisi

Bilgisayar veriler arasındaki bağlantıları, özellikleri ve kuralları tespit etme sorumluğuna sahiptir. Amaç, daha önceden bilinmeyen veri desenlerini ortaya çıkarabilmektir. Bu ortaya çıkarma işlemi için makine öğrenme algoritmaları kullanılmaktadır. Bu çalışmada temel olarak 3 adet makine öğrenmesi modeli (algoritması) kullanılmış olup, Rapid Miner veri madenciliği programı kullanılmıştır.

Bu çalışmada kullanılan makine öğrenmesi algoritmaları aşağıda verilmiştir:

1. Yapay Sinir Ağları (YSA)
2. Karar Ağacı (KA)
3. Destek Vektör Makineleri (DVM)

2.ÖNCEKİ ÇALIŞMALAR

Gürsoy tarafından 2000 yılında yapılan uzun dönem yük tahmin çalışmasında regresyon, zaman serisi ve YSA kullanılarak Antalya Kepez bölgesi ve Çukurova Elektrik A.Ş (ÇEAŞ) bölgesi için 2020 yılına kadar uzun dönem tahminler yapılmıştır

Saab ve ark. (2001) çalışmalarında tek değişkenli modelleme yöntemiyle Lübnan'ın aylık elektrik enerjisi tüketimini tahmin etmeyi amaçlamıştır. Makalede, Otoregresif (AR), Otoregresif Entegre Hareketli Ortalama (ARIMA) ve yüksek geçirgen filtreli AR (1) konfigürasyonu olmak üzere üç farklı tek değişkenli yöntem kullanılmıştır. Çalışmanın sonunda yüksek geçirgen filtreli AR (1) konfigürasyonu diğer yöntemlere göre üstünlük sağlamıştır.

Yalçınöz ve Eminoğlu (2005) makalelerinde güç dağıtım hatlarında yakın zamanlı pik yük tahmini, yakın zamanlı toplam yük tahmini ve orta zamanlı aylık yük tahmini için ileri beslemeli sinir ağı modelini kullanmıştır. Çalışma Niğde ili için temin edilen gerçek verilerle yapılmıştır. İki gizli katmanlı YSA modeli aylık yük tahmini ve pik yük tahmini için daha iyi sonuç vermiştir. Tüm modellerin, hata oranları göz önünde bulundurulduğunda gerçek hayata uygulanabilir olduğu görülmüştür.

Demirören ve Ceylan (2006) makalelerinde, Çok Katmanlı Yapay Sinir Ağı (ÇKYSA) yöntemini kısa dönemli yük tahmininde kullanmıştır. Araştırmada Türkiye'nin Orta Anadolu Bölgesindeki 2002-2003 yılları arasındaki gerçek yük ve sıcaklık değerleri kullanılmıştır. Tahmin modelinde maksimum sıcaklık, minimum sıcaklık ve gün tipi faktörlerinden faydalanılmıştır. Tahmin sonuçları regresyon yöntemiyle karşılaştırıldığında ÇKYSA yöntemi daha iyi sonuç vermiştir.

Ghiassi ve ark. (2006) makalelerinde, orta vadeli elektrik yükü tahmini için Dinamik YSA Modeli geliştirmiştir. Çalışmada gelecekteki elektrik taleplerini tahmin etmek için geçmiş aylara ait sistem yüklerini kullanan bir model sunulmuştur. Ayrıca hava durumu verilerinin dahil edilmesinin yük tahmini doğruluğunu arttırdığı gösterilmiştir. Ancak bu tür modellerde elde edilmesi çok zor olan doğru hava tahminleri yapılması gerekmektedir. Bu yüzden hava durumu değişkenleri kullanılmadan alternatif mevsimsel modeller geliştirilmiştir. Tüm modeller Tayvan

Enerji Kurumu'ndan sağlanan gerçek sistem yükü verileri kullanılarak doğrulanmıştır. Hem yıllık hem de mevsimsel modeller, ortalama %1'in altında Ortalama Mutlak Yüzde Hata (MAPE) değerleri üretmiş ve orta vadeli yükleri tahmin etmede etkin oldukları kanıtlanmıştır. Son olarak, sonuçlar çoklu doğrusal regresyon (MLR) ve ARIMA modelleriyle karşılaştırılmıştır.

Toksarı (2007), enerji talebi modeli için Karınca Algoritması Optimizasyonunu kullanmıştır. Bu algoritma, karıncaların toplanma davranışlarından esinlenerek problemin optimizasyonunu sağlamaktadır. Enerji talebi tahmini için, nüfus, gayri safi yurtiçi hasıla, ithalat ve ihracat değerleri bağımsız değişken olacak şekilde kullanılmıştır. Çalışmada tavsiye edilen tüm denklemler doğrusal ve kuadratiktir. Quadratik tahmin modeli, ekonomik göstergelerdeki dalgalanmalardan dolayı daha iyi bir çözüm sağlamıştır

Gonzalez-Romera vd. (2008) çalışmalarında İspanya'nın aylık elektrik talep serisinin periyodik davranışlarını incelemiştir. Periyodik davranış Fourier serisiyle, trend ise YSA ile tahmin edilmiştir. Yöntem, ARIMA ve YSA'nın kullanıldığı sistemlerle karşılaştırıldığında %2'den küçük çıkan MAPE değeriyle daha iyi bir sonuç vermiştir.

Ekonomou (2009), YSA yöntemini, Yunanistan'ın uzun dönemli elektrik tüketiminin tahmin edilmesinde kullanmıştır. Geliştirilen ÇKYSA modeliyle 2005-2008, 2010, 2012 ve 2015 yılları enerji tüketimi tahmin edilmiştir. 2005-2008 yılları arasında YSA ile tahmin sonuçları, Lineer Regresyon (LR) ve DVM yöntemleriyle karşılaştırıldığında gerçek enerji tüketim değerlerine daha yakın sonuçlar vermiştir.

Kavaklıoğlu vd. (2009), Türkiye'nin enerji tüketimini öngörebilmek ve modellemek için YSA Yöntemini uygulamıştır. YSA modeli olarak Geri Beslemeli öğrenme algoritmasına sahip Çok Katmanlı YSA kullanılmıştır. Elektrik tüketimi, nüfus, gayrisafi yurtiçi hasıla, ithalat ve ihracat değerleri gibi göstergeler tahmin modeli değişkenleri olarak kullanılmıştır. 1975 ve 2006 yılları arasındaki veriler kullanılarak Türkiye'nin 2027'ye kadar elektrik tüketimi tahmin edilmiştir.

Demirel (2009) tarafından yapılan çalışmada Türkiye'nin yıllık uzun dönem yük verileri tahmin edilmiştir. Giriş parametreleri olarak Gayri Safi Milli Hasıla, tüketilen

enerji, üretilen enerji, nüfus sayısı ve kurulu güç verileri kullanılmıştır. Tahmin yöntemleri olarak ANFIS, ARMA, YSA ve regresyon modelleri kullanılmış ve sonuçlar karşılaştırılmıştır. En iyi tahmin sonucunu ANFIS yönteminin verdiği sonucuna ulaşılmıştır.

Demren (2011) tarafından İstanbul Avrupa Yakası için orta vadeli günlük yük öngörüsünde bulunulmuştur. Eğitim verileri olarak 2006-2009 yılları seçilirken, 2010 yılı Nisan dönemine ait puant yük değerleri öngörülmüştür. Bağımlı değişkenler olarak geçmiş yük verileri, ortalama hava sıcaklığı, takvim günleri ve elektrik fiyatı kullanılmış ve bağımsız değişkenin tahmin sonucuna etkisini görmek amacıyla hava sıcaklığı ve geçmiş dönemlere ait yük verisi ile farklı modeller kurulmuştur. Tahmin metodolojisi olarak DVM ve YSA kullanılmıştır. Model olarak DVM'nin YSA modeline göre daha üstün olduğu sonucu çıkmıştır. Sıcaklık ve geçmiş yük bağımsız değişken olarak seçilen modelin doğruluk oranının daha yüksek olduğu ortaya çıkmıştır.

Bilgili vd. (2011), YSA, LR ve Lineer Olmayan Regresyon (NLR) Yöntemlerini kullanarak Türkiye'nin konut ve sanayi sektöründeki elektrik tüketimini tahmin etmiştir. Kurulu kapasite, toplam elektrik üretimi, nüfus ve toplam abone adedi kullanılan bağımsız değişkenlerdir. Gelecekteki elektrik tüketimi öngörüsünde bulunmak için iki adet model tavsiye edilmiştir. LR, NLR ve YSA'dan ortaya çıkan sonuçlar, Enerji ve Tabi Kaynaklar Bakanlığı'nın elektrik tüketim öngörüsü ve literatürdeki sonuçlarla karşılaştırılmıştır. Karşılaştırma sonuçları YSA'nın LR ve NLR'den daha iyi performans değerlerine sahip olduğunu göstermiştir.

Boltürk vd. (2012) çalışmalarında, bir Türk firmasının olası elektrik tüketiminin tahmini için 2 yıllık elektrik tüketim verisini incelemiştir. Tahmin yöntemi olarak Singh'in Bulanık Zaman Serileri Metodu seçilmiştir.

Oğcu vd. (2012) çalışmalarında 2010-2011 yılları arasında elektrik çıktısını tahmin etmek için DVM ve YSA yöntemlerini kullanmıştır. Bu çalışmada, verilerin tahmin edilmesi için mevsimsel bir Destek Vektör Regresyon (DVR) modeli önerilmiştir. Çalışma sonucunda mevsimsel DVR modelinin YSA modelinden daha üstün olduğunu gözlenmiş ve yakın gelecekte Türkiye'de elektrik tüketiminin artacağına dair deneye dayalı kanıtlar sağlanmıştır.

Haciefendioğlu (2012) çalışmasında 3 önemli makine öğrenmesi sınıflandırma yöntemi kullanmıştır. DVM, YSA ve KA kullanılarak glokom hastalığının ilk etapta teşhisi edilebilmesi için sınıflandırma yapılmış ve birbiriyle kıyaslanmıştır. Bahsi edilen makine öğrenmesi tekniklerinin performansları çapraz geçerleme tespit edilmiş ve en güçlü sınıflandırma başarısının DVM ile edinileceği görülmüştür.

İşyapar (2013) tarafından yapılan çalışmada elektrik yük tüketim aboneleri yapay zekâ yöntemlerinden kümeleme algoritması yardımıyla sınıflandırılmıştır. İşyapar'a göre bu çalışmada karar ağacı, hiyerarşik metodlar vb. metotlarla elde edilen abone kümelendirme çalışması yük tahmini çalışmasının ön ayağını oluşturmaktadır.

Chai ve Draxler (2014) model değerlendirme çalışmalarında düzenli olarak kullanılmakta olan hata kareler ortalamasının karekökü (RMSE) hem de hata kareler ortalaması Ortalama Mutlak Hata (MAE) da dahil olmak üzere çoğu zaman, model performansını değerlendirmek için bir metrikler kombinasyonunun gerektiğini belirtmişlerdir.

Uzlu vd. (2014), YSA ile Öğretme-Öğrenme Algoritmasını birlikte kullanarak Türkiye'deki enerji tüketimini değerlendirmiştir. Gayrisafi yurtiçi hasıla, ihracat, nüfus ve ithalat değişkenleri bağımsız değişken olarak kullanılmıştır. Bu hibrit modelle, klasik geri yayılımlı YSA modeli, hata kriterleri açısından karşılaştırılmıştır. Önerilen modelin klasik YSA modeline göre daha iyi tahmin yaptığı görülmüştür. Modelin en iyi konfigürasyonu belirlendikten sonra 3 farklı senaryo için tahmin yapılmıştır. Tahmin değerleri Enerji ve Tabii Kaynaklar Bakanlığı'nın tahmin değerleriyle karşılaştırılmış ve 2020 yılı için tüm senaryolarda daha düşük enerji tüketim tahmini yapılmıştır.

Ahmad ve arkadaşları (2014) tarafından yapılmış olan çalışmada yük tahmininde kullanılan ARIMA, YSA, DVM ve bunların hibrit yapıları incelenmiştir. Kullanılan metotların tüketici grubu farklılıkları MAPE ve RMSE parametreleri üzerinden karşılaştırılmıştır. Sonuç olarak ARIMA ve DVM hibrit modelinin diğer modellere nazaran doğruluk oranı yüksek sonuçlar çıkardığı yorumu yapılmıştır.

Toksarı (2015), çalışmasında Karınca Koloni Algoritması ve Tekrarlı Lokal Arama Algoritmasını kullanarak Türkiye'nin elektrik tüketimini tahmin etmiştir.

Ekonomik gösterge olarak gayrisafi yurtiçi hasıla, nüfus, ithalat ve ihracat verileri kullanılmıştır. 1990-2013 yılları arasındaki veriler kullanılmış; 2014-2030 arasındaki tüketim değerleri tahmin edilmiştir.

Selvaluxmiy ve arkadaşları (2016) grafik İşlem Birimini (GPU) kullanarak, K-NN sınıflandırma algoritmasını hızlandırarak, daha hızlı bir yürütme süresi göstermesini sağlamıştır.

Krauss ve arkadaşları (2016) Derin Sinir Ağı, Gradyan Arttırılmış Ağaçlar ve Rastgele Orman algoritmaları ile tahminleme çalışmalarını, dövizdeki kur farklarından işlem yaparak sağlanan kar içeriği için istatistiksel olarak analiz etmişlerdir.

Günay (2016), Türkiye'nin yıllık elektrik talebini Çoklu Lineer Regresyon ve Yapay Sinir Ağlarıyla modellemiştir. Bağımsız değişken olarak nüfus, kişi başına düşen gayrisafi yurtiçi hasıla, enflasyon yüzdesi, ortalama yaz sıcaklığı belirlenmiştir. Çalışmada 1975-2013 yılları arasındaki veriler kullanılmış, 2007-2013 yılları arası test edilmiş ve yapılan tahminlerde yüksek doğruluk yakalanmıştır.

Hamzaçebi vd. (2017) makalelerinde, Türkiye'nin aylık elektrik tüketim ihtiyacını öngörmüştür. Mevsimselliğin ve trendin etkilerini modellemek için dört farklı YSA modeli geliştirilmiş ve üstün olanı seçilmiştir. Ayrıca, seçilen YSA modeli, modelin kabul edilebilirliğini ve güvenilirliğini arttırmak için SARIMA modeli ile karşılaştırılmıştır. Performans ölçümlerine göre başarılı ve yüksek doğrulukta tahminler yapabilen YSA modeli ile 2015 ve 2018 yılları arasında Türkiye'nin aylık elektrik talebi öngörülmüştür.

Doğan ve Türkoğlu (2018) bitki yapraklarının sınıflandırılmasında uygulanan çoğu yönteme kıyasla derin öğrenme yoluyla sınıflandırılma yaparak deep learning algoritmalarının başarımlarını ortaya koymuşlardır.

Akman (2018) tarafından yapılan çalışmada Orta Anadolu Yüz Tevzi (Türkiye'deki bütün barajların sistem durumlarının izlendiği ve kontrol edildiği yerdir) İşletme Müdürlüğüne ait 2009-2015 tarihine kadar gerçekleşen saatlik yük verileri, maksimum ve minimum sıcaklık verileri giriş parametreleri olarak kullanılmıştır. Çıkış olarak günlük yük tahmini yapılmış ve 10 farklı gün tipi seçilerek test edilmiştir. Tahmin yöntemi olarak YSA ile GA ve YSA içeren hibrit metodolojiler kullanılmıştır.

Oluşturulan hibrit modelin gerçeğe daha yakın sonuçlar verdiği çıkarımında bulunulmuştur.

Doruk (2019) tarafından Sakarya bölgesine ait hane halkı verileri elektrik tüketiminin tahmininde kullanılmıştır. Tahmin yöntemi için Durum-Uzay modellerinin Bayesci bir yaklaşımı olan Dinamik Lineer Model ve ARIMA modeli kıyaslanarak tahmin algoritmalarının performansı ortaya konmuştur. Mevsimsel faktör, lineer büyüme ve ARMA kullanılarak oluşturulan modelin doğruluk oranının en yüksek olduğu ortaya konulmuştur.

3.MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Makine Öğrenme Algoritmaları ile Elektrik Tüketim Tahmini

Teknolojideki gelişmelerle birlikte günümüzde veriye ulaşmak, ulaşılan veriyi toplamak ve toplana veriyi depolamak oldukça kolay bir hale gelmiştir. Bireysel ve toplumsal alanda birçok veri anlık olarak izinli ya da izinsiz bir şekilde kaydedilip depolanmaktadır. Her verinin toplanması, kayıt altına alınması avantaj gibi gözükse de gün geçtikçe bu kadar büyük veri içinden anlamlı ve faydalı bilgiler çıkarmak ciddi ve çözümlenmesi zor bir sorun halini almıştır. Bu durum büyük veri (big data) yığınları kavramını tartışılır ve çözülmesi gereken bir konu haline getirmiştir. İnsanlar için büyük veri yığınları değil, analiz edilip anlamlandırılabilen veriler ancak bir anlam ve değer ifade eder. Bu nedenle verileri işlemek ve çözümlemek, çözümlenen veriyi kullanarak mevcut duruma ya da geleceğe dönük değerli sonuçlar elde edebilmek için yapay zekâ gibi özel yöntemlere ihtiyaç duyulmuştur. İnsanın zekasından ilham alarak aynı sistem ve kurguyu robot ve makinelerde kullanılabilir hale getirmeyi hedefleyen yapay zekâ olgusu; tahmin, sınıflandırma, örüntü tanıma, kümeleme gibi amaçlar için makine öğrenmesi kavramının ortaya çıkmasına sebep olmuştur. Makine ve bilgisayar sistemlerinin de insan gibi öğrenip en iyi ve teknik olarak en doğru kararı verebilme arzusu makine öğrenmesi kavramının esas hedefi olmuştur. Makine öğrenmesi metodu ile bilgisayarların da insanlar gibi eğitilip, öğretilerek yeterli bir seviyeye ulaştırılması bu hedefe ulaşmak için zorunlu hale gelmiştir. Makine öğrenmesi sayesinde geçmişte elde edilen verilere dayanarak geleceğe dönük tahmin ve planlama yaparak daha doğru ve geçerli sonuçlar elde edilebilmektedir.

Bu çalışmada, bazı makine öğrenme algoritmalarının Ocak 2018 ve Aralık 2019 yılları için 24 dönemlik (aylık)elektrik tüketimi tahminlemesinde kullanımı incelenmiştir. Bu amaçla, KA, Lineer DVM ve YSA algoritmaları göz ününde tutulmuştur. Tahmin modellerini bahsedilen algoritmalarla eğitmek için Ocak 2000 - Aralık 2017 yılları arasını kapsayan 216 aylık dönemde İhracat, İthalat, Toplam Sanayi

Üretim Endeksi (TSÜE), Nüfus, Sıcaklık Ortalaması ve Yağış Ortalaması gibi 6 adet bağımsız değişkene ait girdi verisi ile aynı döneme ait elektrik tüketimi çıktı verisi kullanılmıştır. Eğitim işlemi Rapid Miner yazılımında gerçekleştirilmiştir. Eğitilen modeller ile Ocak 2018 - Aralık 2019 arasındaki 24 ay için elektrik tüketim tahmini yapılmıştır.

Rapid Miner; veri hazırlama, örüntü tanıma, makine öğrenimi, kümeleme, derin öğrenme, sınıflandırma, metin madenciliği ve öngörüye dayalı sayısal işlemler için bütünleşik bir şekilde çalışmaya imkân sağlayan veri madenciliği (Data Mining) yazılım ortamıdır. Araştırma, geliştirme, tahmin etme analiz etme, sonuç çıkarma, eğitim, öğretim, modelleme çalışmalarında ve uygulama geliştirme gibi iş ve ticari uygulamalarda kullanılır. Aynı zamanda veri hazırlama, veri temizleme, eksik veriyi doldurma, çaprazlama, görselleştirme, model belirleme, model geçerleme ve sistem optimizasyonu dahil olmak üzere makine öğrenim sürecinin tüm aşamalarında kolay şekilde kullanımı destekleyen bir altyapı ve ara yüze sahiptir. İlk olarak YALE (Yet Another Learning Environment) olarak tanınan Rapid Miner, 2001 yılından bu yana Dortmund Teknik Üniversitesi Yapay Zekâ Birimi'nde Ralf Klinkenberg, Ingo Mierswa ve Simon Fischer'in analiz, kestirim vb. alanlarda gerçekleşen performansı geliştirilmeye devam etmektedir. Rapid Miner programının oluşturulmasında Java dili kullanılmıştır. Ayrıca kullanıcıya kendi içerisine Java dili ile kod eklemeye imkân tanımaktadır. Bunun yanında Python, Weka veya R gibi diller/ortamlarla da son derece uyumlu çalışmaktadır. Ücret ödemeden kullanmak isteyen kişilere 1 mantıksal işlemci ve 10.000 veri satırıyla sınırlı olan Rapid Miner Studio Free Edition, AGPL lisansı ile bedelsiz kullanım olanağı bulunmaktadır. Rapid Miner ile Weka vb. veri madenciliği programları ile kıyaslandığında dünya sırlamasında ücretsiz olmalarına rağmen tercih edilme oranı çoğu ücretli yazılım ile rekabet edebilecek düzeydedir. İster yeni başlayan olsun ister veri madenciliği ve yapay zekâ alanın da uzman seviyede çalışma yürüten olsun tüm kullanıcıların ihtiyaçlarını iyi ve kolay şekilde karşılamaktadır. Her geçen gün daha da gelişen veri madenciliği teknolojisine uyum sağlayarak sunucu mimarisinin üstünde yüksek performans ile çalışabilmektedir. Tüm bu özelliklerinin yanında yüzlerce geliştirme ve eklenti seçeneğine sahiptir.

Rapid Miner'ın kullanıcı ara yüzü pratik ve sade tasarlanmıştır. Ve bu ara yüzde 4 temel kullanım penceresi bulunmaktadır.

Bunlar:

1.Repository penceresi: Örnek verileri içerir. Rapid Miner'a yeni veri ekleneceği zaman bu bölümden ekleme yapılır.

2.Operators penceresi: Veri madenciliği ile ilgili operatörleri içerir.

3.Process: Bu boş alanda operatör penceresinden getirilen operatörler ile algoritmalar kurulur ve çalıştırılmak sureti ile sonuca gidilir.

4.Property: Tasarlanan algoritmalarda yer alan modüllere ait parametrelerin düzenlenmesi burada yapılmaktadır.

3.1.2. Kullanılan Makine Öğrenme Algoritmaları

3.1.2.1. Yapay sinir ağları

Biyolojik sinir ağlarının analitik ve matematiksel işleme dayalı modellemeler kullanılarak oluşturulmuş bilgi ve veri kullanma sistemine Yapay Sinir Ağları (YSA) denir. Bu bilgi işleme sisteminde en ufak parçası olarak bilinen sinir hücreleri (nöron) bilgilerin işlenmesini sağlamaktadır (Fausett 1994 ; Aktaran Ekinci, 2017).

Bahsi geçen bilgi işleme sürecinin sonunda YSA'lar belirli bir öğrenme seviyesine ulaşırlar. Bunun sonucunda girdi-çıktı işlemlerine dair edindiği bilgiyi daha önceden görmediği durumlara uygulayarak doğru sonuçlar elde edebilmektedir. Yapay sinir ağları olarak nitelendirilen bu yapı sinir hücrelerinin çeşitli biçimlerde birbirine bağlanması ile oluşmaktadır.

Sinir hücrelerinin farklı tarzlarda birbirine bağlanmasıyla ortaya çıkan bu şekle yapay sinir ağları denilmektedir. Esasında yapay bir sinir ağı 3 kısımdan oluşmaktadır. Bunlar, nöronların birbirleri ile ilişkisinin mimarisi, bağlantı ağırlıklarının öğrenme kaidesi ve bu kaideye bağlı aktivasyon fonksiyonu olarak nitelendirilebilir (Fausett 1994; Aktaran Ekinci, 2017).

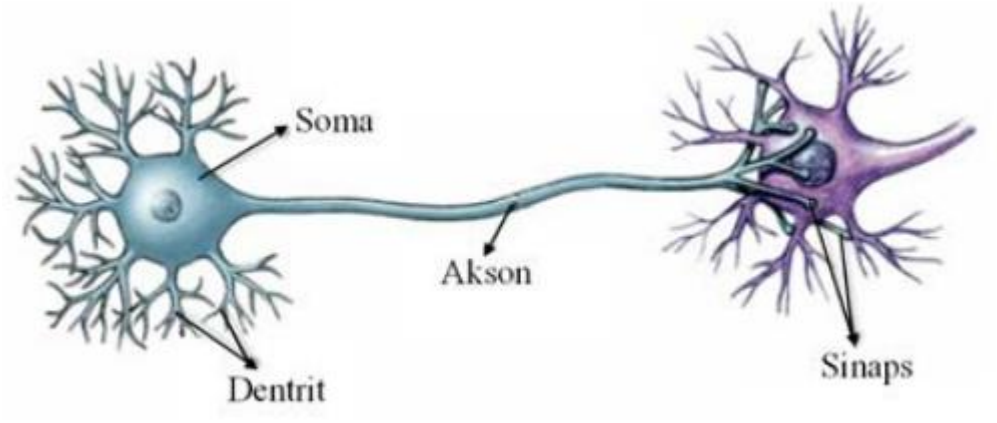
3.1.2.1.1. Sinir hücrelerinin yapısı

1943 yılında McCulloch ve Pitts'in yaptığı çalışmada biyolojik sinir hücresinin çalışma prensibini matematiksel olarak ifade ettiği çalışmalar yapay sinir ağlarının çıkış merkezi olmuştur. Yaptıkları bu çalışmalar sonucunda, basit sinir ağlarının mantıksal ya da matematiksel fonksiyonları öğrenebildikleri anlaşılmıştır (Kriesel (2005) ; Aktaran Ekinci, 2017).

3.1.2.1.1.1. Biyolojik sinir hücreleri

Sinir sistemlerinin ana parçası olan sinir hücrelerinin esas işlevi bilginin aktarımıdır. Bir biyolojik sinir hücresi 3 kısımdan oluşmaktadır bunlar; dentrit, hücre gövdesi (soma) ve akson dur. Bu 3 kısım Şekil 3.1'de (Ekinci, 2017) görülmektedir. Sinir hücresine gelen sinyalleri somaya aktaran yapıya dentrit denilmektedir. Sinir gövdesine yetişen bu sinyaller eğer belli bir eşik değerini aşarsa akson denilen yapı aracılığı ile diğer hücrelere iletilirler (Snell 2010; Aktaran Ekinci, 2017).

Diğer sinir hücrelerine ait dentritler ile kurulan boşluklu yapı olan sinapslar sayesinde akson denilen yapı eldeki bu bilginin iletimini sağlar. Bir sinir hücresi aynı anda birden çok sinir hücresi ile sinapslar aracılığı ile sinaptik adı verilen yapı oluşturabilir. Sinaptik olarak adlandırılan bu yapı uyarıların iletildiği (presinaptik) ile uyarıların alındığı (postsinaptik) kısımlara göre iki kısma ayrılmaktadır (Noback ve ark. 2005; Aktaran Ekinci, 2017).

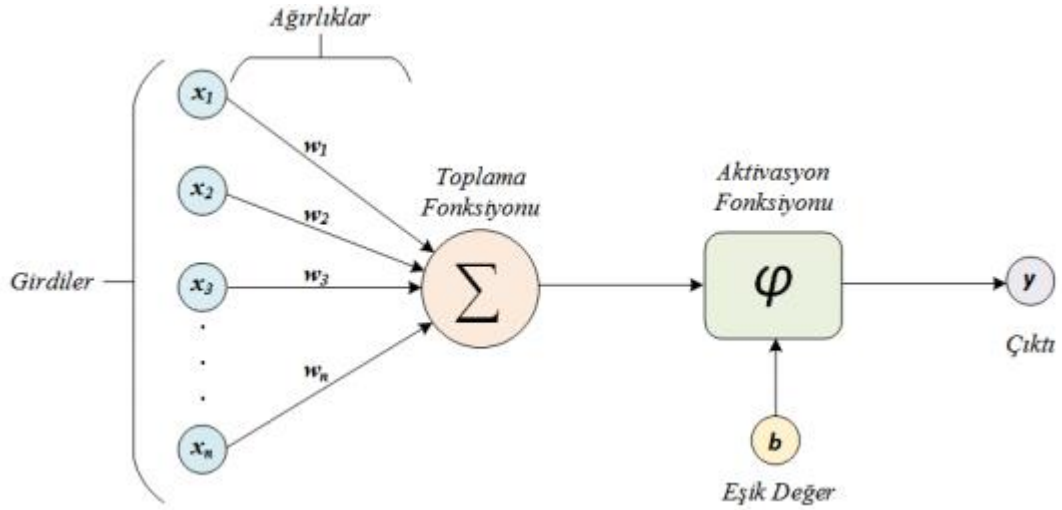


Şekil 3. 1. Biyolojik sinir hücresi.

3.1.2.1.1.2. Yapay sinir hücreleri

1943 yılında McCulloch ve Pitts tarafından matematiksel olarak tanımladıkları biyolojik sinir ağlarının, yapay sinir hücresi olarak gösterimi Şekil 3.2'deki (Ekinci, 2017) gibi bir modeli bulunmaktadır.

Yapay sinir hücreleri ile biyolojik sinir hücrelerini karşılaştırdığımızda, ağırlıklar olarak tanımlanan kısım sinaptik yapıyı, toplama fonksiyonu olarak tanımlanan kısım dentritleri ve çıktı olarak tanımlanan kısmın ise aksonlara denk geldiği söylenebilir (Aktaran Ekinci, 2017).



Şekil 3. 2. Yapay sinir hücresi.

Şekil 3.2 de x_i, i = 1, … . , n şeklinde belirtilen giriş değerleri, henüz derlenmemiş ya da diğer hücrelerden gelen bilgileri göstermektedir. Yapay sinir hücresine gelen giriş değerleri, toplama fonksiyonuna gönderildiği sırada üstünden geçtikleri ağa ait w_i ağırlıklarıyla çarpılırlar. Böylece giriş değerlerinin çıktı değeri üzerinde oluşturacağı etki tespit edilir. Yapay sinir hücresine gönderilmiş olan toplam ağırlıklandırılmış giriş değerini hesaplayan yapı, toplama fonksiyonu olarak adlandırılmaktadır. En sık kullanılan ağırlıklı toplama fonksiyonuyla net giriş değeri aşağıda Denklem (3.1)'deki gibi hesaplanmaktadır: (Ekinci, 2017)

$$z = \sum_{i=1}^{n} x_i w_i \tag{3.1}$$

Toplama fonksiyonu sayesinde hesaplanan net giriş değeri, bb eşik değeri de dikkate alınarak aktivasyon fonksiyonu ile hesaplanıp yapay sinir hücresinin çıktısı oluşturulur.

McCulloch-Pitts tarafından tasarlanan modelde net girdi değerini çıktı değerine çevirecek araç olarak Denklem (3.2)'de verilen basamak (step) fonksiyonu kullanılmıştır (Yegnanarayana 1999; Aktaran Ekinci, 2017).

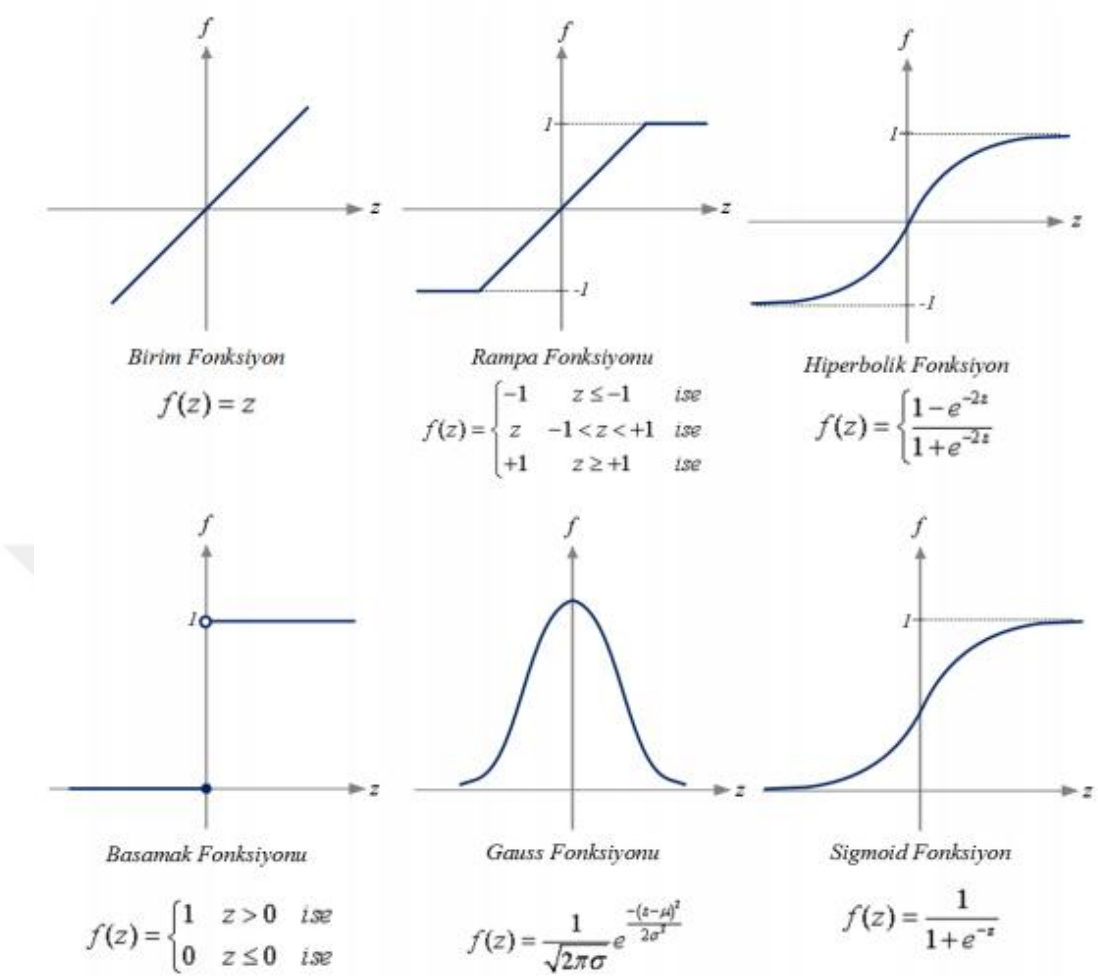
Ağırlıklandırılmış toplam giriş değerini bu fonksiyon sayesinde 0 ve 1 olmak üzere iki farklı sonuca çevirmektedir. Bu iki değer aşağıda Denklem (3.2)'de görülmektedir (Ekinci, 2017).

$$y = f(z) = \begin{cases} 1 & z > b \; ise \\ 0 & z \leq b \; ise \end{cases} \quad (3.2)$$

Sonuç olarak yapay nöronun işleyiş mantığını şu şekilde çalışmaktadır; 1. Aşamada hücre ye gönderilen toplam sinyalin (z) eşik değeri (b) aşıp aşamadığı kontrol edilir.

Toplam sinyal eşik değerini aşmış ise hücre aktif (y = 1) olacaktır. Tersi durumda hücreyi harekete geçirecek düzeyde sinyalin hücreye ulaşmadığı söylenebilir. Bundan dolayı hücre pasif (y = 0) durumdadır (Fausett 1994; Aktaran Ekinci, 2017).

Bununla birlikte, teorik bakımdan literatürü incelediğimizde çok sayı da farklı fonksiyon tipinin aktivasyon fonksiyonu olarak kullanılabildiği görülmektedir. Kullanılan farklı aktivasyon fonksiyonlarından bazılarına Şekil 3.3'te yer verilmiştir (Kröse ve Smogt, 1996; Aktaran Ekinci, 2017).



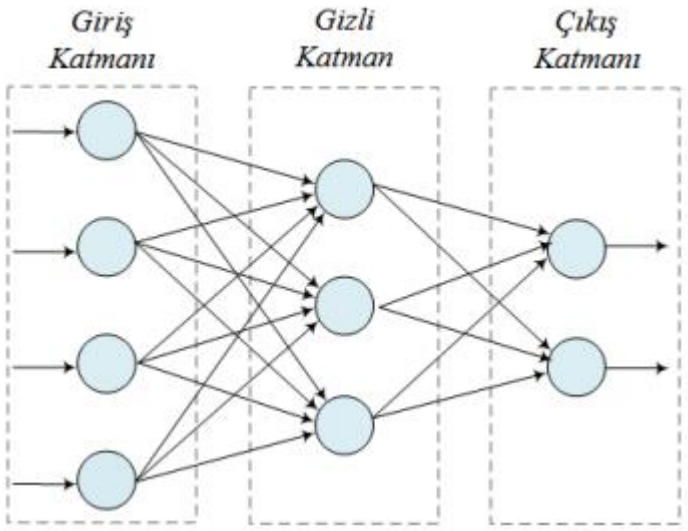
Şekil 3. 3. Aktivasyon fonksiyonları.

Şekil 3.3. incelendiğinde Aktivasyon fonksiyonları ve bu aktivasyon fonksiyonuyla belirlenen çıktı değerleri, yapay olarak tasarlanmış bir sinir hücresinin son aşama öğeleridir. Aynı zamanda her bir nöron hücresi yalnızca tek bir çıktısı olur. Diğer nöronlar için bu çıktı değerleri giriş değeri görevi görme niteliğine sahiptir (Mehrotra ve ark., 1996; Aktaran Ekinci, 2017).

3.1.2.1.2. Yapay sinir ağlarının yapısı

Sinir hücrelerinin çok sayıda farklı çeşide sahip bağlantılar ile bir araya gelip grup olarak çalıştıkları yapıya yapay sinir ağları denilmektedir. Esas olarak bu yapı giriş ve çıkış katmanları olarak şekillenmektedir. Tek katmanlı algılayıcı olarak

tanımlanan modeller sadece giriş ve çıkış katmanlarından oluşmaktadır. Fakat modellenmiş bazı sinir ağlarında gizli katman olarak nitelendirilip giriş ve çıkış katmanlarının arasında işlem sorumluluğunu üzerine alan yapılar da vardır. İçinde gizli katmanda barındıran ve çok katmanlı yapay sinir ağı yapısı olarak nitelendirilen yapıya bir örnek aşağıda Şekil 3.4'te gösterilmiştir (Ekinci, 2017).



Şekil 3. 4. Çok katmanlı bir sinir ağı yapısı.

Şekil 3.4'ü incelediğimizde giriş katmanı olarak nitelendirilen kısım yapay sinir ağına gelen bilginin sisteme yüklendiği ve sisteme yüklenen bu bilginin bir sonraki katmana yayıldığı kısımdır. Veri kümesinde bulunan öz nitelik kadar hücre giriş katmanında bulunur. Giriş katmanından gönderilen bilginin işlendiği asıl kısma gizli katman adı verilmektedir. Son kısımda yer alan çıkış katmanı ise gizli katmandan elde edilen bilgilerin yapay sinir ağına ait çıktı değerine çevrildiği katmandır.

Bir sinir ağı modeli tasarlanırken giriş ve çıkış katmanı olarak birer adet katman bulunurken gizli katmanın sayısı için bir sınırlama bulunmamaktadır (Ekinci, 2017).

Yapay sinir ağı hücrelerinden elde edilen çıktı değerlerinin aktarım yönleri göz önünde bulundurulduğunda; bu sinir ağı hücreleri ileri veya geri beslemeli sinir hücreleri olarak ikiye ayrılmaktadır.

Bilgi aktarımının tek doğrultuda olduğu ileri beslemeli yapay sinir ağları, esas olarak bir katmanı oluşturan sinir hücrelerinin çıktı değerlerinin, bir sonraki katmanda

bulunan sinir hücrelerine ağırlıklar aracılığı ile giriş değeri olarak gönderildiği sinir ağı modelidir (Yegnanarayana, 1999; Aktaran Ekinci, 2017).

Bu bakımdan ileri beslemeli yapay sinir ağlarının kullanım alanlarını incelediğinde çoğunlukla desen tanıma ve tahminleme problemlerinin çözümünde kullanıldığı görülmektedir (Annema, 2012; Aktaran Ekinci, 2017).

Yegnanarayana (1999) Diğer yandan çalışma şekli olarak geri beslemeli yapıya sahip yapay sinir ağlarının yapısı ve çalışma mantığı incelendiğinde, en az bir sinir hücresinden oluşan ve çıktı değerini kendisi dâhil bütün sinir hücrelerine giriş değeri olarak verebilen bir yapıdan oluştuğu görülmektedir. Geri beslemeli sinir ağlarında standart bir yapı bulunmamaktadır bundan dolayı geri besleme işlemi hücrenin kendisine ya da kendisinden hemen önceki katmanda yer alan hücrelere doğru olabilir (Ekinci, 2017).

He ve Xu (2010) Sonuç olarak çalışma şekli olarak geri beslemeli yapıya sahip yapay sinir ağlarının kullanım alanları incelendiğinde çoğunlukla; sinyal işleme ve doğrusal olmayan konveks programlama gibi problemlerin çözümünde kullanıldığı görülmektedir (Ekinci, 2017).

3.1.2.1.3. Yapay sinir ağlarında öğrenme stratejileri

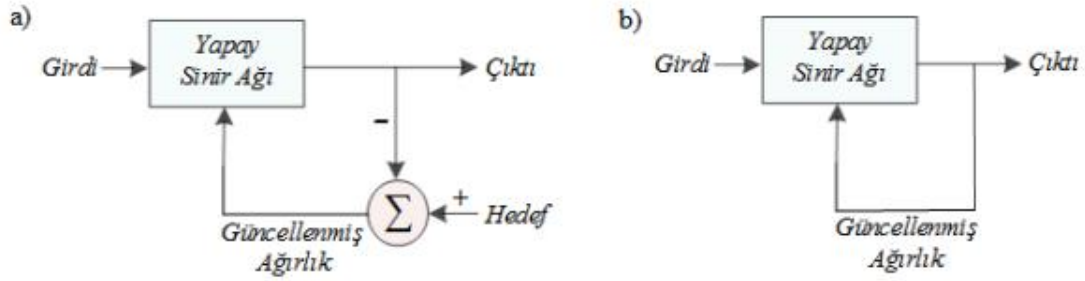
Zurada (1992) Öğrenme kavramını incelediğimizde, gözlemlenen değer veya durumların yorumlanmasıyla elde edilen tecrübeye ilişkin sürekli veya uzun süreli davranışsal sonuçlar doğurma durumu olarak tanımlanabilir. Öğrenme fiili hem canlılar hem de makineler için geçerlidir. Canlılara kıyasla makine öğrenmesi metotlarından biri olan yapay sinir ağlarında öğrenme süreci dolaylı olmayacak şekilde gerçekleşmektedir (Ekinci, 2017).

Jain ve ark. (1996) Öğrenme işlemi girdi-çıktı bağlantısı ile gerçekleşmektedir. Bu öğrenme işlemi yapay nöronlar arasında sağlanan bağlantıların ağırlıkları şeklinde depolanırlar. Temel olarak ağırlıkların üstünde iteratif güncellemeler yapıldığında başarılı sonucu verecek model bulunmaya çalışılmaktadır

Ağın girdiler üzerinde başarılı bir genelleme becerisi kazanması, en iyi performans olarak nitelenmektedir. Genelleme yeteneği yüksek olan sinir ağının test verisinde iyi sonuçlar vermesi beklenmektedir. Yapay sinir ağlarında 3 çeşit öğrenme yöntemi kullanılmaktadır. Bu yöntemler; gözetimli, gözetimsiz ve pekiştirmeli öğrenmedir (Ekinci, 2017).

Akış diyagramı Şekil 3.5 (a)'da (Zurada'dan, 1992) görülen gözetimli öğrenme yöntemi, önceden etiketi belirlenmiş veri kümesi üstünden çıkarım yapmaya çalışan öğrenme stratejisidir.

Gözetimli öğrenme mantığı ile çalışan bir sinir hücresinde, çıktı sonucunun hedef sonucundan hangi miktarda uzakta durduğu dikkate alınarak ağdaki ağırlıklar güncellenir. Bunun sonucunda sinir ağı girdi-çıktı ilişkisini öğrenir (Ekinci, 2017).



Şekil 3. 5.YSA'da öğrenme stratejileri: a) gözetimli öğrenme, b) gözetimsiz öğrenme.

Akış diyagramı Şekil 3.5 (b)'de görülen gözetimsiz öğrenme yönteminde çıktı değerleri herhangi bir hedef değeri ile karşılaştırılamadığı zamanlarda kullanılır. Bu öğrenme metodunda esas hedef var olan desenlerin keşfedilmesidir. Bundan dolayı bu öğrenme metodu çoğunlukla kümeleme yönteminde kullanılmaktadır (Ekinci, 2017).

Pekiştirmeli öğrenme metodunda, gözetimli öğrenme yöntemindeki gibi bir hedef değere sahip değildir. Bu metot ta öğrenme işi, çıktı değerinin ödüllendirilmesi ya da cezalandırılması şeklinde sonuçlanır (Ekinci, 2017).

3.1.2.1.4. Yapay sinir ağlarında öğrenme kuralları

Yapay sinir hücrelerinde öğrenme süreci incelendiğinde, esas olarak iki giriş değeri olan ağırlıklandırılmış giriş değeri ve eşik değer şeklinde gerçekleşmektedir. Ağırlık uzayı ve eşik değer uzaylarında yapılan çalışmalar sonucunda en yüksek performansa sahip sonuca ulaşmayı hedefleyen çeşitli öğrenme kuralları önerilmiştir (Ekinci, 2017).

3.1.2.1.4.1. Hebb öğrenme kuralı

1949 yılında Hebb'in geliştirdiği bu gözetimsiz öğrenme yöntemi, yapay sinir ağlarında gerçekleşen öğrenme sürecinin temelini oluşturmaktadır. Hebb kuralı çok basit bir ilkeye dayanmaktadır. Bu sinir ağının tasarımında İkili (binary) çıktı değeri üretimi vardır.

Bu tasarıma göre, iki nöron arasında bilgi akışı varsa ve bu iki nöron hücresi aynı zamanda aktif ya da pasif ise ağırlık (bağlar) güçlendirilmelidir. Aksi takdir de ağırlık, çıktı değerine kıyasla değişmeyebilir ya da azalır. Denklem (3.3)'te t. iterasyonda hücrelere ait ağırlıkların ne şekilde güncelleneceği belirtilmiştir (Fausett, 1994; Aktaran Ekinci, 2017).

$$w_{i_{(t+1)}} = \omega_{i_{(t)}} + y_i x_i \tag{3.3}$$

Denklemi incelediğimizde; nöron hücreleri {(0), (1)} gibi ikili çıktı değeri veren bir sinir ağında, çıktı ve girdi değerlerinin birbirinden farklı olursa ağırlıkta bir değişim gerçekleşmeyecektir. Farklı durumda nöronları {(−1), (1)} gibi iki uçlu çıktı değeri üreten bir sinir ağındaysa çıktı değeri ve girdi değerinin birbirinden farklı olması halinde ağırlıkta azalış gerçekleşecektir (Ekinci, 2017).

3.1.2.1.4.2. Perceptron öğrenme kuralı

1958 yılında ikili sınıflandırma problemlerinde kullanılmak üzere Rosenblatt tarafından geliştirilen perceptron (algılayıcı) öğrenme kuralı, gözetimli öğrenme kurallarından biridir. Perceptron öğrenme kuralını inceleyecek olursak, bu kural çıktı değerinin (y_i), hedef değer (d_i) üstünden değerlendirilmesi ile tanımlanmaktadır.

Eğer çıktı değeri ile hedef değeri karşılaştırıldığında uyuşmazlık tespit edilirse bu ağda yer alan ağırlıkların ve bu ağırlıklara ait eşik değerlerinin güncellenmesi gerekliliği ortaya çıkar. Mitchell (1997) Bu güncelleme çalışmasında öğrenme katsayısı olarak nitelendirilen; küçük değerli ve pozitif bir sayı olan ($0 \leq \eta \leq 1$) bir sayı kullanılmaktadır. Öğrenme katsayısının amacı temel olarak, hedef değere ulaşma süreci sırasında yapılan güncellemenin adım büyüklüğünün ne kadar olacağını belirler (Alavala, 2012; Aktaran Ekinci, 2017).

$$w_{i(t+1)} = w_{i(t)} + \eta(d_i - y_i)x_i \tag{3.4}$$

$$b_{i(t+1)} = b_{i(t)} + \eta(d_i - y_i) \tag{3.5}$$

3.1.2.1.4.3. Delta öğrenme kuralı

Bir diğer öğrenme kuralı Widrow ve Hoff tarafından geliştirilen ve tek katmandan oluşan Adaline (adaptive linear element) modelidir. Madaline (Multiple Adaline) yapısı ise iki veya daha fazla Adaline ünitesinin kullanılması ile oluşturulan iki katmanlı yapıya verilen addır (Ekinci, 2017). Kullanılan öğrenme kuralı Adaline/Madaline modelinin perceptronlardan farkını belirler. En küçük ortalama kareler hesaplaması Widrow ve Hoff (delta) öğrenme kuralında kullanılmaktadır. Bu öğrenme kuralının temel amacı çıktı değeri ile hedef değer arasındaki karesel hataların minimize edilmesidir. Alavala (2012) Aşağıdaki Denklem (3.6) da hata değerinin hesaplanması görülmektedir (Fausett, 1994; Aktaran Ekinci, 2017).:

$$E = \frac{1}{2}\sum_{i}(d_i - y_i)^2 \tag{3.6}$$

Delta öğrenme kriterin de, hatanın ağırlığa göre olan değişimi, ağırlıklardaki değişimle orantılıdır.

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} \tag{3.7}$$

Gradyan iniş (gradient descent) metoduyla hata fonksiyonunu enküçükleyecek olan wi değerleri bulunur (Zurada, 1992; Aktaran Ekinci, 2017).

$$\frac{\partial E}{\partial w_i} = \frac{\partial\left(\frac{1}{2}(d_i - y_i)^2\right)}{\partial w_i}$$

$$= \frac{\partial\left(\frac{1}{2}(d_i - y_i)^2\right)}{\partial y_i} . \frac{\partial yi}{\partial w_i}$$

$$= -(d_i - y_i) . \frac{\partial yi}{\partial w_i} \tag{3.8}$$

$$= -(d_i - y_i) . \frac{\partial yi}{\partial z_i} . \frac{\partial zi}{\partial w_i}$$

$$= -(d_i - y_i) . x_i$$

Denklem (3.9)'da ağırlıktaki değişim ifade edilmektedir.

$$\Delta w_i = w_{i(t+1)} - w_{i(t)} = \eta(d_i - y_i)x_i \tag{3.9}$$

Hedef değer ile gerçekleşen çıktı değeri arasındaki fark δ ile ifade edersek, ağırlıkların ve bu ağırlıklara ait aşağıdaki denklemeler de eşik değerinin yenilenmesi görülmektedir.

$$w_{i(t+1)=}w_{i(t)} + \eta\delta_i x_i \tag{3.10}$$

$$b_{i(t+1)} = b_{i_{(t)}} + \eta\delta_i \tag{3.11}$$

3.1.2.1.4.4. Kohonen öğrenme kuralı

Gözetimsiz öğrenme kurallarından biridir. 1982 yılında Kohenen tarafından geliştirilmiştir. Bu öğrenme kuralında bütün sinir hücreleri öğrenmek için birbirleri ile kıyasıya rekabet etmektedir. Bu rekabette kazanan nöronlar girdi değerine en yakın ağırlığı taşıyan nöronlardır.

Bu öğrenme kuralına göre kazanan hücrelerin çıktı değerleri 1 olurken kaybeden diğer hücrelerin çıktı değerleri ise 0 olacaktır. Bu durumdan dolayı "kazanan hepsini alır" kuralı olarak da adlandırılmaktadır(Negnevitsky, 2005; Aktaran Ekinci, 2017). Bu kurala ait denklem Denklem (3.12)'de verilmiştir

$$w_{i(t+1)=}w_{i(t)} + \eta(x_{i-}w_{i(t)}) \tag{3.12}$$

3.1.2.1.5. Yapay sinir ağı modelleri

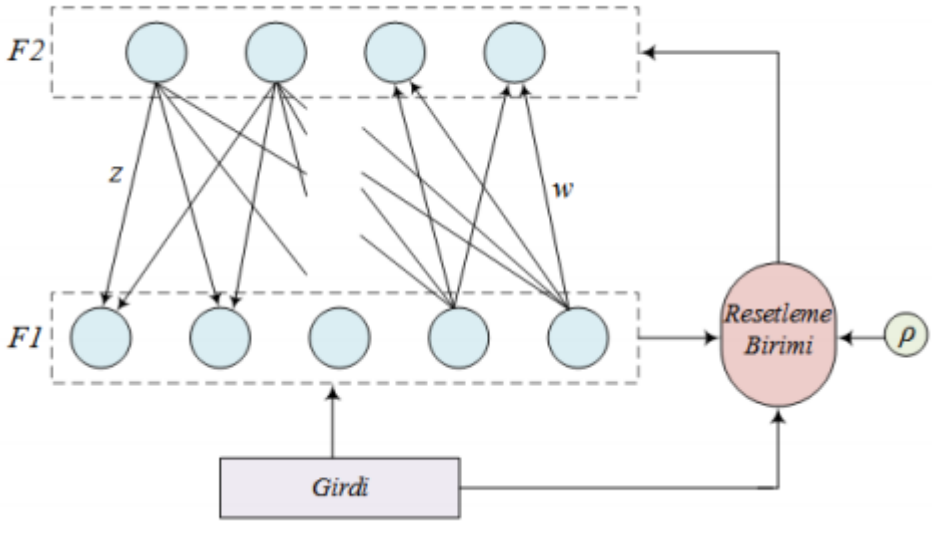
Yapay sinir ağı modelleri geliştirilirken geliştirilen modellerin katman sayısı, modelde yer alan sinir hücreleri ve modeldeki katmanlar arasındaki besleme yönü, modellerin öğrenme yöntemleri olarak belirtilebilecek tercihlerin farklı tarzlarda, benzer veya farklı problem tarzları için kullanılmasıyla birbirinden farklı çok sayıda yapay sinir ağı modeli geliştirilmiştir (Ekinci, 2017).

3.1.2.1.5.1. Adaptif rezonans teorisi

1986 yılında Carpenter ve Grossberg tarafından yapay sinir ağı modellerinden olan Adaptif rezonans teorisi (ART), geliştirilmiştir. ART gözetimsiz öğrenme stratejisine sahiptir ve gerçek zamanlı öğrenme sağlayan bir sinir ağı modelidir. ART modelinin yeni durumlar karşısında adapte olma gücü yüksektir. ART bu gücünü öğrenme ve unutma işlemlerini aynı anda gerçekleştirebilmesinden almaktadır. (Öztemel, 2012; Aktaran Ekinci, 2017).

ART Şekil 3.6'da (Ekinci, 2017) görüldüğü gibi, $F1$ ve $F2$ olarak adlandırılan 2 katmana sahiptir ve bu katmanlar birbirine iki yönlü bağlıdır. (Chakraborty, 2010). Bundan dolayı bu ağda nöronlar hem ileri hem de geri beslemeli olacak şekilde bir yapıya sahiptirler. Burada $F1$ girdi değerlerinin özelliklerini temsil ederken, $F2$ değeriyse çıktı katmanını sembolize etmektedir. Rekabetçi bir öğrenme kuralı uygulanarak $F2$ katmanında çıktı oluşturulur.

Daha sonra oluşturulan bu çıktı değerinin, giriş desenine olan benzerlik derecesi bulunmaya çalışılır. Araştırılan bu benzeme derecesi benzerlik katsayısı (ρ) olarak adlandırılmış bir parametre ile denenir. Bu sınama sonucunda nihai karar ise $F1$ katmanından sinyal alan resetleme ünitesindedir (Carpenter ve Grossberg, 1987; Aktaran Ekinci, 2017).



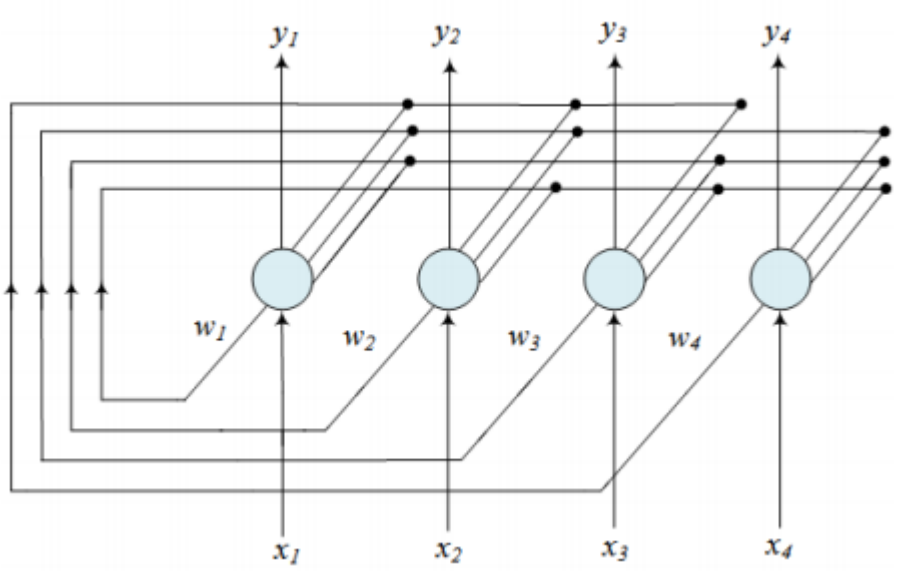
Şekil 3. 6. ART ağlarının genel yapısı.

3.1.2.1.5.2. Hopfield ağı

Hopfield ağı 1982 yılında Hopfield tarafından tek katmanlı olarak tasarlanmıştır. Bu ağ genel olarak incelendiğinde tekrar beslemeli (recurrent) olarak çalışan ve tüm sinir hücrelerinin birbiriyle bağlı olan simetrik bir yapıya sahip olduğu görülmektedir ünitesindedir (Hajek, 2005 ; Aktaran Ekinci, 2017).

Aşağıda Şekil 3.7'de (Ekinci, 2017) Hopfield ağının yapısı görülmektedir. Metot olarak özelleştirilmiş Hebb öğrenme kuralı ile Hopfield ağları eğitilmektedir. Öğrenme katsayısını kullanılmasından dolayı bu yöntem klasik Hebb öğrenme kuralından farklılık göstermektedir.

Bir Hopfield ağı eğitilirken sisteme verilen örüntüler bellekte saklanmaktadır. Öğrenimin denenmesi aşaması olan test aşamasında ise, bellekte saklanan örüntüler, gürültülü ya da kısmi ipuçları verilmiş olan desenler ile eşleştirilmeye çalışılır (Sezgin ve ark. ,2012; Aktaran Ekinci, 2017).



Şekil 3. 7. Hopfield ağının yapısı.

McCulloch-Pitts sinir hücresi modeli Kesikli Hopfield ağlarında işaret aktivasyon fonksiyonuna sahiptir ve burada kullanılır (Negnevitsky, 2005; Aktaran Ekinci, 2017).

Kesikli ağlar ile sürekli Hopfield ağları aynı yapıya sahiptir. Fakat Hopfield ağında sürekli olan ve sigmoid fonksiyonuna benzer özellikler taşıyan bir aktivasyon fonksiyonu bulunmaktadır (Rojas, 1996; Aktaran Ekinci, 2017).

3.1.2.1.5.3. Kohenen ağı (SOM)

1984 yılında Kohenen tarafından öne sürülen SOM (self-organizing maps), beynimizde bulunan çok sayıda çalışma modelinden biri olarak tanımlayan ve ilişkisel hafıza (associative memory) olarak adlandırılan kavram üzerine inşa edilmiştir (Demartines ve Blayo, 1992 ; Aktaran Ekinci, 2017).

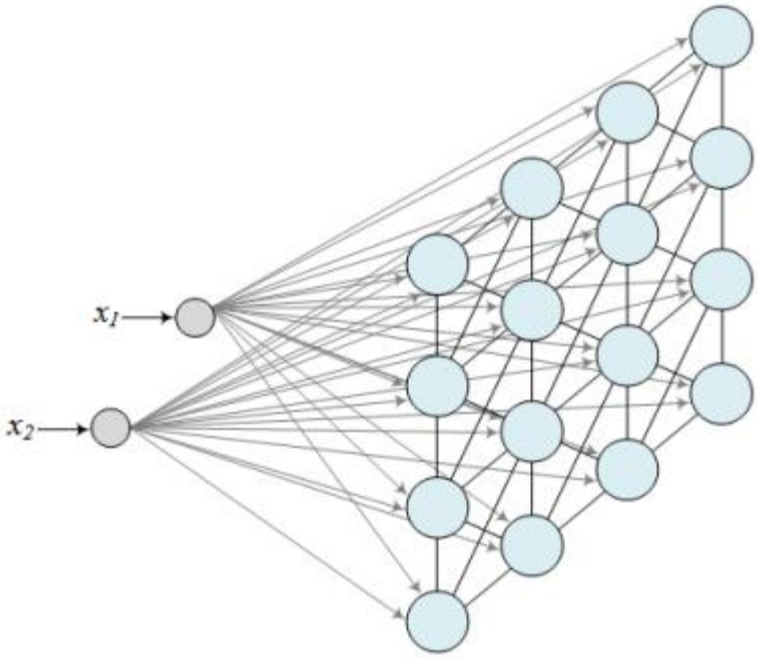
Kavram olarak İlişkisel hafızayı incelersek, duyu organları vasıtası ile beyine gönderilen uyarıların, bellek de önceden yer alan desenlerle ilişki kurulduğu bellek tipi olarak açıklanmaktadır (Khan ve Makwana, 2005 ; Aktaran Ekinci, 2017).

Şekil 3.8'de (Ekinci, 2017) yapısı görülen SOM, 2 adet katmana sahiptir bu katmanlar bir adet girdi ve iki boyutlu çıktı katmanından meydana gelmektedir. Girdi katmanı tarafından üretilen her bir çıktı, çıktı katmanında yer alan bütün sinir hücrelerine gönderilir. Gönderilen bu çıktılar sayesinde çıktı katmanında yer alan sinir hücreleri rekabetçi öğrenme kriterleri ile eğitilirler.

Bu rekabette başarılı çıkan sinir hücresiyle söz konusu olan sinir hücresinin yakınında yer alan diğer sinir hücreleri arasında komşuluk bağı tahsis edilir. Rekabette başarılı çıkan sinir hücresi ve komşuları için ağırlık vektörü güncellenir. Daha sonra; rekabette başarılı çıkan sinir hücresi en fazla, onun komşuları ise rekabette başarılı çıkan nörona olan mesafeleriyle ters orantılı olacak şekilde girdi vektörüne yakınsarlar (Gutierrez-Osuna, 2002; Aktaran Ekinci, 2017).

Bu öğrenme süreci ilerlemesinin sonunda tabiat gereği komşu sinir hücresi sayısı azalmaktadır ve başarılı çıkan nöronlar çevresinde gruplaşma oluşacaktır. Bundan

dolayı, Kohonen ağları olarak nitelenen ağlar kümeleme problemlerinin çözümlenmesine gayet uygundur ((Beale ve Jackson, 1990; Aktaran Ekinci, 2017).



Şekil 3. 8. Kohonen ağının (SOM) yapısı.

3.1.2.1.5.4. Sayaçlı yayılım ağı

1988 yılında Hecht-Nielsen tarafından geliştirilmiş olan Sayaçlı yayılım ağının çok katmanlı bir yapısı vardır. Yapısal olarak incelendiğinde sayaçlı yayılım ağı Kohonen ağı ve Grossberg outstar öğrenme kriterlerinin kombinasyonlarından meydana gelmektedir (Sivanandam ve ark. , 2006; Aktaran Ekinci, 2017).

Girdi vektörleri Kohonen katmanına gönderilir ve bu vektörler burada kümelenirler. Outstar öğrenme kuralıyla kümelenmiş veri Grossberg katmanında eğitilir sonradan sinir ağının çıktılarını oluşturur (Taylor , 2006; Aktaran Ekinci, 2017).

3.1.2.1.5.5 Çok katmanlı algılayıcı

1969 yılında Minsky ve Rupert'in yazdığı "Perceptrons" adlı kitapta, perceptron lar incelenmiş ve perceptronların yalnızca doğrusal yolla ayrılabilen problemleri çözme becerisine sahip olduğu, ancak XOR tarzında olan ve doğrusal olamayan problemlere için herhangi bir çözüm geliştirilmediği belirtilmiştir.

Yapay sinir ağları alanındaki çalışmaları nerdeyse durduracak düzeyde etki eden bu soruna; 1974 yılında Werbos'un temellerini attığı daha sonra 1986 yılında Rumelhaart vd. nin ilerlettiği geri yayılım algoritması ile (genelleştirilmiş delta öğrenme kuralı) sayesinde çözüm sağlanabilmiştir (Smith, 1997; Aktaran Ekinci, 2017).

Sağlanan bu çözüm esas olarak; ileri beslemeli ve çok katmanlı bir sinir ağında hatanın çıktı katmanından başlamak üzere geriye doğru gönderilmesi ile ağırlıkların düzenlemesi fikrine dayanmaktadır. Belirtilen bu durumdan dolayı bu tarz ağlar, geri yayılım ağları olarak nitelendirilmiştir (Alavala, 2012; Aktaran Ekinci, 2017).

Geri yayılımlı ağlarda öğrenme süreci incelendiğinde dört temel aşamadan oluştuğu görülmektedir. bu aşamalar (Sivanadam ve ark. , 2006; Aktaran Ekinci, 2017):

1. Giriş ağırlıklarının belirlenmesi
2. Girdilerin ileri yönde akışı
3. Hatanın geri yayılımı
4. Ağırlık ve eşik değerlerinin yeniden düzenlenmesi

3.1.2.1.5.5.1. Genelleştirilmiş delta kuralının türetilmesi

Denklem (3.10)'da iki kutuplu çıktı değerleri veren bir tek sinir hücresinde delta kriteri ile hatanın ağırlıklara ne düzeyde etkileyeceği görülmektedir. Çoğunlukla sigmoid fonksiyonu olacak şekilde, doğrusal olmayan aynı zamanda türevlenebilen aktivasyon fonksiyonu işletilen çok katmanlı algılayıcılar (MLP) da delta kuralının

genelleştirilmesine ihtiyaç duyulmaktadır (Kriesel, 2005; Aktaran Ekinci, 2017). Hatanın geriye yayılımını Çıktı katmanından başlayıp girdi katmanına doğru adım adım incelersek;

Şekil 3.9'daki (Ekinci, 2017) gibi bir yapısı olan sinir ağının gizli katmanında yer alan j. Nörondan, wjk ağırlığı üzerinden girdi değeri alan çıktı katmanının k. Nöronunun hata fonksiyonu Denklem (3.13) de ki gibi belirtilir.

$$E = \frac{1}{2}\sum_{k}(d_k - y_k)^2 \tag{3.13}$$

Gradyan iniş metodu ile hata fonksiyonunu enküçükleyecek olan wjk değerleri araştırılır:

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial wjk} \tag{3.14}$$

Hatanın ağırlıklara göre dönüşümü, zincir kuralı ile genişletildiğinde

$$\frac{\partial E}{\partial wjk} = \frac{\partial E}{\partial y_k}.\frac{\partial y_k}{\partial z_k}.\frac{\partial z_k}{\partial w_{jk}}$$

$$= \frac{\partial\left[\frac{1}{2}(d_k - y_k)^2\right]}{\partial y_k}.\frac{\partial yk}{\partial zk}.\frac{\partial zk}{\partial w_j k} \tag{3.15}$$

$$= -(d_k - y_k).\frac{\partial yk}{\partial zk}.\frac{\partial zk}{\partial w_j k}$$

$$= -(d_k - y_k)\, f'(z_k) x_k$$

İfadesi elde edilir.

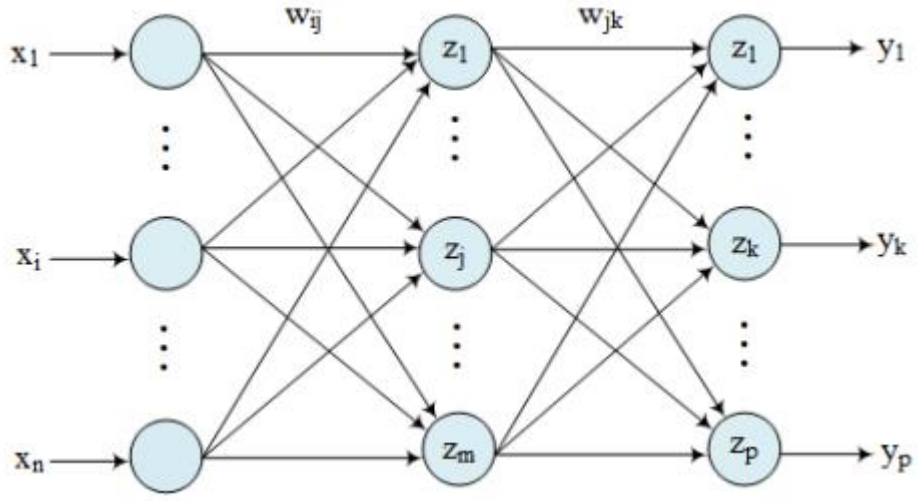
$$\delta = -(d_k - y_k)\, f'(z_k) \tag{3.16}$$

Olmak üzere çıktı katmanına bağlanan ağırlıklar Denklem (3.17) ile düzenlenir. Bu denklemdeki η öğrenme katsayısını göstermektedir. Aynı zamanda ağırlıkların değişim büyüklüğüne de karar vermektedir (Ekinci, 2017).

$$w_{jk_{(t+1)}} = w_{jk_{(t)}} + \eta \delta_k\, x_k \tag{3.17}$$

Denklem (3.17)'de tanımlanan işlem, çıkış katmanına varan bütün bağlantılara ağırlık değerlerinin güncellenmesi için uygulanır. Fakat hedef değere yetişmek amacıyla gizli katmana gönderilen hatalı ağırlıkların da düzenlenmesine ihtiyaç duyulmaktadır (Freeman ve Skapura, 1991; Aktaran Ekinci, 2017).

Bu çerçevede gizli katmanda yer alırken hata en küçüklenmelidir. Ancak gizli katmanın çıktı değerini kıyaslayabilecek bir hedef değer yoktur. Bundan dolayı gizli katmanın ağırlıklarını belirleyebilmek için, toplam hata değeri ile gizli katman arasında matematiğe dayanan bir ilişki oluşturulmalıdır (Ekinci, 2017).



Şekil 3. 9. Geri yayılım ağının yapısı.

Gizli katmanın j. Nöronuna gönderilen girdiler, girdi katmanının i. Nöronundan wij ağırlığıyla iletilmektedir. Denklem (3.18) de hatanın wij ağırlığına göre değişimi, zincir kuralıyla genişleterek ile gösterilir.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial z_k} \cdot \frac{\partial z_k}{\partial y_j} \cdot \frac{\partial y_j}{\partial z_j} \cdot \frac{\partial z_j}{\partial w_{ij}}$$

$$= -(dk - y_k) f'(z_k) w_{jk} f'(z_j) x_j \tag{3.18}$$

$$= \delta_k w_{jk} f'(z_j) x_j$$

Denklem (3.18)'de görüldüğü üzere gizli katmana ait hata değeri, çıktı katmanında iken hesaplanan hatanın (δk), ağırlıklar (wij),üzerinden geriye gönderilmesi ile hesaplamaktadır. Buna dayanarak j. Gizli katmana gönderilen ağırlıkların güncellenmesi Denklem (3.19)'da belirtilen işleme ait formül ile gerçekleşir (Ekinci, 2017).

$$w_{ij_{(t+1)}} = w_{ij_{(t)}} + \eta f'(z_j) x_j \sum \delta_k w_{jk} \tag{3.19}$$

Çıktı katmanı ile gizli katmanlar için ağırlıklar tekrar düzenlendikten sonra, ağa yeni girdi değerleri konulur ve en baştan itibaren süreç tekrarlanır. İstenilen hata çıktısı elde edildiğinde yineleme biter (Freeman ve Skapura, 1991; Fausett, 1994 ; Aktaran Ekinci, 2017).

3.1.2.1.5.5.2. Öğrenme katsayısı

Öğrenme katsayısı geri yayılım algoritmasında, (0,1] Aralığında değer alan ve ağırlıkların güncellenme büyüklüğünü etkileyen bir parametredir. Öğrenme

katsayısının küçük bir değere karşılık gelmesi durumunda, ağırlıkların güncellenmesi işleminin yoğun şekilde tekrar edilmesine sebep olacağından modelin eğitim vaktini doğal olarak arttıracaktır. Diğer taraftan öğrenme katsayısının büyük seçilmesi çözümde büyük artışlara neden olacaktır. Bu durum da bütünsel en iyiyi kaçırma riskinin ortaya çıkmasına yol açmaktadır (Haykin, 2009; Aktaran Ekinci, 2017).

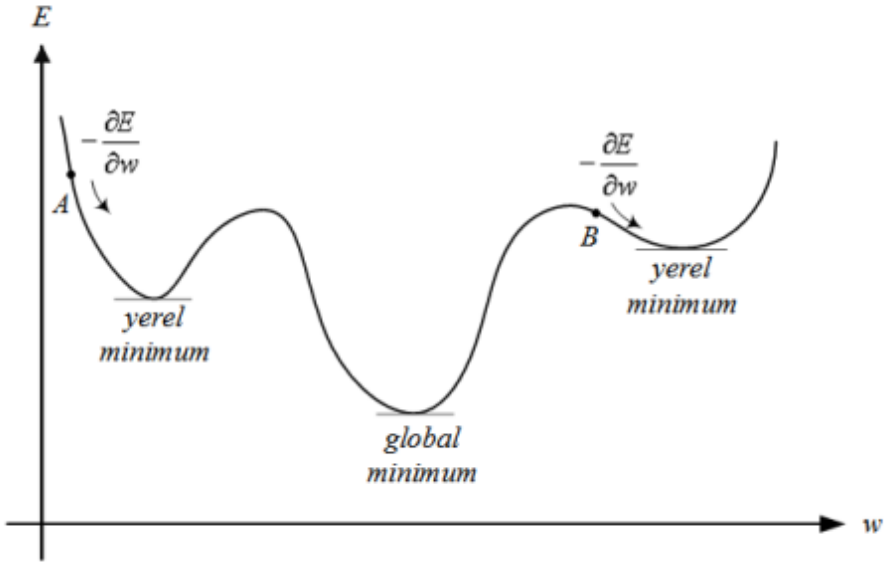
3.1.2.1.5.5.3. Momentum terimi

1997 yılında Gurney tarafından ele alınan ve Şekil 3.10'daki (Ekinci, 2017) gibi iki ve daha fazla ekstremum noktasına sahip hata-ağırlık fonksiyonlarında, gradyan iniş A veya B gibi bir yerden başlarsa çözüm yerel minimuma takılacaktır. Gradyan iniş yöntemi, hatayı azaltma çabasına sahip olduğu için yerel minimuma ulaştıktan sonra hata fonksiyonu yükseldiği kısma yükselemeyecek, bunun için bütünsel minimuma varamayacaktır. Bunun sonucunda algoritma, bütün eğitim verisine karşılık nispi bir çözüm yaratacaktır.

Bu sorunu aşabilmek amacıyla momentum (μ) olarak adlandırılan bir terim geri yayılım algoritmasına eklenmiştir. $0 \leq \mu \leq 1$ Aralığında değerler alabilen momentum teriminin dahil edilmesiyle ağırlıklar Denklem (3.20)'de yer alan formül ile güncellenir (Ekinci, 2017).

$$w_{jk_{(t+1)}} = w_{jk_{(t)}} + \eta\delta_k x_k + \mu(w_{jk_{(t)}} - w_{jk_{(t-1)}})$$

$$w_{jk_{(t+1)}} = w_{jk_{(t)}} + \eta\delta_k x_k + \mu\Delta w_{jk_{(t)}} \tag{3.20}$$



Şekil 3. 10. Hata fonksiyonunda yerel ve bütünsel minimum.

Bir önceki iterasyonda ki değişimin mevcut iterasyonda ki değişime Momentumlu geri yayılım algoritmasında eklenir. Bunun sonucunda yerel minimuma takılı kalan ağlara, sıçrama yaparak bütünsel minimuma erişebilme potansiyeli ve salınımlıların engellenmesi ile sonuca daha çabuk yetişme becerisi kazandırılır (Öztemel, 2012; Aktaran Ekinci, 2017). Belirtilen tüm bu durumların sonucunda 1986 yılında Rumelhart vd. nin ifade ettiği gibi, momentum katsayısı hem çözümü hızını arttırır hem de yerel minimumdan kaçınmaya da destek olur.

3.1.2.2 Karar Ağacı

Sınıflandırma, regresyon ve tahminlemenin makine öğrenme işlemleri için kullanılan popüler yöntemler arasında karar ağacı da bulunmaktadır. Karar ağacı kolay yorumlanır, sürekli ve ayrık özellikleri ele alır, özellik ölçeklendirmesi gerektirmez. Bu sebepler ve çok sayıda avantajı göz önünde bulundurulduğundan yoğun şekilde kullanılmaktadır. Diğer sınıflandırma yöntemlerinde olduğu gibi bu metotta da 2 aşamalı bir işlem gerçekleştirilir. Bu aşamalar; öğrenme ve sınıflandırmadır.

1. Bu aşama da yani öğrenme aşamasında, sınıflandırma algoritması tarafından önceden etiketlenmiş eğitim verisi model üretmek amacı ile analiz edilir. Analiz sonucunda öğrenilen bilgi bir ağaç yapısı üzerinde modellenir ve bu model karar ağacı olarak gösterilir. Bir çeşit karar verme kuralları ile karar ağacının yapısında bulunan kök, ara düğümler ve yapraklar oluşturulur. Bağlaç görevini üstlenen bu kurallar, belirlenmiş şartlar altında ulaşılacak sonucu belirtir.
2. Bu aşama da yani sınıflama aşamasında ise test verisi kullanılarak sınıflama kriterlerinin ya da karar ağacının çıkardığı sonuçların doğruluğu tespit edilir. Sonra öğrenme kümesi oluşturulur. Daha sonra kümedeki örnekleri en başarılı şekilde ayıran öznitelik tespit edilir. Tespit edilen öznitelikle ağaca ait bir düğümü belirlenir.

   Sonradan bu düğümden çocuk düğümleri (ağacın yaprakları) oluşturulur. Bu süreç özyinelemeli olarak tekrar edilir ve bu tekrarlama periyotlarının sonucunda tekrarlama aksiyonunun tahmin üzerinde bir etkisi kalmadığı anlaşılana kadar devam eder. Bu süreç sonunda elde edilen ağaca ait yapraklarda sonuç değerleri yer alır. Aşağıda Tablo 3.1' de karar ağacına bir örnek görülmektedir (Özdeş, 2017).

Çizelge 3. 1. Örnek karar tablosu.

Hafta(Örnek)	Hava	Aile	Para	Sonuç
1	Güneşli	Evet	Var	Sinema
2	Güneşli	Hayır	Var	Tenis
3	Rüzgârlı	Evet	Var	Sinema
4	Yağmurlu	Evet	Yok	Sinema
5	Yağmurlu	Hayır	Var	Ev
6	Yağmurlu	Evet	Yok	Sinema
7	Rüzgârlı	Hayır	Yok	Sinema
8	Rüzgârlı	Hayır	Var	Alışveriş
9	Rüzgârlı	Evet	Var	Sinema
10	Güneşli	Hayır	Var	Tenis

Çizelge 3.1'de (Özdeş, 2017) verilen değerlerden ayırt edebilme katsayısı en yüksek öznitelik belirlenir ve bu öz nitelik daha sonra ağacın kökü şeklinde ifade edilir.

Nihayetinde ağacın çocuk düğümü olan A düğümüne ait alt veri kümesi belirlenir. Alt veri kümesi tespit edilirken, örneklerin hepsi aynı sınıftaysa ve örnekleri birbirinden ayıracak başka bir öznitelik yoksa ve kalan özniteliklerin değerine sahip örnek kalmamışsa çalışma bitirilir. Bu özelliklerin geçerli olmadığı durumlarda da yeniden örnekleri en iyi ayıran öznitelik belirlenir. Yani her bölüm, bir ağaç düğümünde bilgi kazanımını en yüksek seviyeye çıkarmak amacıyla muhtemel bölünmelerden en başarılı bölünme tercih edilerek gerçekleştirilir (Özdeş, 2017).

3.1.2.2.1 Bilgi Kazancı

Karar ağacı oluşturuldukları vakit amaç olarak en ayırt edici özellikleri bulmaktır. Bu özelliğin belirlenebilmesi için her özellik için bilgi kazancının hesaplanması gerekmektedir. Karar ağacında bilgi kazancının ölçülmesinde Entropi (Entropy) kullanılır (Safavian ve ark. (1991); Aktaran Özdeş, 2017).

Entropi ifadesini kelime anlamı olarak incelediğimizde düzensizlik (impurity) olarak açıklanabilir. Entropinin hesaplanması çalışmasına bakıldığında, sınıf etiketlerine dayalı olarak hesaplandığı görülmektedir. Genel olarak tanımlanacak olursa entropi ifadesi belirsizliği ve beklenmeyen durumun meydana gelme olasılığını ifade eder. Entropi kavramı ile bilgi kazancı kavramı kavramsal ve işlevsel olarak birbirlerinin zıttıdır. Yani Entropi değeri 0'a karşılık geliyorsa bilgi kazanımı 1 olarak karşımıza çıkacaktır. Örneğin, on farklı sınıf için özelliğimiz on farklı sonuca karşılık geliyorsa bu durumda Entropi 0 olduğu belirtilir (Özdeş, 2017).

Aşağıda Entropi hesaplamanın formülü verilmiştir.

$$H(x) = E\big(I(X)\big) = \sum_{i=1}^{n} p(x_i) log_2 \left(\frac{1}{p(x_i)}\right) = -\sum_{i=1}^{n} p(x_i) log_2 \left(\frac{1}{p(x_i)}\right) \quad (3.21)$$

Yukarıda verilen karar tablosuna (T kümesi) göre entropi değeri:

$$H(T) = -\left(\frac{6}{10}\right) log_2 \left(\frac{6}{10}\right) - \left(\frac{2}{10}\right) log_2 \left(\frac{2}{10}\right) - \left(\frac{1}{10}\right) log_2 \left(\frac{1}{10}\right) - \left(\frac{1}{10}\right) log_2 \left(\frac{1}{10}\right)$$

$$H(T) = 1{,}571$$

A niteliğinin T veri kümesindeki bilgi kazancı:

Bilgi Kazancı (T,A)=Entropi(T) - ∑P(v) Entropi ($T(v)$)

V: A' nın değeri

P(v)=|T(v)| / |T|

Her bir özellik için bilgi kazanımı hesaplanır;

Bilgi Kazancı (T, $hava$)

= Entropi (T) − (($P(güneşli)$ Entropi ($Tgüneşli$)

+ $P(rüzgarlı)$ Entropi ($Trüzgarlı$)

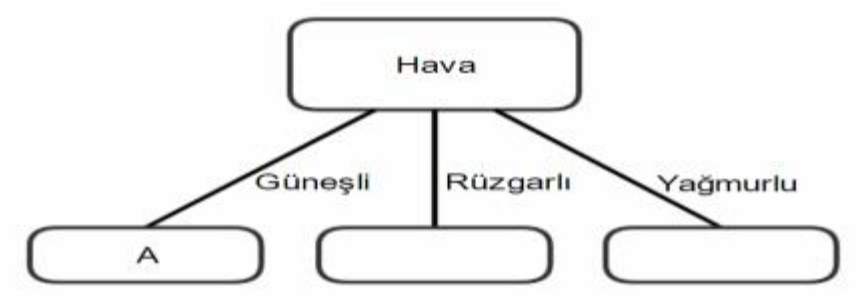
+ $P(yağmurlu)$ Entropi ($Tyağmurlu$)

=0,70

Bilgi Kazancı (T,aile) =0,61

Bilgi Kazancı (T, para) =0,2816

Hava özelliği yukarıdaki hesaplanan bilgi kazançlarıyla kıyaslandığında en yüksek bilgi kazancına sahip olduğundan dolayı en ayırt edici özellik olarak belirlenmiştir (Özdeş, 2017).



Şekil 3. 11. Oluşturulan karar ağacı.

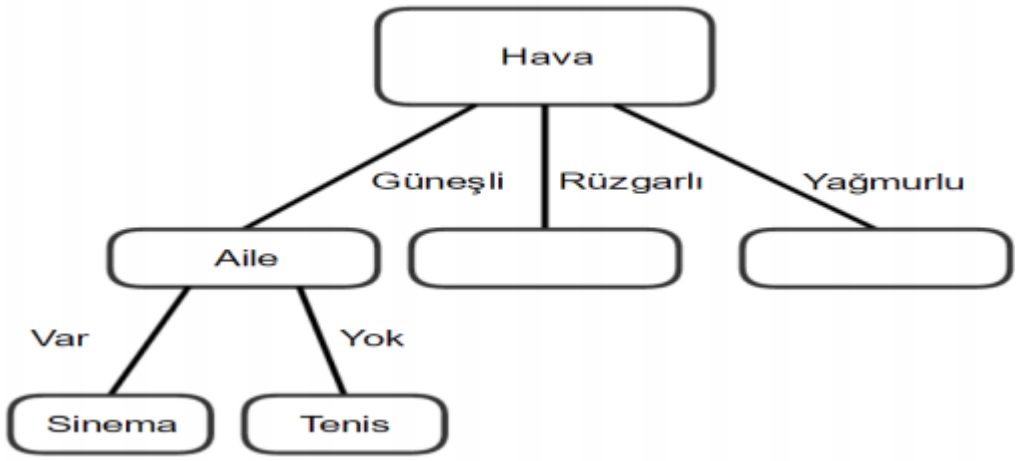
Ağacın çocuk düğümü olarak nitelenen ve Şekil 3.11 de (Özdeş, 2017) görülen A düğümüne ait alt veri kümesi tespit edilir ve her alt küme için tekraren bilgi kazancı hesaplanarak en ayırt edici özellik bulunur.

$Gain(T, para)$ = 0,281645

Aşağıda verilen Çizelge 3.2 de (Özdeş, 2017) havanın durumunun güneşli olduğu zamanlar incelenmiştir. Bu tablodan çıkarılan bilgi kazançları incelendiğinde ayırt etme gücü en yüksek olan özellik aile olarak belirlenmiştir. Örneklerin tümü aynı sınıfa ait, örnekleri bölecek ayırt edici nitelik kalmamış ya da kalan özelliklerin değerine sahip örnek bulunmayana kadar ayırt edici özellik tespit etme süreci her bir düğüm için devam eder (Özdeş, 2017).

Çizelge 3. 2. Ayırt edici özellik bulunduktan sonra karar tablosu.

Hafta(Örnek)	Hava	Aile	Para	Sonuç
1	Güneşli	Evet	Var	Sinema
2	Güneşli	Hayır	Var	Tenis
3	Güneşli	Hayır	Var	Tenis



Şekil 3. 12. Karar ağacı (İkinci adım).

Yukarıda Şekil 3.12 de (Özdeş, 2017) örnek olarak verilen karar ağacı uygulamasına göre yinelemeli olarak bulunan ayırt edici özellikler son buluncaya kadar işleme devam edilmiştir ve bu durumun sonucunda ağacın kökünde bulunan hava parametresi ayır edici özellikler arasında en başarılı paremetre olduğu

görülmüştür. Çizelge 3.2'de verilen havanın güneşli olma durumuna göre bilgi kazanımlarına incelendiğinde aile parametresi en ayırt edici özellik olarak belirlenmiştir. Normal de havanın niteliğinin her bir farklı parametresine göre bu işlemler tekrarlanır fakat yukarıdaki şekil 3.12 de sadece havanın güneşli olması incelenmiştir (Özdeş, 2017).

3.1.2.2.2 Karar ağacı algoritma türleri

Literatüre bakıldığında farklı türlerde karar ağacı algoritmalarının olduğu görülmektedir.

Bu farklı karar ağacı algoritmalarından yaygın olarak kullanılan 5 algoritma aşağıda açıklanmıştır.

ID3 Algoritması (Induction of Decision Trees): Bu algoritma Sydney Üniversitesi'nde J.Ross Quinlan isimli çalışmacı tasarlamıştır. Bir veri kümesinde yer alan örnek veriler içinden ayrık örneği makine öğrenmesi sayesinde tespit ederek, tespit etme aşamasında entropi den faydalanan bir algoritmadır. Entropi, kavram olarak incelediğimizde verilerin birbirinden aayrılmasını sağlayan farklılıklar olarak tanımlanır. Belirlenen bir sistem yada yapı da entropi, o sistem yada yapıda ki karmaşıklığı tespit etmekte bir ölçüt olarak kullanılır ve bir alanın entropi değerinin fazla çıkması, mevcut yapının yada sistemin belirsizliğini arttırmaktadır. Bunun için, doğru bir değer ulaşmak amacıyla karar ağacının dibinde entropi ölçüsü en az karmaşıklık ve kararsızlığa sahip değer kullanılmaktadır (Karabulut,2021).

CART Algoritması: Breiman adlı çalışmacı 1984'te tasarlamıştır. En iyi dallanmayı belirlemek için ID3 algoritması benzer şekilde entropiden faydalanmaktadır. ID3 algoritmasıyla benzerliklerinin bulunmasının yanı sıra farklılıklar da bulunmaktadır. Bu algoritma verilerin dallanması sırasında kriterlerine ayrıştırdığı sırada kaybolan verileri işlem dışına alınmaktadır. "CART algoritması, yöntem olarak kategorik değildir bunun yanı sıra pek çok değer içinden sonuç değişkenini tespit etmede en kıymetli yöntemlerden biridir". "Bağımlı değişkenler

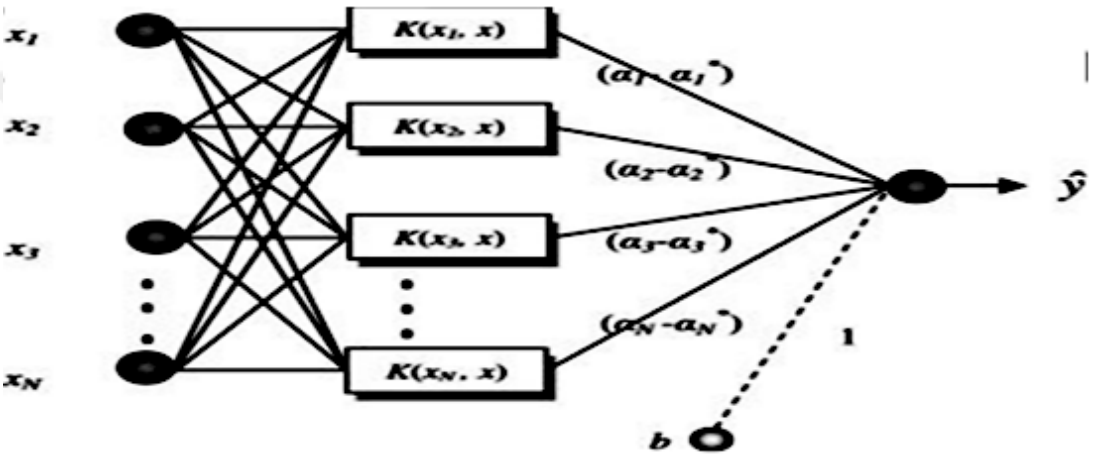
kategorik ise CART algoritması sınıflandırma ağacı üretmektedir". "Eğer bağımlı değişkenler sürekli ise regresyon ağacı oluşturmaktadır" (Karabulut,2021).

C4.5 Algoritması: Bu algoritmayıda 1993'te J. Ross Quinlan adlı araştırmacı tasarlamıştır. Fazla simgesel özelliğe sahip olan ID3 algoritması, C4.5 algoritması ile kıyaslandığında daha görsel olduğu görülmektedir. C4.5 algoritması kategorik niteliklerin aksine matematiksel niteliklerin sınıflandırılmasını hedeflemektedir. ID3'e kıyasla ayrı ve yeni öğrenme algoritmalarıyla daha üstün bir konuma sahip olmaktadır. C4.5 algoritması tespit kayıt edilememiş verileri kriter dışına atarak, sadece veri ve değişkenler aracılığıyla ileri görüşte bulunup kazanç oranı hesaplanmaktadır. Bundan dolayı anlaşılma düzeyi daha yüksek ve çözüm yeteneği daha güçlü ağaç oluşturulmaktadır. (Karabulut,2021).

"CHAID Algoritması: Karar ağacı algoritmaları içinde tercih edilen algoritmalar incelendiğinde en çok tercih edilenler arsında yer aldığı görülmektedir. "CHAID algoritması, bölümlendirme amaçlı kullanılıp, eldeki veride değişkenlerin bütün alt değişkenlerini incelemektedir." "Amaç değişkenle ilişkili değişkenleri eşit şekilde birleştirip, ön kestirim değiri seçildikten sonra eşit şekilde dağılmış değerler kendi arasında gruplanmaktadır." "aynı anlamı ifade etmeyen veriler eşit şekilde dağılmamış veri olarak nitelenmektedir. Veriler arasındaki bu ilişki ve gruplanma hali ağaç tam manası ile büyüyünceye kadar devam etmektedir" (Karabulut,2021).

3.1.2.3 Destek Vektör Makineleri

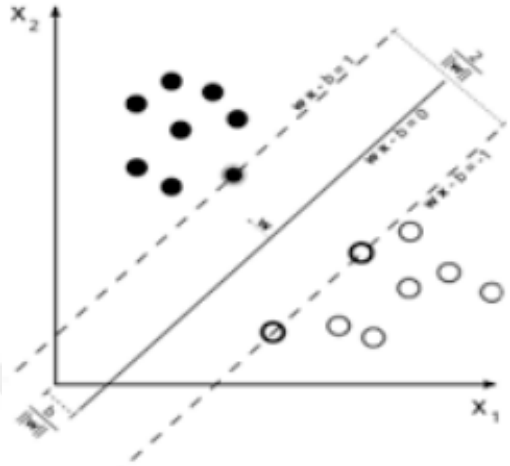
Destek Vektör Makineleri (DVM), yapısal riskin en aza indirilmesi amacına yönelik çalışan bir sınıflama yöntemidir. DVM 1995 yılında Cortesi ve Vapnik tarafından, elde bulunan problemlerin çözümü ve üzerinde çalışılan problemin bilinmeyen durum ve özelliklerine ait bilginin artırılması amacıyla geliştirilmiş bir sınıflama algoritmasıdır. DVM'nin çıkış noktası Vapnik-Chervonenkis (VC) teorisine başka bir ismiyle istatistiksel öğrenme teorisine dayanmaktadır. DVM'nin özet yapısı Şekil 3.13'de (Şanlıtürk, 2018) belirtilmektedir (Şanlıtürk, 2018).



Şekil 3. 13. DVM'nin Genel Yapısı.

Destek Vektör Makineleri sade bir mantığa sahip fakat etkili bir sınıflandırma yöntemidir. Sınıflandırma yaparken bir düzlemde bulunan iki küme arasında bir sınır çizerek bu kümelerin bir hiper düzlem ile ayrılması mantığı ile çalışmaktadır. İki kümeye ait üyelerin bulunduğu konuma en uzak olan nokta söz konusu hiper düzlemin çizileceği yerdir. DVM yöntemi her iki kümeye en uzak noktanın belirlenmesinde kullanılmaktadır. DVM hem doğrusal hem de doğrusal olmayan veri kümelerini sınıflandırabilir. Bu noktada, diğer birçok sınıflama yöntemlerinden ayrılan bir özelliği yer almaktadır. DVM prensibine göre, uygun bir dönüşüm ile veri her zaman bir hiper düzlem ile 2 sınıfa ayrılabilir. Hiper düzleme en yakın öğrenme eğrileri ise, destek vektörleri olarak adlandırılır. Aşağıdaki şekil bir doğrusal DVM olup, her iki grubu ortadan ikiye ayıran doğru hiper düzlemdir. Her 2 gruba en yakın olan ve grup üyelerinin üzerinde bulunduğu doğrular ise, destek vektörleri olarak

adlandırılmaktadır. Doğrusal DVM'de destek vektörleri Şekil 3.14'de gösterilmektedir (Şanlıtürk, 2018).



Şekil 3. 14. Doğrusal DVM'de destek vektörler.

Destek Vektör Makineleri (DVM), 3 alt bileşene ayrılmaktadır:

1.Doğrusal DVM

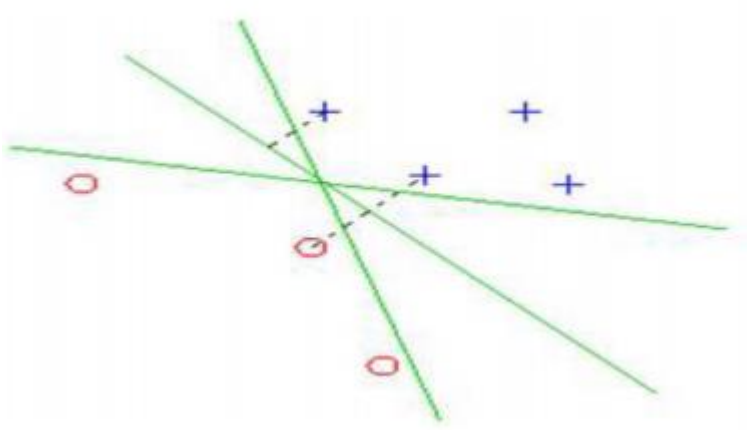
2.Doğrusal Olmayan DVM

3.Çok Sınıflı DVM

İlerleyen bölümlerde bu alt bileşenler detaylı bir şekilde anlatılacaktır.

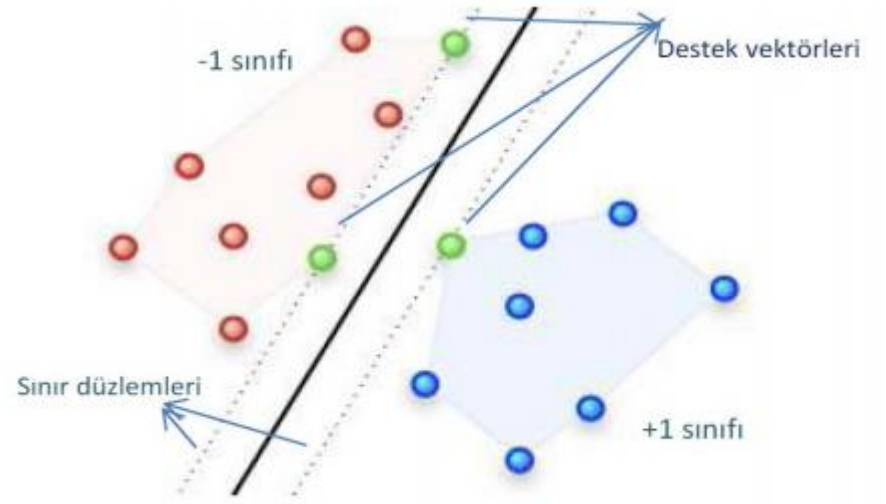
3.1.2.3.1 Doğrusal destek vektör makineleri

Doğrusal destek vektör makineleri, farklı sınıflara ait örnekleri birbirinden en iyi şekilde ayıracak, "ax+b" doğrusal hiper düzleminin bulunmasına yardımcı olan bir makine öğrenimi algoritmasıdır (Ayhan ve Erdoğmuş, 2014; Aktaran Şanlıtürk, 2018). Burada a ağırlık vektörü ve b sabit olarak tanımlanmaktadır. Şekil 3.15'de (Şanlıtürk, 2018) bir sınıfı ayıran farklı hiper düzlemler gösterilmektedir.



Şekil 3. 15. İki sınıflı veri setini ayıran farklı hiper düzlemler.

Yukarıdaki şekilde 2 sınıflı bir doğrusal DVM örneği görülmektedir. Mavi ve kırmızı renkli farklı gruplar birçok hiper düzlem ile ayrılarak farklı renkler ile sembolize edilmiştir. Bu grupları sınıflandırmada kullanılacak sadece bir hiper düzlem bulunmamaktadır. Aksine sonsuz sayıda doğrusal hiper düzlem ile bu gruplar birbirinden ayrılabilmektedir. Aşağıdaki şekilde ise, 2 sınıflı ve iki boyutlu bir sınıflandırma problemi için doğrusal DVM'nin geometrik gösterimi yer almaktadır. Sonsuz sayıdaki doğrunun içerisinden bir hiper düzlem seçmek için destek vektörleri kullanılmaktadır. Destek vektörleri, ayrılacak gruplara en yakın olan doğrular üzerindeki noktalar olarak tanımlanabilir. Hiper düzlem ise, bu 2 destek vektörünün üzerinde yer aldığı sınır düzlemlerine en uzak olan doğrudur. Yeşil ile işaretli noktalar destek vektörleri, kesikli çizgiler ise sınır düzlemleri olarak tanımlanmaktadır. Şekil 3.16'da (Ayhan ve Erdoğmuş, 2014) doğrusal DVM için bir problem örneği gösterilmektedir (Şanlıtürk, 2018).

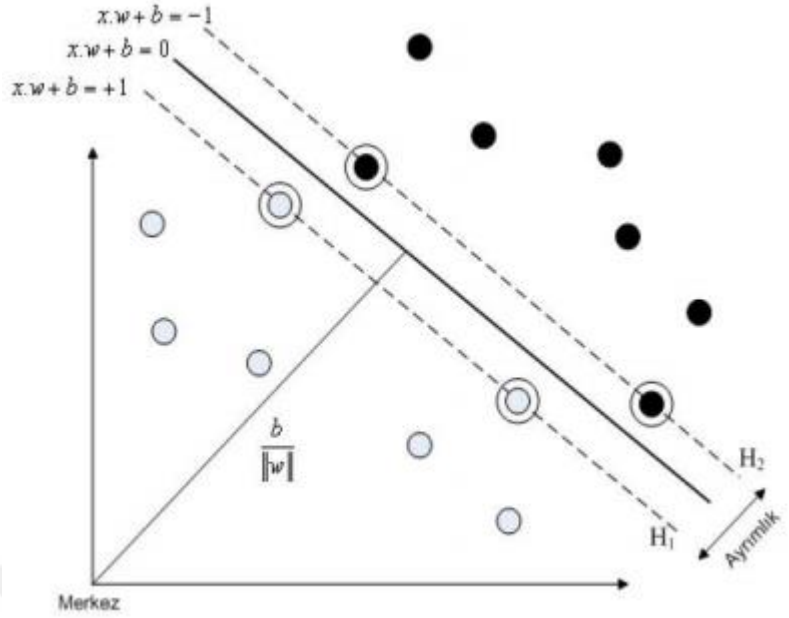


Şekil 3. 16. Doğrusal DVM için problem örneği.

Doğrusal Destek Vektör Makinelerinde, veri setindeki farklı sınıflar birbirinden doğrusal şekilde ayrılabilmektedir. Örnek olarak kredi durumu, üretim bandında ürün tipi sınıflandırması verilebilir. Bir bankanın müşteri bilgileriyle kredi verilebilir/verilemez diye müşterilerini sınıflandırması sınıfların birbirinden doğrusal şekilde ayrılabildiğine örnektir (Şanlıtürk, 2018).

3.1.2.3.1.1 Doğrusal ayrılabilme durumu

DVM'nin doğrusal ayrılabilme durumu H1 ve H2 düzlemlerinin en uygun aşırı düzlemlerdir ve bu düzlemlerin sınıflara olan mesafesi minimum olup, sınıflar arasındaki mesafe de maksimumdur. Bu 2 aşırı düzlemin ortasından geçen düzlem ise en uygun ayırma düzlemidir. Bu durum Şekil 3.17'de (Şanlıtürk, 2018) gösterilmektedir (Şanlıtürk, 2018).



Şekil 3. 17. Doğrusal ayrılabilen DVM.

H2 düzlemi üzerinde kalan noktalar aşağıdaki eşitsizliğe;

$$x_i \,.w + b \leq -1, \quad y_i = -1 \tag{3.22}$$

H1 düzlemi altında kalan noktalar ise aşağıdaki eşitsizliğe;

$$x_i \,.w + b \geq +1, \quad y_i = +1 \tag{3.23}$$

Uymaktadırlar. Optimum ayırma düzlemini bulmak için uygun w ve b değerleri hesaplanır. Optimum aşırı düzlem sınırının en yüksek değere ulaşabilmesi için w değerinin minimum olması gerekmektedir (Şanlıtürk, 2018).

3.1.2.3.1.2 Doğrusal ayrılamama durumu

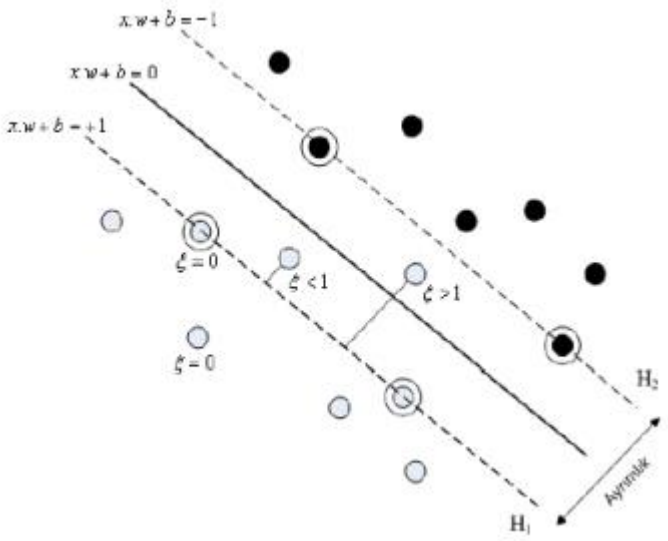
Verilerin pratikte tamamen doğrusal ayrılamadığı durumlarda kullanılan destek vektör makineleridir. DVM'nin en büyük avantajlarından biri de doğrusal olmayan verileri doğrusal seviyeye indirebilmeleridir. Belirli bir hata ile doğrusal ayrılma durumunda iki sınıflı veri setini ayırmak için gevşek sınır (soft margin) yaklaşımı kullanılmaktadır. Soft margin yaklaşımında; negatif olmayan bir slack değişkeni kısıtlara eklenir. Böylece DVM bir miktar hataya izin verebilecek şekilde yeniden tasarlanmış olur (Şanlıtürk, 2018). Bu formülasyonlar şu şekildedir:

$$\begin{gathered} x_i \,.w + b \geq +1 - \xi\text{i}, \;\; y_i = +1 \\ x_i \,.w + b \leq -1 + \xi\text{i}, \;\; y_i = -1 \\ \xi\text{i} \geq 0 \,, \forall i \end{gathered} \tag{3.24}$$

Buna göre;

ξi = 0 ise örnek, ayrım sınırının üzerindedir ve böylece doğru sınıflandırılmış olur. Eğer 0 < ξi < 1 arasında ise; örneklem yine doğru olarak sınıflandırılır. ξi > 1 olan örnekler için hatalı sınıflama söz konusu olacaktır (Şanlıtürk, 2018).

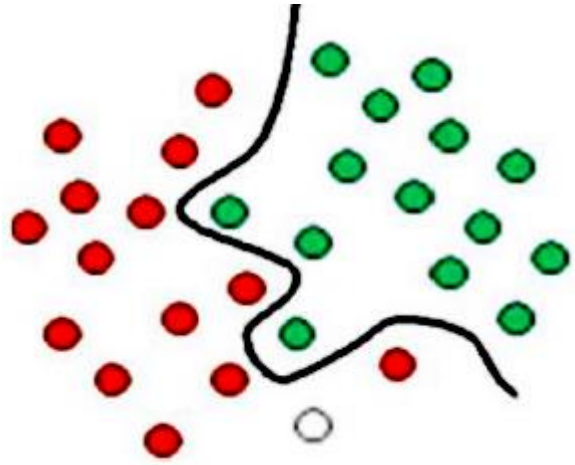
Burada amaç, bir miktar örneğin hatalı sınıflandırılmasına izin vererek aradaki ayrımı en çoklamaktır. Aşağıdaki şekilden de görüldüğü üzere, bazı noktalar sınır düzlemlerinin içinde kalmasına rağmen, iki farklı gruba da en uzak hiper düzlem bu yöntemle çizilmiştir. Doğrusal ayrılamama durumu Şekil 3.18'de (Şanlıtürk, 2018) gösterilmektedir (Şanlıtürk, 2018).



Şekil 3. 18. Doğrusal ayrılamama durumu.

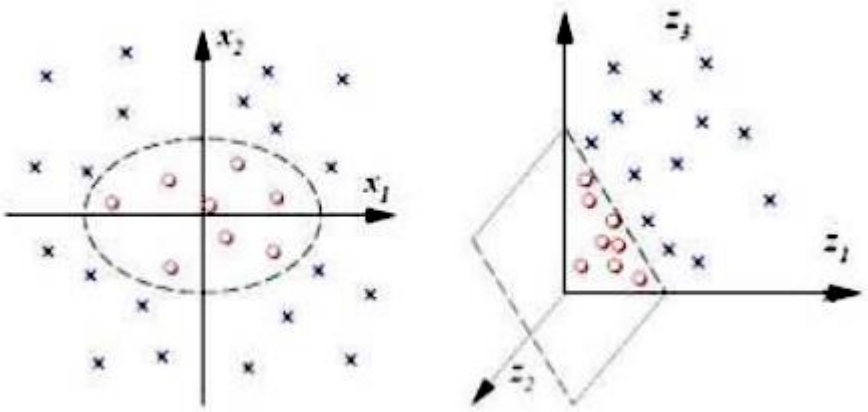
3.1.2.3.2 Doğrusal olmayan destek vektör makineleri

Doğrusal Olmayan Destek Vektör Makineleri, veri seti doğrusal bir fonksiyonla tam veya belirli bir hata ile ayrılamıyorsa kullanılan bir yöntemdir. Gerçek yaşama ait verilerin doğrusal olarak ayrılması mümkün olmadığı için, çok sık kullanılan bir yöntemdir. Aşağıda doğrusal olmayan destek vektör makinelerine örnek olarak gösterilen 2 farklı grup yer almaktadır. 2 grubu doğrusal olarak ayıracak bir hiper düzlem bulunamadığı için parabolik bir eğri ile gruplar birbirinden ayrılmıştır. Şekil 3.19'de (Ayhan ve Erdoğmuş, 2014) bu durum gösterilmektedir (Şanlıtürk, 2018).



Şekil 3. 19. Doğrusal olmayan destek vektör makineleri.

Doğrusal Olmayan Destek Vektör Makineleri modelinde, veriler doğrusal olmayan haritalama yapılarak orijinal girdi uzayından daha yüksek boyuttaki bir uzaya aktarılmaktadır. Aşağıda Şekil 3.20'de (Ayhan ve Erdoğmuş, 2014) ki soldaki ifade orijinal girdi uzayını, sağdaki ifade ise 3 boyutlu uzayı göstermektedir (Şanlıtürk, 2018).



Şekil 3. 20. İki boyutlu girdi uzayından çok boyutlu uzaya geçiş.

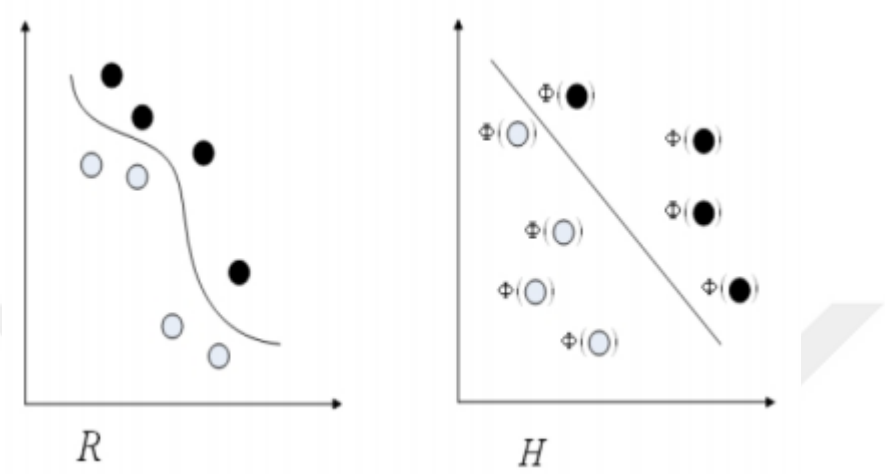
Xi*Xj çarpımı, 3 boyutlu uzayda $\phi(xi).\phi(xj)$ şeklinde tanımlanacaktır.

Bu modelde bazı sorunlar ortaya çıkmaktadır.

• Doğrusal karar sınırının dönüşümünde nasıl bir haritalama fonksiyonu kullanılacağı açık olarak belirtilmemiştir.

• Uygulanan haritalama fonksiyonu biliniyorsa, kurulan optimizasyon probleminin yüksek boyutlu uzaydaki çözümü karmaşık ve zor olmaktadır.

Şekil 3.21'de (Şanlıtürk, 2018) Doğrusal Olmayan DVM örneğinin çözüm kullanılarak Doğrusal DVM'ye dönüştürülmüş şekli görünmektedir (Şanlıtürk, 2018).



Şekil 3. 21. Doğrusal olmayan DVM'nin doğrusal DVM'ye dönüştürülmesi.

Çekirdek Fonksiyonu:

$$K(x_i, x_j) = \phi(x_i).\phi(x_j) \tag{3.25}$$

Şeklinde tanımlanan fonksiyonlara çekirdek fonksiyonu denmektedir.

Çekirdek Fonksiyonunun temel olarak 2 avantajı yer almaktadır.

• Direk girdi uzayındaki veriler kullanılır, φ fonksiyonunu hesaplamaya gerek kalmaz.

• Daha kolay ve düşük maliyetle sonuca ulaştırır.

Aşağıda en sık kullanılan çekirdek fonksiyonları görünmektedir (Şanlıtürk, 2018).

Doğrusal $$K(x_i, x_j) = x_i^T x_j \tag{3.26}$$

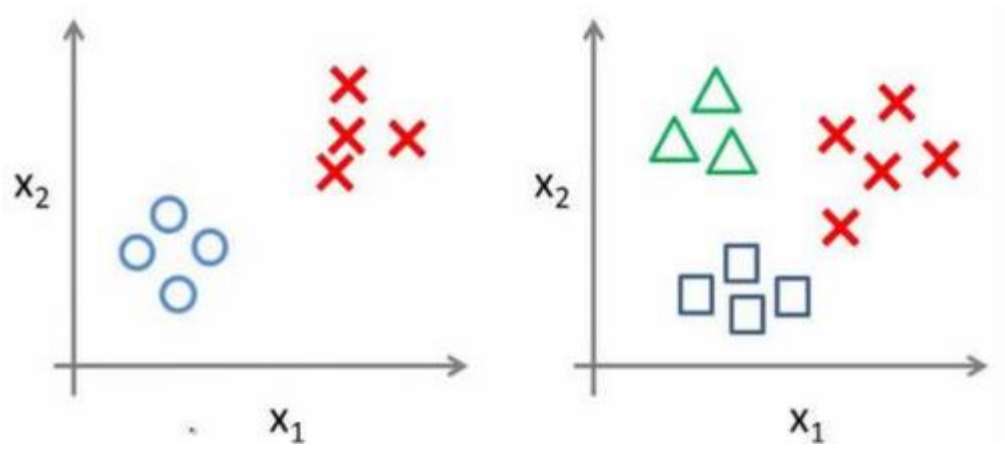
Polinom $$K(x_i, x_j) = (x_i^T x_j + 1)^P \tag{3.27}$$

Gaussian $$K(x_i, x_j) = \exp\left(-|x_i - x_j|^2 / 2o^2\right) \quad (3.28)$$

Sigmoid $$K(x_i, x_j) = \tanh(x_i^T x_j - \delta) \quad (3.29)$$

3.1.2.3.3 Çok sınıflı destek vektör makineleri

Sınıf sayısının 2'den fazla olduğu durumlar için Çok Sınıflı Destek Vektör Makineleri kullanılmaktadır. 2'den fazla sınıf olduğu durumlarda farklı yaklaşımlar ön plana çıkmaktadır. Öne çıkan 2 yöntem bulunmaktadır. Aşağıda 2 sınıflı ve çok sınıflı DVM görselleri Şekil 3.22'de (Şanlıtürk, 2018) gösterilmiştir (Şanlıtürk, 2018).



Şekil 3. 22. Çok sınıflı DVM.

3.1.2.3.3.1 İkili sınıflar halinde sınıflandırmalarla çalıştırmak

Bu yöntemde ikili sınıflar birbirleri ile çalıştırılarak 2 sınıflı çözüm yapılmaktadır. Böylece çoklu sınıftan 2 sınıflı gruplara indirgenerek çözüm kolaylaştırılmaktadır. 3 farklı yaklaşım bulunmaktadır (Şanlıtürk, 2018).

Bire Karşı Bir: Her bir örnek seti diğer örnek setleriyle ayrı ayrı eğitilir (Şanlıtürk, 2018). .

Bire Karşı Hepsi: Her bir örnek seti bir sınıf, geriye kalan sınıfların tamamı bir sınıf kabul edilir ve eğitilir (Şanlıtürk, 2018).

Döngüsel Olmayan Graf Yöntemi: Bire karşı bir yöntemiyle aynı şekilde uygulanmaktadır. Eğitim bire karşı bire göre yapılmakta fakat test aşamasında eğitim örnekleri kontrol edilmek yerine, sınıflandırılacak elemanın ait olmadığı düşünülen sınıflar eklenerek işlem yapılmaktadır (Şanlıtürk, 2018).

3.1.3. Veri Madenciliği Algoritmalarında Performans Ölçümü

Veri madenciliği algoritmalarında performans ölçümü için literatürde çok sayıda yöntem bulunmaktadır. Kullanılan algoritmadan hesaplanmak istenen değere kadar birçok kritere bağlı olarak performans ölçüm yöntemleri değişkenlik göstermektedir. Regresyon, Zaman serileri ve tahminleme çalışmalarında en çok kullanılan 4 kriterin hesaplama mantığı anlatılmıştır. Bu çalışmada performans kriteri olarak önceki bölümlerde de belirtildiği gibi RMSE performans kriteri kullanılmıştır (Veri Bilimcisi, 2021).

4 Adet ölçüm yönteminin özet olarak gösterimi Çizelge 3.3'de (Veri Bilimcisi, 2021) görülmektedir. Burada yt ler gerçekleşen değerleri, et'ler gerçekleşen değerlerle tahmin değerleri arasındaki farkları, yani tahmin hatalarını göstermektedir. n kayıt sayısı ya da örnek hacmi olarak ifade edilebilir (Veri Bilimcisi, 2021).

Çizelge 3. 3. Makine öğrenmesinde kullanılan performans ölçüleri

Ortalama Mutlak Hata (Mean absolute error)	$MAE = \frac{1}{n}\sum_{t=1}^{n}\lvert e_t\rvert$
Ortalama Mutlak Yüzde Hata (Mean (Absolute Percentage Error)	$MAPE = \frac{100\%}{n}\sum_{t=1}^{n}\left\lvert\frac{e_t}{y_t}\right\rvert$
Hata Kareler Ortalaması (Mean squared error)	$MSE = \frac{1}{n}\sum_{t=1}^{n}e_t^2$
Hata Kareler Ortalamasının Karekökü (Root mean squared error)	$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}e_t^2}$

3.1.3.1. Ortalama Mutlak Hata (Mean Absolute Error [MAE])

Ortalama mutlak hata: teknik olarak incelenirse devamlı halde olan iki değişkenin ölçüsüdür. MAE, mesafe olarak tanımlandığında her reel değerle veriye en uygun olan çizgi arasında yer alan ortalama dikey uzaklıktır. MAE değeri

yorumlanabilme kabiliyeti açısından basit yorumlanabilme özelliğinden dolayı regresyon ve zaman serisi çalışmalarında yoğun bir şekilde uygulanır. MAE, işaretlerini önem vermeden bir sürü öngörüdeki yanlışların ortalama büyüklüğünü hesaplayan, bütün tekil yanlışlar ortalama hesaplamada eşit olarak ağırlıklandırılmaktadır. Doğrusal özelliğe sahip bir değerdir. MAE değeri 0 ile ∞ aralığında bulunur. MAE değeri 0'a yakın olan tahminleme sonuçları daha iyidir (Veri Bilimcisi, 2021).

Bu hesaplama yönteminin özet olarak gösterimi Denklem 3.30'da görülmektedir.

$$MAE = \frac{1}{n}\sum_{t=1}^{n}|e_t| \tag{3.10}$$

3.1.3.2. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error [MAPE])

Regresyon ile zaman serileri tasarımlarında öngörülerin doğruluğunu değerlendirmek amacıyla ortalama mutlak yüzde hatadan sıklıkla faydalanılır. Gerçek değerlerin bir bölümünde sıfır var ise, payda da sıfır olması matematiksel olarak hata vereceği için MAPE ölçülemez. Öngörü hatası çok az olan değerlerde hata oranı %100'ü aşamaz, fakat çok güçlü öngörü değerleri olduğunda üst limit yoktur. MAPE, öngörücülerin hata değerini karşılaştırmak amacıyla uygulandığında, öngörüleri çok zayıf olan bir tekniği sistematik bir biçimde seçmesinden dolayı ön yargıya sahiptir. Bu basit ama önemli sorun, öngörü değerlerin reel değerlerine oranını tespit eden bir doğruluk kriteri ile aşılabilir. Bu tarz geometrik ortalama bakımından değerlendirilebilen öngörülere sebep olur (Veri Bilimcisi, 2021).

Bu hesaplama yönteminin özet olarak gösterimi Denklem 3.31'de görülmektedir.

$$MAPE = \frac{100\%}{n}\sum_{t=1}^{n}\left|\frac{e_t}{y_t}\right| \tag{3.31}$$

3.1.3.3. Hata Kareler Ortalaması (Mean Squared Error [MSE])

"sade bir şekilde, ortalama kare hata bir regresyon eğrisinin çok sayıda noktaya hangi oranda yakın mesafede bulunduğunu ifade eder. MSE, bir makine öğrenmesi modelinin, öngörücünün performansını değerlendirir, daima 0 dan büyük değere sahiptir. MSE sonucu sıfıra yakın olan öngörücülerin daha nitelikli performans sergiler" (Veri Bilimcisi, 2021).

Bu hesaplama yönteminin özet olarak gösterimi Denklem 3.32'de görülmektedir.

$$MSE = \frac{1}{n}\sum_{t=1}^{n} e_t^2 \tag{3.32}$$

3.1.3.4. Hata Kareler Ortalamasının Karekökü(Root Mean Square Error [RMSE])

"Bir makine öğrenmesi tasarımının, öngörücünün öngördüğü değerler ile gerçek değerler arasındaki mesafenin tespit edilmesinde çok sık şekilde tercih edilen, farkın(öngörü hatasının) boyutunu tespit eden kuadratik bir metriktir. RMSE öngörü farklarının standart sapma değeridir. Esasında, farklar, regresyon hattının veri noktalarında ne düzeyde uzakta olduğunu gösteren bir ölçüttür; RMSE değeri ise söz konusu farkların ne boyutta dağıldığının bir ölçütüdür. Başka bir ifade ile, verilere uygun olan çizgi etrafında o verilerin ne düzeyde yoğun olduğunu ifade eder. RMSE değeri 0 ile ∞aralığında değer alabilir. RMSE değeri sıfıra yakın oldukça performans gücü artar. RMSE değeri 0 olursa öngörücü hiç hata yapmamış demektir. RMSE, büyük farklı daha güçlü cezalandırır. Bundan dolayı istisnai hallerde daha uygun olabilir. RMSE, çoğu matematiksel ölçümlemede talep edilmeyen mutlak değerin kullanımına izin vermez "(Veri Bilimcisi, 2021).

Bu hesaplama yönteminin özet olarak gösterimi Denklem 3.33'de görülmektedir.

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n} e_t^2} \tag{3.33}$$

3.2. Yöntem

3.2.1. Türkiye de Elektrik Tüketimini Etkileyen Faktörler

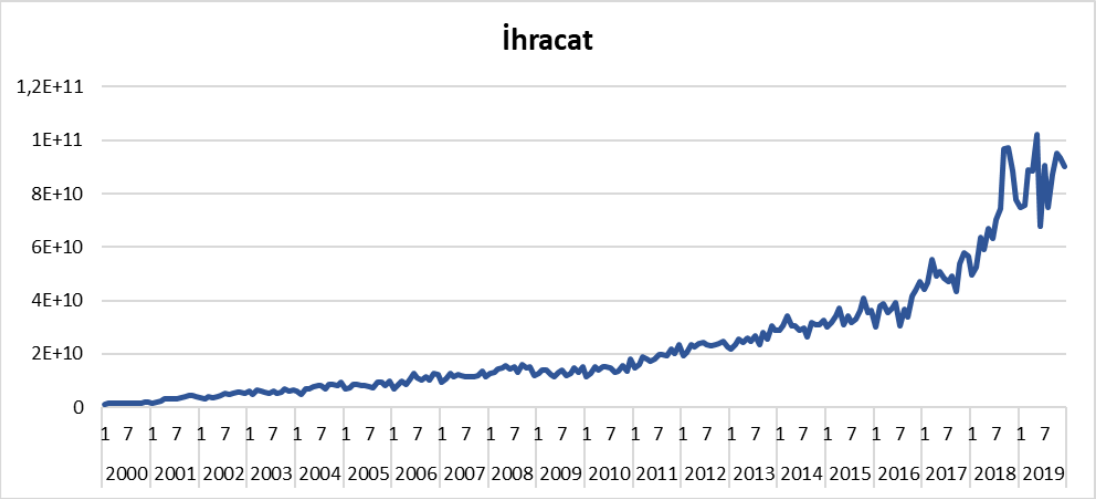
Elektrik tüketim tahmini yapılırken dikkat edilmesi gereken en önemli husus tüketime etki eden etkenlerin belirlenmesidir. Tüketim tahminine etki eden değişkeneler tüketimin tipine ve tüketim tahmininin dönemine göre değişkenlik göstermektedir. Geleceğe dönük elektrik tüketiminin tahminlemesi çalışmalarında veri madenciliği kullanılacak ise çalışmanın en önemli hususlarından birisi tahminleme de kullanılacak değişkenlerin belirlenmesidir. Çünkü belirlenen değişkenlere göre yapılan tahminleme çalışmalarında kullanılan algoritmaların başarı performansları ciddi şekilde etkilenmektedir. Bundan dolayı seçilen değişkenlerin tüketimi etkilemede yüksek korelasyona sahip olması gerekmektedir. Özetle veri madenciliğinde kullanılan algoritmalar için giriş değerleri olarak kullanılan değişkenler gerçekte tüketime etkisi ne kadar yüksek ise alınacak sonucun gerçekleşen tüketim miktarına o derece yakın olduğu gözlemlenecektir. Bu çalışmada Türkiye'nin Ocak 2018 - Aralık 2019 dönem aralığında aylık olarak (24 aylık) elektrik tüketim miktarı tahmin edilmeye çalışılmıştır. Kullanılan algoritmaların tahmin performansları karşılaştırılmıştır. Yapılan bu çalışmayla Ocak 2018 - Aralık 2019 döneminde elektrik tüketimi tahminlemesi için en iyi performansa sahip veri madenciliği yöntemi ve yönteme ait parametreler tespit edilmeye çalışılmıştır. Bu bölümde Türkiye'nin elektrik tüketimine etki eden değişkenler incelenecektir. Literatüre baktığımız zaman elektrik tüketiminin tahminlemesi için daha önceden yapılmış çeşitli çalışmalar ve çeşitli analizler olduğunu görmekteyiz. Bu çalışmalar ve analizlerin ışığında bu çalışmada kullanılacak olan elektrik tüketimine etki eden değişkenler Çizelge 3.4'de detaylı şekilde verilmiştir.

Çizelge 3. 4. Elektrik tüketimine etki eden değişkenler

Girdi Numarası	Değişken	Kısalt.	Birim	Veri Kaynağı	Zaman Dilimi
Girdi 1	İhracat	IHR	Milyon Dolar	OECD	01.2000-12.2019
Girdi 2	İthalat	ITH	Milyon Dolar	OECD	01.2000-12.2019
Girdi 3	Toplam Sanayi Üretim Endeksi	TSÜE	10 Bin TL	OECD	01.2000-12.2019
Girdi 4	Nüfus	N	Bin Kişi	TUİK	01.2000-12.2019
Girdi 5	Yağış	Y	Mm	MGM	01.2000-12.2019
Girdi 6	Sıcaklık	S	℃	MGM	01.2000-12.2019
Çıktı	Elektrik Tüketimi	ET	GWh	TEİAŞ	01.2000-12.2019

3.2.1.1. İhracat

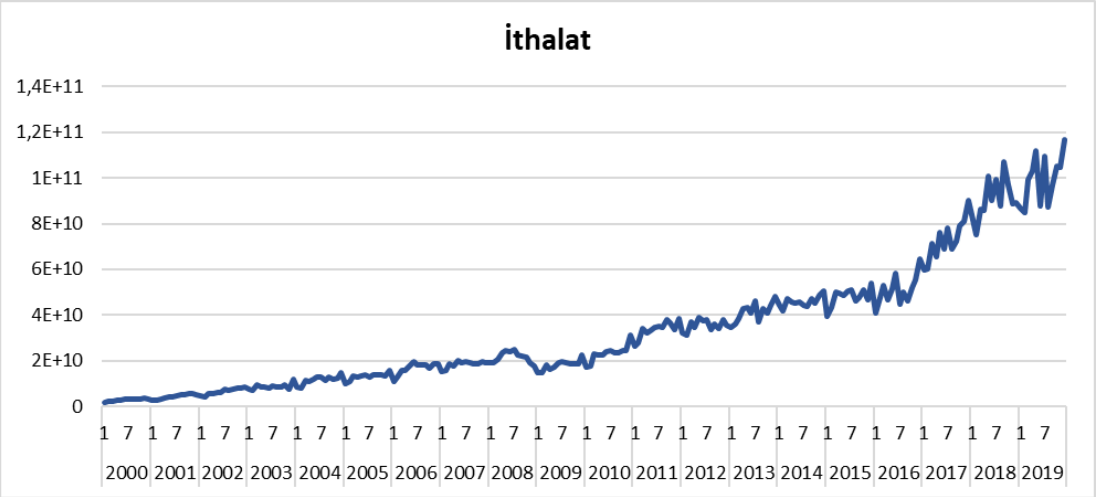
Bir ülkede yıllara göre gerçekleşen ihracat ve ithalat durumu o ülkenin refahının ve büyümesinin ölçülmesinde önemli değişkenlerdir. Bir ülkede ihracat miktarı arttıkça sanayi de tüketilen enerjide artmaktadır. Bu yüzden bu kriter de ki değişimler elektrik tüketimini ciddi oranda etkilemektedir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık İhracat miktarı Şekil 3.23'de (Fred 1, 2021) görülmektedir.



Şekil 3. 23. Ocak 2000 - Aralık 2017 yılları arasındaki ihracat miktarının değişimi.

3.2.1.2. İthalat

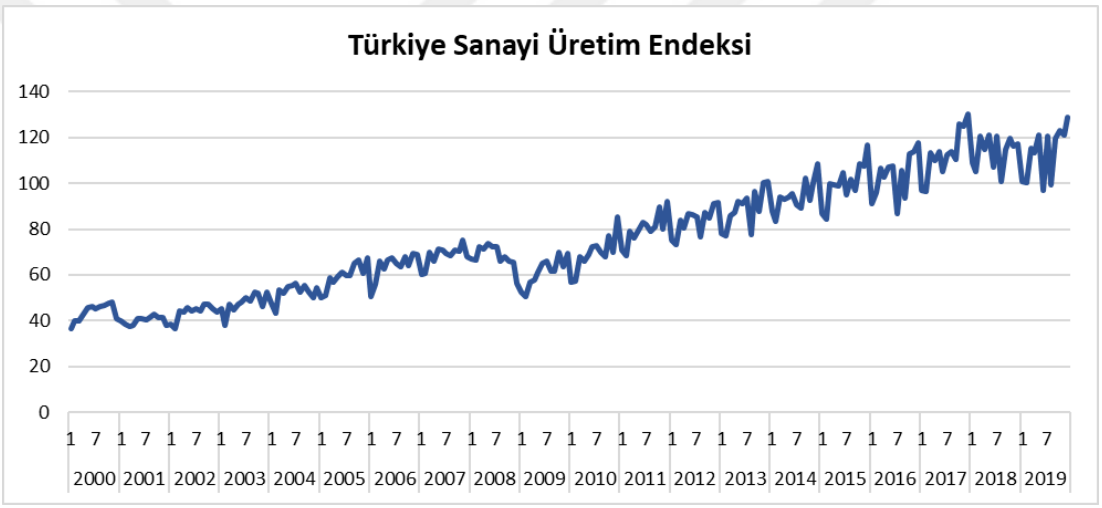
Bir ülkede yıllara göre gerçekleşen ihracat ve ithalat durumu o ülkenin refahının ve büyümesinin ölçülmesinde önemli değişkenlerdir. Elektrik üretiminde birincil kaynakların büyük çoğunluğu ithal edilmektedir. Bu yüzden bu kriterlerde ki değişimler elektrik tüketimini ciddi oranda etkilemektedir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık İthalat miktarı Şekil 3.24'de (Fred 2, 2021) görülmektedir.



Şekil 3. 24. Ocak 2000 - Aralık 2017 yılları arasındaki ithalat miktarının değişimi.

3.2.1.3. Türkiye Sanayi Üretim Endeksi

Toplam sanayi üretimi, madencilik, imalat, elektrik, gaz, iklimlendirme sektörlerinin toplam üretimini kapsar. 2017 verilerine göre elektrik tüketiminin %46,8'i sanayi kaynaklıdır. Bu yüzden Toplam Sanayi Üretim Endeksi (TSEÜ) elektrik tüketiminin tahmininde yüksek öneme sahiptir. TSÜE göstergesi üretim çıktısı hacmindeki değişikliği referans bir endeks yardımıyla ölçer. Elimizdeki verilerde 2015 yılı referans olarak (2015=100) alınmıştır (Polat, 2019). Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık GSYH miktarı Şekil 3.25'de (Fred 3, 2021) görülmektedir.

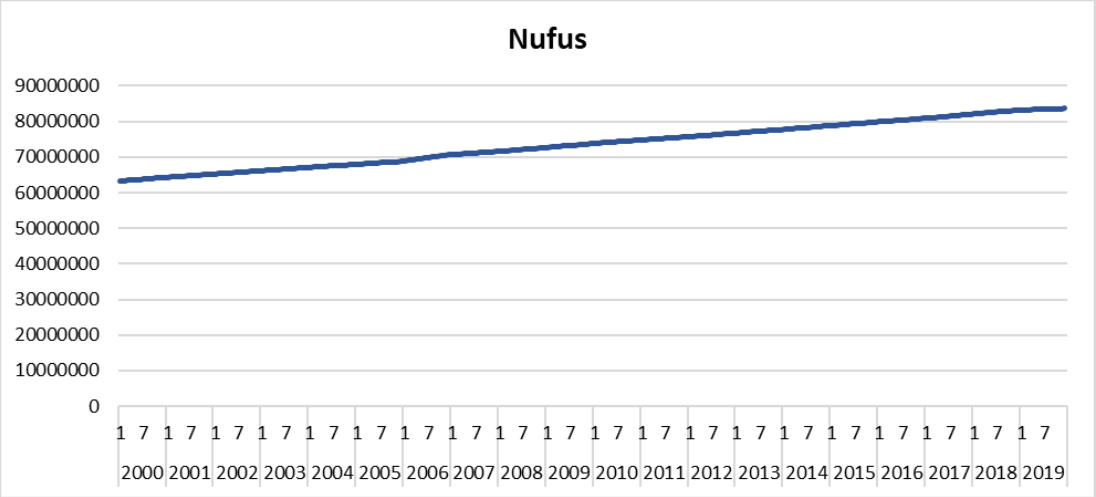


Şekil 3. 25. Ocak 2000 - Aralık 2017 yılları arasındaki Türkiye sanayi üretim endeksinin değişimi.

3.2.1.4. Nüfus

Ülkelerin en önemli gelişim kriterlerinden ve hedeflerinden biri toplumlarının refah seviyesinin artmasıdır. Toplumların refah seviyelerinin arttırmak ya da hedeflenen yere getirebilmek, o toplumları yöneten devletlerin toplumdaki bireylerin ehemmiyetli ihtiyaçlarının karşılanması ile sağlanabilir. İnsan hayatında önemli bir yere sahip olan elektrik enerjisi de gittikçe büyüyen toplumların ehemmiyetli ihtiyaçlarındandır. Elektrik enerjisi ısıtma, aydınlatma gibi toplumların temel ihtiyaç alanlarında fazlası ile kullanılmaktadır. Toplumlarda nüfusun artması elektrik kullanımını da gittikçe arttırmaktadır. Bu artış da beraberinde elektriğe olan bağımlılığı günden güne artırmaktadır. Ülkeler elektrik tüketim planlaması yaparken

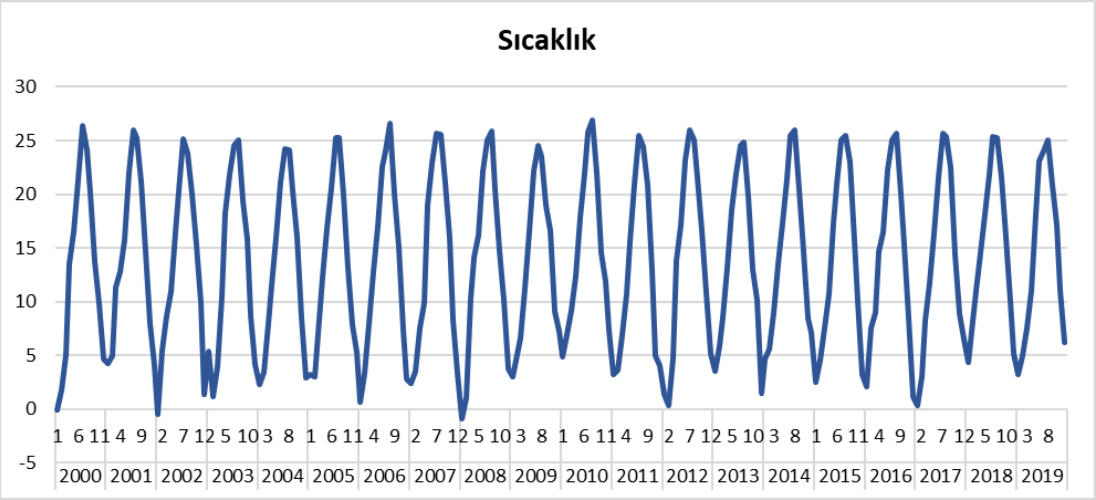
göz önünde bulundurması gereken kriterlerden birisi elektriği kullanan kişilerin yani toplumların nüfusudur. Artan nüfus zamanla artan elektrik ihtiyacı demektir. Bu da elektrik tüketiminin yukarı yönlü gelişme göstermesine neden olacaktır. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık Nüfus miktarı Şekil 3.26'da (TÜİK Nufus, 2021) görülmektedir. Ülkemizde TÜİK tarafından nüfus verileri yıllık (12 ay) olarak açıklanmaktadır. Yıllık olarak açıklanan nüfus verisinin çalışmamızda kullanılabilmesi için 1 yıllık nüfus artışı istatiksel ortalama hesaplama yöntemlerinden olan aritmetik ortalama yöntemine göre 12 eşit parçaya bölünerek aylık olarak ne kadar artış sağladığı bulunmuş ve aylık nüfus artışı bu şekilde kabul edilerek uygulamada aylık giriş değeri olarak kullanılmıştır.



Şekil 3. 26. Ocak 2000 - Aralık 2017 yılları arasındaki nüfus miktarının değişimi.

3.2.1.5. Sıcaklık

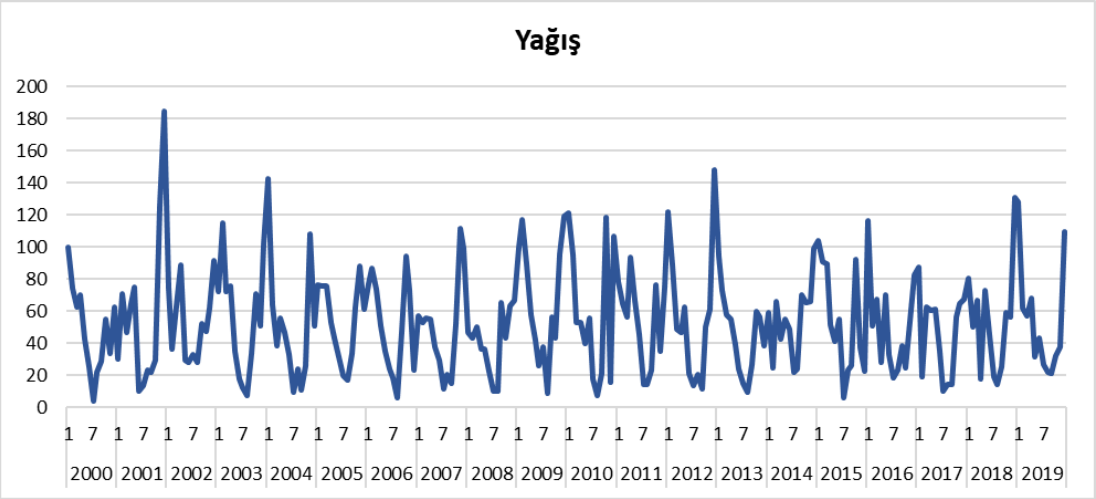
Mesken-Sanayi-Ticarethane-Tarımsal Sulama vb. tüm elektrik tarifelerinde elektrik tüketimiyle, sıcaklık değişimi arasında güçlü bir korelasyon vardır. Özellikle meskenlerde elektrik tüketimini etkileyen en temel faktörün sıcaklık olduğu görülmektedir. Yazın fazla sıcaklık klima vb. soğutma araçlarının kullanılmasını, kış aylarındaki soğuk hava şartlarında ise elektrikli ısıtıcı vb. ısıtma kaynaklarının kullanımını arttırmaktadır. Bunun sonucunda elektrik tüketimlerinde ciddi değişimler gerçekleşmektedir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık Sıcaklık değişimi Şekil 3.27'de (MGM Sıcaklık, 2021) görülmektedir.



Şekil 3. 27. Ocak 2000 - Aralık 2017 yılları arasındaki sıcaklık miktarının değişimi.

3.2.1.6. Yağış

Elektrik tüketimi tahmin çalışmalarında kullanılan değişkenlerden iklimsel değişkenler sınıfında sıcaklık değişkeninden sonra kullanılan önemli bir diğer gösterge yağış miktarıdır. Yağış (Yağmur, Kar) durumuna göre özellikle mesken tipi tüketiciler de enerji tüketimi ciddi değişkenlik göstermektedir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık yağış miktarı Şekil 3.28'de (MGM Yağış, 2021) görülmektedir.



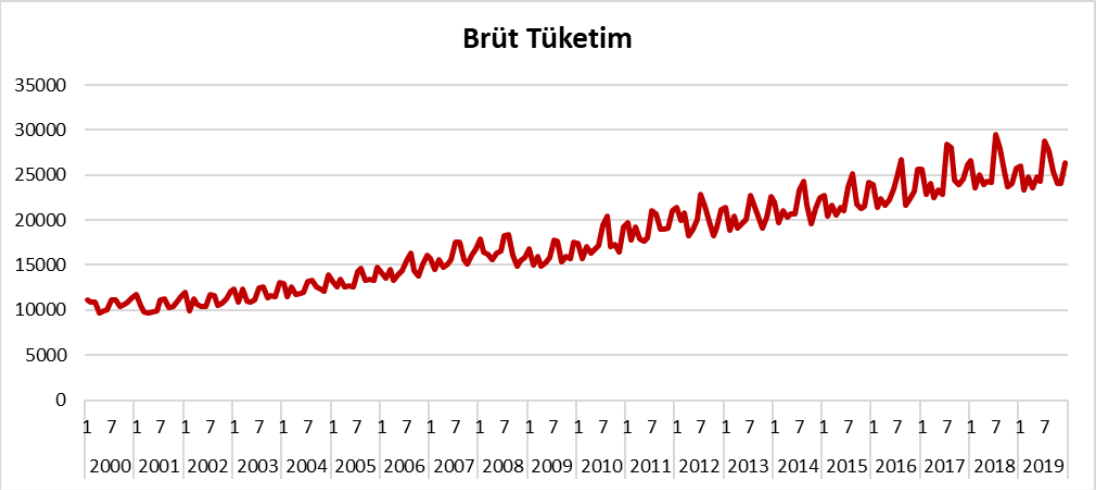
Şekil 3. 28. Ocak 2000 - Aralık 2017 yılları arasındaki yağış miktarının değişimi.

3.2.1.7. Rastgele Değişkenler

Elektrik tüketim tahmininde tahmin edilmesi en güç parametreler tesadüfi durumlardır. Tesadüfü durumlar önceden kestirilemez olduğu için bu faktörlerin olduğu günlerde tüketim miktarı trend çizgisinin dışına çıkıp farklı özellik sergiler. Mesken tüketimini incelediğimizde bireysel ve toplumsal olaylar ve bunların sonuçları rastgele değişkenler arasında sayılabilir. Sanayi tarifesi içinde yer alan tüketimlerde grev veya lokavt olayları, tarımsal sulama vb. tüketimlerde kuraklık ya da aşırı yağış ve 2020 yılında ilk olarak Çinin hubei eyaleti Vuhan kentinde ortaya çıkan daha sonra tüm dünyayı etkisi altına alan Korona virüs (Covid-19) tipi salgın hastalıklar tüm tüketim tarifelerini (Mesken-Sanayi-Ticarethane-Tarımsal Sulama vb.) etkileyen tesadüfi değişkenler olarak elektrik tüketimine direkt etki etmektedir.

3.2.1.8. Elektrik Tüketimi

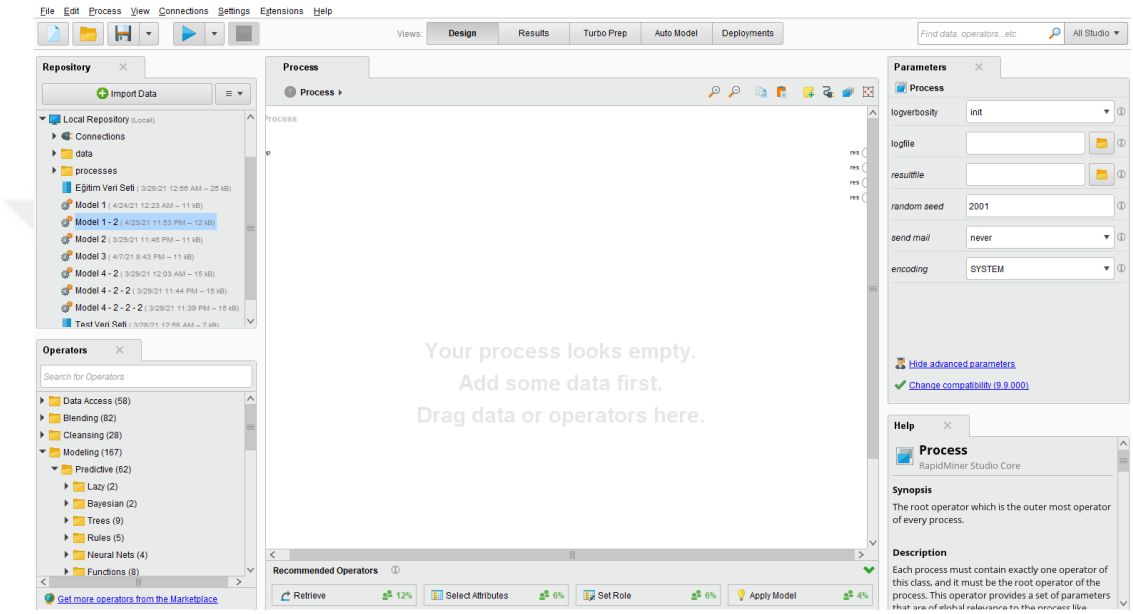
Elektrik Tüketimi tahmin çalışmamızın çıktısını oluşturmaktadır. Bu değer Türkiye'de üretilen elektrik ve ithal edilen elektrikten, ihraç edilen elektriğin düşülmesi mantığına göre merkez bankası EVDS de yer alan raporlardan aylık bazda elde edilmiştir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık elektrik tüketim miktarı Şekil 3.29'da (TEİAŞ, 2021) görülmektedir.



Şekil 3. 29. Ocak 2000 - Aralık 2017 yılları arasındaki elektrik tüketim miktarının değişimi.

3.2.2. Rapid Miner da Modelin hazırlanması süreci

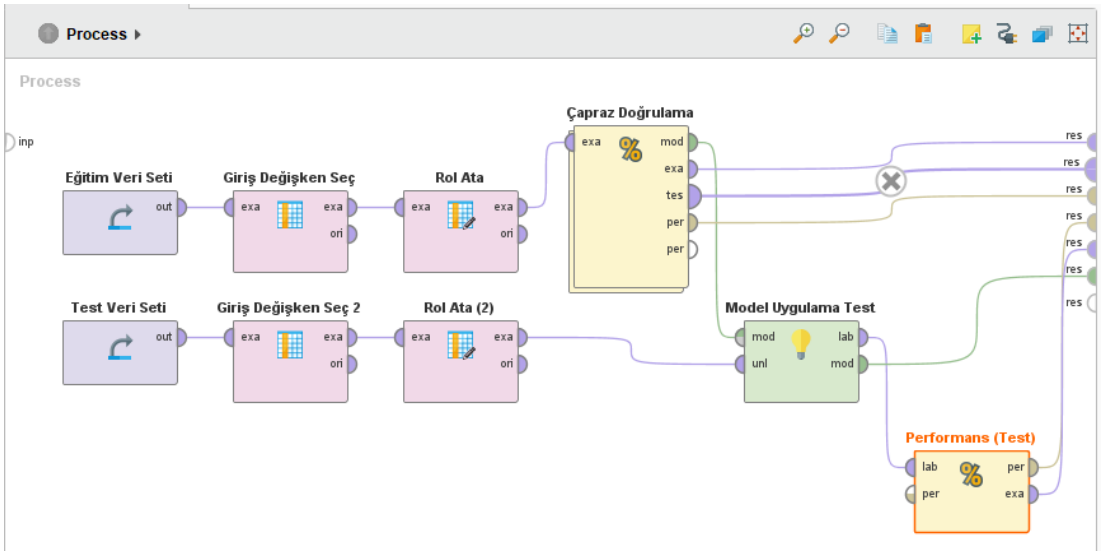
Bu bölümde, Türkiye elektrik tüketim tahmini için bazı veri madenciliği yöntemleri ile modelleme çalışması Rapid Miner programında yapılmıştır. Bu programın kullanıcı ara yüzü Şekil 3.30 da görülmektedir.



Şekil 3. 30. Rapidminer'ın kullanıcı ara yüzü

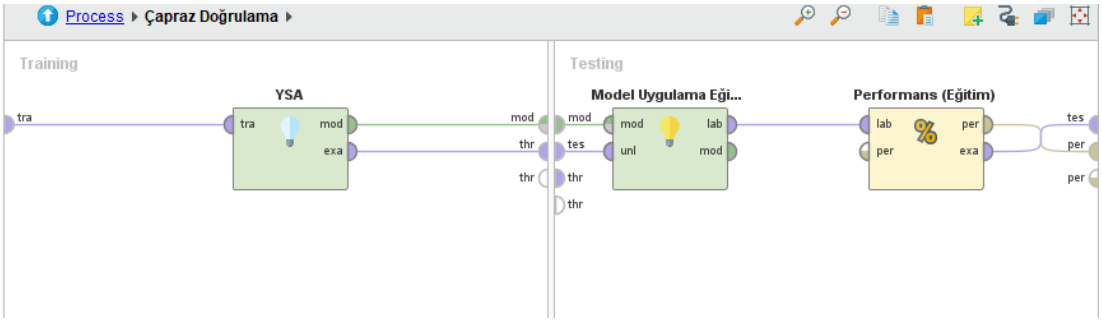
Bu modellerin eğitilmesi amacıyla Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık veri kullanılmıştır. Eğitilen modellerle Ocak 2018 - Aralık 2019 dönemine ait aylık elektrik tüketim miktarı tahmin edilmeye çalışılmıştır.

Ocak 2018 - Aralık 2019 döneminde gerçekleşen girdi değişkenleri ve elektrik tüketim miktarına ait değerler Rapid Miner programına yüklenmiştir. Ocak 2000 - Aralık 2017 yılları arasındaki 216 aylık veri ile modeller eğitildikten sonra Ocak 2018 - Aralık 2019 arasındaki Test verisi üzerinde denenmiştir. Söz konusu bu süreç için Rapidminer programında hazırlanan model Şekil 3.31 de görülmektedir.



Şekil 3. 31. Rapidminer programında hazırlanan model

Rapidminer de kullanılan modellerde algoritmanın ezber yapmaması için Çapraz geçerleme yapılmıştır. Çapraz geçerlemenin içeriği aşağıda Şekil 3.32'de görülmektedir.



Şekil 3. 32. Rapidminer programında hazırlanan çapraz geçerleme detayı

3.2.3. Rapid Miner da Hazırlanan Modellere ait Parametrelerinin Belirlenmesi

Söz konusu uygulama 3 adet algoritma için eğitim sürecindeki parametreler değiştirilerek her algoritma için 10 defa olacak şekilde hazırlanmıştır. Bu algoritmalar için en iyi parametre değerlerini belirlemek için çok sayıda deneme yapılmış ve bu denemelerden en yüksek performansı gösteren paremetreler seçilmiştir.

3.2.3.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağı algoritmasının uygulanması için 10 adet olarak hazırlanan deneme modellerine ait paremetreler aşağıda Çizelge 3.5'te görülmektedir. Yapılan çok sayıda manuel denemeler sonucunda bu parametre kümeleri belirlenmiştir. Modellerde kullanılan girdi değişkenleri sabit tutulmuştur. Çapraz geçerleme, hücre sayısı, katman sayısı, İterasyon sayısı ve öğrenme oranlarında değişiklik yapılarak modeller hazırlanmıştır.

Çizelge 3. 5. Yapay sinir ağı algoritması için hazırlanan modeller

Model No	Girdi Değişkenleri	K (Çapraz Geçerleme)	1.Katman (Hücre Sayısı)	2.Katman (Hücre Sayısı)	İterasyon Sayısı	Öğrenme Oranı
1	IHR,ITH,TSÜE,N,Y,S	10	5	0	1500	0.10
2	IHR,ITH,TSÜE,N,Y,S	9	6	0	2000	0.10
3	IHR,ITH,TSÜE,N,Y,S	10	7	0	2500	0.05
4	IHR,ITH,TSÜE,N,Y,S	9	8	0	3000	0.05
5	IHR,ITH,TSÜE,N,Y,S	10	9	0	3500	0.10
6	IHR,ITH,TSÜE,N,Y,S	9	5	5	1500	0.05
7	IHR,ITH,TSÜE,N,Y,S	10	6	6	2000	0.05
8	IHR,ITH,TSÜE,N,Y,S	9	7	7	2500	0.05
9	IHR,ITH,TSÜE,N,Y,S	10	8	8	3000	0.10
10	IHR,ITH,TSÜE,N,Y,S	9	9	9	3500	0.10

3.2.3.2. Karar Ağacı (KA)

Karar ağacı algoritması için belirlenen 10 adet parametre kümesi aşağıda Çizelge 3.6'de görülmektedir. Yapılan çok sayıda manuel denemeler sonucunda bu parametre kümeleri belirlenmiştir. Modellerde kullanılan girdi değişkenleri ve uygulanan karar ağacı algoritması (En küçük kareler) sabit tutulmuştur. Çapraz geçerleme, maksimum derinlik, en düşük bilgi kazancı ve en düşük dal boyutu değerlerinde değişiklik yapılarak modeller hazırlanmıştır.

Çizelge 3. 6. Karar ağacı algoritması için hazırlanan modeller

Model No	Girdi Değişkenleri	K (Çapraz Geçerleme)	Kriter	Maksimum Derinlik	En Düşük Bilgi Kazancı	En düşük Dal Boyutu
1	IHR,ITH,TSÜE,N,Y,S	10	En küçük kareler	5	0.01	1
2	IHR,ITH,TSÜE,N,Y,S	9	En küçük kareler	10	0.02	2
3	IHR,ITH,TSÜE,N,Y,S	10	En küçük kareler	15	0.03	1
4	IHR,ITH,TSÜE,N,Y,S	9	En küçük kareler	5	0.04	2
5	IHR,ITH,TSÜE,N,Y,S	10	En küçük kareler	10	0.05	1
6	IHR,ITH,TSÜE,N,Y,S	9	En küçük kareler	15	0.1	2
7	IHR,ITH,TSÜE,N,Y,S	10	En küçük kareler	5	0.2	1
8	IHR,ITH,TSÜE,N,Y,S	9	En küçük kareler	10	0.3	2
9	IHR,ITH,TSÜE,N,Y,S	10	En küçük kareler	15	0.4	1
10	IHR,ITH,TSÜE,N,Y,S	9	En küçük kareler	20	0.5	2

3.2.3.3. Destek Vektör Makineleri (DVM)

Destek vektör makinesi için belirlenen 10 adet parametre kümesi aşağıda Çizelge 3.7'de görülmektedir. Yapılan çok sayıda manuel denemeler sonucunda bu parametre kümeleri belirlenmiştir. Modellerde kullanılan girdi değişkenleri sabit tutulmuştur. Çapraz geçerleme, Kernel tipi: Nokta çarpım (Dot),Varyans analizi (Anova), Kernel Cache, c, epsilon ve en fazla iterasyon değerlerinde değişiklik yapılarak modeller eğitilmiştir.

Çizelge 3. 7. Destek vektör makineleri algoritması için hazırlanan modeller

Model No	Girdi Değişkenleri	K (Çapraz Geçerleme)	Kernel Tip	Kernel Cache	C	Epsilon	En Fazla İterasyon
1	IHR,ITH,TSÜE,N,Y,S	10	Dot	200	0	0.001	100.000
2	IHR,ITH,TSÜE,N,Y,S	9	Anova	200	50	0.81	100.000
3	IHR,ITH,TSÜE,N,Y,S	10	Dot	200	8	0.002	100.000
4	IHR,ITH,TSÜE,N,Y,S	9	Anova	200	100	0.81	100.000
5	IHR,ITH,TSÜE,N,Y,S	10	Dot	200	200	0.001	100.000
6	IHR,ITH,TSÜE,N,Y,S	9	Anova	200	5	0.81	100.000
7	IHR,ITH,TSÜE,N,Y,S	10	Dot	200	50	0.05	100.000
8	IHR,ITH,TSÜE,N,Y,S	9	Anova	200	8	0.81	100.000
9	IHR,ITH,TSÜE,N,Y,S	10	Dot	200	100	0.003	100.000
10	IHR,ITH,TSÜE,N,Y,S	9	Anova	200	200	0.81	100.000

4.ARAŞTIRMA BULGULARI ve TARTIŞMA

Söz konusu uygulamada 3 algoritmanın eğitim sürecindeki parametre düzeyleri değiştirilerek her algoritma ile 10 tane model eğitilmiştir. Her model bir kez, toplamda program 30 kez çalıştırılmıştır. Eğitilen modellerin performansı RMSE kriteri ile ölçülmüştür. Modellerin Ocak 2000 - Aralık 2017 yılları arasındaki eğitim verisi üzerindeki ve Ocak 2018 - Aralık 2019 arasında ki döneme ait test verisi üzerindeki tahmin performansları RMSE değerlerine göre kıyaslanmıştır.

4.1. Yapay Sinir Ağları (YSA) Algoritması ile Elektrik Tüketim Tahminlemesi

YSA algoritması ile eğitilen modellerden elde edilen sonuçlara ait RMSE değerleri Çizelge 3.8'de görülmektedir.

Çizelge 3. 8. YSA modeline ait RMSE değerleri

Model No	Eğitim	Test
1	826.625 +/- 556.201	1583.409 +/- 0.000
2	778.067 +/- 372.376	5139.426 +/- 0.000
3	539.355 +/- 169.164	745.083 +/- 0.000
4	529.838 +/- 182.967	872.262 +/- 0.000
5	692.144 +/- 213.417	8327.685 +/- 0.000
6	628.803 +/- 263.530	1017.216 +/- 0.000
7	633.082 +/- 323.272	951.581 +/- 0.000
8	564.035 +/- 285.653	1455.359 +/- 0.000
9	815.162 +/- 472.525	5599.903 +/- 0.000
10	680.643 +/- 319.895	10308.275 +/- 0.000

4.2. Karar Ağacı Algoritması (KA) ile Elektrik Tüketim Tahminlemesi

Karar ağacı algoritması ile eğitilen modellerden elde edilen sonuçlar ait RMSE değerleri Çizelge 3.9'da görülmektedir.

Çizelge 3. 9. KA modeline ait RMSE değerleri

Model No	Eğitim	Test
1	1424.591 +/- 593.952	1620.214 +/- 0.000
2	1339.391 +/- 641.898	1579.846 +/- 0.000
3	1278.061 +/- 674.759	1635.242 +/- 0.000
4	1394.867 +/- 640.568	1620.214 +/- 0.000
5	1279.188 +/- 675.108	1635.242 +/- 0.000
6	1339.423 +/- 641.895	1579.846 +/- 0.000
7	1424.591 +/- 593.952	1620.214 +/- 0.000
8	1390.380 +/- 609.555	1579.846 +/- 0.000
9	1856.053 +/- 943.767	2117.382 +/- 0.000
10	1968.493 +/- 938.211	4237.906 +/- 0.000

4.3. Destek Vektör Makineleri (DVM) Algoritması ile Elektrik Tüketim Tahminlemesi

Destek vektör makinesi algoritması ile eğitilen modellerden elde edilen sonuçlar ait RMSE değerleri Çizelge 3.10'da görülmektedir.

Çizelge 3. 10. DVM modeline ait RMSE değerleri

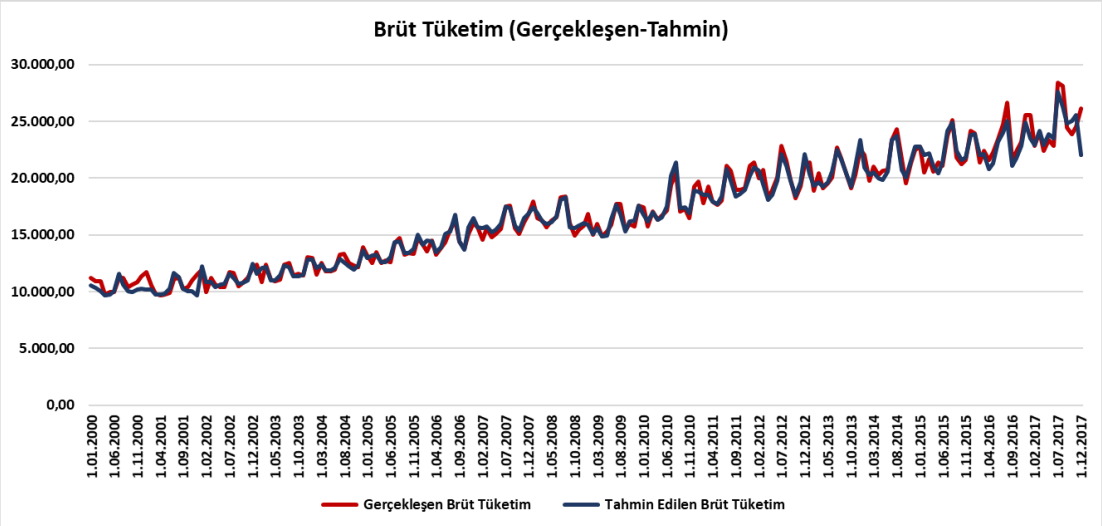
Model No	Eğitim	Test
1	4532.039 +/- 2299.710	8360.091 +/- 0.000
2	1023.616 +/- 1263.309	3564.723 +/- 0.000
3	1499.179 +/- 401.327	2509.185 +/- 0.000
4	979.739 +/- 1148.982	3045.081 +/- 0.000
5	1163.319 +/- 423.309	1813.994 +/- 0.000
6	1833.643 +/- 1876.086	6414.030 +/- 0.000
7	1225.904 +/- 426.019	2341.652 +/- 0.000
8	1533.954 +/- 1705.907	5629.239 +/- 0.000
9	1190.277 +/- 422.853	1949.340 +/- 0.000
10	1156.852 +/- 1191.439	3402.648 +/- 0.000

4.4. 3 Algoritmaya ait Modellerin Değerlendirilmesi

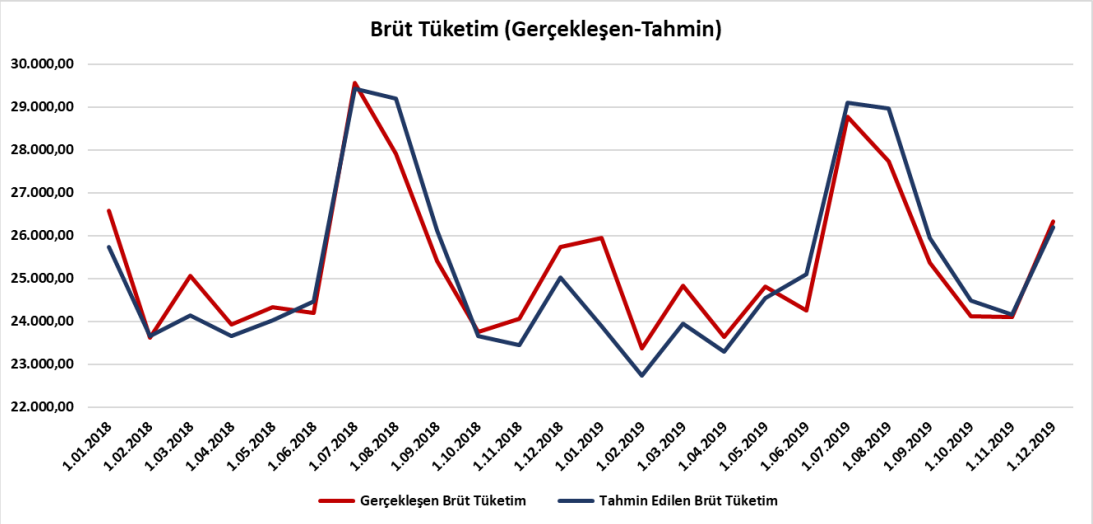
Bir model ile yapılan tahminlerin doğruluk ölçümünde kullanılan RMSE değeri 0'a ne kadar yakın olursa modelin tahmin performansı o kadar yüksek olur, dolayısıyla çıktı değişkeni için gerçekleşen değerlere daha yakın tahminler elde edilir.

Bu durumda Tablo 3.8, 3.9 ve 3.10'da modellerin test performanslarını gösteren RMSE değerleri incelendiğinde en küçük değerin 3 nolu YSA modeline ait olduğu (745.083 +/- 0.000) görülmektedir.

Gerçekleşen değerlerle birlikte 3 nolu YSA modelinin eğitim ve test verisi üzerindeki tahmin performansını gösteren grafikler aşağıda Şekil 4.1 ve Şekil 4.2'de görülmektedir.

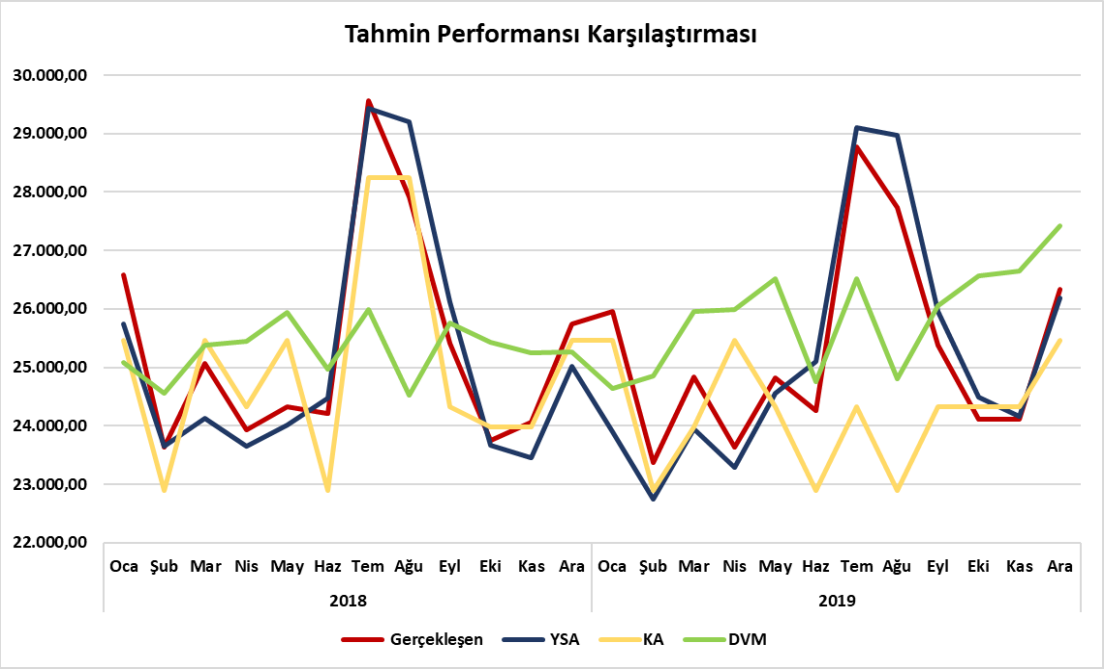


Şekil 4. 1. Eğitim tahmin performansı (Gerçekleşen-Tahmin)



Şekil 4. 2. Test tahmin performansı (Gerçekleşen-Tahmin)

Ayrıca 3 adet Algoritma ile eğitilen 30 adet modelden, her algoritma için tahmin performansı en yüksek olan modele ait tahmin değerleri ile gerçekleşen tüketim değerlerini bir arada gösteren grafik aşağıda Şekil 4.3'de görülmektedir.



Şekil 4. 3. YSA, KA, DVM Test tahmin performansı (Gerçekleşen-Tahmin)

5.SONUÇLAR ve ÖNERİLER

5.1. Sonuçlar

Literatüre bakıldığında elektrik tüketim tahmini başta olmak üzere birçok tahminleme çalışmasında giriş değişkeni olarak nitelikli ve büyük miktarda veri kullanıldığında YSA algoritmalarının çok iyi düzeyde öğrendiği ve bu öğrenim gücünü test verilerinde çok başarılı tahminler yaparak gösterdiği bilinmektedir.

Bu çalışmada elde edilen RMSE değerleri incelendiğinde, 3 nolu YSA modelinin diğer modellere kıyasla en küçük RMSE değerine sahip olduğu görülmektedir. Elde ettiğimiz bu sonuçlar ile literatür için yukarıda belirttiğimiz durum bir kez daha doğrulanmıştır.

Ayrıca Elektrik tüketim tahminlemesi çalışmalarında literatür incelendiğinde çoğunlukla yıl bazlı tahminler yapıldığı görülmektedir. Bu çalışmada ise literatürden farklı olarak aylık(dönemsel) tahmin yapılmıştır.

5.2. Öneriler

Bu uygulamada kullanılan ithalat, ihracat vb. giriş değişkenleri ile bölge ve il özelinde de tahmin çalışmaları yapılabilir. Ayrıca YSA algoritmasına kıyasla KA ve DVM algoritmasının performansı daha düşük kalmıştır. Bu düşük performansın geliştirilmesi için mevcut parametre değişikliklerine ek olarak parametreler üzerinde değişimler yaparak farklı modeller tasarlanabilir ve daha başarılı sonuçlar elde edilebilir.

KAYNAKLAR

ADRIAANS, P. ve ZANTINGE, D., 1996. "Data Mining", Addison-Wesley Professional Publishing Abd, Pp.10-78 110-120

AHMAD, A. S., HASSAN, M. Y., ABDULLAH, M. P., RAHMAN, H. A.,HUSSIN,F. and ABDULLAH, H., & SAIDUR, R., 2014. A Review on Applications of ANN and SVM for Building Electrical Energy Consumption Forecasting. Renewable and Sustainable Energy Reviews, 33: 102-109.

AKMAN, T., 2018. Yapay Zekâ Modelleri Kullanarak Ankara Bölgesinin KısaDönem Elektrik Enerjisi Yük Tahmini. Gazi Üniversitesi,Lisans Tezi, Fen Bilimleri Enstitüsü, Ankara.

ALAVALA, C.R., 2012, Fuzzy Logic and Neural Networks: Basic Concepts&Applications, New Age International, p.131, 135, 139.

ANNEMA, J., 2012, Feed-Forward Neural Networks: Vector Decomposition Analysis, Modelling and Analog Implementation, Springer Science & Business Media, p.9.

AYHAN, S. ,EDOĞMUŞ, Ş., (2014). Destek vektör makineleriyle sınıflandırma çözümü için çekirdek fonksiyon seçimi, Eskişehir Osmangazi Üniversitesi İibf Dergisi, 9 (1), 175- 198.

BEALE, R., JACKSON, T., 1990, Neural Computing: An Introduction, Taylor &Francis Group, p.118.

BİLGİLİ, M.,ŞAHİN, B., YASAR, A. ve ŞİMŞEK, E., 2012. "Electric Energy Demands of Turkey in Residential and Industrial Sectors", Renewable and Sustainable Energy Reviews, 16(1):404-414.

BOLTURK, E., ÖZTAYŞİ, B. ve I. U. SARI., 2012. "Electricity Consumption Forecasting Using Fuzzy Time Series", IEEE 13th International Symposium on Computational Intelligence and Informatics (CINTI), 2012:245-249

CARPENTER, G.A., GROSSBERG, S., 1987, A massively parallel architecture for a self-organizing neural pattern recognition machine, Computer Vision, Graphics, and Image Processing, 37,1, 54-115.

CHAI, T., DRAXLER, R., R., 2014. Root mean square error (RMSE) or Mean Error (MAE)? Geoscientific Model Development, 7: 1247-1250.

CHAKRABORTY, C., 2010, Adaptive Resonance Theory: Soft Computing Course Lecture 25-28, http://www.myreaders.info/05-Adaptive_Resonance_Theory.pdf, erişim tarihi: 20.12.2015.

ÇALIŞ, A., KAYAPINAR S. ve ÇETİNYOKUŞ T., 2019. Veri Madenciliğinde Karar Ağacı Algoritmaları ile Bilgisayar ve İnternet Güvenliği Üzerine Bir Uygulama. Gazi Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Dergisi, 25, 3-4.

DEMARTINES, P., BLAYO, F., 1992, Kohonen self-organizing maps: Is the normalization necessary?, Complex System, 6, 105-123.

DEMİREL, Ö., 2009. Anfıs ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.

DEMİRÖREN, A. ve CEYLAN, G., 2006. "Middle Anatolian Region Short-Term Load Forecasting Using Artificial Neural Networks", Electric Power Components and Systems, 34(6):707-724.

DEMREN, D., 2011. Electrical Load Demand Forecasting Application Using Support Vector Machines, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü,Yüksek Lisans Tezi, İstanbul.

DOĞAN, F. ve TÜRKOĞLU, İ., 2018. Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. Sakarya University Journal of Computer and Information Sciences, 1: 1-2018.

DORUK, E., 2019. Sakarya Bölgesi Hanehalkı Elektrik Tüketiminin Dinamik Lineer Model ile Tahmini. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sakarya.

EKİNCİ, M.E., 2017. Destek Vektör Regresyon ile Hava Kirliliği Tahmini. Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Eskişehir.

EKONOMOU, L., 2010. "Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks", Energy, 35(2):512-517.

POLAT, E., 2019. Türkiye'nin Aylık Elektrik Tüketiminin Yapaya Sinir Ağlarıyla Tahmini. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.

FAUSETT, L., 1994, Fundamentals of Neural Networks: Architectures, Algorithms and Applications, Prentice-Hall, p.3, 22, 48, 80, 88, 295-296.

FAYYAD, U.M., PIATETSKY-SHAPIRO, G. and SMYTH, P., 1996. "From Data Mining To Knowledge Discovery İn Databases" Aı Magazine 17(3) Pp. 37-54.

FRAWLEY, W. J., PIATETSKY-SHAPIRO, G and MATHEUS, J., 1991. "Knowledge Discovery İn Databases: An Overview" Aaaı Press Menlo Park.

FREEMAN, J.A., SKAPURA, D.M., 1991, Neural Networks: Algorithms, Applications, and Programming Techniques, Addison-Wesley Publishing Company, p.100, 102.

GHIASSI, M., ZIMBRA, D. K. and SAIDANE, H., 2006. "Medium Term System Load Forecasting With a Dynamic Artificial Neural Network Model", Electric Power Systems Research, 76(5):302-316.

GURNEY, K., 1997, An Introduction to Neural Networks, Kindle Edition, UCL Press, p.43- 44.

GUTIERREZ-OSUNA,R., 2002, Competitive Learning, http://research.cs.tamu.edu/prism/lectures/pr/pr_l16.pdf, erişim tarihi: 20.12.2015.

GÜNAY, M. E., 2016. "Forecasting Annual Gross Electricity Demand by Artificial Neural Networks Using Predicted Values of Socio-Economic Indicators and Climatic Conditions: Case of Turkey", Energy Policy, 90:92-101.

GÜRSOY, E., 2000. Yük Tahmini Yöntemleri ve Çukurova Elektrik AŞ, Kepez Elektrik T.A.Ş. Bölgelerine Uygulanması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.

GONZALEZ-ROMERA., JARAMILLO-MORAN, M. A. ve CARMONA-FERNANDEZ, D., 2008. "Monthly Electric Energy Demand Forecasting with Neural Networks and Fourier Series", Energy Conversion and Management, 49(11):3135-3142 .

HACİEFENDİOĞLU, Ş., 2012. Makine Öğrenmesi Yöntemleri ile Glokom Hastalığının Teşhisi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.

HAJEK, M., 2005, Neural Networks, http://www.cs.ukzn.ac.za/notes/NeuralNetworks2005.pdf, erişim tarihi: 20.12.2015.

HAMZAÇEBİ, C., Es, H. A. ve ÇAKMAK, R., 2017. "Forecasting of Turkey's Monthly Electricity Demand by Seasonal Artificial Neural Network", Neural Computing And Applications, 2017:1-15.
HAND D., MANNILA, H. VE SMYTH, M., 2001. "Principles Of Data Mining" Isbn: 026208290X Mıt Press İngiltere.
HAYKIN, S., 2009, Neural Networks and Learning Machines, 3rd Edition, Pearson Education, p.137.
HE, X., XU, S., 2010, Process Neural Networks: Theory and Applications, Springer Science & Business Media, p.128.
HOPFIELD, J.J., 1982, Neural networks and physical systems with emergent collective computational abilities, Proceedings of National Acad Sciences, 79, 8, 2554–2558.
İŞYAPAR, M. T., 2013. In Partial Fulfillment of the Reqouirements for the Degree of Master of Science in Computer Engineering. Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
JAIN, A.K., MAO, J., MOHIUDDIN, K.M., 1996, Artificial neural networks: A tutorial, Computer, 29, 3, 31-44.
KAVAKLIOĞLU, K., CEYLAN, H., ÖZTURK, H. K. ve CANYURT O. E. , 2009. Modeling and Prediction of Turkey's Electricity Consumption Using Artificial Neural Networks", Energy Conversion and Management, 50(11):2719-2727.
KARABULUT, D.,2021. Hastane Bilgi Yönetim Sistemlerinde Veri Madenciliği: Hasta Profil Tahmini. Karabük Üniversitesi, Fen Bilimleri Üniversitesi, Yüksek Lisans Tezi, Karabük.
KHAN, W.U., MAKWANA, A., 2005, Soft Computing, D. Garg, A. Singh (Eds.), Allied Publishers, p.33.
KILIÇALAN, M.B., 2018. Hanehalkı İşgücü Araştırma Verileri ile Veri Madenciliği Yöntemlerinin Uygulanması ve Modellerin Karşılaştırılması. Hacettepe Üniversitesi, İstatistik Anabilim Dalı, Ankara.
KOHONEN, T., 1982, Self-organized formation of topologically correct feature maps, Biological Cybernetics, 43, 1, 59-69.
KRAUSS, C., Do, X., A., HUCK, N., 2016. Deep Neural Networks, Gradient-Boosted Trees, Random Forests: Statistical Arbitrage on the S & P 500. European Journal of Operational Research, 259: 689-702.
KRIESEL, D., 2005, A Brief Introduction to Neural Networks, e-kitap, 8, 86, http://www.dkriesel.com/en/science/neural_networks, erişim tarihi: 18.12.2015.
KRÖSE, B., SMAGT, P., 1996, An Introduction to Neural Networks, 8th Edition, e-kitap, The University of Amsterdam, 17, https://www.infor.uva.es/~teodoro/neuro-intro.pdf, erişim tarihi: 18.12.2015.
LEE, W. and STOLFO, J., 1998. "Data Mining Approaches For Intrusion Detection" 7Th Usenıx Security Symposium San Antonio Teksas Abd.
MEHROTRA, K., MOHAN, C.K., RANKA, S., 1996, Elements of Artificial Neural Networks, The MIT Press, p.9, 85.
MITCHELL, T.M., 1997, Machine Learning, McGraw-Hill, p.88.
NEGNETVITSKY, M., 2005, Artificial Intelligence: A Guide to Intelligent Systems, 2nd Edition, Addison-Wesley, p.189, 207.
NOBACK, C.R., STROMINGER, N.L., DEMAREST, R.J., RUGGIERO, D.A., 2005, The Human Nervous System: Structure and Function, Springer Science & Business Media, p.67.

OĞCU, G., DEMİREL, O. F. and ZAİM, S., 2012. "Forecasting Electricity Consumption With Neural Networks and Support Vector Regression", Procedia-Social and Behavioral Sciences, 58:1576-1585.
ÖZTEMEL, E., 2012, Yapay Sinir Ağları, 3. Basım, Papatya Yayıncılık, s.137
ÖZDEŞ, M., 2017. Büyük Veri Araçlarını Kullanarak Duygu Analizi Gerçekleştirimi. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Denizli.
PRIDDY, K.L., KELLER, P.E., 2005, Artificial Neural Networks: An Introduction, SPIE Press, p.5.
ROJAS, R., 1996, Neural Networks: A Systematic Introduction, Springer, p.374.
RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., 1986, Learning representations by back propagating errors, Nature, 323, 533-536.
SAAB, S., BADR, E. and NASR, G., 2001. "Univariate Modeling And Forecasting of Energy Consumption: The Case Of Electricity in Lebanon", Energy, 26(1):1-14.
SAFAVIAN, S. R., & LANDGREBE, D., "A survey of decision tree classifier methodology", IEEE transactions on systems, man, and cybernetics, 21(3), 660-674, (1991).
SARLE, W. S., 1994. "Neural Networks and Statistical Models" Proceedings Of The 19 Th. Annual Sas Users Group International Conference Cary Nc: Sas Institute Pp.1538-1550.
SCHALKOFF, R. J., 1992. "Pattern Recognition: Statistical Structural And Neural Approaches" Wiley New York Abd.
SELVAUXMİY, S., RAGEL. R., and KUMARA T.N., 2016. Accelerating K-NN Classification Algorithm Using Graphics Processing Units. IEEE International Conference on Information and Automation for Sustainability (ICIAfS)
SEZGIN, N., TEKIN, R., ÇALIŞKAN, A., 2012, Örüntü tanımada Hopfield ağının kullanılması, Yaşam Bilimleri Dergisi, 2, 1, 257-266.
SIVANANDAM, S.N., SUMATHI, S., DEEPA, S.N., 2006, Introduction to Neural Networks Using Matlab 6.0, McGraw-Hill, p.187, 260-261.
SİLAHTAROĞLU, G., 2013. "Veri Madenciliği Kavram ve Algoritmaları" 2. Basım, Papatya Yayıncılık, İstanbul.
SMITH, B.R., 1997, Neural network enhancement of closed-loop controllers for ill-modeled systems with unknown nonlinearities, Ph.D. thesis, Faculty of the Virginia Polytechnic Institute and State University, 139 p.
SNELL, R.S., 2010, Clinical Neuroanatomy, Lippincott Williams & Wilkins, p.34.
ŞANLITÜRK, E., 2018. Makine Öğrenme Algoritmarıyla Hatalı Ürün Tahmini. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
TAYLOR, B.J., 2006, Methods and Procedures for the Verification and Validation of Artificial Neural Networks, Springer Science & Business Media, p.71.
TOKSARI, M. D., 2007. "Ant Colony Optimization Approach to Estimate Energy Demand of Turkey", Energy Policy, 35(8):3984-3990.
TOKSARI, M. D., 2016. "A Hybrid Algorithm Of Ant Colony Optimization (ACO) and Iterated Local Search (ILS) for Estimating Electricity Domestic Consumption: Case of Turkey", International Journal of Electrical Power & Energy Systems, 78:776782.
UZLU, E., KANKAL, M., AKPINAR, A. and DEDE, T., 2014. "Estimates of Energy Consumption in Turkey Using Neural Networks with the Teaching–LearningBased Optimization Algorithm", Energy, 75:295-303.

WITTEN, H. and FRANK, E., 2000. Data Mining: Practical Machine Learning Tools And Techniques With Java Implementations Morgan Kaufmann Publishers Isbn 1-.55860-5525.

YALÇINOZ, T. and EMİNOĞLU, U., 2005. "Short Term And Medium Term Power Distribution Load Forecasting By Neural Networks", Energy Conversion and Management, 46(9-10):1393-1405.

YEGNANARAYANA, B., 1999, Artificial Neural Networks, p.26-27, 88.

YOHANNES Y., 2018. Hoddinott J., Classification and Regressıon Trees: An Introductıon Technical Guide, International Food Policy Research Institute. 2033 K Street, N.W. Washington, D.C. 2006 U.S.A., Mart 1999, S.2, Classification and Regression Trees an Introduction.

ZURADA, J.M., 1992, Introduction to Artificial Neural Systems, West Publishing Company, p.55, 57, 66-67.

Towards. "Towards Data Science". Erişim:1 Mayıs 2021. https://towardsdatascience.com/clearly-explained-how-machinelearning-differs-from-statistical-modeling-967f2c5a9cfd

Veri Bilimcisi. Erişim: 24 Nisan 2021.https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/ adresinden edinilmiştir.

Fred 1. "Organization for Economic Co-operation and Development (OECD)", Exports: Value Goods for Turkey [XTEXVA01TRM664N], retrieved from FRED, Federal Reserve Bank of St. Louis; Erişim: 24 Nisan 2021. https://fred.stlouisfed.org/series/XTEXVA01TRM664N

Fred 2. "Organization for Economic Co-operation and Development (OECD)",Imports: Value Goods for Turkey [XTIMVA01TRM664N], retrieved from FRED, Federal Reserve Bank of St. Louis. Erişim: 24 Nisan 2021. https://fred.stlouisfed.org/series/XTIMVA01TRM664N

Fred 3, "Organization for Economic Co-operation and Development (OECD)", Production of Total Industry in Turkey [TURPROINDMISMEI], retrieved from FRED, Federal Reserve Bank of St. Louis; https://fred.stlouisfed.org/series/TURPROINDMISMEI

TÜİK Nufus. "Yıllara Göre İl Nufusları". Erişim: 24 Nisan 2021. https://data.tuik.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-SistemiSonuclari-2020-37210

MGM Yağış. "Türkiye Yağış 2020". Erişim: 24 Nisan 2021. https://www.mgm.gov.tr/veridegerlendirme/il-veilceleristatistik.aspx?k=parametrelerinTurkiyeAnalizi.

MGM Sıcaklık." Türkiye Ortalama Sıcaklık 2020". Erişim: 24 Nisan 2021. https://www.mgm.gov.tr/veridegerlendirme/ilveilceleristatistik.aspx?k=parametrelerinTurkiyeAnalizi.

TEİAŞ, "48-Tür. El. En. Ür-İt-İh.ve Brüt Talebinin Yıllar İtibariyle Aylık Dağılımı (1989-2002), 49-Tür. El. En. Ür-İt-İh.ve Brüt Talebinin Yıllar İtibariyle Aylık Dağılımı (2003-2019)". Erişim 24 Nisan 2021. https://www.teias.gov.tr/tr-TR/turkiye-elektrik-uretim-iletim-istatistikleri.