T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KURULUŞLARIN ENERJİ TALEBİ ANALİZİ ve TAHMİNİ

Sefa BEYAZTOPRAK

DANIŞMAN
Dr. Öğr. Üyesi Cengiz Polat UZUNOĞLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

İSTANBUL-2019

Bu çalışma 01.07.2019 Tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektrik-Elektronik Mühendisliği Programı Yüksek Lisans Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

Dr.Öğr.Üyesi Cengiz Polat UZUNOĞLU
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr.Öğr.Üyesi Abdurrahim AKGÜNDOĞDU
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr.Öğr.Üyesi Serap CEKLİ
Maltepe Üniversitesi
Mühendislik ve Doğa Bilimleri Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, İstanbul Üniversitesi-Cerrahpaşa Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin ..... numaralı projesi ile desteklenmiştir.
Bu tez, ... numaralı ..... projesi ile desteklenmiştir.

ÖNSÖZ

Yüksek lisans eğitimim boyunca ve tez hazırlama sürecinde yardımlarını esirgemeyen, bilgisi ve desteğiyle sürekli yönlendirmelerine ihtiyaç duyduğum Dr. Öğr. Üyesi Cengiz Polat UZUNOĞLU'na katkılarından dolayı en derin saygı ve şükranlarımı sunarım. Hazırlamış olduğum tezde verilerin sağlanması konusunda yardımcı olan Alstom fabrikası ve Tesis Yönetim Sorumlusu Mahmut Kısacık'a teşekkürü bir borç bilirim.

Son olarak bana olan inancını hiçbir zaman yitirmeyen ve her konuda desteklerini arkamda hissettiğim annem Nevin Beyaztoprak ve babam Zeynal Beyaztoprak'a sonsuz teşekkürlerimi sunarım.

Haziran 2019 Sefa BEYAZTOPRAK

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **vii**
TABLO LİSTESİ ..... **ix**
SİMGE VE KISALTMA LİSTESİ ..... **x**
ÖZET ..... **xi**
SUMMARY ..... **xii**
1. GİRİŞ **1**
2. GENEL KISIMLAR **4**
2.1 ENERJİ TALEBİ 4
2.2 ENERJİ YÖNETİMİ VE ENERJİ TALEBİNİ ETKİLEYEN FAKTÖRLER 6
2.3 MAKİNE ÖĞRENMESİ 7
2.3.1 Gözetimli Öğrenme (Supervised Learning) 9
2.3.2 Gözetimsiz Öğrenme (Unsupervised Learning) 10
2.3.3 Takviyeli Öğrenme 12
2.4 YAPAY SİNİR AĞLARI 12
2.4.1 Yapay Sinir Ağlarında Öğrenme 14
3. MALZEME VE YÖNTEM **15**
3.1 ENERJİ TALEP ANALİZİ YAPILAN FABRİKA 15
3.2 KULLANILAN ALGORİTMALAR 16
3.2.1 3.2.1. WEKA 16
3.2.2 3.2.2 Çapraz Doğrulama (Cross Valıdatıon) 18
3.2.3 Oranlı Bölme (Percantage Splıt) 19
3.2.4 Eğitim Bölümü (Use Tranının Set) 19
3.2.5 Test Sonuçlarının Yorumlanması 20
3.3 KULLANILAN ALGORİTMALAR 22
3.3.1 Doğrusal Regresyon 23
3.3.2 Çok Katmanlı Algılayıcılar 24
3.3.3 Rassal Orman 26
3.3.4 M5P Algoritması 28

3.3.5 K-NN Algoritması 29
4. BULGULAR 30
4.1 VERİ SETİ 30
4.2 DOĞRUSAL REGRESYON SONUÇLARI 31
4.3 ÇOK KATMANLI ALGILAYICI ALGORİTMASI 34
4.4 RASSAL ORMAN ALGORİTMASI 36
4.5 M5P ALGORİTMASI 40
4.6 KNN ALGORİTMASI 43
5. TARTIŞMA VE SONUÇ 45
KAYNAKÇA 47
ÖZGEÇMİŞ 50

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1 Türkiye elektrik enerjisi talep tahmini (Enerji ve Tabii Kaynaklar Bakanlığı, 2017)....4

Şekil 2.2 Enerji yönetim diyagramı....7

Şekil 2.3 Makine öğrenme şeması....8

Şekil 2.4 Gözetimli öğrenme akış diyagramı (Şeker, 2008)....9

Şekil 2.5 Kedi ve köpek eğitim verisi (Kaggle web sitesi, 2019)....10

Şekil 2.6 Gözetimsiz öğrenme akış diyagramı (Şeker, 2008)....11

Şekil 2.7 Yapay sinir ağı gösterimi (Keskenler & Keskenler, 2017)....13

Şekil 3.1 Trafo üretim şeması....15

Şekil 3.2 Alstom fabrikası genel görünüş....16

Şekil 3.3 WEKA yazılımı arayüzü....17

Şekil 3.4 WEKA özellik arayüzü....18

Şekil 4.1 Doğrusal regresyon gerçek değer ve tahmin edilen değer karşılaştırması....33

Şekil 4.2 Doğrusal regresyon hata gösterimi....33

Şekil 4.3 Çok katmanlı algılayıcı çift katman gösterimi....35

Şekil 4.4 Çok katmanlı algılayıcı gerçek ve tahmin karşılaştırması....36

Şekil 4.5 Çok katmanlı algılayıcı hata gösterimi....36

Şekil 4.6 Rassal orman gerçek değer ve tahmin değeri karşılaştırma....39

Şekil 4.7 Rassal orman hata gösterimi....39

Şekil 4.8 M5P algoritması ağaç oluşumu....40

Şekil 4.9 M5P Algoritması gerçek değer ve tahmin değeri karşılaştırması....42

Şekil 4.10 M5P algoritması hata gösterimi....42

Şekil 4.11 KNN gerçek değer ve tahmin değeri karşılaştırma....44

Şekil 4.12 KNN hata gösterimi 44

TABLO LİSTESİ

Sayfa No

Tablo 3.1 Matris verilerinin açılımı....20
Tablo 3.2 Hata parametrelerin açılımı....21
Tablo 4.1 Veri seti....30
Tablo 4.2 Öznitelik tablosu....31
Tablo 4.3 Doğrusal regresyon eğitim sonuçları....32
Tablo 4.4 Doğrusal regresyon çapraz doğrulama sonuçları....32
Tablo 4.5 Doğrusal regresyon oranlı bölme sonuçları....32
Tablo 4.6 Çok katmanlı algılayıcı eğitim sonuçları....34
Tablo 4.7 Çok katmanlı algılayıcı çapraz doğrulama sonuçları....34
Tablo 4.8 Çok katmanlı algılayıcı oranlı bölme sonuçları....35
Tablo 4.9 Rassal orman eğitim sonuçları....37
Tablo 4.10 Rassal orman çapraz doğrulama sonuçları....37
Tablo 4.11 Rasal orman oranlı bölme sonuçları....37
Tablo 4.12 Rassal orman gerçek ve tahmin değerlerinin karşılaştırıldığı örnek sonuçlar....38
Tablo 4.13 M5P algoritması eğitim sonuçları....41
Tablo 4.14 M5P algoritması çapraz doğrulama sonuçları....41
Tablo 4.15 M5P algoritması oranlı bölme sonuçları....41
Tablo 4.16 KNN algoritması eğitim sonuçları....43
Tablo 4.17 KNN algoritması çapraz doğrulama sonuçları....43
Tablo 4.18 KNN algoritması oranlı bölme sonuçları....43

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

°C : Santigrat Derece
%Rh : Nem Yüzdesi
m² : Metrekare
X : Giriş Verisi
Y : Çıktı
e” :Hata Gösterimi
D1 :Hata Büyüklüğü
D2 :Kesin Hata
D3 :Hata Kare
AJ :Gerçek Değer
PJ :Tahmin Değeri
KVAR/GÜN :Gün Bazında Harcanan Reaktif Güç

Kısaltmalar **Açıklama**

kV : Kilo Volt
MAPE :Ortalama Mutlak Yüzde Hata
STFL :Kısa Dönemli Yükleme Tahmini
CART : Sınıflandırma ve Karar Ağacı
RMSE : Kök Ortalama Kare Hata
MARE : Ortalama Mutlak Göreceli Hata
HL : Isıtma Yükü
CL : Soğutma Yükü

ÖZET

YÜKSEK LİSANS TEZİ

KURULUŞLARIN ENERJİ TALEBİ ANALİZİ ve TAHMİNİ

Sefa BEYAZTOPRAK

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Cengiz Polat UZUNOĞLU

Elektrik enerjisi dağıtımında büyük güçlü tüketiciler yüksek enerji ihtiyaçları nedeniyle devamlı olarak gözlemlenmelidir. Büyük güçlü tüketicilerin yük durumları şebekelerin düzgün çalışmasını, kararlılığını ve devamlılığını belirlemektedir. Bu tez kapsamında piyasada aktif olarak çalışan bir trafo fabrikası, büyük güçlü endüstriyel tüketici örneği olarak seçilmiştir. Bu fabrikanın enerji talepleri analiz edilmiş ve enerji ihtiyacının tahminine yönelik çalışmalar çeşitli algoritmalar kullanılarak yapılmıştır. Çeşitli ortam ve çalışma şartlarının enerji talebine etkilerinin belirlenmesi için bir senelik veri seti kullanılmıştır. Fabrikanın aktif güç tüketimini tahmin etmek için nem, mevsim, sıcaklık, çalışan sayısı vb. parametreler kullanılmıştır. Çeşitli matematiksel ve makine öğrenmesi yöntemleriyle fabrikanın enerji talebinin incelenmesi ve modellenmesi yapılmıştır. Tahmin modellerinde Doğrusal regresyon, M5P, Çok Katmanlı Algılayıcı, KNN, rassal orman algoritmaları kullanılmıştır. Büyük güçlü tüketiciler için enerji talebi tahminlerinin önerilen yöntemlerle etkili bir şekilde yapılabildiği ortaya konulmuştur.

Haziran 2019, 62 sayfa.

Anahtar kelimeler: enerji talebi, makine öğrenmesi, enerji analizi,

SUMMARY

M.Sc. THESIS

ANALYSIS AND PREDICTION OF ENERGY DEMAND FOR INSTITUTIONS

Sefa BEYAZTOPRAK

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Electrical and Electronic Engineering

Supervisor : Assist. Prof. Dr. Cengiz Polat UZUNOĞLU

In the power distribution systems high power consumers need to be observed constantly due to their extreme power demand. Loading of high power consumers define proper operation of networks, stability and durability of the power systems. In this thesis a transformer factory is chosen as a high power consumer which is fully operational. Power demand of this factory is analyzed and prediction of energy demand is investigated by using different algorithms. In order to investigate effects of the various environmental and operational effects on energy demand, a one-year data set is used. Active power consumption of the factory is predicted by using environmental and operational factors such as humidity, season, temperature, number of workers and etc. By using various mathematical and machine learning methods energy demand of the factory is investigated and modelled. Linear regression, M5P, multi-layer perceptron, KNN and random forest algorithms are employed for prediction model of the factory. Energy demand predictions of high power consumers can be fulfilled by using proposed methods effectively.

June 2019, 62 pages.

Keywords: Energy demand,machine learning, Energy analysis

1. GİRİŞ

Sürdürülebilir, kaliteli ve ulaşılabilir enerjinin temini, aynı zamanda kullanılan enerjinin en verimli şekilde kullanılarak kazanç sağlanması kalkınmanın temelini oluşturur. Verimi artırmak ve enerjiyi yönetebilmek için enerjinin okunması yani tüketilen enerjinin değişken tüm parametrelerini anlık olarak izlenmesi, kontrol altına alınması ile yapılır. Elektrik enerjisinde bu parametreler genellikle aktif güç, reaktif güç, harmonik bozulmalar ve talep gibi parametrelerdir (Üstünsoy, 2018). Bu verilerin kontrolünün ve yorumunun yapılması sadece enerji planının yapılmasında değil ayrıca arıza sıklıkları, enerjinin kalitesi, verimlilik oranları, ödenen fatura bedellerine kadar birçok hususta bilgi vermektedir. Yenilebilir olmayan enerji kaynaklarının kısıtlı olması nedeniyle enerji tüketimindeki artışla beraber doğru planlama ve verim artırma çalışmaların önemini ortaya koymaktadır. Ayrıca kaynakların kısıtlı olmasının ve talebin artmasının haricinde üretilen elektrik enerjisinin depolanamaması diğer bir sorundur. Dolayısıyla elektrik enerjisin kendine özgü bu yapısı nedeniyle enerji tüketimi ve üretimi paralel olmalıdır.

Elektrik enerjisi iletim, üretim dağıtım sistemlerinde düzenli planlamaların yapılması ve öngörülerin uygun ve doğru sonuçlar vermesi için talep tahmin yöntemlerine başvurulmaktadır. Türkiye'de enerji talep tahmini üzerine yapılan çalışmalar 1960'lara dayanmaktadır. 1970'ler sonrasında talep tahminlerinde matematiksel yöntemler kullanılmaya başlanmıştır (Tugal, 2014). İlk etapta kullanılan basit regresyon modelleri 1984'ten sonra enerji planlanması ve ulusal politikalarda kullanılmaya başlanmıştır. Devlet Planlanma Teşkilatı (DPT) ve Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) tarafından yapılan bu tahminler genellikle gerçekleşen tüketim değerlerinin çok daha üstünde değerler elde edilmesine yol açmıştır (Tugal, 2014).

Bu çalışmada enerji tüketiminin yoğun olarak gerçekleştiği endüstriyel tesislerin enerji talep tahmin analizinin çeşitli makine öğrenmesi algoritmaları ile yapılması önerilmiştir. Veri setinde günlük ortalama sıcaklık değerleri, ortalama nem değerleri, aktif güç, reaktif güç, çalışan sayısı, üretim miktarı, fabrikanın kapalı açık olma durumu, hangi mevsim olduğu gibi veriler değerlendirilerek analiz edilmiştir. Talep tahmin analizlerinde birçok algoritma ve yöntem bulunmaktadır. Buna bağlı olarak en doğru analizi gerçekleştiren ve tahmin konusunda en başarılı algoritma seçilmiş ve makine öğrenmesi gerçekleşmiştir. Kullanılan makine öğrenmesi

programı ve buna bağlı algoritmalar detaylı bir şekilde açıklanmıştır. Veriler gerçek bir trafo fabrikasından alınmış olup, çevresel ve işletme açısından değişken parametrelerin enerji tüketimi üzerindeki etkisi incelenmiştir.

Analiz çalışmasının yapıldığı fabrika yaklaşık 90.000 m² alan üzerine kurulu büyük kapasitelerde güç transformatörü, jeneratör kesicileri, hava ve gaz yalıtımlı kesiciler, ayırıcılar, güç kompanzasyonu ve ölçü transformatörleri üretimlerinin yapıldığı endüstriyel bir tesistir. 800 kV'a kadar test yapabilen 4 test laboratuvarını bünyesinde bulundurmaktadır. 525 kV'tan 1200 MVA'a kadar tüm güç aralıklarında transformatör üretme kapasitesine sahip bir tesistir. 90.000 m² karelik alanın 54.000 m²'lik kapalı alandan oluşmaktadır.

Bu çalışmada WEKA yazılımından yararlanılmıştır. WEKA, makine öğrenimi amacıyla Waikato Üniversitesinde geliştirilmiş ve "Waikato Environment for Knowledge Analysis" kelimelerin baş harflerinden oluşmuş yazılımın ismidir (Waikato, 2005). Günümüzde yaygın kullanımı olan çoğu öğrenme algoritmalarını ve metotlarını içermektedir. Ayrıca program açık kaynak kodludur. Analiz kısmında kullanılan algoritmalar çok katmanlı perseptron (Multilayer perceptron), doğrusal regresyon, rassal orman (random forest), KNN ve m5p' dir.

Çok katmanlı perseptron yapay sinir ağı daha çok tıp ve mühendislik alanında çok kullanılan bir modeldir. Bu tarz çok katmanlı ağlar bir girdi kısmı, bir veya birden fazla gizli katman ve bunlara bağlı çıktı kısmından oluşmaktadır. Bir katmandaki tüm elemanlar sonrasında gelecek olan üst katmandaki tüm elemanlara bağlıdır. Bilgi akışı sürekli olarak ileri beslemelidir. Girdi ve çıktı elemanları arasında bulunan ara gizli katmanların fazlalığı hata oranın düşürür fakat test kümesinde de hata oranının artışına sebep olur (Karabacak, 2012).

Rastgele orman algoritması son zamanlarda yaygın olarak çeşitli çalışmalarda kullanılmaktadır. Yaygın kullanımının en önemli nedenlerinden biri sistem içerisinde oluşturulan ağaç yapısının kurallarının sade ve anlaşılır olmasıdır. Genelde karmaşık bir problemi aşamalı bir sisteme dönüştürerek basit karar verdirebilir bir yapıya dönüşmesini sağlar. Karar ağaçları özniteliklere göre dallanmaları oluşturur. Nitelik seçiminde en yaygın kriterler entropi, ID3, C4.5 algoritmaları ve regresyon ağaçları şeklinde sıralanabilir (İnce, 2018).

Doğrusal regresyon analizi veri içerisinde bulunan iki değişken arasındaki fonksiyonu bulmak için kullanılmaktadır. İki değişken arasındaki bu ilişki hem zıt yönlü hem de aynı yönlü olabilir. Basit regresyon modelinde tek bağımsız değişken ile tek bağımlı değişkeni incelerken çoklu

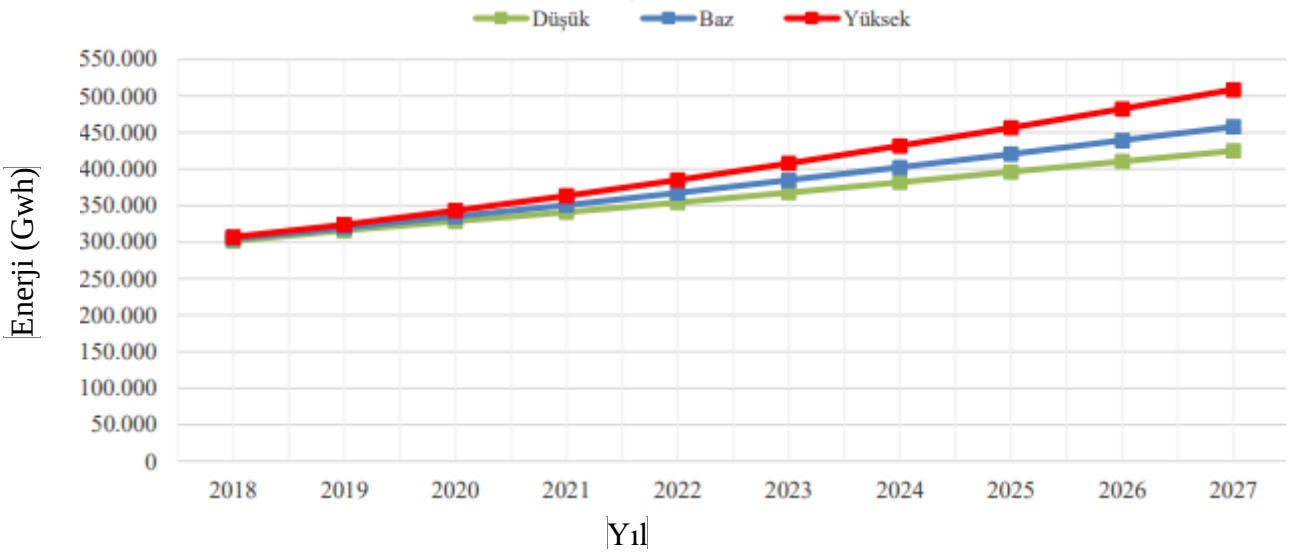
doğrusal regresyonda bir bağımlı değişken birçok bağımsız değişkenle ifade edilir (Akın, 2018). Bu regresyon yönetiminde genelde en küçük kareler yöntemi ve en büyük olabilirlik yöntemi kullanılır. Daha çok hava durumu tahmini, bir ürüne olan talep ve güç tüketim tahminlerinde verimli sonuçlar ortaya koymaktadır.

KNN, en yakın komşuluk algoritmaları literatürde yaygın olarak kullanılan en basit örnek tabanlı öğrenme algoritmalarındandır (Çölkesen & Kavzoğlu, 2017). Fonksiyon sayısal veya sembolik öznitelik değerlerine sahip olan veri setlerin sınıflandırılmasında kullanılır. KNN algoritması 2009 yılında Husain Aljazzar tarafından doktora çalışması sırasında geliştirmiştir. K algoritması diğer örnek tabanlı algoritmalardan ayrılan iki avantaj sunar. Bunlardan birincisi hızlı çalışma özelliğine sahip olması ve hedef kılavuzlu arama için sezgisel değerlendirme işlevini kullanmasıdır (Haufe, 2017). Bu çalışmada kullanılan algoritmalar ile gelecek tahmin enerji projeksiyonunda kullanılarak yapılacak yatırımların doğru bir şekilde planlanmasını kolaylıkla yapılabilir.

2. GENEL KISIMLAR

2.1 ENERJİ TALEBİ

Sürdürülebilir enerji sistemleri, gelecek nesillerin gelişimini tehlikeye atacak çevresel etkilerden kaçınarak doğal kaynakları korumak için gereklidir. Sürdürülebilir enerji sağlamak, talep tarafı da dâhil olmak üzere üretim sürecinin verimliliğini arttırmaktadır. Gelecekteki enerji kaynaklarının mimarisinin, kojenerasyon ve yenilenebilir enerji sistemleri de dâhil olmak üzere, artan sayıda dağıtılmış enerji kaynağı ile geleneksel merkezi enerji santrallerinin bir kombinasyonu şeklinde olacağı öngörülmektedir. Bu nedenle, güç tüketen tesislerin enerji talebini öngören etkin tahmin araçları gereklidir. Enerji piyasalarında tahminin rolü, elektrik enerjisi satın almak ve üretmek, yük değiştirme ve talep tarafı yönetimi gibi kilit karar verme aşamalarında önemlidir. Bu nedenle enerji taleplerinin analizi yeni yapılacak yatırımlar ve üretim için önem teşkil etmektedir (Schellong, 2011). Şekil 2.1'de Türkiye'nin belirtilen yıllar arasındaki talep eğrisi bizlere enerji talep artışının ne denli hızla arttığını göstermiştir (YerTutucu1; TEİAŞ Planlama ve Yatırım Dairesi Başkanlığı , 2017). Bu tarz sistemler için çeşitli analiz ve tahmin yöntemleri mevcuttur.



Şekil 2.1 Türkiye elektrik enerjisi talep tahmini (Enerji ve Tabii Kaynaklar Bakanlığı, 2017)

Şekil 2.1'de gösterilen talep projeksiyonunda elektrik tüketimini etkileyen başlıca etkenler ekonomik büyüme oranı, nüfus, hane halkı sayısı, ulaştırma sektörünün tüketime katkısı, iç

tüketim kayıpları, şebeke kayıpları ve verimlilik şeklinde sıralanabilir (Türkiye Elektrik Enerjisi Talep Projeksiyon Raporu, 2017).

Karar ağacı algoritması, temel makine öğrenme algoritmalarından biridir. Bir çalışmada (Gladysz & Kuchta, 2008), CART (Sınıflandırma ve Regresyon Ağaçları) versiyonu, Polonya'daki bir enerji bölgesinden bir yıllık saatlik elektrik tüketimi veri setine uygulanmıştır. Hava ile ilgili faktörleri, güne bağlı faktörlerin yapısını ve takvim ile ilgili faktörleri girdi verisi olarak kullanılmıştır.

Polonya Güç Sistemlerinin elektrik yükleri hakkındaki tahmin edebilme yeteneğini ölçmek için 2002 - 2004 yılları arasındaki elektrik enerji tüketim veri setlerini CART (Sınıflandırma ve Regresyon Ağaçları) sınıflandırıcıları topluluğundan rasgele orman yöntemini kullanarak analiz etmiştir (Dudek, 2014). Test seti olarak iki farklı ay verisi alınmıştır. Ortalama olarak ulaştıkları MAPE (Ortalama Mutlak Yüzde Hatası) değeri 1.16 olmuştur.

STLF'de (Kısa Dönem Yük Tahmini) çeşitli çalışmalarda destek vektör makineleri yöntemi uygulanmıştır. Bu çalışmalardan birinde, Suudi Arabistan'ın doğu bölgesinden saatlik elektrik yükü verilerine 1 Ocak 1992'den itibaren toplanan 6 yıllık veriye destek vektör makineleri algoritması uygulanmıştır. Geçmiş yük verileri girdi olarak alınmıştır. Mevsim verilerini kaldırdıktan sonra yine aynı algoritmayı kullanmışlardır. Performans ölçüleri RMSE (Kök Ortalama Kare Hata) olarak verilmiş ve 0.0028 RMSE değeri görülmüştür (Mohandes, 2002).

Çok sayıda etki faktörü ve belirsizlikleri nedeniyle, enerji talebi için kesin bir fiziksel model oluşturmak mümkün değildir. Bu nedenle, enerji talebi, iklim faktörlerinin ve çalışma koşullarının enerji tüketimi üzerindeki etkisini tanımlayan istatistiksel modellere dayanarak hesaplanmaktadır. Ayrıca yapay zekâ araçları kullanılmaktadır. Enerji talebi tahmini için çok çeşitli matematiksel yöntemler ve fikirler kullanılmıştır (Fischer, 2008).

Diğer bir makine öğrenme aracı yapay sinir ağlarıdır (YSA). Literatürde bu yöntem ve türevleri kısa çalışma yükünü tahmin etmek için çeşitli çalışmalarda uygulanmıştır. Bir çalışmada (Lee & Park, 1992), her mevsim için 1 aylık Kore Elektrik Şirketi'nden saatlik elektrik yükü verilerine YSA algoritması uygulanmıştır. Girdi olarak yalnızca önceki yük verilerinin bazıları kullanılmıştır. Bu verileri kullanarak, yaklaşık yüzde 2 bağıl hataya ulaşmışlardır.

Hong (Hong, Dong, Chen, & Wei, 2011), aylık elektrik yüklerini tahmin etmek için destek vektör regresyon (SVR) modelini, kaotik bağışıklık algoritmasını ve mevsimsel ayarlama mekanizmasını içeren tahmin modelini geliştirmiştir. Tüm modeller, ürettikleri tahmin hataları temelinde karşılaştırılmaktadır.

Suchao Jake Parkpoom (Parkpoom, 2007), iklim değişikliğinin Tayland'ın kısa ve uzun vadeli elektrik talebini nasıl etkileyeceğini ve sıcaklığın günlük ve mevsimsel talep üzerindeki etkisini yakalamak için öngördüğü konut ve ticari tüketimine ilişkin regresyon analizini önermiştir.

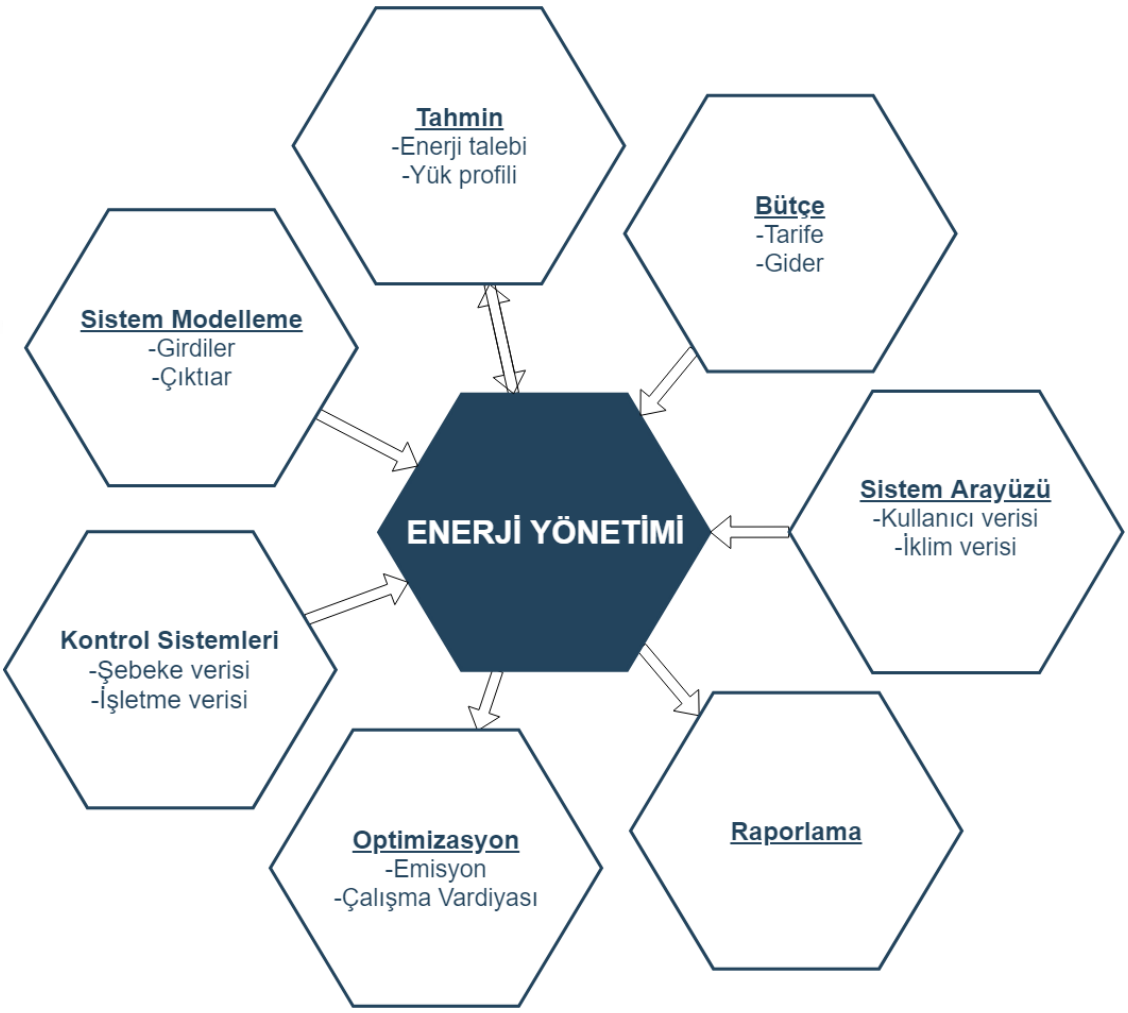
Tsanas ve Xifara, sekiz girdi değişkeninin (bağıl kompaktlık, yüzey alanı, duvar alanı, çatı alanı, toplam yükseklik, oryantasyon, cam alanı, cam alanı dağılımı) iki çıktı değişkenine etkisini incelemek için istatistiksel bir makine öğrenme çerçevesi geliştirmiştir. Konut binalarının ısıtma yükü (HL) ve soğutma yükü (CL) 768 farklı konutta yapılan kapsamlı benzetim ile HL ve CL'yi tahmin edebildiklerini göstermişlerdir (Tsanas & Xifara, 2012).

Castelli (2015), konutların enerji performansını (ısıtma yükü ve soğutma yükü) tahmin etmek için genetik programlama tabanlı bir yöntem önermiştir. Önerilen çerçeve yakın zamanda geliştirilen bir genetik programlama metodunu yerel bir arama metodu ve doğrusal ölçeklendirme ile harmanlamaktadır. Sonuçta ortaya çıkan sistem, her iki dikkate alınan parametrenin doğru bir tahminini yapan bir model oluşturmayı sağlamaktadır. 768 farklı konut binasında yapılan kapsamlı benzetim, önerilen yöntemin ısıtma yükünü ve soğutma yükünü tahmin etmedeki uygunluğunu doğrulamaktadır (Castelli, Trujillo, Vanneschi, & Popovic, 2015).

2.2 ENERJİ YÖNETİMİ VE ENERJİ TALEBİNİ ETKİLEYEN FAKTÖRLER

Matematiksel analiz ve optimizasyon yöntemleri, enerji veri tabanları ve enerji üretim sürecinin veri yönetimi ile birleştirilebilmelidir. Bir enerji sisteminin ana girdi ve çıktı verilerinin ayrıntılı analizi, verimliliğini artırmak için gereklidir. Enerji sistemlerinin verimliliğini arttırmak veya daha temiz ve verimli enerji sistemleri geliştirmek, enerji talebindeki büyümeyi yavaşlatır, fosil yakıt kullanımında derin azalmayı sağlar ve kirletici emisyonları azaltır. Bu nedenle doğru talep analizlerinin yapılması, yapılacak gereksiz yatırımların önüne geçilmesi ve doğru sistem kurulumlarının yapılmasına yön verir. Talebin en doğru bir şekilde tahmin ve analizini yapabilmek için enerji yönetimi ve buna bağlı olarak enerji veri tabanı oluşturulur. Şekil 2.2'deki diyagramda verilen metodoloji sayesinde sistem modellemeleri, tahminler, gider

yönetimi, üretim kontrol sistemleri, mevsim etkilerini, son kullanıcıların sisteme etkileri, sistem optimizasyonu incelenir.



Şekil 2.2 Enerji yönetim diyagramı

2.3 MAKİNE ÖĞRENMESİ

Günümüzde bilgisayarlar iş gücü bakımından insanların işlerini önemli oranda azaltsalar da istenilen seviyeye ulaşamamıştır. Makine öğrenmesi metodu ile mevcut verileri analiz ederek tecrübe kazandırılabilir ve bunların gelecekte oluşturabileceği durumlar hakkında tahminler yaptırabilir. Bir başka deyişle, makine öğrenmesi çeşitli algoritmalar ve yöntemlerle verilerde bazı kalıpları arar ve bunlara karşılık gelen etiketlere bakarak öğrenme gerçekleştirir. Öğrendiği

durumlardan yararlanarak yeni çıkarımlar yapabilme imkânı sağlar (Şeker, 2008). Başka bir tanımda makine öğrenmesini şu şekilde açıklayabiliriz; makine öğrenmesi, deneyimi buna bağlı T görev sınıfından, P performans ile öğrenmesi beklenen bir bilgisayar yazılımı olarak tanımlanabilir. Bu durumda T görevindeki performansı P ile ölçümleyebiliyorsak, E deneyimi ile gelişim sağlanabilir. Bu yapı aşağıda örnekle açıklanmıştır (Mitchell, 1997) .

Görev T'yi dama oynama olarak tanımlayabiliriz. Performans parametresi "P" rakiplerle oynanan oyunlarda başarılı olma yüzdesi ve antreman deneyimi ise "E" kendisi ile oyun oynama ve alıştırmanın yapılması olarak verilmiştir.

Makine öğrenmesi algoritmaları genellikle üç şekilde sınıflandırılır:

- Gözetimli Öğrenme (Supervised Learning)
- Gözetimsiz Öğrenme (Unsupervised Learning)
- Takviyeli Öğrenme (Reinforcement Learning)

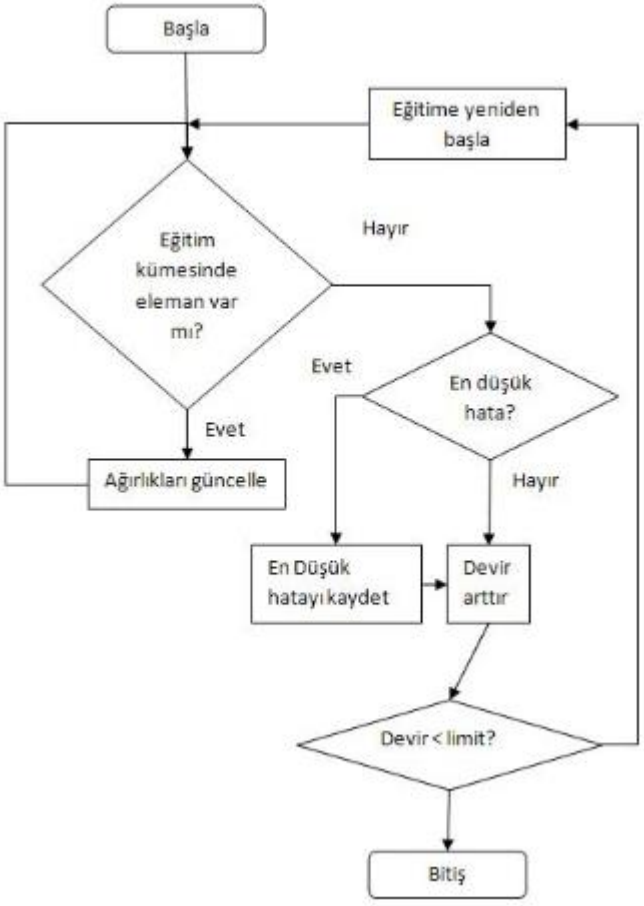


Şekil 2.3 Makine öğrenme şeması

Şekil 2.3'te görüldüğü gibi gözetimli öğrenme regresyon ve sınıflandırma olarak ikiye ayrılmıştır. Gözetimsiz öğrenme ise kümelenme ve boyut indirme olarak iki ayrı sınıfa ayrılmaktadır.

2.3.1 Gözetimli Öğrenme (Supervised Learning)

Eğitim verileri üzerinden bir fonksiyon üreterek makinenin kendi kendine öğrenmesini sağlayan tekniktir. Başka bir deyişle, bu öğrenme tekniğinde girdiler, işaretlenmiş veriler ile istenen çıktılar arasında eşleme yapan bir fonksiyon üretir. Eğitim verisi hem girdiler hem de çıktılardan oluşur. Fonksiyon ise genelde sınıflandırma veya eğri uydurma algoritmaları ile belirlenebilir. Gözetimli öğrenmenin en büyük avantajlarından birisi öğrenme sırasında bulduğu en düşük hata miktarını saklayıp bu durumu başarılı olarak kabul etmesidir. Bu hata miktarının hafızada saklanması ile sistemin daha önceki ve sonra meydana gelecek hataları atlamasını sağlayabilmektedir. Şekil 2.4'te gözetimli öğrenmenin akış şeması gösterilmiştir.



Şekil 2.4 Gözetimli öğrenme akış diyagramı (Şeker, 2008)

Bir farklı örnekle açıklayacak olursak; şekil verilen resimlerde kedi olduğunu sistemin tahmin etmesini istiyorsak sisteme öncesinde kedi resmi içeren veri setleri ekleyerek

öğretilmesi gerekmektedir. Buna eğitim verisi (train data) denilir. Şekil 2.5' de örnek bir veri seti verilmiştir. İlk örnek kedi resmi olarak tanımlanıp veri etiketlenmiş olarak sisteme verilir. Aynı işlem köpek resimleri için de yapılır. Böylece yeni bir resmin içindeki hayvanın kedi veya köpek olduğu tahmin edilebilir.

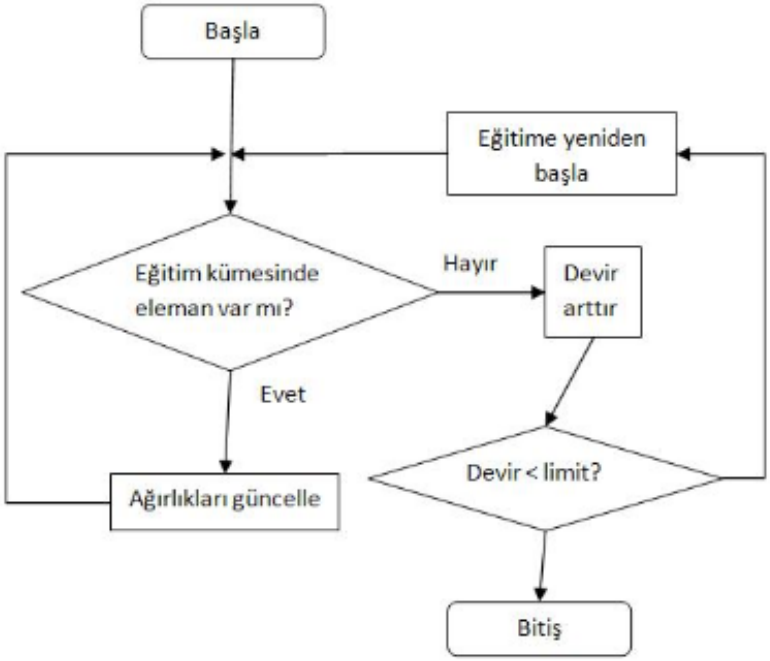


Şekil 2.5 Kedi ve köpek eğitim verisi (Kaggle web sitesi, 2019)

Gözetimli öğrenmede sınıflandırma yönetimine (classification method) göre verilerin belirli özelliklere göre sınıflandırma işlemi yapılmaktadır. Regresyon metodu ise regresyon problemlerinde, üretilen çıktının sürekli sayılardan oluştuğu durumlarda kullanılır.

2.3.2 Gözetimsiz Öğrenme (Unsupervised Learning)

Gözetimli öğrenmeden temel farkı işaretlenmemiş (unlabelled) veri üzerinden bilinmeyen bir yapıyı tahmin etmek için bir fonksiyon kullanan makine öğrenmesi metodu olmasıdır.



Şekil 2.6 Gözetimsiz öğrenme akış diyagramı (Şeker, 2008)

Gözetimsiz öğrenmede şekil 2.6'da gösterildiği gibi eğitim belirli bir limite kadar iterasyon sayısı artırılarak devam etmekte ve sonrasında limit değerine ulaşınca eğitimin tamamlandığı sonucuna varılmaktadır. Gözetimsiz öğrenme yöntemleri genelde üç başlık altında değerlendirilir. Bunlar kümeleme (clustering), birliktelik kuralı (association rule mining) ve boyut azaltma (dimensionality reduction) şeklinde sıralanabilir. Kümeleme yönteminde veri setindeki her verinin birbirine benzerlik durumlarına göre kendi içinde gruplara ayrılması sağlanır. Her bir grup küme anlamına gelir. Her kümede kendi içerisindekilere en benzer veriler olmalıdır. Birbirinden farklı özellikler bulunduran veriler farklı kümelerle ilişkilendirilir. Farklı kümelerdeki benzerliğin ise minimum olması gerekmektedir. Kısaca küme içinde değerlerin birbirine benzer, olması kümelerin ise olabildiğince birbirinden farklı verilere sahip olması gerekmektedir. Birliktelik kuralı veri setinde bulunan değişkenler arası ilişkileri belirtmek için kullanılır. Bulunan bağıntılarla da veri tahmini yapabilir. Boyut azaltma, istenen sonuç doğrultusunda en iyi neticeyi verecek olan öznitelikler (feature) ile çalışmak için kullanışsız, gereksiz olan öznitelikleri çıkartmak, veri boyutlarını azaltmak olarak nitelendirilebilir.

Gözetimli öğrenme ve gözetimsiz öğrenme arasında belirgin farklar bulunmaktadır. Gözetimli öğrenmenin dezavantajı eğitim verisini oluşturmasıdır. Eğitim verisi sayesinde

bir makine öğrenmesi metodu ile bir fonksiyon üretilir. Bu fonksiyon ile yeni gelen veriler tahmin edilmeye çalışılır. Gözetimli öğrenmede asıl zaman alan kısım eğitim verisinin hazırlanma aşamasıdır. Gözetimsiz öğrenmede ise herhangi bir eğitim verisine ihtiyaç bulunmamaktadır. Gruplar algoritma öğrenmeye çalışır. Algoritmalar verileri ayırarak yeni gelecek verileri en uygun gruba atamaya çalışır. Eğitim verisi olmadığından uygulaması kolaydır. Fakat karmaşık problemler için iyi sonuçlar elde edilmeyebilir.

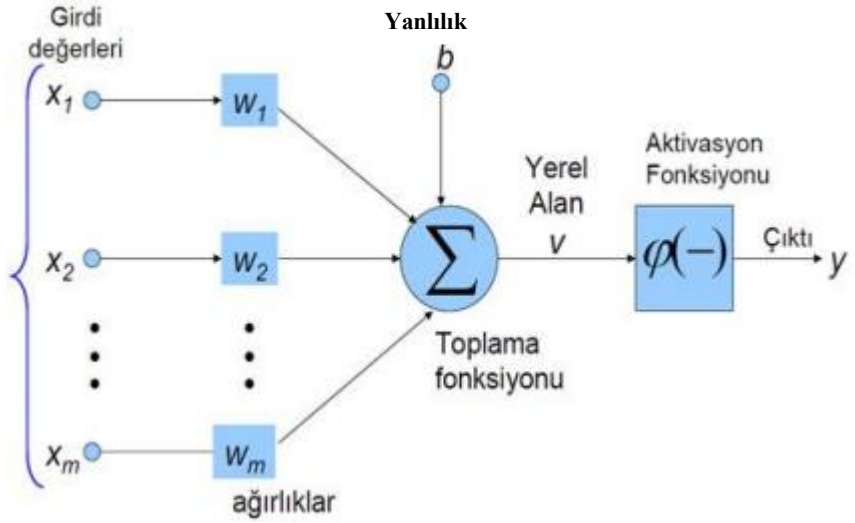
2.3.3 Takviyeli Öğrenme

Takviyeli öğrenme, amaca yönelik ne yapılması gerektiğini öğrenen bir makine öğrenmesi yaklaşımıdır. Takviyeli öğrenmede ajan (agent) adı verilen öğrenen makine karşılaştığı durumlara bir tepki verir ve bunun karşılığında da sayısal bir ödül sinyali alır. Ajan/öğrenen makine aldığı bu ödül puanını maksimuma çıkartmak için çalışır. Bu şekilde çalışan deneme yanılma yöntemi, takviyeli öğrenmenin en ayırt edici özelliğidir. Tüm takviyeli öğrenme ajanları açık hedeflere sahip olup çevrenin özelliklerini algılayabilir ve çevrelerini etkileyebilecek eylemleri seçebilir. Örnek olarak satranç oyuncusu bir hamle kararı aldığında muhtemel hamleleri ve karşıt cevaplarını planlar. Belirli konumları ve hareketleri sezgisel yargılarla belirler.

2.4 YAPAY SİNİR AĞLARI

İnsan beyni araştırmalarının artması ve paralelinde gelişen elektronik teknolojisi sayesinde yapay sinir modelleri tabanlı çalışmalar hız kazanmıştır. İlk YSA modelinin1943 yılında nöroloji uzmanı Warren MCCulloch ve matematik uzmanı Walter Pitts tarafından yapıldığı bilinmektedir. McCulloch ve Pitts yaptığı çalışmalar ile elektik devrelerini referans alarak insan beyninden esinlenerek yapay sinir ağı hücresini geliştirmişlerdir (Sack, 2019). Bu gelişme ile birlikte her türlü mantıksal kararların formülize edilmesinin mümkün olabildiğini göstermişlerdir (Keskenler & Keskenler, 2017). 1949 yılında Donald Hebb "Hebbian öğrenme" adlı öğrenme ile ilgili temel teoriyi ortaya koymuştur (Keskenler & Keskenler, 2017). 1957 yılında Perceptron, Frank Rosentblatt tarafından keşfedilmiştir. Buradaki perseptron hali hazırda kullandığımız eğitilebilen ve tek bir çıkış veren yapay sinir hücresidir. 1980'li yıllara gelindiğinde Kohonen "Kendi kendine öğrenme nitelik haritaları" çalışmasını yayınlamıştır (Kohohen,1982). 1986 yılında Rumelhart ve McClelland tarafından geriye yayılmalı öğrenme algoritması ile ilgili çalışmaları yayınlanmıştır

(Keskenler & Keskenler, 2017). Şu anda birçok alanda geriye yayılmalı öğrenme algoritması kullanılmaktadır. Teknik olarak YSA'nın asıl görevi, veri seti tanımlanan sistemde girdi setinin Şekil 2.7'de gösterildiği gibi belirli süzgeçlerden ve fonksiyonlardan geçerek bir çıktı üretmesinden ibarettir. Bu yeteneğe sahip olabilmesi için verilen örnek verilerle öğrenme işlemini yapar. Öğrenme belirli seviyeye ulaştığında genelleme yapabilecek ve kendi kendine karar verebilecek bir yapıya ulaşır. Kazanılan bu yetenekler girdilere karşılık çıktılar üretir. İnsan beyninde de bir nöron kendine gelen girişleri toplar.



Şekil 2.7 Yapay sinir ağı gösterimi (Keskenler & Keskenler, 2017)

İnsan beyninde de her bir nöron kendine gelen girişleri toplar. Eğer bu girişler iç eşik değerini aşarsa bir çıkış üretecek hale gelir. Yaygın olarak kullanılan beş tane iç eşik fonksiyonu vardır. Bunlar doğrusal, rampa, basamak, sigmoid ve tanx fonksiyonlarıdır.

Yapay sinir ağlarının gelişmesi ile birlikte her geçen gün kullanım alanı artmaktadır. Başlıca uygulama alanları; hastalıkların değerlendirilmesi, beynin modellenmesi, kan analizlerin yapılması, parmak izi tanıma, otonom araçlar, meteorolojik tahminlerin yapılması, ses tanıma, elektrik işareti tanımlaması, el yazısı tanımlama, radar ve sinyallerin sınıflandırılması, istenmeyen maillerin filtrelenmesi vb. olarak gösterilebilir.

2.4.1 Yapay Sinir Ağlarında Öğrenme

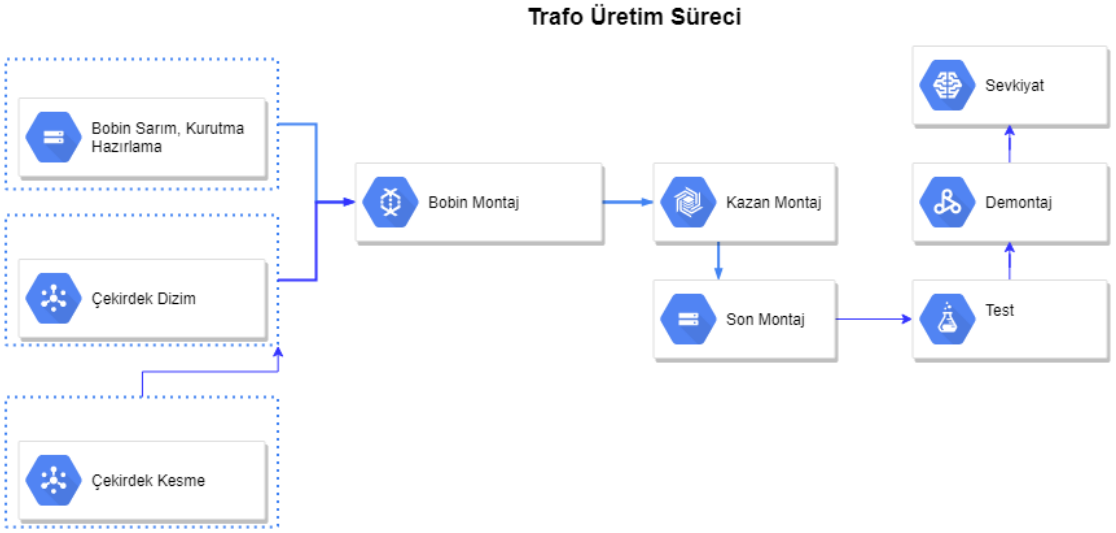
Yapay sinir ağlarında en önemli kısımlarından birisi de öğrenim algoritmalarıdır. Öğrenme algoritması problemin en uygun şekilde çözülmesini sağlamak için en uygun kuralı belirtir. Buna bağlı olarak iki farklı öğrenme türü vardır. Bunlar gözetimli öğrenme kuralı ve gözetimsiz öğrenme kuralıdır. Gözetimsiz öğrenme kısmında YSA sadece giriş verilerini kullanarak bunlar arasında bir ilişki oluşturmaya çalışır. Sistemin kendi kendine öğrenmesi beklenmektedir. Diğer gözetimli öğrenmede ise girdi ve çıktı verilerini kullanarak aralarındaki bağlantıya göre öğrenme gerçekleşir. YSA kullanılmadan önce verilerle eğitilir. YSA normalden fazla eğitme işlemine tabi tutularsa problemi öğrenmek yerine verileri ezberler. Bu da YSA'nın genelleme yapmamasına ve hatalı sonuçlar vermesine sebep olur.

3. MALZEME VE YÖNTEM

Bu bölümde enerji talep analizi yapılacak fabrika hakkında ve işletmesinin yapısı hakkında bilgiler verilmiştir. Ayrıca kullanılan yazılım programı ve buna bağlı kullanılan algoritmaların çalışma yapılarından bahsedilmiştir.

3.1 ENERJİ TALEP ANALİZİ YAPILAN FABRİKA

Bu tez kapsamında birçok farklı türde trafo üreten Alstom fabrikasının verileri analiz edilmiştir. Türkiye'de 1960'lı yıllarda faaliyet göstermeye başlayan Alstom, Türkiye'nin enerji ve demiryolu taşımacılık hizmetlerini sağlamaktadır. Bu fabrika Türkiye'de 90.000 m² kapalı alanda hizmet vermektedir. Firma, orta ve büyük güçte güç transformatörleri, şönt reaktörler gibi elektriksel ekipmanlar üretmektedir. Firmanın yaklaşık 1200 çalışanı vardır ve güç üretimi, güç iletimi alanında projeler üretmektedir. Fabrikanın kurulu gücü 6.5 MVA'dır. Şekil 3.1'de trafo üretim şeması gösterilmiştir.



Şekil 3.1 Trafo üretim şeması

Fabrikada üretim aşamasında 16 adet sarım makinesi, sarım esnasında bobin kurutma işleminde kullanılan 7 adet kurutma fırını bulunmaktadır. Trafo testleri 4 değişik test laboratuvarında yapılmaktadır. Şekil 3.2'de trafo fabrikasının dıştan görünüşü verilmiştir.



Şekil 3.2 Alstom fabrikası genel görünüş

3.2 KULLANILAN ALGORİTMALAR

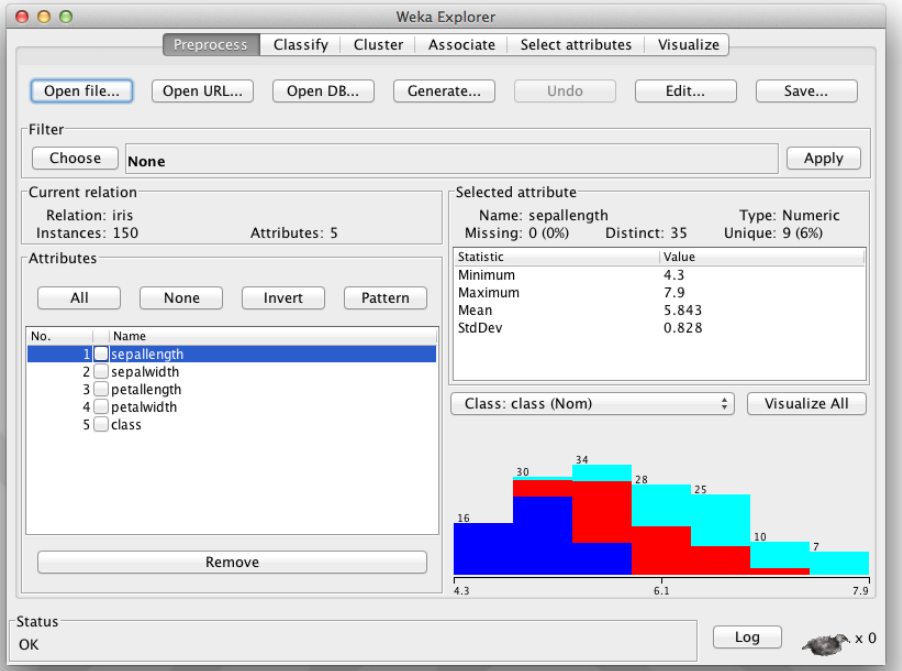
Çalışmanın bu bölümünde kullanılan yöntemden ve yapılma aşamalarından bahsedilecektir. Bu çalışmada WEKA yazılımı kullanılmıştır ve bulgular ise bu programdaki test ve analizlere göre yapılarak sonuçlar elde edilmiştir.

3.2.1 3.2.1. WEKA

WEKA veri madenciliğinde sıkça kullanılan bir programdır. Waikato Üniversitesi tarafından sunulmaktadır. Açık kaynak olarak dağıtılan ve Java ile geliştirilen bir programdır (Waikato, 2005). İstatistiki verilerin sonuçlarında tahmin yapmamızı sağlayarak seçilen herhangi bir veri kümesi için istediğimiz konu hakkında geleceğe yönelik tahminler ve yorumlar yapmamızı sağlar. Algoritmalar doğrudan bir veri kümesine uygulanabildiği gibi Java kodunda da çağrılabilir. WEKA, veri ön işleme, sınıflandırma, regresyon, kümeleme, birleştirme kuralları ve görselleştirme için araçlar içerir.

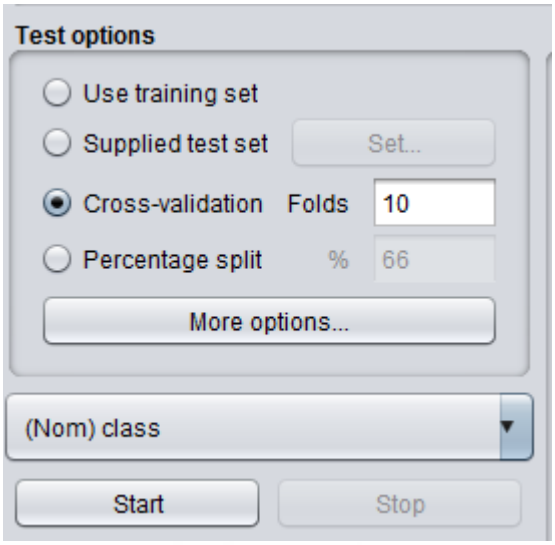
WEKA GUI (Graphical User Interface*)* Seçici, Explorer, Experimenter, KnowledgeExplorer ve Basic CLI (komut satırı arayüzü) ara yüzlerinden birini seçmenize izin verir.

WEKA yazılımı içerisinde deneme yapılabilecek birkaç makine öğrenme veri setini bünyesinde bulundurur. Şekil 3.3'de WEKA programının arayüz görüntüsü verilmiştir.



Şekil 3.3 WEKA yazılımı arayüzü

Herhangi bir veri kümesi yüklediğinizde, sorunu modellemek ve tahmin etmek için uygun olan algoritma seçilerek uygulamaya geçilir. Bu, Weka'da yüklü bir veri setine karşı algoritmaları çalıştırma alanıdır. Burada en önemli konu çalışmaya göre seçilen algoritma modelidir. Çünkü çıkan özet tablo bu seçilen algoritmaya göre olacaktır. Ayrıca bu ekranda test ve sağlama (validation) için ayrı kümeler kullanmak da mümkündür. Sınıflandırma hataları ayrı bir ekranda açılır ve şayet sınıflandırma algoritması bir karar ağacı (decision tree) oluşturursa bu da ayrıca bir ekranda görüntülenir. Bu kısımda test yöntemlerinden olan çapraz doğrulama, oranlı bölme ve eğitim bölümlerinden bahsedilmiştir. Şekil 3.4'te WEKA'da bulunan 4 farklı özellik görülmektedir.



Şekil 3.4 WEKA özellik arayüzü

3.2.2 Çapraz Doğrulama (Cross Validation)

Çapraz doğrulama, istatistiksel analiz sonuçlarının sınırlı sayıda ve bağımsız bir veri setine nasıl genelleştirildiğinin değerlendirilmesinde kullanılan bir tekniktir. Bu teknik 1930'lu yıllarda Larson tarafından bir algoritmayı eğitmek aynı zamanda verilere ilişkin istatiksel performansını değerlendirmek için kullanmıştır (Mostellller & Tukey, 1968). Çapraz doğrulama bazen rotasyon tahmini olarak da adlandırılır. Çapraz doğrulama, büyük ölçüde hedefin öngörü olduğu ortamlarda kullanılır ve bir tahmin edici modelin performansının doğruluğunu ölçer. Pratik bir kural olarak tercih edilir ve çok fazla veri seti bulunuyorsa, herhangi bir yüzdesel oran ile kullanabilir. Kullanılan yüzdelik değer eğitimde sadece bir kez değerlendirir.

Çapraz doğrulama modele çok sayıda eğitim yapma fırsatı verir. Bu, modelin görünmeyen veriler üzerinde ne kadar iyi performans göstereceğine dair daha iyi bir göstergedir. Veri seti, eğitim seti ve test seti olarak adlandırılan iki gruba ayrılmıştır.

K-katlama çapraz doğrulama; Veri setinde başarının denenmesi için veriler ikiye ayrılır. Birinci eğitim seti, ikincisi test setidir. Bu bölünme şekli değişik oranlarda yapılır. Örneğin bulgular kısmında alınan değerler ve analizler verinin %70'ini eğitirken %30'unu test için kullanır. Eğitilen veriler diğer bir kısım ile sınanarak başarı oranları test edilir. Bu yöntemde öncellikle bir k değeri seçilir. K adet alt gruba ayrılır ve bekleme yöntemi k kez tekrarlanır. Her seferinde, k alt kümelerinden biri test seti olarak kullanılır ve diğer k-1 altkümeleri bir eğitim seti oluşturmak için bir araya getirilir. Tüm k denemelerinde ortalama hata hesaplanır. Bu

yöntemin avantajı, verinin nasıl bölündüğünün daha az önemli olmasıdır. Her veri noktası tam olarak bir kez bir test setine girer ve k-1 kez bir eğitim setine girer. Elde edilen tahminin varyansı, k arttıkça azalır. Bu yöntemin dezavantajı ise, eğitim algoritmasının en baştan k zaman tekrarlanması gerektiğidir, yani değerlendirme yapmak için k kat daha fazla hesaplama gerekir. Bu yöntemin bir çeşidi, verileri rastgele bir test ve eğitim setine farklı zamanlarda bölmektir. Bunu yapmanın avantajı, bağımsız olarak her test setinin ne kadar büyük olduğunu ve ortalama kaç deneme yapacağınızı seçebilmektir. Bir nevi verileri parçalayarak test ve eğitimini yapar.

Hold out yöntemi; Bu yöntem çapraz doğrulamanın en basit yöntemidir. Veriler iki gruba ayrılır. Yöntemde eğitim kısmı modelin eğitilmiş verisi iken test seti modelin eğitilmemiş veriler üzerinde ne kadar başarılı olduğunu gösteren verilerini belirtir. Bunu yaparken eğitim seti bir fonksiyona uyum sağlar. Sonraki adımda fonksiyonun yaklaşımından test setindeki verilerin çıkış değerlerinin tahmin edilmesi istenir. Bu işlemi gerçekleştirirken sistemin tahmin işlemini daha önce çıkış verileri öğretilmemiş olan verileri tahmin etmesi beklenir. Bulduğu hataları modeli değerlendirmek için kullanır. Böylelikle hata hesaplamasına gerek duyulmaz.

3.2.3 Oranlı Bölme (Percantage Splıt)

WEKA programında yüzde payda kavramı olarak kullanılmaktadır. Verilen yüzdeye göre hata payları hesaplanmaktadır. Bu durum çıkan sonucu birebir etkilemektedir. Örneğin herhangi bir konuda araştırma yapan biri hata payını geniş tutarak sonuçlarda sapmaya neden olabilir ya da dar tutarak iyi olan bir çalışmaya ters sonuç verebilir. Oranlı bölme testi ile seçilen yüzdenin doğru ya da yanlış olma durumu test edilebilir. Bundan dolayı herhangi bir çalışma yapılmadan önce mutlaka bu yönteme başvurulmalıdır.

3.2.4 Eğitim Bölümü (Use Tranınıng Set)

Sisteme girilen veri setinin tamamı analize dâhil edilmek isteniyorsa bu testten yararlanılması doğru olacaktır. Burada konuya göre ilerlenmesi doğru olacaktır. Çünkü veriler değersiz hale gelebilir ve standart sapma oranını tüm veriye işlemek veri artışına sebep olacaktır. Tüm bu test yöntemleri verinin uygunluğu ve amaca yönelik seçilip işlem uygulanır.

3.2.5 Test Sonuçlarının Yorumlanması

Öncelikle kurulan modelin başarılı olup olmadığının test edilmesi gerekmektedir. Burada kullanılan kavramlar hata oranı, kesinlik, duyarlılık testidir. Buradaki başarı kavramını etkileyen faktör ise doğru sınıfa atanan ve yanlış sınıfa atılan veri sınıfıyla alakalıdır. Başarılı olup olmadığı ise karışıklık matrisi ile çözülür. Bu matriste satırlar gerçek veri olmakla beraber sütun ise modelin tahminidir. Gerçek pozitif gerçek değerleri 1 ve tahmin edilen değerlerinde 1 olduğunu gösteren örneklerdir. Gerçek veya doğru negatifler gerçek değerinin ve tahmin edilen değerlerin 0 olduğu örneklerdir. Yanlış pozitif olan örnekler gerçek değeri 0'ı tahmin ettiği değer ise 1 olan örneklerdir. Yanlış negatifler ise gerçek değeri 1 olurken tahmin edilen değeri 0 gösteren örneklerdir.

Tablo 3.1 Matris verilerinin açılımı

A(GP)	GERÇEK POZİTİF
B(YN)	YANLIŞ NEGATİF
C(YP)	YANLIŞ POZİTİF
D(DN)	DOĞRU NEGATİF
Doğruluk Oranı	(A+D)/(A+B+C+D)
Hata Oranı	(C+B)/(A+B+C+D)
Kesinlik	A/ (A+C)
Duyarlılık	A/ (A+B)

Korelasyon Katsayısı; Rastgele iki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ifade eder (Orhan & Kaşıkçı, 2002) . Yapılan hipotezlerde değişkenler arasında güçlü bir etki ve ilişki olup olmadığı bu testler ile ifade edilir. Değişkenler arasındaki ilişkiden söz edilirken negatif yönde mi yoksa pozitif yönde mi etki olduğu da yine bu testle doğrulanır.

Korelasyon katsayısı ise açıklanabilen bir varyasyonun açıklanamayan diğer bir varyasyona oranı olarak da ifade edilebilir. Eğer doğrusal eğri, grafik üzerindeki tüm noktalardan geçiyorsa, r=1 olur. Bu durumda, açıklanabilen varyasyonun, açıklanamayan varyasyona eşit olduğu gözlemlenmektedir.

$$D1 = AJ - PJ = e_j \tag{3.1}$$

$$D2 = \left|A_j - P_j\right| = e_j \tag{3.2}$$

$$D3 = \left|A_j - P_j\right|2 = e_{j2} \tag{3.3}$$

Tablo 3.2 Hata parametrelerin açılımı

AJ: gerçek değer
PJ: ön görülen değer
D1:hatanın büyüklüğü
D2:kesin hata
D3:hata kare
e_j: hata gösterimi

Ortalama yüzde hata (MSE), yönlerini temel almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçebilen, tüm tekil hataların ortalamada eşit ağırlıkla verildiği doğrusal bir değerdir. Başka bir deyişle, ortalama kare hata bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu göstermektedir. MSE, bir makine öğrenmesi modelinin, tahmin edici performansını ölçer, her zaman pozitif değerlidir ve MSE değeri sıfıra yakın olan tahmin edicilerin daha iyi bir performans gösterdiği söylenebilir. Tablo 3.2'de hata parametrelerin açılımı verilmiştir.

$$MSE = \frac{1}{n} \quad \sum_{j=1}^{n} e^{j2} \tag{3.4}$$

RMSE bir makine öğrenmesi modelinin, tahmin edicilerin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan bir ölçüttür. Ayrıca hatanın

büyüğünü ölçen kuadratik bir metriktir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır. Yani, kalıntılar, regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir göstergesidir; RMSE ise bu kalıntıların ne kadar geniş bir alana yayıldığının bir ölçüsüdür. Başka bir deyişle, verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE değeri 0'dan ∞'a kadar farklı bir değerler alabilir. Negatif yönelimli puanlar yani daha düşük değerlere sahip tahmin edicilerin daha iyi performans göstermesini sağlar. RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. Fakat birçok uygulamada hata değerinin sıfır değerini alması zordur. RMSE, büyük hataları daha fazla cezalandırmanın avantajına sahiptir, bu yüzden bazı durumlara daha uygun olabilir. RMSE, birçok matematiksel hesaplamada istenmeyen mutlak değerin kullanılmasını engellemektedir.

$$RMSE = \sqrt{\sum_{j=1}^{n} eje^{2/n}} \qquad RMSE = \sqrt{MSE} \tag{3.5}$$

Göreli mutlak hata (RAE), gerçek değerlerin yalnızca ortalaması olan basit bir öngörücüye bağlı olması nedeniyle göreceli kare hataya çok benzer. Bu durumda, hata, toplam kare hatası yerine sadece toplam mutlak hatadır. Bu nedenle, göreli mutlak hata toplam mutlak hatayı alır ve basit kestiricinin toplam mutlak hatasını bölerek normalize eder.

$$RAE = \sum_{j=1}^{n} |ej| \ / |AJ - \bar{A}| \tag{3.6}$$

Kök bağıl kare hatası basit bir verinin kullanılması durumunda ne olacağına bağlıdır. Daha spesifik olarak, bu basit öngörücü gerçek değerlerin yalnızca ortalamasıdır. Böylece, göreli kare hatası toplam kare hatasını alır ve basit kestiricinin toplam kare hatasını bölerek normalize eder. Göreceli kare hatanın karekökü alınarak, hata tahmin edilen miktar ile aynı boyutlara indirgenir.

$$RRSE = \sqrt{\sum_{j=1}^{n} ej^2 / \overline{(AJ - A)^2}} \tag{3.7}$$

3.3 KULLANILAN ALGORİTMALAR

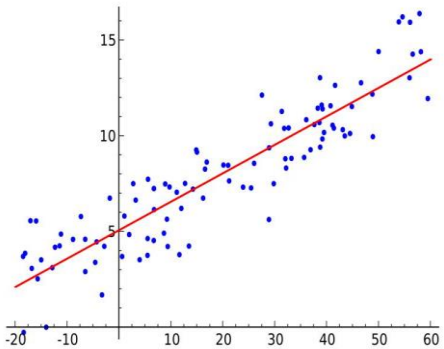
Bu kısımda uygulaması yapılan çalışmada kullanılan algoritmalar hakkında bilgi verilecektir. Bu algoritmalar doğrusal regresyon, çok katmanlı algılayıcılar, rassal orman, MP5 ve K-NN algoritmalarıdır.

3.3.1 Doğrusal Regresyon

Regresyon, iki ya da daha fazla değişken bulunan durumlarda değişkenler arasındaki doğrusal ilişkinin fonksiyonel şeklini göstermektedir. Bu değişkenlerden biri bağımlı diğeri bağımsız değişken olmak suretiyle bir doğru denklemi olarak göstermekle kalmaz, aynı şekilde değişkenlerden birinin değeri bilindiğinde diğeri hakkında tahmin yapılmasına olanak sağlar.

Doğrusal regresyon birçok problemde sayısal değerlerin tahmini için uygulanır. Nominal yani tamamıyla metin ya da karakter verilerin tahmini gibi bir yeteneğe sahip değildir. Tahmin yapılması için bu değerlerin sayısal değere dönüştürülmesinin akabinde formül üzerinde uygulanması gerekir. Parametreler arasındaki ilişkiyi fonksiyon olarak tanımlamaktadır. Parametreler birbirinden bağımlı veya bağımsız olabilir. Doğrusal regresyonun amacı parametreler arasındaki ilişki fonksiyonunu elde etmektir. Regresyon kavramı iki değişken için etkinin ölçüldüğü en önemli bulgudur.

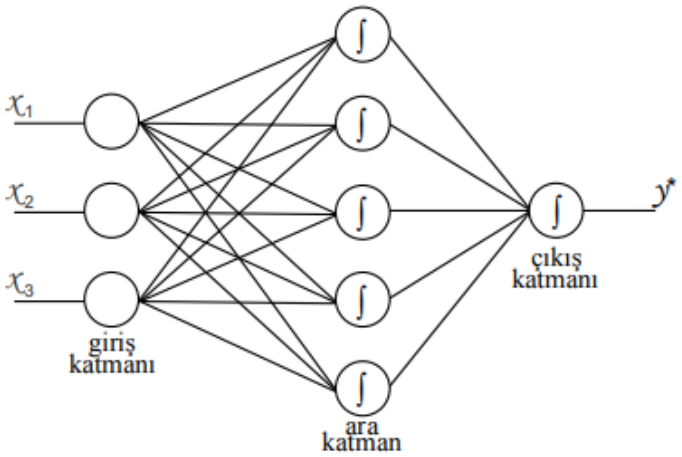
Doğrusal regresyon modelinde parametrelerin tahmini ve problemlere göre gelişmesi, uyum sağlaması kolaydır. Veriler kendi içerisinde çok geniş ve çeşitli ilişkiler ile ifade edilebilir. Yüz binlerce parametre ve faktör içeren doğrusal modelleri bilgisayar programları ile kurmak mümkündür. Doğrusal olmayan parametreler geçici değişkenler tanımlanarak standart bir şekle dönüştürülür. Genişletilmiş veri kümesinde ilişki tespiti için doğrusal model kullanılabilir. Modelde doğrusal olmayan parametreler varsa bu parametreler değişkenlerden hesaplanıp veri kümesine eklenmesi gerçekleştirilir. Doğrusal modelinde sınıflandırma probleminde olduğu gibi doğrusal bir sınıf sınırı oluşturur (Kabur, 2016). Şekil 3.5'te doğrusal regresyon fonksiyonun örnek gösterimi verilmiştir.



Şekil 3.5 Doğrusal regresyon

3.3.2 Çok Katmanlı Algılayıcılar

Çok Katmanlı Algılayıcılar (MLP) son yıllarda tıp ve mühendislik problemlerini çözmek için kullanılan bir metottur. Rumelhart ve arkadaşları tarafından geliştirilen bu model 'Back Propogation Model' ya da hatayı ağa yaydığı için 'Hata Yayma Modeli' olarak adlandırılmaktadır. Öğrenme metodu olarak Delta Öğrenme Kuralı denilen metot kullanılmaktadır. Bu algoritma özellikle sınıflandırma ve genelleme konusunda başarılı bir şekilde çalışır. Çok Katmanlı Ağ'ların yapısı Şekil 3.6'da gösterilmiştir (Arora & Suman, 2012).

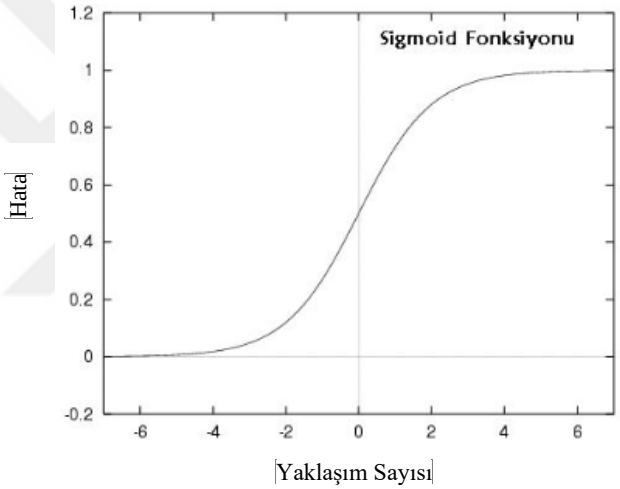


Şekil 3.6 MLP modeli

Tahmin sırasında birçok giriş için bir nöronun yeterli olmadığı durumlar meydana gelebilir. Paralel işlem yapıldığı durumlarda ve birden fazla nörona ihtiyaç duyulduğunda algoritma içerisinde ek katman kavramı devreye girer. Şekil 3.6'de görüldüğü gibi tek katmanlı YSA modelden farklı olarak arada gizli (hidden) katman bulunmaktadır. Giriş katmanı gelen verileri alarak ara katmana değerlendirmesi için gönderir. Gelen bilgiler içerisinde bulunan katmanlara sırasıyla iletilir. Ara katman sayısı problemin niteliğine ve durumuna göre değişmektedir. Her katmanın çıkışı bir sonraki katmanın girişi olacak şekilde modellenmektedir. Böylelikle girişten başlayan süreç adım adım çıkışa ulaşır. Her işlem elemanı yani nöron bir sonraki katmanda bulunan bütün nöronlara bağlıdır. Ayrıca katmandaki nöron sayıları da probleme göre belirlenir. Çıkış katmanı önceki katmanlardan gelen verileri işleyerek ağın çıkış modelinin nasıl şekilleneceğini belirler. Sistemin giriş sayısı girişteki katmana ve çıkış sayısı çıkış katmanında bulunan eleman sayısına eşittir.

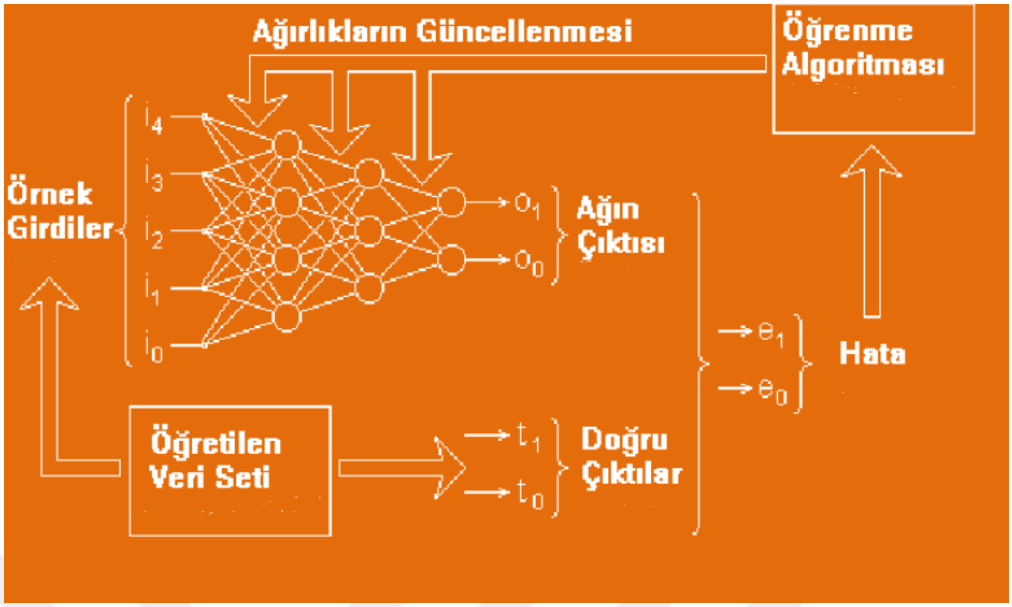
İleri ve geri beslemeli hesaplama modellerinde ileriye doğru hesaplama yaparken sisteme verilen girdiler ara katmanlardan geçerek çıkışa ulaşmaktadır. Her işlem elemanına gelen girdiler toplanılarak toplam net girdi hesaplanmaktadır. Bu net girdi aktivasyon fonksiyonundan geçirilerek mevcut işlem elemanının çıktısı bulunur. Bulunan ve bir öncekinin çıktı değeri olan veri bir sonraki katmanda bulunan işlem elemanlarına gönderilir. Bu işlemler tekrar edilerek aşama aşama en son katmandan çıktılar elde edilene kadar devam eder. En çok kullanılan aktivasyon fonksiyonu olan sigmoid fonksiyonu Şekil 3.7'de gösterilmiştir.

$$f^x = \frac{1}{1+e^x} \tag{3.8}$$



Şekil 3.7 Sigmoid aktivasyon fonksiyon gösterimi

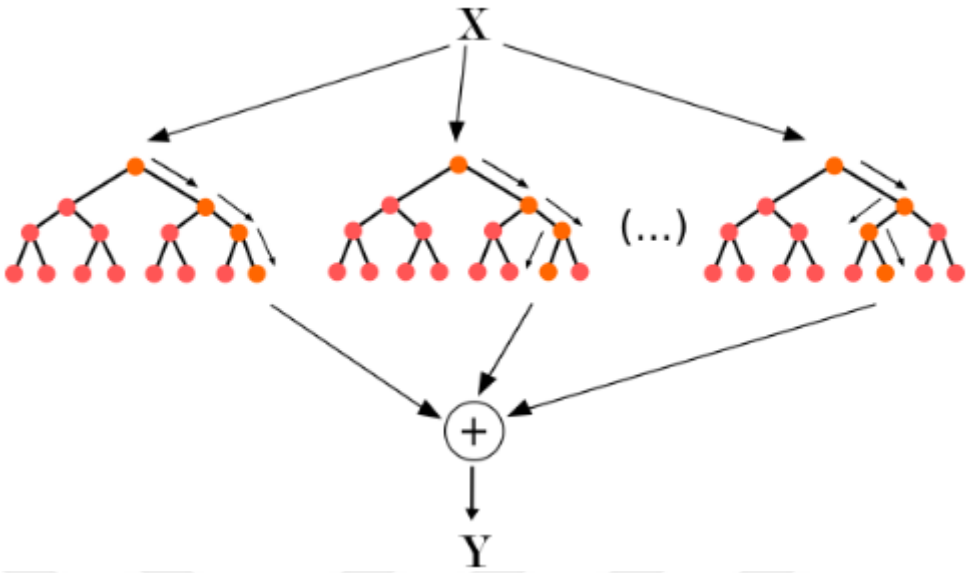
Model döngüsü iki aşamada tamamlanır. İlk aşamada ağ çıktı ürettiği anda öğrenmenin ilk aşaması bitmiş olur. İkinci aşamada ise hata dağıtma işlemi başlar. Öngörülen çıktı değeri ile elde ettiğimiz değer arasında bir fark bulunuyorsa bir hata bulunmaktadır. Geriye doğru hesaplama adımında yapılan her iterasyonda var olan hata ağırlık değerlerinin azaltılması sağlanır. Sisteme başlangıçta rastgele olarak dağıtılan ağırlık değerleri, hataların ağırlıklara dağıtılmasıyla ve tekrarlanan iterasyonlar ile ağırlık değerleri güncellenmiş olur. Genelleştirilmiş hata yayma modelinin gösterimi Şekil 3.8'deki gibidir.



Şekil 3.8 MLP genel yapısı

3.3.3 Rassal Orman

Rassal Orman, veri setine göre değişiklik gösteren parametre olmadan bile, çoğu zaman etkili bir sonuç veren esnek, kullanımı kolay bir makine öğrenme algoritmasıdır. Aynı zamanda en çok kullanılan algoritmalardan biridir. Basitliği ve hem sınıflandırma hem de regresyon görevleri için kullanılabilmesi avantajlarındandır. Birçok alanda başvurulan yöntemlerden olan karar ağaçlarının en büyük problemlerinden biri aşırı öğrenme ve aşırı öğrenme ile oluşan ezberlenme sürecidir (overfitting). Rassal orman modeli problemi çözmek için hem veri setinden hem de öznitelik setinden rastgele olarak onlarca, yüzlerce farklı alt kümeler seçer ve bunları eğitir. Bu yöntemle yüzlerce karar ağacı oluşturulur ve her bir karar ağacı kendi içerisinde tahminlerde bulunur. Uygulamada regresyon modeli kullanılıyor ise karar ağaçlarının tahminlerinin ortalaması alınarak devam edilirken regresyon modeli kullanılmıyor ise tahminler arasında en çok ağırlığa sahip olan seçilerek devam edilir. Rassal orman ağaç yapısı Şekil 3.9'da verilmiştir.



Şekil 3.9 Rassal orman ağaç yapısı

Rassal orman algoritması büyük veri tabanlarında verimli çalışır. Değişken silmeden binlerce giriş değişkenini işleyebilir. Sınıflandırmada hangi değişkenlerin önemli olduğu konusunda tahminler verir. Değişkenler ve sınıflandırma arasındaki ilişki hakkında bilgiler hesaplanır. Kümelemede, aykırı değerlerin konumlandırılmasında verilerin görünümlerini bulabilmek için kullanılabilecek vaka çiftleri arasındaki yakınlıkları hesaplar. Değişken etkileşimlerini tespit etmek için deneysel bir yöntem sunar.

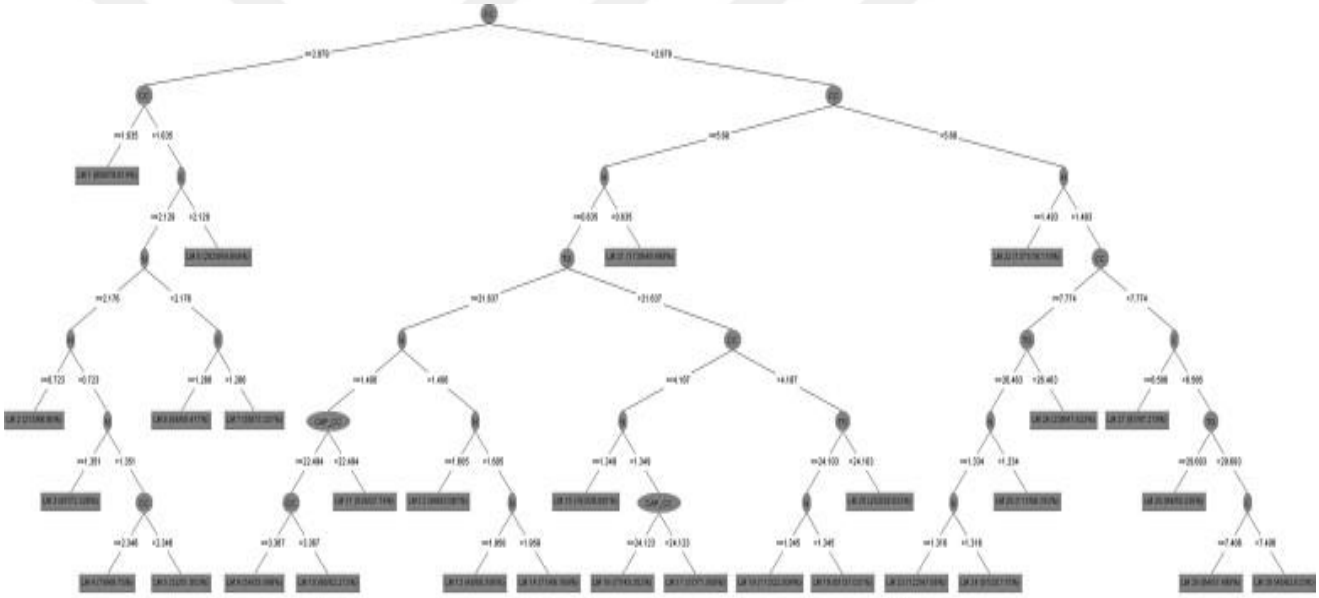
Rassal Orman ağacının diğer bir özelliği ise bize özniteliklerin ne kadar önemli olduğunu bildirmesidir. Bir özniteliğin önemli olması demek o özniteliğin bağımlı değişkendeki varyansının açıklanmasına ne kadar katkı yaptığıyla alakalıdır. Rassal orman algoritmasına istenilen sayıda öznitelik verip en yararlı x tanesini seçmesi istenebilir ve bu bilgi istenen başka bir modelde kullanılabilir.

Rassal Orman algoritması kullanıcı tarafından iki parametreye ihtiyaç duyar. En doğru bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı m ve geliştirilecek ağaç sayısı n olarak verilir. OOB (Out of bag) verisi olarak da adlandırılan, eğitim veri setinin genellikle 1/3'lük geri kalan kısmı hataları test etmek için kullanılır. Her bir düğümde m değişkenleri tüm değişkenler arasından rastgele olarak seçilir ve bu değişkenler arasından en

iyi dal belirlenir. M adet değişken sayısının karekköküne eşit alınan m değişken sayısı genel olarak en iyi sonucu verir.

3.3.4 M5P Algoritması

M5P, geleneksel bir karar ağacını, düğümlerinde doğrusal regresyon fonksiyonlarının olasılığı ile birleştirir. M5P model ağacı verimli bir şekilde öğrenerek ve çok yüksek boyutlar için en doğru sonuçları veren bir yapıdadır. Ayrıca, M5P'in CART'a göre avantajlı olduğu durumlar vardır. Buna göre, model ağaçlar genellikle regresyon ağaçlarından çok daha küçüktür ve incelenen görevlerde daha doğru sonuçlar verdiği görülmüştür. M5P model ağacı, regresyon görevi için kullanılan bir karar ağacıdır. Şekil 3.10'da M5P ağaç yapısı görülmektedir.



Şekil 3.10 Ağaç yapısı

M5P ağacı verileri bir T kümesi parçasına böler. Böylelikle doğrudan T kümesi ile oluşturulan dallar ile ilişkisini belirler. T'yi teste karşılık gelen alt gruplara bölen bir test seçilerek uygulamaya devam edilir. Bu işlem sık sık budanması gereken aşırı karmaşık yapılar üretir. M5P ağacındaki bilgi kazancı, standart sapmadaki azalma ile ölçülür. Testten sonra ilk adım, cevap değerlerinin standart sapmasını hesaplamaktır. Daha sonra M5P ağacı bu beklenen hata minimize eden bir değeri seçecektir.

3.3.5 K-NN Algoritması

K-NN (K-Nearest Neighborhood - En Yakın K Komşu) algoritması gözetimli öğrenme metotlarından sınıflandırma işleminde kullanılan bir metottur. Sınıflandırma işleminde K değeri gözeterek eleman sayısını belirler. Her ne kadar K-NN algoritması k-değer algoritmasına benzer özelliklerini bünyesinde barındırsa da bazı farklılıklar içermektedir. K-NN algoritmasına bir eğitim verisi içerirken k-değer algoritması bir eğitim verisi içermez. Yeni bir değer işlendiğinde K değerine olan mesafeler hesaplanır ve yeni değer bir kümeye dâhil edilir. Eğitim kümesinin büyük olması ve k değerini uygun seçilmesi K-NN algoritmasının başarı oranı açısından çok önemlidir. K-NN algoritmasına karar verdiğinizde eğitim verinizi ve k değerini arttırarak etkili bir K-NN tahmin sistemi oluşturulur. K-NN algoritmasının çalışma prensibi, nesnelerin birbirleri arasında yakınlık ilişkilerine göre kümeleme işlemi yapısına dayanmaktadır. Doğrusal ayrıştırma yöntemi ile koordinat düzleminde çalışırlar. Aşağıda gösterilen eşitsizliklerin birincisinde q değerinin 2 alınması ile oklid uzaklık bağıntısı, q değerinin 1 alınması ile Manhattan uzaklık bağıntısı elde edilir. Q değişken sayısı ise değişken sayısı göz önüne alınarak gözlem değerler arasındaki uzaklığın hesaplanması söz konusu ise Minkowski uzaklık bağıntısına başvurulur. Manhattan uzaklığı yani Denklem (3.10)'daki eşitlik iki nokta arasındaki uzaklığın, bu noktalardan geçen ve dik kesişen doğru parçalarının uzaklığı kadar olduğunu göstermektedir. Oklid uzaklığı yani Denklem (3.9)'daki eşitlik iki nokta arasındaki uzaklığın, bu iki noktayı birleştiren doğrunun uzaklığı olduğunu gösterir (Kabak, 2016).

$$1 = \sqrt{\sum_{i=1}^{k}(xi - yi)2} \tag{3.9}$$

$$2 = \sum_{i=1}^{k}|xi - yi| \tag{3.10}$$

$$3 = \left(\sum_{i=1}^{k}|xi - yi|^{q}\right)1/q \tag{3.11}$$

4. BULGULAR

Analiz edilen fabrikada KNN, rassal orman, doğrusal regresyon, çok katmanlı algılayıcı, M5P algoritmaları enerji talebi ve tahminin ve analizinin yapılması için WEKA kullanılarak sonuçlar elde edilmiştir. Bu analiz sırasında dokuz öznitelik belirlenmiştir. Sıcaklık, nem, çalışan sayısı, üretim miktarı, mevsim, çalışma gün durumu, kapasitif güç ve indüktif güç giriş parametresi olarak belirlenmiş ve aktif güç çıkış değeri olarak alınmıştır. Aktif güç tüketimi firmanın enerji verimliliği açısından ne durumda olduğu bilgisini barındırmaktadır. Her algoritma için 3 farklı adımda veri girişi sağlanıp çıkan doğruluk oranı ve sapma oranı ile karşılaştırılmıştır. Bu 3 farklı yaklaşım sırasıyla eğitim seti, çapraz doğrulama ve oranlı bölmedir.

4.1 VERİ SETİ

Çalışmada kullanılan verilerin bir kısmı Tablo 4.1'de gösterilmiştir. Gün bazında Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğünden ilgili yıllardaki günlük ortalama sıcaklık (°C) ve ilgili yıllardaki yüzde bağıl nem değerleri alınmıştır. Enerji tüketim verileri ve diğer tüm sayısal veriler tesisten temin edilmiştir. Toplamda işlem gören 362 satır yaklaşık bir senelik veri seti bulunmaktadır.

Tablo 4.1 Veri seti

Sıcaklık (°C)	Nem (%)	Mevsim	Çalışan Sayısı	Çalışma Günü	Üretim Âdeti	Kapasitif Güç	Aktif Güç	Endüktif Güç
6.7	86.1	1	24	0	0	44	650	13
8.5	71.7	1	286	1	14	174	1083	0
9.4	82.6	1	286	1	14	72	1843	61
…	…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…	…
5.3	81.7	1	286	1	14	23	2852	120

Tablo 4.2 Öznitelik tablosu

Giriş	**Sıcaklık**
Giriş	**Nem**
Giriş	**Mevsim**
Giriş	**Çalışan Sayısı**
Giriş	**Çalışma Günü**
Giriş	**Üretim Âdeti**
Giriş	**Kapasitif Güç**
Çıkış	**Aktif Güç**
Giriş	**Endüktif Güç**

Kullanılan öznitelikler Tablo 4.2'de verilmiştir. Birinci öznitelik sıcaklık değerini vermektedir. Ve birimi santigrat derecedir (°C). Veriler Meteoroloji Müdürlüğünden temin edilmiştir. İkinci öznitelik nem değerini gösterir ve birimi % RH 'tır. Nem verileri Meteoroloji Müdürlüğünden temin edilmiştir. 6. öznitelik günlük üretim kapasitesini göstermektedir. Üretim âdeti/gün olarak verilmiştir. 7. öznitelik bir günlük süreçte sayaçtan okunan kapasitif güç değerdir ve birimi kvar/gün' dür. 8. öznitelik bir günlük süreçte sayaçtan okunan aktif güç değerdir ve birimi kW/gün 'dür. 9. öznitelik ise bir günlük süreçte sayaçtan okunan endüktif gücü gösterir. Birimi kvar/gün 'dür.

4.2 DOĞRUSAL REGRESYON SONUÇLARI

Bu algoritma genel anlamda iki ya da daha fazla değişken arasından doğrusal bağıntının fonksiyonunun şeklini belirlemede kullanılmaktadır. Değişken değerleri biliniyorsa diğer bilinmeyenler hakkında tahmin yürütme kapasitesine sahiptir. Sürekli inişli ve çıkışlı bir veri seti var ise bu algoritmayı kullanmak çok doğru sonuçlar üretmeyecektir. Çünkü algoritma tüm verilerden geçecek ya da kapsayacak bir doğru çizmeyi hedeflemektedir. İnişli çıkışlı veriler genelde logaritmik dalga biçimine benzemeye çalıştırılır (Atmaca, 2017). Tablo 4.3'de doğrusal regresyon eğitim sonuçları verilmiştir. Eğitim sonucunda başarı oranı yaklaşık olarak % 83 olduğu görülmüştür. Kök ortalama kare hatası 333.969 olarak ölçülmüştür. Bu değer verilerin regresyon hattına ne kadar uzak olduğu veya o hat üzerinde o verilerin ne kadar yoğun olduğunu gösterir.

Tablo 4.3 Doğrusal regresyon eğitim sonuçları

Test modu	%100 eğitim
Korelasyon katsayısı(başarı)	%82.99
Ortalama mutlak hata(mae)	234.9348
Kök ortalama kare hata(rmse)	333.9669
Rölatif mutlak hata(rae)	%49.6938
Rölatif karesel hatanın karekökü(rrse)	%55.7866
Toplam veri sayısı	362

RMSE değeri 0'dan ∞'a kadar olabilir. (MAE) Ortalama mutlak hata ise yaklaşık 234'tür. MW değerinde güçler söz konusu olduğu için değerler büyük gözükmekle beraber aslında hata verilen değerin bindelik gösterimi oluşturur. Doğrusal regresyon çapraz doğrulama sonuçları Tablo 4.4'te görülmektedir.

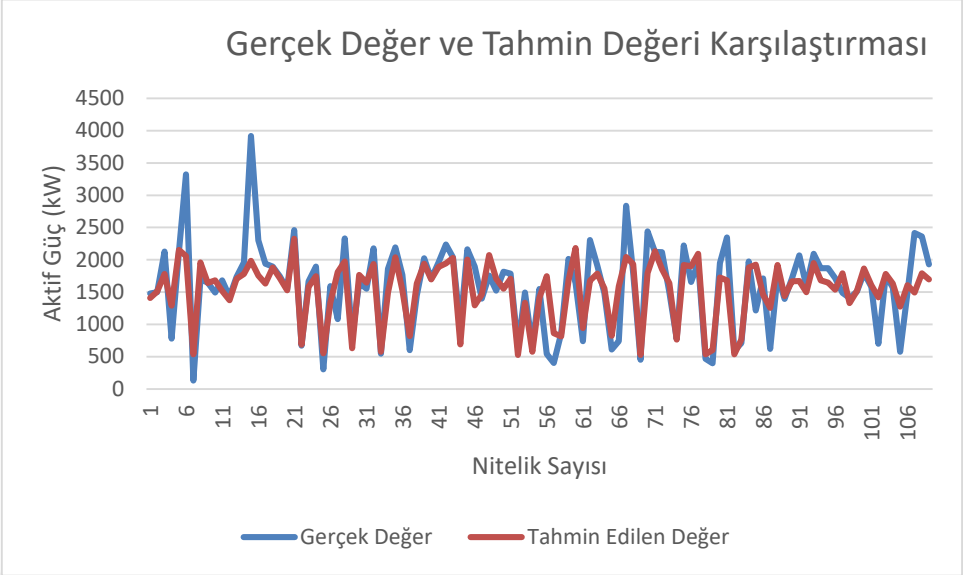
Tablo 4.4 Doğrusal regresyon çapraz doğrulama sonuçları

Test modu	10'lu kümeleme
Korelasyon katsayısı(başarı)	%81.13
Ortalama mutlak hata(mae)	244.8224
Kök ortalama kare hata(rmse)	350.1674
Rölatif mutlak hata(rae)	%51.7067
Rölatif karesel hatanın karekökü(rrse)	%58.4053
Toplam veri sayısı	362

Eğitim sonucunda başarı oranı yaklaşık olarak % 81 olduğu görülmüştür. Kök ortalama kare hatası eğitim analizine göre bir miktar artmıştır. Doğrusal regresyon oranlı bölme sonuçları Tablo 4.5'te verilmiştir. Eğitim ve çapraz doğrulama metoduna göre hata oranı artmış ve doğruluk oranında ise düşüş gözlenmiştir.

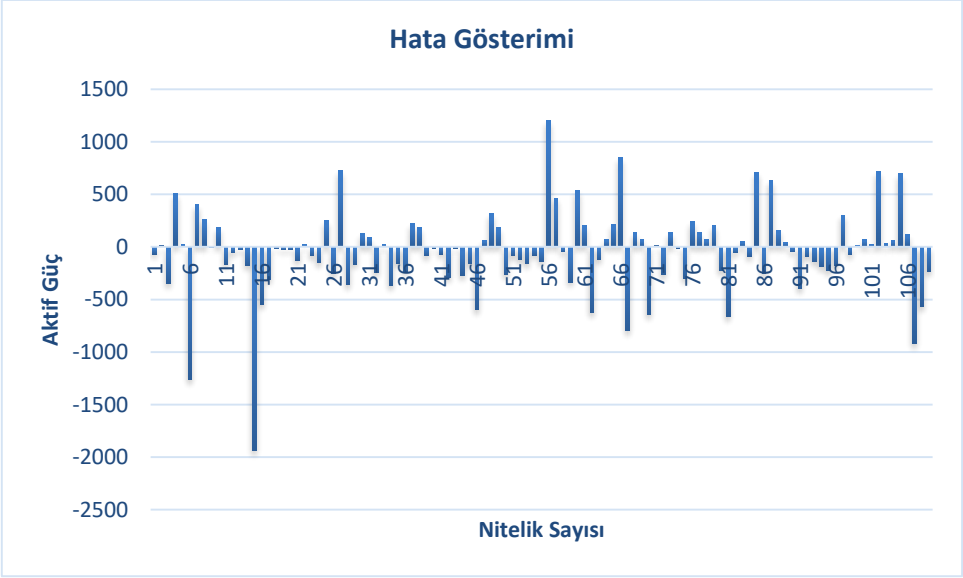
Tablo 4.5 Doğrusal regresyon oranlı bölme sonuçları

Test modu	%70 bölme
Korelasyon katsayısı(başarı)	%80.12
Ortalama mutlak hata(mae)	263.4156
Kök ortalama kare hata(rmse)	398.8826
Rölatif mutlak hata(rae)	%52.1355
Rölatif karesel hatanın karekökü(rrse)	%60.9848
Toplam veri sayısı	109



Şekil 4.1 Doğrusal regresyon gerçek değer ve tahmin edilen değer karşılaştırması

Şekil 4.1'de doğrusal regresyon karşılaştırma sonuçları verilmiştir. Yüksek tepe değerleri haricinde gerçek değerlere yakın bir grafik çizmiştir.



Şekil 4.2 Doğrusal regresyon hata gösterimi

Şekil 4.2'de gösterilen hata grafiğinde görüldüğü üzere 16. değerde yaklaşık 2000 birimlik bir hata gözlemlenmiştir. Yaklaşık olarak 10 kez gerçek değerden sapma meydana getirmiştir.

4.3 ÇOK KATMANLI ALGILAYICI ALGORİTMASI

Çok katmanlı algılayıcı öğrenme stratejisinde denetimli öğrenme yöntemini kullanır. Girdi olarak verilen her verinin karşılığında olması beklenen çıktı bilgileri de verilir. Öğrenme sürecinde bir genelleme yaparak problemin çözüm yolunu oluşturur (Demirhan, 2015). Analiz edilen veriler ile tahmin edilen verilerin karşılaştırılması yapılarak doğruluk oranı en yüksek algoritma seçilmiştir. Çok Katmanlı Algılayıcı eğitim sonuçları Tablo 4.6'da verilmiştir.

Tablo 4.6 Çok katmanlı algılayıcı eğitim sonuçları

Test modu	%100 eğitim
Korelasyon katsayısı(başarı)	%88.09
Ortalama mutlak hata(mae)	217.3811
Kök ortalama kare hata(rmse)	295.4634
Rölatif mutlak hata(rae)	%45.9809
Rölatif karesel hatanın karekökü(rrse)	%49.3549
Toplam veri sayısı	362

Çok katmanlı algılayıcı da eğitilirken modelin oluşturulması 0.31 saniye sistemin öğrenmesi 0.02 saniye sürmüştür. Doğruluk oranı %88 olup kök ortalama kare hatası 217 civarındadır. Çok Katmanlı Algılayıcı çapraz doğrulama sonuçları Tablo 4.7'de verilmiştir.

Tablo 4.7 Çok katmanlı algılayıcı çapraz doğrulama sonuçları

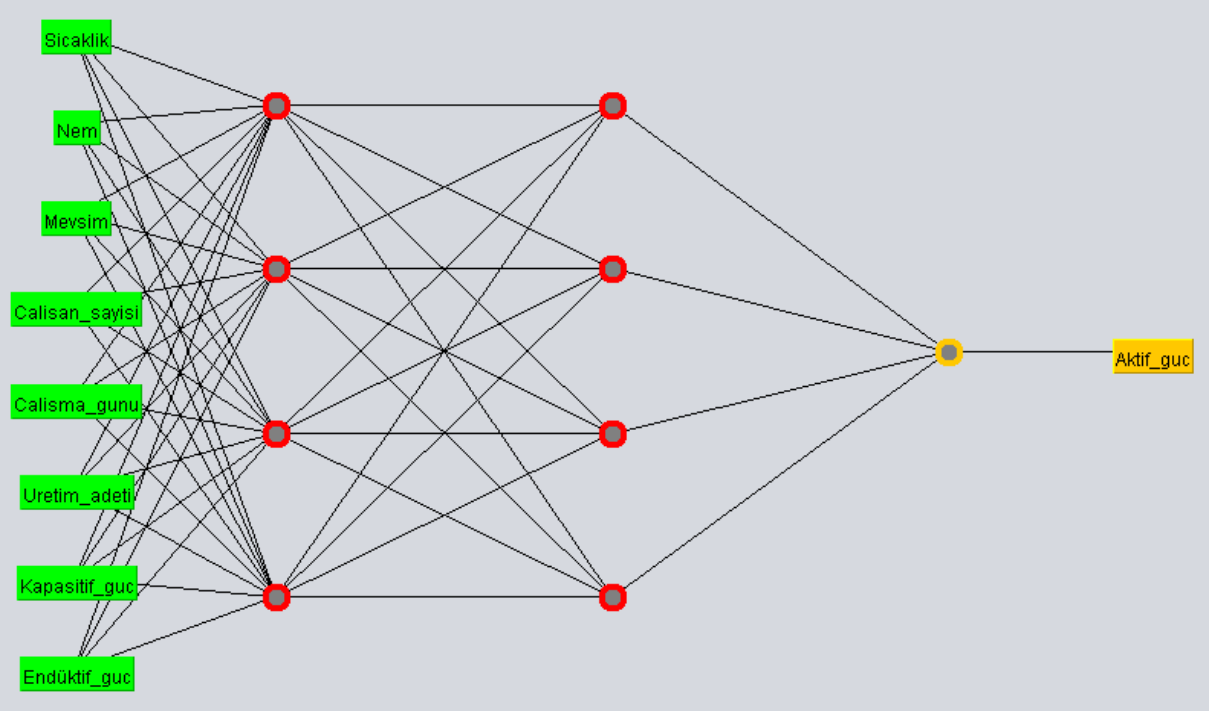
Test modu	10'lu kümeleme
Korelasyon katsayısı(başarı)	%78.68
Ortalama mutlak hata(mae)	270.3441
Kök ortalama kare hata(rmse)	375.3523
Rölatif mutlak hata(rae)	%57.0969
Rölatif karesel hatanın karekökü(rrse)	%62.6059
Toplam veri sayısı	362

Doğrulama kümesi 10 olarak alındığında modelin kurulması 0.23 saniye sürmüştür. Doğruluk oranı %78'de kök ortalama kare hatasının ise 270 olduğu görülmüştür. Çok Katmanlı Algılayıcı oranlı bölme sonuçları Tablo 4.8'de verilmiştir.

Tablo 4.8 Çok katmanlı algılayıcı oranlı bölme sonuçları

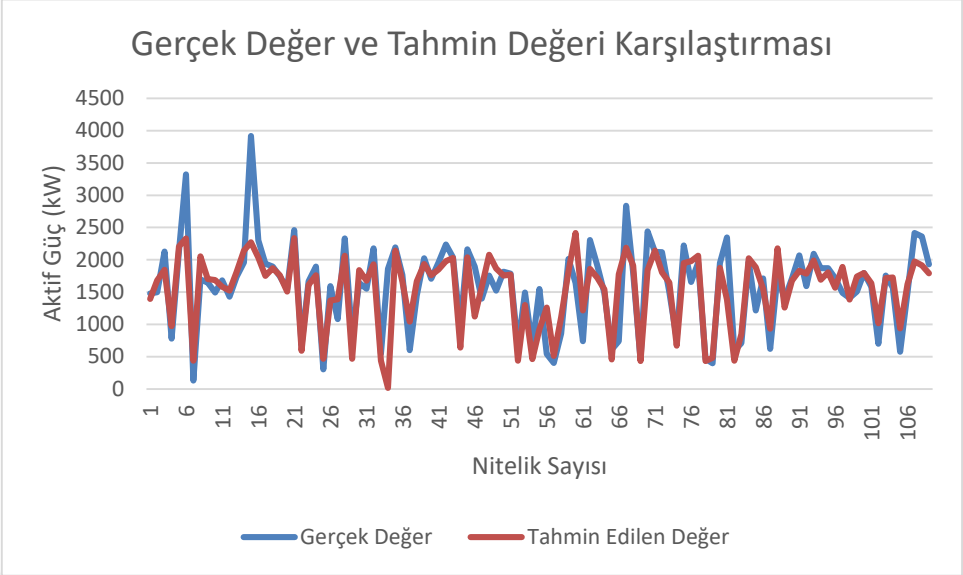
Test modu	%70 eğitim
Korelasyon katsayısı(başarı)	%80.3
Ortalama mutlak hata(mae)	258.7495
Kök ortalama kare hata(rmse)	391.6865
Rölatif mutlak hata(rae)	%51.212
Rölatif karesel hatanın karekökü(rrse)	%59.8846
Toplam veri sayısı	109

Verilen kümeyi diğer algoritmalarda olduğu gibi %70'i eğitim, geri kalan verileri test için kullandırılması sağlanmıştır. Burada doğruluk oranı %80, kök ortalama hata oranı ise 258 olmuştur. Çok Katmanlı Algılayıcı çift katman yapısı Şekil 4.3'te verilmiştir.



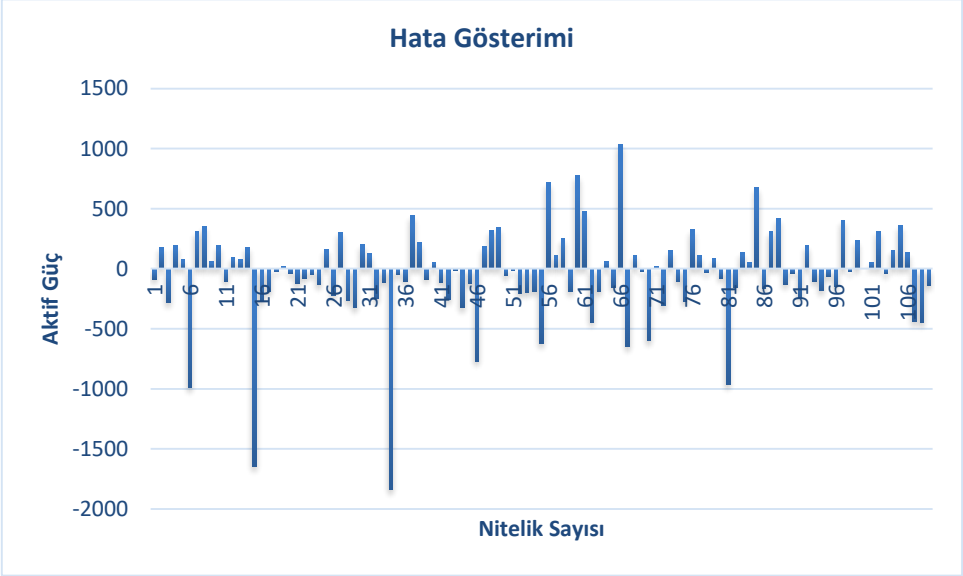
Şekil 4.3 Çok katmanlı algılayıcı çift katman gösterimi

Çok katmanlı algılayıcılarda gizli katmanı artırınca yaklaşım sayısının düştüğü gözlemlenmiştir. Normal veri setinde 5 katman var iken 0,033 değerinde katman sayısı 5,6 şeklinde model oluşturulduğunda yaklaşım sayısı 0,029'a düşmüştür. Yaklaşım sayısına göre eğitim esnasında yeniden belirlenen ağırlıklara göre veriler tekrar eğitilerek uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine yaklaşım (epoch) denilir. Yaklaşım sayısı ne kadar fazla ise başarı oranı o kadar artacaktır. Çok Katmanlı Algılayıcı karşılaştırma verisi Şekil 4.4'te verilmiştir.



Şekil 4.4 Çok katmanlı algılayıcı gerçek ve tahmin karşılaştırması

Bu algoritmada tahminlerde benzer grafik elde etmesine rağmen verinin tepe yaptığı noktalarda yetersiz kalmıştır. Çok Katmanlı Algılayıcı hata verisi Şekil 4.5'te verilmiştir. 34. veride yaklaşık 1800 kW'lık bir sapma görülmüştür.



Şekil 4.5 Çok katmanlı algılayıcı hata gösterimi

4.4 RASSAL ORMAN ALGORİTMASI

Rassal orman algoritması hem regresyon problemlerinde hem de sınıflandırma işlemlerinde kullanılır. Kendi içerisinde oluşturduğu rastgele ağaçları tahmin etme aşamasında birleştirir ve

en doğru oranı yakalamaya çalışır. Sistem 100 iterasyon kullanarak (bagging) sonuca ulaşmıştır. Rassal Orman eğitim sonuçları Tablo 4.9'da verilmiştir.

Tablo 4.9 Rassal orman eğitim sonuçları

Korelasyon katsayısı(başarı)	%98.58
Ortalama mutlak hata(mae)	75.90
Kök ortalama kare hata(rmse)	108.53
Rölatif mutlak hata(rae)	%16.05
Rölatif karesel hatanın karekökü(rrse)	%18.12
Toplam veri sayısı	362

Rassal orman algoritmasında eğitim başarısı ciddi oranda yüksek yani yaklaşık %99 başarı oranını yakalamıştır. Rassal Orman çapraz doğrulama sonuçları Tablo 4.10'da verilmiştir.

Tablo 4.10 Rassal orman çapraz doğrulama sonuçları

Model tipi	Bagging yöntemi ile 100 iterasyon
Korelasyon katsayısı(başarı)	%87,87
Ortalama mutlak hata(mae)	203.205
Kök ortalama kare hata(rmse)	289.07
Rölatif mutlak hata(rae)	%42.9267
Rölatif karesel hatanın karekökü(rrse)	%47.715
Toplam veri sayısı	362

Rassal orman metodunda çapraz doğrulama özelliği kısmında 100 iterasyon sonucu başarı oranı %87,87 olarak gözlemlenmiştir. Rassal Orman oranlı bölme sonuçları Tablo 4.11'de verilmiştir.

Tablo 4.11 Rasal orman oranlı bölme sonuçları

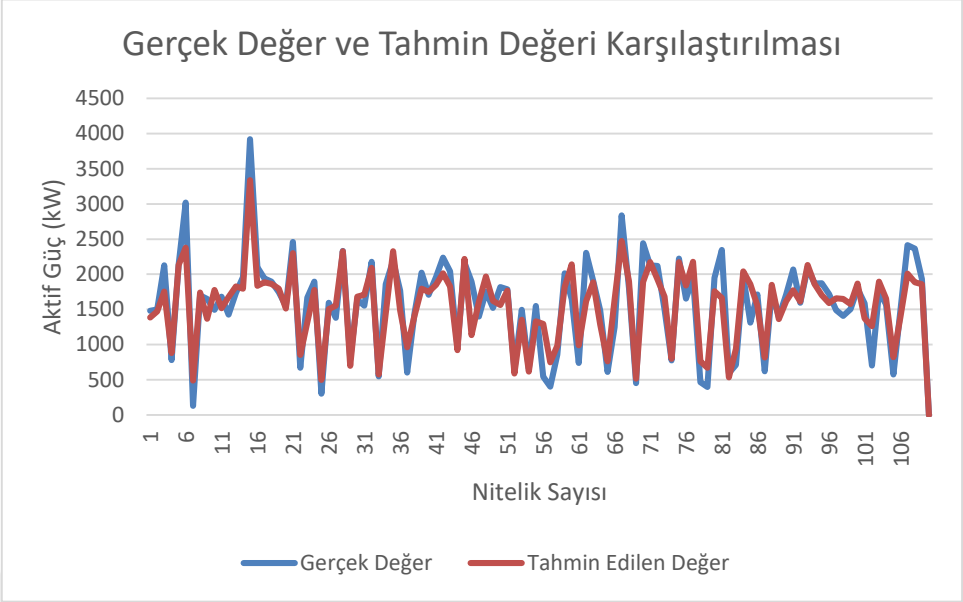
Test modu	%70 eğitim kümesi
Korelasyon katsayısı(başarı)	%87,75
Ortalama mutlak hata(mae)	223.97
Kök ortalama kare hata(rmse)	325.08
Rölatif mutlak hata(rae)	%44.32
Rölatif karesel hatanın karekökü(rrse)	%49.70
Toplam veri sayısı	109

Oranlı bölme özelliğinde rassal orman algoritmasında başarı oranı düşmeyip yüksek başarı oranı yakalamıştır. Rassal Orman algoritmasında sistem giriş, çıkış ve hata değerleri Tablo 4.12'de görülmektedir.

Tablo 4.12 Rassal orman gerçek ve tahmin değerlerinin karşılaştırıldığı örnek sonuçlar

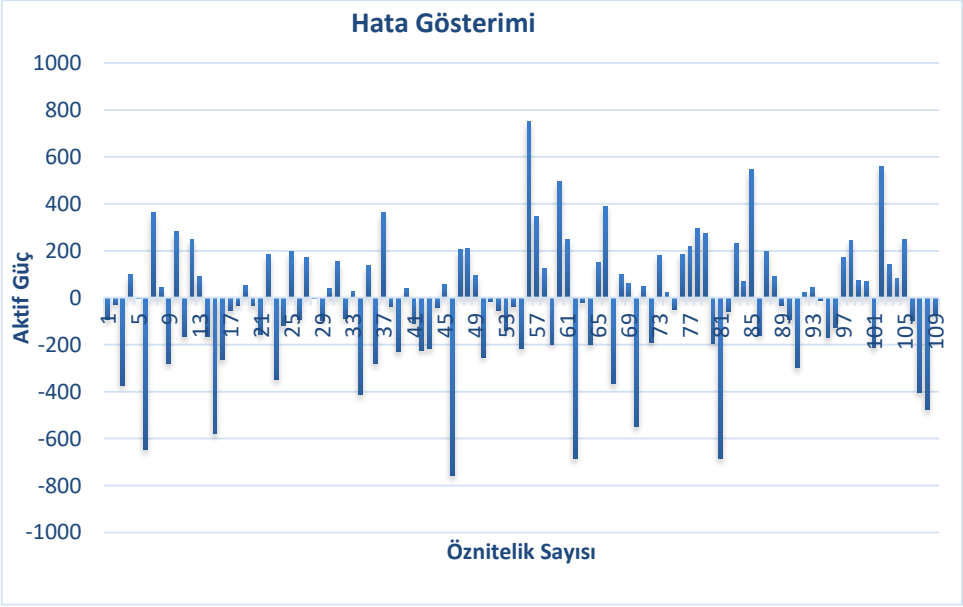
Veri Noktası	Gerçek Giriş/Çıkış Aktif Güç Miktarı(Kw)	Giriş/Çıkış Aktif Güç Tahmini (Kw)	Hata(Kw)
1	1481	1387,298	-93,702
2	1500	1473,981	-26,019
3	2128	1756,284	-371,716
4	780	879,929	99,929
5	2135	2129,811	-5,189
6	3321	2375,601	-945,399
7	128	490,251	362,251
8	1698	1741,372	43,372
9	1648	1368,867	-279,133
10	1494	1776,318	282,318
11	1683	1518,763	-164,237
12	1428	1677,718	249,718
13	1735	1826,474	91,474
14	1960	1795,606	-164,394
15	3919	2339,42	-1579,58
16	2299	1836,717	-462,283
17	1940	1885,725	-54,275
18	1897	1864,612	-32,388
19	1744	1794,533	50,533
20	1549	1513,598	-35,402

Tabloya göre diğer algoritmalarla karşılaştırıldığında hata oranının en iyi düzeyde olduğunu görülmektedir. Şekil 4.6'da 109 örnek için Rassal Orman metodu ile gerçek verilerin tahmin verileri ile birlikte verilmiş değişimi görülmektedir.



Şekil 4.6 Rassal orman gerçek değer ve tahmin değeri karşılaştırma

Diğer algoritmalar ile karşılaştırıldığında nerdeyse birebir örtüşme sağlanmış ve olabildiğince yakın grafik çizimi (daha az hata) Orman algoritması ile sağlanmıştır. Rassal Orman hata verisi Şekil 4.7'de verilmiştir.

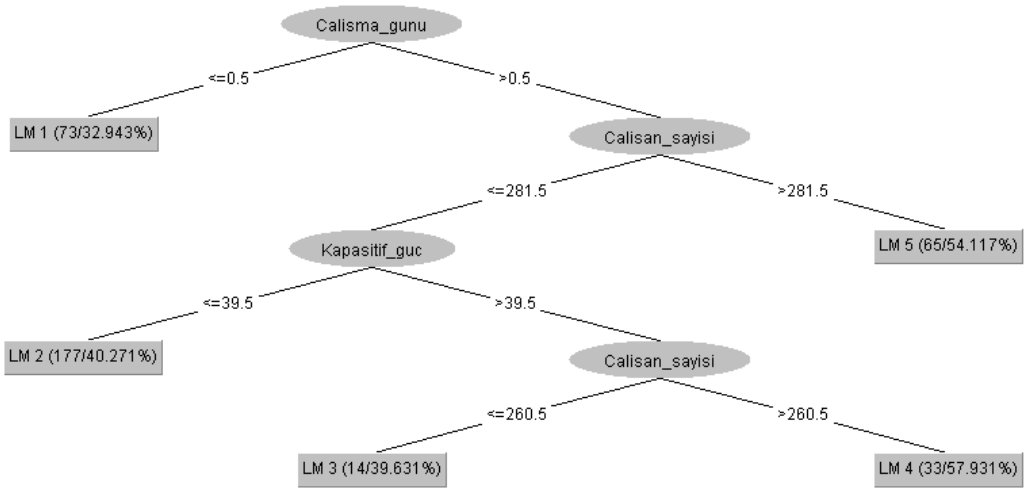


Şekil 4.7 Rassal orman hata gösterimi

Şekil 4.6'da ve 4.7'de görüldüğü üzere 6. veride 645 kW, 46. veride 759 kW, 56. veride 750 kW, 62.veride 686 kW, 81.veride 685 kW ve 102. veride ise 559 kW değerinde normalin farklı hatalı tahmin yapılmıştır.

4.5 M5P ALGORİTMASI

M5P aslında Rassal Orman gibi karar ağaçları oluşturur. Hedef, girdi değerlerini diğer özelliklerin değerleri ile ilişkilendiren bir model oluşturmaktır. Modelin verimliliği genel olarak tahmin edilmesi gereken durumların hedef değerlerini tahmin ettiği doğrulukla belirlenir. Ağaç tabanlı modeller böl ve yönet yöntemiyle üretilir (Quınlan, 2006). M5P algoritmasının ağaç yapısı Şekil 4.8'de görülmektedir.



Şekil 4.8 M5P algoritması ağaç oluşumu

Bu ağaç gösteriminde incelediğimiz fabrika açısından bakılırsa dal oluşumu anlaşılabilir. Örneğin çalışma günü eğer 0.5'in üzerinde ise doğrudan çalışan sayısı dalı oluşturup değerlendirme aşamasında 281.5 değerinin üzerinde ve altında olmak üzere ağacın dalları oluşturulmaktadır. Sonuç olarak sınıflandırmada üçüncü kümede 14 değerin %39'unu doğru sınıflandırmıştır. Diğer tarafta 33 verinin %57'si doğru sınıfa toplanmıştır. M5P algoritmasının eğitim sonuçları Tablo 4.13'te görülmektedir.

Tablo 4.13 M5P algoritması eğitim sonuçları

Test modu	smoothed doğrusal modeli
Korelasyon katsayısı(başarı)	%89,51
Ortalama mutlak hata(mae)	198.84
Kök ortalama kare hata(rmse)	267.87
Rölatif mutlak hata(rae)	%42.06
Rölatif karesel hatanın karekökü(rrse)	%44.74
Toplam veri sayısı	362

Eğitim sonuçlarında doğrusal model uygulanmıştır. Başarı oranı yaklaşık %90 olarak ölçülmüştür.M5P algoritmasının çapraz doğrulama sonuçları Tablo 4.14'de görülmektedir.

Tablo 4.14 M5P algoritması çapraz doğrulama sonuçları

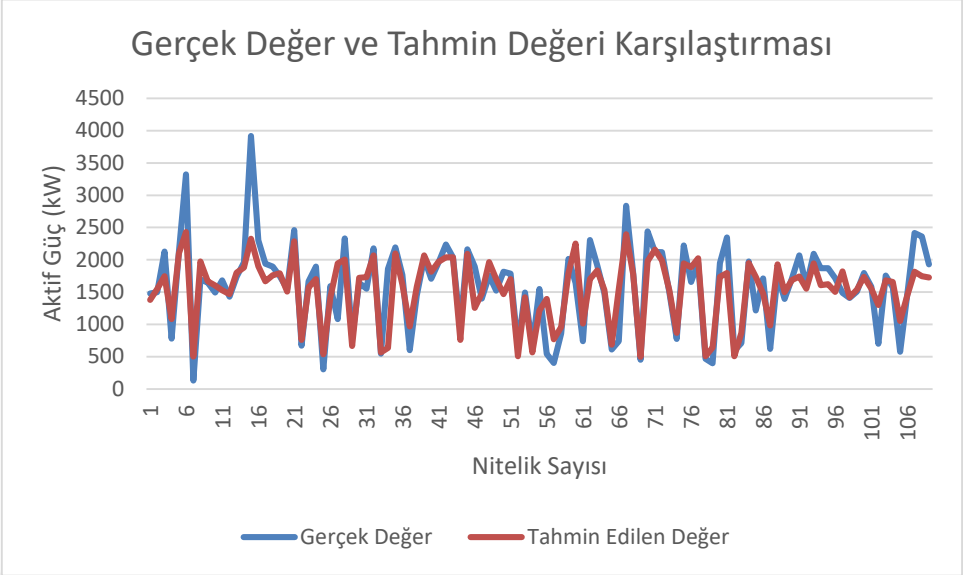
Test modu	Smooted doğrusal model
Korelasyon katsayısı(başarı)	%84,51
Ortalama mutlak hata(mae)	230.96
Kök ortalama kare hata(rmse)	320.06
Rölatif mutlak hata(rae)	%48.77
Rölatif karesel hatanın karekökü(rrse)	%53.38
Toplam veri sayısı	362

Eğitim sonuçlarına göre başarı oranı düşüp hata oranı yükselmiştir. M5P algoritmasının oranlı bölme sonuçları Tablo 4.15'te görülmektedir.

Tablo 4.15 M5P algoritması oranlı bölme sonuçları

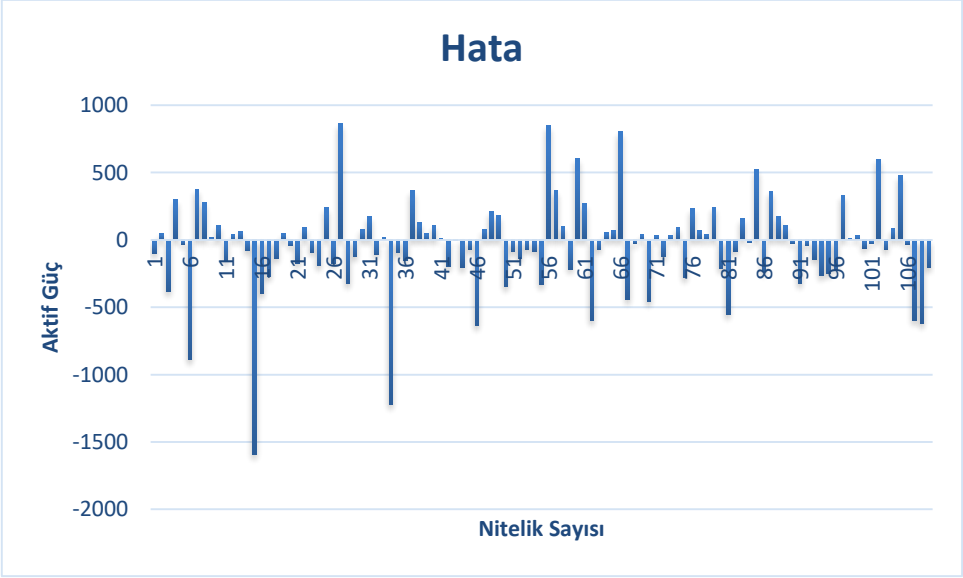
Test modu	Smooted doğrusal model
Korelasyon katsayısı(başarı)	%85,11
Ortalama mutlak hata(mae)	237.99
Kök ortalama kare hata(rmse)	353.91
Rölatif mutlak hata(rae)	%47.10
Rölatif karesel hatanın karekökü(rrse)	%54.10
Toplam veri sayısı	109

%70'lik oranlı bölme ile başarı oranı %85 olduğu gözlenmiştir. Şekil 4.9'da M5P metodu ile gerçek verilerin tahmin verileri ile birlikte verilmiş değişimi görülmektedir.



Şekil 4.9 M5P Algoritması gerçek değer ve tahmin değeri karşılaştırması

Tepe ve çukur noktalarında benzer değerlerin elde edilmesi başarılı sonuç elde edildiğinin göstergesidir. M5P metodu için hata verisi Şekil 4.10'da görülmektedir.



Şekil 4.10 M5P algoritması hata gösterimi

M5P modelinde en fazla hata 1500 kW değeri ile gözlemlenmiştir.

4.6 KNN ALGORİTMASI

KNN algoritması örnek tabanlı bir sınıflandırıcıdır. Sınıflandırma yaparken eski veri ile sınıflandırılacak verinin bir önceki verilere göre yakınlığına bakarak ilgili sınıfa atmaktadır. Yakınlığı tespit eden k katsayısı 1 olarak alınmıştır. Bu algoritmada bütün veri setinin taranması sağlanır. KNN algoritmasının eğitim sonuçları Tablo 4.16'da görülmektedir.

Tablo 4.16 KNN algoritması eğitim sonuçları

Test modu	%100 eğitim
Korelasyon katsayısı(başarı)	%100
Ortalama mutlak hata(mae)	0
Kök ortalama kare hata(rmse)	0
Rölatif mutlak hata(rae)	%0
Rölatif karesel hatanın karekökü(rrse)	%0
Toplam veri sayısı	362

KNN algoritmasında eğitim oranı %100 görülürken hatalar 0 olarak hesaplanıştır. KNN algoritmasının çapraz doğrulama sonuçları Tablo 4.17'de verilmiştir.

Tablo 4.17 KNN algoritması çapraz doğrulama sonuçları

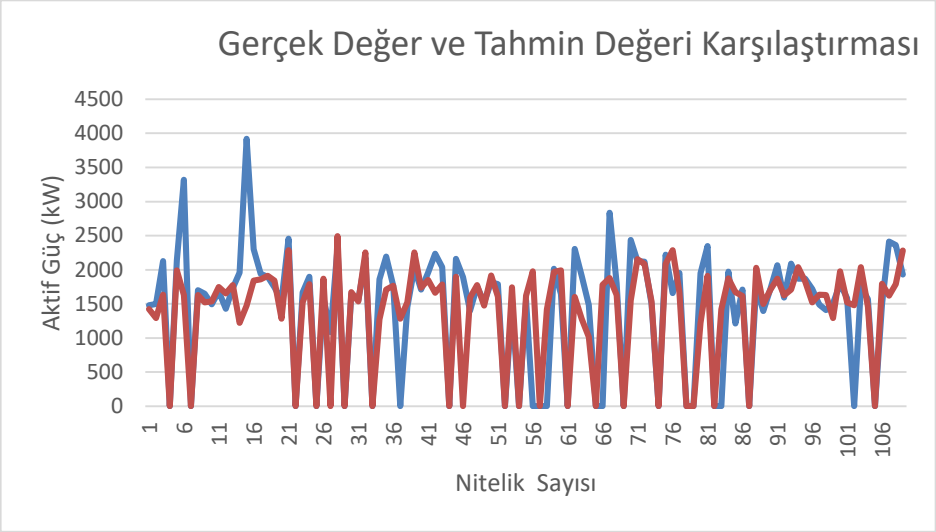
Test modu	10'lu kümeleme
Korelasyon katsayısı(başarı)	%74.41
Ortalama mutlak hata(mae)	291.721
Kök ortalama kare hata(rmse)	414.7956
Rölatif mutlak hata(rae)	%6.6117
Rölatif karesel hatanın karekökü(rrse)	%69.1848
Toplam veri sayısı	362

Algoritma ile diğer sonuçlar karşılaştırıldığında ciddi oranda başarı oranı düşmüştür. KNN algoritmasının oranlı bölme sonuçları Tablo 4.18'de verilmiştir.

Tablo 4.18 KNN algoritması oranlı bölme sonuçları

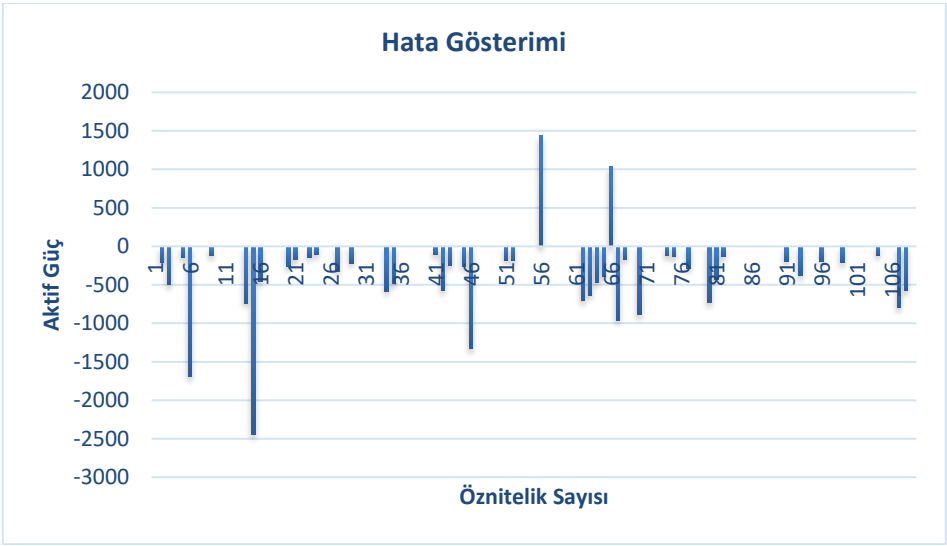
Test modu	%70 bölmeli
Korelasyon katsayısı(başarı)	%69.86
Ortalama mutlak hata(mae)	306.4553
Kök ortalama kare hata(rmse)	469.0866
Rölatif mutlak hata(rae)	%60.8859
Rölatif karesel hatanın karekökü(rrse)	%72.179
Toplam veri sayısı	109

KNN algoritmasını %69 başarım oranı nedeniyle yeterli tahmin performansını göstermediğine karar verilmiştir. Şekil 4.11'de KNN algoritması ile gerçek verilerin tahmin verileri ile birlikte verilmiş değişimi görülmektedir.



Şekil 4.11 KNN gerçek değer ve tahmin değeri karşılaştırma

Gerçek verilerle tahmin edilen veriler karşılaştırdığında birçok noktada benzer değerlerin olmasına rağmen hata oranın fazla olduğu verilerde şekilde görülmüştür. KNN metodu için hata verisi Şekil 4.12'de verilmiştir.



Şekil 4.12 KNN hata gösterimi

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında yüksek enerji tüketen endüstriyel kuruluşların enerji tüketim verilerinin günlük olarak incelenmesine yönelik bir çalışma yürütülmüştür. Bu kapsamda elde edilen sonuçlarla tüketim değişiminin nasıl oluştuğu irdelenmiştir. Tüketim hakkında analiz yapılırken çevresel faktörler ve çalışma koşulları göz önünde bulundurulmuştur. Enerji tüketiminin fazla olduğu tesislerde enerji verimliliği kadar dikkat edilmesi gereken bir diğer husus ise kapasite artırımına gidilmesi gereken durumlarda tesis yatırımının doğru bir şekilde yapılmasıdır. Çünkü yanlış analizler ekstra yatırım maliyetlerine yol açmaktadır.

Bu tez kapsamında güç trafosu ve ekipmanları üreten bir fabrikanın enerji analiz ve tahmin çalışması yapılmıştır. İncelenen fabrika yaklaşık 1200 çalışanı olan 90 000 metre kare alan üzerine kurulu 6,5 MVA Kurulu güce sahip bir tesistir. Enerji analizin doğru bir şekilde yapılması için en fazla enerji tüketen ekipman veya cihazların güç analizleri ile anlık takibi hangi durumlarda ve ne kadar enerji tüketildiğini anlık izleme ve raporlama imkanı sağlar. Bu izleme metodu aslında enerji yönetimin bir parçasıdır.

Bu çalışmada fabrikadan alınan sıcaklık, nem, çalışan sayısı, mevsim, aktif güç, çalışma gün durumu, üretim âdeti, kapasitif güç ve endüktif güç değerleri incelenmiştir. Toplamda dokuz öznitelikten sekizi giriş olarak alınıp, asıl tüketim değerinin parametresi olan aktif güç ise çıkış olarak alınmıştır. Tahmin edilen değerler ile gerçek değerler arasındaki farklar analiz edilmiştir. Bu analizler sırasında elde edilen hata oranlarına bakılarak en uygun kestirim yöntemi b

Tahmin ve analiz yöntemi için WEKA yazılım programı kullanılmış olup, yazılımın içerisinde bulunan 3 farklı özellik ile veriler test edilmiştir. Eğitim seti, çapraz doğrulama ve oranlı bölme yöntemleri uygulanmıştır. Alınan veriler WEKA yazılımında bulunan 5 farklı algoritma ile analiz edilmiştir. Bu tez kapsamında KNN, M5P, Doğrusal Regresyon, Çok Katmanlı Algılayıcı ve Rassal Orman algoritmalar kullanılmıştır.

Algoritmalar tek tek denenmiş olup, doğruluk oranları, başarı yüzdeleri, mutlak hataları, ortalama kare hataları, rölatif mutlak hataları ve bağıl karesel hatanın karekökleri karşılaştırılmıştır. Bu değerlendirme sonucunda en yüksek başarı oranı ve en düşük hata oranı veren algoritma Rassal Orman algoritması olarak gözlemlenmiştir. Gerçek ve tahmin edilen

değerler karşılaştırıldığında belirli noktalarda değişkenlik gösteren değerler haricinde gerçek değerlere paralel olup benzer kestirim sonuçları elde etmemizi sağlamıştır.

Yapılan tahmin tesis özelinden tüm Türkiye'de de genelleştirip endüstriyel tesislerin tüketimlerinin analizi yapılıp değişken durumlardaki elektrik enerjisi tüketimi tahmin edilip buna göre elektrik enerjisi talep arz dengesi kurabilmek için kullanılabilir. Üretim arttırma gibi enerji tüketimini dengeleyecek faktörleri kontrol edip enerji verimliliği ile ilgili tahminler yapılabilir. Böylelikle hem tesisin hem de ülke genelinde ciddi kazançlar sağlanabilir.

KAYNAKÇA

(2019, Nisan). Kaggle web sitesi: https://www.kaggle.com/datasets

Akın, M. (2018). *Ekstrem Rüzgarların Yapay Sinir Ağları ve Çoklu Lineer Regresyon Kullanarak Kısa Süreli Tahmini.* İstanbul: İstanbul Teknik Üniversitesi.

Atmaca, K. (2017, Mart 10). Mayıs 12, 2019 tarihinde Kenan Atmaca Blog Sitesi: https://kenanatmaca.com/lineer-regression-algoritmasi/ adresinden alındı

Castelli, M., Trujillo, L., Vanneschi, L., & Popovic, A. (2015). *Prediction of Energy Performance of Residential Buildings:A Genetic Programming Approach.* Eenergy Build.

Çölkesen, İ., & Kavzoğlu, T. (2017). *Örnek Tabalı K-Star Algoritması ile Uzaktan Alınan Görüntülerin Sınıflanıdrılması.* Kocaeli: GYTE,Mühendislik Fakültesi,Jeodezi ve Fotogrameti Müh. Bölümü.

Demirhan, T. (2015). *Makine Öğrenmesi Algoritmalarının Karmaşıklık ve Doyugnluk Analizinin Bir Veri Kümesi Üzerinde Gerçekleştirilmesi.* Edirne: Trakya Üniversitesi Fen Bilimleri Enstitüsü.

Dudek, G. (2014). *Short-Term Load Forecasting Using Random Forests "Intelligent Systems"*. Springer International Publishing.

Enerji ve Tabii Kaynaklar Bakanlığı. (2017). *Türkiye Elektrik Enerjisi Talep Projeksiyon Raporu.* Ankara.

Fischer, M. (2008). *Modelling and Forecasting Energy Demand Principles and Difficulties In Management of Weather and Climate Risk in the Enegy Industry.* Netherlands: Springer Verlag.

Gladysz, B., & Kuchta, D. (2008). *Application of Regression Trees In The Analysis Of Electricity Load* (Cilt 1). Badania Operacyjne.

Haufe, S. (2017). *A workbench for the K Algorithm.* Konstanz: Universtiy of Konstanz Departmant of Computer Information Science.

Hong, W., Dong, Y., Chen, L., & Wei, S. Y. (2011). *SVR with Hybrid Chaotic Immune Algorithm for Seasonal Load Demand Forecasting Enegies.* http:dx.doi.org/10.3390/en4060960

İnce, A. (2018). *Yapay Sinir Ağları ve Rastgele Orman Yöntemleri ile Landsat 8 Görüntülerinden Otomatik Kıyı Çizgisi Çıkartılması.* İstanbul: Yıldız Teknik Üniversitesi.

Karabacak, M. (2012). *Çok Katmanlı Perseptron Yapay Sinir Ağlarıyla Sigara Bırakmaya Etki Eden Faktörlerin İncelenmesi.* Edirne.

Keskenler, M. F., & Keskenler, E. F. (2017). *Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi* (Cilt 5). Erzurum: Atatürk Üniversitesi, RTE Üniversitesi.

Lee, K., & Park, J. H. (1992). *Short-Term Load Forecasting Using An Artificial Neural Network "Transactions on Power Systems* (Cilt 7).

Mitchell, M. T. (1997). *Machine Learning.* (McGraw-Hill, Dü.) USA.

Mohandes, M. (2002). *Support Vector Machines For Short-Term Electrical Loac Forecasting.* İnternational Journal of ENergy Research.

Parkpoom, S. J. (2007). *The Impact of Climate Change on Electricity Demand in Thailand.* The Universty of Edinburg.

Quınlan, J. (2006). *Learning with Contınuous Classes.* Sidney, Avusturalya: Basser Departmant of Compter Science Unıversty of Sydney.

Schellong, W. (2011). *Energy Demand Analysis and Forecast.* (D. G. (Ed.), Dü.) Shanghai, China.

TEİAŞ Planlama ve Yatırım Dairesi Başkanlığı . (2017). *10 Yıllık Talep Tahminleri Raporu.* İstanbul.

Tsanas, A., & Xifara, A. (2012). *Accurate Quantitaive Estimation of Energy Performance of Residential Buildings Using Statistical Machine Learning Tools.* (E. Building, Dü.)

Tugal, N. (2014). *Enerji Talebi ve Enerji Talebini Belirleyen Faktörler.* Afyonkarahisar.

Üstünsoy, F. (2018). *Orta Ölçekli Bir Tesisin Scada ile Enerji Yönetim.* Ankara.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	SEFA BEYAZTOPRAK
Doğum Yeri	ADIYAMAN
Doğum Tarihi	10.06.1991
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	05079518569
E-Posta Adresi	sefabeyaztoprak@gmail.com
Web Adresi	



Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektrik Elektronik Mühendisliği
Mezuniyet Yılı	2015

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Elektrik-Elektronik Mühendisliği Anabilim Dalı
Programı	Elektrik Elektronik Mühendisliği

Makale ve Bildiriler