T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI İLE TÜRKİYE'NİN UZUN DÖNEM ELEKTRİK TALEP TAHMİNİ

Seda TURGUT

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

Danışman

Doç. Dr. Gülder KEMALBAY

Temmuz, 2019

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI İLE TÜRKİYE'NİN UZUN DÖNEM ELEKTRİK TALEP TAHMİNİ

Seda TURGUT tarafından hazırlanan tez çalışması çalışması 25.07.2019 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Gülder KEMALBAY

Yıldız Teknik Üniversitesi

Danışman

Jüri Üyeleri

Doç. Dr. Gülder KEMALBAY, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Gülhayat GÖLBAŞI ŞİMŞEK, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. Ozan KOCADAĞLI, Üye
Mimar Sinan Güzel Sanatlar Üniversitesi _____

Danışmanım Doç. Dr. Gülder KEMALBAY sorumluluğunda tarafımca hazırlanan Yapay Sinir Ağları İle Türkiye'nin Uzun Dönem Elektrik Talep Tahmini başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Seda TURGUT

İmza

Aileme

ve

biricik eşime

TEŞEKKÜR

Lisans ve Yüksek Lisans öğrenimim boyunca ihtiyaç duyduğum her konuda bana yardımcı olan, hoşgörülü ve anlayışlı yapısıyla beni motive etmesine ek olarak engin bilgi ve tecrübesiyle yol göstericim değerli hocam Doç. Dr. Gülder Kemalbay'a sonsuz saygı sevgi ve teşekkürlerimi sunarım.

Aynı zamanda hayatımın her aşamasında benden desteklerini, güvenlerini, sonsuz emeklerini esirgemeyen kıymetli aileme, her zaman beni iyi hissettirerek yanımda olan arkadaşlarıma, sabır ve anlayışıyla her daim benim yanımda olan hayat arkadaşım Burak Obenik'e çok teşekkür ederim. İyi ki varsınız…

İstanbul Seda TURGUT

Temmuz, 2019

İÇİNDEKİLER

SİMGE LİSTESİ **X**

KISALTMA LİSTESİ **XI**

ŞEKİL LİSTESİ **XIII**

TABLO LİSTESİ **XIV**

ÖZET **XV**

ABSTRACT **XVII**

1 Giriş **1**

1.1 Literatür Özeti 1

1.2 Tezin Amacı 4

1.3 Hipotez 4

2 Türkiye Elektrik Sistemi **5**

2.1 Dünyada Elektriğin Tarihsel Gelişimi 5

2.2 Türkiye'de Elektriğin Tarihsel Gelişimi 7

2.2.1 İmtiyazlar ve Dağınık Uygulamalar Dönemi (1902-1970) 8

2.2.2 Bütünleşme (Yarı Tekel) Dönemi (1970-1982) 8

2.2.3 Kamu Tekeli Dönemi (1982-1983) 9

2.2.4 Özel sektöre açılım dönemi (1984-2001) 9

2.2.5 Serbest Piyasa Dönemi (2001 ve sonrası) 10

2.3 Elektrik Üretim Sistemi ve Kurulu Güç 10

2.4 Elektrik İletim Sistemi 12

2.5 Elektrik Dağıtım Sistemi 13

2.5.1 Dallı Şebekeler 13

2.5.2 Ring Şebekeler 14

2.5.3 Ağ Gözlü Şebekeler 14
2.5.4 Enterkonnekte Şebekeler 15
2.6 Elektrik Tüketim Sistemi 17
2.7 Elektrik Piyasası 18
2.7.1 İkili Anlaşmalar 19
2.7.2 Gün Öncesi Piyasası 20
2.7.3 Gün İçi Piyasası 20
2.7.4 Dengeleme Güç Piyasası 21
3 Yapay Sinir Ağları 22
3.1 Yapay Sinir Ağlarına Giriş 22
3.2 Yapay Sinir Ağlarının Genel Özellikleri 23
3.3 Yapay Sinir Ağlarının Dezavantajları 25
3.4 Geleneksel Algoritmalar ile Yapay Sinir Ağlarının Karşılaştırılması 26
3.5 Yapay Sinir Ağlarının Kullanıldığı Alanlar 26
3.6 Yapılarına Göre Yapay Sinir Ağları 27
3.6.1 Tek Katmanlı İleri Beslemeli Ağlar 27
3.6.2 Çok Katmanlı İleri Beslemeli Ağlar 28
3.6.3 Geri Beslemeli Ağlar 29
3.7 Yapay Sinir Ağlarında Öğrenme Kuralları 30
3.7.1 Hata Düzeltme Öğrenimi (Error-Correction Learning) 30
3.7.2 Bellek Tabanlı Öğrenme (Memory-Based Learning) 30
3.7.3 Hebbian Öğrenme 30
3.7.4 Rekabetçi Öğrenme (Competitive Learning) 30
3.7.5 Boltzman Öğrenme 30
3.7.6 Hopfield Öğrenme Kuralı 31

3.7.7 Delta Kuralı (Widrow ve Adaline) 31
3.7.8 Kohonen Kuralı 31
3.8 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları 31
3.8.1 Danışmalı Öğrenme 31
3.8.2 Danışmansız Öğrenme 31
3.8.3 Destekleyici Öğrenme 31
3.9 Yapay Sinir Hücresinin Yapısı 32
3.9.1 Girdiler 32
3.9.2 Ağırlıklar 32
3.9.3 Birleştirme Fonksiyonu 33
3.9.4 Aktivasyon Fonksiyonu 34
3.9.5 Çıktılar 37
3.10 Yapay Sinir Ağlarının Eğitilmesi 38
3.11 Yapay Sinir Ağlarında Normalizasyon Çeşitleri 39
3.11.1 Z-Score Normalizasyonu 39
3.11.2 Min-Max Normalizasyonu 40
3.11.3 Medyan Normalizasyonu 40
3.11.4 Sigmoid Normalizasyonu 40
3.11.5 D_Min_Max Normalizasyonu 41
4 Uygulama **42**
4.1 MATLAB Programının Genel Özellikleri 42
4.2 Eğitim- Onaylama- Test Veri Setlerinin Belirlenmesi 43
4.3 MATLAB Programına Verilerin Aktarılması 44
4.4 Ağ Yapısının Belirlenmesi 46
4.5 Uzun Dönem Projeksiyon 54

5 Sonuç ve Öneriler **56**

Kaynakça **57**

Tezden Üretilmiş Yayınlar **62**

SİMGE LİSTESİ

GWh	Cigavat Saat
kW	Kilovat
MW	Megavat
MWh	Megavat Saat
MWA	Megavolt Amper

KISALTMA LİSTESİ

AB	Avrupa Birliği
AC	Alternatif Akım
AHP	Analitik Hiyerarşi Süreci
AIC	Akaike Bilgi Ölçütü
AICc	Düzeltilmiş Akaike Ölçütü
BIC	Bayesian Bilgi Ölçütü
BİST	Borsa İstanbul
DGP	Dengeleme Güç Piyasası
DSİ	Devlet Su İşleri
DVM	Destek Vektör Makineleri
EKK	En Küçük Kareler
EPDK	Enerji Piyasası Düzenleme Kurumu
EPİAŞ	Enerji Piyasaları İşletme A.Ş.
EÜAŞ	Elektrik Üretim Anonim Şirketi
GİP	Gün İçi Piyasası
GÖP	Gün Öncesi Piyasası
GRU	Geçitli Tekrarlayan Üniteler
GSYİH	Gayri Safi Yurt İçi Hasıla
IMF	Uluslararası Para Fonu
İA	İkili Anlaşmalar
İHD	İşletme Hakkı Devri
LSTM	Uzun Kısa Süreli Hafıza
MYTM	Milli Yük Tevzi Merkezi

OHK	Ortalama Hata Karesi
OMYH	Ortalama Mutlak Yüzde Hata
PTF	Piyasa Takas Fiyatı
R	Regresyon
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TEK	Türkiye Elektrik Kurumu
Yİ	Yap İşlet
YİD	Yap İşlet Devret
YSA	Yapay Sinir Ağları
YTBS	Yük Tevzi Bilgi Sistemi
YTM	Yük Tevzi Merkezleri

ŞEKİL LİSTESİ

Şekil 2.1 Dallı şebeke sistemi 14
Şekil 2.2 Ring şebeke sistemi 14
Şekil 2.3 Ağ gözlü şebekeler 15
Şekil 2.4 Türkiye enterkonnekte sistemi ağ haritası 15
Şekil 2.5 Türkiye'nin yıllar itibariyle kişi başına düşen tüketim değişimi 17
Şekil 2.6 Elektrik enerjisi piyasa yapısı 19
Şekil 3.1 Tek katmanlı ileri beslemeli yapay sinir ağ yapısı 28
Şekil 3.2 Çok katmanlı ileri beslemeli yapay sinir ağ yapısı 28
Şekil 3.3 Geri beslemeli yapay sinir ağ yapısı 29
Şekil 3.4 Yapay sinir hücresi modeli 32
Şekil 4.1 Neural network araç kutusu 44
Şekil 4.2 Çalışma sayfasındaki girdi-çıktı değerleri 44
Şekil 4.3 Yapay sinir ağı veri yöneticisi 45
Şekil 4.4 Veri ekleme çubuğu 45
Şekil 4.5 Yapay sinir ağı araç kutusu 46
Şekil 4.6 Yeni ağ/veri oluşturma ekranı 47
Şekil 4.7 Oluşturulan ağ görünümü 50
Şekil 4.8 Oluşturulan ağın performans grafiği 51
Şekil 4.9 Eğitim, onaylama ve test verileri için regresyon grafiği 51
Şekil 4.10 Eğitim durumu 52

TABLO LİSTESİ

Tablo 2.1 Kurulu gücün kuruluşlara göre 2017-2018 yılları arasındaki değişimi.... 11
Tablo 2.2 Kurulu gücün yakıt cinsine göre 2017-2018 yılları arasındaki değişimi.. 11
Tablo 2.3 Türkiye enerji iletim hatları 12
Tablo 2.4 TEİAŞ trafo merkezleri 12
Tablo 2.5 Elektrik şebeke gerilimleri 13
Tablo 2.6 Türkiye'nin bölgelere göre elektrik dağıtım şirketleri 16
Tablo 2.7 2018 yılı Türkiye ulusal puant değerleri 18
Tablo 2.8 2018 yılı Türkiye elektrik piyasa hacimleri 19
Tablo 2.9 Türkiye yük tevzi işletme müdürlükleri 21
Tablo 3.1 Geleneksel algoritmalar ile yapay sinir ağlarının karşılaştırılması 26
Tablo 3.2 YSA'da kullanılan algoritmalar ve MATLAB kodları 32
Tablo 4.1 Ağın performansını etkileyen ölçütler 47
Tablo 4.2 Logsig transfer fonksiyonuna ait ağın performansı 48
Tablo 4.3 Tansig transfer fonksiyonuna ait ağın performansı 49
Tablo 4.4 Simule tüketim ile gerçek tüketim arasındaki uyum 53
Tablo 4.5 Test verisi için gerçek ve simule tüketim değeri kıyaslaması 54
Tablo 4.6 2019-2027 yılları için TEİAŞ projeksiyonu ile YSA tahmin kıyaslaması .. 55

ÖZET

Yapay Sinir Ağları ile Türkiye'nin Uzun Dönem Elektrik Talep Tahmini

Seda TURGUT

İstatistik Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Gülder KEMALBAY

Elektrik, bir ülkenin ekonomik göstergelerinin şekillenmesine etki eden en önemli etmenlerden birisidir. Ülkelerin gelişmişlik düzeyleri arttıkça elektrik talepleri de artacaktır. Ülkelerin gelecek planlamasında yapılması gereken en önemli tahminlemelerden birisi elektriktir. Elektrik enerjisi depolanamadığı ve üretildiği anda tüketildiği için planlamanın optimal seviyede olması gerekir. Aksi halde bu durum ciddi kayıplara yol açacaktır. Planlamayı optimal seviyede tutmak ile birlikte elektrik arz ve talep dengesi sağlanacak, israf minimuma indirilecek ve elektrik şebekeleri güvende olacaktır. Her ülke de elektrik stratejilerinde bu durumları amaçlamaktadır. Bu çalışmanın amacı, yapay sinir ağları (YSA) yaklaşımını kullanarak Türkiye'de uzun dönem elektrik enerjisi talep tahminini yapmaktır. Bu kapsam dahilinde, 1923-2018 yılları arasında gerçekleşen toplam nüfus, kurulu güç ve brüt elektrik üretim değerleri kullanılarak çok katmanlı ileri beslemeli geri yayılımlı ağ yapıları oluşturulmuştur. Ağın performansı, ortalama hata karesi kriteri ile ölçülmüştür. Elde edilen sonuçlara göre yapay sinir ağlarının oldukça başarılı

tahminler gerçekleştirdiği görülmüştür. Daha sonra ise Türkiye'de 2019 - 2027 yılları arasında gerçekleşecek olan toplam elektrik talep değerleri tahmin edilmiştir.

Anahtar Kelimeler: Elektrik, enerji, talep, talep tahmini.

ABSTRACT

Turkey's Long-Term Electricity Demand Forecasting with Artificial Neural Networks

Seda TURGUT

Department of Statistics

Master of Science Thesis

Advisor: Assoc. Prof. Dr. Gülder KEMALBAY

Electricity is one of the most important factors affecting the shaping of a country's economic indicators. As the development levels of countries increase, so will the demand for electricity. Electricity is one of the most important predictions for the future planning of countries. Planning should be optimal because electrical energy cannot be stored and consumed at the time of production. Otherwise, this will cause serious losses. In order to keep the planning at an optimal level, the balance of electricity supply and demand will be ensured, waste will be minimized and electricity networks will be safe. Each country aims at these situations in their electricity strategies. The purpose of this study, artificial neural networks (ANN) using the approach is to make the long-term electricity demand forecasts in Turkey. Within this scope, multi-layered feed forward feed back network structures were formed by using the total population, installed power and gross electricity generation values realized between 1923-2018. The performance of the network was measured by the mean error square criterion. According to the results, it has been seen that artificial neural networks make very successful predictions. Later in

Turkey in 2019 - the total value of electricity demand, which will take place between 2027 was estimated

Keywords: Electricity, energy, demand, demand forecasting.

1
Giriş

1.1 Literatür Özeti

Yapay sinir ağları ile elektrik talep tahmini konusunda yapılan çalışmalar aşağıdaki gibi özetlenmiştir.

Mandal ve Sinsa, yapay sinir ağlarını kullanarak kısa dönemli elektrik talep tahminini yapmışlardır. Ağı eğitirken 7 farklı model üzerinde çalışmışla ve elde edilen modellerin hata değerleri %2 civarlarında bulunmuştur (Mandal ve Sinsa, 1995).

Voss ve diğerleri, günlük ve saatlik yağış akışı modellemesi için çok katmanlı ileri beslemeli YSA yaklaşımını kullanmışlardır. Hava durumu ve ekonomik gelişmeler girdi değişkeni olarak olarak kullanılmıştır. Ağın eğitimi esnasında çoklu model performans ölçümlerinin bir kombinasyonunun kullanılması önerilmiştir (Voss vd., 1995).

Parlos ve diğerleri, uzun dönemli elektrik talep tahmini konusundaki çalışmalarını YSA kullanarak gerçekleştirmişlerdir. YSA'ya ek olarak genetik algoritma ve bulanık mantık modellemelerini de kullanmış ve melez bir model elde etmişlerdir (Parlos vd., 1996).

Yalçınöz ve diğerleri, yapay sinir ağları ve hareketli ortalamalar metodlarını kullanarak Niğde bölgesinin elektrik tüketimini tahmin etmişlerdir. Çalışmanın sonucunda iki yönetimi kıyaslamış ve yapay sinir ağlarının daha başarılı olduğunu görmüştür. Aynı zamanda 4 girişli 1 çıkışlı ağ yapısının yük tahmini için oldukça başarılı olduğunu gözlemlemiştir (Yalçınöz vd., 2002).

Hsu ve Chen, Tayvan'da bölgesel elektrik yük tahminini yapmak için yapay sinir ağları ve regresyon tekniklerini kullanmışlar ve sonuçları kıyaslamışlardır. Çalışmaya göre, YSA yöntemi daha başarılı performans göstermiştir (Hsu ve Chen, 2002).

Hamzaçebi ve Kutay, YSA ile Türkiye elektrik enerjisi tüketimini 2010 yılına kadar tahmin etmişlerdir. Uygulama kısmında zaman serileri, regresyon ve YSA tekniklerini aynı anda kullanılmıştır. YSA ve regresyon tekniklerinin sonucu iyi çıkmıştır. Ancak regresyon teknik sonucunun iyi çıkması veri fazlalığıyla ilgilidir. Daha az veriler ile çalışırken YSA daha sağlıklı sonuçlar verecektir. Sonuç olarak YSA tekniğinin iyi bir tahmin aracı olduğuna karar verilmiştir (Hamzaçebi ve Kutay, 2004).

Özpınar, yenilenebilir enerji santrallerinde üretimin modellenmesi ve planlanması için YSA yöntemini kullanmıştır. Rüzgar, güneş ve su kaynaklarına göre ayrı ayrı modelleme yaparak en uygun sonuçlara ulaşmıştır. Kısa, orta ve uzun vadedeki planlamaları çıkan sonuçlara göre değerlendirmiştir (Özpınar, 2007).

Ekonomou, Yunanistan'ın enerji tüketim tahminini yapay sinir ağlarını kullanıp destek vektör makineleri (DVM) ve regresyon modelleri ile karşılaştırarak tahmin etmiştir. Bu karşılama sonucunda elde ettiği YSA tahminleri oldukça başarılı gözlemlenmiştir (Ekonomou, 2010).

Pao, Tayvan'da elektrik tüketim tahmini için hibrit doğrusal olmayan modeller kullanmıştır. Çalışmasında, YSA tahminlerinin çeşitli doğrusal olmayan tahminleme metodlarından daha başarılı olduğu görülmüştür (Pao, 2006).

Kavaklıoğlu ve diğerleri, Türkiye'nin elektrik talep tahmini modellemesinde yapay sinir ağlarını kullanmışlardır. Girdi değişkenleri olarak ithalat, ihracat, nüfus, GSYİH değerlerinden yararlanmışlar ve YSA tekniğinin talep tahmini konusunda başarılı olduğu sonucuna ulaşmışlardır (Kavaklıoğlu vd., 2009).

Kaya, Türk Telekomünikasyon A.Ş.'de elektrik tüketim tahmini için Yapay Sinir Ağları ve Regresyon Analizi uygulamaları yapmış ve sonuçları karşılaştırmıştır. Regresyon analizi sonucunda elde edilen en düşük hata oranının, YSA modelinin ürettiği hata oranından oldukça yüksek olduğu gözlenmiş ve YSA yönteminin başka tahminlemelerde de rahatlıkla kullanılabileceği sonucuna ulaşılmıştır (Kaya, 2010).

Tutun, yüksek lisans tez çalışmasında yapay zeka teknikleri ile elektrik enerjisini tahmin etmiştir. Değişken sayısı arttıkça tahmin performansının düştüğünü gözlemlemiş ve bunun üzerine en fazla dört değişken ile çalışmaya karar vermiştir.

En iyi model yapısı ve bu modele bağlı olan kombinasyonları teker teker açıklamıştır. %2,55 ortalama mutlak yüzde hata (OMYH) değeri ile geçmiş çalışmalar arasındaki en başarılı performansa ulaşmıştır (Tutun, 2012).

Kaytez, doktora tez çalışmasında Türkiye'nin uzun dönem elektrik talep tahminini gerçekleştirmiştir. Çalışmasında DVM, en küçük kareler (EKK) ve yapay sinir ağlarını kullanıp kıyaslama gerçekleştirmiştir. Sonuçları değerlendirdiğinde OMYH değerlerine bakıldığında DVM-EKK %1.7, YSA %2.04 hata oranlarına sahiptir. İki yöntemle de talep tahminini yapmak mümkündür (Kaytez, 2012).

Buhari ve Adamu, kısa vadeli Nijerya elektrik tüketim tahminini yapay sinir ağlarını kullanarak yapmışlardır. Ağın eğitimi için Levenberg-Marquardt algoritması kullanılmış ve ortalama hata karesi (OHK) kriterine göre tahmin sonuçları oldukça başarılı performans sergilemiştir. (Burahi ve Adamu, 2012).

Yavuz ve Deveci, istatistiksel normalizasyon tekniklerinin yapay sinir ağlarının tahmin performansına etkisi konusunda çalışma yapmışlardır. Normalizasyon tekniklerinden D_Min_Max gerçeğe en yakın sonucu vermiştir. YSA yönteminin de tahmin etmede etkili bir yöntem olarak kullanılacağını savunmuşlardır (Yavuz ve Deveci, 2013).

Balın, Türkiye enerji planlaması için çok ölçütlü bir model önerisinde bulunmuştur. YSA, bulanık mantık, bulanık çıkarım sistemi, analitik hiyerarşi süreci (AHP), Topsis yöntemlerini kullanarak çalışmasını tamamlamıştır. İlk aşamada problemin çözümü için hibrit bir model oluşturulmuş, ikinci aşamada ise enerji planlama ve yatırımına yönelik sorunları çözmek için diğer bir hibrit model kurulmuştur. Üçüncü aşamada ise Dünya ile birlikte Türkiye'nin enerji durumu detaylı incelenerek kaynak değerlendirmesi açısından Swot analizi oluşturulmuştur. Son aşamada Türkiye'nin sağlıklı enerji kullanımı için stratejiler belirlenmiştir (Balın, 2014).

Bayrak ve Esen, çalışmalarında Türkiye'nin artan enerji ihtiyacına karşılık enerji üretimin aynı oranda artmamaması nedeni ile ortaya çıkan enerji açığı sorununa çözüm olarak arz ve talep yönlü yaklaşımlar öne sürmüşlerdir. (Bayrak ve Esen, 2014).

Masaebi, yüksek lisans tez çalışmasında yapay sinir ağları tekniğini kullanarak İran elektrik tüketim tahmini üzerinde çalışmıştır. Yakın geleceğin tahminlemesinde YSA zaman serisi modelinin, uzun geleceğin tahminlemesinde ise YSA sebep-sonuç modelinin daha başarılı sonuçlar verdiğini gözlemlemiştir. Girdi-çıktı arasındaki ilişkilerin karmaşık olmasına rağmen YSA sonuçları oldukça başarılı ve tatmin edici olmuştur (Masaebi, 2016).

Karabulut, yüksek lisans tez çalışmasında elektrik tüketimi için bir karar destek mekanizması oluşturmuştur. Çalışma sonucunda %0.076876 oranında hata payı elde edilmiştir. Kullanıcı dostu bir arayüz sayesinde mevcut durum ve gelecek durum analizlerinin kolaylıkla yapılması sağlanmıştır (Karabulut, 2017).

Tokgöz, tekrarlayan sinir ağı tabanlı elektrik tüketim tahmini konusunda yüksek lisans tezini hazırlamıştır. YSA, uzun kısa süreli hafıza (LSTM), geçitli tekrarlayan üniteler (GRU) yöntemlerini birlikte kullanmıştır (Tokgöz, 2018).

1.2 Tezin Amacı

Tez çalışmasının amacı, yapay sinir ağları yaklaşımını kullanarak Türkiye'nin uzun dönemli elektrik talep tahminini gerçekleştirmektir. Bu amaç doğrultusunda, 1923-2018 yılları arasında gerçekleşen Türkiye Net Elektrik Tüketimi, Türkiye Nüfusu, Kurulu Gücü ve Türkiye Brüt Elektrik Üretimi verileri kullanılacak ve oluşturulacak yapay sinir ağları modeli ile Türkiye'nin 2019-2027 yılları arasında gerçekleşecek olan elektrik talebini tahmin etmek hedeflenmektedir.

1.3 Hipotez

Bu tez çalışmasında, uzun dönem Türkiye elektrik talebinin yapay sinir ağları ile tahmin edilebileceği hipotezi savunulmaktadır. Hipotezin doğruluğunu test etmek amacıyla çok katmanlı ileri beslemeli yapay sinir ağ yapıları oluşturulmuştur ve gizli katmanda bulunacak nöron sayıları AIC, AICc, BIC gibi bilgi kriterleri ile belirlenirken ağın performansı OHK kriteri ile ölçülmüştür. Elde edilen tahmin sonuçları, TEİAŞ'ın uzun dönem projeksiyonu karşılaştırılarak elektrik talep tahmini için Yapay Sinir Ağları yaklaşımının başarısı araştırılmıştır.

2
Türkiye Elektrik Sistemi

Elektrik bir ülkenin ekonomik göstergelerinin şekillenmesine etki eden en önemli etmenlerden birisidir. Aynı zamanda ülkelerin sadece iç ekonomisini şekillendirmekle kalmayıp dış ilişkilerin şekillenmesinde de önemli bir payı vardır. Ülkelerin stratejik politikalarında önemli rol oynayan elektriğin önemi yadsınamaz. Günümüzde enerji ticareti ve üretimi uluslararası boyutta gerçekleşmektedir ve Türkiye de bu sürecin içerisindedir.

Elektriğin tarihçesine baktığımızda son evrede serbest piyasa dönemini görmekteyiz. Serbest piyasa döneminin uygulanmasıyla beraber piyasanın serbestleştirilmesi ve elektrik endüstrisinin özelleştirilmesi politikaları yerleştirilmektedir. Dünya Bankası, IMF gibi kurumlar ülkemizde bu politikaların yer alması için baskı kurmaktadırlar. Avrupa Birliği'ne geçiş sisteminde de elektrik sistemi ile ilgili kriterler söz konusudur. AB hukuğuna uygun bir Türkiye Elektrik Sistemi oluşturulmaya çalışılmaktadır (Göltaş ve İpek, t.y.).

2.1 Dünyada Elektriğin Tarihsel Gelişimi

Elektrik, birbirine iki cismin sürtünmesiyle, sıkıştırma gibi herhangi bir mekanik etki sırasında veya ısının bazı kristallere olan etkisi sebebiyle meydana gelen ve etkisini, itme, çekme, kimyasal, mekanik veya ısı olayları şeklinde gösteren bir enerji çeşididir. Kehribarın kumaşa sürtünmesinden sonra kıl ve toz gibi ağır olmayan cisimleri kendisine çekmesi olayı ile insanlar elektriği yüzyıllar önce tanımıştır.

Yunanlı filozof ve bilgin Thales (M.Ö. 640-546) bu deneyi ilk yapan kişidir. Bu olaya elektron adını kullanmıştır ve sadece kehribarla ilgili olduğunu sanmıştır. Yıllar geçtikten sonra elektriğin kanunları bulunmuştur. Anlaşılacağı gibi Yunanlılar devamlı bir yere sürtülen böylece kızan amberin mantar ve kağıt parçaları türünden hafif maddeleri çekebilme yeteneğini İsa'dan 600 yıl önce biliyorlardır.

İngiliz bilim adamı William Gilbert 16. Yüzyılın sonlarına doğru elektriği ciddi olarak incelemeye başlayan kişi olarak tarihe geçti. Gilbert, durgun elektrikle manyetizma arasındaki ilişki üzerinde araştırmalar yaparak elektrik teriminin ilk kullanıcılarından olarak bilinmiştir.. William Gilbert kimi kesimler tarafından elektrik mühendisliğinin veya elektrik ve manyetizmanın babası olarak düşünülür.

Joseph Priestley, 1767 yılında, aralarındaki uzaklığın karesiyle ters orantılı olarak elektrik yüklerinin birbirlerini çektiklerini buldu.

İtalyan bilim adamı Alessandro Volta'nın 1800 yılında yaptığı deneylerle akan elektriğin bulunuşu başlar. İlk elektrik pilini ve ilk elektrik akımını Alessandro Volta elde etmeyi başarmıştır.

Buna rağmen, elektriğin icadı ile ilgili kayda değer bir gelişme olduğu 1672 yılına kadar söylenemez. Otto von Guericke adında bir kişi, 1672 yılında, elini hızla dönen bir sülfür (kükürt) kürenin karşısına tutarak, daha kuvvetli elektrik üretti.

Stephen Gray 1729 yılında, metallerin bir yerden başka bir yere elektrik ilettiklerini keşfetti. "kondüktör-iletken" diye bu tür maddeleri tanımlandılar. Diğer yandan kükürt, cam, amber, balmumu gibi diğer bazı maddeler de elektriği taşımıyor,bir yerden bir yere iletmiyorlardı. "Yalıtkan" adı da bu tür maddelere verildi.

1733 yılında Du Fay adında bir Fransızın negatif ve pozitif elektrik yüklerini bulması atılan diğer önemli adım olmuştur. Du Fay, pozitif ve negatif şarjların, iki ayrı tür elektrik olduğunu sanmıştı. Buna rağmen elektriğin gerçeğe en yakın tanımlamasını yapan Benjamin Franklin'dir. Benjamin Franklin'in düşüncesine göre, tabiattaki maddelerin tamamının bünyesinde elektriksel bir akış vardı. İki madde arasındaki sürtünme, bu akıştan bir kısmının, miktar bakımından fazlalık meydana getirecek biçimde öteki maddeye geçmesine neden oluyordu. Bu akışın negatif yüklü elektronlardan oluştuğu bugün söylenebilmektedir.

1800 yılında Alessandro Volta tarafından elektrik konusunda en önemli gelişmelerin ilk pilin keşfiyle başladığı tartışmasız bir gerçektir. Bahsi geçen batarya, ilk güvenilir ve devamlı elektrik kaynağı olmak niteliğiyle, öteki buluşlar ve uygulamalar yolunda dünyaya rehberlik etmiştir.

1808'de Humphry Davy, elektrik akımı taşıyan iki kömür elektrodu birbirinden ayırarak bir ark oluşturmayı başardı ve böylelikle elektriğin ısı ya da ışık enerjisine dönüşebileceğini gösterdi. Hans Christian Orsted, 1820 yılında içinden elektrik akımı geçen bir iletkenin yakınındaki bir mıknatıs iğnesinin saptığını gözlemleyerek, elektrik akımının iletken çevresinde bir magnetik alan oluşturduğu sonucuna vardı.

Elektrik sihirbazı Sırp kökenli Amerikalı mühendis olan Nikola Tesla 1900'lerin başında, ticari elektriğin doğuşuna yüksek fayda sağladı. Elektromanyetizma alanında fazlaca çalışarak devrimci gelişmeye katkıda bulundu. Edison ile beraber çalıştı. Devrim niteliği taşıyan çalışmaları ise; AC motorları, Alternatif akım (AC), çok fazlı elektrik dağıtım sistemi ile ilgili yaptığı çalışmalardır.

19. yüzyılın ikinci yarısında elektriğin günlük yaşamdaki ve sanayideki yerini alma dönemi başladı. Elektrik enerjisinin havai hatlar aracılığıyla etkin bir biçimde iletilebileceğini Zénobe-Théopline Gramme gösterdi. Thomas Edison 1881' de New York'ta ilk elektrik üretim merkeziyle dağıtım şebekesini kurdu.Böylelikle elektrik enerjisi sanayide ve evlerde yaygınca kullanılmaya başlandı.

1880'lerde elektriğin enerji olarak kullanılması başlamıştır. Faraday'dan sonra alternatif akım jeneratörünü Fransız Hippolyte Pixli yapmıştır. Yüksek güçte jeneratörlerin kullanılması 1866'da Alman Weiner von Siemens'in jeneratörlerde mıknatıs değil de elektromıknatısı geliştirmesiyle sağlanmıştır. Elektrik enerjisinin aydınlatmada kullanılma miladı ise Thomas Edison'un 1880'lerde ampülü icat etmesi ile olmuştur (İnternet, İcatlar, 2017).

2.2 Türkiye'de Elektriğin Tarihsel Gelişimi

Türkiye'nin elektrik enerjisi ile tanışması Mersin'in Tarsus ilçesinde bir su değirmeninden yararlanılarak üretilmiş olan hidroelektrik enerji sayesinde olmuştur. O zamanın Türkiyesi'nde 2 kW boyutunda olan proje oldukça başarılı bir başlangıç sayılabilir (Demirel, 2009). Bu tarihten itibaren gelişmelere göre değerlendirdiğimizde Türkiye Elektrik Enerjisi gelişimi 5 aşamada incelenebilir (Tutuş, 2006).

1. İmtiyazlar ve dağınık uygulamalar dönemi (1970'e kadar)

2. Bütünleşme (Yarı Tekel) Dönemi (1970-1982)

3. Kamu Tekeli Dönemi (1982-1983)

4. Özel sektöre açılım dönemi (YİD,Yİ, İHD, Otoprodüktör) (1984-2001)

5. Serbest Piyasa Dönemi(2001 ve sonrası)

2.2.1 İmtiyazlar ve Dağınık Uygulamalar Dönemi (1902-1970)

Bu dönem 1910 yıllarında 2 kW gücündeki santralle başlamıştır. Diğer santraller yabancı şirketlerle imzalanan imtiyaz anlaşmaları ile kurdurulmuştur. Bu dönemde elektrikle uğraşan kuruluşların sayısı birden fazla olduğu için dağınık bir dönem yaşanmıştır. 1923 yılında bilindiği gibi Türkiye Cumhuriyeti kurulmuştur ve kurulu güç 33 MW'tır. Elektrik enerjisi 1930 yılından itibaren endüstrinin gelişmesinin de katkısı ile aydınlatma dışında da kullanılmaya başlamıştır. Atatürk'ün sayesinde 1932 yılında su ile ilgili işler başlatılmıştır. 1935 yılında ise Türkiyenin enerji gereksinimini tespit etmek, su ve diğer enerji kaynakları ile ilgili inceleme ve araştırmalar yapmak amacıyla Elektrik İşleri Etüt İdaresi kurulmuştur. Seyhan Sarıyar, Kesikköprü, Hirfanlı, Demirköprü ve Kemer Barajları dönemin en önemli projeleridir. 28 adet hidroelektrik santrali 1940 yılına kadar kurulmuş, benzer dönemde kurulmuş olan Etibank ve İller Bankası da küçük ölçekli hidroelektrik santralların inşası işlerini yürütmüştür. 1950 yılına gelindiğinde toplam kurulu güç içerisinde hidroelektriğin payı 18MW kurulu güç ile %4,4'e ulaşmıştır. 1954 yılında Devlet Su İşleri Genel Müdürlüğü (DSİ) kurulmuş, toprak ve su kaynaklarının geliştirilmesi amaçlanmıştır. Bu dönem sonunda toplam enerji üretimindeki Hidroelektrik enerjinin payı %35'e gelmiştir (Tutuş, 2006).

2.2.2 Bütünleşme (Yarı Tekel) Dönemi (1970-1982)

1970 yıllarında ülkede üretim artmış, dağıtım ve iletim gereksinimleri kurumsal bir yapının olması gerektiğini hissettirmiş ve bundan dolayı kanun ile Türkiye Elektrik Kurumu (TEK) kurulmuş ve sektördeki dağınıklık kısmi olarak giderilmiştir. Önemli sorunlarından birisi olan üretim alanları ile tüketim alanlarının birbirlerinden uzakta olmasını çözmek amacıyla hidroelektrik projeler için enterkonnekte sistem geliştirilmiştir. Türkiye'nin Atatürk (2400 MW), Karakaya (1800 MW), Keban (1330

MW), Altınkaya (700 MW), Oymapınar (540 MW) gibi önemli projeleri bu dönemde projelendirilmiş veya gerçekleştirilmiştir. Hidroelektriğin kurulu gücü bu dönemin sonunda 3082 MW'lere gelip toplam üretim içinde %53'lük paya ulaşmıştır. Hidroeletrik anlamında 'Altın Çağ' yaşanmıştır (Tutuş, 2006).

2.2.3 Kamu Tekeli Dönemi (1982-1983)

Askeri yönetim döneminde belediyelerin elinde olan elektrik dağıtım şebekeleri de çıkarılan bir kanun ile TEK bünyesine katılmış ve kısa süreli bir kamu tekeli dönemi başlamıştır. Yalnızca 157 MW kurulu güç bu dönemde sisteme ilave edilebilmiştir (Tutuş,2006).

2.2.4 Özel sektöre açılım dönemi (1984-2001)

2. ve 3. dönemin sonlarında elektrik arz eksikliği ortaya çıkmıştır. Kamu kaynakları yeni yatırımlar konusunda yetersiz kalmıştır. Tüm bu sebeplerden ötürü TEK tekeli kaldırılmış ve sektör özel girişimcilere açılmaya karar verilmiştir. Yatırım yapmaya teşvik 3096 sayılı Kanun ile Yap İşlet (Yİ), Yap İşlet Devret (YİD), İşletme Hakkı Devri (İHD) ve Otoprodüktör modelleri ile verilmiştir. Ancak bu modeller de olması gereken planlama sürecinden geçirilmemiştir. 17 yıl içerisinde yalnızca kurulu güçleri toplamı 980 MW ve ortalama üretimleri toplamı 3908 GWh/yıl olan 18 adet hidroelektrik santral projesi YİD modelinde, 29.80MW kurulu gücünde ortalama üretimi 50 GWh/yıl olan 1 adet proje İşletme Hakkı Devri modelinde işletmeye alınmıştır. 499.45 MW kurulu gücünde ve 1921 GWh/yıl ortalama üretime sahip 23 adet proje ise otoprodüktör statüsünde sözleşme imzalanmıştır. 1990 'lı yıllarda gerekli olan yatırım yapılamamıştır ve arz-talep dengemiz önemli dönemden geçmiştir. Taleplerin bir kısmı ithalatla karşılanmıştır. Dönemin sonlarına doğru aldatıcı veriler ile bazı çalışmalar yapılıp hidroelektrk projelerinin önemi azaltılıp doğal gaz ile çalışan santrallerin payı arttırılmıştır. Bu durum da kaçınılmaz son olan dışa bağımlı bir ülke olmamıza sebep olmuştur. 2000 yılı kış döneminde kısa süreli de olsa elektrik kısıntıları yaşanmıştır. Bunun sebepleri; doğalgaz teminindeki kaçınılmaz aksamalar, yüksek soğuk havalar sebebiyle doğalgaz çekişindeki ani artışlardır. Bu kötü durumları engellemek için aslında pik (yüksek) seviyede çalıştırılması gereken depolamalı hidroelektrik santralar baz (düşük) seviyede çalıştırılarak su seviyeleri minimum düzeye indirilmiş, düşünün azalmasıyla

santralarda daha az enerji üretilmiş ve bu durum da kamuoyuna hidrolektrik santrallerinin güvensiz ve yetersiz olduğu kanısını oluşturulmuştur. (Tutuş, 2006).

2.2.5 Serbest Piyasa Dönemi (2001 ve sonrası)

Bu zamana kadar uygulanan modeller başarılı olmamışlardır. Bunun sonucunda Dünya Bankasının girişimi ile birlikte ve AB mevzuatına paralel olarak bazı yapılanma çalışmaları başlatılmıştır. 3 Mart 2001 tarihinde 4628 sayılı Elektrik Piyasası Kanunu yürürlüğe girmiş ve 3 Eylül 2002 tarihinden itibaren yeni piyasa modeli uygulamaya konmuştur. Söz konusu Kanun'un temel amacı, elektriğin yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde tüketicilerin kullanımına sunulması için, rekabet ortamında özel hukuk hükümlerine göre faaliyet gösterebilecek, mali açıdan güçlü, istikrarlı ve şeffaf bir elektrik enerjisi piyasasının oluşturulması ve bu piyasada bağımsız bir düzenleme ve denetlemenin sağlanmasıdır (Tutuş, 2006).

2.3 Elektrik Üretim Sistemi ve Kurulu Güç

Özellikle 21. Yüz yılın başlarından itibaren artış gösteren elektrik talebini karşılamak amacıyla yeni üretim kaynakları ve yenilenebilir enerjiye yönelik pek çok alanda yatırımlar yapılmıştır. Türkiye enerji planlamasında dışa bağımlılığı minimuma indirmeyi temel hedef olarak belirlemiştir.

Elektrik enerjisinin en önemli özelliklerinden birisi depolanamıyor olmasıdır. Bu sebeple üretim-tüketim dengesinin kurulması oldukça önem taşımaktadır. Ne gerekenden fazla üretmek ne de gerekenden az üretmek yeterli olmayacaktır. Tüketim miktarına uygun üretim yapılması Elektrik sistemimizin sağlığı ve sürdürülebilirliği açısından büyük önem taşımaktadır. Türkiye elektrik sistemi hakkında bilgi sahibi olmak adına öncelikle bazı veriler konusunda bilgi sahibi olunması gerekmektedir (Göltaş ve İpek, t.y.).

Türkiye elektrik sistemindeki kurulu gücün kuruluşlara göre 2017-2018 yılları arasındaki değişimi Tablo 2.1'deki gibidir.

Tablo 2.1 Kurulu gücün kuruluşlara göre 2017-2018 yılları arasındaki değişimi

	2017 Yıl Sonu İtibariyle		2018 Yıl Sonu İtibariyle	
Kuruluş Türleri	Kurulu Güç (MW)	Santral Sayısı	Kurulu Güç (MW)	Santral Sayısı
Eüaş	19899,8	62	18488,9	55
İşletme Hakkı Devredilen Santraller	1820,9	76	3386,7	87
Yap İşlet Santralleri	6101,8	5	6101,8	5
Yap İşlet Devret Santralleri	1378,9	15	1358,8	12
Serbest Üretim Şirketleri	52353,3	1127	53862,2	1216
Lisanssız Santraller	3645,3	3736	5352,4	6048
Toplam	85200	5021	88550,8	7423

Tablo 2.1'e göre kurulu güç %3,9 artış göstermiştir. Santral sayısı ise %48'lik bir artış göstermiştir ancak bu kadar artış kurulu güce yansımamıştır. Bunun sebebi santral sayısındaki artışın lisanssız santrallerde yaşanması ve lisanssız santrallerin kapasitelerinin çok düşük olmasıdır. Yakıt cinslerine göre kurulu güç değişimi de Tablo 2.2'deki gibidir.

Tablo 2.2 Kurulu gücün yakıt cinsine göre 2017-2018 yılları arasındaki değişimi

	2017 Yıl Sonu İtibariyle		2018 Yıl Sonu İtibariyle	
Yakıt Cinsleri	Kurulu Güç (MW)	Santral Sayısı	Kurulu Güç (MW)	Santral Sayısı
Fuel Oil-Nafta Motorin	303,6	12	294	11
Yerli Kömür	9872,6	30	10203,5	31
İthal Kömür	8793,6	11	8793,9	11
Doğal Gaz+Lng	23063,7	243	22437,8	251
Yenilenebilir Atık	575,1	98	738,8	127
Çok Yakıtlılar Katı+Sıvı	682,9	22	697,1	22
Çok Yakıtlılar Sıvı+ D.Gaz	3433,6	47	3443,2	48
Jeotermal	1063,7	40	1282,5	48
Hidrolik Barajlı	19776	117	20536,1	118
Hidrolik Akarsu	7489,7	501	7747,7	524
Rüzgar	6482,2	161	6942,3	175
Güneş	18	3	81,7	9
Termik (Lisanssız)	201,1	67	300,5	104
Rüzgar (Lisanssız)	34	46	63,1	74
Hidrolik (Lisanssız)	7,4	10	7,6	11
Güneş (Lisanssız)	3402,8	3613	4981,2	5859
Toplam	85200	5021	88551	7423

Tablo 2.2'ye göre 31 Aralık 2018 itibariyle %25,3 kapasite ile Doğalgaz + Lng 1. Sırada, %23,2 kapasite ile Barajlı Hidrolik 2. Sıradadır.

2.4 Elektrik İletim Sistemi

Türkiye'de elektrik iletiminden sorumlu kuruluş TEİAŞ'tır. TEİAŞ, 2003 yılında Elektrik Piyasası Düzenleme Kurumu'ndan (EPDK) aldığı İletim Lisansı çerçevesinde yeni piyasa yapısına uygun olarak merkez birimleri ve yurt geneline yayılmış proje, tesis, kontrollük, işletme, bakım ve yük dağıtım üniteleriyle faaliyetlerini sürdürmektedir. TEİAŞ'ın ana faaliyet alanı bir elektrik tesisinin planlanması, yapımı, iletime alınana kadar gerekli tüm işlemleri yürütmektir. TEİAŞ'ın iletim şebekesi 729 trafo merkezi, 163.849 MVA trafo gücü, 66.453 km uzunluğunda enerji iletim hattı ve komşu ülkelerle olan 12 enterkoneksiyon hattından oluşmaktadır. 2018 yıl sonu itibariyle 88.511 MW santral kurulu gücü, 47.660 MW ani puantı, 295,5 milyar kWh yıllık elektrik enerjisi üretimine sahiptir.

Tablo 2.3 Türkiye enerji iletim hatları

	Enerji İletim Hatları (31 Aralık 2017)				
	400 kW	154 kW	220 kW	66 kW	Toplam
Enerji İletim Hattı	22506	43152	84,82	109,67	65852,49
Yer Altı Kablosu	73,31	342,6	-	-	415,91
Deniz Altı Kablosu	15,96	-	-	-	15,96
Toplam	22595,27	43494,6	84,82	109,67	66284

Tablo 2.4 TEİAŞ trafo merkezleri

TEİAŞ Trafo Merkezleri(31 Aralık 2017)			
Gerilim (kW)	Merkez Adedi	Trafo Adedi	Güç (MVA)
400	106	327	66378
220	1	2	400
154	613	1392	95972
66	7	29	431
Toplam	727	1750	163181

2.5 Elektrik Dağıtım Sistemi

Elekrik enerjisi üreten santraller hem güvenlik hem de maliyet amaçlı yerleşim yerlerinden uzağa inşa edilmiştir ve işletmelerini sürdürmektedir. Üretilen enerjinin yerleşim yerlerine iletilmesi ve dağıtılması gereklidir. İetimde kullanılan şebekelere iletim şebekesi, dağıtımda kullanılan şebekelere ise dağıtım şebekesi adı verilmektedir. Elektrik dağıtım ve iletim şebekeleri elektriğin kesintisiz ve güvenilir biçimde iletilmesi için gerekli olan koşullara uygun olmalıdır.

Elektrik şebekeleri kullanıldıkları gerilimlere göre aşağıdaki gibi sınıflandırılmaktadır.

Tablo 2.5 Elektrik şebeke gerilimleri

Alçak Gerilim	0-1 kW arası
Orta Gerilim	1 kW-35 kW arası
Yüksek Gerilim	35 kW-154 kW arası
Çok Yüksek Gerilim	154 kW ve üzeri

Yerleşim birimlerindeki tüm yapılar boyunca döşenen har parçalarının birbirine ilave edilmesiyle dağıtım şebekeleri meydana gelir. Elektrik şebekelerini kurarken ergonomik ve ekonomik olması temel kuraldır ve bu kuralı yerine getirebilmek için de değişik şebeke sistemleri geliştirilmiştir.

Dağıtım şekillerine göre en uygun olarak kullanılan şebeke sistemleri şunlardır (Elektrikport, 2013).

2.5.1 Dallı Şebekeler

Beslenmesi tek kaynaktan yapılır, dağıtım şekli ağaç dallarına benzediği için bu şekilde adlandırılır. Dağıtım yapılacak yerin ağırlık merkezlerine trafolar yerleştirişir. Bu trafonun etrafında iletim yapılacak olan dükkan, apartman vb yapılara önce kalın kollara sonra da ince kollara ayrılarak son tüketiciye ulaşır. Dallı şebekelerin maliyetleri ucuzdur ancak emniyet konusunda problemleri vardır. Bir arıza olduğunda çok sayıda abone enerjisiz kalacağından yaygın tercih edilmemektedir.

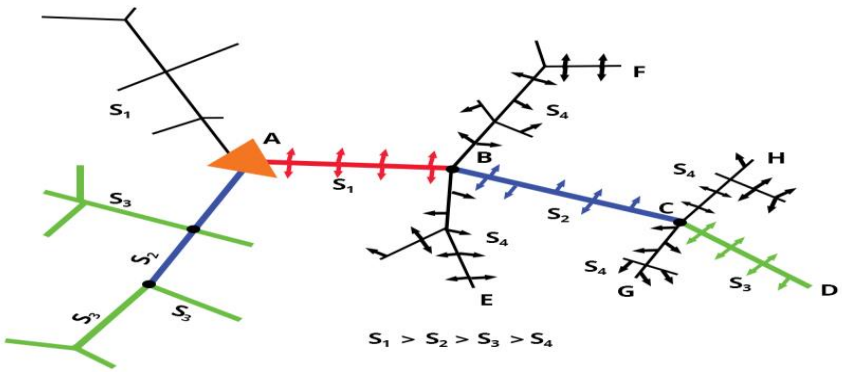

Şekil 2.1 Dallı şebeke sistemi

2.5.2 Ring Şebekeler

Bu şebeke tipinde besleme birden fazla trafo ile yapılır, trafolar birbirine parelel şekilde bağlanmıştır. Bu şebeke tipinde besleme işlemi birden fazla trafo ile yapılmaktadır. Arıza olması halinde sadece arıza olan kısım devre dışı kalır ve dallı şebekedeki gibi çok sayıda abone enerjisiz kalmaz. Ne yazıkki bu şebeke tipinde tesis maliyeti yüksektir.

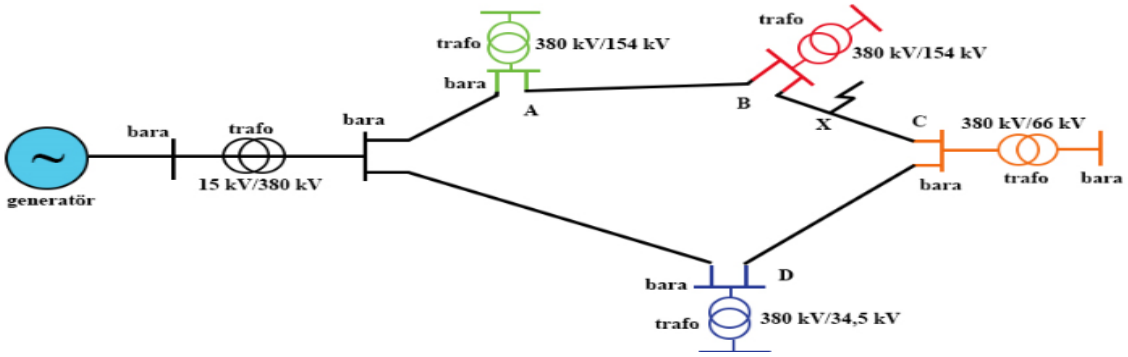

Şekil 2.2 Ring şebeke sistemi (Elektrikport, 2013)

2.5.3 Ağ Gözlü Şebekeler

Bu şebeke tipinde beslenme birden fazla trafo ile yapılır. Hatlar bir şebeke ile örülür. Herhangi bir arıza durumunda sadece arızalı kısım devre dışı kalır. Fakat bakım ve işletmeleri zordur ve kısa devre akımı etkisi büyüktür.

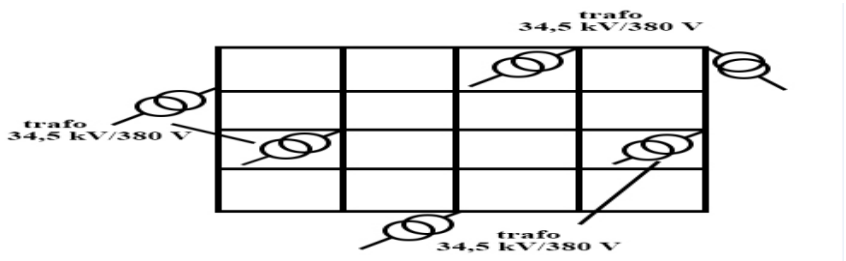

Şekil 2.3 Ağ gözlü şebekeler (Elektrikport, 2013)

2.5.4 Enterkonnekte Şebekeler

Ülkenin tamamının veya bir kısmının elektrik enerji gereksinimlerini karşılayabilecek bir biçimde tüketim ile üretim merkezleri arasındaki enerji alışverişini sağlayan enerji taşıma sistemine verilen isimdir. O bölgedeki bütün elektrik tüketim ve üretim araçları sisteme dahil edilmektedir. Birbirinden uzak olan elektrik üretim merkezleriyle tüketim noktaları arasındaki bağlantı bu şebeke sistemi ile sağlanmaktadır. Türkiye'de bir enterkonnekte şebeke sistemi vardır. Bu sistem içerisinde TEDAŞ'a, üretim şirketlerine ve otoprodüktörlere ait 350 elektrik santrali vardır. Bütün bu santraller enterkonnekte sistem ile birbirlerine bağlıdır.

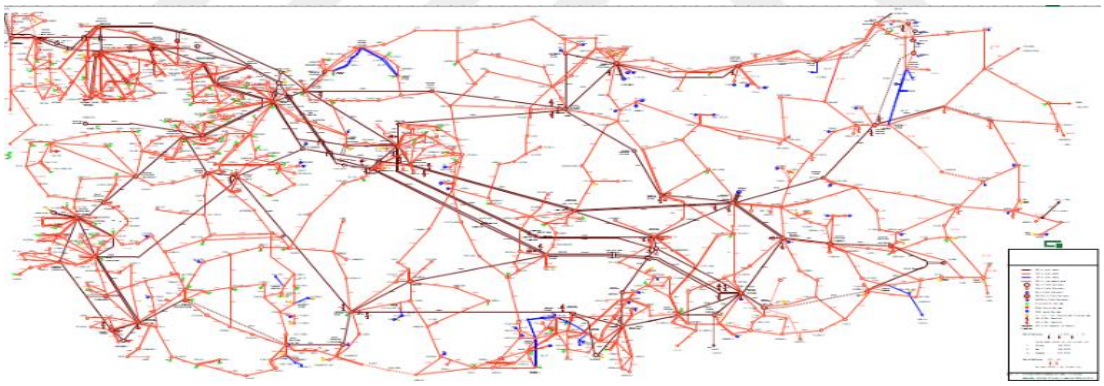

Şekil 2.4 Türkiye enterkonnekte sistemi ağ haritası (TEİAŞ)

Türkiye'de dağıtım hatlarının uzunluğu ise 812.400 km'dir. Türkiye'de Dağıtım sisteminin kapsamını düşünürsek tüketim ihtiyaçlarına göre şebekeler kurmak, bunları yönetmek, bakımlarını yapmak, şebeke-tüketici arasındaki bağlantıları yapmak, dağıtılan elektriğin devamlılığını sağlamak sorumluluklarını kapsamaktadır. Elektrik Enerjisi Sektörü Reformu ve Özelleştirme Strateji Belgesi ile Türkiye 21 dağıtım bölgesine bölünmüştür. Bu dağıtım bölgeleri aşağıdaki şekildedir:

Tablo 2.6 Türkiye'nin bölgelere göre dağıtım şirketleri (TEDAŞ)

Bölgelere Göre Dağıtım Şirketleri	
Şirket	**Görev İlleri**
1. Dicle Elektrik Dağıtım A.Ş.	Diyarbakır, Şanlıurfa, Mardin, Batman, Siirt, Şırnak
2. Vangölü Elektrik Dağıtım A.Ş	Bitlis, Hakkari, Muş, Van
3. Aras Elektrik A.Ş.	Erzurum, Ağrı, Ardahan, Bayburt, Erzincan, Iğdır,Kars
4. Çoruh Elektrik Dağıtım A.Ş.	Trabzon, Artvin, Giresun, Gümüşhane, Rize
5. Fırat Elektrik Dağıtım A.Ş.	Elazığ, Bingöl, Malatya, Tunceli
6. Çamlıbel Elektrik Dağıtım A.Ş.	Sivas, Tokat, Yozgat
7. Toroslar Elektrik Dağıtım A.Ş.	Adana, Gaziantep, Hatay, Mersin, Osmaniye, Kilis
8. Meram Elektrik Dağıtım A.Ş.	Kırşehir, Nevşehir, Niğde, Aksaray, Konya, Karaman.
9. Başkent Elektrik Dağıtım A.Ş.	Ankara, Kırıkkale, Zonguldak, Bartın, Karabük, Çankırı, Kastamonu.
10. Akdeniz Elektrik A.Ş.	Antalya, Burdur, Isparta İl sınırları
11. Gediz Elektrik Dağıtım A.Ş.	İzmir, Manisa
12. Uludağ Elektrik Dağıtım A.Ş.	Balıkesir, Bursa, Çanakkale, Yalova
13. Trakya Elektrik Dağıtım A.Ş.	Edirne, Kırklareli, Tekirdağ.
14. İstanbul Anadolu Yakası Elektrik Dağıtım A.Ş.	İstanbul ili Anadolu Yakası.
15. Sakarya Elektrik Dağıtım A.Ş.	Sakarya, Bolu, Düzce, Kocaeli
16. Osmangazi Elektrik Dağıtım A.Ş.	Eskişehir, Afyon, Bilecik, Kütahya, Uşak
17. Boğaziçi Elektrik Dağıtım A.Ş	İstanbul ili Rumeli Yakası.
18. Kayseri ve Civarı Elektrik T.A.Ş.	Kayseri
19. Aydem Elektrik Dağıtım A.Ş.	Denizli, Aydın, Muğla
20. Göksu Elektrik Dağıtım A.Ş.	K.Maraş, Adıyaman
21. Yeşilırmak Elektrik Dağıtım A.Ş.	Samsun, Amasya, Çorum, Ordu, Sinop

2.6 Elektrik Tüketim Sistemi

Kişi başına düşen elektrik tüketimi miktarı ülkelerin gelişmişlik düzeylerini gösteren temel yapı taşlarından birisidir. Türkiyede'de gelişmişlik düzeyinin artışıyla birlikte kişi başına düşen elektrik tüketimi miktarında yıldan yıla artış gözlenmiştir. Toplumun refah seviyesini de elektrik kullanımı ile özleştirebiliriz. Elektrik kullanımının artışı toplumun daha rahat daha refah bir düzeyde yaşayacağını gösterecektir. Türkiye'nin 1961-2017 yılları arasındaki kişi başına düşen tüketim miktarı değişimi aşağıdaki grafikteki gibidir;

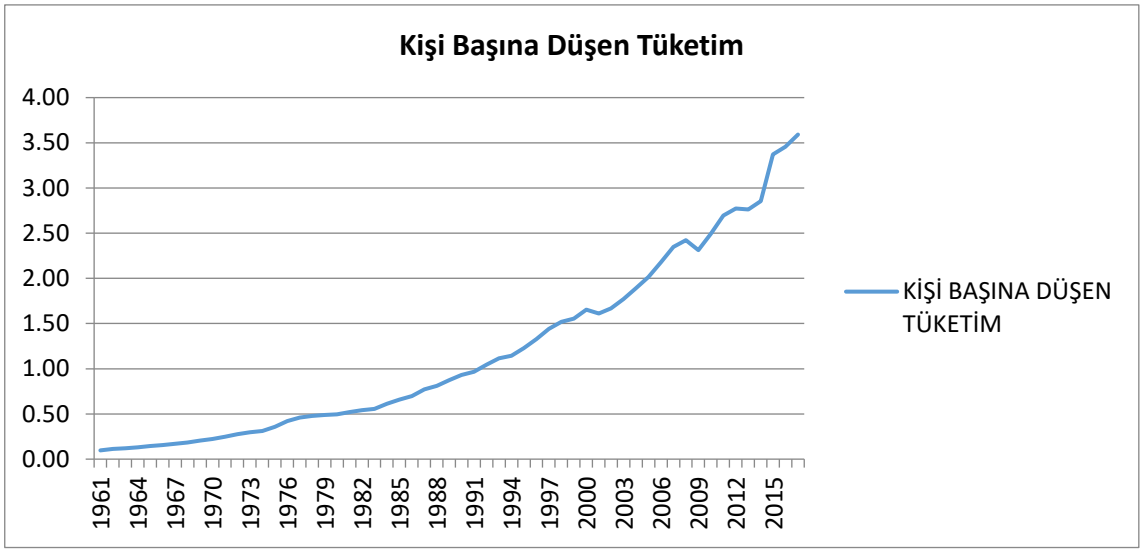

Şekil 2.5 Türkiye'nin yıllar itibariyle kişi başına düşen tüketim değişimi

Buradan da anlaşılacağı üzere 2001 ve 2009 yılları krizlerinde kişi başına düşen tüketim miktarlarında azalma meydana gelmiştir. Bu durum da ülkenin refah düzeyi ile tüketim seviyesinin nasıl birbiriyle çok bağlantılı olduğunu gözler önüne sermektedir.

Tüketimin en yoğun olduğu dönem 'puant' olarak adlandırılmaktadır. Türkiye'de 2018 yılında gerçekleşen verileri Yük Tevzi Bilgi Sistemi'nden (YTBS) aldığımızda aşağıdaki Tabloye ulaşmaktayız. Tablo 2.7'ye göre en yüksek tüketim 1 Ağustos tarihinde, en düşük tüketim ise 16 Haziran tarihinde gerçekleşmiştir.

Tablo 2.7 2018 yılı Türkiye ulusal puant değerleri

Ulusal Puant Değerleri	Tarihi	Değer (MW/MWh)
En Yüksek Ani Puant	2018-08-01	46.160
En Düşük Ani Puant	2018-06-16	18.212
En Yüksek Saatlik Puant	2018-08-03	45.996
En Düşük Saatlik Puant	2018-06-16	18.497
Maksimum Türkiye Üretimi	2018-08-02	975.198
Minimum Türkiye Üretimi	2018-06-16	552.679
Maksimum Türkiye Tüketimi	2018-08-02	979.215
Minimum Türkiye Tüketimi	2018-06-16	543.908

2.7 Elektrik Piyasası

Elektrik enerjisi depolanamadığından ötürü üretim ile tüketimin sürekli dengede olması gerekmektedir. Enerjinin kesintisiz olarak sunulabilmesi için talebin karşılanıyor olması, yeterli arzın bulunması gerekmektedir. En istenilen senaryo tüketilecek kadar enerji üretmek, fazla üretimin gerçekleşmesine engel olmaktır. Bu beklenilen düzenin sağlanabilmesi için Elektrik Piyasasının tarihsel gelişimini ele alınırsa;

*2001 yılında 4628 sayılı Elektrik Piyasası Kanunu yayımlandı.

*2004 yılında Geçici Dengeleme ve Uzlaştırma Yönetmeliği yayımlandı.

*2006 yılında Dengeleme Güç Piyasası mekanizması 1. Aşaması devreye girdi. Dengesizliklerin gece-gündüz-puant periyotlarında uzlaştırmalarına başlanıldı.

*2011 yılında Gün Öncesi Piyasası mekanizması, teminat ve avans ödeme mekanizması devreye girdi. Yek destekleme mekanizması başladı.

*2013 yılında 6446 sayılı Elektrik Piyasası kanunu ile Enerji Piyasaları İşletme A.Ş.'nin (EPİAŞ) kurulması hükme bağlanmıştır.

*12 Mart 2015 yılında EPİAŞ kurulmuştur.

*1 Temmuz 2015 yılında Gün İçi Piyasası açılmıştır.

*1 Eylül 2015 yılında EPİAŞ piyası işletim lisansı almıştır.

Elektrik piyasasının serbestleşmesine ait dönüşüm özellikle 2000'li yılların başından itibaren gerçekleşmiştir. Gelinen son aşamada EPİAŞ 1 Eylül 2015 tarihinde çalışmalarına başlamıştır. EPİAŞ %30 BİST, %30 TEİAŞ %40 özel sektör katılımına açılmıştır.

Günümüz elektrik piyasası birbirini tamamlayan fakat farklı özelliklerde yapıların birleşmesi ile işlemektedir. Bu yapılar aşağıdaki şekildedir.



Şekil 2.6 Elektrik enerjisi piyasa yapısı

2.7.1 İkili Anlaşmalar

İkili anlaşmalar fiyat/miktar risklerine karşı koruma ve uzun süreli arz güvenliğini sağlamak amacıyla esas olarak yapılmaktadır. Bu piyasadaki tahminler uzun süreli tahminler üzerinden gerçekleşmektedir. Fiyat dalgalanması daha azdır. Taraflar arasındaki yatırım stratejileri ön plandadır. Pozisyonlar bu stratejilere göre alınır. Türkiye elektrik piyasalarında 2018 yılında gerçekleşen işlemlerin miktarları ve genel toplamdaki dağılımları aşağıdaki gibidir. Buna göre Gün Öncesi Piyasasında (GÖP) %53 oranda işlem gerçekleşirken bunu %45 ile ikili anlaşmalar izlemektedir.

Tablo 2.8 2018 yılı Türkiye elektrik piyasa hacimleri

	Net İA Miktarı	GÖP Takas Miktarı	DGP Talimat Miktarı
2018 Yılı	124.673.966	149.394.716	5.869.013
Pay	45%	53%	2%

2.7.2 Gün Öncesi Piyasası

Bu piyasada elektrik teslimat gününden bir gün önce işlem görmektedir. Piyasa EPİAŞ tarafından işletilir ve organize edilir. Gün Öncesi Piyasası için Aralık 2011-Haziran 2016 yılları arasında Fransa kökenli bir şirketin ürünü kullanıldı. Ancak EPİAŞ ürünün işleyişine hakim olamıyordu, kodlar gizliydi, sorunlarda müdahale çok yavaştı, geliştirme istekleri çok maliyetliydi. Günlük bazda açıklanan fiyat bazen akıl almayacak derecede farklı çıkıyordu. Kimse de bunun sebebini anlayamıyor, piyasa bu fiyat üzerinden işliyordu.

Bu sebeplerle yerli yazılım çalışmaları başlatılmıştır. En nihayetinde GÖP'te Türk GÖP kullanılmaya başlanmıştır. Böylece kodlara müdahale kolaylaşmış, bakım masrafları azalmış, olası sorunlara karşı müdahale süresi ciddi miktarda kısalmıştır. GÖP ile;

*Piyasa katılımcıları tüketim veya üretim ihtiyaçlarını gün öncesinde dengeleme şansına sahip olur.

*Elektrik Enerjisinin kalbi olan PTF (Piyasa Takas Fiyatı) belirlenir.

*Sistem işletmecisi TEİAŞ Milli Yük Tevzi Merkezi (MYTM) gün öncesinde piyasası dengelemiş, arz-talep güvenliğini daha emin bir şekilde sağlamış olur.

2.7.3 Gün İçi Piyasası

1 Temmuz 2015 tarihi itibariyle katılıma açılmıştır. Kullanılması zorunlu değildir, ancak enerji dengelemesi açısından oldukça faydalı bir piyasadır. Gün öncesinde sağlanan uzlaştırma gün içerisinde sapmalar gösterebilir. Örneğin gün öncesinde 10 MW üreteceğini söyleyen bir santral aynı güne gelindiğinde arıza yapıp üretmeyebilir. Piyasanın da üretim yapmazsa kendisine yaptırımı olacağından eksik kalan enerjisini Gün İçi Piyasasında (GİP) işlem yaparak satın alabilir. GİP gerçek zamandan bir saat öncesine kadar tekliflerin verilebileceği, dengeleme yapmak açısından piyasa katılımcısı dostu bir piyasadır. İşlem hacmi oldukça düşüktür, ancak zamanla artması beklenmektedir.

2.7.4 Dengeleme Güç Piyasası

Önce TEİAŞ sorumluluğunda işletilmeye başlanmış, sonra işletilmesi EPİAŞ'a devredilmiş, şuanda ise tamamen TEİAŞ'ın sorumluluğuna alınan piyasadır.

Bu piyasada da teklifler gün öncesinde verilir. Dengeleme Güç Piyasasında SMF (Sistem Marjinal Fiyatı) belirlenmektedir. Gün öncesinde bir piyasa referans fiyatı olan PTF belirlenmişti. Ancak bu fiyat nihai fiyat değildir. Piyasadaki o günlük işleyişe göre gerçek dengeleme sonucunda SMF belirlenir. İstenilen PTF-SMF fiyatlarının birbirine yakın olmasıdır. Eğer bu fiyatların değerlerinde yüksek farklar var ise tahmin edilen ile gerçekleşen durumlar arasında farklılık var demektir. Bu durumlarda piyasası ve elektrik arz-talep dengesini riske atacak sebeplerdendir.

Dengeleme birimi olan üretim santrallerinin katılabileceği piyasada yük alma ve yük atma teklifleri verilmektedir. Arz-talep güvenliğinin sağlanması amacıyla Piyasa İşletmecisi TEİAŞ anlık durumlara göre yük aldırıp yük attırabilir. Bu durum YTM (Yük Tevzi Merkezleri) ile kontrol altında tutulmaktadır. Türkiyedeki 10 adet Yük Tevzi İşletme Müdürlükleri aşağıdaki gibidir.

Tablo 2.9 Türkiye yük tevzi işletme müdürlükleri

Yük Tevzi İşletme Müdürlükleri
Milli Yük Tevzi İşletme Müdürlüğü (Çankaya/Ankara)
Orta Anadol Yük Tevzi İşletme Müdürlüğü (Gölbaşı/Ankara)
Kuzeybatı Anadolu Yük Tevzi İşletme Müdürlüğü (Adapazarı)
Batı Anadolu Yük Tevzi İşletme Müdürlüğü (Işıkkent/İzmir)
Orta Karadeniz Yük Tevzi İşletme Müdürlüğü (Samsun)
Güneydoğu Anadolu Yük Tevzi İşletme Müdürlüğü (Elazığ)
Trakya Yük Tevzi İşletme Müdürlüğü (İstanbul)
Doğu Anadolu Yük Tevzi İşletme Müdürlüğü (Erzurum)
Doğu Akdeniz Yük Tevzi İşletme Müdürlüğü (Adana)
Batı Akdeniz Yük Tevzi İşletme Müdürlüğü (Kepez/Antalya)

3
Yapay Sinir Ağları

3.1 Yapay Sinir Ağlarına Giriş

Uzun yıllar boyunca insan beyninin üstün olan özellikleri bilim adamları tarafından araştırma konusu olmuştur. Bu araştırmalar öncelikli olarak nöronların modellenmesi ve bilgisayar sistemleri üzerinde uygulanmasıyla başlamış, daha sonra bilişim sistemlerinin daha da gelişmesiyle pek çok alanda kullanılabilir hale gelmiştir. Bilim adamları çalışmalarında insan beyninin nörofiziksel özelliklerinden faydalanarak matematiksel modeli çıkarmaya çalışmışlardır. İnsan beyninin tüm davranışlarını matematiksel olarak modelleyebilmek için fiziksel bileşenlerini doğru bir şekilde modellemek gerekmektedir. Bu sebeple çeşitli ağ hücreleri ve yapay hücreler geliştirilmiştir. Bu şekilde Yapay Sinir Ağları denilen ve bilgisayarların hesaplama yöntemlerinden farklı bir bilim dalı ortaya çıkmıştır (Öztemel, 2003).

Genel olarak YSA beynin belirli faaliyetlerini yapabilmek adına tasarlanan sistem olarak tanımlanabilir. YSA yapay sinir hücrelerinin birbirlerine çeşitli biçimlerde bağlanmasından oluşur ve katmanlar halinde düzenlenir. Yapay sinir ağları birbirlerine birbirlerine hiyerarşik düzende bağlıdır ve paralel olarak çalışabilen yapay hücrelerden meydana gelmektedirler.

Teknik olarak bir sinir ağının en öncelikli görevi kendisine eğitilen girdi değişkenine karşılık bir çıktı üretmesidir. Bunu gerçekleştirebilmesi için geçmişe dair örnekler verilerek genelleme yapabileceği bir yeteneğe ağ kavuşturulur. Bu genelleme özelliğini kazandıktan sonra geçmişte yaşadığı olaylarla gelecekte yaşayacağı olaylar tahmin edebilecektir.

3.2 Yapay Sinir Ağlarının Genel Özellikleri

Yapay bir sinir hücresi matematiksel bir sinir hücresini ortaya koyan algoritma veya fiziksel araç olarak kullanılmaktadır. Farklı şartlar olduğunda çok hızlı bir şekilde karar verebilme gibi yeteneklerin karmaşık problemler halinde çözülmesiyle amaçlanmaktadır.

Yapay sinir ağlarının tüm modeller için geçerli olan karakteristik özellikleri aşağıdaki gibi sıralanmaktadır (Öztemel, 2003).

-Yapay sinir ağları makina öğrenmesi gerçekleştirirler.

Yapay sinir ağları olaylar karşısında öğrenme gerçekleştirerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

-Proglamanın çalışma stili bilinen diğer geleneksel öğrenme programlarına benzememektedir.

Yapay zeka veya geleneksel bilgisayar programlama tekniklerinin uyguladığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemine sahiptir.

-Bilginin saklanılabilirliği diğer programlama tekniklerinde olduğu gibi veriler bir programın içerisinde gömülü değildir. Bilgi ağın bağlantıları ile ölçülmekte ve bağlantıları ile saklanmaktadır.

-Geçmiş örnekleri kullanarak öğrenirler.

Yapay sinir ağları adaptif öğrenme yolu ile geçmiş olayları kullanarak gelecekteki olaylar hakkında genelleme yapabilme yeteneğine sahip olurlar. Buradan Yapay Sinir Ağları için örnek sayısının, miktarının ve niteliğinin ne kadar önemli olduğunu anlayabiliriz.

-Yapay sinir ağlarının öncelikle çok iyi bir şekilde eğitilmesi ve performanslarının test edilmesi gerekmektedir.

Tek bir ağa geçmişteki olaylar çok iyi bir şekilde öğretilerek ağın kendi mekanizmasının çalıştırılması sağlanır. Ağ da bu olaylardan çıkarımlar yaparak geleceği tahminleyebilir.

-Daha önce görmediği örnekler hakkında çıkarım yapabilir.

Ağlar kendisine gösterilen örneklerle eğitilip daha önce hiç görmediği olaylar hakkında çıkarımlar yapabilmektedir.

-Algılamaya yönelik bilgileri işlemede kullanılırlar.

-Şekil ilişkilendirme sınıflama yapabilmektedirler.

Ağların bir diğer özelliği ise sınıflandırma yapmaktır. Gelen örnekleri sınıflandırma yoluyla ayırarak daha sonra gelecek örneğin hangi sınıfa ait olacağını tahmin ederler.

-Tamamlama gerçekleştirebilirler.

Ağlar kendilerine verilen eksik şekil veya örüntüntü olduğunda bu eksiğin bulunması istenirse çok etkin çözümler üretebilmektedirler.

-Kendi kendini organize etme ve yönetebilme teknikleri vardır.

Örnekler ile olaylara adapte olurlar.

-Yapay sinir ağları eksik bilgiler ile çalışabilmektedir.

Geleneksel yöntemler eksik bilgi olduğu zaman çalışmazlar, sonuç üretmezler. Yapay Sinir Ağları ise eksik bilgi olduğunda da mevcut bilgileri en iyi şekilde değerlendirerek sonuç verirler. Hatta bu sonucu performansları düşerek de vermeyebilirler. Eğer eksik olan bilginin modelin eğitimi konusunda etkisi az ise sonucu etkilememe durumları vardır.

-Hata töleransları vardır.

Ağlar eksik bilgilerle çalışa çalışa hatalara karşı töleransları gelişmiştir. Ağın bazı hücreleri bozulursa veya çalışamaz duruma gelirse dahi ağ çalışmaya devam edebilir.

-Dereceli bozulma gösterirler.

Yapay sinir ağları eksik bilgiler ile çalışıp hata töleransları olmasından ötürü dereceli bozulma gösterirler. Eksik veya yanlış olan bilgi bozulduğunda ağ da yavaş yavaş ve çok narin bir şekilde bozulmaktadır.

-Sadece nümerik bilgiler ile çalışabilirler.

3.3 Yapay Sinir Ağlarının Dezavantajları

Yapay Sinir Ağlarının bazı dezavantajları da mevcuttur. Bunlar aşağıdakiler gibi sıralanmaktadır (Öztemel, 2003).

- Donanım bazlı çalışmaları önemli bir sorun olarak değerlendirilebilir. Yapay sinir ağlarının gerçek zamanlı veri işleyebilmeleri paralel çalışan işlemcilerin varlığına bağlıdır. Günümüzdeki çoğu makine tek veri işleyip seri bir şekilde çalışmaktadır. Seri makinelerde paralel işlemler yapmaya çalışmak zorlayıcı ve zaman kaybı oluşturucudur
- Problemin çözümü için oluşturulacak sinir ağının belirli bir kuralı yoktur. En uygun Yapay Sinir ağını bulurken belirli kurallar ile bunu gerçekleştiremeyiz. Tek yol deneme yanılma yolu ile en başarılı performans gösteren ağı bulmaktır. Bulunduğu düşünülen çözümün en iyi çözüm olduğunun da hiçbir zaman garantisi yoktur. Bu sebepledir ki yapay sinir ağları kabul edilebilir çözümler üretir fakat en iyi çözümü üretmeyi garanti etmez.
- Ağlarda belirlenmesi gereken bazı parametrelerin (nöron sayısı, katman sayısı vb.) belirli kurallara bağlı olmaması da önemli sorunlardandır. Bu da tamamen deneme yanılma yöntemiyle uygulayıcının tecrübesine bağlı olarak belirlenir. Her problemin çözümünde iyi sonuç verecek parametre değerleri farklıdır. Kurala bağlı olmadan parametre seçiminde de hepsi teker teker denenmelidir.
- Ağa öğretilecek problemin nümerik değerlere sahip olma koşulu da kullanıcıyı zorlayan diğer dezavantajdır. Her veriyi nümerik değerlere çevirmek kolay olmayabilir, uzmanlık gerektirebilir. Problemin nümerik çözümü olsa dahi bunu ağa doğru bir biçimde göstermek gereklidir. Aksi halde ağın performansını olumsuz yönde etkileyebilir.
- Ağın eğitiminin ne zaman sonlandırılacağı belirli kurala bağlı değildir. Bu durum da kullanıcının ne zaman ağın eğitimini bitireceği konusunda kararsızlıklar yaşamasına sebep olur. Ağın performans, hata değerlerinin belirli seviyede olduğunu görünce ağın eğitimini bitirmeyi doğru bulabilir.

Fakat bu optimal çözümün bu çözüm olduğu garantisini vermez. Bununla ilgili araştırmalar yapılması gerekmektedir ve kesinlikle çözülmesi gereken bir dezavantajdır.

- Ağın davranışlarının açıklanamaması da bir diğer önemli sorundur. Ağ bir çözüm ürettiğinde bunun neden ve nasıl olduğunu açıklamaz, bu da ağın ürettiği değerlere olan güveni azaltmaktadır.

3.4 Geleneksel Algoritmalar ile Yapay Sinir Ağlarının Karşılaştırılması

Tablo 3.1 Geleneksel algoritmalar ile yapay sinir ağlarının karşılaştırılması

Geleneksel Algoritmalar	Yapay Sinir Ağları
Hesaplama merkezi, eş zamanlı ve ardışıklıdır.	Hesaplama toplu, eş zamansız ve öğrenmeden sonra paraleldir.
Bellek paketlenmiş ve hazır bilgi depolanmıştır.	Bellek ayrılmış ve ağa yayılmıştır.
Hata töleransı yoktur.	Hata töleransı vardır.
Hızlıdır.	Yavaş ve donanıma bağlıdır.
Bilgiler ve sonuçlar kesindir.	Deneme yanılma yöntemine dayanır.

3.5 Yapay Sinir Ağlarının Kullanıldığı Alanlar

Yapay sinir ağları günümüzde geliştirilmiş olan en güncel ve mükemmel örüntü sınıflandırıcı olarak bilinmektedir. Özellikle çok sayıda veriyi işleme alma durumlarında Yapay Sinir Ağları çok fazla tercih edilmektedir. Yapay Sinir Ağları gürültülü, karmaşık, kesin olmayan, hatalı veya eksik verilerin olduğu durumlarda yaygın olarak kullanılmaktadır. Genellikle aşağıdaki fonksiyonları gerçekleştirirler (Şen, 2004).

Uzay: Uçak simülasyonları, otomatik pilot uygulamaları vs

Otomotiv: Otomatik yol izleme, rehber, sürüş analizi vs

Bankacılık: Müşteri analizi, kredi kartı uygulamalarının gelişmesi vs

Savunma: Radar, sinyal işleme, hedef seçme vs

Elektronik: Çip bozulma analizi, lineer olmayan modelleme vs

Eğlence: Animasyonlar, pazarlama öngörüsü vs

Finans: Pazar performans analizi, bütçe belirleme, hedef belirleme vs

Sigortacılık: Ürün Optimizasyonu vs

Üretim: Kalite kontrol, iş planı hazırlanması, ürün dizaynı vs

Sağlık: Göğüs kanseri erken teşhisi, ilaç etkileri analizi, kalp krizi erken teşhisi, manyetik rezonans.

Petro Kimya: Arama ve verim analizi vs

Robotik: Görsel sistemler, uzaktan okumalı sistemler, rota belirleme vs

Dil: Sözcük tanıma, dil tercüme vs

Telekomünikasyon: Görüntü ve data karşılaştırma, ses ve görüntü işleme, trafik yoğunluğunu kontrol etme vs

Güvenlik: Parmak izi tanıma, retina tanıma, yüz eşleştirme vs

Yukarıdaki örnekler Yapay Sinir Ağlarının çözebileceği problem alanlarından sadece bazılarıdır. Bu örnekleri arttırmak mümkündür. Görüldüğü gibi hayatımızın hemen her alanında Yapay Sinir Ağlarından faydalanabiliriz.

3.6 Yapılarına Göre Yapay Sinir Ağları

Yapay Sinir Ağları nöronların birbirlerine bağlanış biçimine göre üçe ayrılmaktadır. Bunlar izleyen alt başlıklarda verilmiştir.

3.6.1 Tek Katmanlı İleri Beslemeli Ağlar

Öncelikle ağa girdi değerleri ve çıktı değerleri verilir. Eğitim, ağ çıktıları üretmeye başlayana kadar devam eder. Ağın ağırlıkları her iterasyonda değiştirilir çünkü çıktı değerlerine bu şekilde ulaşılmaktadır. Ağın eğitimi çıktı değerlerine ulaşıldığında

tamamlanır. Bu Yapay Sinir Ağı çeşidi yalnızca doğrusal problemlerin çözümünde kullanılmaktadır (Gurney, 1996).

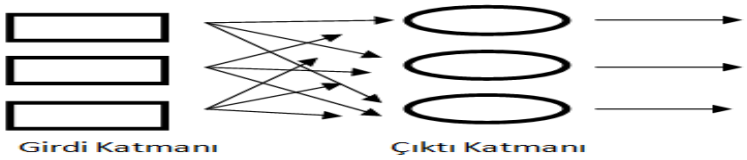

Şekil 3.1 Tek katmanlı ileri beslemeli yapay sinir ağ yapısı

3.6.2 Çok Katmanlı İleri Beslemeli Ağlar

Bir önceki paragrafta bahsedildiği gibi tek katmanlı ağlar yalnızca doğrusal problemlerin çözümünde kullanılır. Ancak gerçek hayatta karşılaşabileceğimiz problemlerin çoğu doğrusal olmayabilir. Bu durumda tek katmanlı ağlar bizi çözüme götürmeyecektir. 1969 yılında Tek Katmanlı Yapay Sinir Ağlarının yetersiz olduğu bulunmuştur. Bunun üzerine YSA'ya olan ilgi azalmış hatta ve hatta durma noktasına gelmiştir. Bu durgunluk Çok Katmanlı Yapay Sinir Ağlarının bulunmasına kadar devam etmiştir.

Nöronlar arasındaki bilgi Çok Katmanlı İleri Beslemeli Ağlarda, girişten çıkışa doğru tek yönlü düzenli katmanlar halindedir (Uğur ve Kınacı, 2006). Bir katman yalnızca kendinden sonra gelen katmana bağlanmıştır ve bir nöronun çıktısı yalnızca kendinden sonra gelecek olan nöron katmanına girdi olabilir. Eş katmandaki başka bir nörona bağlantı yoktur (Haykin, 1999). Bu ağlara örnek olarak çok katmanlı algılayıcılar ve sayısallaştırılmış öğrenmen vektörü verilebilir (Saygılı, 2008). Girdi katmanı, gizli katman ve çıktı katmanında sinir hücreleri işlem görür.

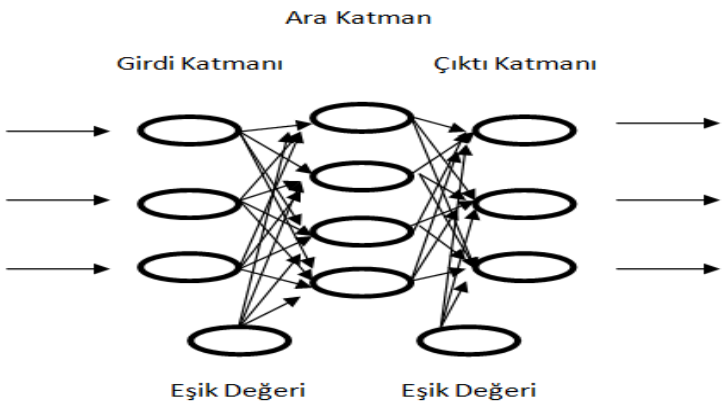

Şekil 3.2 Çok katmanlı ileri beslemeli yapay sinir ağ yapısı

Çok katmanlı ağlar doğrusal olmayan problemlere daha uygun olduğu için daha çok tercih edilmektedir. En büyük sorun ise işlemlerin uzun süre alabilmesidir.

3.6.3 Geri Beslemeli Ağlar

Geri beslemeli ağlarda hafızaya sahip nöronlar mevcuttur ve katmanlar arasında sinir hücreleri kendileri arasında bağlantılıdır (Ülker ve Civalek, 2002). Geri beslemeli ağlar yalnızca kendinden sonraki katmana bilgi vermezler. Bir nöron kendi katmanındaki bir nörona veya kendinden önceki katmandaki nörona girdi olarak bağlanabilir. Dinamik yapı göstermek Geri beslemeli ağların özelliklerindendir. Geri besleme, hem katmandaki nöronlar arasında olabilir hem de diğer katmanlardaki nöronlar arasında olabilir. Geri beslemenin kuruluş biçimine göre farklı mimaride ağlar oluşur (Rao ve Srinivas, 2003). Geri besleme sayesinde ağ, meydana gelen her tür hatayı belirleyip geriye dönük hata düzeltmesi yapabilir ve aynı hataları kolayca önleyebilir. Ağdaki ağırlıkların farklılaşmasında üç durum olabilir (Haykin, 1999). Bu durumlar; gizli katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi, gizli katmanlar arasındaki ağırlıkların değiştirilmesi veya girdi katmanı ile gizli katmanın arasındaki ağırlıkların değiştirilmesidir. Geri besleme aşamasında gizli katmanlardaki veya çıkış katmanındaki aktivasyon değerlerini daha sonraki iterasyona girdi olarak taşımakla görevlendirilmiş olunan geciktirme elemanı bulunur. Geri beslemeli Yapay Sinir Ağlar oldukça kompleks bir çalışma düzenine sahiptir. Yine de ön tahmin uygulamalarında dinamik hafızaları sayesinde başarılı sonuçlar verir (Saygılı, 2008).

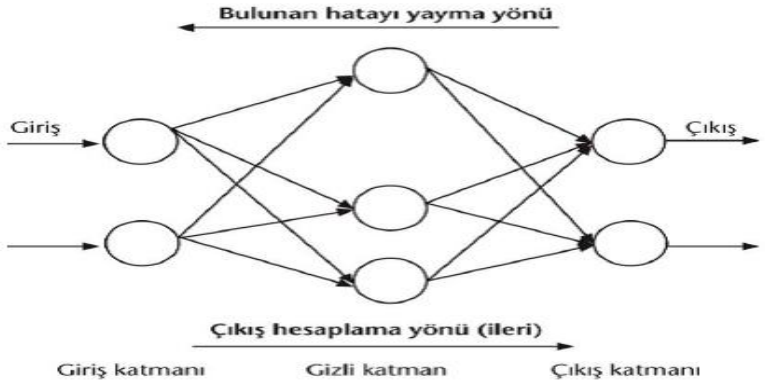

Şekil 3.3 Geri beslemeli yapay sinir ağları (Kabalcı, 2014).

3.7 Yapay Sinir Ağlarında Öğrenme Kuralları

3.7.1 Hata Düzeltme Öğrenimi (Error-Correction Learning)

Bu yöntem öğrenmeli öğrenme yöntemi olarak kullanılır ve sisten çıktısını gerçek çıktı ile karşılaştırarak hatayı eğitime yönlendirmek için kullanılır (Belciug ve Gorunescu, 2014).

3.7.2 Bellek Tabanlı Öğrenme (Memory-Based Learning)

Doğal dil işleme sınıflandırma problemlerinde öğrenme elde edilmesi için önerilen bir yöntemdir (Daelemans vd., 2003). Bellek tabanlı öğrenmede geçmiş deneyimlerin tamamı giriş-çıkış örneklerinin hafızasında açıkça saklanır (Ahamed ve Akthar, 2016).

3.7.3 Hebbian Öğrenme

Nöropsikoloji alanında çalışmalar yapan Kanadalı bilim adamı Donald Holding Hebb tarafından geliştirilmiştir. The Organization of Behavior en çok bilinen çalışması olmuştur. Nöropsikoloji ve sinir ağlarının babası olarak Hebb bilinir.

3.7.4 Rekabetçi Öğrenme (Competitive Learning)

Yapay Sinir Ağlarında denetlenmemiş öğrenmenin bir farklı çeşididir ve her bir düğümde girdi verileri cevap vermek için yarışırlar, bu yarışta her defasında yalnızca bir çıktı nöronu aktiftir (Rumelhart ve Zipser, 1985). Girdi değerlerini en iyi temsil edecek olan nöron sinir hücreleri arasında belirlenir. Rekabetçi öğrenme, Hebbian öğrenmenin bir çeşididir ağdaki her düğümün başarılı olmasını arttırarak çalışır (Hinton vd., 2006).

3.7.5. Boltzman Learning

Boltzmann makineleri, ikili birimlerden (“açık” için +1 ve “kapalı” için -1) oluşur ve simetrik tekrar eden ağlardır. Bir stokastik öğrenme kuralı olan Boltzman öğrenme, aynı zamanda hata düzeltme öğrenmesine benzer. Öğretmenli eğitim esnasında kullanılır (Jain vd., 1996).

3.7.6. Hopfield Öğrenme Kuralı

Bu kural Hebb kuralının kuralları ile benzerlik gösterir ancak tek farklı bağlantı ağırlıklarının yalnızca işaretlerinin değil büyüklüklerinin de değiştirilmesidir. Öğrenme oranı çoğunlukla 0 ile 1 arasında değer alır, sabit bir değerdir ve genellikle de 0.2 ile 0.4 arasında seçilen bir değer olmaktadır (Durak, 2012).

3.7.7. Delta Kuralı (Widrow ve Adaline)

Bu kural Hebb kuralına benzemektedir. Ağdaki bağlantı ağırlıkları sürekli olarak değiştirilir. Böyle ağın çalıştırılması sonucunda elde edilmesi beklenen değer ile ağ çalıştırıldıktan sonra elde edilen çıktı değeri arasındaki farkın azaltılması amaçlanır (Yetkin, 2015).

3.7.8. Kohonen Kuralı

Sinir hücreleri en büyük çıktıyı vermek için kendileri arasında yarışır. Yarışta kural, bir hücre için en büyük çıktıyı elde etmektir. Aynı zamanda kendi bağlantı ağırlığının değiştirilmesi yarışını kazanmaktır (Taşova, 2011).

3.8 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

Yapay Sinir Ağları öğrenme algoritmaları biçimlerine göre üçe ayrılmaktadırlar. Bunlar;

3.8.1 Danışmanlı Öğrenme: Bu öğrenme biçiminde ağa verilen girdi değerlerinin yanında çıktı değerleri de verilir. Ağ bu çıktılar ile kendi öğrenmesi sonucunda gerçekleşen çıktıyı hesaplar.

3.8.2 Danışmansız Öğrenme: Danışmansız öğrenmede ağa öğrenme sırasında sadece girdiler verilmektedir. Girdi değerlerine göre ağ her bir örneği kendi arasında sınıflandıracak şekilde yeni kurallar oluşturur. Bu biçimde öğrenme işini tamamlar.

3.8.3 Destekleyici Öğrenme: Ağ her iterasyon sonucunda elde ettiği sonucun iyi veya kötü olduğu konusunda bilgi verir. Ağ bu sonuçlara göre kendisini yeniden düzenler (Öztemel, 2003).

3.9 Yapay Sinir Hücresinin Yapısı

Biyolojik sinir hücrelerine benzer yapıda olan sinir ağları yapay nöronlar gibi aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Biyolojik nöronlara benzer şekilde Yapay Sinir Ağlarının da giriş sinyali alıp bu sinyali toplayıp işleyip çıktılarını iletmesi için gerekli düzeneğin bulunduğu bölümleri mevcuttur.

Yapay Sinir Hücresi beş ana bölümden oluşmaktadır. Bu bölümler; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır.

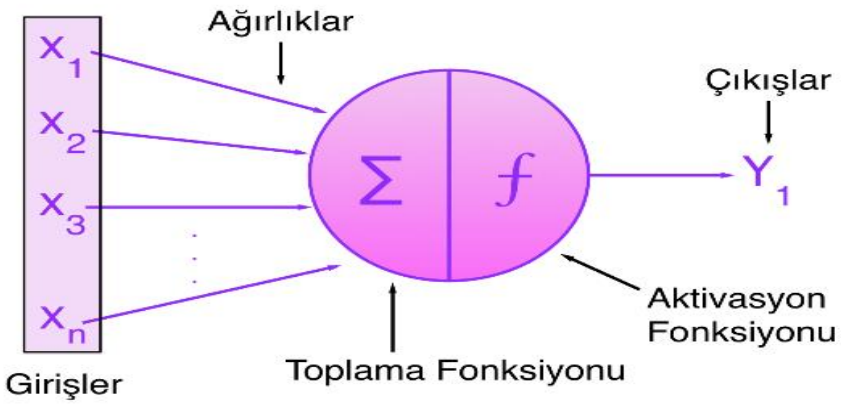

Şekil 3.4 Yapay sinir hücresi modeli (Güzel, 2018)

Bu beş ana bölüm biraz daha detaylı incelenirse:

3.9.1 Girdiler

Dış dünyadan gelen bilgileri toplayan katman girdi katmanıdır. Sinir hücresi sayısını dışarıdan gelen girdi sayısı belirler. Bu katmanda girdiler bir işleme tabi tutulmaz ve diğer katmana geçer (Rojas, 2013).

3.9.2 Ağırlıklar

Bir hücreye gelen bilgilerin önem derecesini ağırlıklar gösterir. Ağırlıklar hem pozitif hem de negatif olabilir. Etkilerinin pozitif veya negatif olması ağırlıklardan belli olur. Eğitime başlanılınca ağırlıklar rastgele Yapay Sinir Ağına verilir. İşlem sonunda çıkış değerlerinin hata payları kabul edilebilir düzeyde ise bu ağırlıklar kabul edilebilir (Caner ve Akarslan, 2009).

3.9.3 Birleştirme Fonksiyonu

Toplama fonksiyonu hücreye gelen net girdiyi hesaplamaktadır. En yaygın olarak kullanılan ağırlıklı toplamı kullanmaktır ancak farklı fonksiyonlar da mevcuttur. Her gelen girdi değeri kendi ağırlığı ile çarpılıp toplanmaktadır.

Farklı durumlara göre girdi değeri veya girdi sayısının miktarı önemli olabilmektedir. En uygun toplama fonksiyonunu belirlemek için de belirli bir kural yoktur. Karar vericinin tecrübe ve deneyimlerine dayanmaktadır

Aşağıda verilmiş olan formül NET hesaplama yöntemi olarak toplamanın kullanıldığı formüldür.

$$NET=\sum_{i=1}^{n} Xi.\,Wi \qquad (3.1)$$

Bu formülde 1.girdiden n.girdiye kadar olan girdilerin her birinin kendilerine seçilmiş rastgele ağırlık değerleri ile çarpılması ve ortaya çıkan sonuçların toplanması anlatılmaktadır.

Tüm yapay sinir ağları için farklı birleştirme fonksiyonları kullanılabilir. Deneyerek veriler için farklı fonksiyon sonuçları incelenebilir. Hangisinin kullanılacağı deneme yanılma yoluyla öğrenilecektir. Aşağıda literatürden elde edilen bazı birleştirme fonksiyonları verilmiştir. (Harrington, 1933; Öztemel, 2003; Debes vd., 2005; Çayıroğlu, 2015).

$$NET=\sum_{i=1}^{n} Xi.\,Wi \qquad (3.2)$$

Birinci girdiden n. girdiye kadarki girdilerin tamamının kendilerine rastgele verilmiş ağırlık değerleri ile çarpılması ve ardından elde edilen değerlerin birbirleri ile çarpılması ile Net girdi elde edilmiş olur.

$$NET=Max\ (Xi.Wi) \qquad (3.3)$$

Birinci girdiden n. girdiye kadar olan girdilerin tamamının kendilerine rastgele verilmiş ağırlık değerleri ile çarpılması ve ardından elde edilen değerlerden en büyük olanın Yapay Sinir Ağları'nın net girdisi olarak alınması ile Net girdi elde edilmiş olunur.

$$NET=Min\ (Xi,Wi) \qquad (3.4)$$

Birinci girdiden n. girdiye kadar olan girdilerin tamamının kendilerine rastgele verilmiş ağırlık değerleri ile çarpılması ve ardından elde edilen değerlerden en küçük olanın Yapay Sinir Ağları'nın net girdisi olarak alınması ile Net girdi elde edilmiş olur.

$$NET=\sum sgn(Xi.Wi) \tag{3.5}$$

Birinci girdiden n. girdiye kadar olan girdilerin tamamı kendilerine rastgele verilmiş ağırlık değerleri ile çarpılır sonra elde edilen değerlerden pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı yapay sinir ağının net girdisi olarak alınır.

$$NET=Net\ (eski)+\sum(Xi.Wi) \tag{3.6}$$

Yapay sinir hücresine gelen bilgiler ağırlıkları ile çarpılarak toplanır. Bu toplam geçmişten gelen bilgilere eklenerek Net girdi bulunur.

3.9.4 Aktivasyon Fonksiyonu

Birleştirme fonksiyonu sonucunda çok büyük değerler elde edilebilir. Yapay hücrede birleştirme fonksiyonundan sonra elde edilen NET değeri ile daha sonraki aşama olan aktivasyon fonksiyonuna geçilir. Her fonksiyon için genel kabul görmüş bir aktivasyon fonksiyonu yoktur. Bu fonksiyon, hangi birleştirme fonksiyonu ile olursa olsun elde edilen NET girdi değerini işler ve mevcut ağın üreteceği çıktıyı belirler.

Bu fonksiyonlar çoğunlukla doğrusal olmayan bir fonksiyon olarak seçilirler. Yapay sinir ağlarının doğrusal olmama özelliği aktivasyon fonksiyonunun bu özelliğinden gelmektedir. En yaygın olarak kullanılan 'Çok Katmanlı Algılayıcı' modelinde genel olarak aktivasyon fonksiyonu olarak 'Sigmoid Fonksiyonu' kullanılır. Aktivasyon fonksiyonu çeşitleri aşağıdaki gibidir.

3.9.4.1 Sigmoid (Logsig) Fonksiyonu

Literatürde uygulamalara bakılırsa en çok kullanılan fonksiyonun Sigmoid Fonksiyon olduğu görülmektedir (Öztemel, 2003).

Sigmoid fonksiyonunda hem doğrusal hem de doğrusal olmayan fonksiyonların her ikisi için de dengelenmiş çıktılar üreterek modelleme yapabilir (Öztemel, 2012).

Sigmoid fonksiyonu için ağın değeri aşağıdaki denklem ile hesaplanmaktadır.

$$F(Net)=\frac{1}{1+e^{-Net}} \quad (3.7)$$

3.9.4.2 Hiperbolik Tanjant (Tansig) Fonksiyonu

Yapay sinir ağlarında en çok kullanılan bir diğer aktivasyon fonksiyonu çeşididir. (Demuth ve Beale, 2000). Bu fonksiyonu kullanabilmek için girdi değerleri önce [-1,1] aralığında normalize edilir ve sonuç olarak çıktı değerleri de [-1,1] aralığında elde edilir.

Tansig fonksiyonu için ağın değeri aşağıdaki denklem ile hesaplanmaktadır.

$$F(Net)=\frac{e^{Net}-e^{-Net}}{e^{Net}+e^{-Net}} \quad (3.8)$$

3.9.4.3 Doğrusal (Purelin) Fonksiyonu

Doğrusal fonksiyon yapay sinir hücresinde aktivasyon fonksiyonu olarak kullanılabilir. Bu durumda girdilerden elde edilen Net girdi aynen çıktı olarak üretilir (Debes vd., 2005). Bu, modelin doğrusal olduğu durumlarda tercih edilen bir fonksiyondur (Demuth ve Beale, 2000).

Purelin fonksiyonu için ağın değeri aşağıdaki denklem ile gösterilmektedir.

$$F(Net)=Net \quad (3.9)$$

3.9.4.4 Doğrusal Pozitif (Poslin) Fonksiyonu

Poslin (Positive Linear Transfer Fuction) pozitif doğrusal bir fonksiyondur. Bu fonksiyonda ağ Net değeri 0'dan büyükse veya eşit ise Net değerini, 0'dan küçükse 0 değerini alır. Negatif değer almaz.

Algoritma: Net, Eğer Net≥0

(3.10)

0, Eğer Net<0

3.9.4.5 Adım (Step veya Heaviside) Fonksiyonu

Eşik değerinden (T) küçük veya eşit tüm Net değerinde ağ çıktı olarak 0 verirken, eşik değerinden büyük değerlerde ağ 1 değerini üretecektir.

Algoritma: Adım (Net) 1, Eğer Net>T

(3.11)

0, Eğer Net≤T

3.9.4.6 Rampa Fonksiyonu

Bu fonksiyonda 2 adet rampa oluşturucu değeri vardır. Bunlardan biri T1, diğeri T2 değeridir.

Algoritma: Rampa (Net)=0, Net< T1

$\frac{Net-T1}{T2-T1}$, T1≤Net≤T2 (3.12)

1, Net>T2

3.9.4.7 Gaussian Fonksiyonu

n= Net değeri
σ=Varyans olmak üzere;

Algoritma: Gaussian (n)=$e^{\frac{n^2}{2\sigma^2}}$ (3.13)

Gaussion fonksiyonu simetrik bir fonksiyondur. Bu nedenle girdinin eşit negatif ve pozitif değerleri için aynı çıktı sonucunu verir. Ağ hiç giriş olmadığında ve çıktıların mesafesi sıfırdan uzaklaştıkça maksimum çıktısını verir.

3.9.4.8 Satlin ve Satlins Fonksiyonları

Yapay sinir ağlarında kullanılan bir diğer fonksiyonda Satlin fonksiyonudur.

$$\text{Algoritma:Satlin (Net)} = \begin{cases} 0, & \text{Eğer Net} \le 0 \\ \text{Net}, & \text{Eğer } 0 \le \text{Net} \le 1 \\ 1, & \text{Eğer Net} \ge 1 \end{cases} \tag{3.14}$$

$$\text{Algoritma: Satlins(Net)} = \begin{cases} -1, & \text{Eğer Net} \le -1 \\ \text{Net}, & \text{Eğer } -1 \le \text{Net} \le 1 \\ 1, & \text{Eğer } 1 \le \text{Net} \end{cases}$$

3.9.4.9 Hardlim ve Hardlims Fonksiyonları

Bir diğer aktivasyon fonksiyonu Hardlim fonksiyonudur. Ağ 0 ve 1 olmak üzere iki sonu verir. Algoritmada bir eşik değeri ile karşılaştırma yoktur.

$$\text{Algoritma: Hardlim:} \begin{cases} 1, & \text{Eğer Net} \ge 0 \\ 0, & \text{Aksi takdirde} \end{cases} \tag{3.15}$$

$$\text{Algoritma: Hardlims:} \begin{cases} 1, & \text{Eğer Net} \ge 0 \\ -1, & \text{Aksi takdirde} \end{cases}$$

3.9.5 Çıktılar

Tek veya çok katmanlı olarak bir yapay sinir ağı tasarlanabilir. Ara katmanlardaki hücre sayıları da farklı olabilir. İşlemler ara katmandaki hücre sayısının artması ile karmaşıklaşır. Fakat hücre sayısının artmasıyla daha iyi sonuç üretebilme şansı da doğar. Ara kaymanda işlenen ve bilgiye dönüşen verinin son geçiş katma çıktı

katmanıdır. Çıkış katmanından çıkan bilgi başka bir hücre veya hücrelere girdi olacaktır. Ya da direkt bilgi olarak hücreden çıkacaktır (Diler, 2003).

Yapay Sinir Ağları işlemlerinin adımları aşağıdaki gibi sıralanabilmektedir (Hu, 2002).

Adım1: Problemin tanımlanması

Adım2: Problemle ilgili değişkenlerin belirlenmesi

Adım3: Verilerin toplanması

Adım4: Verilerin ön işlemden geçirilmesi

Adım5: Sinir ağının tasarlanması

Adım6: Ağın eğitilmesi

Adım7: Ağın geçerliliğine bakılıp hata tespitinin yapılması

3.10 Yapay Sinir Ağlarının Eğitilmesi

İnsan hayatını sürdürdükçe beyni daha da gelişir tecrübe edinir. Yaşadığı tecrübeler karşısında nasıl davranacağını bilir duruma gelir. Ancak daha önce hiç karşılaşmadığı durumlar olursa tecrübesiz ve tepkisiz kalabilir. Yapay sinir ağlarının öğrenme sürecinde de dış çevreden bilgiler alınır, aktivasyon fonksiyonundan geçirilir ve çıkış üretilir. Sırasıyla ağ eğitim aşamaları aşağıdaki gibidir:

-Örneklerin Toplanması: Ağa öğretilecek olay ile ilgili geçmişte gerçekleşmiş olayların bulunması adımıdır. Ağıtın eğitimi ve testi için ayrı ayrı veriler toplanır. Bu örneklerin hepsi teker teker ağa gösterilerek öğrenmesi sağlanır. Ağ olayı öğrendikten sonra test setindeki örnekler gösterilir ve ağın performansı ölçülür. Daha önce görmediği örnekler karşısında başarısı ağın iyi öğrenme performansını ortaya koyar.

-Ağın Topolojik Yapısının Belirlenmesi: Kaç tane girdi, ara katman, çıktı olması gerektiği bu adımda belirlenmektedir.

-Öğrenme Parametrelerinin Belirlenmesi: Ağın öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametrelerin belirlendiği adımdır.

-Ağırlıkların Başlangıç Değerlerinin Atanması: Ağırlık değerlerinin ve eşik değer ünitesinin ağırlıklarının başlangıç değer atamaları yapılır. Başlangıç genellikle rastgele atanır.

-Öğrenme Setinden Örneklerin Seçilmesi ve Ağa Gösterilmesi: Ağı öğretmek ve ağırlıkları değiştirmek amacıyla ağa örnekler verilir.

-Gerçekleşen Çıktının Beklenen Çıktı İle Karşılaştırılması: Ağın ürettiği hata değerleri hesaplanır.

-Ağırlıkların Değiştirilmesi: Üretilen hatanın azaltılması için çalışmalar yapılır.

-Öğrenmenin Tamamlanması: Hatalar kabul edilebilir düzeye gelince öğrenme uygulayıcı tarafından tamamlanır (Öztemel, 2003).

3.11 Yapay Sinir Ağlarında Normalizasyon Çeşitleri

Yapay Sinir Ağlarında ağın giriş ve çıkış verilerine bazı uygulamalar yaparak verilerin eğitimi daha verimli hale getirilebilir. Veriler arasındaki büyüklük farkları azaltılır, veriler belirli aralıklarda kalır. Bu uygulama Normalizasyon işlemidir ve normalize edilmeden ağı eğitmeye çalışmak çok yavaş olabilir, sonuçlar da beklenildiği gibi olmayabilir. Normalleştirme işlemlerinde farklı teknikler kullanılabilir. x'=Normalize edilmiş girdi değişkenini ve x_i=Girdi değişkeninin değerini göstermek üzere, bu teknikler aşağıdaki gibidir:

3.11.1 Z-Score Normalizasyonu

Aynı veri setinde bazı değerler 0'dan küçük iken bazı değerler 0'dan büyük olabilmektedir. Bu durum uç verilerin sonuçlar üzerinde daha hakim olacağını göstermektedir. Normalleştirme işlemi ile modeldeki her bir parametrenin tahmin işlemine aynı katkıyı sağlamaları sağlanır. Aşağıda her bir değişkene karşı gelen sütunların aritmetik ortalaması ve standart sapması bulunmuştur. Daha sonra, aşağıdaki eşitlikte belirtilen formül ile veriler normalleştirilerek, veriler arasındaki uzaklıklar ortadan kaldırılır ve verilerdeki uç noktaları azaltır (Yüksek vd., 2007: 97-112).

$$x' = \frac{x_{i-\mu}}{\sigma} \tag{3.16}$$

Bu eşitlikte;

μ=Girdi setinin ortalamasını

σ=Girdi setinin standart sapmasını

ifade etmektedir.

3.11.2 Min-Max Normalizasyonu

Doğrusal olarak verileri bu yöntem normalize eder. Min-Max normalizasyon işlemi ile veri 0 ile 1 arasındaki sayılardan oluşur. Minimum değer en küçük veriyi maksimum değer ise en büyük veriyi verir. Hesaplama işlemi aşağıdaki gibidir:

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \tag{3.17}$$

Bu eşitlikte;

x_{min}=Girdi seti içerisinde yer alan en küçük sayıyı

x_{max}=Girdi seti içerisinde yer alan en büyük sayıyı

ifade etmektedir.

3.11.3 Medyan Normalizasyonu

Medyan normalizasyonunda her girdinin öncelikle medyan değeri alınır ve her veriye uygulanır. Medyanın en önemli özelliği aşırı sapmalardan etkilenmiyor oluşudur (Jaya-lakshmi ve Santhakumaran, 2011: 89-93). Hesaplama işlemi aşağıdaki eşitlik ile yapılmaktadır:

$$x' = \frac{x_i}{M} \tag{3.18}$$

Bu eşitlikte;

M=Girdi setinin meydanını

ifade etmektedir.

3.11.4 Sigmoid Normalizasyonu:

Sigmoid normalizasyonu fonksiyonu verileri 0 ile 1 veya -1 ile 1 arasında sınıflandırır. Bir kaç tane doğrusal olmayan sigmoid fonksiyon çeşidi vardır. Tanjant sigmoid fonksiyonu süreçleri hızlandırırken doğru bir seçim olabilir (Jayalakshmi ve Santhakumaran, 2011: 89-93). Bu yöntem için aşağıdaki eşitlik kullanılır:

$$x' = \frac{e^{xi} - e^{-xi}}{e^{xi} + e^{-xi}} \tag{3.19}$$

Bu eşitlikte;

e=Doğal logaritmanın tabanını

ifade etmektedir.

3.11.5 D_Min_Max Normalizasyonu

Modelin uygulanması için aşağıda verilen denklem ile tüm veriler 0,1 ile 0,9 arasında normalize edilmiştir. Normalizasyon yapılarak veriler boyutsuz hale getirilmiş olur (Doğan vd., 2007: 4119-4131). Bu normalizasyon yöntemi için aşağıdaki eşitlik kullanılmaktadır:

$$x' = 0{,}8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0{,}1. \tag{3.20}$$

4
Uygulama

Bu bölümde, Türkiye'nin uzun dönem elektrik talebini tahmin etmek amacıyla çok katmanlı ileri beslemeli geri yayılımlı yapay sinir ağ yapıları oluşturulmuştur. Hedef değişkeni olarak Türkiye Net Elektrik Tüketimi; giriş değişkenleri olarak ise Türkiye Nüfusu, Kurulu Gücü ve Türkiye Brüt Elektrik Üretimi seçilmiştir. Uygulamada, tüm değişkenler nümerik olmak üzere üç giriş ve bir hedeften oluşan ve 1923-2018 yılları arasında yer alan 96 gözleme sahip bir veri seti kullanılmıştır. Analizler, MATLAB programının Yapay Sinir Ağları modülünde gerçekleştirilmiştir. Uygulama kısmında detaylı olarak verilerin işlenişi, MATLAB içerisindeki adımlamalar, elde edilen sonuçlar ve yorumlamaları anlatılacaktır.

4.1 MATLAB Programının Genel Özellikleri

MATLAB (Matrix Laboratory), çok paradigmalı sayısal hesaplama yazılımı ve dördüncü nesil programlama dilidir. Dördüncü nesil programa dili derken hazır şablonlar ve sihirbazlar aracılığıyla bazı ihtiyaçlarda pratik çözümler geliştirmeye yönelik olan diller kast edilmektedir. Kullanımları kolay ve az kod yazılan dillerdir (Özel, 2018).

- MatWorks şirketi MATLAB'i geliştirmektedir.
- MATLAB ile matris işlemleri, fonksiyon ve veri çizme, algoritma geliştirme işlemleri yapılmaktadır.
- C,C++,Java gibi diğer dillerde yazılmış programlarla birlikte çalışma imkanı sağlar.
- İlk olarak kontrol mühendisliği araştırmacıları tarafından kabul edilen MATLAB eğitim, sayısal analiz öğrenimi ve doğrusal cebir alanlarında da kullanılmaktadır.
- MATLAB istatistik, optimizasyon, nümerik analiz gibi hesaplamaları kolay ve hızlı bir şekilde yapar.

- Çok karışık hesaplamalar bile kısa sürede çözüme ulaştırılır.
- İki ve üç boyutlu grafikler rahatlıkla çizilebilir.

İçerdiği 600'den fazla matematik, istatistik ve mühendislik fonksiyonları ile birçok mühendislik uygulamasında rahatlıkla kullanılabilecek MATLAB'ın temel kullanım alanları şu başlıklar altında toplanabilir (Mathworks, 2005):

Matematiksel Ölçüm ve Hesaplamalar

- Algoritma Geliştirme
- Veri Elde Etme
- Görüntü İşleme
- Sayısal İşaret İşleme
- Süzgeç Tasarımı
- Dalgacıklar
- Yapay Sinir Ağları
- Veritabanı
- Optimizasyon
- Modelleme ve Simülasyon

4.2 Eğitim-Onaylama-Test Veri Setlerini Belirlenmesi

Yapay Sinir Ağlarında ağın giriş ve çıkış verilerine bazı ölçeklendirme işlemleri yaparak verilerin eğitimi daha verimli hale getirilebilir. Böylece, veriler arasındaki büyüklük farkları azaltılır, veriler belirli aralıklarda kalır. Bu uygulama, normalizasyon işlemidir ve normalize edilmeden ağı eğitmeye çalışmak çok yavaş olabilir, sonuçlar da beklenildiği gibi olmayabilir. Tez çalışmasında, literatüre göre oldukça başarılı sonuçlara sahip olan Min-Max Normalizasyon tekniği kullanılmıştır.

Mevcut verilerin yüzde kaçının eğitim, test ve onaylama için kullanılacağına MATLAB programı rassal olarak karar vermektedir. Toplam 96 gözlemden oluşan veri setinin %70'i eğitim (66 gözlem), %15'i onaylama, (15 gözlem) ve %15' i (15 gözlem) test veri seti olarak ayrılmıştır.

4.3 MATLAB Programına Verilerin Aktarılması

MATLAB programını çalıştırdıktan sonra Yapay Sinir Ağları araç kutusu olan Neural Network araç kutusu aşağıdaki şekilde açılır.

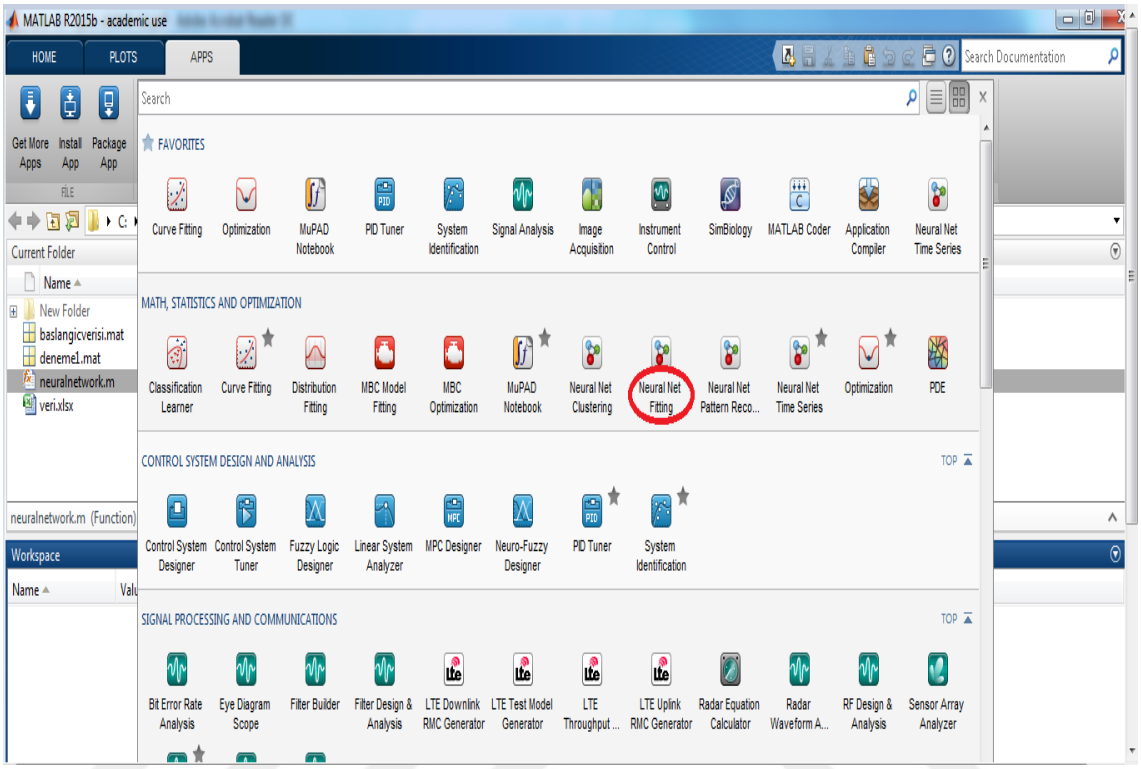

Şekil 4.1 Neural network araç kutusu

MATLAB üzerindeki uygulamalardan Neural Network Fitting Tollbox seçilir. Bu araç kutusu ileri beslemeli problemleri çözümde kullanılır.

MATLAB'e veri aktarmak için öncelikle MATLAB'te çalışma sayfasına girdi ve çıktı değişkenleri tanımlanmıştır. Girdi değişkeni için 'İnput', çıktı değişkeni için 'Target' isminde dosyalar oluşturulmuştur.

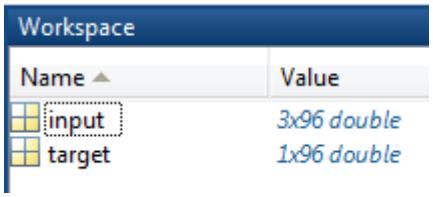

Şekil 4.2 Çalışma sayfasındaki girdi-çıktı değişkenleri

Her bir değişken için 96 adet gözlem verisi yukarıdaki gibi ağa eklenmiştir. Daha sonra MATLAB komut penceresini Command Window 'a 'nntoll' komudunu yazarak getirilmiştir.

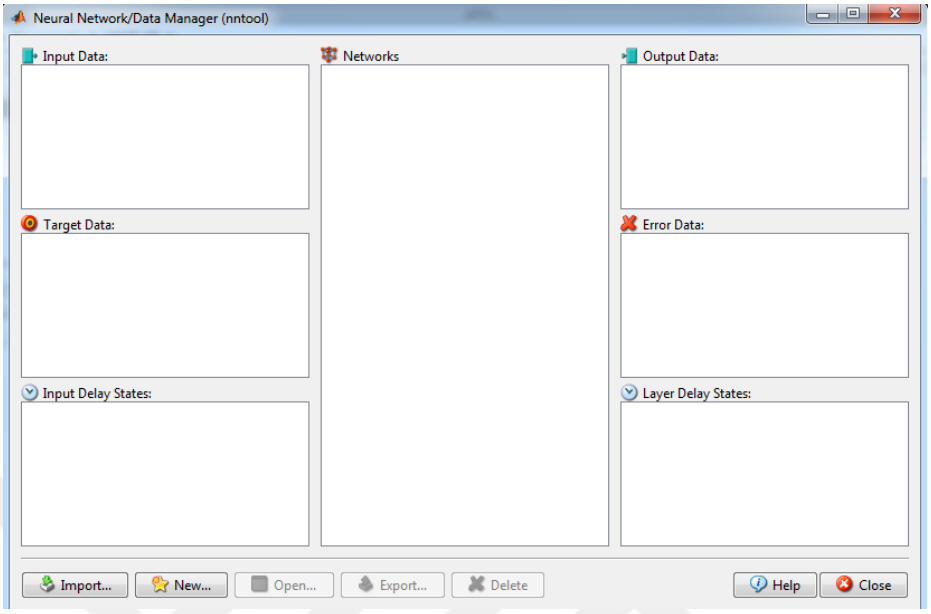

Şekil 4.3 Yapay sinir ağı veri yöneticisi

Açılan komut penceresinde sol altta yer alan 'import' seçeneğine basarak girdi ve çıktı değişkenleri tanımlanmıştır. Girdi değişkeni olarak 'INPUT', çıktı değişkeni olarak ise 'TARGET' seçilmiştir.

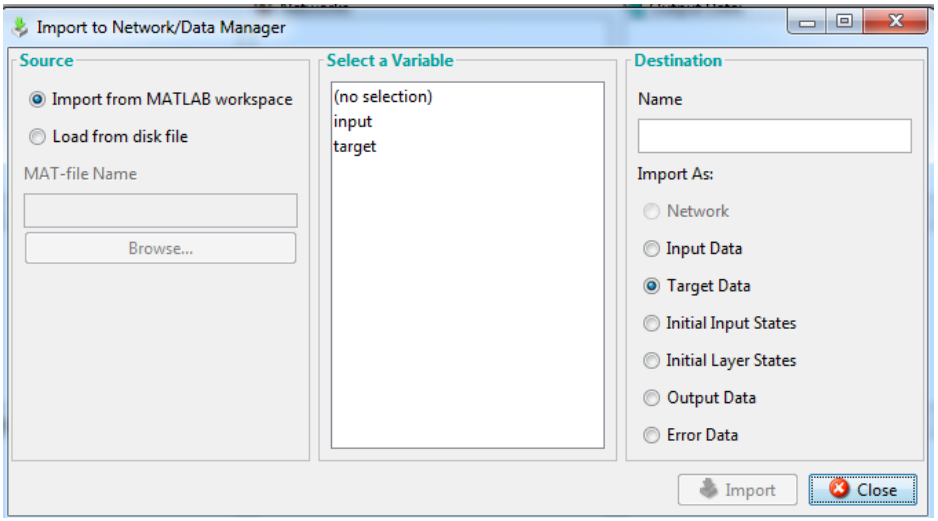

Şekil 4.4 Veri ekleme çubuğu

Tanımladıktan sonra Neural Network Toolbox'ına değişkenlerin atandığını görülmüştür. Atanan değişkenlerden sonra Neural Network Toolbox'ı aşağıdaki gibi görülecektir. Yeni bir ağ eğitmek için 'new' seçeneğine basılmıştır.

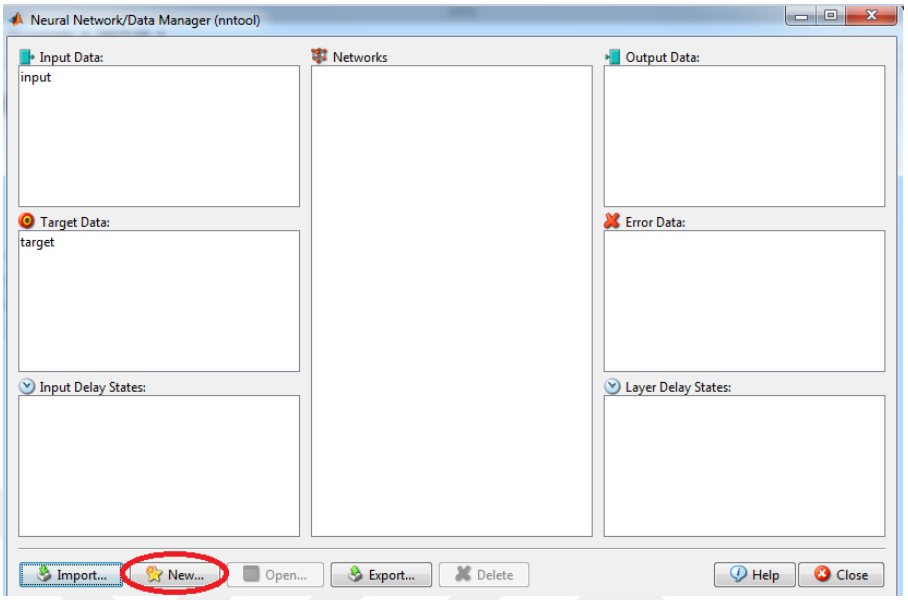

Şekil 4.5 Yapay sinir ağı araç kutusu

Bu seçeneğe basıldıktan sonra ağı oluşturmak için gerekli olan seçeneklerin seçilmesi için ağ veya veri oluşturma sihirbazı açılır. Buradan sonra sırasıyla aşağıdaki işlemler uygulanmıştır.

4.4 Ağ Yapısının Belirlenmesi

Veri setinin eğitim-onaylama-test kümesi olarak ayrılma işleminden sonra, oluşturulacak ağın yapısına karar verilir. Bu aşamada, girdi sayısı, gizli katman sayısı, çıktı katman sayısı, katmanların kaçar adet nöron içereceği, hangi öğrenme algoritmasının kullanılacağı, öğrenme algoritmasına ait parametreler, hangi transfer fonksiyonunun kullanılacağı ve performans kriteri gibi ölçütleri belirlenir. Elektrik talep tahmini, OHK kriterini minimize etmeye dayalı olan ileri beslemeli ağ yapıları ile gerçekleştirilmiştir. Bu çalışmada çok katmanlı ileri beslemeli ağ yapıları oluşturulmuştur ve ağ yapısı izleyen şekildedir:

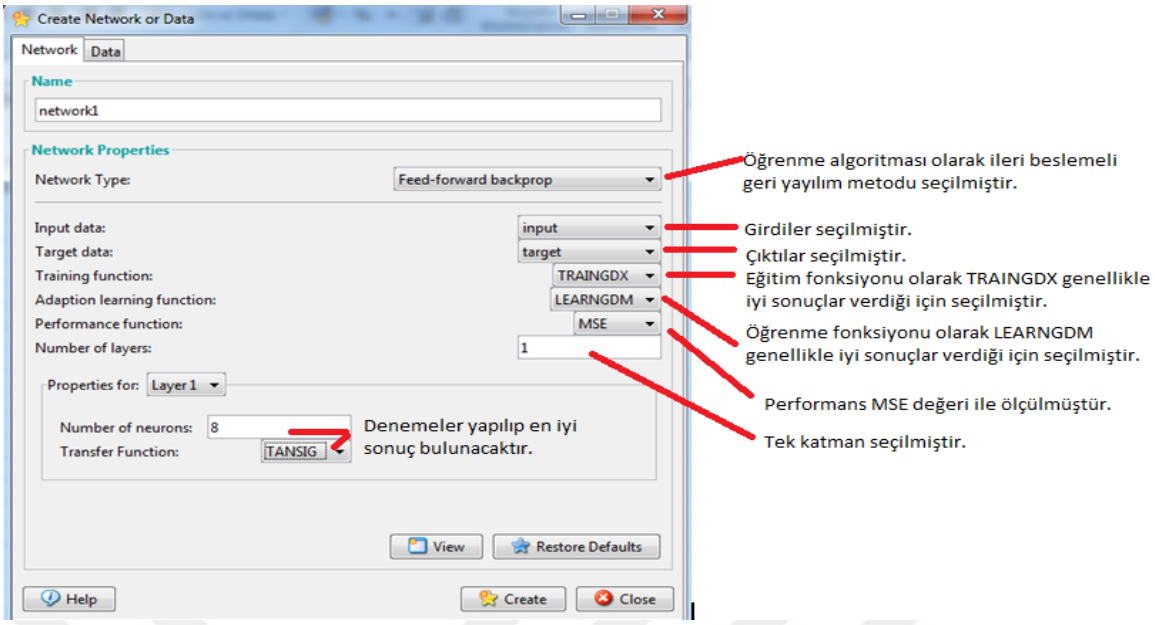

Şekil 4.6 Yeni ağ/veri oluşturma ekranı

Ağın eğitilmesi esnasında gizli katmanda bulunacak nöron sayısı değiştirilerek ve transfer fonksiyonu olarak tanjant hiperbolik ile sigmoid fonksiyonları ayrı ayrı denenerek kıyaslama yapılmıştır. Algoritma 1000 iterasyon ile çalıştırılmıştır. Birden fazla gizli katman kullanımı ağın eğitimini yavaşlatması sebebi ile tek gizli katman kullanılması tercih edilmiştir. Gizli katmanda bulunacak nöron sayıları sırası ile 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 25, 50 ve 100 olacak şekilde denenmiştir. YSA'nın performansını değerlendirmek için kullanılan ölçütler izleyen şekilde belirlenmiştir:

Tablo 4.1 Ağın performansını etkileyen ölçütler

Ağ Tipi	İleri Beslemeli Geri Yayılımlı Ağ
Eğitim Fonksiyonu	TRAINGDX
Öğrenme Fonksiyonu	LEARNGDM
Gizli Katman Sayısı	1
Nöron Sayısı	1 ile 100 arasında
Transfer Fonksiyonu	TANSIG, LOGSIG
İterasyon Sayısı	1000
Performans Kriteri	OHK,
Diğer Ölçütler	Korelasyon, AIC, AICc, BIC

Ağın eğitilmesi için momentumlu en dik azalış algoritması seçilmiştir. Algoritma, 0.01 öğrenme oranı ve 0.9 momentum sabiti ile çalıştırılmıştır. Eğitim sırasında yapılan nöron sayısı denemelerine karşılık momentumlu en dik azalış algoritmasının performansını gözlemleyebilmek için iterasyon sayısı 1000 olarak sabit kılınmıştır. Yapılan denemeler sonucunda algoritmanın elde edilen farklı ağ yapıları için hem eğitim hem de test veri setindeki korelasyon katsayıları ve OHK değerleri ile eğitim veri setindeki AIC, AICc BIC gibi bilgi kriterlerine göre performansları Tablo 4.2 ve Tablo 4.3'te verilmiştir.

Tablo 4.2 Logsig transfer fonksiyonuna ait ağın performansı

Nöron Sayısı	Parametre Sayısı	Eğitim OHK	Test OHK	Eğitim Korelasyon	Test Korelasyon	AIC	AICc	BIC
1	6	0,017	0,003	0,996	0,998	-258,491	-257,068	-245,353
2	11	0,352	0,002	0,996	0,997	-46,912	-42,023	-22,826
3	16	0,430	0,001	0,998	0,999	-23,702	-12,600	11,332
4	21	0,039	0,001	0,999	0,999	-172,797	-151,797	-126,814
5	26	0,147	0,003	0,995	0,998	-74,543	-38,543	-17,612
6	31	0,083	0,001	0,998	0,999	-102,110	-43,757	-34,230
7	36	0,157	0,001	0,999	0,998	-50,200	41,662	28,628
8	41	0,735	0,004	0,999	0,996	61,680	205,180	151,455
9	46	0,076	0,001	0,999	0,999	-77,997	149,582	22,727
10	51	0,012	0,002	0,999	0,998	-190,460	188,397	-78,788
25	126	0,318	0,001	0,998	0,997	176,384	-348,272	452,280
50	251	0,132	0,001	0,999	1,000	368,353	-311,776	917,956
100	501	0,113	0,001	0,999	1,000	858,096	-295,583	1.955,113

Tablo 4.2'deki AIC, AICc ve BIC bilgi kriterleri, iterasyon sayısı ve YSA parametreleri sabit tutulduğunda gizli katmandaki nöron sayısının arttırılıp arttırılmayacağı hakkında bir gösterge olarak kullanılabilir. O halde, aynı OHK seviyesinde daha düşük bilgi kriterine sahip model seçilmelidir. (Kocadağlı, 2012; Kocadağlı ve Aşıkgil, 2014). Buna göre, Tablo 4.2 incelendiğinde gizli katmandaki nöron sayısı arttığında bilgi kriterleri yükselmektedir. Buna karşılık, nöron sayısı arttığında eğitim veri setindeki OHK değeri artmaya başlarken test veri setinin OHK değeri eksik uyumdan dolayı azalmaktadır ve tam tersi olarak eğitim veri setindeki OHK değeri azalmaya başlarken test veri setindeki OHK değeri aşırı uyumdan dolayı artmaktadır. Sonuç olarak, sigmoid transfer fonksiyonu kullanıldığında en dik azalış algoritması kullanılan parametrelere göre iyi performans gösteremediği söylenebilir. Bu nedenle transfer fonksiyonu olarak hem türevlenebilir olması hem de hesap kolaylığı bakımından tanjant hiperbolik fonksiyonu denenmiştir ve sonuçlar Tablo 4.3'te verilmiştir.

Tablo 4.3 Tansig transfer fonksiyonuna ait ağın performansı

Nöron Sayısı	Parametre Sayısı	Eğitim OHK	Test OHK	Eğitim Korelasyon	Test Korelasyon	AIC	AICc	BIC
1	6	0.054	0.003	0.996	0.999	-180.639	-179.215	-167.501
2	11	0.009	0.001	0.998	0.999	-289.855	-284.966	-265.769
3	16	0.025	0.001	0.998	0.999	-212.799	-201.697	-177.765
4	21	0.000	0.001	0.998	0.999	-504.881	-483.881	-458.899
5	26	0.171	0.001	0.999	1.000	-64.562	-28.562	-7.631
6	31	0.575	0.000	9.000	0.999	25.477	83.830	93.356
7	36	0.582	0.001	0.999	0.998	36.275	128.137	115.103
8	41	0.691	0.001	0.999	0.998	57.605	201.105	147.381
9	46	0.445	0.001	0.999	0.998	38.561	266.140	139.285
10	51	0.366	0.001	0.999	0.998	35.662	414.519	147.334

Tablo 4.3 Tansig transfer fonksiyonuna ait ağın performansı (devamı)

Nöron Sayısı	Parametre Sayısı	Eğitim OHK	Test OHK	Eğitim Korelasyon	Test Korelasyon	AIC	AICc	BIC
25	126	0.064	0.000	1.000	0.999	70.883	-453.773	346.780
50	251	0.018	0.000	0.999	0.999	235.743	-444.386	785.347
100	501	0.005	0.000	1.000	1.000	649.479	-504.200	1,746.496

Tablo 4.3'e göre nöron sayısı arttığında AIC, AICc ve BIC bilgi krtierleri azalmaya başlamaktadır. Buna karşılık, nöron sayısı 1'den başlayarak birer birer arttırıldığında eğitim OHK değeri azalmaya başlarken test OHK değeri de azalmaya başlamaktadır. Nöron sayısı 5 ve daha fazla seçildiğinde ise hem eğitim veri setine ait OHK değerleri hem de bilgi kriterleri artmaya başladığı için nöron sayısı artışı durdurulmuştur. Nöron sayısı 4 seçildiğinde ise bilgi kriterleri minimum değere ulaşmaktadır. Aynı nöron sayısında, eğitim ve test veri setleri setleri için korelasyonlar sırası ile 0,998 ve 0,999 olarak bulunmuştur. Sonuç olarak, Tablo 4.3'e göre algoritma, 0.01 öğrenme oranı ve 0.9 momentum sabiti ve 1000 iterasyon sayısı ile çalıştırıldığında en iyi uyuma tek gizli katmanda 4 nöron sayısı ile ulaşılmıştır ve elde edilen ağın görünümü Şekil 4.7'deki gibidir:

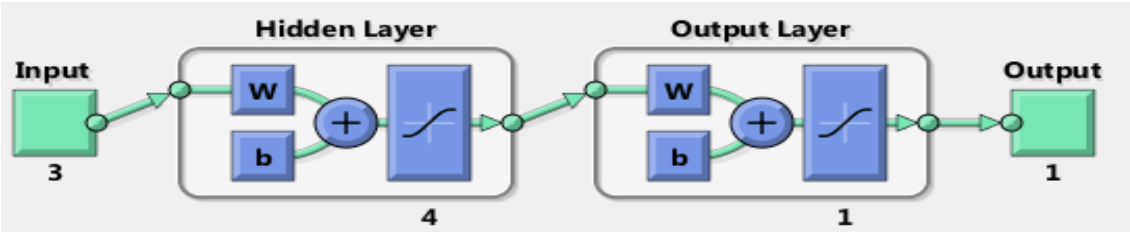

Şekil 4.7 Oluşturulan ağ görünümü

Oluşturulacak ağ yapısının nihai parametrelerine karar verildikten sonra; eğitim, onaylama ve test veri kümeleri için elde edilen OHK değerlerine ait grafik Şekil 4.8'de gösterilmektedir.

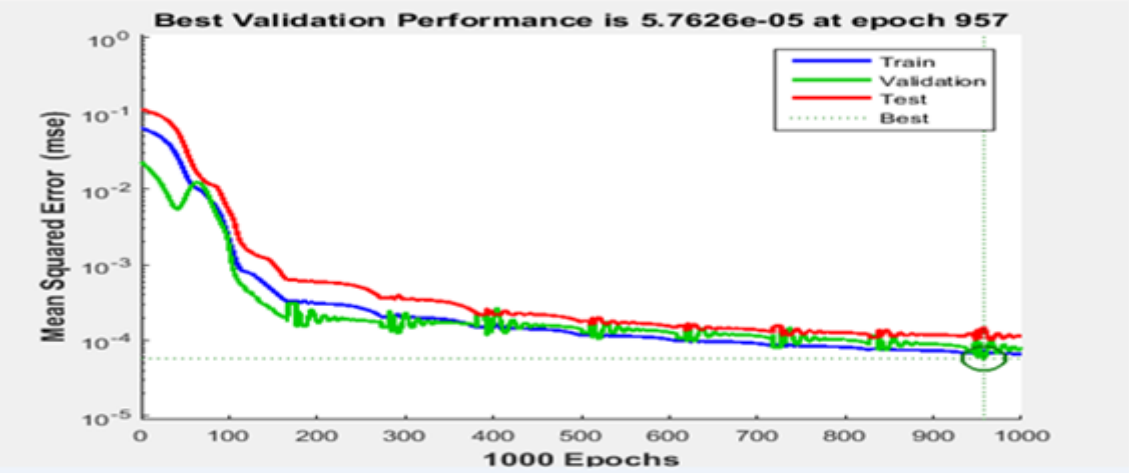

Şekil 4.8 Oluşturulan ağın performans grafiği

Onaylama kümesine ait hata, eğitim kümesine ait hata gibi ağın eğitimin ilk aşamasından itibaren azalır. Fakat ağın veriyi ezberlemesi durumunda onaylama kümesi hatası artmaya başlar. Onaylama hatası minimum olduğu anda optimal çözüme ulaşılmıştır. Onaylama kümesinin minimum hataya ulaştığı nokta, en iyi performans değerini gösterir. Şekil 4.8'e göre en iyi onaylama performans değeri, 0.00025 OHK değeri olup 957. iterasyonda gerçekleşmiştir.

Optimal çözüme ulaşıldığı anda ağın ağırlıkları ve bias değeri saklanacaktır, yani bu aşamada artık ağın eğitimi durdurulur. Ağ sonuçlarının daha iyi görülebilmesi için Şekil 4.9'da verilen regresyon grafikleri incelenmelidir.

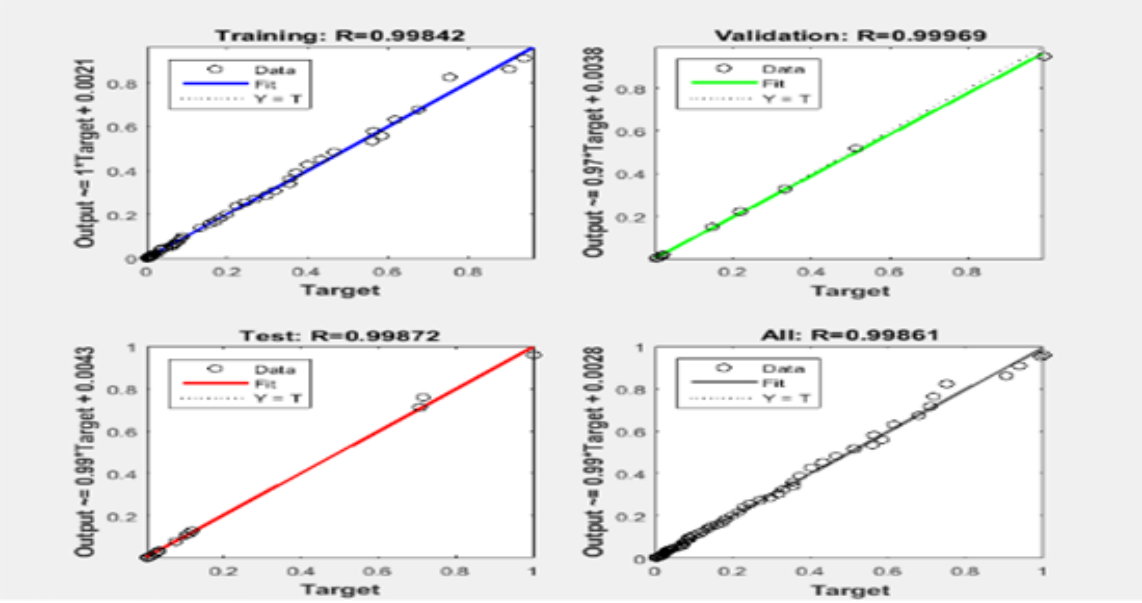

Şekil 4.9 Eğitim, onaylama ve test verileri için regresyon grafiği

Şekil 4.9 eğitim, onaylama ve test veri kümeleri için ayrı ayrı regresyon sonuçlarını verir. Grafikte elde edilen R değerleri gerçek değerler ile tahmin değerler arasındaki korelasyonu göstermektedir. Bu değerin 1'e yakın olması tahmin değerlerinin oldukça başarılı olduğunu; yani ağın başarılı bir şekilde eğitildiğini göstermektedir. Ağın eğitim durumu Şekil 4.10'da verilmektedir.

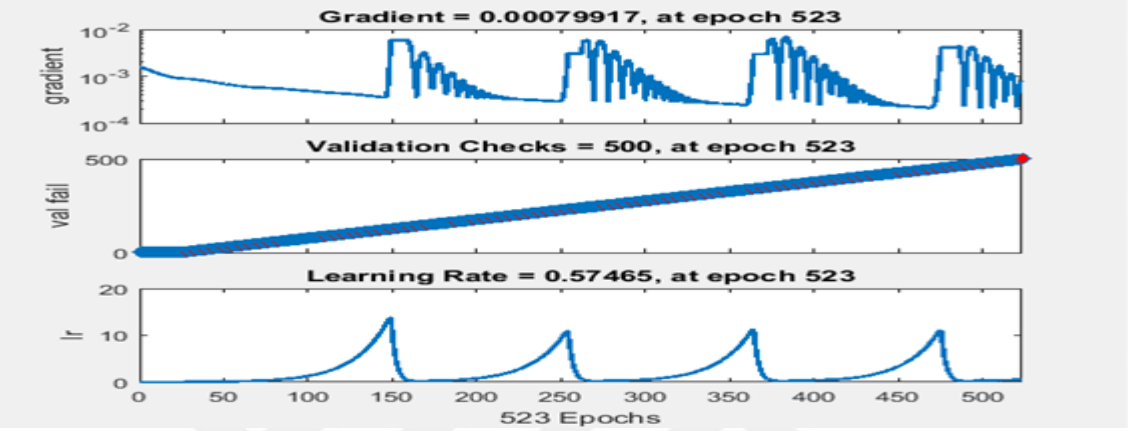

Şekil 4.10 Eğitim durumu

Momentumlu en dik azalış algoritması grandyent temelli bir algoritma olduğundan gradyent değerinin azalarak 0'a yaklaşması gereklidir ve Şekil 4.10'da gradyent grafiğinin bu koşulu sağladığı görülmektedir.

Ağın eğitiminden sonra eğitimin ne derecede başarılı olduğu ağı simule ederek anlaşılabilir. Yani girdi değişkenlerinden bir kısmını ağa girdi olarak atayıp ağın oluşturacağı çıktılar ile gerçekte olan çıktılar kıyaslanıp başarı ölçülebilir. Bu esnada eğitim kümesinin değerleri Tablo 4.3'te açıklanan en iyi uyuma sahip parametreler ile bulunmuştur.

Simülasyon işlemi için 2004-2018 yılları arasındaki 15 adet gerçekleşen nüfus, kurulu güç ve brüt elektirk üretim değeri ağa girdi olarak verilmiştir. Bu girdi değerlerine karşılık ağın hangi elektrik tüketim değerlerini tahmin edeceği gözlenmiştir. Ağın tahmin ettiği değerler ile gerçekte 2004-2018 yılları arasında olan tüketim değerleri kıyaslanmıştır.

Tablo 4.4 Simüle tüketim ile gerçek tüketim arasındaki uyum

Nüfus	Kurulu Güç	Brüt Üretim	Simule Tüketim	Gerçek Tüketim	OHK
0,785	0,416	0,548	0,438	0,434	1,821E-05
0,796	0,439	0,580	0,471	0,468	1,034E-05
0,809	0,458	0,612	0,507	0,513	3,207E-05
0,822	0,461	0,644	0,553	0,559	3,577E-05
0,849	0,472	0,667	0,589	0,584	2,202E-05
0,864	0,506	0,655	0,571	0,565	3,749E-05
0,881	0,559	0,710	0,590	0,617	0,001
0,895	0,598	0,772	0,657	0,677	0,000
0,908	0,645	0,806	0,728	0,707	0,000
0,923	0,723	0,808	0,697	0,716	0,000
0,938	0,785	0,848	0,782	0,753	0,001
0,953	0,826	0,881	0,875	0,903	0,001
0,968	0,887	0,923	0,947	0,940	4,020E-05
0,982	0,963	0,962	0,974	0,992	0,000
1	1	1	0,982	1	0,000

Tablo 4.4'e göre, test veri kümesi için elde edilen simüle tüketim değerleri ile gerçek tüketim değerleri birbirine çok yakındır. OHK değeri, 0.000292'dir. Ham verileri kıyaslamak için normalize edilen değerler denormalize edilerek de tüketim değerleri hesaplanmış ve Tablo 4.5'te sunulmuştur.

Tablo 4.5 Test verisi için gerçek ve simule tüketim değeri kıyaslaması

Yıllar	Gerçek Tüketim (MWh)	Simule Tüketim (MWh)
2004	126.774.000	128.020.482
2005	136.750.000	137.689.504
2006	149.826.000	148.171.591
2007	163.353.000	161.605.734
2008	170.604.000	171.974.714
2009	165.087.000	166.875.771
2010	180.212.000	172.460.764
2011	197.935.000	191.986.164
2012	206.712.000	212.699.171
2013	209.222.000	203.591.181
2014	219.889.000	228.379.703
2015	263.827.983	255.658.579
2016	274.754.725	276.607.015
2017	289.979.557	284.679.928
2018	292.171.352	286.924.075

Tablo 4.5'e göre gerçek tüketim ile ağın tahmin ettiği tüketim değerleri birbirine çok yakındır. Ağ başarılı bir performans göstermiştir.

4.5 Uzun Dönem Projeksiyon

Tez çalışmasında oluşturulan ağ eğitilmiş, eğitim sonuçları başarılı bir performans göstermiştir. Eğitilen değerler test edilmiş ve bu test değerlerinin de performans değerleri oldukça yüksek olduğu gözlenmiştir. O halde oluşturulan çok katmanlı ileri beslemeli geri yayılımlı YSA modeli ile 2019-2027 yılları için uzun dönem elektrik tüketim tahmini yapılabilir.

Ağın girdi değişkenleri olan Toplam Nüfus, Kurulu Güç ve Brüt Üretim verileri için zaman serilerinin ARIMA modelleri ile tahminleme yapılıp 2019-2027 yılları için elde edilen veriler ağa girdi olarak atanmıştır. Ağa girdi olarak atanmadan önce verilere normalizasyon işlemi uygulanmıştır. TEİAŞ'ın 2019-2027 yılları

projeksiyonu ile YSA ile elde edilen tüketim değerleri kıyaslanmıştır. Nihai seçilen ağ parametreleri ile gerçekleştirilen ağ modelinin tahmin ettiği tüketim değerleri Tablo 4.6'da sunulmuştur.

Tablo 4.6 2019- 2027 yılları için TEİAŞ tüketim projeksiyonu ile tüketim tahmini kıyaslaması

Yıllar	TEİAŞ Tüketim Projeksiyonu (MWh)	YSA Tüketim Tahmini (MWh)
2019	315.807.000	316.242.314
2020	328.409.000	316.422.181
2021	341.037.000	318.368.890
2022	354.156.000	321.557.111
2023	367.876.000	332.875.390
2024	381.814.000	377.856.151
2025	396.139.000	391.320.220
2026	410.530.000	417.152.907
2027	424.973.000	423.069.570

5
Sonuç ve Öneriler

Yapılan tez çalışmasında, Yapay Sinir Ağları kullanılarak 2019-2027 yılları için uzun dönemli Türkiye elektrik talebi tahmin edilmiştir. YSA eğitiminde kullanılan algoritmanın parametreleri ve iterasyon sayısı sabit tutulduğunda, gizli katmanda bulunacak nöron sayısı AIC, AICc ve BIC bilgi kriterlerine göre belirlenmiştir. Gizli katmanda bulunan nöron sayısı ve transfer fonksiyonu değiştirilerek denenen ağ yapıları içerisinde OHK performans kriterine göre en başarılı ağ modeli seçilmiştir. Buna göre; tek gizli katmanlı, 4 gizli nöronlu, TANSIG transfer fonksiyonlu, Min-Max normalizasyon tekniğini kullanan ağ yapısı minimum hata ile en başarılı performansı göstermiştir.

Elde edilen sonuçlara bakılarak yapay sinir ağlarının Türkiye elektrik talep tahmini için başarılı bir yöntem olduğu söylenebilir. Veriler arasındaki doğrusal olmayan ilişkileri yapay sinir ağları ile modele öğretip genelleme yaptırılabilir. Böylelikle YSA ile eğitilen veriler daha önce hiç karşılaşmadığı sorulara kabul edilebilir hatalar ile cevap verebilirler. Bu sebeplerle Yapay Sinir Ağları tahminlemelerde etkin bir yöntem olarak kullanılmaktadır.

Ülkelerin uzun dönemli planlama kalemlerinin en önemlilerinden olan elektrik talebi bu çalışma ile başarılı bir şekilde tahminlenmiştir. Eksik veya fazla tahminlemeler sonucunda ciddi zararlara yol açabilecek olan bu tahmin problemi konusunda yapılacak olan diğer çalışmalara da yol gösterecektir.

Kaynakça

[1] Ahamed, K.I. ve Akthar, S., (2016). "Survey on Artificial Neural Network Learning Technique Algorithms", International Research Journal of Engineering and Technology, 03(2): 36-39.

[2] Balın, A., (2014), Türkiye Enerji Planlaması İçin Çok Ölçütlü Bir Model Önerisi, Doktora Tezi, Yıldız Teknik Üniversitesi FBE, İstanbul.

[3] Bayrak, M. ve Esen, Ö., (2014). "Türkiye'nin Enerji Açığı Sorunu ve Çözümüne Yönelik Arayışlar", Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 28(3): 139-147.

[4] Belciug, S. ve Gorunescu, F., (2014). "Error-correction learning for artificial neural networks using the Bayesian paradigm. Application to automated medical diagnosis", Journal of biomedical informatics, 52: 329-337.

[5] Buhari, M. ve Adamu, S., (2012). Short-Term Load Forecasting Using Artificial Neural Network, Proceedings of the International MultiConferences of Engineers and Computers Scientists, March 14-16, Hong Kong.

[6] Caner, M. ve Akarslan, E., (2009). "Mermer kesme işleminde spesifik enerji faktörünün ANFIS ve YSA yöntemleri ile tahmini", Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 15(2): 221-226.

[7] Daelemans, W., Hoste, V., De Meulder, F. ve Naudts, B., (2003). "Combined optimization of feature selection and algorithm parameters in machine learning of language", In European Conference on Machine Learning, Springer, Berlin, Heidelberg, (84-95).

[8] Debes, K., Koenig, A. ve Gross, H.M., (2005). "Transfer Functions in Artificial Neural Networks A Simulation- Based Tutorial", Brains, Minds and Media, 9(3).

[9] Demirel, Ö., (2009). Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini, Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 4-27.

[10] Demuth, H. ve Beale, M., (2000). Neural network toolbox user's guide, http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=273667F22FFC23C630E4E4A8CC2FCE47?doi=10.1.1.123.6691&rep=rep1&type=pdf, 20 Mayıs 2019.

[11] Diler, A.İ., (2003). "İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi Türkiye'de Bankalar, Sermaye Piyasası ve Ekonomik Büyüme: Koentegrasyon ve Nedensellik Analizi", İMKB Dergisi, 7(25-26): 65-81.

[12] Doğan E., Işık S. ve Sandalcı M., (2007). "Günlük Buharlaşmanın Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi", İMO Teknik Dergi, 271: 4119-4131.

[13] Durak, A., (2012). Konvektif bir kurutma prosesinin yapay sinir ağları ile modellenmesi, Yüksek Lisans Tezi, Namık Kemal Üniversitesi Makine Mühendisliği Anabilim Dalı, Tekirdağ.

[14] Ekonomou, L., (2010). "Greek long-term energy consumption prediction using artificial neural networks", Energy, 35(2): 512–517.

[15] Göltaş, C. ve İpek, N., (t.y.). "Türkiye'de Elektrik Sistemi ve Genel Politikalar", Elektrik Mühendisleri Odası Bildirisi, http://www.emo.org.tr/ekler/6c9908b7b1766f5_ek.pdf, 17 Mayıs 2019.

[16] Gurney, K., (1996). "Computers and Symbols Versus Nets and Neurons", UCL Draft Papers, 1, U.K.

[17] Güzel, Y., (2018), Yapay Zeka Ders Notları 03, Biyolojik Sinir Sistemi ve Yapay Sinir Ağı Hücresi, https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-03-biyolojik-sinir-sistemi-ve-yapay-sinir-a%C4%9F%C4%B1-h%C3%BCcresi-6555add68d80, 17 Mayıs 2019.

[18] Hamzaçebi, C. ve Kutay F., (2004). "Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini", Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 19(3): 227-233.

[19] Harrington, P.B., (1993). Transfer functions in artificial neural Networks. Center for Intelligent Chemical Instrument, Department of Chemistry, Ohio University, Athens, OH, 65: 2167-2168.

[20] Haykin, S., (1999). "Neural Networks-A Comprehensive Foundation", Prentice Hall, 2. Edition, New Jersey.

[21] Hinton, G.E., Osindero, S. ve Teh, Y.W., (2006). "A fast learning algorithm for deep belief nets", Neural computation, 18(7): 1527-1554.

[22] Hsu, C. ve Chen, C., (2002). "Regional load forecasting in Taiwan applications of artificial neural Networks", Energy Conversion and Management, 44(12): 1941-1949.

[23] Hu, C., (2002). "Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling", Doktora Tezi, Purdue University, MI,USA.

[24] Teiaş, Teiaş nedir, https://www.enerjiportali.com/turkiye-elektrik-iletim-anonim-sirketi-teias-nedir/, 15 Mayıs 2019.

[25] Elektrikport, Elektrik Dağıtım Şebekeleri, https://www.elektrikport.com/universite /elektrik-dagitim-sebekeleri/8703#ad-image-0, 15 Mayıs 2019.

[26] Epiaş, Dönemlik Piyasa Hacimleri, https://rapor.epias.com.tr/rapor/xhtml/donemlikPiyasa Hacim.xhtml, 15.05.2019.

[27] Teiaş, Yük Tevzi Bilgi Merkezi İstatistikleri, https://ytbsbilgi.teias.gov.tr/ytbsbilgi/frm_istatistikler.jsf Türkiye puant değerleri, 15 Mayıs 2019.

[28] Elektrikport, Elektrik Dağıtım Şebekeleri, https://www.elektrikport.com/teknik-kutuphane/elektrik-dagitim_sebekeleri/8703#ad-image-0, 17 Mayıs 2019.

[29] İlk Kim Buldu, Elektriğin icadı, https://www.ilkkimbuldu.com/elektrik-kim-buldu/, 17 Mayıs 2019.

[30] Jain, A.K., Mao, J. ve Mohiuddin, K.M., (1996). "Artificial neural Networks: A tutorial", Computer, 29(3): 31-44.

[31] Jayalakshmi T. ve Santhakumaran A., (2011). "Statistical Nor-malization and Back Propagation for Classification'', International Journal of Computer Theory and Engineering, 3(1): 1793-8201.

[32] Kabalcı, E., (2014). Yapay Sinir Ağları Ders Notları, https://ekblc.files.wordpress.com/2013/09/ysa.pdf, 17 Mayıs 2019.

[33] Karabulut, M., (2017). Elektrik Tüketim Tahmini için Bir Karar Destek Sistemi, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara.

[34] Kavaklıoğlu, K., Ceylan, H., Öztürk, H. K. ve Canyurt, O. E., (2009), "Modelig and Prediction of Turkey's Electricity Consumption Using Artifical Neural Networks" Energy Conversion and Management, 50:2719- 2727.

[35] Kaya, Y., (2010). Türk Telekomünikasyon A.Ş.'de Elektrik Tüketiminin Yapay Sinir Ağları ile Yerel Tahmini, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi FBE, İstanbul.

[36] Kaytez, F., (2012). En küçük kareler destek vektör makineleri ile Türkiye'nin uzun dönem elektrik tüketim tahmini ve modellemesi, Doktora Tezi, Gazi Üniversitesi FBE, Ankara.

[37] Kocadağlı, O., (2012). Genetik Algoritmalar ve Bulanık Üyelik Fonksiyonlarıyla Hibrit Bayes Yapay Sinir Ağları, Doktora Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi FBE, İstanbul.

[38] Kocadağlı, O. ve Aşıkgil, B., (2014). "Nonlinear time series forecasting with Bayesian neural networks", Expert System with Applications, 41(15): 6596-6610.

[39] Mandal, JK. ve Sansa, AK., (1995). "Application of Recurrent Neural Network for Short Term Load Forecasting in Electric Power System", International Conference on Neural Networks, 27 Nov.-1 Dec. 1995, Australia.

[40] Masaebi, P., (2016). Yapay Sinir Ağları ile İran Elektrik Tüketim Tahmini, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi FBE, Trabzon.

[41] Mathworks, Kodlar https://www.mathworks.com/products/matlab. html, 17 Mayıs 2019.

[42] MATLAB R2015b menüsü

[43] Özel, H., (2018), "MATLAB nedir?", https://medium.com/ @halilozel1903/matlab-nedir-91a904a74f45, 17 Mayıs 2019.

[44] Özpınar, A., (2007). "Yenilenebilir enerji santrallerinde yapay sinir ağları yöntemi ile enerji üretiminin modellenmesi ve planlanması, Doktora Tezi, Yıldız Teknik Üniversitesi FBE, İstanbul.

[45] Öztemel, E., (2003). "Yapay Sinir Ağları", 1. Baskı, Papatya Yayıncılık, İstanbul.

[46] Öztemel, E., (2012). "Yapay Sinir Ağları", 3. Baskı, Papatya Yayıncılık, İstanbul.

[47] Pao, H., (2006). "Comparing Linear and Nonlinear Forecasts for Taiwan's Electricity Consumption", Energy, 31(12): 2129-2141.

[48] Parlos, A.G., Oufi, E., Muthusami, J., Patton, A.D. ve Atiya, A.F., (1996). "Development of an intelligent long-term electric load forecasting system", Proc. Intl. Conf. on Intelligent Systems Applications to Power Systems, 288-292, 28 Jan.-2 Feb. 1996, USA.

[49] Rao, M.A ve Srinivas, J., (2003). "Neural Networks Algorithms and Appplications", Pangbourne England, Alpha Science International Ltd.

[50] Rojas, R., (2013). "Neural Networks: A systematic Introduction", Springer Science & Business Media.

[51] Rumelhart, D.E. ve Zipser, D., (1985). "Feature discovery by competitive learning", Cognitive science, 9(1): 75-112.

[52] Saygılı, Y., (2008). "İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülememesi", Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.

[53] Şen, Z., (2004). "Yapay Sinir Ağları İlkeleri", Su Vakfı Yayınları, İstanbul.

[54] Taşova, O., (2011). Yapay Sinir Ağları ile Yüz Tanıma, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi FBE, İzmir.

[55] Tutun, S., (2012). Yapay Zeka Teknikleri ile Elektrik Enerjisi Net Tüketim Tahmini Türkiye Örneği, Yüksek Lisans Tezi, Erciyes Üniversitesi FBE, Kayseri.

[56] Tutuş, A., (2006). "Türkiye'de Elektrik Enerjisinin Tarihsel Gelişimi ve Yeni Piyasa Düzeni İçerisinde Hidroelektrik Enerjisinin Yeri", TMMOB Su Politikaları Kongresi, 1: 318-330.

[57] Türkiye İstatistik Kurumu, Elektrik tüketim ve Türkiye nüfus verisi, http://www.tuik.gov.tr/PreTablo.do?alt_id=1029, 17 Mayıs 2019.

[58] Uğur, A. ve Kınacı, A.C., (2006). "Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması", XI. Türkiye'de İnternet Konferansı Bildirileri (iner-tr'06), 363-367 Ankara.

[59] Ülker, M. ve Civalek, Ö., (2002). "The Buckling Analysis of Axially Loaded Columns with Artificial Neural Networks", Turkish Journal of Engineering and Enviromental Sciences, 26(2): 117-126.

[60] Tokgöz, A., (2018). Recurrent Neural Network Based Approaches for Electricity Comsumption Forecasting, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.

[61] Türkiye Elektrik Enterkonnekte sistemi, Teiaş, https://www.teias.gov.tr/ sites/default/files/201806/2016%20TE%C4%B0A%C5%9E%20Faaliyet%20Raporu.pdf, 17 Mayıs 2019 .

[62] Voss, NJ. Ve Rientjes, THM., (1995). "Constraints of artificial neural networks for rainfall-runoff modelling: trade-offs in hydrological state representation

and model evaluation", Hydrology and Earth System Sciences Discussions, 2(1): 365-415.

[63] Yalçınöz, T., Herdem, S. ve Eminoglu, U., (2002). "Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini", http://www.emo.org.tr/ekler/f82db7535530637_ek.pdf, 10 Ocak 2019.

[64] Yavuz, S. ve Deveci. M., (2013). "İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi", Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 40: 167-187.

[65] Yetkin, M., (2015). Tanker- şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi FBE, İstanbul.

[66] Ying L.C. ve Pan M.C., (2008). "Using Adaptive Network Based Fuzzy İnference System to Forecast Regional Electricity Loads", Energy Conversation and Management, 49(2): 205-211.

[67] Yüksek G., Bircan H., Zontul M. Ve Kaynar O., (2008). "Sivas İlinde Yapay Sinir Ağları İle Hava Kalitesi Modelinin Oluşturulması Üzerine Bir Uygulama", Cumhuriyet Üniversitesi İktisadi ve Bilimler Dergisi, 8(1): 97-112.

Tezden Üretilmiş Yayınlar

İletişim Bilgisi: sedaturgut13@gmail.com

Konferans Bildirileri

1. Turgut S. ve Kemalbay G. (2019). Yapay Sinir Ağları İle Uzun Dönem Türkiye Elektrik Tüketim Tahmini, XI. Ibaness Kongreler Serisi, 9-10 Mart 2019, Tekirdağ-Türkiye.