



**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**

**OPTİMAL DOĞAL GAZ TÜKETİMİNİN TESPİTİNDE FARKLI
YAPAY SİNİR AĞI ALGORİTMALARININ KULLANIMI: SAMSUN
İLİ ÖRNEĞİ**

Yüksek Lisans Tezi

Bedia KANT

Danışman
Prof. Dr. Mehmet Serhat ODABAŞ

SAMSUN
2021

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI



**OPTİMAL DOĞAL GAZ TÜKETİMİNİN TESPİTİNDE
FARKLI YAPAY SINIR AĞI ALGORİTMALARININ
KULLANIMI: SAMSUN İLİ ÖRNEĞİ**

Yüksek Lisans Tezi

Bedia KANT

Danışman

Prof. Dr. Mehmet Serhat ODABAŞ

SAMSUN
2021

TEZ KABUL VE ONAYI

Bedia KANT tarafından, **Prof. Dr. Mehmet Serhat ODABAŞ** danışmanlığında hazırlanan “**Optimal Doğal Gaz Tüketiminin Tespitinde Farklı Yapay Sinir Ağı Algoritmalarının Kullanımı: Samsun İli Örneği**” başlıklı bu çalışma, jürimiz tarafından 28.1.2021 tarihinde yapılan sınav sonucunda oy birliği / oy çokluğu ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Danışman	Prof. Dr. Mehmet Serhat ODABAŞ Ondokuz Mayıs Üniversitesi Akıllı Sistemler Mühendisliği Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Aslı ÇALIŞ BOYACI Ondokuz Mayıs Üniversitesi Akıllı Sistemler Mühendisliği Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Nurettin ŞENYER Samsun Üniversitesi Yazılım Mühendisliği Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye			<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye			<input type="checkbox"/> Kabul <input type="checkbox"/> Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY
... / ... / ...
Prof. Dr. Ali BOLAT
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım yüksek lisans/doktora/sanatta yeterlik tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

02/03/ 2021
Bedia KANT

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : Optimal Doğal Gaz Tüketiminin Tespitinde Farklı Yapay Sinir Ağı Algoritmalarının Kullanımı: Samsun İli Örneği

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 18/12/2020 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 21

Tek kaynak oranı : % 4 çıkmıştır.

02/03/2021
Danışman Prof. Dr. Mehmet Serhat ODABAŞ

ÖZET

OPTİMAL DOĞAL GAZ TÜKETİMİNİN TESPİTİNDE FARKLI YAPAY SİNİR AĞI ALGORİTMALARININ KULLANIMI: SAMSUN İLİ ÖRNEĞİ

Bedia KANT

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Akıllı Sistemler Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Ocak/2021

Danışman: Prof. Dr. Mehmet Serhat ODABAŞ

Sosyal ve ekonomik hayatın vazgeçilmez unsurlarından olan doğal gaz enerjisi, yaşayışın sürekliliğinin sağlanabilmesi için kesintiye uğramaması gerekmektedir. Aynı zamanda doğal gaz enerjisi hem stratejik hem de ticari avantajları sebebiyle oldukça önemli bir konuma sahiptir. Yatırım maliyetlerinin yüksek olması, planlamanın ve tahminlemenin önemini daha da önemli hale getirmektedir.

Bu çalışmada Samsun ili için farklı yapay sinir ağları algoritmaları kullanılarak aylık doğal gaz tüketim tahmini için uygun modellerin bulunması amaçlanmıştır. 2009-2018 yılları arasında aylık doğal gaz tüketim verileri, konut ve serbest tüketici fiyatı, aylık ortalama aktüel basınç, aylık ortalama nispi nem, aylık ortalama rüzgâr hızı, aylık ortalama sıcaklık, ortalama güneşlenme süresi verileri kullanılıp farklı yapay sinir ağları yöntemi ile tahmin edilmesi planlanmaktadır.

Yapay sinir ağları tahmin yönteminin kullanılmasının amacı algoritmaların doğrusal olmayan verilerin modellenmesinde iyi sonuçlar vermesi ve birden fazla tahminin aynı anda yapılabilmesidir. Çalışmada genetik algoritma, parçacık sürü optimizasyonu, çok katmanlı algılayıcı, grup veri işleme yöntemi algoritmaları kullanılmıştır. Sırasıyla regresyon değerleri yapay sinir ağı için 0.94684, genetik algoritma için 0.91978, parçacık sürü optimizasyonu için 0.95609, çok katmanlı algılayıcı için 0.97528, grup veri işleme yöntemi için 0.87883 olarak bulunmuştur. Grup veri işleme yöntemini yönteminin Türkiye’de kullanıldığı herhangi bir çalışma bulunmamaktadır. Bu yöntem kullanılarak teze özgünlük kazandırılmıştır.

Ayrıca uygulama sırasında kullanılan yazılım programı MATLAB hakkında bilgiler verilmiştir.

Bu tezin birinci bölümünde teze giriş yapıp ikinci kısmında doğal gazın Dünya’daki Türkiye’deki piyasası anlatılmıştır. Üçüncü bölümde doğal gaz enerjisinin Samsun’daki yeri incelenmiştir. Dördüncü bölümde doğal gaz tahmininin literatür çalışmasına yer verilmiştir. Beşinci bölümünde talep tahmini kavramı anlatılıp, yöntemleri açıklanmıştır. Altıncı bölümde yapay sinir ağlarından bahsedilip, yedinci bölümde uygulamasına yer verilmiştir. Son olarak sekizinci bölümde sonuç kısmına yer verilmiştir.

Anahtar Sözcükler: yapay sinir ağı, talep tahmini, genetik algoritma, parçacık sürü optimizasyonu, grup veri işleme yöntemi, çok katmanlı algılayıcı

ABSTRACT

THE USE OF DIFFERENT ARTIFICIAL NERVE NETWORK ALGORITHMS IN DETERMINING OPTIMAL NATURAL GAS CONSUMPTION: SAMPLE OF SAMSUN

Bedia KANT

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Intelligent Systems Engineering

Master, January/2021

Supervisor: Prof. Dr. Mehmet Serhat ODABAŞ

Natural gas energy, which is one of the indispensable elements of social and economic life, should not be interrupted to ensure the continuity of life. At the same time, natural gas energy has a very important position due to both strategic and commercial advantages of it. The high investment costs make the importance of planning and forecasting even more important.

In this study, it is aimed to find suitable models for monthly natural gas consumption estimation by using different artificial neural network algorithms for Samsun province.

By using the data of monthly natural gas consumption, residential and free consumer prices, monthly average actual pressure, monthly average relative humidity, monthly average wind speed, monthly average temperature, average sunshine duration, it is planned to estimate with different artificial neural networks method between 2009 and 2018.

The purpose of using artificial neural networks prediction method is that algorithms give good results in modeling nonlinear data and more than one estimation can be made simultaneously.

In the study, genetic algorithm, particle swarm optimization, multi-layer perceptron, group method of data handling algorithms have been used. Regression values were found as 0.94684 for artificial neural network, 0.91978 for genetic algorithm, 0.95609 for particle herd optimization, 0.97528 for multi-layer perceptron, and 0.87883 for group data processing method, respectively. Group method of data processing does not have any work in Turkey. Using this method, the thesis has been given originality.

In addition, information has been given about the software program MATLAB, which was used during the technic.

In the first section of this thesis, there is an introduction to the thesis and in the second part of it, natural gas market has been described in the world and Turkey. In the third section, the place of natural gas energy in Samsun has been examined. In the fourth section, the literature study of natural gas estimation has been given. In the fifth section, the concept of demand forecasting has been described and its methods have been explained. In the sixth section, artificial neural networks have been mentioned and in the seventh section its application has been given. Finally, in the eighth section, the conclusion part has been given.

Keywords: artificial neural network, demand forecasting, genetic algorithm, particle swarm optimization, group method of data handling, multilayer perceptron

ÖNSÖZ VE TEŞEKKÜR

Tez yazım çalışmalarım boyunca yardımlarını esirgemeyen danışman hocam Sayın Prof. Dr. Mehmet Serhat Odabaş' a teşekkürlerimi sunarım.

Tez kapsamında kullanılan ver kümesi için SAMGAZ ve Samsun Meteoroloji 10. Bölge Müdürlüğü'ne teşekkür ederim.

Hayatımın boyunca desteklerini hep yanımda hissettiğim, bugün geldiğim noktada en büyük paya sahip olan aileme, manevi destekleriyle yanımda olan arkadaşlarıma teşekkür ederim.

Bedia KANT

İÇİNDEKİLER

1. GİRİŞ	1
2. DOĞAL GAZ	3
2.1. Doğal Gaz Piyasası.....	3
2.1.1. Dünya’da Doğal Gaz Piyasası	4
2.1.2. Türkiye’de Doğal Gaz Piyasası	5
3. DOĞAL GAZ ENERJİSİNİN SAMSUN’DAKİ YERİ	11
4. DOĞAL GAZ TAHMİNİNİN LİTERATÜR İNCELENMESİ	12
5. TALEP TAHMİNİ	19
5.1. Talep Tahmini Aşamaları	19
5.2. Talep Tahmin Yöntemleri	20
5.2.1. Zaman Serisi Analizi	21
5.2.1.1. Box-Jenkins Yöntemi.....	21
5.2.1.2. Trend Analizi	22
5.2.1.3. Basit Ortalama Yöntemi.....	22
5.2.1.4. Hareketli Ortalamalar Yöntemi.....	22
5.2.1.5. Üstel Düzeltmeler Tekniği	23
5.2.2. Yapay Zekâ ve Sezgisel Algoritmalar	23
5.2.2.1. Genetik Algoritmalar	24
5.2.2.2. Destek Vektör Makineleri	24
5.2.2.3. Yapay Sinir Ağları	25
6. YÖNTEM	26
6.1. Yapay Sinir Ağları.....	26
6.1.1. Yapay Sinir Ağlarının Tanımı	27
6.1.2. Yapay Sinir Ağları Tarihçesi	29
6.1.3. Yapay Sinir Ağlarının Genel Özellikleri	30
6.1.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları.....	32
6.1.5. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	34
6.1.5.1. Biyolojik Sinir Hücreleri.....	34
6.1.5.2. Yapay Sinir Hücresi	35
6.1.5.3. Yapay Sinir Ağları Mimarileri.....	37
6.1.6. Yapay Sinir Ağları Öğrenme Stratejisi.....	39
6.1.6.1. Gözetimli (Öğretmenli) Öğrenme Yöntemi.....	39
6.1.6.2. Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi.....	40
6.1.6.3. Destekleyici Öğrenme Yöntemi.....	41
6.2. Genetik Algoritma	41

6.2.1. Genetik Algoritma Akış Diyagramı.....	42
6.2.2. Genetik Algoritma Parametreleri.....	43
6.2.2.1. Seçilim	43
6.2.2.2. Çaprazlama.....	43
6.2.2.3. Mutasyon.....	44
6.3. Parçacık Sürü Optimizasyonu	45
6.3.1. Parçacık Sürü Optimizasyonu Akış Diyagramı	46
6.3.2. Parçacık Sürü Optimizasyonu Parametreleri	47
6.3.2.1. Sürünün Büyüklüğü	47
6.3.2.2. Yineleme Sayısı	47
6.3.2.3. Bilişsel ve Sosyal Bileşenler	47
6.3.2.4. En Yüksek Hız	47
6.4. Çok Katmanlı Algılayıcı	47
6.5. Grup Veri İşleme Yöntemi (GMDH)	48
7. TALEP TAHMİNİ UYGULAMASI.....	50
7.1. Yapay Sinir Ağı Probleminin Tanımlanması	50
7.2. MATLAB Hakkında Genel Bilgi	50
7.3. Yapay Sinir Ağının Eğitilmesi ve Test Edilmesi	51
7.4. Yapay Sinir Ağı Uygulaması ve Matlab Kullanımı	53
7.4.1. Yapay Sinir Ağı İle Çözümü	54
7.4.2. Genetik Algoritma ile Çözümü.....	57
7.4.3. Parçacık Sürü Optimizasyonu (PSO) İle Çözümü.....	60
7.4.4. Çok Katmanlı Algılayıcılar (ÇKA) İle Çözümü.....	62
7.4.5. Grup Veri İşleme Yöntemi (GMDH) İle Çözümü.....	64
8. SONUÇ	68
KAYNAKLAR	71
ÖZ GEÇMİŞ.....	74

ŞEKİLLER DİZİNİ

Şekil 2.1. Dünya Rezerv Miktarları (m^3)	5
Şekil 2.2. 2007-2019 yılları arasında üretilen doğal gaz miktarları	7
Şekil 2.3. Türkiye'de yapılması planlanan doğal gaz boru hattı	9
Şekil 2.4. Serbest tüketici ve abone sayısının toplam kullanıcı üzerine etkisi.....	10
Şekil 5.1. Talep tahmin yöntemleri	20
Şekil 5.2. Örnek satış eğilim grafiği.....	22
Şekil 5.3. Genetik algoritmanın temel prensipleri	24
Şekil 6.1. İlk insan sinir hücresi	28
Şekil 6.2. Geleneksel yöntemler ve yapay sinir ağlarının karşılaştırılması	29
Şekil 6.3. Biyolojik sinir hücresi.....	34
Şekil 6.4. Yapay sinir ağı modeli.....	35
Şekil 6.5 Tek katmanlı ileri beslemeli yapay sinir ağı	38
Şekil 6.6. Çok katmanlı ileri beslemeli yapay sinir ağı	39
Şekil 6.7. Gözetimli öğrenme.....	40
Şekil 6.8. Gözetimsiz öğrenme	40
Şekil 6.9. Destekleyici öğrenme.....	41
Şekil 6.10. Genetik algoritma akış diyagramı.....	42
Şekil 6.11. Çaprazlama işlemcisi temel süreci.....	44
Şekil 6.12. Mutasyon işlemcisi temel süreci.....	45
Şekil 6.13. Parçacık sürü optimizasyonu akış diyagramı.....	46
Şekil 6.14. Çok katmanlı algılayıcı topolojik yapısı	48
Şekil 7.1. Yapay sinir ağı eğitim aşaması	52
Şekil 7.2. Kullanılan yapay sinir ağı modeli	54
Şekil 7.3. Yapay sinir ağı eğitim sonuçları	55
Şekil 7.4. Yapay sinir ağı doğrulama sonuçları	55
Şekil 7.5. Yapay sinir ağı test sonuçları.....	56
Şekil 7.6. Genetik algoritma optimizasyon ağırlığı	57
Şekil 7.7. Genetik algoritma tahmin edilen ve gerçek eğitim veri ilişkisi	58
Şekil 7.8. Genetik algoritma eğitim sonuçları.....	58
Şekil 7.9. Genetik algoritma tahmin edilen ve gerçek test veri ilişkisi.....	59
Şekil 7.10. Genetik algoritma test sonuçları	59
Şekil 7.11. PSO ile tahmin edilen ve gerçek eğitim veri ilişkisi.....	60
Şekil 7.12. Parçacık sürü optimizasyonu eğitim sonuçları	61
Şekil 7.13. PSO ile tahmin edilen ve gerçek test veri ilişkisi	61
Şekil 7.14. Parçacık sürü optimizasyonu test sonuçları	62
Şekil 7.15. Çok katmanlı algılayıcı eğitim sonuçları	63
Şekil 7.16. Çok katmanlı algılayıcı doğrulama sonuçları	63
Şekil 7.17. Çok katmanlı algılayıcı test veri sonuçları.....	64
Şekil 7.18. GMDH eğitim verileri sonuçları.....	65
Şekil 7.19. GMDH test verileri sonuçları.....	65
Şekil 7.20. GMDH regresyon sonuçları.....	66

TABLolar DİZİNİ

Tablo 2.1. Bölgelere göre Türkiye'de çıkarılan doğal gaz miktarları	6
Tablo 2.2. 2007-2019 yılları arası doğal gaz üretim miktarları (m3).....	6
Tablo 2.3. 2013-2018 yılları arasında doğal gaz ithalatı gerçekleştiren şirketlerin payları	7
Tablo 2.4. Sektörel bazda doğal gaz tüketim miktarları	10
Tablo 3.1. Doğal gazın yıllara göre sektörlerde kullanım miktarları	11
Tablo 4.1. Doğal gaz tüketim tahmini literatür taraması	16
Tablo 6.1. Çeşitli sinir ağı modellerinin kuvvetli ve zayıf yönleri	33
Tablo 6.2. Biyolojik sinir sistemi ile YSA'nın benzerlikleri.....	35
Tablo 6.4. Grup veri işleme yöntemi algoritmaları.....	49
Tablo 7.1. Doğal gaz tüketimi veri seti üzerinde yapılan yapay sinir ağları ile tahmin değerleri.....	56
Tablo 7.2. Doğal gaz tüketimi veri seti üzerinde yapılan çok katmanlı algılayıcı ile tahmin değerleri	64
Tablo 7.3. Doğal gaz tüketim verileri üzerinde grup veri işleme yöntemi değerleri .	66
Tablo 8.1. Algoritma sonuçları R ² değerleri	69

1. GİRİŞ

Yer kabuğunun içinde bulunan doğal gaz karbon temelli bir fosil yakıttır. Günümüzde petrolden sonra ekonominin en değerli ve en stratejik hammaddesinden birisi haline gelmiştir. Doğal gaz arzında herhangi bir aksama yaşandığı zaman ekonominin olumsuz etkilendiğini görmekteyiz. Petrolün çevreye verdiği zarar ve pazarındaki düzensizlikler sebebiyle, doğal gaz petrole alternatif kaynaklar arasında ilk sırada yer almaktadır. Çevreyi kirletmemesi, havadan daha hafif olması ve taşıma kolaylığı ile doğal gaza olan talep her geçen gün artmaktadır. Evlerde ve endüstride karbon ve kükürt oksit gibi havayı kirleten atık maddeleri açığa çıkarmadığı için daha çok tercih edilmektedir. Daha çok tercih edilmesinin bir diğer sebebi de kalorifer yakıtı olarak kullanılmak istendiği zaman herhangi bir ön hazırlık ve depolama gerektirmemesidir (Kuru, 2014).

Enerji Bakanlığının 2018 yılı verilerine göre doğal gaz rezervinin %38,4'ü (75,5 trilyon metreküp) Orta Doğu ülkelerinde, %33,9'ü (66,7 trilyon metreküp) Avrupa ve Avrasya ülkelerinde, %16,5'i (32,5 trilyon metreküp) Afrika/ Asya Pasifik ülkelerinde bulunmaktadır. 2018 yılında ülkemizde 48,9 milyar metreküp doğal gaz tüketimi gerçekleşmiştir.

Doğal gaz üretimi Dünyada Antartika dışında hemen hemen bütün kıtalarda gerçekleşmektedir. En büyük doğal gaz üreticisi Rusya ve İran'dır. Bu ülkeleri ABD, Kanada, Hollanda takip etmektedir.

Doğal gaz Türkiye 'de ilk defa Kırklareli'nde 1970 yılında keşfedilmiştir. Pınarhisar Çimento fabrikasında 1976 yılında tüketilen doğal gaz, 1948'de SSCB ile yapılan doğal gaz ithalatı anlaşması sonucu enerji ihtiyacımızın önemli bir kısmını karşılıyor hale gelmiştir. Doğal gaz piyasası oluşturulması yolunda 2001 yılında 4646 sayılı Doğal Gaz Piyasası Kanunu oluşturulmuş, iletim, depolama, ithalat, ihracat, toptan satış, gibi faaliyetlerin lisansının alınması zorunlu hale getirilmiştir.

Günümüzde ülkemizde az üretilen ve %99'unu dışarıdan ithal ettiğimiz doğal gazın tüketiminin tahmin edilmesi son derece önemli bir noktadadır. Talep tahminin doğru yapılması, yurtdışından gaz alımı ile ilgili anlaşmaları, sektöre yönelik yapılacak yatırımları ve buna bağlı olarak sektörün gelişimini etkileyecek etkenlerden birini oluşturur. Bilindiği üzere doğal gaz tüketiminin doğru tahmin edilmesi hem gaz dağıtıcıları hem de tüketicileri açısından önemlidir. Doğal gaz

dađıtıcısı aısından incelendiđinde dođru tahmin deđerleri sistemde oluřabilecek hataları azaltır ve gaz dađıtım limitlerinin dođru řekilde dzenlenmesini sađlar. Talep tahmini ne kadar dođru yapılırsa, planlama alıřmaları da olumlu sonu gsterecektir. Bylece gaz sistemleri ok daha tutarlı bir hale gelir. Ayrıca tketicisi aısından bakıldıđı zaman dođru tahmin deđerleri tketim miktarını azaltır.

2. DOĞAL GAZ

Doğal gazın ne olduğu bilinmeden önce insanlar gizemli bir olay olarak görmüştür. Yeraltında bulunan gaz sızıntılarının şimşek çakmasıyla birlikte yanmaya başlaması birçok insanları hayrete düşürmüş ve birçok batıl inancın başlamasına sebep olmuştur. Bu alevlerden M.Ö. 500 yıllarında Çinliler faydalanmaya başlamışlardır. Gaz sızıntılarının olduğu bölgeleri belirleyerek bambudan elde edilen borularla gazı farklı bölgelere taşımışlardır (Beşergil, 2009).

Doğalgazın oluşumu, petrolün oluşum sürecinden biraz farklıdır. Bitki ve hayvan kalıntıları gibi organik maddelerin üstüne zaman geçtikçe yer tabakalarının yığılmasıyla birlikte oluşan havasız ortamda uygun basınç, ısı ve bakterilerin çürümesi ile birlikte milyonlarca yıl bekleyen, yer altında doğal radyoaktivite yardımıyla ısınan organik kütle yer altından daha derine çökmesiyle daha fazla ısınacağından doğal gaz oluşur. Daha derine çökemeyen organik kütlede meydana gelen gaza kaya gazı (shale gas) denir (Yılmaz, 2014).

Kömür yataklarından elde edilen doğal gaz evleri ve sokakları aydınlatmak amacıyla ilk olarak Britanya’da (1795) ve daha sonra Amerika’da (1816) kullanılmaya başlandı. Ancak kömürden elde edilen doğal gaz yer altı kaynaklarında doğal olarak oluşan doğal gaz gibi verimli değildir ve çevreyi olumsuz etkileyen bir yakıttır.

1891 yılında boru hatlarıyla doğal gaz taşımacılığı başladı. Bununla birlikte ev, sanayi, iş yerleri, elektrik üretimi gibi birçok alanda kullanımı yayıldı. Doğal gaz güvenli taşıma ve depolama yöntemleri ile popüler bir enerji kaynağı olmuştur (Beşergil, 2009).

2.1. Doğal Gaz Piyasası

Doğal gaz, günümüzde stratejik ve ticari avantajları nedeniyle önemli bir enerji kaynağıdır. Ülkeler arasında doğal gaz arz ve talebini oluşturan sözleşmeler olduğu gibi her ülkenin kendi bünyesinde doğal gaz ticaretini ve dağıtımını belirleyen düzenlemeleri bulunmaktadır (Taşkıner, 2018).

Dünya’da birçok ülke ilk petrol krizinin ardından doğal sektöründe yaşanan talep talep patlaması sebebi ile doğal gaz enerjisi üzerine yoğunlaşmışlardır. Üretim ve tüketim adına birçok plan ve politika arayışına girilmesi doğrultusunda doğal gaz

enerjisi bu zamana kadar gelişimini sürdürmüş ve sürdürmeye devam etmektedir (Oruç ve Eroğlu, 2017).

19. yüzyılın ortalarından itibaren ABD’de enerji kaynağı olarak kullanılan doğal gaz, 40-50 sene önce gereksiz sayılıp dünyada geniş bir kullanımı yoktu. Ancak 1973 yılında gerçekleşen ilk doğal gaz krizi sonrası önem kazanmıştır. Doğal gaz günümüzde 70’den fazla ülkede üretilmektedir (Mazak, 2004)

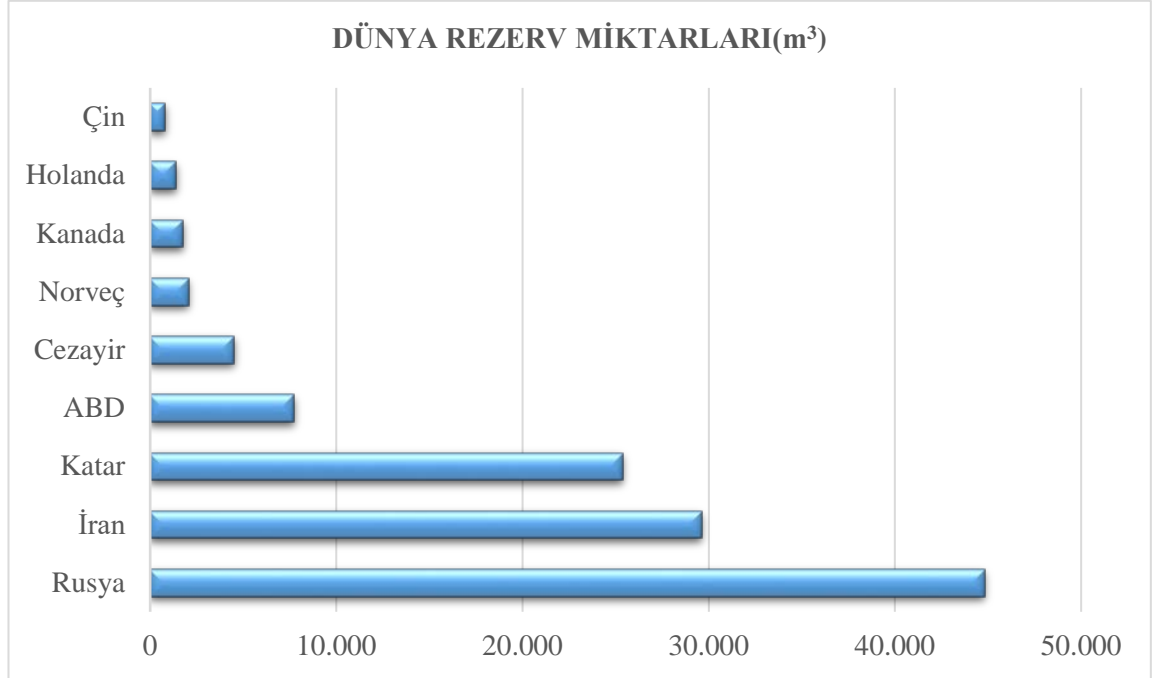
2.1.1. Dünya’da Doğal Gaz Piyasası

MÖ 6000-2000 yılları arasında ilk doğal gaz sızıntısı İran’da ortaya çıkmıştır. Doğal gazın yakıt olarak kullanılmaya başlanması M.Ö. 900’lü yıllarda Çin’de gerçekleşmiştir. Çin’de su ısıtma amacıyla kullanıldığı düşünülen doğal gazı kokusuz ve renksiz olmasından dolayı “hayalet” olarak tanımlamışlardır. Kayıtlarda M.Ö. 50 yıllarında günümüz Irak topraklarında yer alan çatlaklardan sızan doğal gazın yakıldığı bilgisine ulaşılmaktadır. Çinliler doğal gazı bir enerji türü olarak ilk defa tuz kurutma işinde kullandılar.

17. yüzyıla gelince Avrupa’da doğal gazla tanışmıştır. 1659 yılında ilk doğal gaz İngiltere’de bulunmuştur. 17. Yüzyılda İtalyanlar doğal gazı ısınma ve aydınlanma amacıyla kullanmışlardır. İtalyan bilim adamı olan Lazzaro Spallanzani diğer bilim adamlarının türettiği gaz teriminden esinlenerek “doğal gaz” ismiyle adlandırmıştır. Amerika’da ise ilk doğal gazın bulunması 1815 yılında gerçekleşmiştir. Keşfinden 5 yıl sonra da ilk ticari gaz işletmeciliği New York eyaletinde yapılmıştır (Mazak,2015).

Dünyanın en büyük doğal gaz rezervine sahip Rusya 2011 yılı BP istatistiki verilerine göre 44,8 trilyon metreküp kanıtlanmış rezerve sahiptir. Bu oran bütün dünya rezervlerinin %24’üne denk gelmektedir. İran Rusya’dan sonra Dünyanın en büyük ikinci doğal gaz rezervine sahip ülkesidir. 29 trilyon 610 milyar metreküp kanıtlanmış rezerve sahip olan İran’ın doğal gaz ihracatı dünyadaki ihracat oranının %1’ini aşmamaktadır. Cezayir 4 trilyon 502 milyar metreküp ile kanıtlanmış doğal gaz rezervine sahiptir. Avrupa Birliğinin ihtiyacının %25’ini Cezayir karşılamaktadır. Hollanda 1 trilyon 387 milyar metreküp kanıtlanmış rezerve sahiptir. Hollanda doğal gaz üretiminin büyük bir kısmını kıyı kuyularından elde etmektedir. İn 800 milyar metreküp kanıtlanmış rezerve sahiptir. Çin hükümeti doğal gazın bir kısmını ithal ederken kaya gazı üretimi için gereken yasal işlemleri

tamamlamıştır. Norveç 2 trilyon 39 milyar metreküp kanıtlanmış rezerve sahiptir. Kendi ihtiyacının 16 katı fazla üretim yapan Norveç arta kalan gazın tamamını Avrupa'ya ithal etmektedir (Salih,2012).



Şekil 2.1.Dünya Rezerv Miktarları (m³)

Dünya enerji tüketimi 2016 yılında 13258 mtpe iken 2017 yılında 13511 mtpe ulaşmıştır. Bunun %34,2'si petrol, %23,4'ü doğal gaz, %27,6'sı kömür olmak üzere %85,2'si fosil kaynaklardan, %4,4'ü nükleer enerji, %6,8'i hidrolik, % 3,6'sı yenilebilir enerjiden sağlanmaktadır. 85 mtpe ile 2017 yılında 2016 ya göre artıştaki en büyük katkıyı doğal gaz yapmıştır (Wec, 2019).

2.1.2. Türkiye'de Doğal Gaz Piyasası

Türkiye'de ilk doğal gaz kullanımı 1970 yılında Kırklareli'nde gerçekleşmiştir. Şehir içi kullanımı Ankara ile başlamış olup, sırayı İstanbul, Bursa, Eskişehir izlemiştir. Doğal gazın ilk defa kullanılmaya başladığı bu zamanlarda doğal gaz faaliyetleri BOTAŞ ve belediyeler tarafından gerçekleştirilmekteydi. 2001 yılında 4628 sayılı Enerji Piyasası Düzenleme Kurumunun Teşkilat ve Görevlerini düzenleyen Kanunu'nun resmi gazetede yayınlanmasıyla Enerji Piyasası Düzenleme Kurumu (EPDK) kurulmuştur. Günümüzde de hala doğal gaz piyasasına dair düzenlemeler EPDK tarafından devam ettirilmektedir (Taşkın, 2018).

Türkiye’de 1986 yılında doğal gaz taşımacılığının ve ticaretinin ilk adımı BOTAŞ tarafından SSCB şirketi ile 25 yıllık yapılan gaz alımı anlaşmasıyla atılmıştır. İlk doğal gaz ithalatı fiili olarak 1987 yılında gerçekleşmiştir.

Cezayir ile 1988 yılında LNG alım anlaşması imzalanmış olup, Marmara Ereğlisi LNG Terminali 1994 yılında devreye girmiştir. 1995 yılında ikinci LNG alım anlaşması Nijerya ile imzalanmıştır. Ülkeye yeni arz kaynakları kazandırmak adına 1996 yılında İran ile anlaşma imzalanmıştır. Mavi Akım Hattı için 1997 yılında, ilk doğal gaz ithalatı yapılan Batı Hattı için 1998 yılında Rusya ile anlaşma imzalanmıştır. Arz kaynakları genişletilerek 2001 yılında Azerbaycan ile doğal gaz alım anlaşması imzalanmıştır.

4646 sayılı Doğal Gaz Piyasası Kanunu Resmi Gazete ’de 2001 yılında yayımlanıp Türkiye’nin doğal gaz piyasasının liberalleşmesi adına ciddi bir adım atılmıştır. BOTAŞ’ın piyasadaki payının azaltılarak piyasanın serbestleşmesi adına bir diğer adım atılmıştır (Yıkılmaz, 2015).

Türkiye’de 2018 yılı itibariyle 49.328,93 milyon m³ doğal gaz tüketimi gerçekleşmiştir. Bu tüketimin 428,17 milyon m³ lük kısmı ülkemizde bulunan rezervlerden karşılanmıştır. EPDK’dan alınan verilere göre Türkiye’de çıkarılan doğal gazın bölgelere göre dağılımı aşağıda bulunan tablodaki gibidir (EPDK, 2018)


Tablo 2.1. Bölgelere göre Türkiye’de çıkarılan doğal gaz miktarları

İLLER	MİKTAR (milyon m ³)
TEKİRDAĞ	176,39
İSTANBUL	156,6
ÇANAKKALE	43,51
KIRKLARELİ	40,75
DÜZCE	8,45
ADANA	1,76
ADİYAMAN	0,63
EDİRNE	0,05
HATAY	0,03
GENEL TOPLAM	428,17

2018 yılında doğal gaz üretimi, 2017 yılına göre %20,9 oranında bir artış göstermiştir. Yıllara göre değişimi aşağıdaki gibidir (EPDK,2018)

Tablo 2.2. 2007-2019 yılları arası doğal gaz üretim miktarları (m3)

Yıllar	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2018	2019
Miktar	874	969	684	682	759	632	537	479	381	367	354	428



Şekil 2.2. 2007-2019 yılları arasında üretilen doğal gaz miktarları (EPDK sektör raporlarından derlenmiştir.)

Türkiye kullandığı doğal gazın %99'unu yurtdışından ithalat yapabilme lisansına sahip şirketler tarafından karşılamaktadır. Türkiye 2018 yılında doğal gaz ithalatını Rusya, İran, Azerbaycan, Cezayir, Nijerya'dan toplamda 50.361 milyon m³ yapmıştır. Doğal gaz ithalatı LNG ve boru gazı olmak üzere 2 şekilde yapılmaktadır. Aşağıdaki çizelgede yıllara göre doğal gaz ithalat miktarları gösterilmektedir.

Tablo 2.3. 2013-2018 yılları arasında doğal gaz ithalatı gerçekleştiren şirketlerin payları (EPDK, 2018)

Gazın Türü	BORU GAZI		LNG		TOPLAM
	Miktar (milyon m ³)	Pay (%)	Miktar (Milyon m ³)	Pay(%)	Miktar (milyon m ³)
Yıllar					
2013	39.419	87	5.849	12	45.268
2014	41.981	85	7.280	14	49.262
2015	40.778	84	7.648	15	48.427
2016	38.724	83	7.627	16	46.352
2017	44.484	80	10.765	19	55.249
2018	39.032	77	11.328	22	50.360

EPDK verilerine göre 2018 yılında toptan satış lisansı bulunan şirketlerce ülkemizde üretilerek satışa sunulan doğal gazın toplam miktarı 428,17 milyon Sm³'tür. Türkiye'de doğal gaza olan talebin her geçen gün artması ancak yurt içi üretim miktarlarının ve rezervlerin bu talebe karşılık verememesi doğal gaz ithalatını zorunlu kılmaktadır. Mevcut doğal gaz arzının %0,84'ü ülkemizde üretilen doğal

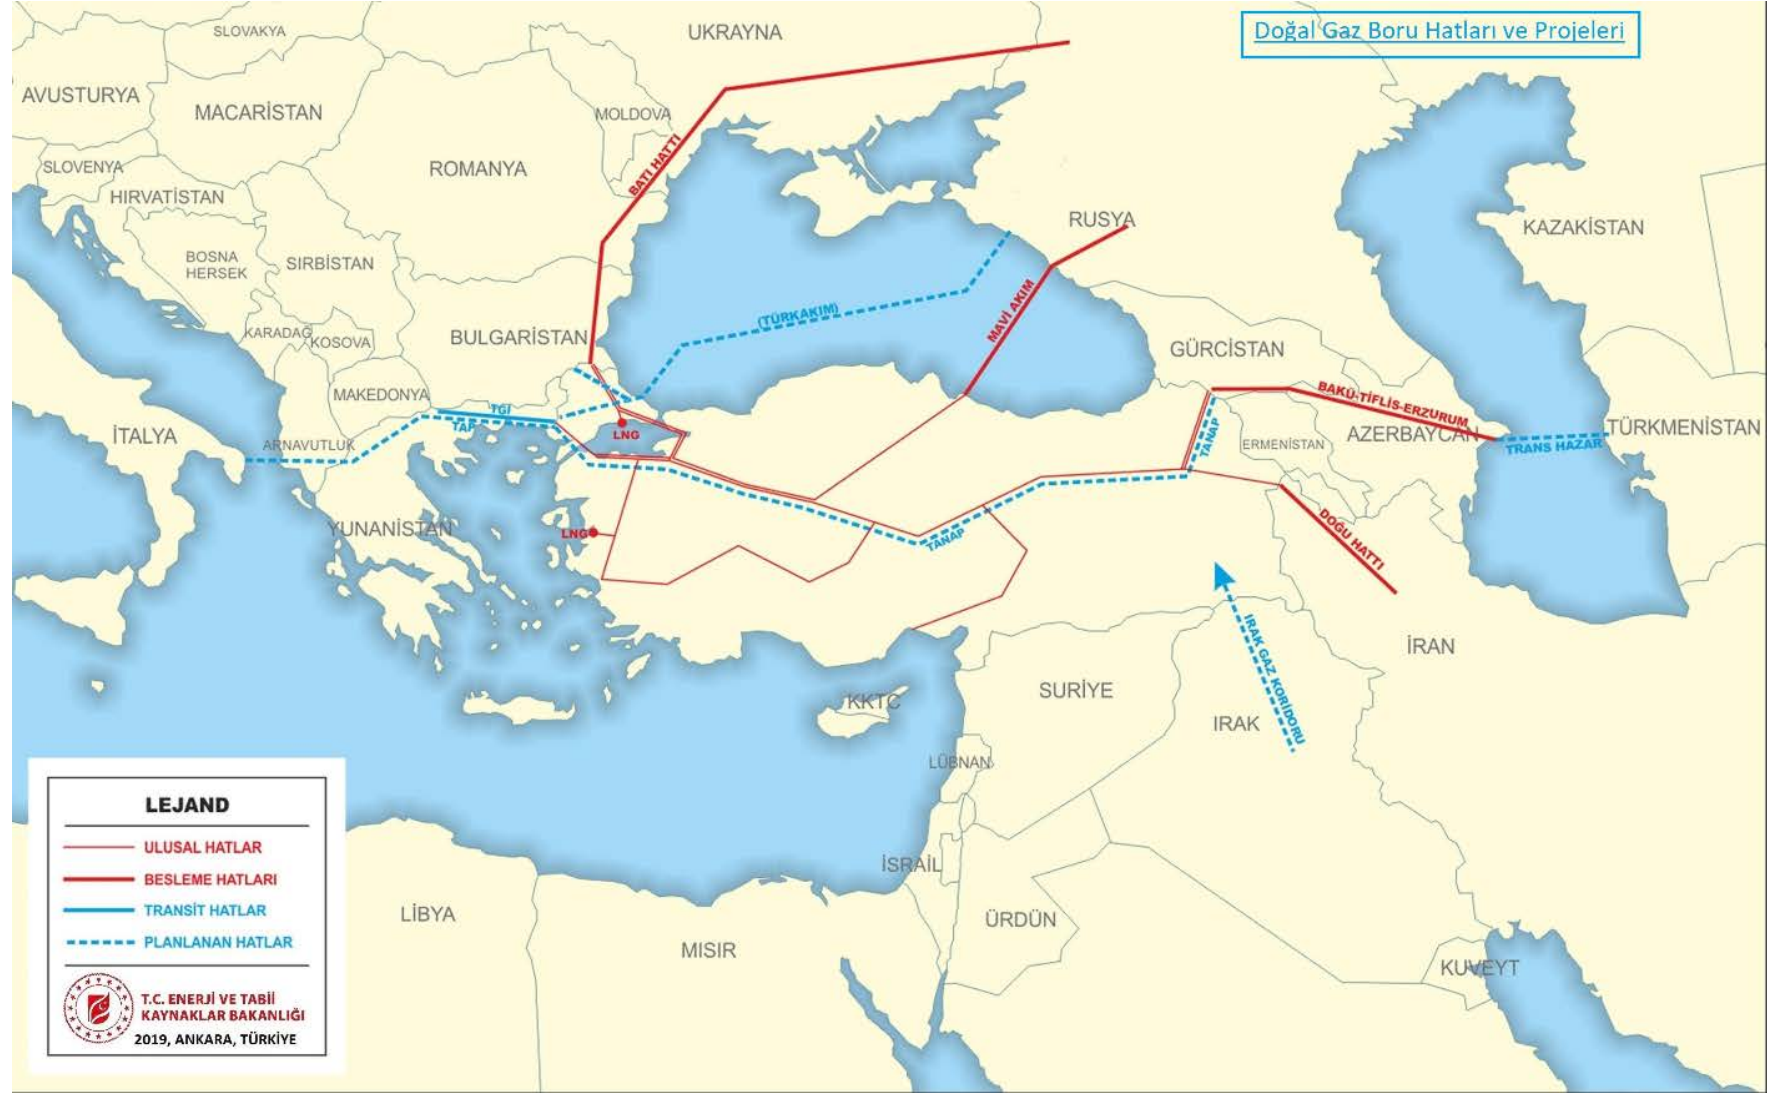
gazdan temin edilirken %99,16 'lık büyük bir kısım ithalat lisansı sahibi şirketler tarafından karşılanmıştır.

Ülkemizde doğal gaz ithalatı yoğunlukla BOTAŞ tarafından gerçekleştirilmektedir. Ancak EPDK lisansına sahip şirketler tarafından da ithalat gerçekleştirilebilir (EPDK, 2018).

Ülkemizin doğal gaz arzının sağlandığı uluslararası 4 tane hat bulunmaktadır.

- İran-Türkiye Doğal Gaz Boru Hattı: 8 Ağustos 1996 tarihinde BOTAŞ ile İran Ulusal Gaz Şirketi (NIGC) arasında 9,6 milyar m³ gaz alımı ile anlaşma sağlanmıştır. Doğu Beyazıt'tan başlayıp, Kars, Erzurum, Sivas yolunu izleyerek Ankara'ya ulaşan hat ile ülkemize doğal gaz iletimi sağlanmıştır. Seydişehir'e Kayseri ve Konya üzerinden bu hat ile doğal gaz sağlanmaktadır.
- Batı Hattı (Rusya Türkiye Doğal Gaz Hattı): Türkiye ve SSCB arasında 18 Eylül 1984 tarihinde imzalanmıştır. 845 km uzunluğundaki hat Haimtabat, Ambarlı, İstanbul, İzmit, Bursa, Eskişehir ve Ankara yolunu takip etmektedir. Bu hattın 10 milyar m³ özel şirketler, 4 milyar m³ BOTAŞ'tan olmak üzere toplamda 14 milyar m³ gaz alımı sağlanmaktadır.
- Bakü Tiflis Erzurum Doğal Gaz Boru Hattı (BTE): 12 Mart 2001 tarihinde SOCAR ve BOTAŞ arasında 6,6 milyar m³ doğal gaz alımı için anlaşma imzalanmıştır. Bu anlaşma ile oluşturulan hattın uzunluğu 690 km ve 20 milyar m³ kapasiteye sahiptir.
- Mavi Akım (Rusya Türkiye Doğal Gaz Hattı): 15 Aralık 1997 tarihinde BOTAŞ ve Gazexport arasında imzalanan anlaşma ile yılda ithal edilen gaz miktarı yılda 16 milyar m³'tür. Hattın uzunluğu 871 km olup, Samsun'dan başlayıp Ankara'ya kadar uzanmaktadır (Taşkiner, 2018).

Şekil 2.3'te Türkiye'de ki mevcut ve yapılması planlanan doğal gaz boru hatları gösterilmektedir.



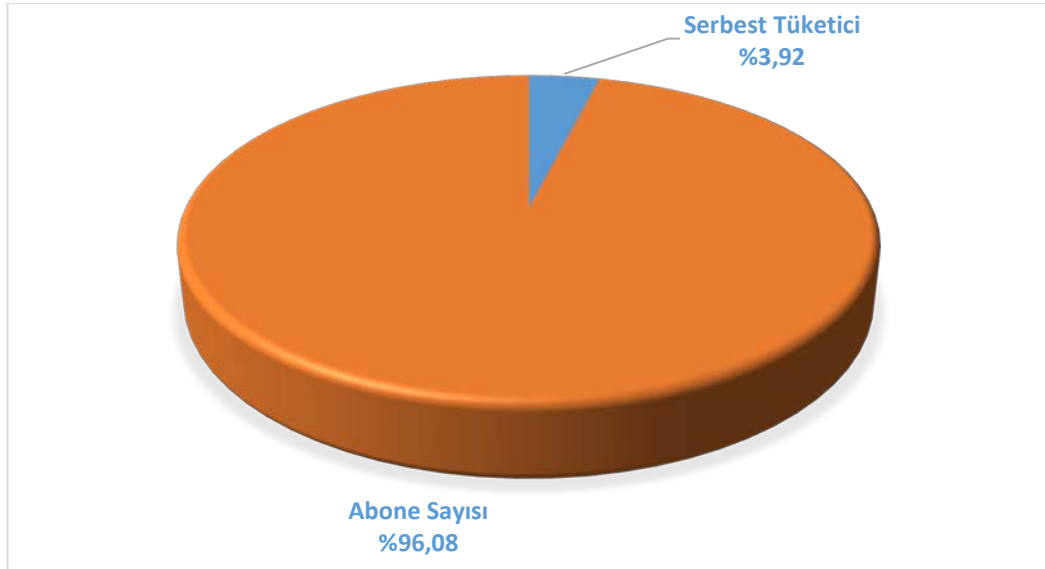
Şekil 2.3. Türkiye'de yapılması planlanan doğal gaz boru hattı

Türkiye'nin 2018 yılı sonu itibariyle depolarında bulunan stok miktarı 3.167,28 milyon m³'tür. Fiili yer altı depolama kapasitesinde 2017 yılına göre %6,27 oranında artış gerçekleşmiştir. Türkiye'de doğal gaz hizmeti sağlanan toplam abone sayısı 2018 yılı sonu itibariyle 14.755.011'e ulaşmıştır. Serbest tüketici sayısı 601.348 abone varken konut abone sayısı 14.752.452'dir. Doğal gaz tüketim miktarları sektör bazında aşağıdaki gibidir.

Tablo 2.4. Sektörel bazda doğal gaz tüketim miktarları

Sektör	2017 (milyon m3)	2018 (milyon m3)
Dönüşüm Sektörü	20.536,52	18.197,51
Enerji Sektörü	2.056,51	1.735,04
Ulaşım Sektörü	529,42	430,5
Sanayi Sektörü	14.372,13	11.987,95
Hizmet Sektörü	3.725,76	4.043,15
Konut	13.514,94	12.701,85
Diğer Sektörler	121,86	232,93
Genel Toplam	53.857,14	49.328,93

2018 yılı itibariyle serbest tüketici ile abone sayısının toplam kullanıcı üzerindeki etkisi aşağıda gösterilmektedir.



Şekil 2.4. Serbest tüketici ve abone sayısının toplam kullanıcı üzerine etkisi

3. DOĞAL GAZ ENERJİSİNİN SAMSUN'DAKİ YERİ

Doğal gaz doğal olaylar sonucu yer kabuğundan sızarak oluşmaya başlayıp, Dünya'da ve ülkemizde günümüzün en ekonomik, en verimli, en temiz ve en konforlu kullanımını sağlayan enerji kaynağı halini almıştır. Türkiye'de ilk defa 1988 yılında Ankara'da kullanılmaya başlayan doğal gazın 1990'lı yıllara kadar çoğu ile iletimi sağlanmış ve kullanılmaya başlanmıştır (Çelik, 2016).

EPDK'nın DAG/336-12/058 sayılı kurul kararı ile 06.07.2004 tarihinde Tekkeköy, Canik, Atakum ve Kavak ilçelerinde faaliyetini sürdürmektedir. Samsun ili doğal gaz iletimi SAMGAZ tarafından gerçekleştirilmektedir. Aşağıdaki tabloda 2015-2018 yılları arasında farklı sektörlerdeki kullanım miktarları gösterilmektedir.

Tablo 3.1. Doğal gazın yıllara göre sektörlerde kullanım miktarları (EPDK sektör raporlarından derlenmiştir.)

Yıllar/Sektörler	2015	2016	2017	2018
Dönüşüm/Çevrim Sektörü	1.168.825.758,46	1.206.722.807,11	1.755.117.139,77	903.319.355,98
Enerji Sektörü	271.831,84	2.028.036,01	10.548,65	6.723,90
Sanayi Sektörü	102.128.876,70	78.398.982,46	93.393.003,57	88.833.594,02
Hizmet Sektörü	42.909.028,53	49.447.416,90	59.298.490,26	55.142.754,46
Konutlar	153.504.870,69	168.382.302,75	219.479.274,95	203.035.796,73
Diğer	169.751,00	120.026,04	229.189,50	245.545,37

4. DOĞAL GAZ TAHMİNİNİN LİTERATÜR İNCELENMESİ

Doğal gaz sektöründe talep tahminin yapılması hem yatırım planlaması hem de ekonomik gibi stratejik açıdan oldukça fazla önem arz etmektedir. Doğal gaz açısından dış ülkelere bağlı olunması, alınacak gaz miktarının ve fiyatların belirlenmesi açısından önemlidir. Literatürde doğal gazın tahminlenmesine dair çalışmalar farklı yöntemlerle yer almaktadır.

Taşkiner “Ankara İli Doğal Gaz Tüketiminin Yapay Sinir Ağları İle Öngörüsü” adlı çalışmasında Ankara ili için doğal gaz tüketimini yapay sinir ağları yöntemini kullanarak tahmin etmiştir. Ağa girdi olarak ortalama sıcaklık tahmini, hissedilen maksimum sıcaklık tahmini, nem, ısı değer ve bağımsız birim sayısı verilmiştir. Çıktısında tüketim bulunmaktadır. 2014-2017 yılı arası veriler kullanılarak tahminleme yapmıştır (Taşkiner, 2018).

Kuru 2014 yılında ele aldığı “Tümevarım Yöntemi Kullanarak Türkiye Geneli Toplam Doğal Gaz Tüketimi Analizi” adlı çalışmasında enerji kaynaklarının üretim ve tüketim şekillerine ait yakın dönem verilerini kullanarak yenilebilir enerji ve mevcut fosil kaynakları için gelecekte ne olacağına dair araştırma yapmıştır. Doğal gaz tüketim tahminini tümevarım ve tündengelim yöntemleri ile yapmıştır. 2013 yılı tüketimi ele alınarak analitik model oluşturmuştur. Yaptığı çalışma sonucunda tümevarıma dayalı olarak geliştirdiği model, tündengelim yöntemine göre üstünlük sağlamış, 2013 yılı doğal gaz tahmini daha az hata ile bulunmuştur. Tümevarım yöntemiyle oluşturulan iki model %1,69 ve %92 tahmin hatası ile, tündengelim yöntemiyle oluşturulan model %3,63 hata ile çalışmıştır (Kuru, 2014).

Meral 2019 yılında ele aldığı “Türkiye’deki Enerji Santrallerinde Doğal Gaz Tüketiminin Destek Vektör Regresyon İle Tahmini” adlı çalışmasında doğal gaz tüketimini regresyon yöntemi kullanarak tahmin edilmiştir. Araştırmasında kullanacağı veriler 2013-2018 yılları arasında Enerji İşleri Genel Müdürlüğü ve Türkiye Enerji Piyasası Düzenleme Kurumu’ndan temin edilmiştir. Çalışmasında ilk önce Türkiye’de doğal gazın önemi, üretim, tüketim, ihracat ve ithalat miktarları değerlendirilmiştir. Bu değerlerin birim farklılıklarında dolayı veriler önce standartlaştırılmıştır. Çekirdek fonksiyon olarak Radyal Tabanlı Fonksiyon (RTF) seçilmiştir. Sonrasında destek vektörler, karar sabiti ve ağırlıklar belirlenmiştir.

Destek vektörler ve ağırlıklar çarparak yan yana ekleyip modeli elde etmiştir (Meral, 2019).

Demirceylan 2012 yılında ele aldığı “ Erzurum doğal gaz tüketim miktarının yapay sinir ağları ile çoklu doğal regresyon analizi sonuçlarını karşılaştırmıştır. Doğal gaz tüketimini etkileyen verileri kullanarak analizi gerçekleştirmiştir. Mevsimsel etkiyi incelemek için aylar, aylık ortalama sıcaklık, mevsimsellik ve aylık tüketim miktarı girdi olarak ağda kullanılmıştır. Aylık tüketim miktarı ağın çıktı katmanıdır. Çoklu regresyon yönteminden aldığı sonuç ile yapay sinir ağlarından aldığı sonucu karşılaştırmıştır. Yapay sinir ağları hata oranı daha düşük sonuç vermiştir. Çoklu regresyon yönteminde 30 ayın verileri kullanılarak sadece gelecekteki 30 ay için tahmin yapılabilir. Ancak yapay sinir ağları yönteminde ağı eğittikten sonra her değer için tahmin yapılabilir (Demirceylan, 2012).

Akgül ve diğerleri “ Doğal Gaz Tüketim Tahmini” adlı makalesinde Dünyada ve Türkiye’de doğal gaz kullanımından bahsetmiştir. TUIK’ ten elde ettiği verilerle yapay sinir ağları ve klasik zaman serileri (ARIMA) yöntemlerini kullanmıştır. Eğitim ve test verileri için ek küçük MSE (Mean Squared Error) değerine göre en iyi modeller seçilmiştir. Yapılan analizler sonucunda yapay sinir ağları yönteminin daha iyi sonuç verdiği görülmüştür (Akgül, 2013).

Kaynar ve diğerleri “Yapay Sinir Ağlarıyla Doğal Gaz Tüketim Tahmini” adlı makalelerinde doğal gaz bakımından dışa bağımlılığımızdan bahsedip tahmin edilmesinin ne kadar önemli olduğunu vurgulamışlardır. Tahmin yöntemlerinden YSA ve zaman serileri analizi yönteminden ARIMA modelini kullanarak sonuçlar elde etmiş ve tahminin hangisinde daha iyi sonuç verdiğini karşılaştırmışlardır. Çalışmada Ankara iline ait Ocak 2005 Haziran 2006 arasındaki günlük ve haftalık doğal gaz arz verilerini kullanılmıştır. Çalışmada %80’i eğitim %20’si doğrulama verisi olarak kullanılmıştır. YSA modelinde MATLAB programı kullanılarak bir model geliştirilmiştir. MSE performans ölçütü kullanılarak sonuçlar kıyaslandığında yapay sinir ağları yönteminin daha iyi sonuçlar verdiği görülmüştür (Kaynar, vd., 2011).

Szoplik 2015 yılında ele aldığı “Yapay Sinir Ağları İle Doğal Gaz Tüketiminin Tahmini” çalışmasında Szecin’e (Polonya) ait gerçek doğal gaz tüketimini tanımlayan verileri kullanarak MLP’ nin tasarımını ve eğitimi gerçekleştirmiştir.

Modelde, bireysel tüketiciler ve küçük sanayi tarafından gaz tüketimi üzerinde etkisi olan takvim (ay, ayın günü, haftanın günü, saat) ve hava (sıcaklık) faktörlerini dikkate almıştır. Gizli katmandaki nöron sayısı ve eğitim sürecinde kullanılan veri setinin büyüklüğünde farklılık gösteren MLP modellerinin kullanımı ile tahminlerin sonuçları karşılaştırılmıştır. Elde edilen sonuca göre MLP modelinin yılın herhangi bir günü ve günün herhangi bir saatinde gaz tüketimini tahmin etmek için başarıyla kullanılabilceği bulunmuştur (Szoplik, 2015).

Oruç ve arkadaşları 2017 yılında ele aldığı “Isparta ili için doğal gaz talep tahmini” adlı çalışmasında Gri Tahminleme, Üstel Düzleştirme, Box-Jenkins yöntemlerini kullanmıştır. Mevsimsel etkiyi araştırmada farklılıklar gösteren bu 3 yöntemi karşılaştırmıştır. Elde edilen sonuçlarda en iyi başarıyı gri Tahminleme yöntemi ile elde ettiğini, bu veri setine göre en başarısız tahminlemeyi Box-Jenkins yönteminin gerçekleştirdiğini bulmuştur (Oruç vd., 2017).

Akın 2017 yılında ele aldığı “Yapay sinir ağlarıyla konya bölgesinde kullanıcı doğal gaz tüketim öngörüsü” çalışmasında yapay sinir ağları kullanarak günlük tüketim tahmini yapmıştır. Tüketime etki eden 17 parametreyi veri setinde kullanmıştır. Girdi parametreleri; meteorolojik veriler (nem, sıcaklık, rüzgar hızı, gün öncesi ve sonrası sıcaklık farkları), yağış miktarı, bu parametrelerden elde edilen diğer parametreler, abone sayısı ve satış fiyatıdır. Çıktı parametresi olarak 2005-2015 yılları günlük doğal gaz tüketim verileridir. Yapay sinir ağı ile elde ettiği modelin yüksek başarı verdiğini gözlemlemiş, bu sonuçları basit ve çoklu doğrusal regreyon değerleri ile karşılaştırmıştır. Yapay sinir ağları modelinde R^2 0.9940, basit doğrusal regresyon modelinde R^2 0.779 ve çoklu doğrusal regresyon modelinde R^2 0.967 olarak bulunmuştur (Akın, B. 2017).

Tuna 2019 yılında ele aldığı “Doğal gaz talep tahmini: Erzurum ili üzerine bir uygulama” adlı çalışmasında daha önce Erzurum iline ilişkin böyle bir çalışma yapılmadığından bahsetmiş, Anadolu’daki iklim değişikliğinin doğal gaz talebine olan etkisini görmek için tahminlemeyi yapmayı öngörmüştür. Ocak 2009- Kasım 2018 yıllarına ait konut sektörü aylık doğal gaz tüketim verileri kullanılmıştır. Verilerin mevsimsellik içerdiği tespit edilmiştir. Tahmin edilmesinde tek değişkenli zaman serisi yöntemlerinden olan Box Jenkins metodu ile ARIMA modeli kullanılmıştır. Aralık 2018-Aralık 2020 dönemine ait doğal gaz tüketim değerleri için öngöründe bulunulmuştur (Tuna, 2019).

Akpınar ve diğerleri 2016 yılında “ Hibrit Sinir Ağları İle Doğal Gaz Tüketiminin Tahmin Edilmesi – Yapay Arı Kolonisi” adlı makalede yapay sinir ağı kullanan belirli bir tüketim grubu için tüketim talebini tahminini incelemeyi amaçlamışlardır. Hazırlanan tüketim verileri iki gruba ayrılmıştır. İlk üç yıllık günlük tüketim verileri eğitim için tutulurken, dördüncü yıl verileri test için tutulur. Tüketim tahmini için kendi geçmiş verileri kullanılır. Araştırma, her biri on bir farklı alt modelden oluşan iki farklı model türü uygulanarak tamamlanmıştır. Alt modellerde farklı sayıda nöron ve en fazla üç gizli katman bulunur. Tahminler toplam yirmi iki farklı senaryo ile yapılmaktadır. İki farklı modelde YSA ağırlıkları, geri yayılım ve yapay arı kolonisi algoritmaları ile eğitilir. Eğitim aşamasından sonra, ağ yapıları test veri kümeleri ile test edilir. Sonuç olarak, iki gizli katmanlı senaryoya sahip yapay arı kolonisi modelinin talep tahmininde diğerlerinden daha iyi sonuçlar verdiği sonucuna varılmıştır (Akpınar, 2016).

Anagnostis ve diğerleri “ Yapay Sinir Ağlarının Doğal Gaz Tüketim Tahmininde Uygulanması” makalesinde Yunanistan’daki on beş şehirde doğal gaz tüketimini tahmin etmen için 3 farklı sinir ağı yaklaşımını ele almışlardır. Bunlar: basit bir algılayıcı Yapay Sinir Ağı (YSA), son teknoloji ürünü Uzun Kısa Süreli Bellek (LSTM), ve önerilen Derin Sinir Ağı (DNN). Bu çalışmada sosyal yönlerle ilgili değişkenlerin girdi olarak tanıtıldığı bir DNN uygulaması önerilmiştir. Önerilen DNN, basit YSA ve avantajlı LSTM arasında karşılaştırmalı bir analiz yapılır ve sonuçlar, Yunan şehirlerinin özelliklerini ve sakinlerinin alışkanlıklarını daha derinlemesine anlamayı sağlar. Önerilen uygulama, dört yıla kadar günlük enerji tüketimi değerlerinin tahmin edilmesinde etkinlik göstermektedir. Önerilen yaklaşımın değerlendirilmesi için, doğal gaz tahmini için gerçek hayattan bir veri seti kullanılmıştır. Literatürde özellikle doğru ve etkili olarak nitelendirilen, uygulanan yaklaşımların, YSA ve LSTM'nin ve insan davranışını yöneten niteliksel değişkenlerin dahil edilmesiyle önerilen DNN'nin performansı hakkında ayrıntılı bir tartışma sağlanmaktadır (Anagnostis, 2020).

Eren vd. 2017 yılında yazdığı “Türkiye’deki Doğal Gaz Tüketimi Ve Gri Tahmin Metoduyla Tahmin Edilmesi” makalesinde yıllık doğal gaz tüketim verileri ve yıllık nüfus verilerini kullanmıştır. Gri tahminleme yöntemi diğer yöntemlerden farklı olarak daha az sayıdaki veri seti kulanıp, yüksek başarı ile tahmin yapabilir. Literatürde bu yöntemin oldukça sık kullanılması başarılı ve gerçekçi bir yöntem

olduğunu ortaya koymaktadır. Gri tahminleme yöntemi kullanılarak 2004-2016 yılları arasında nüfus miktarı ve milyon m³ doğal gaz tüketimi tahmin edilmiştir. TÜİK’den alınan 2004-2016 yılı tüketim ve nüfus verileri ile karşılaştırılarak hata değeri hesaplanmıştır. Hata eđeri %4,74 hesaplanmış olup, %10’un altında hata oranı ile çalıştığı için yüksek doğruluk oranında çalıştığı kabul edilmiştir (Eren vd., 2017)

Topçu 2013 yılında yazdığı “Türkiye Doğal Gaz Tüketim Tahmini” tezinde SARIMA modelini kullanmıştır. Çalışmasında 1987-2011 yılları arasında toplam aylık olarak toplam 298 adet doğal gaz tüketim verisi kullanmıştır. Doğal gaz tahminleme çalışmasını Minitab paket programını kullanarak gerçekleştirmiştir. Yapılan analizler sonucunda histogram, otokorelasyon ve kısmi otokorelasyon grafikleri elde edilmiştir. Analizler doğrultusunda SARIMA modeli için belirlenen parametrelerin istatistiksel olarak anlamlı olduğu belirlenmiştir. %95 güven aralığında yapılan tahminleme sonucunda doğal gaz tüketiminin 2020 yılına kadar %6-7,5 lik bir oranda artış göstereceğini öngörmüştür (Topçu, GY. 2013).

Tablo 4.1. de doğal gaz tüketimi talep tahmininde literatürde kullanılan yöntemler ve ele alınan parametreler listelenmiştir.

Tablo 4.1. Doğal gaz tüketim tahmini literatür taraması

Yayın Yılı	Yazar(lar)	Çalışma Adı	Kullanılan Yöntem	Kullanılan Parametreler
2011	Oğuz Kaynar, Serkan Taştan, Ferhan Demirkoparan	Yapay Sinir Ağlarıyla Doğal Gaz Tüketim Tahmini	Yapay Sinir Ađı MLP Modeli, Klasik Zaman Serileri ARIMA Modeli	-Günlük ve Haftalık Doğal Gaz Arz Verileri
2012	Seda Demirceylan	Erzurum Doğalgaz Tüketim Miktarını Yapay Sinir Ađı Algoritması Kullanılarak Tahmin Edilmesi	Çoklu Doğrusal Regresyon İle Yapay Sinir Ağlarının Karşılaştırılması	-Aylar -Aylık Ortalama Sıcaklık -Mevsimsellik -Aylık Tüketim Miktarı
2013	Sevim Akgül, Şaduman Yıldız	Doğal Gaz Tüketim Tahmini	Yapay Sinir Ađı MLP Modeli Klasik Zaman Serileri ARIMA Modeli	-Tüketim Verileri
2013	Görkem Yusuf Topçu	Türkiye Doğal Gaz Tüketim Tahmini	SARIMA	-Aylık Doğal Gaz Tüketim Verisi (1987-2011 yılları arasında)
2014	Volkan Kuru	Türkiye Doğal Gaz Tüketiminin Sektörel Bazda Analitik	Tümevarım ve Tümdengelim Yöntemleri	-GSYH (2011 sabit \$) -Enerji Sektörü DG Payı (GWh) -Sanayi Sektörü Enerji

		İncelenmesi		Yoğunluğu -Tahmini Abone Sayısı -Ankara Isıtma Derece Gün
2015	Jolanta Szoplik	Yapay Sinir Ağları İle Doğal Gaz Tüketiminin Tahmini	Yapay Sinir Ağı MLP Modeli	-Gaz Tüketimi -Günler -Saat -Hava Sıcaklığı
2016	Mustafa Akpınar, M.Fatih Adak, Nejat Yumuşak	Hibrit ile Doğal Gaz Tüketiminin Tahmin Edilmesi Yapay Sinir Ağları-Arı Kolonisi	Yapay Sinir Ağı / Yapay Arı Kolonisi	-Günlük Doğal Gaz Tüketim Verileri
2017	Kenan Oğuzhan Oruç, Şeyma Çelik Eroğlu	Isparta İli İçin Doğal Gaz Talep Tahmini	Gri Tahminleme, Box-Jenkins, Üstel Düzleştirme	-Aylık Konut Sektörü Doğal Gaz Tüketim Verisi
2017	Burcu Akın	Yapay Sinir Ağlarıyla Konya Bölgesinde Kullanıcı Doğal Gaz Tüketim Öngörüsü	Yapay Sinir Ağı	-Günlük Doğal Gaz Tüketim Verileri -Abone Sayısı -Günlük Ortalama Sıcaklık (°C) -Günlük Minimum Sıcaklık (°C) -Günlük Maksimum Sıcaklık (°C) -Günlük Ortalama Nem (%) -Günlük Ortalama Rüzgar Hızı (m/s) -Günlük Toplam Yağış Miktarı (mm)
2017	Tuğba Eren, Sibkat Kaçtıoğlu	Türkiye'deki Doğal Gaz Tüketimi ve Gri Tahmin Metoduyla Tahmin Edilmesi	Gri Tahmin Yöntemi	-Yıllık Doğal Gaz Tüketim Verileri -Yıllık Nüfus Verileri
2018	Burak Taşkner	Ankara İli Doğal Gaz Tüketiminin Yapay Sinir Ağları İle Öngörüsü	Yapay Sinir Ağları	<u>Girdi Verileri:</u> -Nem -Ortalama sıcaklık tahmini -Minimum sıcaklık tahmini -Hissedilen minimum sıcaklık tahmini -BBS(Bağımsız Birim sayısı) -Isıl değer <u>Çıktı Verisi:</u> -Tüketim
2019	Gizem Meral, Sinan Saraçlı	Türkiye'de Enerji Santrallerinde Doğal Gaz Tüketiminin Destek Vektör Regresyon İle Tahmini	Destek Vektör Regresyonu (Doğrusal, Polinomiyal, Radyal Tabanlı Fonksiyon, Sigmoid)	-Bağımlı Değişken: Enerji santralleri tüketimi -Bağımsız Değişken: Sanayi tüketimi, Şehir Tüketimi, Üretim, İthalat, İhracat
2019	Çiğdem Tuna	Doğal Gaz Talep Tahmini: Erzurum İli Üzerine Bir Uygulama	Zaman Serisi / Box-Jenkins Yöntemi	-Konut Sektörü Aylık Doğal Gaz Tüketim Verisi

2020	Athanasios Anagnostis, Elpiniki Papageorgiou, Dionysis Bochtis	Yapay Sinir Ağlarının Doğal Gaz Tüketim Tahmininde Uygulanması	Yapay Sinir Ağı, Uzun Kısa Süreli Bellek, Derin Sinir Ağı	-Günlük Enerji Tüketim Verileri
------	--	--	--	------------------------------------

5. TALEP TAHMİNİ

Tüketicilerin bir hizmeti ve ya ürünü belirli bir fiyattan almayı kabul ettikleri miktara talep denir. Gelecekteki bir zaman dilimi için firmanın bir ürünü veya farklı ürünleri için talep düzeyini tespit etmeye talep tahmini denir.

Müşteri talebinin tahmin edilmesini ne kadar ürünün, ne kadar işgücü ve hammaddeyle, ne kadar üretileceğinin planlanması, stok miktarının belirlenmesi açısından önemlidir. Talep tahmini büyük, orta, küçük çaplı işletmelerin, yatırımcıların tümünde kullanılan bir yöntemdir (Soysal ve Ömürgönülşelen, 2010).

Talep tahmini şirket yönetiminin taktik ve stratejik kararlar alınmasında, kısa ve uzun dönemli hedeflere ulaşmak için kullanılması gereken en temel araçlardan biridir. Doğru bir şekilde yapılmış talep tahmini ile şirket optimum kar seviyesine ulaşır. Yapılacak tahmin tipini ve süresini talep yöntemi ve ürünün özellikleri etkilemektedir. Ürüne olan talep miktarı sabit ise tahmin süresi kısalsabilir. Ancak ürüne ait talepte dalgalanmalar mevcutsa tahminleme süresi uzayabilir. Bazı ürünler mevsimsel farklılıklar gösterdiği için talep değerleri azalabilir veya çoğalabilir. Bu değişimlerin sebebini belirleyebilmek için mevsimsel tahmin yöntemleri kullanılmalıdır (Adıyaman, 2007).

5.1. Talep Tahmini Aşamaları

Talep tahmin işlemi genel olarak 5 aşamada gerçekleştirilir.

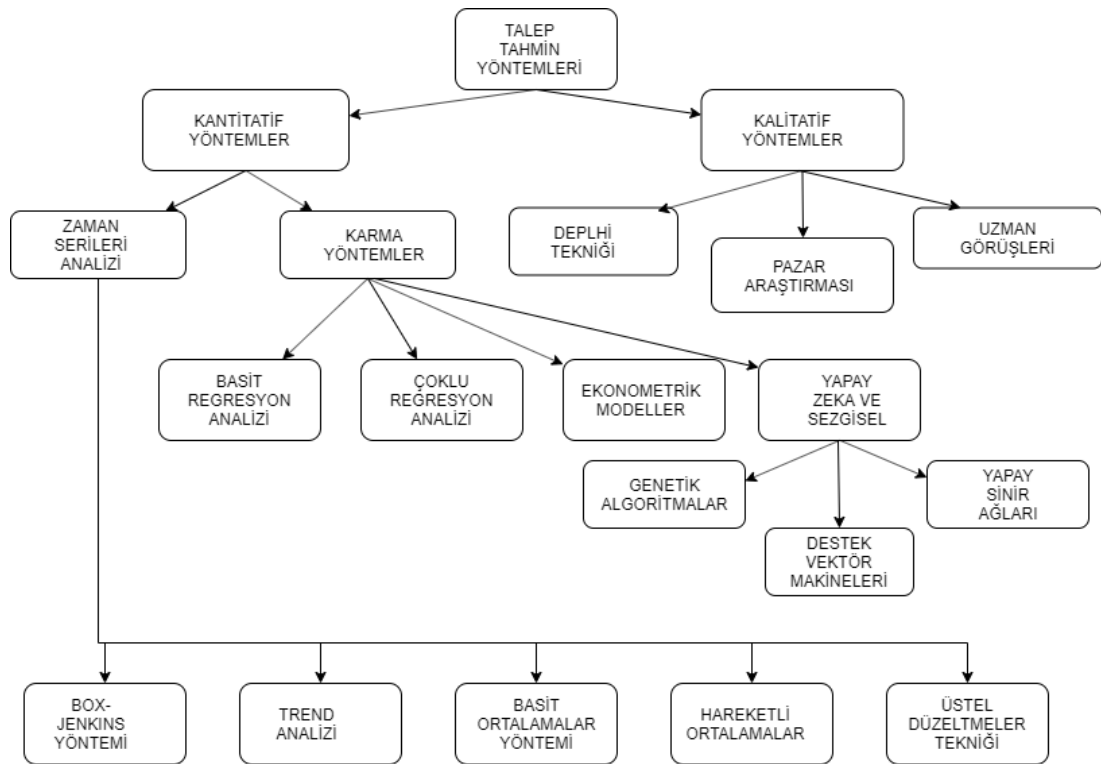
- Talebi Etkileyen Etkenlerin Belirlenmesi: Talep tahmini yapılmadan önce şirketin ürettiği ürünler, şimdiki durumu ve gelecekte gelmek istediği durum, hangi çevre ortamında olduğu, fiyat talep ilişkisi, rakiplerinin durumu, iktisadi, endüstriyel, sosyal değişimler, teknolojik gelişim gibi talebi etkileyen etkenler ve buna bağlı olarak ağırlıkları belirlenmelidir.
- Verilerin Toplanması: Talebi etkileyen tüm veriler toplanır. Genellikle geçmiş gerçek veriler, hedef veriler ve istatistiksel olasılıklardan oluşur. Verilerin düzenlenmesinde şirketin yapmış olduğu anketler, yayınlanmış istatistiki verileri, iç kaynaklar ve iktisadi veriler kullanılabilir.
- Talep Tahmin Periyodunun Tespiti: Yapılacak tahmin ile kullanım süresi arasında yakın bir ilişki bulunmaktadır. Örneğin; aylık yapılan tahminlerin uzun dönemlerde kullanılması doğru sonuçlar vermeyebilir.

- Tahmin Yönteminin Seçimi: Talep tahmin yöntemleri kantitatif ve kalitatif olmak üzere ikiye ayrılır. Kantitatif yöntemler matematiksel modellemeye dayanırken, kalitatif yöntemler tecrübeye dayanmaktadır.
- Tahmin Sonuçlarının Geçerliliğinin Araştırılması: Sonuçların gerçek verilerle karşılaştırılarak doğruluğu tespit edilmelidir.

5.2. Talep Tahmin Yöntemleri

Tahmin yöntemleri, kantitatif ve kalitatif olmak üzere ikiye ayrılır. Kantitatif yöntemler, matematiksel model içeren, belirli bir miktarda sayısal verinin bulunduğu durumlarda kullanılmaktadır. Kalitatif yöntemler ise; kişinin düşüncelerine bağlı olarak gerçekleşir (Karaatlı, vd., 2012).

Aşağıda yer alan şemada talep tahmin yöntemleri gösterilmektedir.



Şekil 5.1. Talep tahmin yöntemleri

Talep tahmin çalışmaları genellikle dört döneme ilişkin yapılır.

- Çok Kısa Süreli Tahminler: Günlük ve haftalık tahmin yapılması olarak değerlendirilir. Stokların kontrol edilmesi, yeniden sipariş verilmesi amacıyla kullanılabilir.

- Kısa Süreli Tahminler: 1 hafta ile 6 ay arasında yapılan tahminlerdir. Sipariş miktarının bulunması amacıyla kullanılabilir.
- Orta Süreli Tahminler: 6 ay ile 5 yıla kadar yapılan tahminlerdir. Tedarik süresi uzun veya belirsiz olan malzeme alımlarının planlanması amacıyla kullanılabilir.
- Uzun Süreli Tahminler: 5 yıl veya daha uzun süreye kadar yapılan tahminlerdir. Sermaye planlaması, tesis yatırımları amacıyla kullanılabilir (Adıyaman, 2007).

5.2.1. Zaman Serisi Analizi

Zaman serisi eşit aralıklı ve ardışık zamanlarda bağımsız bir değişkenin aldığı değerleri gösteren küme şeklinde ifade edilebilir. Tanımlanan bağımsız değişken saat, gün, ay, yıl gibi zaman dilimi olmalıdır ve değişkenler arasında eşit aralık bulunmalıdır. Zaman serisinde geleceğe dair tahmin geçmiş döneme ilişkin verilere bakılarak yapılır. Zaman serisinde geçmişe olan bulguların gelecekte de sürdürüleceği kabul edilir. Zaman değişiminde farklılıklar, istikrarsızlıklar olursa bu yöntem doğru sonuç vermeyebilir (Taşkın, 2018).

Model oluşturulduktan sonra, bu yöntem gelecek değerlerin tahminlenmesinde kullanılabilir. Bir durumun gelecekteki değerinin tahmin edilmesi aşağıdaki şekilde ifade edilebilir.


- Bir zaman serisinin gözlem değerleri $x_1, x_2, x_3, \dots, x_n$ şeklinde ise, tahmin değerleri x_{n+1}, x_{n+2}, \dots şeklinde olmalıdır.
- n zamanında hesaplanan t adım ilerideki x_{n+t} tahmini $x_n(t)$ ile gösterilir. Burada t tam sayısı tedarik zamanıdır (Şişçi, 2017).

5.2.1.1. Box-Jenkins Yöntemi

Gwilym M. Jenkins ve George E.P.Box tarafından geliştirilen Box-Jenkins yöntemi ARIMA modeli olarak da bilinmektedir. Bu yöntem, kısa dönem tahminlemesinde başarılı sonuçlar vermektedir. Box-Jenkins yöntemi doğrusal ve kesikli stokastik süreçlere dayanmaktadır. Durağan modeller, zamana göre değişmeyen olasılık özelliklerine sahip modellerdir. Zamanla değişmeyen varyansa ve ortalamaya sahiptir (Akdağ, 2015).

5.2.1.2. Trend Analizi

Uzun vadede zaman serisinin deęişim yönünü göstermektedir (Taşkıner, 2018). Trend analizi, veri noktalarını düz bir çizgiyle takip etmektedir ve geleceęe ilişkin tahmin yapabilmek üzere satışları yansıtmak için bu düz çizgi kullanılır.



Şekil 5.2. Örnek satış eğilim grafięi (Şişçi, 2017)

Doęrusal veya doęrusal olmayan regresyon eğilim tahmininde kullanılmaktadır. Zaman serisi verilerinin kuadratik veya üstel, doęrusal fonksiyon kullanılıp eğilim çizgisine benzetilmesine dayanmaktadır (Şişçi, 2017).

5.2.1.3. Basit Ortalama Yöntemi

Geçmiş veriler sürekli bir şekilde artış veya azalış göstermiyorsa ve uzun vadede ciddi bir deęişiklik görünmüyorsa bu yöntem kullanılabilir. Basit ortalama yöntemi, bir veri setinde verilerin toplanıp gözlem sayısına bölünmesiyle bulunur (Taşkıner, 2018). Formülü

$$Y_{i+1} = \frac{\sum_{i=1}^n Y_i}{n} \quad (5.1)$$

şeklinde ifade edilir.

5.2.1.4. Hareketli Ortalamalar Yöntemi

Hareketli ortalamalar yöntemi, mevsimsel dalgalanmaların talebe olan etkisini gözlemlemek için kullanılabilir. Bu yöntem ile tesadüfi gerçekleşen etkenlerin sebep

olduğu deęişimler etkisiz kılınabilir. Böylece tahmine etki eden nedenlere yoğunlaşarak tahminin doğruluęu artırılabilir. Hareketli ortalamalar yönteminde geçmiş verilerden yakın zamandaki verilere kadar ağırlıklar verilir ve bu ağırlıklar doğrultusunda tahmin yapılır. Formülü

$$Y_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (5.2)$$

şeklinde ifade edilir.

5.2.1.5. Üstel Düzeltmeler Teknięi

Hareketli ortalama yöntemine benzerlik göstermektedir. Üstel düzeltmeler teknięinde tüm veri seti ağırlıklandırılır. Geçmişe ilişkin olan verilere daha az ağırlık verilerek tahmin edilir. Hareketli ortalamalar yönteminde ise bütün tarihlerde aynı ağırlıkları vermektedir. Üstel düzeltmeler teknięi, tüm tarihi verilerin hareketli ortalaması olarak deęerlendirilebilir. Bu yöntemdeki amaç, talepteki dalgalanmanın etkisini azaltıp genel eğilime göre tahmin yapabilmektir.

Düzeltilme katsayısı a , 0-1 arasında bir deęer almaktadır.

$$F_{t+1} = ay_t + (1-a)F_t \quad (5.3)$$

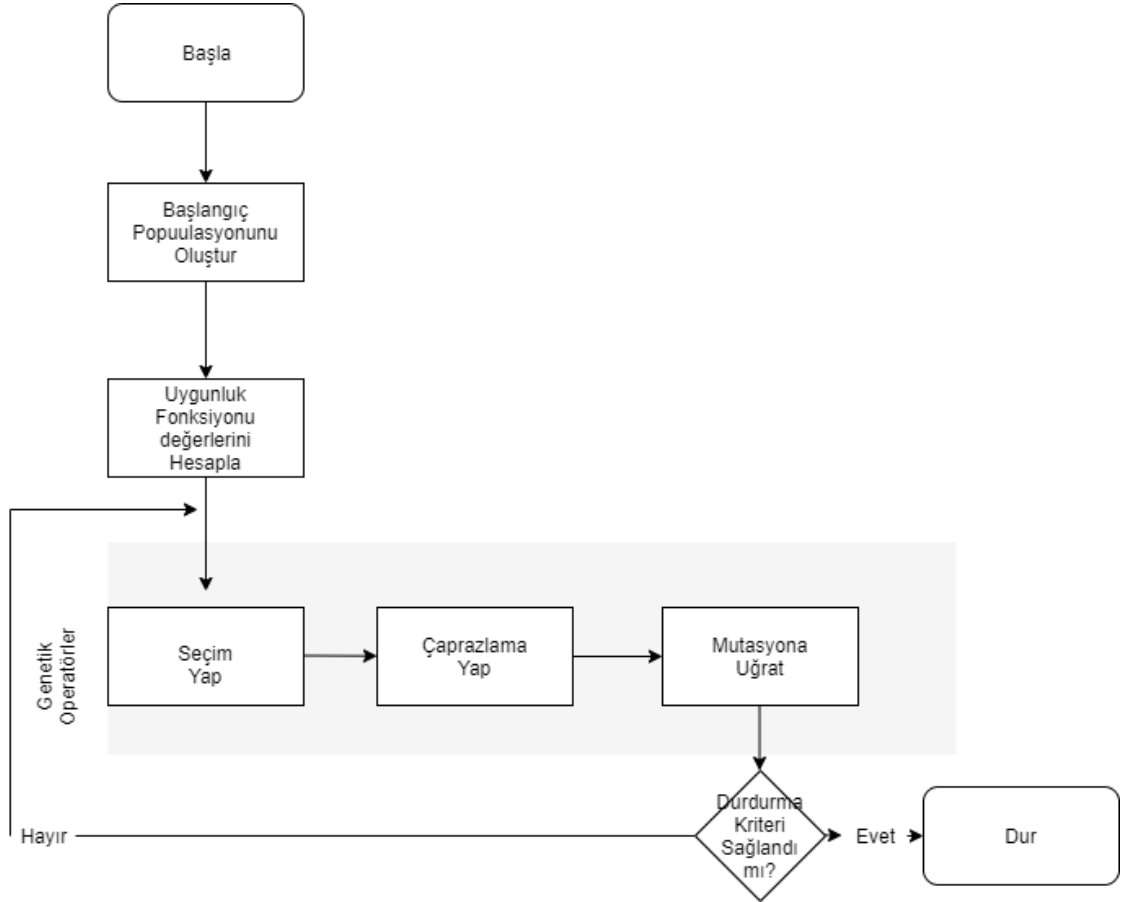
Bu formülde F_{t+1} yeni tahmin deęeri, F_t bir önceki dönem tahmin deęeri, y_t gerçekleşen deęer, a düzeltilme katsayısıdır (Şişçi, 2017).

5.2.2. Yapay Zekâ ve Sezgisel Algoritmalar

Problemlerin optimuma yakın uygun çözümünü üreten fakat bulunan çözümlerin optimum olup olmadığı hakkında net sonuçlar vermeyen algoritmalara sezgisel algoritma denir. Bu algoritma optimuma yakın olacak şekilde tasarlanır. En iyileme teknięi, en iyi çözümü garanti ederken sezgisel algoritmalar en iyi çözümü garanti etmez ve kısa sürede sonuç verirler (Tuna, 2014). Yapay zekâ ve sezgisel algoritmaların kullanım alanı oldukça geniştir. Talep tahmininde kullanıldığında genetik algoritmalar, destek vektör makineleri ve yapay sinir aęları kullanılmaktadır (Şişçi,2017).

5.2.2.1. Genetik Algoritmalar

Genetik algoritma biyolojik evrimin süreçlerini göz önüne alarak oluşturulan çözüm algoritmasıdır. Karmaşık problemlerin çözümünde kromozomların yeni diziler üretmesinden esinlenerek yapılan sezgisel araştırma yöntemidir. Genetik algoritmayı diğer yöntemlerden ayıran en önemli özellik biyolojik evrimin esas alınmasıdır. Çözüm kümesi kromozom yapısı ile ifade edilir. Bu yöntemin amacı en iyi uygunluk değerini veren gen dizilimine ulaşmaktır. Genetik algoritmayı oluşturan süreçler aşağıdaki gibidir (Tuna, 2014).



Şekil 5.3. Genetik algoritmanın temel prensipleri (Tuna, 2014)

5.2.2.2. Destek Vektör Makineleri

Makine öğrenmesinin temeli olan destek vektör makineleri doğrusal olmayan bir algoritma türüdür ve verilerin genelleştirilmesini sağlar. Doğrusal vektör makinelerine kuadratik programlama tekniği ile çözüm bulunabilir. Bu yöntemde ilk olarak sınıflandırıcı eğitim gerçekleştirilir. Eğitim esnasında sınıflandırıcının

performansını maksimum düzeyde tutmak için daha iyi bir sınıflandırma gerçekleştirilmesini sağlar (Kaya, 2016).

5.2.2.3. Yapay Sinir Ağları

Yapay sinir ağı biyolojik sinir ağından esinlenerek oluşturulmuş, girdi, çıktı ve gizli katmandan oluşan matematiksel modellerdir. Yapay sinir ağları öğrenme yeteneğine sahiptir. Bilgisayarların daha hızlı ve daha verimli çalışmaya başlamasıyla yapay sinir ağlarının kullanım alanları genişlemiştir (Taşkın, 2018).

Yapay sinir ağlarında talep tahmini yapılırken geçmiş veriler kullanılır ve en küçük kare hatası üretilmeye çalışılır. Uygun ağırlık değerini belirlemek amacıyla sinir ağları eğitilir. Çözüm üretilene kadar eğitim birçok iterasyondan geçirilir. Ağ girdi, çıktı ve gizli katman olmak üzere üç katmandan oluşur. Girdi katmanında bağımsız değişkenler için birer hücre bulunur. Çıktı katmanında bağımlı değişken sayısı kadar hücre bulunur. Gizli katmanında ise girdi sayısının iki katını geçmeyecek şekilde hücre bulunur. Girdi ile ara katmandaki ve ara katman ile çıktı katmanındaki hücreler arasında ağırlık değerleri bulunur. (Adıyaman, 2007).

Bir sonraki bölümde yapay sinir ağlarından detaylı bir şekilde bahsedilecektir.

6. YÖNTEM

6.1. Yapay Sinir Ağları

Yapay sinir ağları insan beyninin en temel fonksiyonunu gerçekleştiren bilgisayar sistemidir. Öğrenme işlemi geçmiş veriler yardımıyla gerçekleştirilir. Bu ağlar birbirine bağlı yapay sinir hücrelerinden oluşmaktadır. Her hücrenin bir ağırlık değeri saklı olup ağa yayılmıştır.

Yapay sinir ağları, basit işlem hücrelerinden oluşturulup bilgiyi depolama ve kullanma yeteneğine sahip olarak geliştirilen işlemcidir. İki yönden beyin ile benzerlik göstermektedir. Bunlardan birincisi; bilgiyi öğrenme yoluyla çevreden elde etmesi ikincisi ise; öğrenilen bilgiyi depolamak için sinaptik ağırlık olarak da bilinen nöronlar arasında bulunan bağlantıyı kullanmasıdır (Hatipoğlu, 2010).

Yapay sinir ağları diğer hesaplama yöntemlerinden farklılık göstermektedir. Buldukları ortama adapte olabilen, eksik verilerle çalışabilen, hatalara karşı toleranslı olabilen, belirsizlik altında karar verebilen bu ağlar hemen hemen her kullanım alanında başarılı uygulama örneklerine sahiptir. Ağ parametresinin seçiminde belli standardın olmaması, verilerin yalnızca numerik olarak ifade edilmesi, ağı davranışlarının tam olarak bilinmemesine rağmen yapay sinir ağlarına ilgi sürekli artmaktadır. Örüntü tanıma, sınıflandırma, veri sıkıştırma, optimizasyon ve sinyal filtreleme çalışmalarında yapay sinir ağları en sık kullanılan teknikler arasında yer alır. Bunlar haricinde; optimum rota belirleme, malzeme analizi, parmak izi tanıma, kalite kontrol, veri madenciliği, iş çizelgeleme gibi konularda da örnekleri bulunmaktadır (Öztemel, 2012).

Yapay sinir ağları makine öğrenmesi alanında geliştirilen uygulamalardan birisidir. Örnek veriler yardımıyla genel yargılar ve sonuçlar üretmeye çalışırlar. Bilgisayar sistemindeki ağa uygulayıcı tarafından örnekler girilir ve ağın bu örnekler yardımıyla sonucu bulması sağlanır. Ağ öğrenimini tamamladıktan sonra hiç görmediği örnekler hakkında bilgi verebilir, sonuç üretebilir (Sönmez Çakır, 2019).

1970 yılının yapay sinir ağlarında bir dönüm noktası olarak ifade edilebilir. Bu tarihten önce birçok araştırma yapılsada 1969 yılında XOR probleminin çözülememesi ile birlikte çalışmalara ara verildiği görülmektedir. 1970 yılından sonra XOR problemi birkaç araştırmacının çalışmasını sürdürmesi sonucu çözüme ulaşmıştır ve yapay sinir ağları konusu tekrardan ilgi görmeye başlamıştır. 10 yıl

içerisinde birbirinden farklı 30 civarlarında model geliştirilmiştir. Bununla birlikte yapay sinir ağları laboratuvar ortamından çıkarak günlük hayatta da kullanılan sistem haline gelmiştir. Bu çalışma hem donanım teknolojisi hem de yapay zekâ ile desteklenerek herkesin kabul ettiği ve kullanmak istediği teknoloji haline gelmiştir (Öztemel, 2012).

6.1.1. Yapay Sinir Ağlarının Tanımı


Yapay sinir ağları beynin çalışma prensibini temel alarak, birbiriyle paralel çalışan, bilgi gönderen ve birbirinden bilgi alan hücrelerden oluşmaktadır. Problemin çözülmesi amacı ile kullanılan yapay sinir hücreleri, ağ şeklinde birbirine bağlıdır. Sistemin zeki davranması ve öğrenme yeteneği bağlantı değerleriyle oluşmaktadır.

Yapay sinir ağları, öğrenme yolu ile yeni bilgiler türetebilen, keşfedebilen, herhangi bir yardım almaksızın kullanılan bilgisayar sistemleridir. Geçmiş örneklerden kazandıkları bilgiler ile kendi deneyimlerini oluştururlar ve benzer nitelikteki örneklerle karşılaştınca benzer karar verirler. Bilim insanları, beynin nöro-fiziksel yapısını inceleyip matematiksel modelini çıkarmaya çalışmışlardır. Beynin sahip olduğu bütün davranışlarını modelleyebilmek için birçok ağ modeli ve yapay hücre geliştirmişlerdir (Ballı, 2014).

Yapay sinir ağları insan beyninin özelliklerine benzer olarak,

- Sınıflandırma
- Öğrenme
- Genelleme
- İlişkilendirme
- Optimizasyon
- Özellik Belirleme

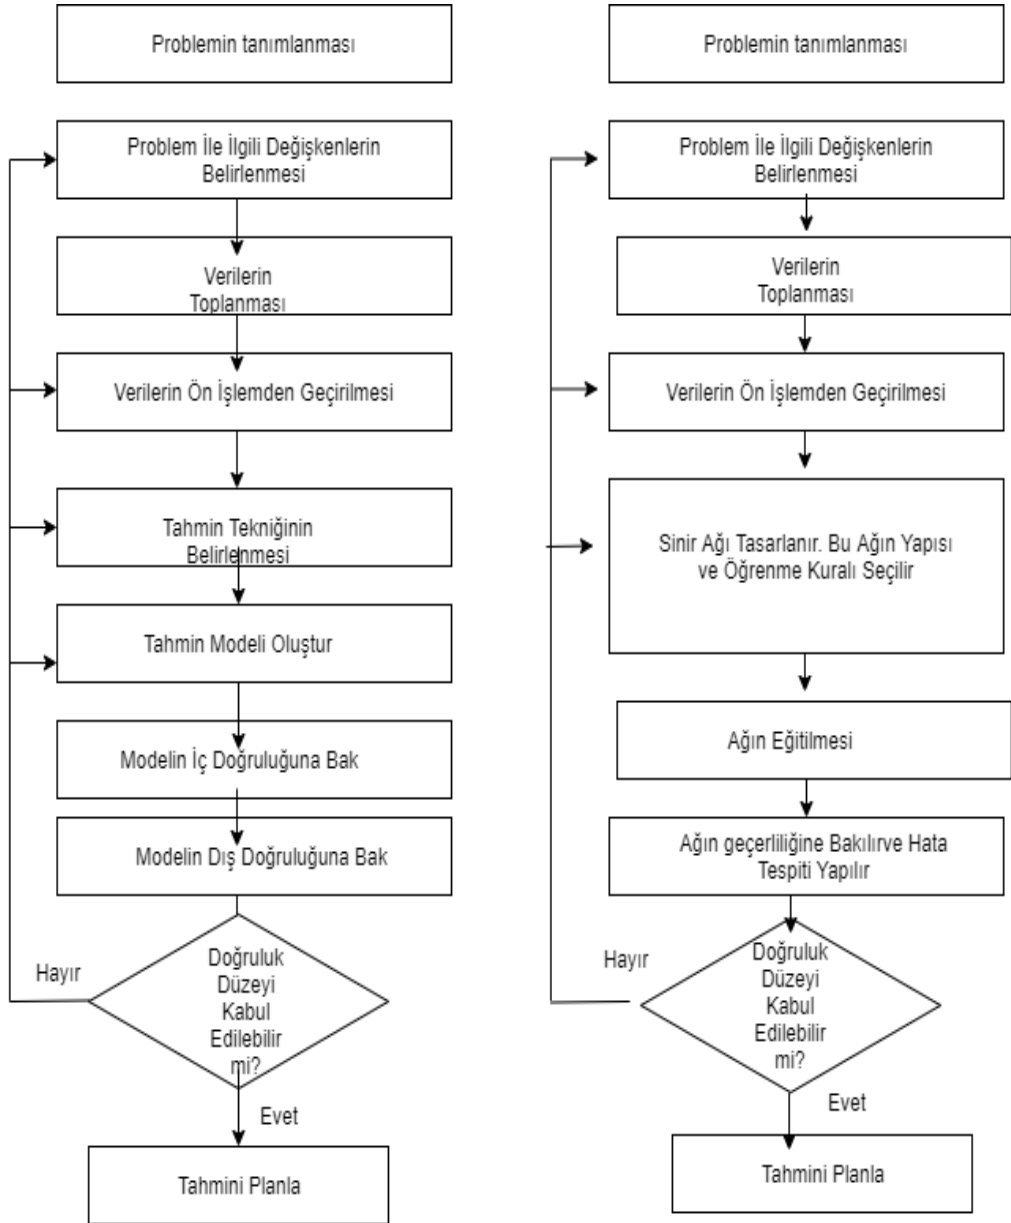
gibi konularda uygulanmaktadır (Adıyaman, 2007).



Şekil 6.1. İlk insan sinir hücresi (Toğa, 2012)

Ağları birbirine bağlayan bağlantı değerlerine ağırlık denir. 3 katman bir araya gelerek sinir ağını oluşturur. Bunlar; girdi katmanı, ara katmanlar ve çıktı katmanıdır. Girdi katmanından bilgiler ağa iletilir. Veriler ara katmanda işlenerek çıktı katmanına gönderilir. İşlenmesi demek bilginin ağırlıklarla çarpılarak çıktıya dönüştürülmesidir. Doğru çıktıların oluşması için ağırlık değerlerinin doğru olması gerekmektedir. Doğru ağırlıklar bulunduğu takdirde ağ eğitilmiş olur. Başlangıçta rastgele atanan değerler ağın öğrenme kuralına göre değişir. Başka örnekler ağa gösterilerek ağırlıklar tekrar değiştirilir ve en doğru ağırlık değeri bulunmaya çalışılır (Öztemel, 2012).

Bu yöntemin her ne kadar kendine özgü yapılarının olduğu düşünülse de daha önceden kullanılan sınıflandırma, tahmin, kontrol vb. modellerle benzerlik göstermektedir. Tekli ve çoklu regresyon, matris ve vektör hesapları, korelasyon, stokastik süreçleri zaman serisi gibi bazı yöntemlerle ortak mimarileri vardır. Yapay sinir ağları ve geleneksel metotların iş akışının karşılaştırılması aşağıdaki görseldeki gibidir (Çakır, 2019).



Şekil 6.2. Geleneksel yöntemler ve yapay sinir ağlarının karşılaştırılması

6.1.2. Yapay Sinir Ağları Tarihçesi

Yapay sinir ağları yönteminin tarihçesi insanların nörobiyolojiye ilgi duymaları ve ile bilgisayar ortamında uygulanması ile başlamışlardır.

- 1890: İnsan beyninin fonksiyonları ve yapısıyla ilgili ilkyazının yazılması
- 1911: İnsan beyni bileşenlerinin sinir hücrelerinden oluştuğunun benimsenmesi
- 1943: “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” teorisi Warren McCulloch/Walter tarafından ortaya atılmıştır.

- 1949: Hebb Kuralı ile öğrenmenin bilgisayarlar tarafından gerçekleştirilecek şekilde geliştirilmesi.
- 1956-1962: Windrow ve Adaline öğrenme algoritmasının geliştirilmesi
- 1957-1962: Tek Katmanlı Algılayıcı geliştirilmesi
- 1965: Makine öğrenme kitabının ilk defa yazılması.
- 1967-1969: Grosberg öğrenme algoritmasının geliştirilmesi
- 1969: Problemleri çözme yeteneğinin tek katmanlı algılayıcılarda olmadığına kanıtlanması
- 1969-1972: Doğrusal ilişkilendiricinin geliştirilmesi
- 1969-1972: Kohonen ve Anderson çalışması (Çağrışımlı Bellek konusu)
- 1972: Matriks ve korelasyon belleğinin geliştirilmesi
- 1974: Çok katmanlı algılayıcıların ilk çalışması olan geri yayılım modelinin geliştirilmesi
- Öğretmensiz Öğrenmenin geliştirilmesi:
 - 1978: ART modelinin geliştirilmesi
 - 1982: SOM modeli ve Kohonen öğrenmesinin geliştirilmesi
- 1982: Çok katmanlı algılayıcıların ve Hopfield ağlarının geliştirilmesi
- 1984: Boltzman makinesinin geliştirilmesi
- 1985: Genelleştirilmiş Delta kuralı ile çok katmanlı algılayıcıların geliştirilmesi
- 1988: RBF ve PNN modelinin geliştirilmesi
- 1991: GRNN modelinin geliştirilmesi
- 1991 sonrasında günümüze kadar sayısız çalışmalar yürütülmüştür (Ballı, 2014)

6.1.3. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının tüm modeller için geçerli olan özellikleri bulunmaktadır. En önemli özellikleri; doğrusal olmayan yapıları modellemesi, öğrenme ve genelleme yapabilme yeteneği, farklı problemler için uygulanabilir olması, hata toleransına sahip olması, paralel dağılmış yapısıdır. Bu özellikle sayesinde mühendislik, işletme, finans, tıp ve birçok alanda tercih edilmektedir (Eş, 2013).

Öğrenme: İnsan beyninin çalışma prensibini esas alan YSA, problemin verilerini kullanıp veri yapısındaki ilişkileri belirleyerek ağın öğrenmesini sağlar. Öğrenme işlemi ile yapay sinir hücreleri arasındaki bağlantı ağırlıkları belirlenir.

Genelleme: Yapay sinir ağı eğitildikten sonra eksik veri olmasına rağmen sonuç üretebilir. Geleneksel sistemlerden bir farkı eksik veriyle de çalışmaya devam edebilirler.

Uyarlanabilirlik: Belirli bir problem için eğitilen yapay sinir ağı, problem farklı bir hal aldığında yeni probleme göre uyarlanıp yeniden eğitilebilir.

Hata toleransı: Ağın eksik verilerle çalışabilmesi oluşabilecek hatalara karşı toleranslı olmasını sağlamaktadır. Ağın bazı hücrelerinin bozulması halinde ağ yine de çalışmaya devam eder. Bununla birlikte ağı performansında düşmeler gözlemlenebilir. Hangi hücrenin önemli olduğuna eğitim esnasında ağ karar vermektedir (Eş, 2013).

Doğrusal olmama: Yapay sinir ağının temel işlem elemanı doğrusal değildir. Doğrusal olmama özelliği ile karmaşık problemlere çözüm üretebilmektedir.

Paralel çalışma: Bütün işlem elemanları paralel çalıştıkları için çok hızlı çıktı üretebilmektedirler.

Bilginin saklanması: Bilgi, ağın bağlantılarında saklanmaktadır.

Kendi ilişkisini oluşturma: Yapay sinir ağları kullandığı verilere göre kendi ilişkisini kendisi oluşturur. Sabit bir denklem içermez.

Algılamaya yönelik olaylarda kullanılabilirlik: Genellikle algılamaya yönelik bilgileri işlemede kullanılmaktadır. Bilgi odaklı işlemlerde genellikle uzman sistemlerin kullanıldığı görülmektedir.

Dereceli bozulma: Hata toleransına sahip oldukları için sistemin bozulması dereceli olur. Geleneksel programlarda hata varsa program çalışmaz. Ancak yapay sinir ağları eldeki verilerle bilgi üretmeye çalışırlar (Yılmaz, 2010).

Donanım ve hız: Yapay sinir ağları paralel olması sebebiyle büyük ölçekli bütünleşmiş devre teknolojisi ile gerçekleştirilmektedir. Bu özellik hızlı bilgi işleme özelliğini artırarak gerçek zamanlı uygulamalarda tercih edilmesini sağlamaktadır.

Analiz ve tasarım: Yapay sinir hücresinin yapısı ve modeli tüm yapay sinir ağı yapılarında hemen hemen aynıdır. Bu sebeple farklı uygulama alanlarında da aynı hücre yapısı kullanılacaktır. Farklı uygulama alanlarında kullanılsalar dahi benzer teorilerini ve uygulama alanlarını paylaşabilmektedirler (Ballı, 2024).

Sadece nümerik bilgiler ile çalışabilme: Sembolik olarak ifade edilen bilgilerin nümerik ifadeye çevrilmesi gerekmektedir (Serttaş, 2011).

6.1.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağları hesaplama yapabilme gücünü ilk olarak paralel dağıtılmış yapısından, ikinci olarak öğrenme ve genelleştirme yeteneğinden almaktadır. Genelleştirme yapay sinir ağının öğrenme sırasında rastlanmayan girdilere çıktı üretmesi olarak tanımlanır. Karmaşık problemlerin çözümünde etkin kullanılmaktadır (Hatipoğlu, 2010).

Avantajları:

- Matematiksel modele ihtiyaç duymazlar. Verilerin yapay sinir ağının eğitiminde kullanılması için herhangi bir varsayıma rastlanılmamıştır.
- YSA, önceki tecrübelerinden öğrenebilir, bir kere eğitildiği zaman yeni bir problemin çözümünü sağlayabilir, bir örnekten yola çıkarak diğer örnekleri açıklayabilmektedir.
- Karmaşık problemlerde bilinmeyen ilişkileri kolayca ortaya çıkarabilir. Bu özelliği uygulama açısından oldukça önemlidir.
- Geleneksel bilgisayar sistemleri, bilgide oluşacak hataya karşı oldukça hassastır. Bir hata meydana geldiğinde sonuçta büyük hatalara yol açabilmektedir. Ancak yapay sinir ağlarında hata oluştuğu zaman geleneksel yöntemlerde olduğu kadar etkilenmez.
- Ağın yapısı, ağırlığı değiştiği zaman problem çözümünde kendini adapte edebilme yeteneğine sahiptir.
- Ağ doğrusal olmadığı için karmaşık problemleri daha doğru çözerler. Matematiksel olarak çözmek zordur (Yılmaz, 2010).
- Diğer sistemlere göre zaman bakımından verimli çalışıp daha kısa sürede sonuca ulaşılabilir.
- YSA'nın uygulanması hem pratik hem de ekonomiktir. Yalnızca probleme ilişkin verilere ihtiyaç duyulduğu için basit bir programla aile çözümüne ulaşılabilir (Eş, 2013).

Dezavantajları:

- Bir problemin çözümünde hata yapabilirler ya da uygun bir çözüm bulamayabilirler. Bunun sebebi ağı eğitecek fonksiyonun bulunmaması ya da yeterli verinin bulunmamasıdır.
- Farklı sistemlere uyarlanabilmesi zor olabilmektedir.

- YSA'nın kalitesi ve kapasitesi uygulama alanındaki hızı ile orantılıdır. Düğüm sayısının artışı bile çözüm süresinin artmasına sebep olabilir (Yılmaz, 2010).
- Ağın davranışları açıklanamadığı için yapay sinir ağına olan güven azalmaktadır.
- Bulunan çözüm en uygun çözüm değil de en iyi çözümlerden birisidir. Ancak geleneksel yöntemlerde en uygun çözümler üretilmektedir (Eş, 2013).

Tablo 6.1. Çeşitli sinir ağı modellerinin kuvvetli ve zayıf yönleri (Serttaş, 2011)


Sinir Modeli	Temel Uygulamalar	Kuvvetli Yönler	Zayıf Yönler
Kohonen (LVQ)	Eksik veri ve resim parçalarının tamamlanması, sınıflandırma	Geniş çaplı uygulama	Öğrenme yok, ağırlıkların verilmesi gerekli
Hopfield	Eksik veri ve resim parçalarının tamamlanması, sınıflandırma	Geleneksel optimizasyon algoritmaları ile çözülmesi mümkün olmayan karmaşık problemlerin çözülmesi	Ağın minimum hata düzeyine ulaşmasının her durumda mümkün olmaması
Algılayıcı (Perseptron)	Basılı yazı karakterlerinin tanınması	En eski sinir ağı	Karmaşık örüntüleri tanıyamama, değişikliklere karşı duyarlılık
Çok katmanlı algılayıcı/Delta kuralı	Örüntü (desen) tanıma	Basit algılayıcının geliştirilmiş hali	Karmaşık örüntülerin tanınmaması
Geriye yayma	Geniş uygulama alanı: konuşma sentezi ve analizi, kredi başvurusu değerlendirme	En popüler ağ, iyi çalışır, öğrenmesi kolaydır	Çok fazla örnekle desteklenen öğretmenli öğrenme
Boltzman Makinesi	Örüntü tanıma (radar, sonar)	Gürültü fonksiyonunu en küçük enerji seviyesine ulaştırmak için kullanılan ağ	Uzun öğrenme süresi
Kohonen Grosberg Ağı	Görüntü sıkıştırma, istatistiksel analiz, şekil tanıma ve kredi notlama	Çok katmanlı algılayıcı, geriye yayma algoritmasından daha hızlı, eksik ve kısmen yanlış verilerle çalışabilme	Çok sayıda yapay nöron ve bağlantı
SOM (Kohonen) Ağı	Geometrik bir alanı bir başkasına eşleştirme	Birçok algoritmik teknikten daha iyi performans	Yoğun eğitim gereksinimi, uzun öğrenme süresi
Neocognitron Ağı	El yazısı karakterlerin tanınması	İnsan görme sistemini modelleyen, karmaşık örüntüleri algılayabilen ileri düzey bir ağ	Çok sayıda yapay nöron ve bağlantı

6.1.5. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

Yapay sinir hücreleri beynin sinir hücrelerine benzetilmektedir. Biyolojik sinir ağları sinir hücrelerinden oluşurken, yapay sinir ağları da yapay sinir hücrelerinden oluşmaktadır. YSA hücreleri süreç elemanları olarak da adlandırılmaktadır. Bir yapay sinir hücresinin girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 tane temel elemanı vardır (Demirceylan, 2012).

6.1.5.1. Biyolojik Sinir Hücreleri

İnsan beynini oluşturan en temel taşlardan biri biyolojik sinir hücreleridir. Milyarlarca sinir hücresinin bir araya gelmesiyle birlikte bir sinir ağı oluşur. Biyolojik sinir hücresi; sinapslar, soma (hücre gövdesi), akson ve dentritlerden oluşmaktadır. Sinir hücreleri arasında elektrik sinyallerinin iletilmesini sağlayan bağlantılara sinapslar denir. Daha sonra bu sinyaller somaya ve dentritlere iletilmektedir. Bu sinyalleri sinapslara gönderip diğer sinir hücrelerine aktarılır (Adıyaman, 2007).



Şekil 6.3. Biyolojik sinir hücresi

İnsan beyninde yaklaşık 10 milyar sinir hücresi, nöronların birbiriyle olan bağlantı sayısının 60 trilyon olduğu düşünülmektedir. Girdi bilgilerini duyu organlarından almaktadır. Taşıyıcı sinirler sinyalleri işleyerek bir sonraki sinire aktarır, sinir sistemine kadar ulaşmasını sağlamaktadır. Merkezi sinir sistemi gelen sinyalleri yorumladıktan sonra tepki sinyali üretir. Bu sinyaller de tepki sinirleri yoluyla tepkilerin oluşacağı organlara iletilir. Duyu organından gelen bilgiye karşı tepki organına işaret sinir sistemi yoluyla gönderilir (Kakıcı, 2017).


Tablo 6.2. Biyolojik sinir sistemi ile YSA'nın benzerlikleri

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron (Sinir)	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

6.1.5.2. Yapay Sinir Hücresi

Yapay sinir hücreleri, yapay sinir ağının temel birimleridir. Yapay sinir hücreleri girdilerden bilgiyi alır ve bunlardan bir çıktı üretmeye çalışır (Metin, 2018).

Yapay sinir hücresinin yapısı aşağıdaki şekilde gösterilmiştir.



a. Girdiler

Yapay sinir hücresine gelen bilgidir. Bu bilgiler diğer sinir hücresinden ya da dış ortamdan gelebilir (Demirceylan, 2012).

b. Ağırlıklar

Yapay sinir hücresine giren bilgilerin hangi ağırlıkta değerlendirilmesi gerektiğini belirleyen değerlerdir. Ağırlıkların negatif veya pozitif olması ağa etkisinin hangi yönde olacağını göstermektedir. Sinir hücresinin ağırlığı sabit olacağı gibi değişken de olabilir (Yılmaz, 2010).

c. Toplama Fonksiyonu

Birleştirme fonksiyonunun en yaygın kullanılan türü olan toplama fonksiyonu, biyolojik sinir hücresinde dentritlerin yaptığı görevi yapmaktadır. Sinir hücresine giren net girdileri hesaplamaktadır. Girdilerin ilgili ağırlıkla çarpımının toplamıdır. Net girdinin hesaplanma işlemidir. Bu fonksiyon aşağıdaki formülle gösterilmektedir.

$$Net = \sum G_i \cdot A_i \quad (n = 1, \dots, n) \quad (6.1)$$

Bu formülde G girdileri, A ağırlıkları, n girdi sayısını gösterir. Bir problemde optimal toplama fonksiyonunun bulunmasını sağlayacak bir formül yoktur. Her girdi aynı toplama fonksiyonuna sahip olabileceği gibi farklı toplama fonksiyonuna da sahip olabilmektedir. Aşağıdaki örnekler de toplama fonksiyonuna örnek olarak verilebilir:

- Maksimum: $Net = \text{Max} (G_i \cdot A_i)$
- Minimum: $Net = \text{Min} (G_i \cdot A_i)$
- Çarpım: $Net = \sum G_i \cdot A_i$
- Kümülatif Toplam: $Net = \text{NET}_{(eski)} + \sum (G_i \cdot A_i)$
- Çoğunluk: $Net = \sum \text{sgn} (G_i \cdot A_i)$ (Ballı, 2014).

d. Aktivasyon Fonksiyonu

Hücre davranışını belirleyen bir diğer fonksiyonlardan birisi de aktivasyon fonksiyonudur. Toplam fonksiyonunun sonuçları ile birlikte çıktıya dönüştürülür. Sinir hücresine gelen girdinin işlenerek ne kadar çıktı üreteceğini belirlemektedir. Aktivasyon fonksiyonunun amacı, çıktıların büyük değerlere ulaşmasını engellemektir. Çıktı yüksek çıkarsa ağ eğitimi engellenmiş olmaktadır. Bir yapay sinir ağında aktivasyon fonksiyonu nöronun çıkış değerini $[0,1]$ veya $[-1,1]$ arasında sınırlamaktadır. Linear, Logaritmik Sigmoid ve Hiperbolik Tanjant modelleri en sık kullanılan aktivasyon modelleridir.

e. Çıktılar

Çıktılar en uç katman olarak bilinmektedir. Ağların sonuçlarıdır ve birden fazla girdiye sahip olabilmektedir. Gizli katmandan veriyi alıp işler ve çıktısını vermektedir. Çıktı katmanındaki sinir hücre sayısı, yapay sinir ağına sunulan her verinin çıkış sayısı kadardır. Aktivasyon fonksiyonu tarafından çıktı oluşturulmaktadır. Her sinir ağının sadece bir çıktı düzeyi bulunmaktadır (Oğuz, 2019).


6.1.5.3. Yapay Sinir Ağları Mimarileri

Yapay sinir ağları bağlantıların ağ içerisindeki işaretlerin yönüne veya bağlantıların yönüne göre sınıflandırılmaktadır. Bunlar; tek katmanlı ileri beslemeli ağlar, çok katmanlı ileri beslemeli ağlar ve geri beslemeli ağlardır (Taşkın, 2018).

Bir yapay sinir ağının kaç katmanı olduğu sorusuna cevap, kaç adet gizli katmanı olduğudur. Tek katmanlı modeller, basit ve linear problemlerin çözümünde kullanılır. Ancak çok katmanlı modellerde karmaşık ve nonlinear problemlerin çözümünde kullanılmaktadır. Yapay sinir ağları sahip olduğu katman sayısına bağlı olarak tek katmanlı ve çok katmanlı olarak iki gruba ayrılmaktadır (Çakır, 2019).

a. Tek katmanlı ileri beslemeli yapay sinir ağları

Tek katmanlı yapay sinir ağlarında girdi verilerinin sisteme iletiildiği giriş nodları ve çıktı nöronlarının bulunduğu çıkış katmanı bulunmaktadır. Çıkış katmanında bulunan aktivasyon fonksiyonu yardımıyla ağın çıkış değeri hesaplanmaktadır ve aktivasyon fonksiyonu yalnızca çıkış katmanında bulunur (Taşkın, 2018).



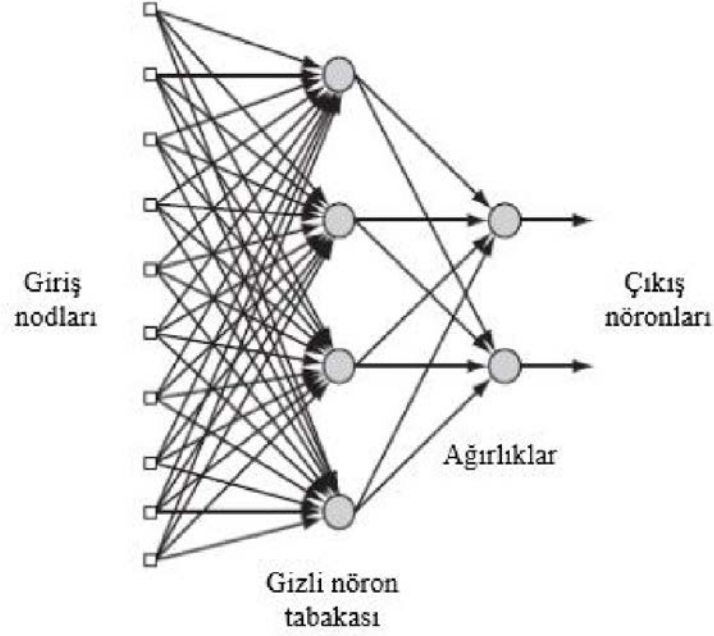
Şekil 6.5 Tek katmanlı ileri beslemeli yapay sinir ağı (Taşkın, 2018)

En basit tek katmanlı yapay sinir ağı “Perceptron” dur. Perceptron kavramı Frank Roseblant tarafından örüntü sınıflandırma amacıyla geliştirilmiştir. Roseblant yapay zekâ konusunda çalışmalar yapan Amerikalı bir psikologdur. Hebb’ in geliştirdiği mimariye benzemektedir. Bu modelde önemli olan eşik değeridir. Hebb mimarisinden farklı olan kısmı modelde bulanık bir bölgenin bulunuyor olmasıdır. Bu sebeple sınıflandırma Hebb modeline göre daha dikkatli yapılmaktadır. Çıktılar arasına doğru çizilebiliyor ve çıktı değerleri bu doğrular ile ayrılabilir Perceptron kullanılabilir (Çakır, 2019).

b. Çok katmanlı ileri beslemeli yapay sinir ağları

Doğrusal problemlerin çözümünde tek katmanlı algılayıcılar kullanılmaktadır. Fakat gerçek hayat problemlerinin birçoğu doğrusal formda olmayabilir. Tek katmanlı algılayıcılar doğrusal olmayan problemler için sonuç üretmez. 1969 yılı tek katmanlı yapay sinir ağlarının yetersiz olduğu keşfedildiği bir yıl olmuştur. Çözülmemesi sonucu yapay sinir ağları kavramına ilgi azalmıştır. Çok katmanlı algılayıcıların oluşturulması ile birlikte YSA kavramı yeniden canlanmıştır.

Çok katmanlı ileri beslemeli yapay sinir ağlarında nöronlar arasındaki bilgi, girişten çıkışa doğru tek yönlü düzenli katmanlar halinde gerçekleşir. Bir katman yalnızca kendinden sonraki katmana bağlıdır ve bir nöronun çıktısı yalnızca kendinden sonra gelen nöron katmanına girdi olabilmektedir (Çakır, 2019).



Şekil 6.6. Çok katmanlı ileri beslemeli yapay sinir ağı (Taşkın, 2018)

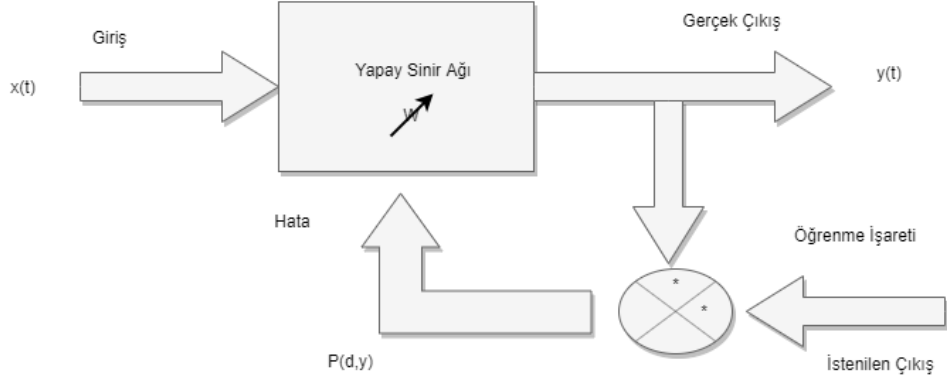
Kullanım alanı oldukça yaygın olan çok katmanlı yapay sinir ağı (MLP); bir giriş, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katmanda bir ya da daha fazla işlemci bulunabilir (Ballı, 2014).

6.1.6. Yapay Sinir Ağları Öğrenme Stratejisi

Yapay sinir ağlarında öğrenme, yapının en iyi sonucu vermesini sağlayacak bağlantı ağırlıklarının hesaplanması işlemine denir. Literatürde genel olarak bilinen üç öğrenme stratejisi vardır.

6.1.6.1. Gözetimli (Öğretmenli) Öğrenme Yöntemi

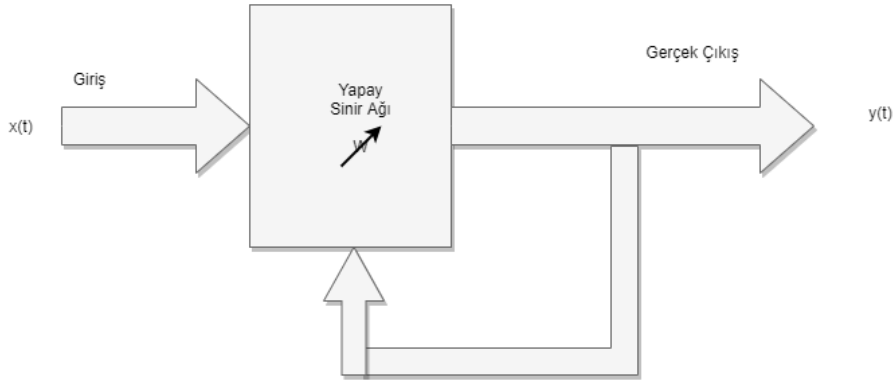
Bu öğrenme yönteminde ağın öğrenebilmesi için bir öğretmen faktörü yer almaktadır. Ağın öğrenme işlemini sağlayabilmesi için öğrenilmesi istenen olayın girdi verileri, girdiler sonucunda olması gereken çıktı değerleri sisteme öğretilir. Böylece sistem kendisine verilen girdiler ile oluşturması gereken çıktı verileri hakkında bilgi edinmiş olur. Çıktı değerleri tam olarak bilindiği için yapay sinir ağının ürettiği değerler ile karşılaştırılır ve hata toleransı bu noktada önemlidir. Yapay sinir ağının çıktıları ile ağdan beklenen çıktılar arasındaki farklar alınır ve hata miktarı her bir nöron için belirlenir. Hata miktarlarına göre nöronlar kendi ağırlıklarını güncellemektedir.



Şekil 6.7. Gözetimli öğrenme

6.1.6.2. Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi

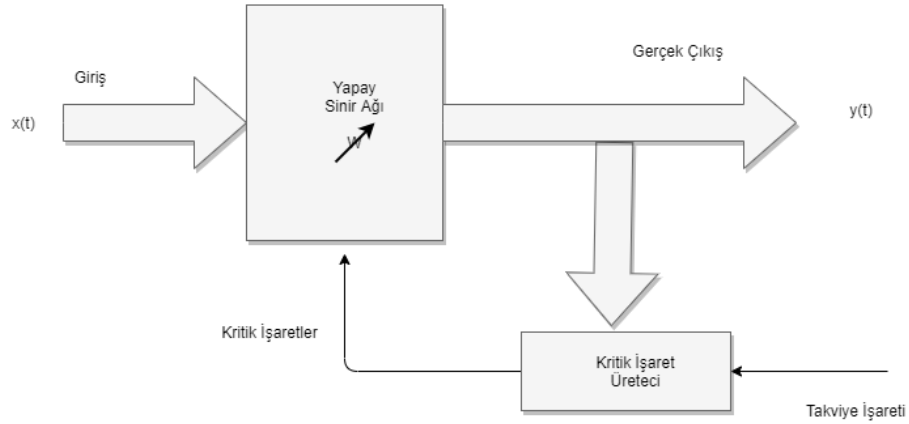
Bu öğrenme yönteminde ağın öğrenebilmesi için herhangi bir öğretmen yoktur. Bu Öğrenme sistemi daha çok kümeleme çalışmalarında kullanılmaktadır (Öztemel, 2012). Sistem kendisine öğretilen girdiler ile çıktılar üretmeye çalışır. Sistemin girdi verilerindeki parametreler ile arasındaki bağlantıyı kendi kendine öğrenmesi beklenmektedir. Ağın öğrenme işlemi bittikten sonra sistemi çalıştıran kişinin çıktıları yorumlaması gerekir.



Şekil 6.8. Gözetimsiz öğrenme

6.1.6.3. Destekleyici Öğrenme Yöntemi

Gözetimli öğrenme yöntemine benzemektedir. Gözetimli öğrenme yöntemi gibi sisteme bir öğretmen yardım etmektedir. Bu öğrenme yönteminde öğretmenin “başarısız” komutuyla birlikte sistem tekrar çalışır ve “başarılı” komutunu alana kadar ağı eğitimi devam ettirilir (Sönmez Çakır, 2019). Gözetimli öğrenmede olduğu gibi girdi değerlerine karşılık sistemin üretmesi beklenen çıktı verileri sisteme verilmez. Bu yöntemde sistemden beklenen girdi değerlerine karşılık çıktı değerlerini kendisinin üretmesidir. Sistem üretilen çıktı değerinin doğru olduğuna karar verirse öğrenme sürecini tamamlar. Çıktı değerlerinin yanlış olduğuna karar verirse öğrenme süreci doğru çıktı değerleri üretilene kadar devam eder.



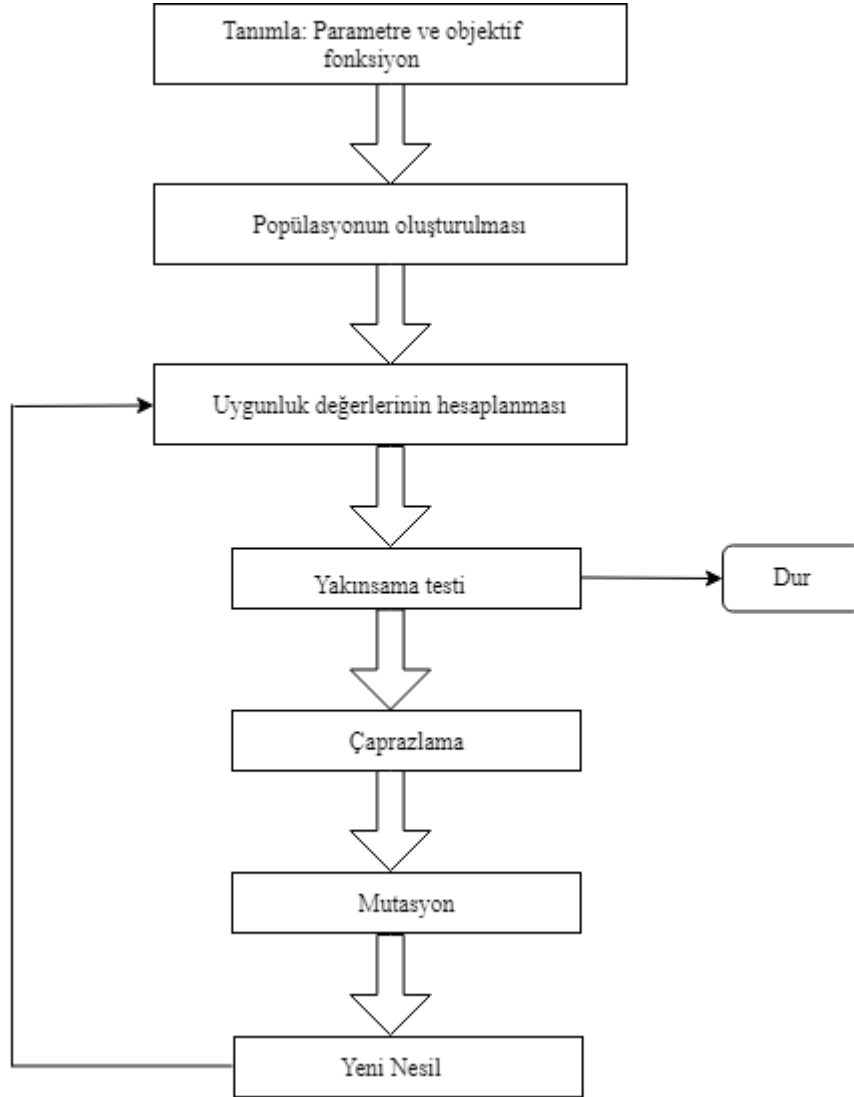
Şekil 6.9. Destekleyici öğrenme

6.2. Genetik Algoritma

Genetik algoritma, doğada gözlemlenen evrimsel sürece benzer bir şekilde çalışan optimizasyon yöntemidir. Genetik algoritmalar uzun araştırmalar sonucunda ilk olarak John Holland tarafından optimizasyon problemlerinde kullanılmıştır. Temel ilkeleri belirlendikten sonra birçok çalışma yapılmıştır. Geleneksel optimizasyon yöntemleri ile arasında farklılıklar bulunmaktadır. Genetik algoritmalar parametre kümesini kullanmazken kodlanmış biçimlerini kullanırlar. Yalnızca amaç fonksiyonuna ihtiyacı olan genetik algoritmalar çözüm kümesinin tamamını değil, yalnızca bir kısmını tararlar. Böylelikle hızlı ve kısa bir sürede etkin sonuca ulaşılır (Emel ve Taşkın, 2002).

Genetik algoritma parametreleri, biyolojideki genleri temsil etmektedir. Parametrelerin toplu kümesi de kromozomu oluşturur. Genetik algoritmanın her olası çözümü kromozomu temsil eder. Olası çözümler kümesine popülasyon denmektedir. Belirli kurallar çerçevesinde popülasyonun uygunluğu minimize ya da maksimize edilir.

6.2.1. Genetik Algoritma Akış Diyagramı



Şekil 6.10. Genetik algoritma akış diyagramı

Genetik algoritma çalışma basamakları aşağıda anlatılmaktadır.

1. Bir başlangıç popülasyonu oluşturulur. Popülasyonda bulunacak kromozom (birey) sayısı problemin türüne göre değişiklik gösterebilir. Popülasyon rastgele oluşturulmaktadır. Problemin türüne göre farklı yöntemlerle kodlanmaktadır.

2. Amaç fonksiyonu kullanılarak her bireyin uygunluk değeri hesaplanmaktadır. Genetik algoritmanın başarılı olması genellikle amaç fonksiyonunun doğru tespit edilmesine bağlıdır. Bu çalışma adımında en iyi kromozom seçilip yerel çözüm belirlenir.
3. Önceden belirlenen jenerasyon sayısı ya da herhangi bir ideal küresel çözüm durdurma ölçütü olarak verilebilir. Durdurma ölçütü test edilir. Kriterler sağlanmışsa algoritma durdurulur ve en son elde edilen küresel çözüm yerel çözüm olarak kabul edilir. Ancak kriter sağlanmamışsa bir sonraki adıma geçilir.
4. Çaprazlama olacak kromozomlar oluşturulurken uygunluk değeri baz alınır. Seçilen kromozomlar mutasyon ve çaprazlama yapılarak yeni nesil bireyler oluşturulur. 2. Adıma tekrar gidilir. Fakat popülasyonun büyüklüğü sabit kalmalıdır.

6.2.2. Genetik Algoritma Parametreleri


Genetik algoritmalarda bilinen üç temel genetik işlemci bulunmaktadır: Seçilim, çaprazlama ve mutasyon. Çaprazlama işlemcisi için popülasyondan önce iki tane birey seçilir. Daha sonra bu bireylerde çaprazlanma işlemi yapılacak nokta belirlenir ve karşılıklı olarak yer değiştirme işlemi gerçekleşir. Bu işlem sonucunda iki yeni birey elde edilmiş olur. Mutasyon ile bireylerin genleri değiştirilmektedir. Gen değişimi popülasyonun %1 ile %5'lik bir kısmını kapsamaktadır. Bu işlem popülasyonda çeşitliliğe sebep olur (Özsağlam ve Cunkaş, 2008).

6.2.2.1. Seçilim

Uygunluk değerine yakın olan kromozomların neslini devam ettirebilmesi ve hayatta kalabilmesi için problemin çözümüne daha hızlı ve doğru bir şekilde ulaşması gerekmektedir. En iyi kromozomların seçilmesi için birden çok yöntem geliştirilmiştir. Çalışmalarda sıklıkla kullanılan yöntemler; rulet çarkı, elitist strateji ve turnuma seçim yöntemleridir (Emek, 2016).

6.2.2.2. Çaprazlama

Genetik algoritma işlemcisi olan çaprazlama, kromozomun yapısını değiştirmek ve yeni özellikli bireylerin oluşturulması için kullanılır. Birden fazla ebeveyn yardımıyla yeni bireyler oluşturulur (Akan,2017). Çaprazla işlemi sonucunda oluşan bireyler ebeveynlerin özelliklerini taşımaktadır.




Şekil 6.11. Çaprazlama işlemcisi temel süreci

Literatürde çaprazlama işlemcisini 6 temel başlıkta incelenmektedir:

- Tek nokta çaprazlama
- Çift nokta çaprazlama
- Sıraya dayalı çaprazlama
- Pozisyona dayalı çaprazlama
- Uniform çaprazlama
- Kısmi planlı çaprazlama (Alcan,2014).

6.2.2.3. Mutasyon

Genetik algoritma yöntemi ile belirli orandaki popülasyon ile çalışıldığı için belli bir süre sonra kromozomu oluşturan genler olabilir. Çaprazlama işlemcisi ile kromozomu değiştirebilmek olanaksızdır. Çaprazlamadan sonra kromozomlar mutasyona uğratılır. Kromozomlara mutasyon işlemcisi ile dışarıdan müdahale edilir ve rastgele gen değişikli yapılır (Akan, 2017). Mutasyon işlemcisinin amacı kromozomların genetik özelliğini değiştirmek ve popülasyonda çeşitlilik oluşturmaktır.



Şekil 6.12. Mutasyon işlemcisi temel süreci

Literatürde mutasyon işlemcisi 5 temel başlıkta incelenmektedir:

- Ters mutasyon
- Komşu iki gen değiştirme
- Keyfi iki gen değiştirme
- Keyfi üç gen değiştirme
- Araya yerleştirme (Alcan, 2014).


6.3. Parçacık Sürü Optimizasyonu

Parçacık sürü optimizasyonu, Kenedy ve Eberhart tarafından 1995 yılına sürü halinde hareket eden böcekler ve balıklardan esinlenilerek geliştirilmiş bir optimizasyon yöntemidir. Sürü zekasını temel alan bir algoritmadır. Kuş sürüleri, balık sürüleri ve diğer sürü halinde hareket eden hayvanların yiyecek ararken ve güvenlik gibi durumlarda rastgele gösterdikleri hareketler incelendiğinde amaçlarına daha hızlı ve kolay eriştikleri gözlemlenmiştir. Bu sosyal etkileşim parçacık sürü optimizasyonu ile modellenmiştir (Özsağlam ve Cunkaş, 2008).

Parçacık sürü optimizasyonu, genetik algoritma gibi evrimsel bir algoritmadır. Sürüdeki her bir bireye parçacık denir. Genetik algoritma yönteminde tüm çözümlere popülasyon adı verilirken PSO yönteminde sürü adı verilmektedir. PSO, GA gibi evrimsel bir algoritma olmasına rağmen çözümü daha basittir. Genetik algortmada çaprazlama ve mutasyon gibi işlemciler varken PSO'da bulunmamaktadır. Bu sebeple optimum çözüme ulaşılması daha hızlı gerçekleşir (Erdoğan ve Yalçın, 2015).

PSO çizelgeleme problemleri, güç ve voltaj kontrolü, sipariş miktarı belirleme, tedarik seçimi gibi birçok problemde başarılı sonuçlar veren bir optimizasyon yöntemidir.

6.3.1. Parçacık Sürü Optimizasyonu Akış Diyagramı



Şekil 6.13. Parçacık sürü optimizasyonu akış diyagramı

PSO algoritması temel olarak aşağıdaki çalışma adımlarından oluşmaktadır.

1. Başlangıç sürüsü rastgele üretilen başlangıç hızları ve pozisyonları ile oluşturulur.
2. Sürü içinde bulunan bütün parçacıkların uygunluk değerleri hesaplanır.
3. Mevcut jenerasyondan her bir parçacık için yerel en iyi (pbest) bulunur. Sürü içindeki en iyilerin sayısı, parçacık sayısı kadar olmalıdır.
4. Mevcut jenerasyonda bulunan yerel en iyiler (pbest) içinden küresel en iyi (gbest) seçilir.
5. Pozisyon ve hızlar formülde verildiği gibi yenilenir.

$$V_{id} = W * V_{id} + c_1 * rand_1 * (P_{id} - X_{id}) + c_2 * rand_2 * (P_{gd} - X_{id}) \quad (6.2)$$

$$X_{id} = X_{id} + V_{id} \quad (6.3)$$

X_{id} pozisyon, V_{id} hız değerlerini verir. $rand_1$ ve $rand_2$ rastgele üretilmiş sayılardır. W atalet ağırlık değerini, C_1 ve C_2 değerleri ölçeklendirme faktörlerini temsil etmektedir.

6. Durdurma kriteri sağlanmışsa sonuç alınır, sağlanmamışsa 2, 3, 4 ve 5..adımlar tekrarlanır (Özsağlam ve Cunkaş, 2008).

6.3.2. Parçacık Sürü Optimizasyonu Parametreleri

Parçacık sürü optimizasyonunda seçilen parametreler, algoritmanın sistemine ve çözüme ulaşma süresine etki etmektedir.

6.3.2.1. Sürünün Büyüklüğü

Sürünün büyüklüğü parçacık sayısını ifade eder. Sürüde daha fazla parçacık olması her yinelemede Sürü büyüklüğünün fazla olması her yinelemede o kadar fazla konum araştırabildiği anlamına gelir. Ancak parçacık sayısının fazla olması yineleme miktarını artırdığı için hesaplama süresinde artışa sebep olur.

6.3.2.2. Yineleme Sayısı

Parçacık sürü optimizasyonunda sürünün büyüklüğüne göre yineleme sayısı değişiklik göstermektedir. Ancak yineleme sayısının artması hesaplamada karmaşıklık oluşturabilir ve çözüme ulaşmasının uzamasına sebep olabilir.

6.3.2.3. Bilişsel ve Sosyal Bileşenler

Bilişsel ve sosyal bileşenler olan c_1 ve c_2 optimizasyon boyunca sabit olarak kabul edilmektedir. Bilişsel bileşen sosyal bileşenden büyük olursa sürüdeki parçacık kendi en iyi değerine doğru yönelir. Tam tersi şekilde sosyal bileşen bilişsel bileşenden büyük olursa parçacıklar en iyi küresel değer doğru hareket ederler. Her iki bileşen dengelendiği zaman parçacık sürü optimizasyonu verimli bir şekilde çalışır.

6.3.2.4. En Yüksek Hız

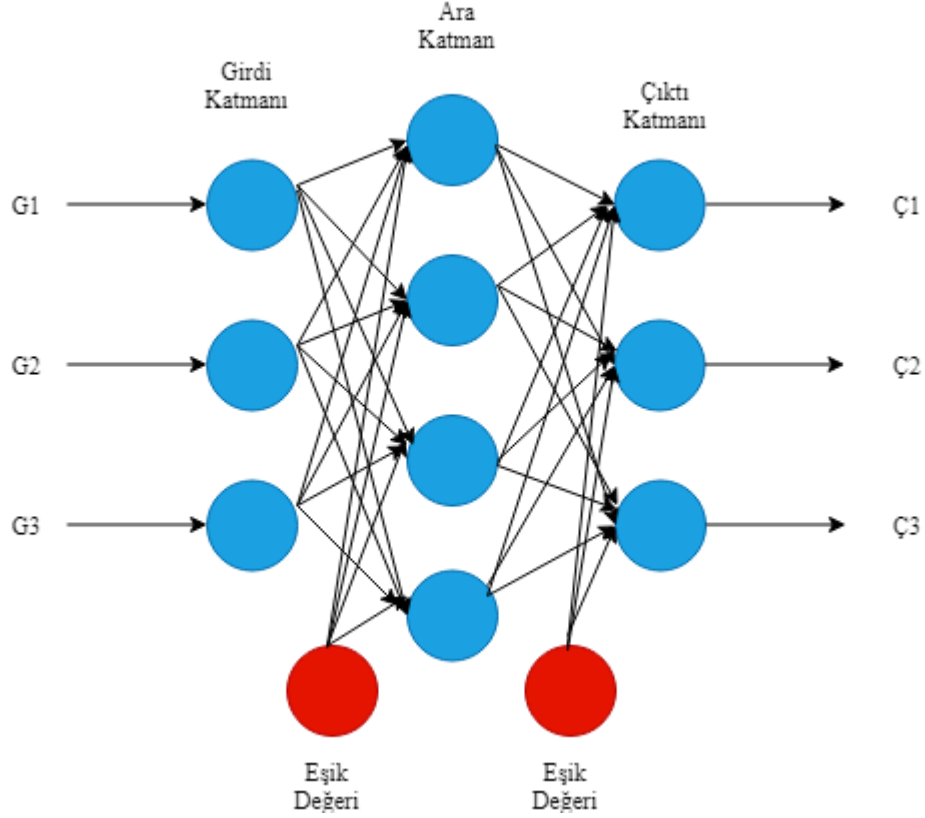
Sürüdeki parçacıkların hızı V_{max} değeri ile kısıtlanmaktadır. Parçacıkların çözüm uzayı içinde kalmasını sağlayacak parametrenin olmayışı en yüksek hız değerinin ortaya çıkmasına sebep olmuştur. Bir parçacık V_{max} değerinin üstüne çıkarsa o parçacığın hızı V_{max} değeri olarak belirlenmektedir (Akbulut, 2009).

6.4. Çok Katmanlı Algılayıcı

Doğrusal olmayan problemlerin çözümünde tek katmanlı algılayıcıların başarısız olmaları sonucunda çok katmanlı algılayıcı kavramı oluşmuştur. Çok katmanlı algılayıcılarda, veri girişi yapılan girdi katmanı, gizli katmandan ve bir çıktı

katmanından oluşmaktadır. Tüm katmanlar birbiriyle bağlantılıdır. Katmanlar arasında geri ve ileri yayılım denilen geçişler bulunmaktadır. İleri yayılım aşamasında, yapay sinir ağının çıktısı ve hata değeri hesaplanmaktadır. Ger yayılım aşamasında bulunan hata değerini minimize etmek için katmanlar arasındaki bağlantının ağırlık değerleri güncellenmektedir (Arı ve Berberler, 2017).

Şekil 6.14. te Çok Katmanlı Algılayıcının topolojik yapısı gösterilmiştir.



Şekil 6.14. Çok katmanlı algılayıcı topolojik yapısı

6.5. Grup Veri İşleme Yöntemi (GMDH)

Grup veri işleme yöntemi, oluşturulan modelin otomatik yapısal ve parametrik optimizasyonunu içinde bulunduran çok değişkenli veri kümelerinin bilgisayar tabanlı matematiksel modellemesidir.

GMDH algoritmasının yurtdışındaki ilk araştırması R. Shankar tarafından 1972 yılında yapılmıştır. Shankar'a göre yapay zeka problemlerinde kullanılacak en iyi yöntemdir.

Grup veri işleme yöntemi, optimizasyon ve örüntü tanıma, tahmin ve veri madenciliği, derin öğrenme ve bilgi keşfi gibi birçok alanda uygulanmaktadır. Grup

veri işleme yöntemi algoritmaları ile verilerdeki ilişkileri bulma, ağın optimum yapısını belirleme, var olan algoritmanın doğruluğu artırma olanağı sağlamaktadır.

GMDH ağı, çeşitli çözümleri bularak kullanıcının etkisini en aza indirmeyi amaçlar. Bilgisayar, ağın optimal sonuçlarını bulunur. Grup veri işleme yöntemi, kümeleme, parametrik, analog karmaşıklıklaştırma, olasılık ve yeniden birleştirme algoritmalarından oluşur.

Avantajları:

- Gizli katmanların nöron ve katman sayısı, değişkenler, modelin yapısı otomatik olarak belirlenir.
- GMDH algoritmaları en iyi çözümü en doğru ve tarafsız şekilde sunacağını garanti etmektedir.
- Veri içindeki yorumlanabilir ilişkileri otomatik seçer ve etkisi olan parametreleri belirler.
- Yazılım geliştirmek için GMDH sıralama algoritmaları oldukça basittir (Anonim, 2020).

Tablo 6.3. Grup veri işleme yöntemi algoritmaları

	GMDH Algoritmaları	
Değişkenler	Parametrik	Parametrik Olmayan
Sürekli	<ul style="list-style-type: none"> -Kombinatoryal (COMBI) -Çok Katmanlı Yinelemeli (MIA) -GN -Hedef Sistem Analizi (OSA) -Harmonik -İki seviyeli (ARIMAD) -Çok Katmanlı Katkı (MAA) 	<ul style="list-style-type: none"> -Hedef Bilgisayar Kümelemesi (OCC) -İşaret Parmağı (PF) kümeleme algoritması -Analog Kompleks Oluşturma (AC)
Ayrık veya ikili	-Harmonik Yeniden Ayrıştırma	-Çok Katmanlı İstatistik Kararlar Teorisi (MTSD) temelinde algoritma

7. TALEP TAHMİNİ UYGULAMASI

Bu çalışmada Samsun ili doğal gaz tüketiminin farklı yapay sinir ağı algoritmaları ile tahmin edilmesi amaçlanmıştır. Doğal gaz tüketimine etki edebilecek parametreler ve doğal gaz tüketim verileri Samsun Meteoroloji 10. Bölge Müdürlüğünden ve SAMGAZ Doğal Gaz Dağıtım AŞ'den elde edilmiştir.

7.1. Yapay Sinir Ağı Probleminin Tanımlanması

Doğal gaz tüketimini etkileyen Meteoroloji 10. Bölge Müdürlüğü ve Samgaz firmalarından alınan veriler aşağıdaki gibidir:

- Doğal Gaz Tüketim Verileri
- Konut Fiyatı (Sm³/TL)
- Serbest Tüketici Fiyat (Sm³/TL)
- Aylık Ortalama Aktüel Basınç (hPa)
- Aylık Ortalama Nispi Nem (%)
- Aylık Ortalama Rüzgar Hızı (m÷sn)
- Aylık Ortalama Sıcaklık (°C)
- Aylık Toplam Güneşlenme Süresi (saat)

Veriler 2009-2108 yılları arasında aylık bazda toplanmıştır.

Bu çalışma ile Samsun ili doğal gaz tüketiminin farklı 5 yapay sinir algoritması ile tahmin edilmesi amaçlanmıştır. Bu algoritmalar: Yapay Sinir Ağı (ANN), Genetik Algoritma (GA), Çok Katmanlı Algılayıcı (MLP), Parçacık Sürü Optimizasyonu (PSO), Grup Veri İşleme Yöntemi (GMDH). Uygulamada MATLAB programı kullanılarak sonuçların bulunması hedeflenmektedir.

7.2. MATLAB Hakkında Genel Bilgi

Yapay sinir ağı kullanılarak yürütülen çalışmalarda bilgisayar desteği olması kaçınılmazdır. İlk yapay sinir ağı modeli elektronik olarak tasarlanmıştır. Ancak bilgisayar ortamının getirdiği üstünlükler sebebiyle ilk tasarlanan elektronik devre ortamından bilgisayar sistemlerine geçişi sağlanmıştır. Bilgisayarın problemi hızlı çözmesi, karmaşık problemleri tüm kapsamıyla algılayıp modelin geliştirilmesine hızlı olanak sağlaması bakımından oldukça yararlı olduğu görülmektedir (Akkurt,2005).

MATLAB yüksek performans gösteren bir programlama dilidir. Programa gösterilen tüm girdiler ve çıktılar ile diğer programların belirteçlerine gerek duymadan bir matris tanımlar. MATLAB programı üniversitelerde kullanıldığı gibi iş sahalarında mühendislik ve araştırma alanlarında karşılaşılan problemlere hızlı ve pratik çözümler sunmaktadır.

MATLAB programından bahsederken Simulink ve Toolbox alt başlıklarına değinmek gerekir. Gerçek zamanlı uygulamaların benzetimi için Simulink kullanımı uygundur (Akkurt, 2005). MATLAB programında “Araç Kutusu” (Toolbox) olarak belirtilen özellikler bulunmaktadır. Bu özellik sayesinde, kullanıcıların herhangi bir kod yazmasına gerek kalmadan hazır fonksiyon dosyaları ile M-dosya işleme ve derleme, dış aygıtlarla gerçek zamanlı çalışma, veri tabanı oluşturma, dijital sinyal işleme, iletişim kurma ve işleme, Excel bağlantısı kurma, görüntü işleme, finansal zaman serilerini kullanma, güç sistemlerini modelleme, yapay sinir ağı modelleme, sistem tanımlama, bulanık mantık ve daha birçok durumu inceler ve çözüm üretir (Uzunoglu, vd., 2005).

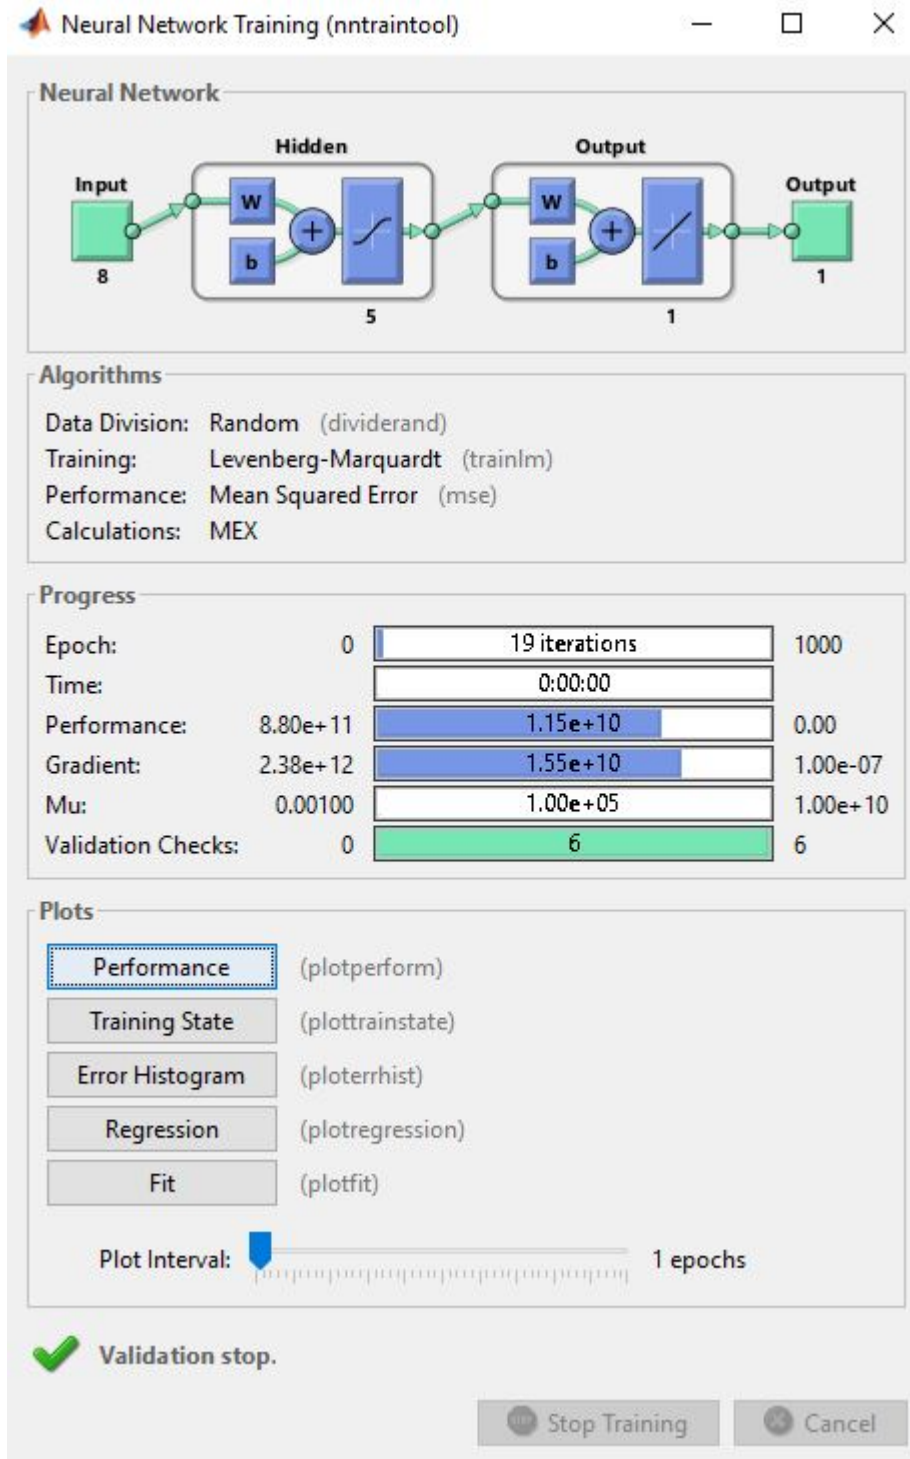
Bu tez çalışmasında yapay sinir ağı uygulamalarında MATLAB programında yer alan yapay sinir ağı alt modülleri kullanılmıştır.

7.3. Yapay Sinir Ağının Eğitilmesi ve Test Edilmesi

Bu uygulamada doğal gaz tüketim tahmini için kullandığımız model 8 girdi, 5 gizli katman ve 1 çıktı katmanından oluşan bir yapay sinir ağı modelidir.

Bu çalışmada 2009-2018 yıllarına ait 8 parametrelilik veriler kullanılmıştır. Ağın eğitiminde kullanılan veri setinin kapsamlı olması ağın girdi ve çıktı verileri arasındaki ilişkiyi daha iyi anlamlandırmasını sağlamaktadır.

Yapay sinir ağının eğitiminde, Levenberg-Marquart (LM) algoritması kullanılmış olup, ağların eğitimi kararlı ve hızlı gerçekleştirilmesi sebebiyle sıklıkla tercih edilmektedir.



Şekil 7.1. Yapay sinir ağı eğitim aşaması

Çalışmada kullanılan farklı algoritmaların doğruluğunu ölçmek için 6 ayrı performans kriteri belirlenmiştir. Bunlar R, R^2 , MSE (ortalama hata karesi), RMSE (kök ortalama hata karesi), hata değeri (μ), standart sapma (σ) değerleridir.

R değeri iki rassal değişen arasındaki ilişkinin yönünü ve gücünü belirler. R^2 değeri, tahmin sonuçları ile gerçek veri sonuçlarının arasındaki ilişkiyi ölçer.

Sonucun 1'e yakın olması tahminleme sonucunun ölçülen veriyle olan ilişkisinin yüksek olduğunu ifade eder.

$$R^2 = \frac{\text{Regresyon Kareler Toplamı}}{\text{Genel Kareler Toplamı}} = 1 - \frac{\text{Hata Kareler Toplamı}}{\text{Genel Kareler Toplamı}} \quad (7.1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_e(i) - x_m(i))^2}{\sum_{i=1}^n x_m(i)^2} \quad (7.2)$$

n= veri çifti sayısı

$x_e(i)$ = tahmin edilen veri

$x_m(i)$ = ölçülen veri

MSE (ortalama hata karesi) değeri tahmin edilen değer ile gerçek değer arasındaki ortalama kare farkını ölçer. Her zaman pozitif değerlidir.

$$MSE = \frac{1}{N} \sum_{i=1}^N e_i^2 \quad (7.3)$$

RMSE (kök ortalama hata karesi) tahmin edilen değer ile gerçek değerler arasındaki uzaklığı ifade eder.


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (7.4)$$

7.4. Yapay Sinir Ağı Uygulaması ve Matlab Kullanımı

Doğal gaz tüketim tahmininde kullanılan yapay sinir ağları, genetik algoritma, çok katmanlı algılayıcı, parçacık sürü optimizasyonu ve grup veri işleme yönteminin ağ yapıları MATLAB uygulamasında kodlama yapılarak çalıştırılmıştır. En başarılı tahminlemeyi yapan algoritma seçilmeye çalışılmıştır. Yapay sinir ağına doğal gaz tüketim verileri, konut fiyatı (Sm^3/TL), serbest tüketici fiyat (Sm^3/TL), aylık ortalama aktüel basınç (hPa), aylık ortalama nispi nem (%), aylık ortalama rüzgar

hızı (m÷sn), aylık ortalama sıcaklık (°C), aylık toplam güneşlenme süresi (saat) kullanılmıştır.

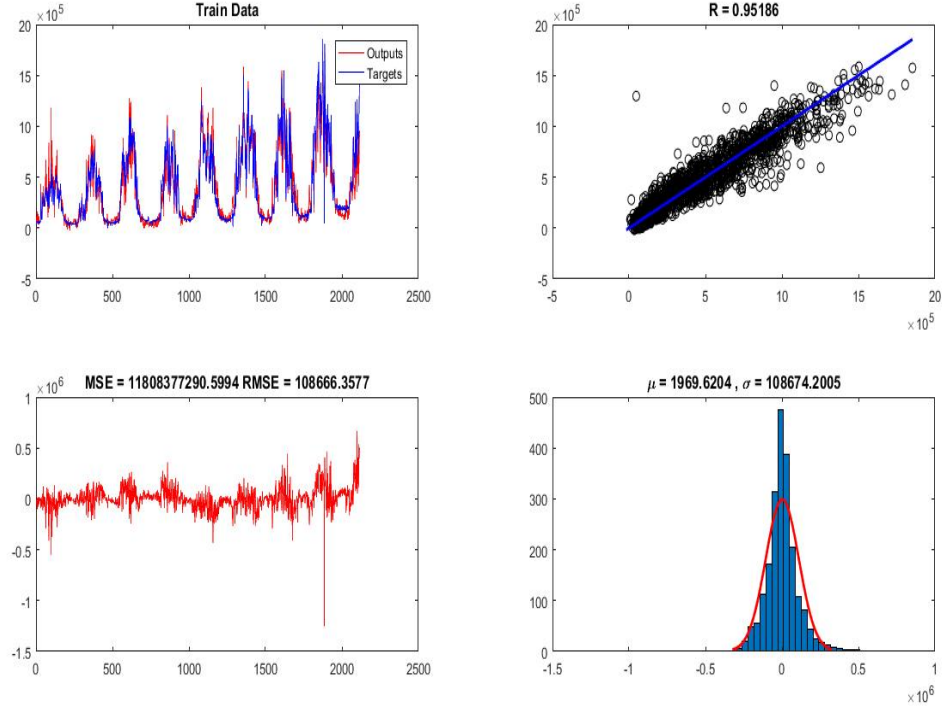
Bu uygulamada doğal gaz tüketim tahmini için kullandığımız model 8 girdi, 5 gizli katman ve 1 çıktı katmanından oluşan bir yapay sinir ağı modelidir.



Şekil 7.2. Kullanılan yapay sinir ağı modeli

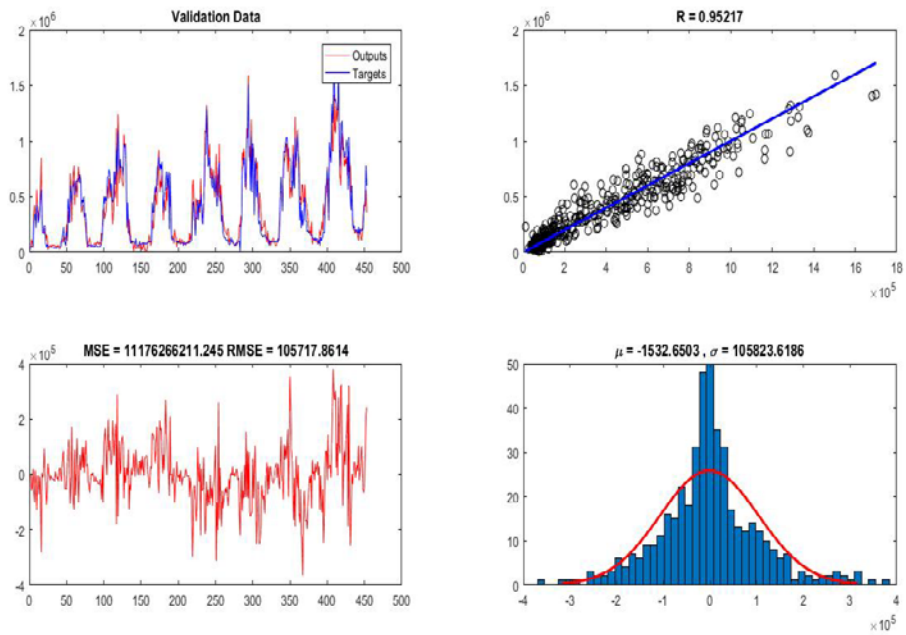
7.4.1. Yapay Sinir Ağı İle Çözümü

Aşağıdaki şekillerde kullanılan yapay sinir ağlarının eğitime ait eğitim, doğrulama ve test grafikleri gösterilmektedir. İlişki analizi olarak da adlandırılan regresyon analizi, herhangi bir değişkenin, bir ya da birden fazla değişken ile arasındaki ilişkinin matematiksel bir fonksiyon şeklinde yazılmasıdır.

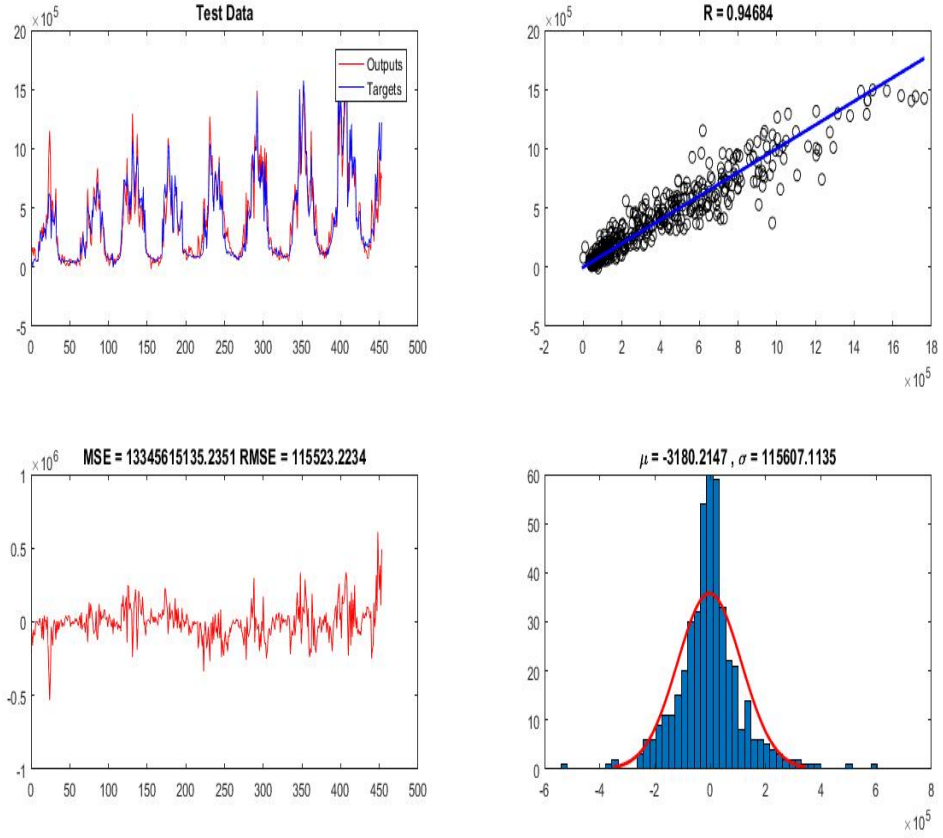


Şekil 7.3. Yapay sinir ağı eğitim sonuçları

Grafikte görüldüğü üzere $R = 0.95186$ çıkmıştır. R değerinin 1 e yakın olması ağı verileri öğrendiğini göstermektedir. Ağı verileri öğrendiği görülmektedir.



Şekil 7.4. Yapay sinir ağı doğrulama sonuçları



Şekil 7.5. Yapay sinir ağı test sonuçları

Şekil 7.5.te görüldüğü gibi ağın verileri öğrendiği ve R değerinin 0.94884 yani 1'e yakın olduğu için tahmin işlemini doğru yaptığını söyleyebiliriz.


Tablo 7.1. Doğal gaz tüketimi veri seti üzerinde yapılan yapay sinir ağı ile tahmin değerleri

	Veri (%)	MSE	RMSE	μ	σ	R
Validation Data	15	11176266211.245	105717.8614	-1532.6503	105823.6186	0.95217
Test Data	15	13345615135.2351	115523.2234	-3180,2147	115607.1135	0.94684
Train Data	70	11808377290.5994	108666.3577	1969.6204	108674.2005	0.95186
All Data	100	11944101363.6456	109289.0725	672.2341	109305.0974	0.95111


Tablo 7.1.de görüldüğü gibi tüm veriler için regresyon değeri 0.95111 bulunmuştur. Yapay sinir ağının yüksek performanslı çalıştığını söyleyebiliriz.

7.4.2. Genetik Algoritma ile Çözümü

Aşağıdaki şekillerde kullanılan genetik algoritma yapay sinir ağına ait eğitim, doğrulama ve test grafikleri, tahmin edilen ve gerçek veriler arasındaki ilişki grafikleri gösterilmektedir.




Şekil 7.6. Genetik algoritma optimizasyon ağırlığı




Şekil 7.7. Genetik algoritma tahmin edilen ve gerçek eğitim veri ilişkisi

Şekil 7.7. de de görüldüğü gibi tahmin ve gerçek veri arasındaki sapma miktarı oldukça düşüktür.




Şekil 7.8. Genetik algoritma eğitim sonuçları

Korelasyon değeri olan $R=0.92408$ çıkmıştır. Şekil 7.8. de görüldüğü gibi ağ verileri doğru bir şekilde öğrenmiştir.



Şekil 7.9. Genetik algoritma tahmin edilen ve gerçek test veri ilişkisi




Şekil 7.10. Genetik algoritma test sonuçları

Korelasyon değeri olan $R = 0.91978$ çıkmıştır. Şekil 7.10. da görüldüğü gibi ağ verileri doğru bir şekilde test etmiştir. Genetik algoritma ile yapılan tahmin işleminde ağın veriyi doğru bir şekilde öğrendiği, ezber yapmadığı söyleyebiliriz. R değerinin 1'e yakın olması tahmin edilen değerler ile gerçek sonuçlar arasındaki ilişkinin yüksek çıktığını göstermektedir.


7.4.3. Parçacık Sürü Optimizasyonu (PSO) İle Çözümü

Aşağıdaki şekillerde kullanılan parçacık sürü optimizasyonuna ait eğitim, doğrulama ve test grafikleri, tahmin edilen ve gerçek veriler arasındaki ilişki grafikleri gösterilmektedir.




Şekil 7.11. PSO ile tahmin edilen ve gerçek eğitim veri ilişkisi

Şekil 7.11. de görüldüğü gibi tahmin ve gerçek veri arasındaki sapma miktarı oldukça düşüktür.




Şekil 7.12. Parçacık sürü optimizasyonu eğitim sonuçları

Korelasyon değeri olan $R = 0.94423$ çıkmıştır. Şekil 7.25 de görüldüğü gibi sapma miktarı oldukça azdır ve ağ verileri doğru bir şekilde öğrenmiştir.



Şekil 7.13. PSO ile tahmin edilen ve gerçek test veri ilişkisi



Şekil 7.14. Parçacık sürü optimizasyonu test sonuçları

Korelasyon değeri olan $R = 0.95609$ çıkmıştır. Şekil 7.14. te görüldüğü gibi sapma miktarı oldukça azdır ve ağ verileri doğru bir şekilde test etmiştir. Parçacık sürü optimizasyonu ile yapılan tahmin işleminde ağın veriyi doğru bir şekilde öğrendiği, ezber yapmadığı söyleyebiliriz. R değerinin 1'e yakın olması tahmin edilen değerler ile gerçek sonuçlar arasındaki ilişkinin yüksek çıktığını göstermektedir.

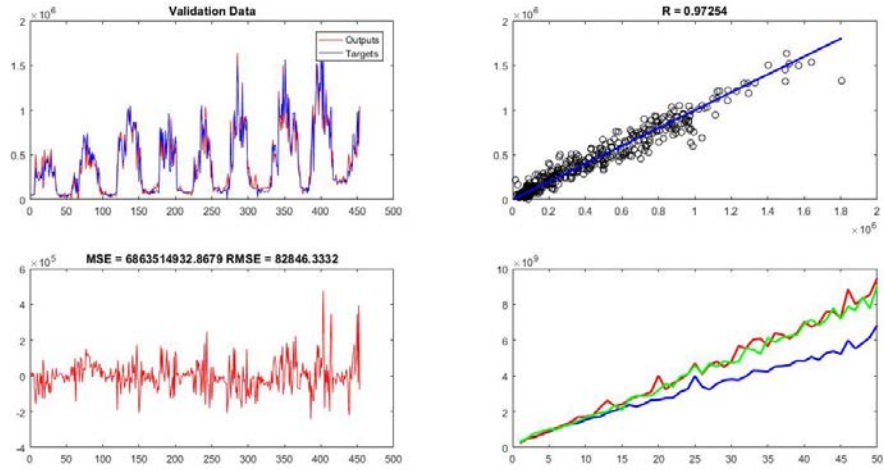
7.4.4. Çok Katmanlı Algılayıcılar (ÇKA) İle Çözümü

Aşağıdaki şekillerde kullanılan çok katmanlı algılayıcı yapay sinir ağına ait eğitim, doğrulama ve test grafikleri gösterilmektedir.

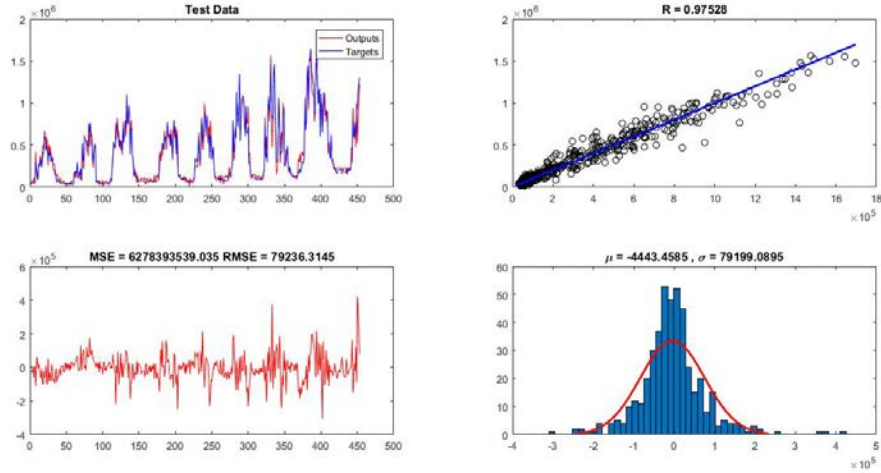


Şekil 7.15. Çok katmanlı algılayıcı eğitim sonuçları

Korelasyon değeri olan $R = 0.97598$ çıkmıştır. Şekil 7.15. te görüldüğü gibi sapma miktarı oldukça azdır ve ağ verileri doğru bir şekilde öğrenmiştir.



Şekil 7.16. Çok katmanlı algılayıcı doğrulama sonuçları



Şekil 7.17. Çok katmanlı algılayıcı test veri sonuçları

Tablo 7.2. Doğal gaz tüketimi veri seti üzerinde yapılan çok katmanlı algılayıcı ile tahmin değerleri

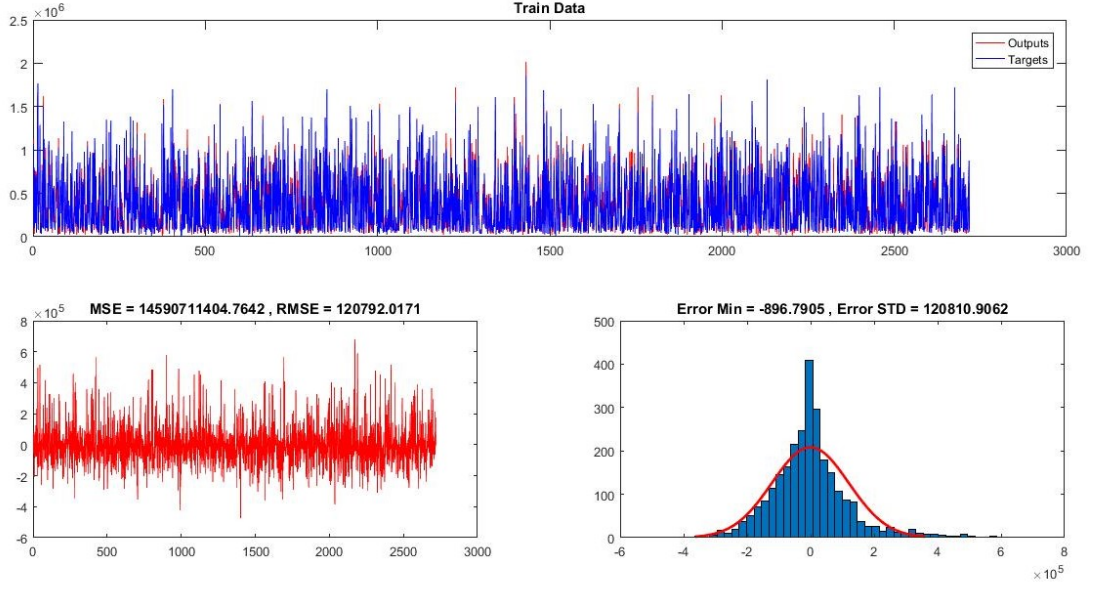
	Veri (%)	MSE	RMSE	μ	σ	R
Validation Data	15	6863514932.8679	82846.3332			0.97254
Test Data	15	6278393538.035	79236.3145	-4443.4585	79199.0895	0.97528
Train Data	70	5948355542.3748	77125.5829	-6919.2611	76832.7438	0.97598
All Data	100	6135073323.368	78326.7089	-5415.1622	78152.2304	0.97533

Tüm veriler için R değeri 0.97533 olarak bulunmuştur. Sapma miktarı oldukça azdır ve ağ verileri doğru bir şekilde test etmiştir. Çok katmanlı algılayıcı ile yapılan tahmin işleminde ağın veriyi doğru bir şekilde öğrendiği, ezber yapmadığı söyleyebiliriz.

Yapılan analizler sonucunda tahmin edilen ve gerçek veriler arasındaki değerlerin yakın değerler olduğu görülmüştür. Buradan da anlaşılacağı gibi oluşturulan yapay sinir ağının performansı yüksek bir şekilde çalıştığı ve doğru sonuçlar verdiği görülmektedir.

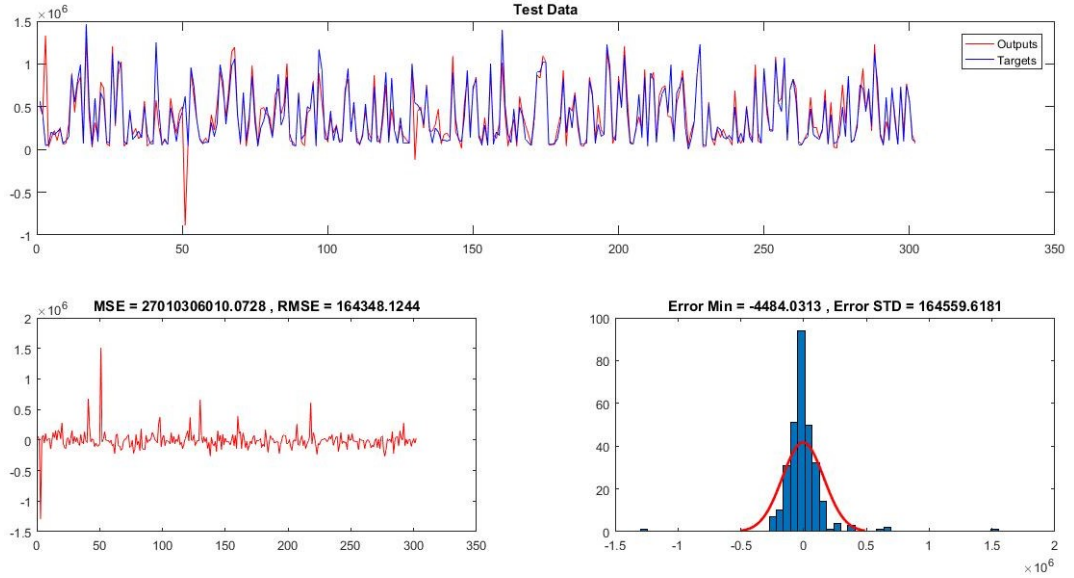
7.4.5. Grup Veri İşleme Yöntemi (GMDH) İle Çözümü

Aşağıdaki şekillerde kullanılan grup veri işlemine ait eğitim, doğrulama ve test grafikleri gösterilmektedir.



Şekil 7.18. GMDH eğitim verileri sonuçları

Grup veri işleme yöntemi ile yapılan öğrenme analizinde elde edilen sonuçlar Şekil 7.18 ile gösterilmiştir. Ortalama Kare Hata 14590711404,7642 olarak bulunurken, Kök Ortalama Kare Hata 120792.0171 olarak tespit edilmiştir. Hata ortalaması 896.7905 ve hata standart sapması 120810.9062 olarak bulunmuştur.

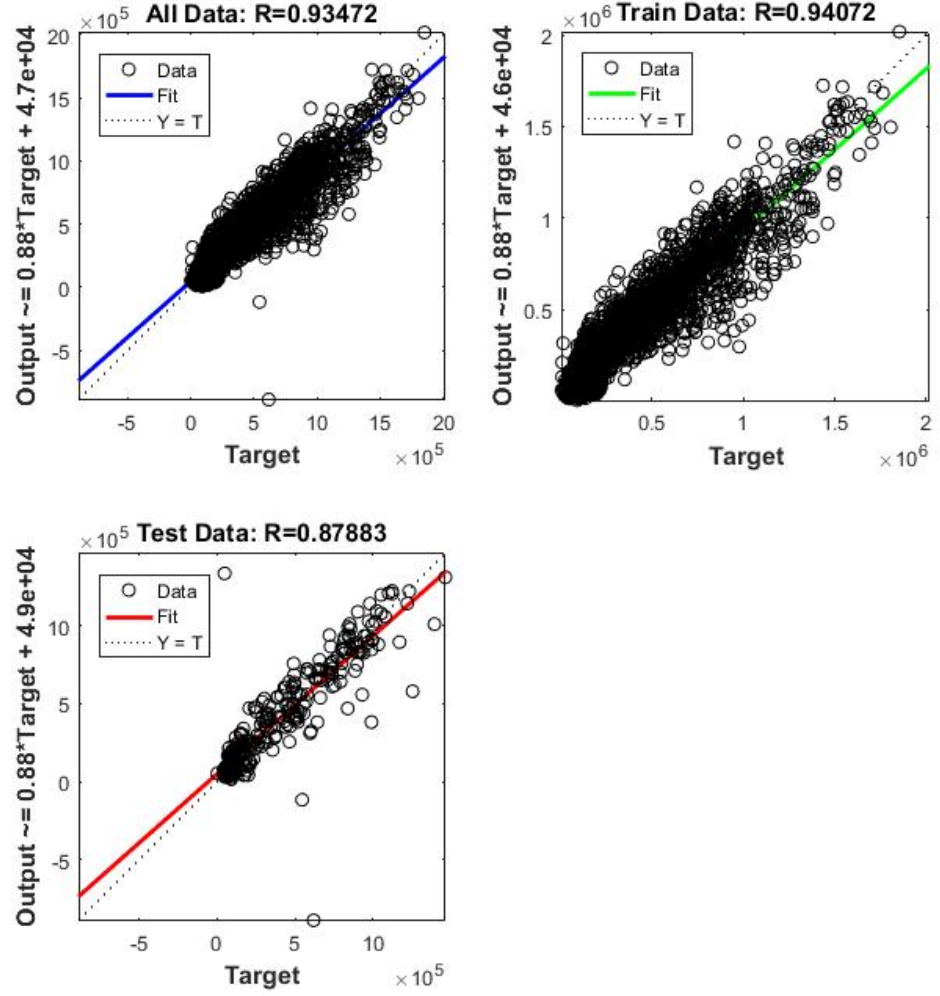


Şekil 7.19. GMDH test verileri sonuçları

Test verileri için yapılan tahminleme analizinde elde edilen sonuçlar Şekil 7.19 ile gösterilmiştir. Ortalama Kare Hata 27010306010.0728 olarak bulunurken, Kök

Ortalama Kare Hata 164348.1244 olarak tespit edilmiştir. Hata ortalaması -4484.0313 ve hata standart sapması 164559.6181 olarak bulunmuştur.

Analiz sonucuna elde edilen regresyon grafiği Şekil 7.20. ile gösterilmiştir.



Şekil 7.20. GMDH regresyon sonuçları

Tablo 7.3. Doğal gaz tüketim verileri üzerinde grup veri işleme yöntemi değerleri

	Veri (%)	MSE	RMSE	μ	σ	R
Validation Data	15					
Test Data	15	27010306010.0728	164348.1244	-4484.0313	164559.6181	0.87883
Train Data	70	14590711404.7642	120792.0171	-896.7905	120810.9062	0.94072
All Data	100	15832259756.5693	125826.3079	-1255.3959	125840.8745	0.93472

Tüm veriler için R değeri 0.93472 olarak bulunmuştur. Sapma miktarı oldukça azdır ve ağ verileri doğru bir şekilde test etmiştir. Grup veri işleme yöntemi ile yapılan tahminlemenin yüksek performanslı çalıştığını söyleyebiliriz.

8. SONUÇ

Günümüzde sosyal ve ekonomik hayatın işleyişi doğalgaz enerjisine oldukça bağımlıdır. Özellikle ülkemizin doğalgaz bakımından %99'luk bir oranla yurtdışına bağımlı olduğunu düşünürsek doğal gaz tüketim tahminlemesi oldukça önemli bir konuma gelmektedir. Bu da ancak talebi karşılayacak düzeyde yatırımların zamanında yapılmasıyla mümkündür.

Literatürde doğal gaz tüketimi talep tahmini çalışmaları incelendiğinde farklı yöntemler kullanıldığı görülmüştür. Kaynar ve arkadaşları 2011 yılında yazdıkları “Yapay sinir ağlarıyla doğal gaz tüketim tahmini” çalışmasında günlük ve haftalık doğal gaz arz verilerini kullanmışlardır. MSE ve MAPE performans kriterleri ile zaman serileri ve yapay sinir ağları yöntemlerini karşılaştırmıştır. Yapay sinir ağının daha iyi sonuç verdiğini görmüştür. Akgül ve arkadaşları 2013 yılında yazdıkları “Doğal gaz tüketim tahmini” çalışmasında doğal gaz tüketim verilerini kullanmışlardır. ARIMA ve YSA modellerini karşılaştırdığında yapay sinir ağlarının daha başarılı sonuçlar verdiğine ulaşmıştır. Demirceylan 2012 yılında “Erzurum doğalgaz tüketim miktarını yapay sinir ağı algoritması kullanılarak tahmin edilmesi” tezinde doğal gaz tüketimini etkileyen verileri kullanarak analizi gerçekleştirmiştir. Aylık tüketim verileri ve mevsimsellik verileri kullanılarak çoklu regresyon ve yapay sinir ağı yöntemleri ile tahminleme gerçekleştirmiştir. Yapay sinir ağının R^2 değerini 0,99 bulurken çoklu regresyon R^2 değerini 0,9 olarak bulmuştur.

Tez kapsamında gerçekleştirilen uygulamanın amacı doğal gaz tüketiminin farklı yapay sinir ağı algoritmaları kullanarak tahminleme yapmaktır. Bu amaçla Samsun ili doğal gaz tüketiminin geçmişe dönük verileri ve tüketimi etkileyen parametre verileri ile sistemin dinamiklerini kavrayabilecek bir ağ eğitime çalışılmıştır. Yapay sinir ağının eğitimi sırasında daha önceden karşılaşmadığı durumlar için ürettiği çıktı değerleri incelenerek ağın sistemi açıklama seviyesi takip edilmiştir.

Doğal gaz tüketim tahmininde kullanılan yapay sinir ağları, genetik algoritma, çok katmanlı algılayıcı, parçacık sürü optimizasyonu ve grup veri işleme yönteminin ağ yapıları MATLAB uygulamasında kodlama yapılarak çalıştırılmıştır. En başarılı tahminlemeyi yapan algoritma seçilmeye çalışılmıştır. Yapay sinir ağına doğal gaz tüketim verileri, konut fiyatı (Sm^3/TL), serbest tüketici fiyat (Sm^3/TL), aylık

ortalama aktüel basınç (hPa), aylık ortalama nispi nem (%), aylık ortalama rüzgar hızı (m÷sn), aylık ortalama sıcaklık (°C), aylık toplam güneşlenme süresi (saat) kullanılmıştır.

Bu çalışmada yapay sinir ağı algoritmaların eğitiminde Levenberg- Marquardt öğrenme algoritması kullanılmıştır. Modelleme kullanılan algoritmaların her biri için MATLAB programında kodlama yapılmış ve kullanılan bütün algoritmalarda yüksek başarı elde edilmiştir.

Tez kapsamında yapay sinir ağı, genetik algoritma, parçacık sürü optimizasyonu, çok katmanlı algılayıcı, grup veri işleme yöntemi algoritmaları kullanılmıştır. Sırasıyla yapay sinir ağı için R= 0.94684, genetik algoritma için R= 0.91978, parçacık sürü optimizasyonu için R= 0.95609, çok katmanlı algılayıcı için R= 0.97528, grup veri işleme yöntemi için R= 0.87883 olarak bulunmuştur. Grup veri işleme yönteminin Türkiye’de kullanıldığı herhangi bir çalışma bulunmamaktadır. Bu çalışmada ilk defa kullanılması teze özgünlük kazandırmıştır.

Tahminlemede R² değeri birçok çalışmada performans kriteri olarak kullanılmaktadır. Tahmin edilen değerlerin gerçek değerlerle arasındaki ilişkiyi ifade eder. Sonucun 1’e yakın olması tahmin sonucunun gerçek veriye ne kadar yaklaştığını ifade etmektedir. Tablo 8.1. de kullanılan algoritmaların R² değerleri gösterilmiştir.

Tablo 8.1. Algoritma sonuçları R² değerleri

Algoritma Adı	R ² Değeri
Çok Katmanlı Algılayıcı	0,95117108
Parçacık Sürü Optimizasyonu	0,91410809
Yapay Sinir Ağı	0,89650599
Genetik Algoritma	0,84599525
Grup Veri İşleme Yöntemi	0,77234217

Yapay sinir ağını MATLAB programında eğitimi yapıp, test işlemlerini gerçekleştirdikten sonra; farklı algoritmaların tahminleme işlemini optimal bir şekilde gerçekleştirdiği test edilmiştir. Çalışmada en yüksek başarı gösteren çok katmanlı algılayıcı algoritması olup elde edilen sonuçlar genetik algoritma, yapay sinir ağı, grup veri işleme yöntemi ve parçacık sürü optimizasyonu ile karşılaştırılmıştır.

Bu alıřmanın devamında veri seti bytlp gnlk veriler kullanılarak ve mevsimsellik etkisi de baz alınarak sonuların geliřtirilmesine katkı saėlanabilir.

KAYNAKLAR

- Adıyaman, F. (2007). *Talep tahmininde yapay sinir ağlarının kullanılması*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 109, İstanbul.
- Akan, E. (2017). *Tersanelerde gemi üretim yönetimi modeli: Marmara bölgesinde bir uygulama*. Doktora Tezi. İstanbul Üniversitesi Fen Bilimleri Enstitüsü Deniz Ulaştırma ve İşletme Mühendisliği Anabilim Dalı, 248, İstanbul.
- Akbulut, İ. (2009). *Parçacık sürü optimizasyonu ile anten tasarımı*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Bilişim Enstitüsü Mühendislikte İleri Teknolojiler Anabilim Dalı, 82, İstanbul.
- Akdağ, M. (2015). *Box-Jenkins ve yapay sinir ağı modelleri ile enflasyon tahmini*. Yüksek Lisans Tezi. Atatürk Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 84, Erzurum.
- Akgül, S., & Yıldız, Ş. (2013). Doğal gaz tüketim tahmini. *Sosyal ve Beşeri Bilimler Dergisi*. 5(1). 440-452.
- Akın, B. (2017). *Yapay sinir ağlarıyla Konya bölgesinde kullanıcı doğal gaz tüketim öngörüsü*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Enerji Enstitüsü Enerji Bilim ve Teknoloji Anabilim Dalı, 125, İstanbul.
- Akkurt, A. (2005). *Yapay sinir ağları ve Türkiye elektrik tüketim tahmini*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, 94, İstanbul.
- Akpınar, M., Adak, M.F. ve Yumuşak, N. (2016). Forecasting natural gas consumption with hybrid neural networks – artificial bee colony. *International Conference on Intelligent Energy and Power Systems (IEPS)*.
- Alcan, P. (2014). *İlişkisiz paralel makineli hibrit akış tipi sıralama probleminde üstünlük özellikleri ve genetik algoritma kullanarak iş sıralama*. Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 189, İstanbul.
- Anagnostis, A., Papageorgiou, E. and Bochtis, D. (2020). *Sustainability*. 1-29.
- Anonim, 2014. *Türkiye Enerji Piyasası Düzenleme Kurumu*. file:///C:/Users/User/Downloads/PortalAdmin_Uploads_Content_FastAccess_DPD_RaporYayin2014edea99a.pdf (Erişim tarihi: 26.11.2019).
- Anonim, 2018. *Türkiye Enerji Piyasası Düzenleme Kurumu*. file:///C:/Users/User/Downloads/PortalAdmin_Uploads_Content_FastAccess_276da_d6c24942.pdf (Erişim tarihi: 26.11.2019).
- Anonymous, 2020. *Group Method of Data Handling*. http://www.gmdh.net/GMDH_his.htm. (Erişim tarihi: 13.12.2020).
- Arı, A. ve Berberler, M.E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*. 1(2). 55-73.
- Ballı, M.T. (2014). *Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması*. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 180, İstanbul.
- Beşergil, B. (2009). *Petrol ve petrol kimyası*. İzmir: Ege Üniversitesi Yayını. 133-185.
- Demirceylan, S. (2012). *Erzurum'da doğalgaz tüketim miktarının yapay sinir ağları yöntemi kullanılarak tahmin edilmesi*. Yüksek Lisans Tezi. Atatürk Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 100, Erzurum.

- Emek, M.S. (2016). *İş yaşam dengesi bakışıyla hastane personelinin genetik algoritma yöntemi ile çizelgelenmesi*. Yüksek Lisans Tezi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 96, Isparta.
- Emel, G.G. ve Taşkın, Ç. (2002). Genetik algoritmalar ve uygulama alanları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 21(1). 129-152.
- Erdoğan, P. ve Yalçın, E. (2015). Parçacık sürü optimizasyonu ile kısıtsız optimizasyon test problemlerinin çözülmesi. *İleri Teknoloji Bilimleri Dergisi*. 4(1). 14-22.
- Eren, T. ve Kaçtıoğlu, S. (2017). Türkiye'deki doğal gaz tüketimi ve gri tahmin metoduyla tahmin edilmesi. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*. 16(31). 23-41.
- Eş, H.A. (2003). *Yapay sinir ağları ile Türkiye net enerji talep tahmini*. Yüksek Lisans Tezi. Gazi Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 87, Ankara.
- Hatipoğlu, T. (2010). *Galvaniz sektöründe bir yapay sinir ağı uygulaması*. Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 117, Sakarya.
- Kakıcı, (2017). *Yapay sinir ağlarının mimarisi ve yapı elemanları*. <https://yapayzeka.ai/yapay-sinir-aglarinin-mimarisi-ve-yapi-elemanlari-2/> (Erişim tarihi: 11.12.2019)
- Karaatlı, M., Helvacıoğlu, Ö.C., Ömürbek, N. ve Tokgöz, G. (2017). Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*. 8(17). 88-100.
- Kaya, K. (2016). *Destek vektör makineleri yardımıyla tüketici kredilerinin sınıflandırılması*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü İşletme Mühendisliği Anabilim Dalı, 135, İstanbul.
- Kaynar, O., Taştan, S. ve Demirkoparan, F. (2011). 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı [Özel Sayı]. *Atatürk Ü. İBBF Dergisi*. 463-474.
- Kuru, V. (2014). *Türkiye Doğal Gaz Tüketiminin Sektörel Bazda Analitik İncelenmesi*. Yüksek Lisans Tezi. Türk Hava Kurumu Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, 104, İstanbul.
- Mazak, M. (2004). Doğal gazın tarihi serüveni. *DTK Dergisi*.
- Meral, G. (2019). *Türkiye'de enerji santrallerinde doğal gaz tüketiminin destek vektör regresyon ile tahmini*. Yüksek Lisans Tezi. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, 47, Afyon.
- Oğuz, Z.D. (2019). *Türkiye'de tasarruf açığının yapay sinir ağları modeli ile analizi*. Yüksek Lisans Tezi. Van Yüzüncü Yıl Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı, 105, Van.
- Oruç, K.O. ve Eroğlu, Ş.Ç. (2017). Isparta ili için doğal gaz talep tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 22(1). 31-42.
- Özsağlam, M.Y. ve Çunkaş, M. (2008). Optimizasyon problemlerinin çözümü için parçacık sürü optimizasyonu algoritması. *Politeknik Dergisi*. 11(4). 299-305.
- Öztemel, E. (2012). *Yapay sinir ağları*. İstanbul, Ankara, İzmir, Adana: Papatya Yayıncılık.
- Salih, M. (2012). *Dünyanın en büyük doğal gaz üreticileri*. <https://www.bloomberght.com/haberler/haber/1269673-dunyanin-en-buyuk-dogalgaz-ureticileri> (Erişim tarihi: 26.11.2019).
- Serttaş, Z.S. (2011). *Türkiye'de perakende sektöründe talebi etkileyen etmenler ve yapay sinir ağlarıyla talep tahmini uygulaması*. Yüksek Lisans Tezi. Yıldız Teknik

- Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 89, İstanbul.
- Soysal, M. ve Ömürgönülşelen, M. (2010). Türk turizm sektöründe talep tahmini üzerine bir uygulama. *Anatolia: Turizm Araştırmaları Dergisi*. 21(1). 128-136.
- Sönmez Çakır, F. (2019). *Matlab kodları ve matlab toolbox çözümleri*. Ankara: Nobel Yayıncılık.
- Szoplik, J. (2015). Forecasting of natural gas consumption with artificial neural networks. *Energy*. 208-220.
- Şişçi, M. (2017). *Yapay sinir ağları ile hisse senedi kapanış fiyatlarının tahmini ve portföy optimizasyonu*. Yüksek Lisans Tezi. Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 166, Kütahya.
- Taşkıner, B. (2018). *Ankara ili doğal gaz tüketiminin yapay sinir ağları ile öngörüsü*. Yüksek Lisans Tezi. İstanbul teknik Üniversitesi Enerji Enstitüsü Enerji Bilim ve Teknoloji Anabilim Dalı, 67, İstanbul.
- Toğa, G. (2012). *Koroner arter hastalarında stent implantasyonu sonrası ölümlerin yapay sinir ağları ile modellenmesi*. Yüksek Lisans Tezi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 112, Kayseri.
- Topçu, G.Y. (2013). Türkiye doğal gaz tüketim tahmini. Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, 112, Ankara.
- Tuna, Ç. (2019). *Doğal gaz talep tahmini: Erzurum ili üzerine bir uygulama*. Yüksek Lisans Tezi. Erzurum Teknik Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı, 167, Erzurum.
- Tuna, T. (2014). *Depo planlaması ve ürünlerin depolara atanması probleminin sezgisel algoritmalar ile çözümü*. Yüksek Lisans Tezi. Gazi Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 125, Ankara.
- Uzunoglu, M., Kızıl, A. ve Onar, O.Ç. (2005). *Her yönü ile Matlab*. İstanbul: Türkmen Yayınevi.
- WEC (2019). *Natural Gas Resources Report*. World Energy Council.
- Yıkılmaz, M.A. (2015). *Türkiye’de doğal gaz tüketiminin incelenmesi ve analitik hiyerarşi süreci ile doğal gaz alım politikasına etkisinin irdelenmesi*. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Enerji Enstitüsü Enerji Bilim ve Teknoloji Anabilim Dalı, 167, İstanbul.
- Yılmaz, A. (2004). *Türkiye’de enerji (doğalgaz) kullanımı ve kalkınma: bir keşfedici mekansal veri analizi*. Doktora Tezi, Dumlupınar üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı, 186, Kütahya.
- Yılmaz, Ü. (2010). *Altı sigma ve yapay sinir ağlarının tekstil sektöründe karşılaştırmalı bir uygulaması*. Yüksek Lisans Tezi. Uludağ Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, 143, Bursa.

ÖZ GEÇMİŞ



Bedia KANT 13.09.1996 tarihinde Trabzon'da doğdu. Mehmet Tekinalp Anadolu Lisesi'ni bitirdikten sonra Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği bölümünden 2018 yılında mezun oldu. 2018 yılında OMÜ LEE Akıllı Sistemler Mühendisliği Yüksek Lisans programına girdi.

İletişim Bilgileri

E mail : bediakant@gmail.com

ORCID ID: <https://orcid.org/0000-0001-6137-9518>

Yayımlar

1. Yapay Sinir Ağları İle Doğal Gaz Tüketim Tahmini Üzerine Yapılmış Çalışmaların İrdelenmesi, Black Sea Journal of Engineering and Science, 2020.
2. ERP Sistemlerinin Farklı Uygulama Alanlarında Kullanımının Kronolojik İncelenmesi, Black Sea Journal of Engineering and Science, 2019.