



**YAPAY SİNİR AĞLARI İLE TÜRKİYE’NİN ELEKTRİK TALEP
TAHMİNİ**

Ebru DOĞAN

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EKİM 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Ebru DOĞAN

18/10/2023

YAPAY SİNİR AĞLARI İLE TÜRKİYE’NİN ELEKTRİK TALEP TAHMİNİ

(Yüksek Lisans Tezi)

Ebru DOĞAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekim 2023

ÖZET

Enerji, bir maddenin ya da makinenin iş yapabilme yeteneğidir. Elektrik enerjisi ise, gerek ekonomik hayatın gerekse de günlük hayatın vazgeçilmez bir parçasıdır. Yaşamın devamı için sürekli olarak sağlanması gerekmektedir. Ayrıca üretilen elektrik enerjisinin depolanma imkanının olmaması ve anında tüketiminin sağlanması gerektiğinden arz-talep dengesinin korunması gerekmektedir. Enerji talebi; nüfus artışı, gelişen teknoloji ve sanayileşme gibi unsurlar nedeniyle her geçen gün artmaktadır. Talebin karşılanamaması da büyük sorunlara yol açmaktadır. Bu nedenle planlamalar yapılarak enerji kaynaklarının etkin biçimde kullanılması gerekmektedir. Bunun yanı sıra talep tahminlerinin gerçeğe yakın olması, elektrik enerjisinin üretim-dağıtım-iletim gibi aşamalarının doğru şekilde planlanması için büyük önem arz etmektedir. Uzun dönemli kaynak planlaması yapılması ve enerji politikalarının belirlenmesi ise, geleceğe yönelik güvenilir tahminler ile olmaktadır. Bu nedenle tahminlerin doğruluğu, enerji kaynaklarının kullanımında önemli rol oynamaktadır. Bu çalışmada regresyon analizi ve yapay sinir ağları yöntemleri ile Türkiye’nin 2023-2040 dönemi için elektrik talep tahmini gerçekleştirilmiştir. Modelde girdi olarak ise, GSYH, nüfus, ihracat, beyaz eşya sayısı, taşıt sayısı, cep telefonu sayısı, elektrikli-hibrit araç sayısı, toplam kurulu güç, elektrik üretimi ve sanayi (GSMH payı) değişkenleri seçilmiş olup değişkenlerin Ocak 1970-Ağustos 2023 dönemindeki resmi verileri ele alınmıştır. Yapılan çalışmada başarılı tahmin değerleri elde edildiği anlaşılmış ve 2023-2040 yılları için Türkiye’nin elektrik talebi tahmin edilmiştir. Sonuçlar, Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) tarafından yapılan tahminler ile karşılaştırılmış ve değerlendirmeler yapılmıştır.

Bilim Kodu : 90619

Anahtar Kelimeler : Yapay sinir ağları, talep tahmini, elektrik tüketimi, enerji

Sayfa Adedi : 127

Danışman : Dr. Öğr. Üyesi Fatma Yeşim KALENDER ÖKSÜZ

FORECASTING TURKEY’S ELECTRICITY DEMAND USING ARTIFICIAL NEURAL NETWORKS

(M. Sc. Thesis)

Ebru DOĞAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

October 2023

ABSTRACT

Energy is the ability of a substance or machine to conduct work. Electrical energy, is an indispensable part of both economic life and daily life. It must be provided continuously for the continuation of life. In addition, the supply-demand balance must be maintained, since the electricity produced cannot be stored and consumed instantly. Energy demand is increasing day by day due to factors such as population growth, developing technology and industrialization. Failure to meet demand also causes major problems. For this reason, it is necessary to plan and use energy resources effectively. In addition, it is of great importance that demand forecasts are close to reality and that the stages of electricity energy such as generation-distribution-transmission are planned correctly. Making long-term resource planning and determining energy policies is not possible with reliable forecasts for the future. Therefore, the accuracy of the forecasts plays an important role in the use of energy resources. In this study, regression analysis and artificial neural network methods are used to forecast Turkey's electricity demand for the period 2023-2040. In the model, GDP, population, exports, number of white goods, number of vehicles, number of cell phones, number of electric-hybrid vehicles, total installed capacity, electricity generation and industry (GNP share) variables are selected as inputs and official data of the variables for the period January 1970-August 2023 are considered. As a result of the study, successful forecasting results were obtained and Turkey's electricity demand was estimated for the years 2023-2040. The results were compared with the estimates made by the Ministry of Energy and Natural Resources and evaluations were made.

Science Code : 90619

Key Words : Artificial neural networks, demand forecasting, electricity consumption, energy

Page Number : 127

Supervisor : Asst. Prof. Dr. Fatma Yeşim KALENDER ÖKSÜZ

TEŞEKKÜR

Bu çalışma boyunca, benimle bilgi ve deneyimlerini paylaşan, yardım ve desteğini esirgemeyen ve her daim destek olan saygıdeğer danışman hocam Dr. Öğretim Üyesi Fatma Yeşim KALENDER ÖKSÜZ'e çok teşekkür ederim. Sevgili aileme de desteklerinden dolayı teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. ELEKTRİK ENERJİSİ	3
2.1. Özellikleri.....	3
2.2. Ekonomi için Önemi	3
2.3. Arz ve Talebi.....	4
3. LİTERATÜR ARAŞTIRMASI	9
4. TALEP TAHMİNİ VE YÖNTEMLERİ	39
4.1. Talep Tahmini	39
4.2. Çalışmada Kullanılan Talep Tahmin Yöntemleri	40
4.2.1. Regresyon analizi	40
4.2.2. Yapay sinir ağları	47
5. YSA VE REGRESYON ANALİZİ UYGULAMASI	79
5.1. Çalışmanın Amacı.....	79
5.2. Veri Seçimi ve Model Tasarımı	79
5.3. Yapay Sinir Ağları Uygulaması	84
5.3.1. Verilerin normalizasyonu.....	84

	Sayfa
5.3.2. Algoritma seçimi	85
5.3.3. Katman sayısının belirlenmesi	86
5.3.4. Nöron (yapay sinir hücresi) sayısının belirlenmesi.....	86
5.3.5. Yapay sinir ağları eğitimi.....	87
5.3.6. Yapay sinir ağlarının test edilmesi.....	91
5.3.7. Yapay sinir ağları için performansların belirlenmesi.....	91
5.4. Çoklu Doğrusal Regresyon Analizi	97
6. SONUÇ VE ÖNERİLER	105
KAYNAKLAR	107
EKLER.....	121
EK-1. Matlab programlama modelinin kodları.....	122
ÖZGEÇMİŞ	127

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Korelasyon katsayısı değerlerinin yorumlanması.....	42
Çizelge 4.2. Beyin ile bilgisayar sisteminin sayısal olarak karşılaştırması	53
Çizelge 4.3. Biyolojik-yapay formdaki sistemlerin benzerlikleri	54
Çizelge 4.4. Toplama fonksiyonuna dair örnekler	57
Çizelge 4.5. Aktivasyon fonksiyon çeşitleri	63
Çizelge 4.6. Aktivasyon fonksiyonları türev gösterimi	64
Çizelge 4.7. Kullanım durumuna göre topolojiler	72
Çizelge 5.1. Sınıflandırılmış ağ türleri.....	80
Çizelge 5.2. Algoritmalar ile kullanım alanları	85
Çizelge 5.3. Geri yayılım algoritmalarının çeşitleri ve özellikleri.....	89
Çizelge 5.4. Performans ölçütleri ve açılımları	91
Çizelge 5.5. Modelin performans değerleri	95
Çizelge 5.6. Modelin tahmin değerleri	96
Çizelge 5.7. Bağımlı ve bağımsız değişkenler	98
Çizelge 5.8. Tanımlayıcı istatistikler	99
Çizelge 5.9. Çoklu regresyon modeli sonuçları	99
Çizelge 5.10. Modelin belirlilik katsayıları	100
Çizelge 5.11. Model 1 Anova testi.....	101
Çizelge 5.12. Model 2 sonuçları	101

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Türkiye'nin elektrik ihracat ve ithalat hacmi.....	5
Şekil 2.2. Türkiye'de sektörlere göre elektrik tüketimi	5
Şekil 2.3. Türkiye'de net ticaretin brüt talebe oranı (%)	6
Şekil 2.4. Türkiye elektrik piyasasında faaliyet gösteren şirketler	7
Şekil 2.5. Türkiye elektrik piyasası zinciri	7
Şekil 2.6. Türkiye elektrik dağıtım bölgeleri	8
Şekil 4.1. Talep tahmin yöntemleri.....	40
Şekil 4.2. Korelasyon değerinin saçılım grafikleri ile gösterimi	43
Şekil 4.3. En küçük kareler yöntemi	44
Şekil 4.4. Nöron ve yapay modeli.....	48
Şekil 4.5. YSA'nın tarih boyunca gelişimi	51
Şekil 4.6. Bir sinir sistemine dair çalışma mekanizması	52
Şekil 4.7. Biyolojik formda bir sinir hücresi.....	52
Şekil 4.8. İnsan beyninde yer alan duyu bölgeleri	53
Şekil 4.9. (a) Biyolojik form ve (b) yapay form	54
Şekil 4.10. Biyolojik formdaki hücrelere denk gelen yapay formdaki noktalar.....	55
Şekil 4.11. Doğrusal fonksiyon.....	58
Şekil 4.12. Parçalı doğrusal aktivasyon fonksiyonu	59
Şekil 4.13. Basamak aktivasyon fonksiyonu	60
Şekil 4.14. Basamak aktivasyonu fonksiyonu (tek kutuplu).....	60
Şekil 4.15. Basamak aktivasyon fonksiyonu (çok kutuplu).....	61
Şekil 4.16. Sigmoid aktivasyon fonksiyonu	62
Şekil 4.17. Hiperbolik tanjant aktivasyon fonksiyonu.....	62

Şekil	Sayfa
Şekil 4.18. Sinüs aktivasyon fonksiyonu	63
Şekil 4.19. Çok katmanlı yapay sinir ağlarının genel görünümü.....	66
Şekil 4.20. Örnek bir ağ yapısı.....	67
Şekil 4.21. Çok katmana sahip ileri beslemeli bir ağ yapısı	69
Şekil 4.22. Geri yönlü beslemeye sahip ağ modeli	70
Şekil 4.23. Danışmanlı öğrenme algoritmalarının işleyişi.....	71
Şekil 4.24. Danışmansız öğrenme algoritmasının işleyişi	71
Şekil 5.1. Değişkenlerin MATLAB üzerinde gösterimi	80
Şekil 5.2. Değişkenlerin SPSS üzerinde gösterimi	80
Şekil 5.3. Verilerin normalizasyonunu sağlayan kod yapısı.....	85
Şekil 5.4. Geri yayılım algoritması için kod yapısı	86
Şekil 5.5. Gizli katman boyutunu içerir kod yapısı	86
Şekil 5.6. Genelleme (a), ezberleme (b)	87
Şekil 5.7. Veri setinin dağılım oranını gösteren kod yapısı	88
Şekil 5.8. Yapay sinir ağları genel kod yapısı	89
Şekil 5.9. Levenberg-Marquardt algoritmasını içerir geri yayımlı yapay sinir ağı kod yapısı.....	89
Şekil 5.10. MSE performans ölçütü için kod yapısı	92
Şekil 5.11. Performans sonuçlarının değerlendirilmesi için kod yapısı.....	93
Şekil 5.12. Tahmin sonuçlarının grafiksel gösterimini ifade eden kod yapısı.....	93
Şekil 5.13. Grafik çizimini gösteren kod yapısı.....	94
Şekil 5.14. Elektrik talebi değişkeninin regresyon değerleri	94
Şekil 5.15. Ölçeklendirilen verilen tabloya aktarımını gösteren kod yapısı	95
Şekil 5.16. Performans ölçütlerini gösteren kod yapısı	95
Şekil 5.17. Veri-tahmin grafiği	97

Şekil	Sayfa
Şekil 5.18. Dağılım diyagramı	100
Şekil 5.19. Elektrik talebine dair gözlem ve tahmin değerleri.....	102
Şekil 5.20. Tahmin değerlerinin karşılaştırılması	103



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar

Açıklamalar

ANFIS	Adaptive neuro fuzzy inference system
ARIMA	Autoregressive integrated moving average
ARMA	Autoregressive moving average
DEKTMK	Dünya Enerji Konseyi Türk Milli Komitesi
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
GA	Genetik algoritma
GSMH	Gayri safi milli hasıla
GSYİH	Gayri safi yurtiçi hasıla
HKT	Hata kareleri toplamı
LR	Linear regression
MAED	Model for analysis of energy demand
MAPE	Mean absolute percentage error
MSE	Mean squared error
NLR	Non-linear regression
RMSE	Root mean square error
SSE	Sum of squares error
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
YSA	Yapay sinir ağları

1. GİRİŞ

Enerji ifadesi, maddenin iş yapabilme kabiliyeti olarak tanımlanmaktadır. Eski Yunan dilinde yer alan ve aktif anlamına gelen $\epsilon\nu$ (en) ile iş anlamına gelen $\epsilon\rho\gamma\omega\acute{\iota}$ (ergon) sözcüklerinden türetilip iş yapabilme kabiliyeti anlamında kullanılmıştır (Karluk, 1999). TDK sözlüğüne göre ise, “maddede var olan ve ısı, ışık biçiminde ortaya çıkan güç” şeklinde tanımlanmıştır (TDK, 1994).

Enerji kullanımı, ülkeler açısından gelişmişlik düzeylerini ifade etmektedir. Özellikle elektrik kullanımı, üretimle bağdaştırıldığından hem gelişmiş hem de gelişmekte olan ülkeler için ekonomik anlamda gelişmişlikle ilişkilendirilmektedir. Ülkeler açısından bakıldığında ekonomik olarak gelişmişlik düzeylerinin artması, elektrik enerjisi kullanımının tüm enerji kullanımındaki payının arttığı görülmektedir. Bu durum üretim faaliyetlerinin genişlemesi ile de ilişkilendirilebilir.

Elektrik enerjisi, günlük ve ekonomik yaşantının vazgeçilemeyecek kadar önemli bir parçasıdır. Yaşantının aksamadan devam etmesi için kesintisiz şekilde sağlanması gereklidir. Ayrıca depolanamayan elektrik enerjisi, üretildiği an tüketilmelidir. Bu nedenle arz-talep durumunun korunması büyük önem arz etmektedir. Elektrik enerjisine olan talep devamlı olarak arttığı için kesintiye uğrayıp karşılanamaması halinde aksaklıklara yol açmaktadır.

Enerji talebi, teknolojinin gelişmesi, nüfusun devamlı olarak atması ve sanayileşmenin hızlanması gibi faktörler doğrultusunda daima artmaktadır. Bu hususta planlamaların yapılarak enerji kaynaklarının hem etkili hem de doğru bir şekilde kullanımı gerekmektedir. Ülkeler, resmi kurumlar tarafından yapılan güvenilir tahminlerle kısa ve uzun vadeli planlamalar yapmakta ve çeşitli politikalar belirlemektedir. Bu nedenlerle doğru ve güvenilir tahminler ile çalışılması, enerji kaynaklarının doğru ve etkili şekilde kullanılmasında büyük rol oynar.

Enerji alanı için yapılan veya yapılması planlanan yatırımlar, tüm ülkelerde genel yatırımlar içerisinde büyük bir orana sahiptir. Türkiye de teknolojinin gelişmesi ile ekonomisini

büyütmektedir. Bunun yanı sıra artmakta olan nüfusun enerji alanındaki ihtiyaçlarını da gidermeye çalışmakta olup mevcut olan kaynakları etkili olarak kullanmaya çalışmaktadır.

Türkiye’de hem genel anlamda enerjiye hem de elektriğe olan talebin her geçen gün artması, bu alanda etkili planlamaların yapılması gerektiğini gözler önüne sermektedir. Geleceğe dair etkili planlamalar ise, doğru ve güvenilir tahminler aracılığıyla yapılabilmektedir. Hem günlük hem de ekonomik yaşantının vazgeçilemez bir kaynağı olan elektrik, alanındaki yatırımların yüksek maliyetli olması açısından da üzerinde çalışılıp planlama yapılması gereken bir konudur.

Elektrik talebinin tahmini, hem nicel hem de nitel birçok yöntem ile yapılabilmektedir. Güncel çalışmalarda ise, geleneksel yöntemlerden çok yapay sinir ağları yöntemi tercih edilmektedir. Geleneksel yöntemlerin uygulanması ile elde edilen sonuçlar ile yapay sinir ağları ile elde edilen sonuçlar karşılaştırıldığında yapay sinir ağlarının daha uygun bir yöntem olduğu anlaşılmaktadır.

Bu çalışmada regresyon analizi ve yapay sinir ağları yöntemleri ile Türkiye’nin 2023-2040 dönemi için elektrik talebinin tahmin edilmesi hedeflenmiştir. Modelin girdi değişkenleri olarak ise, çalışma için seçilmiş olan ilgili değişkenlerin Ocak 1970 - Ağustos 2023 dönemindeki verileri kullanılacaktır.

Çalışmanın amacı, enerji planlarının Türkiye’nin elektrik enerjisini en etkili şekilde kullanmasına temel oluşturacak şekilde hazırlanmasına katkı sağlamaktır. Ayrıca, değişkenlerin resmi kaynaklardan alınan güncel verilerinin değerlendirilip bu çalışma ile değerlendirilmesi de önemli olmaktadır.

Çalışmanın ikinci bölümde ana konuyu oluşturan elektrik enerjisinin özellikleri, önemi ve arz-talep durumu üzerinde durulmuştur. Üçüncü bölümde literatürde yer alan enerji tahmini alanındaki çalışmalar incelenmiş ve detaylı şekilde açıklanmıştır. Dördüncü bölümde çalışma için tercih edilen regresyon analizi ve yapay sinir ağları yöntemleri açıklanmıştır. Beşinci bölümde çalışmanın uygulama aşaması açıklanmıştır. Son bölümde ise sonuçlar değerlendirilmiş ve önerilerde bulunulmuştur.

2. ELEKTRİK ENERJİSİ

2.1. Özellikleri

Elektrik enerjisi, yenilenebilir kaynakların yanı sıra fosil yakıtlar ile nükleer enerjiden de üretilmektedir. Elektrik üretildikten sonra tüketilmesi planlanan yerlere kapasitesi yüksek olan iletim hatları aracılığıyla gönderilmektedir. Bölgeye ulaştığında ise, voltajının düşürülüp son tüketiciye yerel hatlarla dağıtıldığı bilinmektedir (Akgül, 2013).

Elektrik enerjisi hem ara mal hem de nihai mal özelliğine sahiptir. Ekonomik yaşamda ara mal, günlük hayatta ise nihai mal olarak süreç içerisinde yer alır. Ayrıca teknolojinin gelişimiyle günlük yaşamın vazgeçilmez bir parçası haline gelmesi, elektrik tüketiminin enerji tüketimi içerisindeki payının da artmasına neden olmaktadır. Kullanım yelpazesi geniş bir enerji çeşidi olması da elektriğin tüketimini artırmaktadır.

Elektrik enerjisi, olumlu yönlerinin yanı sıra olumsuz yönlere de sahiptir. Depolanma imkanının kısıtlı ve pahalı olması elektrik enerjisinin anında tüketilmesine zemin hazırlamakta olup olumsuz yönlerinden biridir. Ayrıca uzaklığa bağlı olarak iletim kayıpları yaşayan elektrik enerjisi, kesintisiz şekilde sunulamadığında sorunlara yol açabilir.

2.2. Ekonomi için Önemi

Ülkelerin ekonomisi için can simidi olma özelliği taşıyan enerji, büyüyüp gelişmeleri açısından da büyük önem arz etmektedir. Hatta ülkedeki yaşam kalitesinin de enerjinin ucuz ve yeterli olarak kullanılmasıyla ilişkili olduğu görülmektedir. Öyleyse enerjiye duyulan talebin yaşam kalitesini artırma amaçlı olduğu bilinmektedir (Akgül, 2013).

Elektrik enerjisi, oldukça yaygın bir kullanım alanına sahip olup bu enerjiden birçok sektörde yoğun şekilde faydalanılmaktadır. Bu doğrultuda ülkelerin gelişmişlik seviyelerinin değerlendirilmesinde kişi başına düşen elektrik tüketim verileri de değerlendirilmektedir. Kişi başına elektrik tüketimi verisinin yüksek olduğu ülkelere refah seviyesinin de yüksek olduğu görülmektedir.


Gelişmekte olan ülkelerde elektrik enerjisi tüketiminin uluslararası standartların çok gerisinde kaldığı, gelişmiş ülkelerde ise ekonomi büyümenin elektrik enerjisi tüketimiyle paralel şekillendiği görülmektedir. 1970’li yıllardan itibaren de elektrik enerjisinin hem ekonomik hem de toplumsal kalkınma amacıyla dünya ülkelerinin gündeminde yer aldığı bilinmekte olup kıt kaynaklara sahip ülkeler için de kritik öneme sahiptir.

2.3. Arz ve Talebi

Günümüzde birçok ekonomik faaliyetin ana girdisini ifade eden elektrik enerjisi, kullanım alanının artması nedeniyle elektrik enerjisine olan talebinin de artmasına neden olmaktadır. Dağıtım şebekeleri, en küçük yerleşim birimlerine kadar uzanmakta ve tüketiciye büyük kolaylık sağlamaktadır. Bu kolaylık ise, toplam enerji tüketimindeki elektrik enerjisi tüketimini arttırmıştır.


Elektrik enerjisi, üretildiği zaman anında tüketilmesi gerekli olan yani depolanamayan bir enerji çeşidi olup arz ile talebinin daima dengede tutulması gerektiği bilinmektedir (Yavuzdemir, 2014). Bu doğrultuda arz-talep dengesini korumaya yönelik olarak ülkeler tarafından planlamalar yapılmaktadır. Elektrik arz-talep dengesinin sağlanması için üretim, iletim, dağıtım aşamalarının koordineli bir şekilde sürdürülmesi gerekmektedir. Ayrıca sistem üzerinde meydana gelebilecek arıza gibi durumlarda devamlılığın sağlanması da gerekmektedir. Bu husus ise, üretim kapasitesinin yeteri kadar yedeğinin bulundurulması ile mümkündür.

Ülkemiz için 6446 sayılı Elektrik Piyasası Kanunu’nda yer alan ilgili maddede de özellikle elektrik enerjisinin sürekli, kesintisiz, kaliteli ve taraflar arası ayırım gözetmeden tüketiciye ulaştırılmasına dikkat çekilmektedir. Böylece öngörülü ve planlı çalışmalar yapılma zorunluluğu mevcuttur. Ayrıca enerji maliyetlerinin artması da enerji kaynaklarının doğru bir şekilde yönetilmesini gerektirmektedir. Türkiye, 2023 yılında 2,64 TWs elektrik ihracı ve 7,01 TWs elektrik ithali yapmıştır. Bu durum, ülkemizin net elektrik ithalatçısı olduğunu göstermektedir. Şekil 2.1’de Türkiye’nin geçmişten bugüne dek elektrik ihracat ve ithalat hacmi gösterilmektedir.




Şekil 2.1. Türkiye'nin elektrik ihracat ve ithalat hacmi (URL-2, 2023)

Şekil 2.2'de Türkiye için 2025-2035 dönemi elektrik tüketimi planlarında ulaşım sektörünün en hızlı büyüyen sektör şeklinde öne çıktığı, ayrıca bu dönemde elektrik tüketiminin yıllık %27,8 hızla büyüyeceği görülmektedir. Ayrıca elektrikli araçların benimsenip kullanılması da ulaşım sektörünü besleyecek faktörler arasında gösterilmektedir. Şekil 2.3'de ise, net ticaretin brüt talebe oranının sınırlı kaldığı anlaşılmaktadır.




Şekil 2.2. Türkiye'de sektörlere göre elektrik tüketimi (URL-2, 2023)




Şekil 2.3. Türkiye’de net ticaretin brüt talebe oranı (%) (URL-2, 2023)

2.4. Türkiye Elektrik Enerjisi Piyasası

Elektrik enerjisi sistemleri planlanırken maksimum tüketimi karşılayabilecek üretim, iletim ve dağıtım kapasitesi bulundurmak gerekmektedir. Bunun yanı sıra herhangi bir arızaya karşı arz devamlılığının sağlanması için yeterli yedek kapasite olmalıdır. Türkiye elektrik enerjisi piyasasında elektrik üretim faaliyetleri, Enerji Piyasası Düzenleme Kurumundan alınmış üretim lisansına sahip olan özel elektrik üretim şirketleri ve kamu kuruluşları tarafından gerçekleştirilebilmektedir. Elektrik Üretim Anonim Şirketi (EÜAŞ), özel veya kamu şirketleri ve bağlı ortaklıklar üretim lisansına sahiptir. Türkiye’nin toplam kurulu güç değeri ise, 2023 yılı Haziran ayı itibarıyla 104,9 GW olarak hesaplanmıştır. Şekil 2.4’te Türkiye elektrik piyasasında geçmişten günümüze dek faaliyet gösteren kamu şirketleri ve özel şirketler, Şekil 2.5’te ise elektrik piyasası zinciri görülmektedir.




Şekil 2.4. Türkiye elektrik piyasasında faaliyet gösteren şirketler (URL-2, 2023)



Şekil 2.5. Türkiye elektrik piyasası zinciri (URL-2, 2023)

Elektrik iletim faaliyetleri, Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) tarafından sürdürülmektedir. TEİAŞ, iletim ağının faaliyetlerine ek olarak hem bakım hem de onarımından sorumlu olmaktadır. Tüm iletim tesisleri için iletim faaliyeti yürütebilmek üzere Enerji Piyasası Düzenleme Kurumundan iletim lisansı alması gerekmektedir. Bu lisans sayesinde elektrik dengeleme piyasasının işletilmesi ile yatırım planlarının yapılması görevlerini üstlenmektedir.

Elektrik satış faaliyetleri, kamu kuruluşları ve özel şirketler tarafından gerçekleştirilebilmektedir. EÜAŞ, piyasada toptan elektrik satışını yürüten bir kamu kuruluşudur. Dağıtım faaliyeti ise, Enerji Piyasası Düzenleme Kurumundan dağıtım lisansı almış olan şirketler itibarıyla yürütülmektedir. 2004 yılında alınan özelleştirme kararı ile dağıtım bölgeleri yeniden belirlenmiş olup ülkemiz 21 bölgeye ayrılmıştır. Dağıtım şirketleri, lisans bölgelerinde sayaçların okunması ve bakımı gibi faaliyetlerin yanı sıra rekabet ortamı ile mevzuatta yer alan hükümlere uygun davranmakla sorumludur. Şekil 2.6'da elektrik dağıtım bölgeleri yer almaktadır.



Şekil 2.6. Türkiye elektrik dağıtım bölgeleri (URL-2, 2023)

Perakende faaliyeti, elektriğin nihai tüketicilere satılmasını ifade etmektedir. Enerji Piyasası Düzenleme Kurumundan lisans almış olan şirketler, dağıtım bölgesi şartına takılmadan tüketicilere elektrik satışı yapabilmektedir.

3. LİTERATÜR ARAŞTIRMASI

Geçmişte birçok araştırmacı, günümüzde de olduğu gibi enerji ve elektrik talebini tahmin etmek için çeşitli araştırmalar yapmış ve çalışmalar yayınlamıştır. Çalışmalar kapsamında ilk olarak geleneksel yöntemler kullanılmış olup gelişen teknoloji ile yapay sinir ağları da tercih edilmiştir. Çalışmalar kapsamında farklı bağımsız değişkenler ile veri/tahmin dönemleri için farklı zaman aralıklarının seçildiği görülmüştür.

Houthakker (1951) çalışmasında istatistiksel ve ekonomik kuramları kullanarak İngiltere'nin elektrik tüketimini incelemiştir. İngiltere'nin 1937-1938 dönemi için ortalama elektrik tüketimi, ortalama hane geliri, ağır ekipman sahipliği ile elektrik ve LPG'nin marjinal fiyatlarının aylık değerleri kullanılmıştır. Bu çalışma ile elektrik tüketiminde hem gelir hem de fiyat üzerindeki değişmelerin sağladığı etki gözlemlenmiştir. Ayrıca enerji çeşitleri arasındaki rekabet de ele alınmıştır.

Fisher ve Kaysen (1962) Amerika Birleşik Devletleri için elektrik talebini dört kısım halinde incelemiştir. Nüfus büyüklüğü, uzun dönem gelir ve kişi başına düşen elektrikli alet sayısındaki değişim gibi değişime dayalı birçok faktör ele alınmıştır. Konutlar için kısa vadede elektrikli aletlere dair stokların kullanım oranı etkili olurken; uzun vadede ise stokların büyüklüğü için yapılan seçimin etkili olduğu açıklanmıştır. Ayrıca, taleple ilgili olan elektrikli aletler “Beyaz Mallar” olarak tanımlanmış olup bu malların stoklarına dair tahminler ile hane halkının elektrik tüketimi tahmin edilmiştir.

Wilson (1969) araştırmasında gelir, iklim, gaz ve elektrik fiyatları değişkenlerini kullanarak konutların elektrik talebini; sanayiye dair büyüme oranı ve alternatif enerji çeşitlerinin fiyat değişkenlerini kullanarak sanayi elektrik talebini incelemiştir.

Kent P. Anderson (1972) çalışmasında konutların elektrik talebini incelemiştir. Konutların gaz fiyatı (ortalama), kişi başına düşen reel gelir değeri (ortalama), hane halkının büyüklüğü (ortalama), nüfusun başkent olmayan bölümü, elektrik reel fiyatları ile Ocak ve Temmuz aylarındaki sıcaklık değişkenleri kullanılmıştır.

Halvorsen (1975) Anderson'un çalışmasında kullandığı değişkenlere ek olarak şehirli nüfus oranı, çok odaya sahip konut oranı, gün bazında sıcaklık değerleri ile zaman faktörünü ele alan bir analiz yapmış ve anlamlı sonuçlar elde etmiştir.

Tyrell (1975) araştırmasında elektrik talep tahmini için kişi başına düşen gelir, nüfus, elektriğin fiyatı, elektrikli aletlerin fiyatı ve ikame enerji kaynaklarının fiyatı birçok değişkeni kullanmış olup elektrik fiyatı değişkeninin önemli olduğunu ortaya koymuştur.

Thompson (1976) hem uzun hem kısa vadeli tahminler için hava durumuna duyarlı elektrik yüklerinin analiz edilmesini hedefleyen bir çalışma yapmıştır. Çalışmada önerilen model, coğrafi açıdan farklı iklim bölgelerini içermekte olan güç sistemlerine uygulanabilmekte ve yılın her mevsiminde kullanılabilir. Çalışmanın sonucunda ise, modelin hava durumuna oldukça duyarlı uygulama yapılmıştır.

Baughman ve ark. (1979) ekonometrik çalışmasında enerji talebini iki etapta incelemiş olup çapraz fiyat esnekliğini ortaya koymuştur.

Al-Sahlawi (1990) Suudi Arabistan'da elektrik gücünün ekonomik kalkınma için çok önemli bir araç olduğunu ortaya koyan bir araştırma yapmış olup elektrik fiyatı, zaman, GSYİH (reel) ve ortalama gecikmeli talep değişkenlerini kullanmıştır.

Lee ve Singh (1994) elektrik ile doğalgaz kullanımı doğrultusunda endüstriyel açıdan bireysel tüketimin hesaplanması amacıyla çoklu regresyon yönteminin uygulandığını bir analiz yapmıştır. Uygulanan genelleştirilmiş modeller doğrultusunda ise, anlamlı sonuçlar elde edilmiştir.

Tripathy (1997) Hindistan için elektrik enerjisi talebinin tahmin edilmesini hedefleyen bir çalışma yapmıştır. Girdi değişkenlerinin 1966-1990 dönemindeki verileri ile yapılan çalışma, Hindistan hükümetinin elektrik enerjisine dair tüketim öngörülerini konusunda hazırlanan rapora dayanmaktadır.

Eltony ve Hajeer (1999) araştırmalarında Kuveyt'in ticaret sektöründeki elektrik talebinin analizi üzerinde durmuş olup elektriğin fiyatı ile katma değer değişkenlerini kullanmıştır.

Kukla deęiřkene de ihtiya duyulan analiz sonucunda ise anlamlı sonuların elde edildięi grlmřtr.

Filippini (1999) alıřmasında Hindistan'ın elektrik tketimi, elektrik fiyatının ortalama deęeri ve eřitli sosyoekonomik faktrlerine ait veriler ile kentsel olarak hane halklarının elektrięe olan talebini arařtırmıřtır.

Bakırtař ve ark. (2000) Trkiye'nin 1962-1996 dnemine dair verilerini kullanarak 1997-2010 dnemi iin elektrik talebinin tahmin edilmesini hedefleyen bir analiz yapmıřtır. Ayrıca elektrik talebi ile gelir arasındaki iliřki incelenmiř olup uzun vadede beraber hareket etme eęiliminde olduęu sonucuna ulařılmıřtır.

Gmrah ve ark. (2001) arařtırmalarında Ankara'nın 2005 yılına dek yıllık doęalgaz talebinin tahmin edilmesini hedeflemiřtir. 1991-1997 dnemi verileri kullanılarak derece-gn yntemi uygulanmıřtır. Bu alıřma ile hem tketicisi sayısı hem de hava durumuna baęlı olarak tahmin yapılmıřtır.

Ghosh (2002) alıřmasında Hindistan iin GSYH faktrnn kiři bazlı deęeri ile elektrik tketiminin kiři bazlı deęeri arasında bulunan nedensellik durumunu ele almıřtır. alıřmada 1950-1997 dneminin resmi verileri kullanılmıř olup GSYH faktrnn kiři bazlı deęeri ile elektrik tketiminin kiři bazlı deęeri arasında ift ynl olmayan bir nedensellik baęı olduęu grlmřtr.

Ediger ve Tatlıdil (2002) Trkiye iin 2010 yılına dair birincil enerjiye olan talebin tahmin edilmesini hedefleyen bir analiz yapmıřtır. Tam istatistiksel olmayan Dng Analizi yntemi ile 2010 yılı iin yaklaşık olarak enerjiye olan talebin tep cinsinden 130 milyon civarında olabileceęi tahmin edilmiřtir. Ayrıca stel dzeltme yntemi de uygulanmıř olup sonular karřılařtırılmıřtır.

Zivanovic (2002) arařtırmasında kısa dnemli elektrik talebinin tahmin edilmesi amacıyla parametrik olmayan yeni bir algoritma nerisi zerinde durmuřtur. alıřmada Namibya'nın gemiř yk verileri kullanılmıř olup yerel lineer regresyon ile yk zaman serisi trend bileřeni, uygun yerel lineer fonksiyon ile ekstrapolasyon yapılarak trend bileřeni tahmin edilmiřtir.

Akan ve Tak (2003) çalışmasında Türkiye'nin 2001-2025 dönemi için hem sektörel hem de toplam elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada 1970-2000 dönemine dair GSMH, nüfus, elektriğin fiyatı, elektrikli ev aletlerine dair üretim değeri, elektrik tüketiminin yıllık değeri ve bina sayısı gibi değişkenlerinin değerleri kullanılmıştır. Kısa ve uzun dönemli olarak planlanan çalışmada EKK ve hata düzeltme modeli tercih edilmiştir.

Sarak ve Satman (2003) Türkiye için yıllık doğalgaz tüketiminin tahmin edilmesini hedefleyen bir araştırma yapmıştır. Araştırmada ısıtma gün derecesi yöntemi kullanılmış olup 2023 yılında tüm konutlarda yerden ısıtmalı olarak doğalgaz kullanılması halinde 14,92 GM3 doğalgaz tüketileceği tahmin edilmiştir.

Topallı ve Erkmen (2003) çalışmalarında kısa vadeli elektrik yükü tahmininin yapılmasını hedeflemiştir. Çalışmada yapay sinir ağları yöntemi kullanılmış olup 2000 yılına ait verilerle test edilmiştir. Geçmiş verilerin çevrimdışı kullanıldığı ve modelin ise çevrimiçi tahminler için hazırlandığı bir yaklaşımı içeren bu çalışma ile Türkiye'nin toplam elektrik talebi bir gün öncesinden tahmin edilmiştir.

Canyurt ve ark. (2004) Türkiye'nin 2025 yılına dek enerji talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Genetik Algoritma yöntemi doğrultusunda 1970-2001 dönemi için brüt olarak elektriğin üretimi, ihracat ile ithalat değişkeninin verileri modele dahil edilmiştir. Ayrıca nüfus değişkeni de ele alınmıştır. Türkiye'nin 2025 yılı için yaklaşık olarak enerjiye olan talebin 250 milyon tep civarında olacağını belirlemişlerdir.

Hamzaçebi ve Kutay (2004) Türkiye için elektrik tüketiminin tahmin edilmesini hedefleyen bir çalışma yapmıştır. Uzun dönemli tahmini kapsayan bu çalışmada yapay sinir ağları yöntemi doğrultusunda değişken olarak elektrik tüketimi ile nüfus seçilmiş ve bu değişkenlerin verileri kullanılmıştır. Yapay sinir ağları yöntemi ile elde edilen sonuçlar, regresyon ve Box-Jenkins tekniği sonuçları ile karşılaştırılmıştır. Karşılaştırma sonucunda ise, yapay sinir ağları yönteminin elektrik enerjisinin tüketiminin tahmin edilmesi hususunda başka yöntemlerle kıyaslandığında daha uygun sonuç verdiği görülmüştür.

Jumbe (2004) çalışmasında Malawi için GSYH ile elektrik tüketimi arasındaki ilişkiyi incelemiştir. Çalışmada Malawi'nin 1970-1999 dönemi için GSYH ile elektrik tüketimi verileri kullanılmış olup iki yönlü nedensellik ilişkisi olduğu görülmüştür. Buna ek olarak

tarım dışı GSYH ile elektrik tüketimi arasındaki ilişki de incelenmiş, GSYH değişkeninden elektrik tüketimi değişkenine tek yönlü nedensellik ilişkisinin olduğu görülmüştür.

Lam ve Shiu (2004) Çin'in GSYH değeri ile elektrik enerjisinin tüketimine dair değer arasında nedensellik bağı olup olmadığını inceleyen bir analiz yapmıştır. Çalışmada Çin'in 1971-2000 dönemi için GSYH ile elektrik tüketimi verileri kullanılmış olup elektrik tüketimi değişkeninden GSYH değişkenine doğru çift yönlü olmayan bir nedensellik bağı olduğu görülmüştür.

Öztürk ve ark. (2004) araştırmalarında Türkiye'nin 2001-2020 dönemine dair kullanılabilir petrol enerjisinin tahmin edilmesini hedeflemiştir. Genetik Algoritma (GA) yöntemi doğrultusunda 1990-2000 dönemi için gayri safi yurtiçi hasıla (GSYİH) ile araç sahipliği yüzdelik verileri kullanılmıştır. Çalışmada üç form üzerinde çalışılmış ve ortalama bağıl hatası yönünden en uygun olan model, tahmin için tercih edilmiştir. Seçilen formun tahmin konusundaki mevcut tekniklere alternatif olarak kullanılabileceği sonucuna varılmaktadır.

Sözen ve ark. (2004) çalışmasında iki vakaya odaklanmıştır. Esas olarak yapay sinir ağları yöntemi ile Türkiye için güneş enerjisine dair potansiyel üzerinde durulmuştur. Çalışmada, Türkiye'nin 17 iline ait 2000-2002 döneminin meteorolojik verileri seçilmiştir. İkinci olarak ise, geliştirilen sinir ağları yazılımı ile lojistik sigmoid transfer fonksiyonu ve farklı öğrenme algoritmaları doğrultusunda en iyi yaklaşımın belirlenmesi üzerinde çalışılmıştır. YSA yöntemi ile geliştirilen modelin, Türkiye için güneş enerjisine dair potansiyelinin değerlendirilmesi açısından daha yüksek doğruluk payına sahip olduğu görülmüştür.

Yumurtacı ve Asmaz (2004) Türkiye için 2050 yılında elektriğe olan talebinin tahmininin yapılmasını hedeflemiştir. Türkiye'nin 1980-2050 dönemine dair nüfus artışı ile enerji tüketim artışının kişi başına düşen kısmı hesaplanıp veri olarak temel oluşturulmuştur. Yöntem olarak ise, doğrusal regresyon seçilmiştir. Ayrıca yenilenebilir bir enerji kaynağı olan hidroelektrik enerjisine dair potansiyelin kullanılması üzerinde de durulmuştur.

Haldenbilen ve Ceylan (2005) çalışmalarında Türkiye için 2020 tarihine kadar enerjiye olan talebi sektörel anlamda ele almıştır. Genetik algoritma yöntemini kullanılarak taşıma enerjisine dair üç farklı model geliştirilmiştir. Çalışmada Türkiye'nin 1970-2000 dönemine

dair GSYH, nüfus ve araç-km verileri kullanılmıştır. Sonuç olarak ise, modelin ikinci derece formunun daha gerçekçi bir tahmin sunduğu görülmüştür.

Öztürk ve Ceylan (2005) araştırmalarında Türkiye için 2002 yılı ile 2025 yılı arasındaki dönemi kapsar şekilde toplam enerjiye olan talebin tahmin edilmesini hedeflemiştir. Genetik Algoritma yöntemi doğrultusunda 1970-2001 dönemi için GSYİH, nüfus, ithalat ile ihracat değişkenlerinin verileri kullanılmıştır. Çalışmada üç çeşit senaryo uygulanmış olup ETKB verileri ile karşılaştırma yapılmıştır.

Öztürk ve ark. (2005) çalışmalarında endüstriyel ve toplam elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada genetik algoritma tercih edilmiş olup GSMH, nüfus, ihracat ve ithalat ve değişkenleri kullanılmıştır. Çalışma sonucunda ise, doğrusal olmayan iki farklı model önerilmiştir.

Sözen ve ark. (2005) Türkiye için enerji tüketiminin tahmini konulu araştırma yapmıştır. YSA yöntemi ile iki model geliştirilmiş olup Türkiye'nin 1975-2003 dönemi için nüfus, kurulu kapasite ve üretim verileri eğitim verileri olarak kullanılmıştır. 1981, 1994 ve 2003 yıllarına ait veriler ise, test verileri olarak kullanılmıştır. Araştırma sonucunda yapay sinir ağları yönteminin gerçekçi bir sonuç verdiği gözlemlenmiştir.

Yalçınöz ve Eminoglu (2005) çalışmalarında enerji dağıtım sistemleri için kısa vadeli pik ve toplam yük ile orta vadeli aylık yük tahminlerinin yapılmasını hedeflemiştir. Çalışmada yapay sinir ağları yöntemi seçilmiş olup Niğde ilinin günlük ve aylık elektrik tüketimi verileri kullanılmıştır. Çalışma sonucunda ise, iki gizli katmana sahip sinir ağının en uygun sonucu verdiği görülmüştür.

Aslan ve ark. (2006) Kütahya ilinde bulunan dağıtım şirketleri için elektrik puant yük tahmini konulu analiz üzerinde çalışmıştır. Yapay sinir ağları yöntemi kullanılarak 2000-2004 dönemi için sıcaklık değişimi ve nüfus artışı değişkenlerinin verileri kullanılmıştır. Analizin sonucunda ise, gerçek veriler ile sonuçlar karşılaştırılmıştır. Veri sayısının artması ile hata oranının düştüğü sonucu elde edilmiştir. Ayrıca gerçekçi sonuçlar için farklı yöntemler kullanılması gerektiği üzerinde durulmuştur.

Canyurt ve Öztürk (2006) çalışmalarında petrol talebinin tahmin edilmesini hedeflemiştir. Çalışmada genetik algoritmaya dayalı model geliştirilmiş olup GSMH, nüfus, kamyon satışı, petrol ithalatı ve ithalatın kullanıldığı modelin en uygun çözümü sunduğu görülmüştür.

Murat ve Ceylan (2006) Türkiye'nin 2020 yılına kadar olan ulaştırma enerjisine olan talebin tahmin edilmesini hedefleyen bir analiz yapmıştır. YSA yöntemi doğrultusunda Türkiye'nin 1970-2001 dönemi için GSMH ve nüfus değişkenlerinin yanı sıra yıllık olarak araç-km verilerinin ortalama değerleri de kullanılmıştır. Analiz kapsamında iki adet plan oluşturulmuş ve sonuçların uygun olduğu gözlemlenmiştir.

Potter ve Negnevitsky (2006) araştırmalarında Avustralya Tazmanya bölgesi için rüzgâr enerjisinin tahmin edilmesini hedeflemiştir. ANFIS yöntemi doğrultusunda hız ve yön vektörlerine dönüştürülen veriler ile %4'ten daha az mutlak yüzde hata oranı veren model geliştirilmiştir.

Rufael (2006) çalışmasında Afrika kıtasında yer alan 17 adet ülke için GSYH değişkeninin kişi başlı değeri ile elektrik tüketiminin kişi başlı değeri arasındaki ilişkiyi incelemiştir. Çalışmada 1971-2001 yıllarını kapsayan zaman dilimi için GSYH değişkeninin kişi başlı değeri ile elektrik tüketiminin kişi başlı değerine test uygulanmış olup bu değişkenler arasında uzun vadeli ilişki olan, GSYH değişkeninin kişi başlı değerinden elektrik tüketimi değişkenine doğru pozitif tek yönlü bir nedensellik bulunan, ters nedensellik ve çift yönlü nedensellik bağı bulunan ülkeler olduğu görülmüştür.

Say ve Yücel (2006) Türkiye için 1970 yılı ile 2022 yıllarını kapsayan dönemdeki enerji ile alakalı sektör incelemesi yapmıştır. Ekonomik büyüme ve nüfus artışı değişkenlerine dair resmi verileri kullanılmış olup doğrusal regresyon yöntemi ile Türkiye'nin 2010 ile 2015 yıllarına dair enerji talep tahmini uygulaması yapılmıştır.

Sözen ve ark. (2006) Türkiye'nin net enerji talebinin tahmini konulu bir araştırma yapmıştır. Yapay sinir ağları yöntemi doğrultusunda kurulu güç, nüfus ve brüt üretim değişkenlerinin 1953-2000 dönemi verileri kullanılmıştır. Yöntemin kabul edilebilir tahminler sunduğu görülmüş olup gelecek çalışmalar için de önerilmiştir.

Taylor ve ark. (2006) çalışmalarında kısa dönemli elektrik talep tahmini için altı adet tek değişkenli yöntemin doğruluğunu karşılaştırmayı hedeflemiştir. Çalışmada Rio de Janeiro için yarım saatlik, Galler ve İngiltere için saatlik talep verileri kullanılmıştır. Yöntem olarak ise, temel bileşen analizi ile üstel düzeltme yöntemleri önerilmiştir.

Tunç ve ark. (2006) Türkiye'nin 2010-2020 dönemi için elektrik enerjisi tüketim oranlarının analiz edilmesini hedefleyen bir araştırma yapmıştır. Araştırmada regresyon analizi yöntemi tercih edilmiş olup kurulu elektrik gücü, enerji kaynakları, elektrik üretim ve tüketimi üzerinde durulmuştur. Almanya, Fransa ve İsviçre ile de karşılaştırmalar yapılmıştır.

Akay ve Atak (2007) çalışmalarında Türkiye'nin 2016-2015 dönemi için hem endüstriyel hem de toplam elektrik tüketiminin tahmin edilmesini hedeflemiştir. Gri tahmin yöntemi doğrultusunda Türkiye'nin 1970-2004 dönemine dair veriler kullanılmıştır. Tahmin verileri, ETKB'nin MAED (Model for Analysis of Energy Demand) doğrultusunda elde edilen tahmin verileri ile karşılaştırılmıştır.

Ediger ve Akar (2007) Türkiye için 2005 yılı ile 2020 yıllarını kapsayan zaman dilimi için birincil enerjiye olan talebin tahmin edilmesini hedefleyen bir analiz yapmıştır. ARIMA ve mevsimsel ARIMA yöntemleri doğrultusunda Türkiye'nin 1950-2004 dönemine dair fosil yakıtlar değişken olarak seçilmiş olup veriler kullanılmıştır. Hedeflenen 2020 yılı için ülkemizin enerjiye olan talebinin tep cinsinden 150 milyon civarı olabileceği sonucuna varılmış olup bu doğrultuda çeşitli önerilerde bulunulmuştur.

Erdoğan (2007) araştırmasında Türkiye için 2005 yılı ile 2014 yıllarını kapsayan zaman dilimi için elektriğe olan talebin tahmininin yapılmasını hedeflemiştir. Eşbütünleşme analizi ve ARIMA yöntemi doğrultusunda Türkiye'nin 1923-2004 dönemi için GSYH, nüfus, ihracat ve ithalat değişkenlerinin resmi verileri kullanılmıştır. Elde edilen sonuçlar ise, TEİAŞ tarafından yapılan MAED tabanlı tahminlerle karşılaştırılmış olup çalışmada çözümlenen modelin daha sağlıklı değerler ürettiği görülmüştür.

Halıcıoğlu (2007) Türkiye'nin 1968-2005 dönemine dair konut elektrik talebini gelir, fiyat ve kentleşme bakımından inceleyen bir çalışma yapmıştır. Çalışmada Granger nedensellik analizi, eşbütünleşme ve sınır testi uygulanmış olup kısa ve uzun dönem ilişkiler

açıklanmıştır. Çalışma sonucunda ise, gelir, fiyat ve kentleşme üzerinde uzun dönemde Granger nedensellik ilişkisi olduğu ancak kısa dönemde ilişki olmadığı görülmüştür.

Hamzaçebi (2007) çalışmasında Türkiye'nin 2003-2020 dönemi için sektörel elektrik tüketiminin tahmin edilmesini hedeflemiştir. YSA yöntemi doğrultusunda ortaya çıkan tahmin verileri, MAED tahminleriyle karşılaştırılmış olup gerçek değerler ile daha uyumlu sonuçlar elde edildiği görülmüştür.

Mozumder ve Marather (2007) Bangladeş'in GSYH faktörünün kişi başlı değeri ile elektrik tüketimi faktörünün kişi başlı değeri arasındaki ilişkiyi inceleyen bir araştırma yapmıştır. Araştırmada 1971-1999 dönemi için resmi veriler kullanılmış olup kişi başı GSYH değişkeninden kişi başı elektrik tüketime tek yönlü nedensellik ilişkisi olduğu görülmüştür.

Sözen ve Arcaklıoğlu (2007) çalışmalarında Türkiye için enerji tüketiminin tahmininin yapılmasını hedeflemiştir. Çalışmada Türkiye'nin 1968-2005 dönemine dair ekonomi ve nüfus verileri kullanılmıştır. Yapay sinir ağları yöntemi doğrultusunda üç farklı model geliştirilmiş olup bu yöntemin tahmin konusunda güvenilir olduğu belirtilmiştir.

Toksarı (2007) Türkiye'nin 2007-2025 dönemi için elektrik enerjisi talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Karınca kolonisi optimizasyonu yöntemi doğrultusunda Türkiye'nin 1979-2005 dönemi için GSYH, ihracat ile ithalat değişkeninin verileri modele dahil edilmiştir. Ayrıca nüfus değişkeni de ele alınmıştır. Analizde üç adet varsayım uygulanmış olup ETKB projeksiyonu ile karşılaştırma yapılmıştır.

Amarawickrama ve ark. (2008) çalışmalarında Sri Lanka için elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Statik/Dinamik EG, FMOLS, Johansen, PSS ve STSM yöntemleri ile Sri Lanka'nın 1970-2003 dönemi için GSYH, nüfus ve ortalama elektrik tarifesini fiyatlarına ilişkin çeşitli veri tabanlarından alınan resmi veriler kullanılmıştır. Çalışmada tercih edilmiş olan altı farklı yöntem ile Sri Lanka'nın 2026 yılına kadar elektrik tüketimi tahmin edilmiş olup tahminlerin birbirine yakın olduğu gözlemlenmiştir. Ayrıca çalışma sonucunda elde edilen tahminler, CEB (Ceylon Electricity Board) tahminleri ile de karşılaştırılmış ve değerlendirmeler yapılmıştır.

Aras (2008) konutlar için kısa vadeli doğalgaz talebinin tahmin edilmesini hedefleyen bir araştırma yapmıştır. Araştırmada genetik algoritma yöntemi tercih edilmiş olup Eskişehir'in 2009-2013 dönemi için aylık doğalgaz talebi tahmin edilmiştir.

Canyurt ve Öztürk (2008) Türkiye'nin kömür, doğalgaz ve petrol talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Genetik algoritma yöntemi doğrultusunda GSMH, nüfus, ihracat ve ithalat değişkenlerinin resmi verileri kullanılmıştır. Sonuç olarak ise, Türkiye'nin 2020 yılına kadar fosil yakıt talebi tahmin edilmiş olup DEKTMK'nin hazırladığı planlarla karşılaştırılmıştır.

Taylor ve Mcsharry (2008) çalışmalarında kısa vadeli yük tahmini için yöntem incelenmesi yapmıştır. Çalışmada 10 Avrupa ülkesinin elektrik talep verileri kullanılmıştır. Yöntem olarak ise, Holt-Winters ve ARIMA yöntemleri tercih edilmiştir. Çalışma sonucunda ise, Holt-Winters yönteminin daha iyi performans gösterdiği anlaşılmıştır.

Ünler (2008) Türkiye'nin 2006-2025 dönemi için elektrik enerjisi talebini araştırmıştır. Parçacık sürü optimizasyonu ile Türkiye'nin 1979-2005 dönemi için GSMH, nüfus, ihracat ve ithalat değişkenlerinin resmi verileri kullanılmıştır. Parçacık sürü optimizasyonu doğrultusunda elde edilen sonuçlar karınca kolonisi optimizasyonu doğrultusunda elde edilen sonuçlarla karşılaştırılmış ve değerlendirilmiştir.

Ying ve Pan (2008) çalışmalarında Tayvan için bölgesel elektrik yükünün tahmin edilmesini hedeflemiştir. Çalışmada 1981-1996 dönemine ait veriler eğitim, 1997-2000 yıllarını kapsayan verilerin test için kullanıldığı görülmüştür. YSA, ANFIS, genetik algoritmali SVM, genetik algoritmali tekrarlayan SVM ile hibrid elipsoid bulanık sistem yöntemleri ile modeller geliştirilmiştir. Modellerin çözümü ile elde edilen tahminler karşılaştırılmış ve en güvenilir tahminin ANFIS ile çözümlenen modele ait olduğu sonucuna varılmıştır.

Azadeh ve ark. (2009) İran için elektrik tüketiminin tahmin edilmesini hedeflemiştir. Bilgisayar simülasyonu, ANFIS ve zaman serisi algoritmasından oluşan hibrit bir yöntem kullanılmıştır. İran'ın Nisan 1994-Şubat 2005 dönemi için aylık elektrik tüketimine dair resmi verileri kullanılarak ulaşılan tahmin değerleri, YSA ve genetik algoritma yönteminin uygulandığı çalışma sonuçları ile karşılaştırılmıştır. Yapılan değerlendirme sonucunda ise, çalışmada önerilen hibrit yöntemin daha güvenilir tahminlere ulaştığı görülmüştür.

Bianco ve ark. (2009) arařtırmalarında İtalya için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiřtir. Çoklu regresyon yöntemi ile 1970-2007 dönemi için elektrik tüketimi, nüfus ve kiři bařına düşen GSYH ile toplam GSYH deęiřkenlerine dair resmi veriler kullanılmıřtır. Bu çalıřma ile 2030 yılına dek yıllık olarak elektrik tüketim tahmininde bulunulmuř olup demografik ve ekonomik faktörlerin İtalya’da yıllık elektrik tüketimine etkisi incelemiřtir.

Geem ve Roper (2009) Güney Kore’nin 2008-2025 dönemi için enerji talebinin tahmin edilmesini hedeflemiřtir. Yapay sinir aęları yöntemi ile 1980-2007 dönemi için GSYH, nüfus, ihracat ve ithalat verilerine dair resmi veriler kullanılmıřtır. Sonuçlar ise, doęrusal regresyon ile üstel yöntem uygulanan modellerle karřılařtırılmıř olup yapay sinir aęları yönteminin daha güvenilir tahminler verdięi görölmüřtür.

Kavaklıoęlu ve ark. (2009) çalıřmalarında Türkiye’nin 2007-2027 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiřtir. Yapay sinir aęları yöntemi ile Türkiye’nin 1975-2006 dönemi için GSMH, nüfus, ihracat ve ithalat deęiřkenlerinin resmi verileri kullanılmıřtır. Oluřturan modellerin yapay sinir aęları ile çözümleri sonucunda modellerin performans açısından deęerlendirilmesi yapılmıř ve karřılařtırmalar yapılmıřtır.

Pao (2009) Tayvan’ın elektrik ve petrol tüketiminin tahmin edilmesini hedefleyen bir çalıřma yapmıřtır. Çalıřmada iki adet hibrit yapay sinir aęı modeli geliřtirilmiř olup doęrusal modellere göre daha iyi performans gösterdięi anlařılmıřtır.

Rothe ve ark. (2009) arařtırmasında Hindistan’ın elektrik tüketiminin saatlik olarak tahmini için rüzgar ve sıcaklık gibi deęiřkenler kullanmıřtır. Bunun yanı sıra ölkedeki gölge zamanı ile elektrik tüketiminin saatlik verileri kullanılmıř olup regresyon analizi yapılmıřtır.

Sümer ve ark. (2009) çalıřmalarında Kayseri ve Civarı Elektrik Türk A.ř.’ye ait elektrik talebinin 2006-2010 dönemi için tahmin edilmesini hedeflemiřtir. Çalıřmada 1997-2005 dönemine ait veriler kullanılmıřtır. Yöntem olarak ise, ARIMA, SARIMA ve regresyon modeli tercih edilmiřtir. Çalıřmanın sonucunda ise, önerilen modelin dięer modellere kıyasla daha güvenilir tahminler sunduęu görölmüřtür.

Toker ve Korkmaz (2009) Türkiye'nin 2008-2009 dönemi için toplam elektrik tüketimi ile İstanbul'a ait sıcaklık, nem, rüzgâr, yağış gibi meteorolojik faktörler, takvim günleri ile güneş alma süresi değişkenlerinin verileri kullanarak kısa vadeli elektrik tüketiminin tahmin edilmesini amaçlayan bir çalışma yapmıştır. Çalışmada spektrum analizi, filtreleme ve yapay sinir ağları yöntemleri tercih edilmiş olup hata payı düşük bir model geliştirilmiştir (URL-3).

Toksarı (2009) Türkiye için 2007 ile 2025 yıllarını kapsayan zaman dilimi için elektriğin hem üretiminin hem de talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Karınca kolonisi optimizasyonu yöntemi doğrultusunda Türkiye'nin 1975-2006 dönemi için GSYH, nüfus, ihracat, ithalat ve elektrik üretimi değişkenlerinin resmi verileri kullanılmıştır. Analizde hem doğrusal hem de ikinci dereceden modeller oluşturulmuş ve ikinci dereceden modellerin tahmin konusunda daha başarılı olduğu görülmüştür.

Wei ve Zhen-gang (2009) araştırmalarında bir bölgenin elektrik yük tahmininin yapılmasını hedeflemiştir. ARIMA yöntemi doğrultusunda Ocak 2003-Aralık 2008 dönemi için aylık elektrik yük verileri kullanılmıştır. Çeşitli ARIMA modelleri ile tahmin gerçekleştirilmiş olup gelecek çalışmalarda p ile q parametreleri üzerinde durulması önerilmiştir.

Akkurt ve ark. (2010) çalışmasında Türkiye için hem aylık hem de yıllık doğalgaz tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada üstel Box-Jenkins ve Winters gibi yöntemler kullanılmış olup yöntem sonuçları karşılaştırılmıştır.

Altınay (2010) Türkiye'nin 2009 yılı için aylık olarak elektrik tüketiminin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analizde mevsimsel ARIMA yöntemi doğrultusunda 1995-2008 dönemi için aylık tüketim değerlerinin resmi verileri kullanılmıştır.

Cheng ve Wei (2010) çalışmalarında Tayvan için bölgesel elektrik yükünün tahmin edilmesini hedeflemiştir. Çalışmada Tayvan'ın 1981-2000 dönemi için dört bölgesi için elektrik yükü değişkenine dair verileri kullanılmış olup füzyon ANFIS modeli tercih edilmiştir. Çalışma sonucunda ise, MAPE değerinin düşük olması nedeniyle tercih edilen modelin güvenilir tahminler sunduğu görülmüştür.

Çınar ve ark. (2010) Türkiye'nin 2007-2012 dönemi için hidroelektrik enerjisi talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Analizde genetik algoritma ile Türkiye'nin 1970-2006 dönemi için GSMH, nüfus, birincil enerji ve yüklenmiş kapasite değişkenlerinin resmi verileri kullanılmıştır.

Çunkaş ve Altun (2010) araştırmalarında Türkiye'nin 2008-2014 dönemi için elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Araştırmada yapay sinir ağları yöntemi ile Türkiye'nin ekonomisine dair GSMH, GSYH, nüfus, sanayi üretim endeksi, hane sayısı, elektrik ve petrol fiyatı gibi değişkenlerin resmi verileri kullanılmıştır. Çalışmanın sonuçları ise, resmi tahminler ile karşılaştırılarak değerlendirme yapılmıştır.

Demirel ve ark. (2010) çalışmalarında Türkiye'nin 2006-2010 dönemi için elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Çalışmada ARMA ve ANFIS yöntemleri ile Türkiye'nin 1970-2007 dönemi için GSMH, nüfus, kurulu güç, üretilen ve tüketilen enerji değişkenlerinin resmi verileri kullanılmıştır. Çalışmada SPSS ve MATLAB paket programları kullanılmış olup çıkan sonuçlar kurumların resmi verileri ile karşılaştırılmış ve önerilerde bulunulmuştur.

Ekonomou (2010) Yunanistan'ın enerji tüketimi tahmininin yapılmasını hedefleyen bir analiz çalışması yapmıştır. Yapay sinir ağları yönteminin çok katmanlı modeli ile GSYH, kurulu güç kapasitesi, ortam sıcaklığı ve kişi başına elektrik tüketimi verilerine dair resmi veriler kullanılmıştır. Yunanistan'ın 2005-2015 yılları arasındaki belirli dönemler için elde edilen tahminler, destek vektör makineleri ve regresyon modelleri ile karşılaştırılmıştır. Yapılan değerlendirme sonucunda ise, yöntemlerin birbirleriyle uyumlu sonuçlar ortaya çıkardığı ancak yapay sinir ağları yönteminin daha başarılı olduğu görülmüştür.

Erdoğan (2010) çalışmasında Türkiye'nin doğalgaz enerjisi talebinin tahmin edilmesini hedeflemiştir. ARIMA yöntemi ile Türkiye'nin 1987-2007 dönemi için tüketim değişkenine dair resmi verileri kullanılmıştır. Ayrıca çalışmada doğalgaz enerjisi talebinin kısa/uzun vadeli fiyat ile gelir esnekliği üzerinde durulmuş olup çalışmada elde edilen 2008-2030 dönemine dair sonuçlar resmi veriler ile karşılaştırılmıştır. Bu çalışma ile Türkiye'nin doğalgaz talep esnekliğinin düşük olduğu anlaşılmıştır.

Küçükali ve Barış (2010) Türkiye'nin 2009-2014 dönemi için elektrik enerjisi talebinin tahmin edilmesini hedefleyen bir araştırma yapmıştır. Bulanık mantık yöntemi ile Türkiye'nin 1980-2008 dönemi için yalnızca GSMH değişkenine dair resmi verileri kullanılmıştır. Ayrıca araştırmada regresyon yöntemi de kullanılmış olup sonuçlar ile resmi veriler karşılaştırılmıştır.

Küçükdeniz (2010) çalışmasında destek vektör makineleri ile yapay sinir ağı yöntemleri ile uzun vadeli elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Çalışmada şebeke kayıpları ve şebekeye verilmiş olan enerji ayrı şekilde hesaplanarak tahminler elde edilmiştir.

Newsham ve Birt (2010) Kanada'nın Ontario eyaletinde bulunan üç katlı bir bina için elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada dış ortam sıcaklığı, ağı giriş yapan kişi sayısı, soğutma için kullanılmakta olan enerji miktarı ve doluluk oranı hakkında veriler toplanmıştır. ARIMAX modeli geliştirilmiş olup binanın doluluk oranı değişkeninin önemli bir bağımsız değişken olduğu ve modelin güvenilirliğini artırdığı anlaşılmıştır. Sonuç olarak ise, üç katlı binanın elektrik enerjisine olan talebi birkaç saat öncesinde doğru bir şekilde tahmin edilmiştir (URL-1).

Ok (2010) çalışmasında Türkiye'nin orta vadeli brüt elektrik enerjisi talebinin tahmin edilmesi hedeflemiştir. Çalışmada Türkiye'nin 1987-2008 tarihlerindeki GSMH, nüfus, ihracat ve ithalat değişkenlerinin üçer aylık verileri kullanılmış olup ANFIS modeli tasarlanmıştır. Ayrıca ANFIS modeli ile yapılan tahminlerin değerlendirilmesi için çoklu regresyon analizi de uygulanmıştır. Çalışma sonucunda ise, ANFIS modeli ile yapılan tahminlerin daha güvenilir olduğu görülmüştür.

Toksarı (2010) Türkiye'nin 2025 yılına dek doğalgaz talebinin tahmin edilmesini hedefleyen bir araştırma yapmıştır. Araştırmada benzetimli tavlama yöntemi tercih edilmiş olup GSYH, nüfus, ihracat ve ithalat gibi değişkenlerin verileri kullanılmıştır. Araştırma sonucunda ise, doğrusal ve kuadratik formların sapma değerleri karşılaştırılmıştır.

Avami ve Boroushaki (2011) İran için yıllık enerji tüketiminin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analizde yapay sinir ağları yöntemi doğrultusunda İran'ın

1976-2006 dönemi için GSYİH ve nüfus verileri kullanılmıştır. Kurulan 12 nöronlu model sonucunda enerji tüketiminin kabul edilebilir bir doğrulukla tahmin edildiği görülmüştür.

Dilaver ve Hunt (2011) çalışmasında Türkiye'nin 2009-2020 dönemi için sanayi sektöründeki elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Yapısal zaman serisi yöntemi ile Türkiye'nin 1960-2008 dönemi için sanayi sektörünün katma değer endeksi ile elektrik fiyatı değişkenlerine dair resmi verileri kullanılmıştır.

Başaran Filik ve ark. (2011) Türkiye'nin elektrik enerjisi talebinin uzun vadeli tahmin edilmesini sağlayan bir model geliştirmiştir. Geliştirilen model ile Türkiye'nin 1982-2007 dönemindeki yıllık yük değişkenine dair resmi veriler kullanılmıştır. Çalışmada, saatlik yük için minimum hata amaçlı oluşturulan iki boyutlu bir model benimsenmiştir. Model fonksiyonları, tahmin doğrulukları ve RMSE, MAPE sonuçlarıyla beraber çalışmada sunulmuştur.

Geem (2011) araştırmasında Güney Kore'nin 2008-2025 dönemi için ulaşım enerji talebinin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi ile 1990-2007 dönemi için GSYH, nüfus, araç ve yolcu sayısı verilerine dair resmi veriler kullanılmıştır. Sonuçlar ise, çoklu doğrusal regresyon uygulanan modellerle karşılaştırılmış olup yapay sinir ağları yönteminin daha güvenilir tahminler verdiği görülmüştür.

Hotunluoğlu ve Karakaya (2011) çeşitli senaryolar aracılığıyla Türkiye için 2009-2030 döneminin enerji talep tahmininin yapılmasını hedeflemiştir. YSA yöntemi ile Türkiye için 1970 yılı ile 2008 yıllarını kapsayan dönemdeki GSYH ve nüfus faktörünün yanı sıra hem ihracat hem de ithalat faktörleri değerlendirilmiştir. Ayrıca farklı olarak enerjinin yoğunluğu değişkenine dair resmi veriler de modele dahil edilmiştir. Çalışma kapsamında statik, sürdürülebilir ve dönemsel-değişim senaryo olmak üzere üç çeşit senaryo oluşturulmuştur. Sonuçlar ise, ETKB'nin tahminleri ile karşılaştırılmış ve modeldeki tahminlerin daha düşük olduğu görülmüştür.

Kankal ve ark. (2011) çalışmalarında Türkiye'nin 2008-2014 dönemi için enerji tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada yapay sinir ağları yöntemi ile demografik ile sosyo-ekonomik değişkenler incelenmiştir. Çalışmada GSYH, nüfus, ihracat ve ithalat değişkenleri seçilmiş ve dört farklı model kullanılmıştır. En güvenilir sonucu veren model

ele alınarak resmi kurumların tahminleri ile karşılaştırılmıştır. Modelin, Enerji ve Tabi Kaynaklar Bakanlığı projeksiyonlarına göre daha güvenilir sonuç verdiği görülmüştür.

Kavaklıoğlu (2011) Türkiye'nin 2026'ya kadar olan dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedefleyen bir analiz yapmıştır. Analizde destek vektör regresyonu yöntemi ile Türkiye'nin 1975-2006 dönemi için GSMH, nüfus, ihracat ve ithalat değişkenine dair resmi verileri kullanılmıştır. Model performansını değerlendirmek için de RMSE kriteri kullanılmıştır.

Limanond ve ark. (2011) Tayland için 20 yıllık ulaşım enerji talebinin tahmin edilmesini hedefleyen bir araştırma yapmıştır. Log-lineer modeller ile 1989-2008 dönemi için nüfus, GSYH ve araç sayısı değişkenlerinin resmi verileri kullanılmış olup Tayland'ın 20 yıllık ulaşım enerji talebi tahmin edilmiştir.

Yayar ve Hekim (2011) çalışmalarında Tokat ilinin 2011 yılı ilk altı ayına dair elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Çalışmada ARIMA ve ANFIS yöntemleri doğrultusunda yedi farklı tahmin senaryosu uygulanmıştır. Çalışma sonucunda ise, ANFIS yönteminin daha uygun bir yöntem olduğu anlaşılmıştır.

Al-Hafid ve Al-maamary (2012) Irak için günlük en yüksek elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Holt-Winters yöntemi ile 2009-2011 dönemi için günlük tüketim verileri kullanılmıştır. Çalışma sonucunda ise, uygun bir model kurulduğu gözlemlenmiştir.

Bilgili ve ark. (2012) çalışmasında Türkiye'nin 2008-2015 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada hem konutlar için hem de sanayi sektörü için elektrik enerjisi tüketim tahminine odaklanılmıştır. YSA yöntemi ile doğrusal regresyon (LR) ile doğrusal olmayan regresyon (NLR) yöntemleri ile Türkiye için 1990 ile 2007 yıllarını kapsayan zaman dilimindeki nüfus, elektrik üretimi, kurulu güç ve abone sayısı değişkenine dair resmi verileri kullanılmıştır. Çalışmada elde edilen sonuçlar ise, resmî kurumlar tahmin verileri ve literatürdeki çalışmaların tahmin verileri ile karşılaştırılmıştır.

Kıran ve ark. (2012) araştırmasında Türkiye'nin elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Karınca kolonisi optimizasyonu ve parçacık sürü optimizasyonu ile GSYH, nüfus, ihracat ve ithalat değişkenine dair resmi verileri kullanılmış yapılmış ve sonuçlar karşılaştırılmıştır.

Puspitasari ve ark. (2012) Java-Bali Endonezya için yarım saatlik elektrik yükünün tahmin edilmesini hedefleyen bir analiz yapmıştır. Analizde Hibrit ARIMA-ANFIS yöntemine dayalı iki seviyeli mevsimsel model ile 01.01.2009-31.12.2010 dönemi için yarım saatlik elektrik yükü verileri kullanılmıştır. Analiz sonucunda ise, hibrit modelin ARIMA ve ANFIS modellerine göre daha uygun tahminler verdiği görülmüştür.

Wang ve ark. (2012) çalışmalarında Kuzeybatı Çin için elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada PSO, mevsimsel ARIMA ve iki yöntemin hibritlenmesi sonucunda elde edilen yeni bir yöntem tercih edilmiş olup yapılan karşılaştırmalar neticesinde hibrit modelin diğer modellerden daha iyi tahmin yapabildiği gözlemlenmiştir.

Atalay (2013) 5000 adet ticari işletme ile tüm Doğu Slovakya'nın elektrik taleplerinin tahmin edilmesini hedefleyen bir model geliştirmiştir. Dört çeşit makine öğrenmesi tekniği ile hem zamansal hem de meteorolojik faktörler modellenip karşılaştırılmıştır. Ayrıca, makine öğrenmesi tekniklerinin performansını arttıran temel bileşenler analizi yöntemi de kullanılmıştır.

Boltürk (2013) bir şirketin elektrik talep tahmininde kullanılan yöntemlerin karşılaştırılması için inceleme çalışması yapmıştır. ARIMA, YSA, Holt Modeli, Bulanık Mantık, Gri Sistem, Hareketli Ortalama ve regresyon yöntemleri doğrultusunda şirketin 12 yıllık tüketim verileri kullanılmıştır. Kısa, orta ve uzun dönemler için ayrı ayrı talep tahminleri yapılmış ve bulanık mantık yönteminin neredeyse tüm dönemlerde en uygun sonuçları verdiği görülmüştür.

Es ve ark. (2014) çalışmalarında Türkiye'nin 2011-2025 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi ile Türkiye'nin 1970-2010 dönemi için GSYH, nüfus, ihracat, ithalat, taşıt sayısı ve bina yüzölçümü değişkenlerine dair resmi verileri kullanılmıştır. Çalışmada elde edilen sonuçlar ise, zaman serisi ve regresyon yöntemlerine dair modellerin tahminleri ile karşılaştırılmış ve yapılan

değerlendirmeler sonucunda yapay sinir ağıları yönteminin daha başarılı olduğu anlaşılmıştır.

Gürbüz ve ark. (2013) çalışmalarında Türkiye'nin 2010-2022 dönemi için net elektrik tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada 1979-2009 dönemine ait veriler kullanılmış olup yapay arı kolonisi algoritması tercih edilmiştir.

Kheirkhah ve ark. (2013) araştırmasında elektrik tüketimindeki hem aylık hem de mevsimsel tahmin değişikliklerini analiz etmeyi hedeflemiştir. Araştırmada ANOVA, YSA, PCA ve DEA yöntemleri kullanılmış olup İran'ın Nisan 1992-Şubat 2004 dönemi için elektrik tüketimi verileri kullanılmıştır. Araştırmanın sonucunda ise, kullanılan algoritmanın probleme uygun olduğu görülmüştür.

Melikoğlu (2013) çalışmasında Türkiye'nin 2013-2030 dönemi için doğalgaz talebinin tahmin edilmesini hedeflemiştir. Çalışmada zaman serileri analizi tercih edilmiş olup doğrusal modelin orta vadeli; lojistik modelin ise uzun vadeli talep tahmini için uygun olduğu görülmüştür.

Uslu ve ark. (2013) 2014 yılı için aylık elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada 2010-2013 dönemi için aylık elektrik tüketimi, İstanbul ile Ankara'nın ortalama aylık sıcaklık değeri, sanayi üretim endeksi ve aylık iş ile tatil günleri değişkenlerinin verileri kullanılmıştır. Ayrıca mevsimsellik etkisi için bir önceki yıla dair elektrik tüketim verileri de modelde kullanılmıştır. Aylık çalışma günleri de ağırlıklandırılmış olup anlamlı sonuçlara ulaşılmıştır (URL-4).

Yazgan (2013) çalışmasında kısa dönemde şebekede elektrik enerjisinin talebi ile marjinal birim fiyatının gün öncesi değerinin tahmin edilmesini hedeflemiştir. Çalışmada YSA, ARIMA, en küçük kareler yöntemi, destek vektör makineleri ve Kalman filtresi yöntemleri kullanılmış olup bir bilgisayar yazılımı aracılığıyla yöntem uygunluğu kanıtlanmıştır. Çalışma sonucunda ise, destek vektör makineleri yönteminin en küçük hata oranını vermesi nedeniyle diğer yöntemlere göre daha uygun olduğu görülmüştür.

Aydın (2014) Türkiye'nin enerji tüketimi tahmini için demografik ve ekonomik unsurlara dayalı regresyon modeli geliştirmiştir. Oluşturulan üç farklı senaryo ile GSYİH ve nüfus

değişkenlerinin verileri kullanılarak birincil enerji tüketimi tahmini yapılmıştır. Uygulama sonucunda ise, oluşturulan modelin uygun olduğu görülmüştür.

Bayrak ve Esen (2014) araştırmalarında Türkiye'nin 2012-2020 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi ile Türkiye'nin 1960-2011 dönemi için GSYH, nüfus, ihracat ve ithalat değişkenine dair resmi verileri kullanılmıştır. Araştırmada elde edilen sonuçlar ise, resmî kurumların tahmin verileri ile karşılaştırılmış ve değerlendirmeler yapılmıştır.

Hamzaçebi ve Es (2014) Türkiye'nin 2013-2025 dönemi için toplam elektrik enerjisi talebinin tahmin edilmesini hedefleyen bir analiz yapmıştır. Analizde gri sistem teorisi tercih edilmiş olup doğrudan ve iteratif yaklaşımlar uygulanmıştır.

Liu ve ark. (2014) araştırmalarında sıcaklığa bağlı elektrik yükünün kısa vadeli tahmin edilmesini hedeflemiştir. Araştırmada SARIMAX ve YSA yöntemleri doğrultusunda iki farklı model önerilmiştir. İlk aşamada YSA modelinin iyi sonuç verdiği ancak tahmin aşamasında SARIMAX modelinin daha iyi olduğu görülmüştür.

Ozoh ve ark. (2014) çalışmalarında elektrik tüketiminin tahmini amacıyla değiştirilmiş Newton yönteminin analiz edilmesini hedeflemiştir. Malezya'da bulunan bir devlet üniversitesinin 2009-2012 dönemi için elektrik tüketimi verileri ile zaman serisi, yapay sinir ağları ve değiştirilmiş Newton yöntemini kullanmıştır. Çalışma sonucunda ise, yöntemlerin sonuçları analiz edilmiştir.

Perwez ve Sohail (2014) Pakistan'ın net elektrik enerjisi tüketiminin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada LEAP modeli doğrultusunda 2011-2030 dönemi için üç farklı senaryo oluşturulmuştur. Çalışma sonucunda ise, senaryoların analiz edilmesi ile farklı enerji seçenekleri sunulmaktadır.

Yetis ve Jamshidi (2014) araştırmalarında Türkiye'nin 2012-2023 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi ile 1992-2011 dönemi için GDP, nüfus ve sanayi üretim endeksi değişkenlerinin resmi verileri kullanılmıştır.

Kaytez ve ark. (2015) çalışmalarında Türkiye'nin elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada EKK-destek vektör makineleri, yapay sinir ağları ve regresyon analizi yöntemleri tercih edilmiş olup nüfus, kurulu kapasite, brüt elektrik üretimi ve toplam abone sayısı değişkenlerinin 1970-2009 dönemi için verileri kullanılmıştır. Çalışma sonucunda ise, EKK-destek vektör makineleri yönteminin daha uygun olduğu görülmüştür.

Mahmutoğlu ve Öztürk (2015) Türkiye'nin 2015-2023 dönemi için brüt elektrik tüketimini tahmin ederek yenilebilir enerjiye dayalı politika önerilerine temel oluşturmak istemiştir. Çalışmada Box-Jenkins modeli doğrultusunda 1970-2011 dönemi için yıllık elektrik tüketim verileri kullanılmıştır. Çalışma sonucunda ise, model tahminleri ile TEİAŞ tahminleri karşılaştırılmıştır.

Sönmez (2015) çalışmasında Konya'nın Seydişehir ilçesi için 2016 yılına dek orta dönem elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Çalışmada ANFIS, YSA ve regresyon analizi yöntemleri tercih edilmiş olup nüfus, nem, sıcaklık, rüzgar ve tüketim değişkenlerine dair veriler kullanılmıştır. Yöntemlere dair sonuçlar karşılaştırıldığında ise ANFIS yönteminin daha uygun olduğu görülmüştür.

Tutun ve ark. (2015) araştırmalarında yapay sinir ağı ve SARIMA yöntemleri ile gelecekteki bağımsız unsurların tahmin edilmesi için yeni bir model önermeyi hedeflemiştir. Buna bağlı şekilde net elektrik tüketim tahmini için LASSO, LADES ve RADES modelleri uygulanmıştır. Araştırma sonucunda ise, önerilmiş olan modelin elektrik tüketiminin tahmini konulu çalışmalara göre çok daha iyi performans sergilediği görülmüştür.

Uygun (2015) çalışmasında Türkiye'nin Nisan 2015-Mart 2016 dönemi için saatlik elektrik talebinin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi doğrultusunda neden-sonuç ilişkisine dayalı bir talep tahmini gerçekleştirilmiş olup geçerli tahminler elde edilmiştir. Sonuçlar, MAPE performans ölçütü ile değerlendirilmiştir.

Yükseltan ve ark. (2015) Türkiye'nin 2012-2014 dönemi için saatlik elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analizde zaman serileri analizi tercih edilmiş olup doğrusal model geliştirilmiştir.

Barak ve Sadegh (2016) çalışmalarında İran'daki yıllık enerji tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada ARIMA-ANFIS hibrit modeli oluşturulmuş olup AdaBoost (Uyarlamalı Arttırma) ile veri çeşitliliğinin artması sağlanmıştır. Çalışma sonucunda ARIMA ve ANFIS yöntemlerinin hibritlenmesiyle oluşturulan modelin ARIMA ve ANFIS modelleri ile kıyaslandığında daha iyi olduğu görülmüştür. AdaBoost (Uyarlamalı Arttırma) kullanılan hibrit modelin ise, MSE oranı daha düşük tahminleri yaptığı görülmüştür.

Birim ve Tümtürk (2016) araştırmalarında Türkiye'nin 2015-2023 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Yapay sinir ağları yöntemi ile Türkiye'nin 1992-2014 dönemi için GSYH, nüfus, ihracat, ithalat, doğalgaz ve istihdam değişkenlerine dair resmi verileri kullanılmıştır. Dört model oluşturulan çalışmada elde edilen sonuçlar ise, TEİAŞ'ın projeksiyonları ile karşılaştırılmış ve yapılan değerlendirme sonucunda TEİAŞ'ın tahminlerinin üç modelin tahminlerinden daha yüksek olduğu görülmüştür.

Chae ve ark. (2016) çalışmalarında bir bina kompleksinin 15 dakikalık periyotlar için kısa dönem elektrik talep tahmininin yapılmasını hedeflemiştir. Çalışmada Bayes algoritmasına dayalı bir yapay sinir ağı modeli kurulmuş olup modelin başarılı sonuçlar verdiği görülmüştür.

Ertuğrul (2016) günlük elektrik yükünün tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analizde 1990-2012 dönemi verileri kullanılmış olup yeni bir RELM yaklaşımı önerilmiştir. Analizin sonucunda ise, popüler makine öğrenimi teknikleri ile karşılaştırma yapılmıştır.

Ervural ve ark. (2016) araştırmalarında İstanbul için konut ile ticari alanlardaki aylık doğalgaz tüketiminin tahmin edilmesini hedeflemiştir. Araştırmada genetik algoritma-ARMA modeli ile ARMA modeli tercih edilmiş olup genetik algoritma-ARMA modelinin daha uygun olduğu görülmüştür.

Gülcü ve Kodaz (2016) çalışmalarında Türkiye'nin 2030 yılına dek elektrik enerjisi talebinin tahmin edilmesini hedeflemiştir. Çalışmada parçacık sürü optimizasyon algoritması tercih edilmiş olup GSYH, nüfus, ihracat ve ithalat değişkenlerinin 2004-2013 tarihindeki verileri kullanılmıştır.

Günay (2016) yıllık brüt elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada yapay sinir ağı yöntemi tercih edilmiş olup kişi başı GSYH, nüfus, ortalama yaz sıcaklığı ve enflasyon oranı gibi değişkenlerin gelecekteki olabilecek değerleri tahmin edilmiştir. Sonrasında ise, bu veriler simüle edilerek yıllık brüt elektrik talebi tahmini yapılmıştır.

Hussain ve ark. (2016) araştırmalarında Pakistan'ın toplam elektrik tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada ARIMA ile Holt-Winter yöntemleri doğrultusunda 1980-2011 dönemi için günlük elektrik tüketim verileri kullanılmıştır. Çalışma sonucunda ise, Holt-Winter yönteminin ARIMA yöntemine göre daha iyi performans gösterdiği görülmüştür.

Karaca ve Karacan (2016) çalışmalarında Türkiye için elektrik tüketimini etkileyen değişkenlerin değerlendirilmesini hedeflemiştir. Çalışmada GSYİH, ortalama yaşam beklentisi ve internet kullanımı değişkenleri seçilmiştir. Çoklu regresyon yöntemi ile hazırlanan program sonucunda analiz yapılmıştır. Çalışmanın sonucunda ise, elektrik tüketimi ile GSYİH değişkeni arasında pozitif yönde oldukça önemli bir ilişkinin olduğu görülmüştür.

Makas ve Karaatlı (2016) Isparta'nın Aksu ilçesindeki bir santralin 2015 yılı için hidroelektrik enerjisi üretiminin tahmin edilmesini hedefleyen bir çalışma yapmıştır. Ağ yapısı açısından ileri yönlü beslemeye sahip YSA yöntemi ile geri yayılım algoritması da kullanılarak Türkiye'nin 2007-2014 dönemi için yağış, nispi nem ve debi değişkenlerinin aylık ortalamalarına dair resmi verileri kullanılmıştır. Çalışma sonucunda ise, santralin 12 aylık hidroelektrik üretimi tahmin edilmiştir.

Özdemir ve ark. (2016) araştırmalarında doğalgaz talebinin tahmin edilmesini hedeflemiştir. Araştırmada GSMH, nüfus ve büyüme oranı değişkenlerinin verileri kullanılmış olup genetik algoritma ile benzetimli tavla algoritmasının hibrit yöntemi tercih edilmiştir. Araştırma sonucunda ise, Türkiye'nin 2010-2030 dönemi için doğalgaz talebinin iki senaryo ile tahmin edildiği görülmüştür.

Yang ve ark. (2016) çalışmalarında Avusturalya'nın New South Wales eyaleti için kısa dönem elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada yarım saatlik elektrik

güç verileri kullanılarak diff-SARIMA, ANFIS, geri yayımlı (BP) sinir ağları ile bu yöntemlerin hibritlenmesiyle oluşturulan yeni bir yöntem tercih edilmiştir. Çalışmanın sonucunda ise, her bir yöntemin sunduğu tahminler karşılaştırılmış ve oluşturulan hibrit modelin daha uygun olduğu görülmüştür.

Başıoğlu ve Bulut (2017) araştırmalarında uzman sistemler ve YSA tabanlı bir hibrit sistem geliştirerek Türkiye'nin günlük elektrik talebinin tahmin edilmesini hedeflemiştir. Araştırmada kullanılan hibrit EPSİM-NN sistemiyle iki farklı yapay sinir ağından elde edilen sonuç birleştirilmiş ve günlük talep tahmini yapılmıştır. Uzman sistemler ile hesaplanan değerlerin hata oranları minimize edilmiştir. Araştırma sonucunda ise, yeni hibrit yöntemin güvenilir tahmin değerleri sunduğu görülmüştür.

Karaaslan ve Gezen (2017) çalışmalarında Türkiye'nin hem sektörel hem de toplam enerji talebinin tahmin edilmesi ile sektörler arasındaki dağılımın belirlenmesi hedeflemiştir. Çalışmada bulanık gri regresyon yöntemi uygulanmıştır.

Karadede ve ark. (2017) doğalgaz talebinin 2015-2030 dönemi için tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada genetik algoritma ile benzetimli tavlama algoritmasından oluşan hibrit bir yöntem tercih edilmiştir. Çalışmanın sonucunda ise, hibrit yöntemin daha uygun olduğu görülmüştür.

Son ve Kim (2017) çalışmalarında Güney Kore'nin konut sektöründeki bir aylık elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada sosyal değişkenler, hava durumu değişkenleri ve aylık elektrik tüketimi değişkenlerinin Ocak 1991-Aralık 2012 dönemi verileri kullanılmıştır. Çalışmada, değişkenlere karar vermek için destek vektör makinesi (DVM) ve parçacık sürü optimizasyonu (PSO) algoritması kullanılarak Kuzey Kore'nin aylık elektrik tüketimini en iyi ifade edebilecek değişkenlere karar verilmiştir. Analiz aşamasında ise, değişkenler ile DVM yöntemi doğrultusunda aylık elektrik talebi tahmin edilmiştir.

Sönmez ve ark. (2017) araştırmalarında Türkiye'nin ulaşım enerjisinin tahmin edilmesini hedeflemiştir. Araştırmada yapay arı kolonisi algoritması tercih edilmiş olup 1970-2013 dönemi veriler kullanılmıştır. Bu araştırma ile Türkiye'nin 2034 yılına dek ulaşım enerjisi

talebi iki senaryo ile tahmin edilmiştir. Modelin lineer formunun, kuadratik ve üstel formuna göre daha iyi sonuç sunduğu görülmüştür.

Yaşar ve Uçkun (2017) Türkiye'nin 2017-2020 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedefleyen bir analiz yapmıştır. Analizde Yapay sinir ağları yönteminin geri yayılım algoritması ile Türkiye'nin 1965-2015 dönemi için GSYH, nüfus, ihracat, ithalat ve GSYH'nin büyüme oranı değişkenine dair resmi verileri kullanılmıştır. Analizde elde edilen sonuçlar ise, resmî kurumların tahmin verileri ile karşılaştırılmış ve yapılan değerlendirme sonucunda resmi kurum tahminlerinin daha yüksek olduğu görülmüştür.

Yükseltan ve ark. (2017) araştırmalarında saatlik talep tahmin yöntemi geliştirmeyi hedeflemiştir. Araştırmada regresyon analizi tercih edilmiş olup saatlik varyasyonları tahmin edebilen bir model geliştirilmiştir.

Aydın ve Toros (2018) çalışmalarında Ocak 2012-Kasım 2016 dönemi için Türkiye'nin kısa dönemli elektrik tüketiminin sıcaklık ile ilişkisini incelemeyi hedeflemiştir. Çalışmada yapay sinir ağları yöntemi tercih edilmiş olup elektrik tüketiminde en çok etkili 12 ilin sıcaklık değerleri tüketim oranlarına göre ağırlıklandırılmıştır. Çalışmanın sonucunda ise, kabul edilebilir hata oranlarına sahip tahminler elde edildiği görülmüştür.

Bilgen Yaşar (2018) Türkiye'nin 1995-2017 dönemindeki elektrik tüketimini modellemiştir. Genetik algoritma ve ANFIS yöntemleri tercih edilmiş olup hipotez testi de uygulanmıştır. Genetik algoritma kapsamında uygulanan lineer ve karesel formlardan lineer form, ANFIS kapsamında uygulanan üçgen ve gauss üyelik fonksiyonlarından üçgen üyelik fonksiyonu daha uygun bulunmuştur. Çalışmanın sonucunda ise, modellerin elektrik tüketim tahmini için kullanılabilir olduğu görülmüştür.

Yüksel Haliloğlu ve Tutu (2018) Türkiye'nin elektrik tüketimini günlük olarak tahmin edebilecek bir model geliştirmeyi hedeflemiştir. Model için eşik sıcaklık değeri ve zaman değişkenleri seçilmiş olup Ocak 2012-Nisan 2018 dönemine ait veriler kullanılmıştır. En Küçük Kareler yönteminin uygulanması ile güvenilir tahmin değerleri elde edilmiştir.

Arjmand ve ark. (2019) çalışmalarında kısa vadeli yük talebi tahmininin veriler üzerinde yapılan ön işlemlerle iyileştirilmesini hedeflemiştir. Çalışmada Kanada'nın Ottawa

eyaletinin günlük yük talebine dair veriler kullanılmış olup NAR, NARX, ANFIS, SVR, ARIMA, ARIMAX ve MLR yöntemleri tercih edilmiştir. Sonrasında ise, Box-Cox, Zscore ve normalleştirme analizleri uygulanarak talep tahminlerinin iyileştiği görülmüştür.

Çiçek ve Lecuna (2019) araştırmalarında Türkiye’deki şehirlerin elektrik tüketimi etkinlik değerlerinin belirlenerek etkin olmayan şehirler için projeler oluşturulmasını hedeflemiştir. Araştırmada veri zarflama analizi ile Türkiye’nin 7 bölgesinin 2018 yılı için elektrik tüketimi etkinliğinin karşılaştırılmış olup mesken, aydınlatma, sanayi, ticarethane ve tüketici sayısı değişkenleri kullanılmıştır. Araştırma sonucunda ise, Akdeniz Bölgesi elektrik tüketiminin daha verimli olduğu görülmüştür.

Ekinci (2019) çalışmasında Türkiye’nin 1970-2015 dönemine ait elektrik enerjisi verileri kullanılarak tahmin yöntemlerinin başarısının analiz edilmesini hedeflemiştir. Çalışmada ANFIS ve YSA yöntemleri tercih edilmiştir. Çalışmanın sonucunda ise, ANFIS yönteminin daha başarılı sonuçlar sunduğu görülmüştür.

Özaydın (2019) Türkiye’nin 2017 yılı elektrik talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada kişi başı GSMH, ihracat, ithalat, kurulu güç, motorlu taşıt, şehir nüfusu ve tüketici fiyat endeksi gibi değişkenlerin 1960-2016 dönemindeki verileri kullanılmıştır. Yöntem olarak yapay sinir ağları tercih edilmiş olup yöntemin güvenilir sonuçlar sunduğu görülmüştür.

Pençe ve ark. (2019) araştırmalarında Türkiye’nin 2017-2023 dönemi için elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Türkiye’nin 1970-2016 dönemi için verileri kullanılmış olup ileri beslemeli yapay sinir ağı modeli tercih edilmiştir. Araştırma sonucunda ise, Türkiye Elektrik İletim A.Ş. tahmin sonuçları ile yakın sonuçlar elde edildiği görülmüştür.

Uzlu (2019) çalışmasında gri kurt optimizasyon algoritması ile eğitilmiş bir yapay sinir ağı modeli aracılığıyla Türkiye’nin enerji tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada GSYİH, nüfus, ihracat ve ithalat değişkenleri kullanılmıştır. Çalışmada tercih edilen yöntem, geri yayılım algoritmasıyla eğitilmiş yapay sinir ağı modeli ile yapay arı kolonisi modeli ile karşılaştırılmıştır. Karşılaştırma sonucunda ise, çalışmada tercih edilen yöntemin daha uygun olduğu görülmüş olup iki farklı senaryo doğrultusunda Türkiye’nin

2023 yılına dek enerji tüketim tahmini yapılmıştır. Sonuçlar, Enerji ve Tabi Kaynaklar Bakanlığı sonuçlarıyla da karşılaştırılmıştır.

Akdi ve ark. (2020) Türkiye'nin günlük elektrik enerjisi tüketiminin talep edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada Türkiye'nin 2012-2016 dönemi için günlük elektrik tüketim verileri kullanılmıştır. Yöntem olarak ise, ARIMA ile harmonik regresyon analizi tercih edilmiştir. Harmonik regresyon analiziyle oluşturulan modelin ARIMA modeline göre daha küçük tahmin hatası varyansı verdiği görülmüştür.

Es (2020) çalışmasında Türkiye'nin toplam enerji talebinin tahmin edilmesini hedeflemiştir. Çalışmada 1995-2018 dönemi için GSYH, nüfus, ithalat, ihracat ve bina yüzölçümü değişkenlerinin verileri kullanılmıştır. Sebep-sonuç ilişkisine dayalı GM (0,N) ve GM (1,N) modelleri ile zaman serisi modellerinden GM(1,1) ve Gri Verhulst modelleri olmak üzere toplamda 4 çeşit gri tahmin modeli üzerinde durulmuş olup GM (1,1) ile zaman serisi ve GM (1,6) ile düşük ve yüksek senaryo bazlı olmak üzere 2025 yılına dek Türkiye'nin toplam enerji talebi tahmin edilmiştir.

Jiang ve ark. (2020) araştırmalarında Çin'de bulunan bir şehrin aylık elektrik tüketiminin tahmin edilmesini hedeflemiştir. Araştırmada şehrin aylık elektrik tüketim verileri kullanılmış olup Meyve Sineği Optimizasyon Algoritması ile Holt-Winters tahmin yönteminden oluşan hibrit bir model önerilmiştir. Önerilen modelin başarı performansı ise farklı senaryolar ile doğrulanmış olup diğer modellere göre daha iyi sonuçlar sunduğu görülmüştür.

Kaytez (2020) Türkiye'nin 2022 yılına dek net elektrik tüketiminin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada ARIMA ve LS-SVM yöntemlerinin hibritlenmesiyle oluşan bir yöntem geliştirilmiştir. Çalışma sonucunda ise, yeni hibrit yöntemin güvenilir sonuçlar verdiği görülmüştür.

Özkan ve ark. (2020) çalışmalarında elektrik tüketim verileri için en ideal tahmin yöntemini bulmayı hedeflemiştir. Çalışmada Ocak 2016- Aralık 2018 dönemi için Türkiye'deki elektrik tüketim verileri ile tahminleme modelleri geliştirilmiş olup EKK Yöntemi ile Fourier Analizi ve Winters yöntemi kullanılmıştır. Modellerde elektrik tüketim değişkenine

için değerler 12-24-36 aylık dönemler şeklinde incelenmiştir. Çalışma sonucunda ise, performans ölçütleri açısından Winters yönteminin daha iyi tahminler sunduğu görülmüştür.

Reşat (2020) araştırmasında bütün endüstrisi için kısa vadeli elektrik tüketiminin tahmin edilmesini hedeflemiştir. Araştırmada bütün endüstrisi üzerine çalışan bir firmanın Ocak 2014-Mart 2019 dönemindeki verileri kullanılmıştır. Bu veriler ile üretim miktarı, çalışma saatleri, güneş enerjisi üretimi ve geçmiş elektrik tüketim verileri değerlendirilerek her biri arasındaki korelasyona bakılmıştır. Araştırma sonucunda geliştirilmiş olan melez tahmin modelinin, yalnızca ARIMA modeli ile yapılan tahminlere göre daha iyi sonuç verdiği görülmüştür.

Erkınay Özdemir (2021) çalışmasında İskenderun'un aylık elektrik enerjisi tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada 2011-2020 dönemi için aylık ortalama enerji tüketimi ile sıcaklık verileri kullanılmıştır. Çok katmanlı ileri beslemeli yapay sinir ağı modeli ile güvenilir tahminler gerçekleştirilmiş olup büyük devlet tesislerinde kullanılabileceği görülmüştür.

Kaur ve ark. (2021) konut sektöründe elektrik enerjisi kullanımına dair analiz yapmıştır. Analizded makine öğrenmesi yöntemleri tercih edilmiş olup en iyi performansın Lasso Regresyonu ile Destek Vektör Regresyonu ile elde edildiği görülmüştür.

Kell ve ark. (2021) araştırmalarında İngiltere için kısa dönem elektrik talebinin tahmin edilmesini hedeflemiştir. Araştırmada 16 çeşit makine öğrenmesi yöntemi tercih edilmiş olup sonuçlar karşılaştırılmıştır.

Nebati ve ark. (2021) çalışmalarında Türkiye'nin 2035 yılına dek elektrik tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada Türkiye'nin nüfus, kişi başı gelir, satılan konut sayısı, beyaz eşya sayısı, işyeri sayısı ve elektrik tüketim değişkenlerinin 1970-2019 dönemindeki verileri kullanılmıştır. Yöntem olarak ise, zaman serisi ve regresyon analizi tercih edilmiştir. Çalışma sonucunda ise, her iki yöntem aracılığıyla elde edilen sonuçlar ile TÜİK üzerinden alınan değerlerin birbirlerine yakın olduğu görülmüştür.

Portabales ve ark. (2021) yapay sinir ağları tabanlı makine öğrenmesi algoritmaları ile elektrik talebinin analiz edilmesini hedefleyen bir analiz çalışması yapmıştır. Çalışmada 50

adet araştırma analiz edilmiştir. Analiz sonucunda ise, yapay sinir ağları tabanlı algoritmaların iyi performans gösterdiği anlaşılmıştır.

Ülkü ve Yalpir (2021) çalışmalarında Türkiye'nin 2030 yılında iller bazındaki elektrik enerjisinin tahmin edilmesini hedeflemiştir. Çalışmada GSYİH, nüfus, ihracat, ithalat, eğitim seviyesi, ortalama hane halkı büyüklüğü ve sanayi gibi değişkenlerin iller bazındaki 2009-2018 dönemi verileri kullanılmıştır. Çoklu regresyon analizi ve yapay sinir ağı yöntemleri uygulanmış olup ortalama %98 başarı sağlanmıştır. Yapay sinir ağı yöntemi tahminlerinin Enerji ve Tabii Kaynaklar Bakanlığı tahminlerine daha yakın olduğu görülmüştür. Ayrıca sonuçlar coğrafi bilgi sistemlerine entegre edilerek haritalar üzerinde de tartışılmıştır.

Avacı ve Aydın (2022) araştırmalarında yük tahmini için yapay zekâ tabanlı tahmin algoritmalarından tekrarlayan sinir ağlarının analiz edilmesini hedeflemiştir. Araştırmada Amerika Birleşik Devletleri'nin Eastern Kentucky eyaletinin enerji tüketim verileri kullanılmıştır. RNN, LSTM ve CNN-LSTM algoritmaları uygulanmış olup en düşük hata oranının CNN-LSTM algoritması ile elde edildiği görülmüştür.

Gezmez (2022) çalışmasında Enerji Piyasası Düzenleme Kurumunun belirlediği tahmin metodolojisine ek olarak makine öğrenmesi yöntemleri ile tahmin yapılmasını hedeflemiştir. Çalışmada doğrusal regresyon ile LSTM yöntemleri ile MATLAB üzerinde uygulama yapılmıştır. Çalışma sonucunda ise, kullanılan yöntemler ile Enerji Piyasası Düzenleme Kurumunun yöntemi karşılaştırılmış olup uygun sonuçlar elde edildiği görülmüştür.

Kaysal ve ark. (2022) araştırmalarında Türkiye için kısa dönem elektrik yük talep tahmininin yapılmasını hedeflemiştir. Araştırmada Türkiye'nin 2019 yılındaki saatlik periyotlarda elde edilen tüketim verileri kullanılmıştır. Yöntem olarak ise yapay sinir ağları, destek vektör regresyonu, Lasso Regresyon ve Ridge Regresyon yöntemleri tercih edilmiştir. İleriye yönelik bir saatlik tahminler gerçekleştirilmiş olup performans ölçütleri ile değerlendirme yapılmıştır. En uygun yöntemin yapay sinir ağları olduğu görülmüştür.

Parreño (2022) çalışmasında Filipinler için 2030 yılına dek elektrik tüketiminin tahmin edilmesini hedeflemiştir. Çalışmada ARIMA yöntemi tercih edilmiş olup en uygun sonucun

ARIMA (0,2,1) modeli ile elde edildiği anlaşılmıştır. Çalışma sonucunda ise, Filipinler'in 2030 yılına 163,639.9 GWh elektrik tüketileceği tahmin edilmiştir.

Pavlicko ve ark. (2022) araştırmalarında Slovakya için elektrik tüketimi tahmini yapılmasını hedeflemiştir. Araştırmada 2000-2020 dönemi için veriler ele alınmıştır. Yöntem olarak ise, yapay sinir ağları, standart gri model, doğrusal olmayan gri Bernoulli modeli ve hibrit model tercih edilmiştir. Araştırma sonucunda ise, modellerin resmi tahminlerden daha iyi sonuçlar elde ettiği görülmüştür.

Sultana ve ark. (2022) çalışmalarında Ontario eyaletinin konut sektörü için saatlik elektrik talebinin tahmin edilmesini hedeflemiştir. Çalışmada 2013-2019 dönemi verileri ele alınmış ve SARIMAX, NARX ve Bayes algoritması tercih edilmiştir. Ayrıca Bayes-SARIMAX ile Bayes-NARX hibrit modeller de denenmiştir. Çalışma sonucunda ise, Bayes-NARX hibrit modelin daha iyi sonuç verdiği görülmüştür.

Babaoğlu ve Haznedar (2023) Türkiye'nin uzun vadeli enerji tüketiminin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analiz çalışmasında Türkiye'nin 1990-2019 dönemi için GSYH, nüfus, ihracat ve ithalat değişkenlerinin verileri kullanılmıştır. Yöntem olarak ise, yapay arı kolonisi algoritması ile balina optimizasyon algoritması tercih edilmiştir. Dört senaryo ile Türkiye'nin 2040 yılına dek enerji tüketimi tahmin edilmiştir. Çalışma sonucunda ise, yapay arı kolonisi algoritmasının balina optimizasyon algoritmasına göre daha iyi tahminler sunduğu görülmüştür.

Deina ve ark. (2023) araştırmalarında ülkelerin elektrik talebini tahmini için çok kriterli bir yaklaşımı sunan model sunmayı hedeflemiştir. Araştırmada Brezilya'nın Paraná eyaletine ait Ocak 2004-Haziran 2019 dönemi verileri kullanılmıştır. Yöntem olarak ise, Holt-Winters, AR, ARIMA, MLP, RBF ve ELM tercih edilmiştir. Arştırmanın sonucunda ise, ELM yönteminin diğer yöntemlere göre daha başarılı olduğu görülmüştür.

Erdemci (2023) Türkiye'nin 2020-2040 yılları arasında elektrik enerjisi talebinin tahmin edilmesini hedefleyen bir analiz çalışması yapmıştır. Analizde 1980-2019 dönemi için GSYH, nüfus, ihracat, ithalat ve elektrik tüketim değişkenlerinin verileri kullanılmıştır. Yöntem olarak ise, yapay sinir ağları, destek vektör regresyonu ile parçacık sürü optimizasyonu tercih edilmiştir. Ayrıca üç çeşit senaryo oluşturulmuş, yöntemlerin sonuçları

karşılaştırılmıştır. Karşılaştırma sonucunda yapay sinir ağları yönteminin daha başarılı performans sergilediği görülmüştür.

Gündüz (2023) araştırmasında Türkiye için elektrik talep tahmini konusunda sıklıkla tercih edilen yöntemlerin denenerek en uygun yöntemin bulunması hedeflemiştir. Araştırmada ARIMA, ANFIS ve yapay sinir ağları yöntemleri denenmiş ve MAPE kriteri doğrultusunda karşılaştırma yapılmıştır. Karşılaştırma sonucunda en uygun yöntemin yapay sinir ağları, yapay sinir ağları kapsamında ise NARX olduğu görülmüştür.

Tarkun (2023) çalışmasında elektrik talep tahmini için uygun yöntemi bulmayı hedeflemiştir. Çalışmada tek değişkenli modeller için brüt elektrik talep miktarı, çok değişkenli modeller için tüketici fiyat endeksi, sanayi üretim endeksi, ülkeye gelen turist sayısı, işsizlik ve brüt elektrik talep miktarı kullanılmıştır. Uygulama dönemi olarak 2007-2020 zaman aralığı ele alınmış olup resmî kurumların 2021 yılı talep miktarıyla tahmin edilen talep miktarı karşılaştırılmıştır. Karşılaştırma sonucunda en küçük hata değerini sunan modelin çok değişkenli yapay sinir ağı olduğu görülmüştür. Ayrıca Temmuz 2022 dönemine dek elektrik talep tahmini yapılmıştır.


4. TALEP TAHMİNİ VE YÖNTEMLERİ

4.1. Talep Tahmini

Talep, tüketicilerin belli bir fiyat seviyesinde olan ürün ya da hizmeti almak için hazır olduğu miktar olarak tanımlanmaktadır. Tahmin ise, en genel ifade ile geçmişe bakılarak geleceğin kestirilmesi olayıdır. Karar verme sürecinin parçası olup yönetimde temel bir işlev olarak yer almaktadır. Talep tahmini, ürün ya da hizmet için gelecekte oluşacak talebin en güvenilir şekilde hesaplanması işlemini ifade etmektedir. Tahmin, çeşitli kurallara göre yapılmakta olup belirli düzeyde hataya sahiptir. Tahmin sürecine dair her aşama büyük bir öneme sahiptir.

Güvenilir talep tahmini için ilk olarak talebin mevcut ile gelecek durumu için planlama yapılmalı, talep üzerinde etkili olan değişkenler belirlenmelidir. Değişkenler tespit edilerek talebi hangi koşul ve oranda etkilediği belirlenerek uygun bir talep tahmin yöntemi seçilmelidir. Değişkenler doğrultusunda model oluşturulmalı, geleceğe dair bilinen veriler modele dahil edilmelidir. Geçerlilik konusunda kontrol yapılmalı ve çözüm uygulanmalıdır. Tahmin yöntemleri ise, kalitatif ve kantitatif olmak üzere iki grupta incelenmekte olup Şekil 4.1’de gösterilmektedir (Akgül,2013).

Kantitatif yöntemler daha çok matematiksel hesaplara dayanırken kalitatif yöntemler kişisel görüşlere dayanmaktadır. Tahmin yöntemleri seçilirken verilerin özelliğinin yanı sıra zaman aralığı, alınması planlanan kararların vadesi ve tolere edilebilecek hata oranı gibi çeşitli unsurlar dikkate alınmaktadır. Klasik yöntemlerin yetmediği durumlarda ise, kantitatif ve kalitatif yöntemler birlikte kullanılmaktadır.



Şekil 4.1. Talep tahmin yöntemleri

Geleceğe yönelik yapılan tahminler gerek özel sektör gerek de kamu kurum ve kuruluşlarındaki karar mekanizmalarının durumlarını ileri bir noktaya taşımaları için vazgeçilmez bir unsurdur. Elektrik enerjisine yönelik talep tahminleri ise, talep üzerinde etkili olan unsurların belirlenerek modele dahil edilmesiyle yapılmaktadır. Güvenilir tahminler ile ülkenin ihtiyaç duyduğu elektrik enerjisinin karşılanması hedeflenmektedir.

4.2. Çalışmada Kullanılan Talep Tahmin Yöntemleri

4.2.1. Regresyon analizi

Regresyon kavramı, ilk olarak Francis Galton tarafından kullanılmış olup Galton'un 19. yüzyılda boyu çok uzun veya çok kısa olan ebeveynlerin çocuklarına dair boy uzunluklarının grup ortalamasına çekilmesi için de kullanılmıştır. Galton'un çalışmalarını yakın bir şekilde takip eden Karl Pearson ise, regresyon konusundaki fikirleri geliştirerek değişkenler arasındaki ilişki miktarının belirlenmesinde faydalı olan korelasyonu geliştirmiştir.

İstatistiksel analizlerde iki ya da daha fazla değişkenin arasında ilişki olup olmadığı, var ise ilişki derecesinin belirlenmesi önemli bir konu olmaktadır. Regresyon analizi, bir bağımlı değişken ile bir veya daha fazla değişkenin arasında olan ilişkinin matematiksel gösterimidir. Değişkenler arasındaki ilişkinin analiz edilmesinde en çok tercih edilen yöntemdir (Karaca ve Karacan, 2016). Bu yöntem ile neden-sonuç ilişkisine sahip olan değişkenler belirlenmekte ve ilişkinin matematiksel gösterimi yapılmaktadır. Regresyon analizinde değişkenlerin bağımlı ve bağımsız olarak iki gruba ayrılması gerekmektedir. Bağımlı değişken, Y harfi ile gösterilmekte olup bağımsız değişkenlerle ifade edilmektedir. Bağımsız değişkenler ise, X harfi ile gösterilmektedir.

Değişkenlerin oluşturduğu fonksiyon, regresyon denklemi olarak adlandırılmaktadır. Regresyon denklemi, bağımsız değişkenlerin değerlerine karşılık olarak bağımlı değişkenin alabileceği değerlerin tahmin edilmesinde kullanılmaktadır. Bağımsız değişkenlerin tahmini ile bağımlı değişken için yapılan planlamalarda hangi değişkenlerin etkili olduğu belirlenmektedir (Çağlar, 2007). Bağımsız değişkenlerin farklı değerleri için bağımlı değişkenin sabit olduğu görülür ise de araştırılacak bir problem olmadığı kanaatine varılmaktadır.

Regresyon modelleri

Regresyon analizi, aralarındaki ilişkinin inceleneceği iki veya ikiden çok değişkenin hangileri olduğuna karar verilmesi ile başlamaktadır. Bağımsız değişkenlerin arasında bulunan ilişkiye göre ise, basit/çoklu doğrusal regresyon analizi ve basit/çoklu doğrusal olmayan regresyon analizi yapılmaktadır.

Regresyon analizi ile regresyon katsayıları tahmininden sonra tahmin güvenirliğinin belirlenmesi amacıyla daha çok korelasyon katsayısı (r) ve determinasyon katsayısı (r^2) kullanılmaktadır. Karar aşamasından önce ilişkiler için saçılım grafiğinin hazırlanması ve değişkenlerin arasındaki korelasyon durumuna bakılması gerekmektedir.

Korelasyon, iki değişken arasında olan ilişkiye dair dereceyi ifade etmekte olup değişkenlerin değişimlerini birlikte ölçmektedir. İlişkiyi denklemin ne kadar tanımlayabildiğini de göstermektedir. İlişki derecesi ne kadar güçlü olursa tahminlerin güvenirliğinin de o kadar artması beklenmektedir (Üreten, 2006).


Basit korelasyon, iki deęişken arasında olan ilişki derecesini katsayı cinsinden ifade etmekte olup bir deęişkenin birden çok deęişkenle berabere deęişimi incelendiğinde çoklu korelasyon katsayısı kullanılmaktadır. Çizelge 4.1’de korelasyon katsayısı deęerlerinin derece olarak yorumlanması yer almaktadır (Özaydın, 2019).

Çizelge 4.1. Korelasyon katsayısı deęerlerinin yorumlanması

Korelasyon Katsayısı Deęerleri	Korelasyon Derecesi
0.90-1.00	Çok yüksek
0.70-0.90	Yüksek
0.40-0.70	Normal
0.20-0.40	Düşük
0.00-0.20	Çok düşük

Korelasyon katsayısı, $-1 \leq r \leq +1$ aralığında olmaktadır. Deęerler 0’a yaklaştıkça düşük, 1’e yaklaştıkça ise yüksek korelasyon ilişkisine işaret etmektedir. r deęeri 0’dan büyükse deęişkenler arasında düz, küçükse ters ilişki vardır. Doğrusal ilişki olmaması halinde ise R deęerinin 0 olduđu görölmektedir. Ayrıca regresyon doğrusu eğimi negatifse korelasyon katsayısı deęeri de negatif olmaktadır (Üreten, 2006). Korelasyon deęeri 0’a yaklaştıkça dağılım yayılmakta, 1’e yaklaştıkça ise dağılım doğrunun etrafında yoğunlaşmaktadır. Şekil 4.2’de saçılım grafikleri ile doğrusal regresyon ile doğrusal olmayan regresyon için örnekler verilmiştir (Ertem, 2020).

Determinasyon katsayısı ise, korelasyon katsayısının karesi olup 0 ile +1 arasında deęer almaktadır. Regresyon modelindeki bağımlı deęişkene ait toplam varyansın yüzdelik olarak kaçının bağımsız deęişkenlerce açıklanabildiğini ifade eder.



Şekil 4.2. Korelasyon değerinin saçılım grafikleri ile gösterimi

Basit doğrusal regresyon analizi

Y ile gösterilen bağımlı değişkenin X ile gösterilen tek bağımsız değişken tarafından etkilenmiş olduğu regresyon modeli, basit doğrusal regresyon modeli olarak tanımlanmaktadır. Değişkenler arasındaki ilişkiyi ifade eden denklem ise şu şekilde gösterilmektedir:

$$y = a + bx + e \quad (4.1)$$

Denklemde yer alan a, doğrusal fonksiyon sabit parametresini göstermekte olup x'in sıfır değerini aldığı durumda regresyon doğrusunun dikey eksenini hangi noktada kestiğini göstermektedir. b ifadesi regresyon katsayısı olup regresyon doğrusuna ait eğimi göstermektedir. Regresyon katsayısı ile bağımsız değişkendeki bir birimlik değişmeye

yüzden birden çok bağımsız değişken için uygun olan çoklu doğrusal regresyon analizi yöntemine ihtiyaç duyulmaktadır.

Çoklu doğrusal regresyon analizinde bağımlı değişken Y şeklinde gösterilirken; bağımsız değişkenler $X_1, X_2, \dots, X_k$ şeklinde gösterilmektedir. Çoklu regresyon denklemi, değişkenler ile şu şekilde gösterilmektedir:

$$Y = \alpha + b_1x_1 + b_2x_2 + \dots + b_kx_k + e \quad (4.2)$$

Çoklu doğrusal regresyon analizinde bağımsız değişkenler dahil edilirken korelasyon ve belirlilik katsayısı değerlerine bakılmakta ve anlamlılık testi yapılmaktadır. İlk olarak korelasyon katsayısı değerleriyle değişkenlerin arasında ilişki olup olmadığına karar verilmektedir. Değer, pozitif veya negatif olması fark etmeksizin 1'e yakın olduğu durumlarda kuvvetli ilişkiye işaret etmektedir. Sonrasında ise, belirlilik katsayısı değerleriyle bağımlı değişkendeki değişimin bağımsız değişkenler tarafından ne kadarının açıklanabileceği anlaşılmakta ve analiz gerçekleştirilmektedir.

Modellerde kullanılan testler

Regresyon modellerinde anlamlılığı ölçme amacıyla F testi ve t testi uygulanmaktadır. F testi, regresyon analizinde bağımsız değişkenlerin bağımlı değişkenin üzerindeki bir etkisi olup olmadığının belirlenmesi amacıyla kullanılmaktadır. Ayrıca bu test ile bağımlı ve bağımsız değişkenler arasındaki doğrusallık da test edilmektedir. Değişkenler arasındaki ilişkinin analiz edilmesi ve anlamlılığının test edilmesi için çeşitli hipotezler oluşturulmaktadır (Tunç, 2018).

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0 \quad (4.3)$$

$$H_1: \beta_1 \neq \beta_2 \neq \dots \neq \beta_k \neq 0 \quad (4.4)$$

H_0 hipotezi, regresyon katsayı değerlerinin sıfır olduğunu, bu doğrultuda ise bağımsız değişkenlerce bağımlı değişkenin açıklanamadığını ve regresyon modelinin istatistiksel olarak anlamlı olmadığını göstermektedir. Bu durumda veri seti kontrol edilip yeni gözlem veya bağımsız değişkenler eklenerek anlamlılık tekrar kontrol edilmektedir. H_1 hipotezi ise,

regresyon katsayıları değerlerinden en az birinin sıfır olmadığını ve bu doğrultuda kurulan regresyon modelinin anlamlı olduğunu göstermektedir (Şahinler, 2000).

t testi, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi ifade eden β parametrelerinin teker teker test edilmesi amacıyla kullanılmaktadır. Ana kütle varyansının bilinmediği ve gözlem sayısının 30'dan küçük ($n < 30$) olduğu durumda tercih edilmektedir. Ana kütle varyansının bilindiği ve gözlem sayısının 30'dan büyük ($n > 30$) durumda ise, Z testi kullanılmaktadır (Tunç, 2018). Katsayı testinin yapılması için hipotez kurulmaktadır.

$$H_0: \beta_j = 0 \quad (4.5)$$

$$H_0: \beta_j \neq 0 \quad (4.6)$$

Hesaplanan istatistik değeri, çizelge değeri ile karşılaştırılıp katsayıların anlamlılığı test edilmektedir. H_0 hipotezinin kabul edildiği durumda β_j katsayısına ait bağımsız değişkenin bağımlı değişkeni açıklamadığı, bu doğrultuda modelden çıkartılması gerektiği görülmektedir (Tunç, 2018).

Analiz uygunluğunun değerlendirilmesi

Regresyon modelinin uygunluğu için çeşitli varsayımların aşağıda yer alan sırayla kontrol edilmesi gerekmektedir (Ertem, 2020).

1. Doğrusallık Kontrolü: Hatalar ile tahmin değerleri arasındaki serpilme diyagramı incelenerek dağılımın doğrusal olup olmadığına bakılmaktadır. İkinci olarak ise, hatalar ile açıklayıcı değişkenler arasındaki serpilme diyagramları incelenip doğrusallığın sağlanmadığı durumda değişkenlerin dönüşümle doğrusal hale getirilmesi veya doğrusal olmayan tahmin yöntemlerinin kullanılması gerekmektedir.
2. Normallik Kontrolü: Hataların güven sınırı içinde olup olmadığına bakılarak normallik varsayımını sağlama durumu değerlendirilmektedir. Güven sınırı içinde ise varsayımı sağlandığı görülür.


3. Sabit Varyans Kontrolü: Hata terimlerinin varyansının sabit olması gerekmektedir. Hatalar ile tahmin değerleri arasındaki serpilme diyagramı incelenerek varsayımın sağlanıp sağlanmadığına bakılmaktadır. İkinci olarak ise, hatalar ile açıklayıcı değişkenler arasındaki serpilme diyagramları incelenip aşağıya ya da yukarıya doğru sistematik eğilim göstermediği görülürse varsayımın sağlandığı anlaşılmaktadır.
4. Bağımsızlık ile Otokorelasyon Kontrolü: Hata terimlerinin arasında otokorelasyon olmamalıdır. Bu kontrol, hatalar ile zaman değişkeni arasındaki serpilme diyagramı incelenerek yapılmaktadır.
5. Çoklu Doğrusal Bağlantı Kontrolü: Bağımsız değişkenler için VIF değerleri hesaplanarak kontrol edilmektedir. VIF değerinin 10'dan büyük olduğu durumda çoklu doğrusal bağlantıdan söz edilmektedir. Çoklu doğrusal bağlantı sorunu, ana kütle yapısı, örnek yapısı veya sapan birimlerden kaynaklı olabilmektedir.

4.2.2. Yapay sinir ağları

Yapay sinir ağlarının tanımı

Beynin öğrenme kabiliyetinin örnek alındığı yapay sinir ağları, nöronlar ile insanın öğrenme ve idrak etme sürecinin matematiksel şekilde modellenmesi olarak tanımlanabilir (Fausett, 1994). Yapay sinir ağları, insan beyinde bulunan nöronlar ile bu nöronların kendi aralarında oluşturduğu bağlantılar doğrultusunda çıktı değeri sunma yapısını modellemekte olup bilgisayarlar veya elektrik devreler ile yazılım şeklinde gerçekleştirilebilen yapay bir sistem olarak da tanımlanabilir (Akkurt, 2005).

En makul tanımlama, öğrenme ve uyumunun yanı sıra verilerin sınıflandırılması, genelleme yapılması veya organize gibi yeteneklere sahip paralel bir işleme temeline inşa edilen bir hesaplama modeli şeklinde olabilir (Akkurt, 2005). Şekil 4.4'te bir nöron ile yapay formu gösterilmektedir.



Şekil 4.4. Nöron ve yapay modeli

Yapay sinir ağlarının tarihsel gelişimi

Tarih boyunca insanlar tarafından beynin çalışma sistemine ilgi duyulmuş, bu konuda çeşitli araştırmalar yapılmıştır. YSA ise, beynin çalışma mekanizmasından esinlenilerek ortaya konulmuş ve karmaşık problemlerin çözülmesinde önemli bir rol oynamıştır.

Yapay sinir ağları konusunda yapılan çalışmalar kronolojik şekilde aşağıda sıralanmıştır (Adıyaman, 2007; Özaydın, 2019).

İnsan beyninin fonksiyonlarını konu alan ilk eser William James tarafından 1890 yılında yayımlanmış olup yapay sinir ağları konusunda ise ilk olarak Helmholtz, Mach ve Pavlov tarafından 19. yüzyılın sonlarına doğru çalışma yapılmıştır.

1948 yılında Wiener tarafından Cybertnetics kitabında yapay sinirlerin çalışma özelliklerinden bahsedilmiştir.

1949 yılında Hebb tarafından Organization of Behavior adlı kitapta sinir ağları için temel olan Hebb Kuralı üzerinde durulmuştur. İnsan beyninin öğrenme sisteminden hücresel düzeyde bahsetmiştir.

1954 yılında Gabor, dik iniş algoritması ile gözlenmiş ve önceki örneklerden üretilmiş olan sinyaller arasındaki hata karelerinin ortalamalarını minimum seviyeye getirebilecek ağırlıkların belirlenmesi konusunda çalışma yapmıştır.

1958 yılında Rosenblatt, McCulloch ve Pitts, perceptron isimli tek katmanlı yapay sinir ağı geliştirilmiş olup bu alanda önemli bir dönüm noktası sayılmaktadır.

1960 yılında Widrow ve Hoff tarafından hata karelerinin ortalamalarını minimum seviyeye getirebilecek bir ADALINE yani Adaptif Linear Neuron modeli geliştirilmiştir. Bu model, yapay sinir ağlarının çeşitli mühendislik alanlarında kullanılmaya başlaması için temel olmuştur.

1962 yılında Rosenblatt tarafından çok katmanlı olan yapay sinir ağlarının eğitilmesi için geri yayılıma sahip bir plan ortaya atılmış olup başarısızlıkla sonuçlanmıştır.

1967 yılında Amari, çok katmanlı yapay sinir ağlarının ağırlıkları için öğrenme konusunda kural belirlerken matematiksel bir çözüme ulaşmış ancak bu çalışmanın değeri uzun zaman anlaşılamamıştır.

1969 yılında Minsky ve Papert, “Perceptrons” adında bir kitap yayınlanmış olup bu kitapta tek katmana sahip algılayıcıların karmaşık olmayan birçok problemi bile çözemediği anlatılmıştır. Ayrıca bunu ispatlamak için XOR problemi üzerinde durulmuş ve çözülemediği kanıtlanmıştır. Bu kitap nedeniyle YSA konusuna olan alaka azalmış, bu alandaki çalışmacılar başka alanlara yönelmiştir.

1970’li yıllarda yapay sinir ağlarına olan ilginin azaldığı ve Amerika’da bulunan DARPA kuruluşunun desteğini çektiği görülmüştür. Ancak araştırmalarına devam eden sınırlı sayıda çalışmacının uğraşları sonucunda ise XOR probleminin çözülmesi ile tekrardan yapay sinir ağlarına olan ilgi artmıştır.

1976 yılında Grossberg tarafından ART yani Adaptif Rezonans Teorist isimli karışık bir yapay sinir ağı modeli geliştirmiştir.

1980’li yıllarda yapay sinir ağıları konusunda birçok çalışma yapılmış olup gelişmesine ivme kazandırılmıştır. Bu süreç içerisinde yapılmış olan çalışmalar ile YSA yönteminin geliştirilebilirlik özelliğinin bulunduğu, bilgisayar üzerinde yapılabilecek programlamalar ile zor problemlere dahi çözüm bulunabileceği anlaşılmıştır. (Hopfield, 1982).

1982 yılında Hopfield tarafından çeşitli teknik konulardaki problemlerin çözülmesi için doğrusal olmayan Hopfield ağıları ve eğiticiyiz öğrenen SOM adı verilen Self Organizing Maps ağı geliştirilmiştir.

1986 yılında McClelland ve Rumelhart, “Paralel Distributed Processing” isimli çalışmasında karmaşık ağılar için geri yayılım algoritmasını geliştirmiştir. Bu sayede XOR probleminin çözülebileceği görülmüştür.

1987 yılında yapay sinir ağıları konulu ilk sempozyum düzenlenmiştir.

1988 yılında Broomhead ve Lowe, radyal tabanlı fonksiyonlar (Radial Basis Functions) konusunda çalışmış ve çeşitli geliştirmeler yapmıştır.

1990 yılında Specht, Probabilistic Neural Network olarak da ifade edilen olasılık tabanlı YSA modeli geliştirmiştir.

1991 yılında Specht, Generalized Regression Neural Network olarak da ifade edilen geliştirilmiş regresyon sinir ağını geliştirmiştir.


1995 yılında yapay sinir ağıları için geçiş süreci olarak sayılan gelişme ile yankı algoritmaları üzerinde çalışılan bir düşünce okulunun temelleri atılmıştır.

İlerleyen yıllarda YSA üzerinde çok sayıda uygulama ve çalışma gerçekleştirilmiştir. Özellikle de YSA’nın eğitilmesi hususu üzerinde durulmuştur. Gelişen teknoloji ile bilgisayarların yeteneklerinin artması da yapay sinir ağılarının gelişimine katkıda bulunmuştur.

Yapay sinir ağılarına olan ilginin artması ile bu alandaki araştırmalara verilen destek artmıştır. Birçok enstitü kurulmuş ve birçok araştırmacı bu alana yönelmiştir. Günümüzde

ise, yapay sinir ağıları konusunda sürekli olarak yeni çalışmalar yapılmakta ve karmaşık problemlerin çözümüne dair çeşitli uygulamalar geliştirilmektedir.

Yapay sinir ağıları için önemli dönüm noktaları, Şekil 4.5'te zaman çizelgesi üzerinde gösterilmektedir (Bayır, 2006).




Şekil 4.5. YSA'nın tarih boyunca gelişimi

Biyolojik sinir sistemi

Sinir sistemi ifadesi, merkezden bilgiyi sürekli bir şekilde alıp, sonrasında yorumlayan ve makul bir karar ortaya koyan insan beyninin olduğu üç katmanlı bir sistemdir. (Haykin, 1999). Katmanlar, dışarıdan alınan sinyallerin elektriksel forma dönüştürülerek insan beynine gönderilmesinden sorumlu alıcı olan sinirler ile elektriksel formdaki sinyallerin uygun çıktılara dönüştürülmesinden sorumlu tepki sinirleri arasında daimî şekilde besleme yaparak makul tepkiler üreten merkezi sinir sistemleridir. Şekil 4.6'da bir sinir sistemine dair çalışma mekanizması, diyagram ile gösterilmektedir (Akgül, 2013).


Her sinir hücresinin bir diğeriyle bağlantı kurmasını sağlayan dentrit ve akson isimli uzantılar bulunmaktadır. Sinir hücrelerinin bu bağlantı noktaları ise, sinaps olarak adlandırılır. Sinaps, bir diğer sinir hücresinin aksonundan aldığı elektrik akımının dentrit uzantısına aktarılmasını sağlamaktadır.



Şekil 4.6. Bir sinir sistemine dair çalışma mekanizması


Dentrit uzantısı, aldığı elektrik akımını hücrenin gövdesine (soma) iletmektedir. Soma ise, hücrenin yaşamasını sağlamakta olup tüm dentritlerden alınan elektrik sinyallerini toplamaktadır. Hücrenin eşik değerinin aşılması halinde akson uzantısında elektrik akımı olmakta ve diğer bir hücrenin dentrit uzantısına sinaps isimli bağlantı noktaları üzerinden aktarılmaktadır.

Miyelin kılıfın üzerinde yer alan ve girişlerin periyodik şekilde yeniden üretilmesini sağlayan kısım ise, ranvier boğumu olarak adlandırılmaktadır. Şekil 4.7’de tüm uzantılarını içerir şekilde biyolojik anlamda bir hücre gösterilmektedir (Freeman ve Skapura, 1991).



Şekil 4.7. Biyolojik formda bir sinir hücresi

Beynin çalışma mekanizmasının işleyişi, yapı taşları niteliğindeki biyolojik sinir hücreleri ile sürmektedir. Ağlar, insanın duyu organları ile topladığı bilgiler ile geliştirilmiş olan hem algılama hem de anlama sistemlerini harekete geçirecek olayların arasındaki bağlantının öğrenilmesini sağlamaktadır. Duyuların beyindeki gösterimleri Şekil 4.8'deki gibidir (Öztemel, 2006).



Şekil 4.8. İnsan beyinde yer alan duyu bölgeleri


Bir insanda yaklaşık olarak 10^{11} adet sinir hücresi bulunması, sinaps uzantısının sonsuz sayıda olmasını sağlamaktadır. Bu sinir hücrelerinin iletim hızları değerlendirilecek olursa bilgisayarların iletim hızlarından daha yavaş olduğu anlaşılmaktadır. Buna rağmen sinaps uzantılarının oluşturduğu bağlantılar, eşzamanlı olarak çok sayıda karar verilmesini sağlamakta olup karmaşık yapısı henüz tam olarak anlaşılamayan insan beyninin duysal verileri çok hızlı bir şekilde değerlendirmesini de sağlar. Çizelge 4.2'de insan beyni ile bilgisayarların değerlerinin karşılaştırılması görülmektedir (Bayır, 2006).

Çizelge 4.2. Beyin ile bilgisayar sisteminin sayısal olarak karşılaştırması

Özellik	Beyin	Bilgisayar Sistemi
Hız (İşlemci)	10^{-3} ms	10^{-9} ms
Nöron	10^{11} & 10^{33}	10^9
Ağırlık	1,5 kilogram	Çok sayıda kilogram
Tüketim (Enerji)	10^{-16} J	10^{-6} J
Hesap	100 (Adım)	Çok sayıda adım

Yapay sinir ağıları sistemi

Ağlar, beyinde yer alan çok sayıdaki sinir hücresinin koleksiyonu olup birbirleriyle bağlanarak işlevlerini yerine getirmektedir. Yapay sinir ağıları ise, birbiriyle bağlantılı olan birçok yapay sinir hücresinden oluşmaktadır. Şekil 4.9’da hem biyolojik formda hem de yapay formda sinir hücresi gösterilmektedir (Ok, 2010).




Şekil 4.9. (a) Biyolojik form ve (b) yapay form

Yapay formdaki hücreler, nöronların basit birer modeli olduğundan biyolojik sinir sistemi ile yapay sinir ağıları arasında bazı benzerlikler göze çarpmaktadır. Çizelge 4.3’te göze çarpan bu benzerlikler gösterilmektedir (Sağıroğlu ve ark., 2003).

Çizelge 4.3. Biyolojik-yapay formdaki sistemlerin benzerlikleri

Biyolojik Form	Yapay Form
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron	İşlem Elemanı
Dendrit	Toplama Fonk.
Soma	Aktivasyon Fonk.
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

Biyolojik formda ağlar, yapay formdaki ağlara dayanak olup beyinde yapay formu ifade eden kısımlar Şekil 4.10’daki gibidir (Öztemel, 2006).



Şekil 4.10. Biyolojik formdaki hücelere denk gelen yapay formdaki noktalar

Yapay sinir hücresi

Yapay sinir ağları, insan beyninin çalışma sisteminin taklit edilmesi sonucu geliştirilmiştir. Yapay sinir hücresi ise, insan sinir hücresinin çalışma prensibine benzer çalışmaktadır. Sinir ağlarını oluşturan nöronlar dışarıdan aldığı birçok girdi sinyalini aynı zamanda toplayabilmektedir. Ancak girdi sinyali, transfer fonksiyonu, ağırlıklara verilen değerler ve eşik gibi faktörlere bağlı gelişerek sadece bir adet çıktı sinyali vermektedir (Hertz, Krogh ve Palmer, 1991).

Yapay formdaki bir sinir hücresi, aşağıdaki beş elemandan oluşmaktadır. Bu elemanlar:

- ✓ Girdi (Input)
- ✓ Ağırlık (Weight)
- ✓ Toplama Fonksiyonu
- ✓ Aktivasyon Fonksiyonu
- ✓ Çıktı (Output)

Girdiler

YSA sisteminin girdileri, nöronlara dışarıdan gelen bilgilerden oluşmaktadır. Bunlar, dışarıdan direkt gelebileceği gibi başka bir sinir hücresinden de gelebilmektedir. Dış ortamdan gelen bilgiler, ağı eğitilmesi için kullanılan örnek bilgilerdir. Yapay sinir ağı sisteminin bağımsız değişkenleri de bağımsız değişkenleri olarak adlandırılabilir.

Ağırlıklar

Bir yapay sinir ağı sisteminde ağırlıklar, yapay sinir hücresine giren bilgilerin hücre üzerinde hangi ağırlık ve oranda etkisinin olacağını belirten katsayılardır. Girdi değişkenleri, bağlantıların ağırlıkları aracılığıyla nöronlara giriş yapmaktadır. Ağırlıklar ise, girdi değerlerinin katsayılarını ifade etmektedir. YSA içerisinde girdi değişkenlerinin nöronlar arasındaki aktarımını sağlayan bağlantılar değişik ağırlık değerlerine sahiptir. Bu sayede her bir ağırlık, her işlemcinin girdilerini etkilemiş olur. Problemlerin çözümü için oldukça büyük önem arz eden ağırlık değerleri, sabit ya da değişken olabilmektedir (Baş, 2006).

Toplama fonksiyonu

Bir yapay sinir ağı sistemin içerisinde bu fonksiyon, nörona dış ortamdan gelen girdiyi net şekilde hesaplamakta olup n adet girişin kendi ağırlıklarıyla çarpımının toplamı şu şekilde formüle edilmektedir;

$$U = \sum_{i=1}^n x_i w_i \quad (4.7)$$

Toplama fonksiyonu, ağ yapısına göre şekillenmekte olup maksimum veya minimum olabilirken; çarpım şeklinde de ifade edilebilmektedir. Problemlerde en makul fonksiyonun seçimine dair bir kural yoktur. Bu seçim, deneme yanılma yöntemi ile yapılmaktadır. Bunun yanı sıra ağda yer alan tüm işlemciler aynı fonksiyona tabi olmak zorunda da değildir. Bazı durumlarda farklı fonksiyonlar da kullanılabilir. Bu husus, araştırmacının seçimine bağlı olarak gelişir. Çizelge 4.4'te toplama fonksiyonu örnekleri gösterilmektedir (Öztemel, 2006).

Çizelge 4.4. Toplama fonksiyonuna dair örnekler

İşlem	Yorum
Çarpım Girdi (Net) = $\prod_i^n x_i w_i$	İlk olarak, her bir girdi değeri ile ağırlığı, sonrasında da bu değerler birbirleri ile çarpılmaktadır.
Max Girdi (Net) = $\max (x_i w_i) , i= 1, 2, \dots, n$	Girdiler, kendi ağırlıkları ile çarpılır. Bunların arasında yer alan değerlerden en büyüğü ise, girdinin net değeri olur.
Min Girdi (Net) = $\min (x_i w_i) , i= 1, 2, \dots, n$	Her bir girdi değeri kendi ağırlığıyla çarpılır. Bunların arasında yer alan değerlerden en küçüğü ise, girdinin net değeri olarak seçilir.
Çoğunluk Net Girdi = $\sum_{i=1}^n \text{sgn}(x_i w_i)$	Girdiler, kendi ağırlıkları ile çarpılır. Sonrasında ise, bu değerlerden hem pozitif hem de pozitif olmayanların sayısı hesaplanır. Bunlar arasında yer alan değerlerden en büyüğü, girdinin net değeri olarak seçilir.
Kümülatif Toplam Girdi (Net) = $\text{Net (eski)} + \sum_{i=1}^n x_i w_i$	Nörona alınan bilgilerin ağırlıklı şekilde toplanması, sonrasında da bu değer ile daha önceki bilgilerin toplanması gerekmektedir.

Aktivasyon (transfer) fonksiyonu

Bir yapay sinir ağı sisteminde aktivasyon (transfer) fonksiyonu, nöronların davranışının belirlenmesinde önemli bir rol oynamaktadır. Bu fonksiyon ile toplama fonksiyonundan gelen girdi işlenerek ağın sonraki adımlarında kullanılacak olan çıktı üretilmektedir.

Bu fonksiyon, toplama fonksiyonu ile nörona gönderilen girdinin dönüştürülmesi ile istenen değer aralığında sınırlandırmasını sağlamaktadır. Bir kısım kaynaklarda eşik ya da sıkıştırma

olarak da isimlendirilmektedir. Değerler, fonksiyonun çeşidine göre $[0,1]$ ya da $[-1,1]$ aralığında yer alabilmektedir (Hamzaçebi, 2011).


Fonksiyon seçimi, ağın hangi durumlar için eğitileceği hususuna bağlı olup en yaygın şekilde kullanılan çeşitleri ise, hiperbolik tanjant ile sigmoid olmaktadır (Baş, 2006). Yapay sinir hücrelerinde sıkça kullanılan transfer fonksiyonları aşağıda gösterilmektedir.

Doğrusal (özdeşlik) aktivasyon fonksiyonu

Doğrusal aktivasyon fonksiyonu, yapay sinir hücresine gelen giriş değerlerini aldığı şekilde çıkış kısmına iletmektedir. Doğrusal olan problemlerde çözüme ulaşmak için tercih edilen bu fonksiyon aşağıdaki gibi formüle edilmektedir.

$$U = \sum_{i=1}^n x_i w_i + \theta \quad \text{ya da} \quad U = \sum_{i=1}^n x_i w_i - \theta \quad (4.8)$$

Doğrusal fonksiyon, Şekil 4.11’de grafiksel olarak gösterilmektedir (Yavuz, 2012).




Şekil 4.11. Doğrusal fonksiyon

Parçalı doğrusal aktivasyon fonksiyonu

Bu fonksiyon, küçük potansiyeller için toplayıcı gibi çalışmakta olup büyük potansiyeller için de nöronun doyum noktasına ulaşmasıyla çıktı değerini 1 (bir) olarak vermektedir. Yüksek getiriler için $\alpha \rightarrow \infty$ olduğunda bu fonksiyonun basamak fonksiyonuymuşçasına davrandığı görülür. Bu fonksiyonun denklemi aşağıda yer almakta, fonksiyon grafiği ise Şekil 4.12’de gösterilmektedir (Yavuz, 2012).

$$y = F(U) = \begin{cases} 0 & U \leq -\frac{1}{2\alpha} \\ \alpha U + \frac{1}{2} & |U| < \frac{1}{2\alpha} \\ 1 & U \geq \frac{1}{2\alpha} \end{cases} \quad (4.9)$$




Şekil 4.12. Parçalı doğrusal aktivasyon fonksiyonu

Basamak (step) aktivasyon fonksiyonu

Basamak aktivasyon fonksiyonunda yapay sinir hücresine iletilen giriş değeri belirlenmiş olan eşik seviyesinin alt veya üstünde ise, duruma bakılarak çıktı değerinin ya 0 ya da 1 olduğu görülmektedir.

$$g(x) = \begin{cases} b & x \geq c \\ a & x < c \end{cases} \quad (4.10)$$

Basamak aktivasyon fonksiyonunun grafiği ise, Şekil 4.13'te gösterilmektedir (Es, 2013).




Şekil 4.13. Basamak aktivasyon fonksiyonu

Basamak aktivasyon fonksiyonları kendi içerisinde tek kutuplu ve çok kutuplu olmak üzere ikiye ayrılmaktadır.

Tek kutuplu (unipolar) basamak aktivasyon fonksiyonu

Basamak aktivasyon fonksiyonlarının bir çeşidi olan tek kutuplu basamak aktivasyon fonksiyonunun denklemi aşağıda yer almakta, fonksiyon grafiği ise Şekil 4.14'te gösterilmektedir (Yavuz, 2012).

$$y = F(U) = \begin{cases} 1 & U \geq 0 \\ 0 & U < 0 \end{cases} \quad (4.11)$$




Şekil 4.14. Basamak aktivasyonu fonksiyonu (tek kutuplu)

Çok kutuplu (bipolar) basamak aktivasyon fonksiyonu

Diğer bir çeşidi ifade eden bu fonksiyonun denklemi aşağıda yer almakta, fonksiyon grafiği ise Şekil 4.15'te gösterilmektedir (Yavuz, 2012).

$$y = F(U) = \begin{cases} +1 & U \geq 0 \\ -1 & U < 0 \end{cases} \quad (4.12)$$




Şekil 4.15. Basamak aktivasyon fonksiyonu (çok kutuplu)

Sigmoid fonksiyonu

Türevi alınabilir olan bu fonksiyon, en sık kullanılan aktivasyon fonksiyonudur. Sürekli artış göstermekte olup her net girdi değeri için yeni bir değer üretmektedir. Bu fonksiyonlar içerisinde en çok tercih edileni ise, 0.0 ile 1.0 aralığında sonuç çıkarabilen lojistik fonksiyonu olmaktadır (Şahin, 2002; Hart, 1992).

Genel anlamda ise, sigmoid aktivasyon fonksiyonunda çıktı değeri 0 ile 1 arasında olmaktadır. Fonksiyonun denklemi ve grafiği ise, aşağıda gösterilmektedir. Denklemden yer alan β parametresi, genelde 1 olarak alınmakta olup fonksiyonun eğiminin kontrolünü sağlamaktadır. Şekil 4.16'da sigmoid aktivasyon fonksiyonu gösterilmektedir (Yavuz, 2012).

$$y = F(U) = \frac{1}{1+e^{-U}} = \frac{1}{2} [\tanh(U/2) + 1] \quad (4.13)$$




Şekil 4.16. Sigmoid aktivasyon fonksiyonu

Hiperbolik tanjant fonksiyonu

Çift kutuplu fonksiyon olarak da bilinen bu fonksiyon, girdinin net değerini tanjant fonksiyonu ile dönüştürmektedir. Hiperbolik tanjant fonksiyonunda çıktı değeri -1 ile 1 arasında olmaktadır. Fonksiyonun denklemi aşağıda yer almakta, fonksiyon grafiği ise Şekil 4.17’de gösterilmektedir (Yavuz, 2012).

$$y = \tanh(\beta U) = \frac{1-e^{-2U}}{1+e^{-2U}} \quad (4.14)$$




Şekil 4.17. Hiperbolik tanjant aktivasyon fonksiyonu

Sinüs fonksiyonu

Bu fonksiyon, öğrenilecek durumların fonksiyona göre dağılım gösterdiği durumda kullanılmaktadır. Fonksiyonun denklemi aşağıda yer almakta, fonksiyon grafiği ise Şekil 4.18’de gösterilmektedir (Yavuz, 2012).

$$y = F(U) = \sin U \quad (4.15)$$



Şekil 4.18. Sinüs aktivasyon fonksiyonu

Literatürde görülebilecek aktivasyon fonksiyonları kullanım alanları ve sıklığıyla ilgili yorumlar Çizelge 4.5’te, bu fonksiyonlara ait formüller de Çizelge 4.6’da gösterilmektedir (Akkurt, 2005).

Çizelge 4.5. Aktivasyon fonksiyon çeşitleri

Fonksiyon	Formül	Açıklama
Sigmoid	$f(s_j) = 1/(1 + e^{-s_j/T})$	Genellikle bu fonksiyonun kullanımının fazla olduğu görülür. Türev, direkt olarak bu fonksiyondan üretilir.
Hiperbolik Tanjant	$f(s_j) = \tanh(s_j/T)$	Formülde yer alan T ifadesi, sıcaklığı belirtmektedir.
Ters Tanjant	$f(s_j) = 2/\pi \tan^{-1}(s_j/T)$	

Çizelge 4.5. (devam) Aktivasyon fonksiyon çeşitleri

Eşik	$f(s_j) = \begin{cases} +1 & s_j > 0 \\ -1 & s_j < 0 \end{cases}$	
Gauss Radyal Temel	$f(s_j) = \exp[-(s_j - m)^2 / \sigma^2]$	Radyal temele sahip ağlarda tercih edilmektedir.
Doğrusal	$f(s_j) = as_j + b$	

Çizelge 4.6. Aktivasyon fonksiyonları türev gösterimi

Fonksiyon	Formül	Türev
Sigmoid	$f(s_j) = 1 / (1 + e^{-s_j/T})$	$f(s_j) \cdot [1 - f(s_j)] / T$
Hiperbolik Tanjant	$f(s_j) = \tanh(s_j / T)$	$(1 - [f(s_j)]^2) / T$
Ters Tanjant	$f(s_j) = 2/\pi \tan^{-1}(s_j/T)$	$(2/\pi T) / (1 + [s_j/T]^2)$
Eşik	$f(s_j) = \begin{cases} +1 & s_j > 0 \\ -1 & s_j < 0 \end{cases}$	s_j değeri 0 olduğunda türev alınamaz.
Gauss Radyal Temel	$f(s_j) = \exp[-(s_j - m)^2 / \sigma^2]$	$-2(s_j - m) \cdot f(s_j) / \sigma^2$
Doğrusal	$f(s_j) = as_j + b$	a

Çıktılar

Bir yapay sinir ağındaki çıktı değeri, yani $y = F(U)$, aktivasyon fonksiyonu tarafından belirlenmektedir. Bu değer, başka bir hücreye ya da sisteme iletilebilmektedir. Ağıdaki bir işlemci, birden çok sayıda girdiye sahip olabilirken sadece bir adet çıktı verebilmektedir.

Düğümün her birinin çıktı değeri, aktivasyon fonksiyonuna dair sonuç ile birbirine eşit olur. Ancak farklı ağlarda birbirine komşu olan düğümlerde yarışma amaçlı fonksiyonlar tekrar seçilebilir. Sonuç olarak ise, bu düğümlerin girdi değerleri ile öğrenme sürecine dahil olacak düğümlerin seçilmesini fayda sağlar (Öztemel, 2006; Elmas, 2003).

Bir ağ, beş elemanın yanı sıra ölçekleme ve sınırlama olarak adlandırılan bir elemana daha ihtiyaç duyabilmektedir. Bu eleman, etkinlik işlevinin sonuçları ile ilgilenmektedir. Ölçeklendirme işlevi doğrultusunda bir ölçek ögesi ile aktivasyon değerinin çarpımı bulunurken; sınırlandırma işlevi doğrultusunda ölçeklenmiş olan sonuçların en az-en çok sınırlarının aşılmasına engel olunur.

Yapay sinir ağı yapısı


Birden fazla nöronun toplanarak bağlantı kurması ile yapay sinir ağı meydana gelmektedir. Bu nöronların bir araya gelmesi ise, rastgele olmamaktadır. Nöronlar, her bir katmanda paralel olarak toplanıp üç ya da üçten fazla katmanı oluşturmaktadır. Tüm bu katmanlar ise, ağın bütünü oluşturur.

Girdi katmanı, bilgilerin dış ortamdan alınarak gizli katmana iletilmesini sağlamaktadır. Bir modelde çok sayıda olabilecek gizli katman ise, ağıdaki diğer hücrelerle bağlantıyı sağlamaktadır. Bu katmanda bilgiler işlenerek çıktı katmanına iletilmektedir. Çıktı katmanında ise, işlenmiş şekilde gelen bilgiler dış ortama iletilmektedir. Katman yapısının daha iyi anlaşılabilmesi için çok sayıda katmana sahip bir ağ Şekil 4.19’da gösterilmektedir (Akkurt, 2005).

Katmanlar

Ağ yapısı son derece basit olan bir yapay sinir ağı sisteminde, nöronların bazıları giriş değerlerini bazıları ise çıktı değerlerini aktarmaktadır. Diğer katmanlar ise, dış dünya yerine yapay sinir ağı içerisindeki diğer hücreler ile bağlantılı olduğundan gizli katman olarak adlandırılmaktadır. Sistemi oluşturan bu katmanlar üç başlık altında sınıflandırılmaktadır:

- ✓ Giriş katmanı
- ✓ Gizli katman
- ✓ Çıktı katmanı



Şekil 4.19. Çok katmanlı yapay sinir ağlarının genel görünümü

Girdi katmanı (input layer)

Girdi katmanında, ağa sunulmak üzere dış ortamdan giriş bilgeleri alınmakta ve herhangi bir işleme uğramaksızın gizli katmana iletilmektedir. Bu katman, girdi değerleri için tampon görevi görmektedir. Girdi değerleri ise, çalışılacak probleme ait başlangıç verilerinin yalnızca sayısal ifadeleri olmalıdır. Girdi katmanında bulunan nöron sayısı, üzerinde çalışılan problemdeki girdi değişkeni ile eşit değerde olup girdi değişkenleriyle alakalı değer içermektedir (Akkurt, 2005).

Gizli katman (hidden layer)

Gizli katman, bir yapay sinir ağı modelinin işleme katmanı olarak bilinmektedir. İsminin gizli katman olmasının sebebi ise, kullanıcı tarafından görünür olmamasıdır. Girdi ve çıktı katmanları arasında yer almakta olup girdi değerlerinin üzerinde çalışılan probleme uygun olan bir fonksiyon ile işlendiği bölümdür. İşlenen bilgiler doğrultusunda elde edilen sonuç ise, gizli katman aracılığı ile çıktı katmanına iletilmektedir.

Bir ağıdaki gizli katman sayısının belirlenebilmesi için genel bir kural bulunmamaktadır. Bu durum, kullanıcı tarafından üzerinde çalışılan probleme uygun olarak belirlenebilmektedir. Kullanıcı ise, en iyi çıktı değerini verebilecek sayıda gizli katmanı modele dahil etmelidir.


Aksi durumda ağıdaki gizli katman sayısının artması ile genelleşme problemi ortaya çıkmaktadır.

Gizli katman sayısının belirlenmesinde olduğu gibi gizli katmanda bulunan yapay sinir hücreleri sayısının belirlenmesinde de genel bir kural bulunmamaktadır. Yapay sinir hücre sayısı az olduğunda hassasiyet azalmakta, çok olduğunda ise değişen durumlara karşı uyum sağlama konusunda zorluk çekilmektedir. Bu nedenle gizli katmanda bulunan yapay sinir hücre sayısının en uygun şekilde seçilmesi gerekir.

Çıktı katmanı (output layer)

Çıktı katmanı, giriş katmanında dış ortamdan alınan ve gizli katmanda uygun fonksiyonla işlenen verilerin çıktı olarak sunulduğu bir katmandır. Bu katmanda elde edilen ve dış dünyaya iletilen çıktı değeri, üzerinde çalışılan problemin sonucu olmaktadır.

Katmandaki yapay sinir hücresi sayısı, yapay sinir ağından beklenen çıktı sayısı ile eşittir. Bir yapay sinir ağının büyüklüğü ise, ağıdaki katman sayısı ile gizli birimlerin sayısı ile ifade edilmektedir. Katmanlarını da gösterir şekilde örnek bir ağ yapısı Şekil 4.20’de verilmektedir (Freeman ve Skapura, 1991).



Şekil 4.20. Örnek bir ağ yapısı

Yapay sinir ağlarının sınıflandırılması

Literatürde karşılaşılabilecek olan birçok yapay sinir ağı çeşidi bulunmaktadır. Her bir yapay sinir ağı, üzerinde çalıştığı probleme çözüm üretmek üzere modellenmiştir. Yapay sinir ağlarının zamanla popüler olması nedeniyle kullanım alanlarının artması ise, yapay sinir ağlarının sınıflandırılmasına ihtiyaç duyulmuştur. Yapay sinir ağları; topolojileri, öğrenme yöntemleri, katman sayıları ve kullanım amaçlarına göre sınıflara ayrılmaktadır.


Topolojilerine (ağ yapılarına) göre yapay sinir ağları

Ağın oluşturulması için gerekli olan nöronların bağlantı şekli, “ağ topolojisi” olarak adlandırılmaktadır. Yapay sinir ağının performansı üzerinde etkili olan ağ topolojisi, yapay sinir hücrelerinin bağlantı şekline göre değişiklik göstermektedir. Topolojisine göre yapay sinir ağları, ileri ve geri beslemeli şeklinde sınıflandırılmaktadır.

İleri beslemeli (feed-forward) ağlar

Bu ağ çeşidi, bilgilerin ilk katman olan girdiden son katman olan çıktıya tek yönde ileriye doğru akış gösterdiği bir ağ çeşididir. Bu ağda herhangi bir katmanda bulunan hücrelerin çıktı değerleri, ağırlıkların çarpımı sonrası kendisinden bir sonraki katmana iletilmektedir. Böylece bir katmanın çıktı değeri, diğer katmanın girdi değeri olmaktadır.

İlk katman olan girdi, dışarıdan iletilen veriyi işlemsiz şekilde gizli olan katmanda bulunan yapay sinir hücrelerine iletmektedir. Veri, gizli katmanda işlenerek çıktı katmanına iletilmekte ve ağın çıktı değerini oluşturmaktadır. Statik ağlar olarak da bilinen bu ağ çeşidi, genellikle geri yayılım algoritması ile eğitilmektedir. Şekil 4.21’de çok katmana sahip ileri beslemeli bir ağ görülmektedir (Kaynar ve Taştan, 2009).




Şekil 4.21. Çok katmana sahip ileri beslemeli bir ağ yapısı

Geri beslemeli (feed-back) ağlar

Bu ağ çeşidi, aynı katmandaki nöronlar arasında ve/veya katmanlar arasında geri besleme özelliğine sahiptir. Bu tip ağlarda bilgi akışı hem ileri hem de geri yönlüdür. Diğer ağ yapısına zıt şekilde dinamik bir yapıdadır. Bu yapıdan dolayı ise, geri yönlü beslemenin doğurduğu zaman anlamında bir gecikme ortaya çıkmaktadır. Ağda bulunan bir önceki çıktı, bir sonraki zamanın çıktısının bulunabilmesi için modele girdi gibi dahil edilmektedir (Akgül, 2013).

Bu tip ağlarda diğer ağ çeşidine göre iletme dair hızın daha düşük seviyede olduğu ortaya konulmaktadır. Çünkü geri yönlü beslemeler ağı geciktirmektedir (Dede, 2008). Şekil 4.22’de ise, bu tip ağlara örnek verilmiştir (Saraç, 2004).




Şekil 4.22. Geri yönlü beslemeye sahip ağ modeli

Öğrenme yöntemlerine göre yapay sinir ağları

Yapay sinir ağı, temel yeteneği olan öğrenme aracılığıyla kendisine verilen giriş değerinden bir çıkış değeri üretmektedir. Öğrenme süreci ise, üzerinde çalışılan olayın örnekleri ile yapay sinir ağının eğitilmesini ifade etmektedir. Genel olarak öğrenme yöntemleri üç gruba ayrılmaktadır.

Danışmanlı (supervised)


Bu yöntem ile hem girdi hem de çıktı değerleri ağı tanıtılmaktadır. Çıktı elemanının gerçek ile hedeflenen değeri arasındaki farkın hata şeklinde kabul edildiği görülmektedir. Bağlantıların ağırlıkları üzerinde değişiklikler yapılarak hata değeri minimize edilmeye çalışılır. Bu nedenle bir danışmana ihtiyaç duyulan danışmanlı öğrenme algoritmasında genelde OMH ve HKOK gibi ölçütler kullanılır. Bu yöntem ile YSA, örnek bir girdinin işlenmesi doğrultusunda çıktı değerini üretip gerçek değerle karşılaştırmaktadır. Böylece düzenlenmiş olan ağırlıklar ağı sunularak ağın benzetilmesi amacı güdülür (Yavuz, 2012). Şekil 4.23'te danışmanlı öğrenme algoritmasının işleyişi yer almaktadır (Hamzaçebi, 2011).



Şekil 4.23. Danışmanlı öğrenme algoritmalarının işleyişi

Danışmansız (unsupervised)

Bu yöntem ile çıktı değerlerinin hedeflenen değerleri ağı yansıtılamamaktadır. Bu yöntemin kullanıldığı bir ağda girdi değerlerinin özellikleri değerlendirilerek ağırlık verilir. Adaptif Rezonans Teorisi, Kohonen ağı ve Hopfield ağı danışmansız öğrenmeye örnek olarak sayılabilir. Şekil 4.24'te danışmansız öğrenme algoritması gösterilmektedir (Elmas, 2003).



Şekil 4.24. Danışmansız öğrenme algoritmasının işleyişi

Takviyeli (reinforcement)

Takviyeli öğrenme yönteminde öğrenme süreci danışman kontrolünde olup hedeflenen çıktı değerleri ağı verilmemektedir. Yöntemde gerçekleşen her öğrenmenin sonucunda doğru-yanlış veya yeterli-yetersiz gibi skor elde edilerek danışman tarafından öğrenme sürecinin devam etmesi veya tamamlanmasına karar verilmektedir (Çaparoğlu, 2021). LVQ (Lineer Vektör Parçalama) gibi takviyeli öğrenme yöntemleri ise hem danışmanlı hem de danışmansız öğrenmenin özelliklerini taşımaktadır.

Kullanım amaçlarına göre yapay sinir ağları

Yapay sinir ağları, bu başlık altında sekiz grupta incelenmektedir. Çizelge 4.7’de ağların kullanım durumlarına göre topolojileri gösterilmektedir (Bayır, 2006).

Çizelge 4.7. Kullanım durumuna göre topolojiler

Amaç	Topoloji
Tahmin - Öngörü	▪ Geri Yayılım ▪ Yüksek Dereceli Sinir Ağları ▪ Elman Ağı ▪ Jordan Ağı
Fonksiyon Yaklaşırma	▪ Geri Yayılım ▪ RBF
Desen (Örüntü) Sınıflandırma	▪ LVQ Ağı ▪ ART Ağları ▪ Olasılık Tabanlı Ağlar ▪ Boltzmann Makinesi ▪ RBF
Veri İlişkilendirme	▪ Kohonen’s SOM ▪ Hopfield Ağları ▪ Boltzmann Makinesi ▪ Hamming Ağları ▪ ART

Çizelge 4.7. (devam) Kullanım durumuna göre topolojiler

Kavramlaştırma / Kümeleme	▪ LVQ ▪ SOM ▪ ART
Veri Filtreleme	▪ Yeniden Dolaşım
Optimizasyon	▪ Geri Yayılım ▪ Olasılık Tabanlı Sinir Ağları
Kontrol	▪ Geri Yayılım ▪ LVQ

Yapay sinir ağlarının genel özellikleri

Yapay sinir ağlarının geleneksel yöntemlerden birçok farklı özelliği bulunmaktadır. Bu yöntemler aşağıdaki gibi sıralanmaktadır (Adıyaman, 2007).

Bilginin saklanabilir olması

Yapay sinir ağları, bilginin ağdaki nöronlar arası bağlantılarda saklandığı bir yöntem olup geleneksel yöntemlerden farklılık göstermektedir. Böylece dağıtılmış hafıza özelliği ile bilginin ağın tümünde saklanabildiği görülmektedir.

Dağıtılmış hafızaya sahip olma

Yapay sinir ağları, geleneksel yöntemlerin aksine dağıtılmış hafızaya sahiptir. Bu özellik ile bilginin bütün ağa yayılımı sağlanmakta olup ağın tamamında saklı tutulmaktadır.

Doğrusal olmama

Yapay sinir ağlarında nöronlar doğrusal olmayıp bu durum tüm ağa etki etmektedir. Bu sayede yapay sinir ağları karmaşık problemlere uygulanmakta olup doğru ve hızlı sonuçlara ulaşılmaktadır. Birçok alanda tahmin gerektiren çalışmalar için de kullanılabilir.

Eksik/hatalı veri ile çalışabilme

Yapay sinir ağları, eğitilme aşamasından sonra eksik ya da hatalı veriler ile de çözüm üretebilmekte olup geleneksel yöntemlerden farklılık göstermektedir.

Genelleme

Yapay sinir ağları, örnekler ile öğrenme faaliyetini gerçekleştirir. Böylece ağ, deneyimlerini oluşturulabilmekte olup genelleme yaparak benzer olaylarda benzer şekilde karar verebilmektedir. Bu sayede, verilerin yanlış veya eksik olması halinde de ağın çalışmaya devam ettiği görülür.

Hata toleransına sahip olma

Esnek bir yapıya sahip olan yapay sinir ağları modelleri, yüksek hata toleransına sahiptir. Geleneksel yöntemlerin aksine dağıtılmış hafızaya sahip olan yapay sinir ağlarında tek bir bölgeye bağlı kalınmayıp ağın tamamında bilgi saklanmaktadır. Böylece eksik ya da hatalı veri olması durumunda ağda yalnızca performans düşüklüğü görülmekte, modelin çalışmasında sorun yaşanmamaktadır.

Kademeli olarak bozulma

Dağıtılmış hafızaya sahip olan yapay sinir ağları, ağın tamamında bilgileri saklamaktadır. Böylelikle ağda herhangi bir nöronda bozulma görüldüğünde kademeli olarak bozulmalar yaşanır, bu durumdan tüm model etkilenmez.

Öğrenme

İnsan beyninin çalışma sisteminden esinlenen yapay sinir ağları verilerle eğitilerek ilgili olayı tecrübe etmektedir. Böylece öğrenmeyi gerçekleştirmekte ve benzer bir olaya karşı benzer sonucu vermektedir. Bu özelliği nedeniyle ise, karmaşık olaylar karşısında karar verebilmektedir.

Paralellik

Yapay sinir ağlarında nöronlar eşzamanlı olarak çalışabilmekte olup bu sayede geleneksel yöntemlerin aksine hızlı bir şekilde sonuç elde edilmektedir. Eşzamanlı olarak çalışan nöronlar, modele konu problemin tamamında değil; yalnızca ilgili kısım üzerinde etkin rol oynar.

Uyarlanabilir olma

Yapay sinir ağları, belirli bir sorunu çözmek için eğitilmiş olsa dahi değişikliklere karşı esnek bir yapıya sahiptir. Tanımında ya da değişkenlerinde değişiklik yaşansa bile probleme doğru çözümler bulması açısından yeniden eğitilebilmektedir (Bulgan, 2013).

Yapay sinir ağlarının avantaj ve dezavantajları

Ağlar, öğrenme kabiliyetine sahip olup farklı problemler için uyarlanabilir olmaktadır. Geleneksel yöntemlere göre daha kullanışlı ve pratik olmasının yanı sıra bazı dezavantajlara da sahiptir.

Avantajları:

- ✓ Matematiksel açıdan zor modellenen ya da hiç modellenemeyen problemlerin modellenmesi ve çözülmesi aşamalarını gerçekleştirebilmektedir.
- ✓ Eşzamanlı olarak çalışan nöronlar sayesinde geleneksel yöntemlerden farklı olarak daha hızlı sonuç elde edilebilmektedir.
- ✓ Değişikliklere karşı esnek yapıya sahip olan yapay sinir ağları, değişen problemlere göre tekrar eğitilerek çözüme ulaşılabilir.
- ✓ Yalnızca ihtiyaç duyulan örnekler ile eğitimi tamamlanabilen yapay sinir ağları, oldukça pratik, gerçekçi ve hızlı bir şekilde uygulama imkanı sunabilmektedir.
- ✓ Öğrenme işlemini örnekleri kullanarak gerçekleştiren yapay sinir ağları, deneyimleri ile genelleme yaparak benzer olaylarda benzer şekilde karar verebilmektedir.

Dezavantajları:

- ✓ Ağın eğitimi oldukça önemli bir aşama olup zaman ve yapılabirlik açısından kimi zaman sorun yaratabilmektedir.

- ✓ Herhangi bir problem için uygun model, katman, eleman seçimi ve örnek toplama işlemi yalnızca kullanıcı tecrübesi ile şekillenmekte olup herhangi bir kural bulunmamaktadır. Deneme yanılma yöntemi ile gereken faktörler seçilmektedir.
- ✓ Modelin uygulanması ile elde edilen çözümün en iyi çözüm olup olmadığı konusunda belirsizlik olup geleneksel yöntemlerden bu yönüyle ayrışmaktadır. Bunun nedeni ise, ağın eğitiminin makul bir hata oranı yakalandığında durdurulması yani bu hususta herhangi bir kural olmamasıdır.
- ✓ Ağın ürettiği çözümün neden ya da nasıl üretildiği hususunun açıklanamaması nedeniyle ağa duyulan güven azalabilmektedir.
- ✓ Yalnızca sayısal veriler ile çalışması nedeniyle sayısal olmayan verilerin dönüştürülmesi gerekmektedir.

Yapay sinir ağlarının kullanım alanları

Ağlar, geleneksel yöntemlerin aksine bulanık verilere sahip karmaşık problemlere uygulanabilmektedir. Zaman içerisinde yaşanan gelişmeler ile çok çeşitli alanlarda uygulanan yapay sinir ağları ile temel anlamda şu fonksiyonlar gerçekleştirilmektedir:

Sınıflandırma: Sunulan verileri kriterler doğrultusunda çeşitli kategorilere ayırmaktadır.

Tahmin: İlgili problem için oluşturulan ağa girdi değişkenleri verilerinin sunulması ile çıktı değişkenlerine dair veriler tahmin edilmektedir.

Tanıma ile eşleştirme: Farklı şekil ile örüntüleri tanıma işlemi gerçekleştirilmekte olup karmaşık ve belirsiz bilgilerin de eşleştirilmesi yapılmaktadır.

Teşhis: Sistemdeki olumsuz kısımların açığa çıkarılması ve bu doğrultuda sorunların teşhis edilmesi sağlanmaktadır.

Veri filtreleme: Ağ tarafından birçok veri arasından uygun olan veri filtrelenmektedir.

Veri ilişkilendirme: Sunulan verilerin eksik/hatalı olup olmadığı hususu belirlenmekte olup eksik veri bulunması halinde tamamlanmaktadır.

Yorumlama: Bir problem için toplanan örnek ve veriler ile ağıın eğitimi tamamlanıp yeni olaylar yorumlanabilmektedir.

Bunların yanı sıra yapay sinir ağları çeşitli alanlarda uygulama imkanı bulmaktadır. Bu alanlar şu şekilde sınıflandırılabilir:

Askeri alan: Yapay sinir ağları, birçok ülke için büyük önem taşıyan askeri alanda hedef izleme, keşif yapma ve radarın algılanması gibi birçok noktada kullanılabilir.

Bankacılık/Finans alanı: Yapay sinir ağları, bankacılık/finans alanında kredi risk değerlendirmesi ve portföylerin analizi gibi birçok noktada kullanılabilir.

Çevresel alan: Yapay sinir ağları, çevresel açıdan hava tahmini konusunda kullanılabilir.

Üretim alanı: Yapay sinir ağları, üretim yapılan işletmelerde kalite kontrol alanında kullanılabilir.

Yapay sinir ağlarının öğrenme kuralları

Ağlar, üzerinde çalışılan problemlerin çözümü için ağıın tasarlanması ve eğitilmesi ile oluşturulur. Ağıın tasarımında katman ve nöron sayısı belirlenmekte olup eğitilmesi sırasında ise bağlantı ağırlıkları belirlenmektedir. Ağlar, bağlantıların sahip olduğu ağırlık değerlerinin belirli kurallar doğrultusunda ayarlanması ile eğitilmektedir. Bu kurallar, ağırlık değerlerinin ne şekilde ayarlanması gerektiğini açıklamaktadır (Akgül, 2013).

Ağların eğitilmesi için birçok öğrenme kuralı geliştirilmiştir. Diğerleri ile kıyaslandığında en eski kuralın Hebb olduğu, diğer tüm kuralların Hebb temelinde geliştiğı görülmektedir (Akgül, 2013).

Hebb kuralı

Bu kural, D. Hebb'in nörobiyoloji alanında yaptığı deneyleri esas alarak 1949 tarihinde geliştirmiş olduğu temel bir kural niteliğı taşımaktadır. Hebb'in bu kuralına göre, iki nöronun aynı anda uyarıldığı ve birinin diğerinden girdi aldığı durumda nöronların

bağlantılarının sahip olduğu ağırlık değeri artırılmalıdır (Akgül, 2013). Kural doğrultusunda bir nöron, kendi durumunun pasif ya da aktif olduğu fark etmeksizin diğer nöronu da kendisine benzetmeye çalışmaktadır (Öztemel, 2006).

Hopfield kuralı

Genel anlamda Hebb kuralına benzeyen Hopfield kuralı, ondan farklı olarak bağlantı ağırlıklarının ne kadar artırılıp azaltılması gerektiğini belirlemektedir. Girdi değeri ile hedeflenen çıktılardan her ikisi de aktifse öğrenme katsayısı değerince artırılıp her ikisinin de pasif olduğu durumda katsayı değerince azaltılmaktadır. Öğrenme katsayısı ise, pozitif ve sabit bir değer olup genellikle 0-1 arasındadır.

Delta kuralı

Hebb kuralının gelişmiş versiyonu olan bu kural, hedeflenen ile gerçekleştiren çıktı arasındaki farkı azaltma amacıyla bağlantı ağırlıklarının sürekli şekilde değiştirilmesi ile çalışmaktadır. Son katmanda çıkan hata, transfer fonksiyonuna dair fonksiyonun türevi ile dönüştürülmeli ve önceki katmana iletilmelidir. Geri iletime dair olan süreç, girdi katmanına ulaşıncaya dek devam etmektedir (Akgül, 2013).

Kohonen kuralı

Bu kural, Teuvo Kohonen tarafından geliştirilmiş olup yapay sinir hücrelerinin bağlantı ağırlıklarının değişmesi ilkesine dayanır. En büyük çıktı değerine sahip olan sinir hücresi, bağlantı ağırlıklarını değiştirebilmektedir. Ayrıca komşu hücrelerin bağlantı ağırlıkları da değiştirilebilmektedir. Ağın eğitilme aşamasında en genişten en daraya komşu tanıma aşamasına geçilir. Girdi değerleri ile en iyi şekilde eşleşmiş olan hücre seçilmektedir (Akgül, 2013).

5. YSA VE REGRESYON ANALİZİ UYGULAMASI

5.1. Çalışmanın Amacı

Elektrik enerjisi, ülkelerin kalkınması için gerekli olan unsurların başında gelmektedir. Yaşamın devamı için gerekli olmakta ve devamlı olarak tüketilmektedir. Depolanma imkanının da kısıtlı ve maliyetli olması nedeniyle elektrik enerjisinin arz-talep dengesinin korunması gerekmektedir. Bu çalışmada çoklu doğrusal regresyon analizi ve yapay sinir ağları yöntemlerinin uygulanması doğrultusunda Türkiye'nin elektrik enerjisi talep tahminleri yapılmış olup optimum sonucu veren yöntemin belirlenmesi amaçlanmıştır.

Çoklu doğrusal regresyon analizi, birden çok bağımsız değişkenin bir bağımlı değişkeni etkilediği durumlarda kullanıldığından bu çalışmada tercih edilmiştir. Uygulama IBM SPSS paket programının 29.0 sürümünde yapılmıştır. Yapay sinir ağları ise, değişik türdeki problemleri çözebilmesi ve girdi-çıkı değişkenleri arasında varsayıma gereksinim duymamasıyla modelleme konusunda avantaj sağladığı için uygulanmıştır. Yapay sinir ağları uygulaması MATLAB paket programının R2022b sürümü kullanılmıştır. MATLAB programı, The MathWorks, Inc. Şirketi tarafından üretilmiş olup sayısal uygulamalar için uygun yapıya sahiptir.

5.2. Veri Seçimi ve Model Tasarımı

Son yıllarda elektrik talebinin tahmin edilmesi amacıyla çeşitli yöntemler tercih edilmiş ve farklı modeller geliştirilmiştir. Çalışmalarda girdi verisi olarak farklı bağımsız değişkenler kullanılmış olup bu değişkenlerin elektrik talebi üzerindeki etkisi değerlendirilmiştir.


Bu çalışmada literatürdeki birçok çalışmada ortak olarak kullanılan GSYH, nüfus, ihracat ve taşıt sayısı değişkenleri ele alınmıştır. Bu kapsamda modele eklenmesi uygun olan farklı değişkenler araştırılmış olup yeterli verilere sahip beyaz eşya, cep telefonu, elektrikli-hibrit araç sayısı ile toplam kurulu güç, elektrik üretimi ve sanayinin GSMH içerisindeki payı da bağımsız değişken olarak modele eklenmiştir.

Türkiye'de elektrik enerjisi tüketimi incelendiğinde üretim değerlerinin doğrudan etkisi olduğu bilindiği için elektrik üretim değeri de bağımsız değişken olarak modele eklenmiştir.

Modelin amacı ise, bu değişkenler doğrultusunda elektrik talebi değişkeninin hesaplanmasıdır. Şekil 5.1’de ise değişkenlerin MATLAB üzerinde ağa tanıtıldığını gösteren kod yapısı yer almaktadır. Şekil 5.2’de ise değişkenlerin SPSS üzerindeki gösterimi yer almaktadır.

```
L=size(D,1);
tb=[];
Names = {'GSYH Veri', 'Nufus', 'Ihracat', 'B.Esya', 'Tasit', 'Cep Tlf', 'ElektrikliHibritAra', 'ToplamKuruGu', 'ElektrikUretimi', 'SanayiGSMHPay', 'Elk.Tuketim'};
```

Şekil 5.1. Değişkenlerin MATLAB üzerinde gösterimi



Şekil 5.2. Değişkenlerin SPSS üzerinde gösterimi

Yapay sinir ağlarında konu edilen her probleme göre farklı ağlar tasarlanmakta olup ağ tasarımının ağın başarısı için büyük önem arz ettiği bilinmektedir. Ağ yapılarının tasarlanma aşamasında katman ve katmanlarda bulunan nöron sayısı, bağlantıları ve ağa gelen bilginin akış yönüne dikkat edilmelidir (Çanakçı ve Hosoz, 2006). Ağlar, kullanım özellikleri açısından üç sınıfta değerlendirilmektedir. Çizelge 5.1’de sınıflandırılmış ağ türleri gösterilmektedir (Saraç, 2004).

Çizelge 5.1. Sınıflandırılmış ağ türleri

Kullanım amacı	Ağ türü	Kullanım alanı
Tahmin	Çok katmanlı ağ	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi
Sınıflandırma	LVQ ART Counterpropagation Olasılıklı sinir ağları	Girdi değerlerinin ait oldukları sınıfları belirlemeye yönelik olarak sınıfların belirlenmesi
Veri ilişkilendirme	Hopfield Boltzmann makinası Bidirectional associative memory	Girdi değerlerindeki eksiklerin tespit edilip tamamlanması, hatalı bilgilerin belirlenmesi

Ağ yapısı tasarlanırken en uygun çözümü veren bir yöntem bulunmamakta olup problem üzerinde çalışan kişinin bilgi ve becerisi önemli hale gelmektedir (Çanakçı ve Hosoz, 2006).

Uygulama kapsamında kurulan modele eklenen değişkenler ve açıklamaları ise, aşağıda sunulmaktadır.

Gayri safi yurtiçi hasıla

GSYH, ülkede tarafından belirli bir zaman dilimi içerisinde üretilen, satılabilen hizmet ve malların parasal anlamda karşılığı olarak tanımlanmakta olup modelin önemli bir değişkenidir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin büyüme performansını gösteren gayri safi yurtiçi hasıla değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

Nüfus

Nüfus, elektrik enerjisinin talebini etkileyen önemli faktörlerden olup ülkemiz için artış eğilimindedir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin insan kaynağını gösteren nüfus değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

İhracat

İhracat, bir ülke tarafından üretilen hizmet ve/veya malların başka ülkelere satışını ifade etmekte olup üretimin göstergesidir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin üretim doğrultusunda elektrik enerjisi tüketimini gösteren ihracat değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

Beyaz eşya sayısı

Beyaz eşyalar, hayatımızı kolay hale getiren ev eşyaları olarak bilinmekte olup elektrik tüketiminin artmasına dolayısıyla da elektrik talebini doğrudan etkilemektedir. Bu ifade ile geçmiş yıllarda çamaşır makinesi, bulaşık makinesi, buzdolabı ve fırın anlaşılmakta olup günümüzde kurutucu ve derin dondurucu da dahil edilmiştir. Bu değişkene dair resmi

uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin bir bakıma gelişmişlik seviyesini gösteren beyaz eşya sayısı değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

Taşıt sayısı

Taşıtlar, zaman içerisinde hayatımızın vazgeçilmez bir unsuru haline gelmiş olup elektrik talebine dolaylı olarak etki etmektedir. Taşıtlar bünyesinde barındırdığı klima, aydınlatma, ses, otomatik kilit, uzaktan kumanda sistemleri ile navigasyon cihazı gibi aksesuarları ile elektrik tüketimini artırmaktadır. Ayrıca elektrikli motosikletler de elektrik tüketiminin artmasına neden olmakta ve elektriğe olan talebi etkilemektedir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin ulaşım sektörünün göstergesi olan taşıt sayısı değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

Cep telefonu sayısı

Cep telefonları, günümüzde hayatımızın önemli bir parçası haline gelse de elektrik tüketimini doğrudan etkilememektedir. Şarj ihtiyacı, internet kullanımı ve kablosuz kulaklık gibi ek cihazlar nedeniyle elektrik tüketimini dolayısıyla da elektriğe olan talebi artırmaktadır. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmıştır. Ülkenin bir bakıma gelişmişlik seviyesini gösteren beyaz eşya sayısı değişkeni, modele bağımsız değişken olarak dahil edilmiştir.

Elektrikli-hibrit araç sayısı

Elektrikli-hibrit araçlar, motorlu araçlara göre çok daha fazla elektrik enerjisi kullanmaktadır. Günümüzde elektrikli araçların kullanımı artmakta, böylece elektriğe olan talep de artmaktadır. Talep artış miktarı ise, bu araçların kullanım yoğunluğu ile pazar payına bağlı olmaktadır. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmış olup modele bağımsız değişken olarak dahil edilmiştir.

Toplam kurulu güç

Toplam kurulu güç, belirli zamanda üretilebilecek maksimum elektrik miktarını ifade etmekte olup elektrik talebini etkileyen önemli unsurların başında gelmektedir. Enerji sorunlarının yaşanmaması için elektrik talebi ile dengede olması gerekmektedir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmış olup modele bağımsız değişken olarak dahil edilmiştir.

Elektrik üretimi

Elektrik üretimi, elektrik talebini doğrudan etkileyen bir unsur olup talebin karşılanması için üretilen elektrik enerjisini ifade etmektedir. Elektrik üretimi ile talebinin dengede olması, enerji sorunlarının önüne geçmektedir. Bu değişkene dair resmi uyumlaştırılmış veriler, TÜİK sayfası üzerinden alınmış olup modele bağımsız değişken olarak dahil edilmiştir.

Sanayi (GSMH payı)

Sanayinin GSMH içindeki payı, ekonomideki sanayileşme seviyesini göstermekte olup elektrik talebini etkilemektedir. Sanayi sektörü geliştikçe GSMH içindeki payı da artacaktır. Bu değişkene dair resmi veriler, Dünya Bankası sayfasından alınmış olup modele bağımsız değişken olarak dahil edilmiştir.

Elektrik talebi

Elektrik talebi; modelin bağımsız değişkenleri olan GSYH, nüfus, ihracat, beyaz eşya, taşıt ve cep telefonu sayısının geçmiş verileri doğrultusunda hesaplanmak istenen bağımsız değişkendir. Elektrik tüketimine dair geçmiş veriler ise, elektrik talebinin hesaplanması için gerekli olmaktadır.

5.3. Yapay Sinir Ağları Uygulaması

5.3.1. Verilerin normalizasyonu

Yapay sinir ağları yönteminin tercih edildiği durumda tahmin aşamasına geçilmeden önce yapılması gereken ön işlemler bulunmaktadır. Bazı olumsuzlukların gerçekleşmemesi için probleme ait veriler normalize edilerek belirlenen bir aralığa transfer edilerek ölçeklenmiş olur (Akgül, 2013).

Veriler, normalizasyon işlemi ile uygun aralığa getirilerek tahmin uygulaması için hazır hale getirilmektedir. Ancak tahmin sonuçlarından sonra verilerin orijinal değerlerine dönüştürülmesi gerekmektedir. Bu çalışmada da tüm veriler, modelde kullanılabilir hale getirilmek amacıyla $[0,1]$ aralığına dönüştürülmüştür.

Verilerin normalleştirilmesi için genellikle bu formüller kullanılır (Es, 2013):

a) $[0,1]$ aralığı için doğrusal dönüşüm:

$$x_n = \frac{x_0 - x_{min}}{x_{maks} - x_{min}} \quad (5.1)$$

b) $[a,b]$ aralığı için doğrusal dönüşüm:

$$x_n = (b - a) \frac{x_0 - x_{min}}{x_{maks} - x_{min}} + a \quad (5.2)$$

c) Basit normalizasyon:

$$x_n = \frac{x_0}{x_{maks}} \quad (5.3)$$

d) İstatistiksel normalizasyon:

$$x_n = \frac{x_0 - \bar{x}}{s} \quad (5.4)$$

Formüllerdeki x_0 ifadesi orijinal, x_n ifadesi ise normalleştirilmiş veriyi sembolize etmektedir. Ayrıca $x_{\min}$ ve $x_{\max}$ ifadeleri veri matrisindeki minimum ve maksimum değerleri; $\bar{x}$ veri matrisindeki ortalama değeri, s ifadesi ise standart sapmayı göstermektedir.

Aşağıda yer alan Şekil 5.3'te çalışma kapsamında kurulan model için D matrisinin minimum ve maksimum değerleri bulunarak verilerin normalizasyonunu sağlayan kod yapısı yer almaktadır. Böylece veriler [0-1] aralığına dönüştürülerek yöntem için uygun hale gelmektedir.

```
load('D.mat')
F=72;
TR=54;
D(:,1)=[ ];

MIND=min(D);
MAXD=max(D);

D=(D-MIND.*ones(size(D,1),size(D,2)))./(MAXD.*ones(size(D,1),size(D,2))-MIND.*ones(size(D,1),size(D,2)));
```

Şekil 5.3. Verilerin normalizasyonunu sağlayan kod yapısı

5.3.2. Algoritma seçimi

Yapay sinir ağlarında modelin başarısı için probleme uygun bir algoritma seçimi yapmak gerekmektedir. Kullanım alanları açısından dört gruba ayrılan algoritmalar Çizelge 5.2'de gösterilmektedir (Saraç, 2004).

Çizelge 5.2. Algoritmalar ile kullanım alanları

Alanlar	YSA
Öngörü	Geri yayılım Delta bar delta
Sınıflandırma	LVQ Counterpropagation
Verinin ilişkilendirilmesi	Hopfield Boltzmann
Verinin kavramlaştırılması	ART SOM

Bu çalışmada oluşturulan tahmin amaçlı modelde Levenberg-Marquardt geri yayılım algoritması tercih edilmiştir. Şekil 5.4'te geri yayılım algoritmasını ifade eden kod yapısı gösterilmektedir.

```
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.
```

Şekil 5.4. Geri yayılım algoritması için kod yapısı

5.3.3. Katman sayısının belirlenmesi

Katmanlar, yapay sinir hücrelerinin bir araya gelmesi ile oluşmakta ve ağ tasarımıda önemli rol oynamaktadır. Katman sayısının belirlenmesi için herhangi bir kural bulunmamaktadır. Ancak katman sayısının artırılması halinde ağın ezberleme olasılığı artmaktadır.

Aşağıda yer alan Şekil 5.5'teki kod yapısında “hidden layer size” değişkeni ise, gizli katmanın boyutunu ifade etmektedir. Görülen yapı, modelin temelini oluşturmaktadır.

```
% Create a Fitting Network
hiddenLayerSize = NR;
net = fitnet(hiddenLayerSize,trainFcn);
net.performParam.regularization = 0.5;
net.trainParam.showWindow = 0;
% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};
```


Şekil 5.5. Gizli katman boyutunu içerir kod yapısı

Üzerinde çalışılan problemde katman sayısının belirlenmesi aşamasında bir kural bulunmamakta olup araştıran kişinin denemeler sonucu elde ettiği tecrübesi ile şekillenmektedir (Kaastra and Boyd, 1994).

5.3.4. Nöron (yapay sinir hücresi) sayısının belirlenmesi

Nöron sayısı, tıpkı katman sayısı gibi deneme-yanılma metodu ile belirlenmektedir. Kullanıcı, istenilen ağ başarısına ulaşana dek nöron sayısını değiştirmelidir. Eğer nöron sayısı düşükse eğitiminin yetersiz olabileceği, çok ise ezber yapabileceği bilinmektedir.

Bir yapay sinir ağı, genelleme özelliğine sahip olmalıdır. Eğitimi sırasında ağı ve ilişkileri ezberlememeli aksine öğrenmelidir. Ağın ezberleme ihtimali, istenen bir durum olmayıp; genelleme kabiliyetinin düzgün gelişmediği ve eğrilerin yeterince düzgün görülmediği durumlarda ortaya çıkar (Küçükönder, 2011). Şekil 5.6'da (a) genelleme, (b) ise ezberleme yapan ağı göstermektedir.



Şekil 5.6. Genelleme (a), ezberleme (b)

Gizli nöron sayısı seçiminin önemli olduğu kadar aktivasyon fonksiyonu seçimi de ağın performansı üzerinde etkilidir. Ağlarda geliştirilmiş modelin ortalama bir şekilde bir davranışı öğrenmesi hedef alınmıyorsa sigmoid fonksiyonu kullanılmalıdır. Ancak ortalamanın öğrenilmesinin aksine sapmayı öğrenmesi isteniyorsa hiperbolik tanjant fonksiyonu kullanılmalıdır (Küçükönder, 2011).

5.3.5. Yapay sinir ağları eğitimi

Bir ağda bulunan işlemcilerin eğitimi, bağlantıların sahip olduğu ağırlık değerlerinin belirlenip uygulamaya dahil edilmesi ile yapılmaktadır (Öztemel, 2006). Ağların tasarlanma aşamasında problemin veri setinin eğitim verileri ve test verilerinden oluştuğu görülmektedir. Nöron ve katman sayısının belirlenmesi işleminde olduğu gibi eğitim ve test verilerinin ayrıştırılmasında da herhangi bir kural bulunmamaktadır. Bu durum hem problemin yapısına hem de kullanıcının tecrübesi ile şekillenir.

Ağda test yapılırken eğitimi sırasında kullanılmamış olan veriler ele alınır. Bu veriler, girdi şeklinde modele dahil edilir. Ağın ürettiği sonuç ile hedeflenen sonuçlar karşılaştırılarak genelleme için uygun olup olmadığı kontrol edilir (Çanakçı ve Hosoz, 2006).

Çalışmada öğrenme algoritması olarak ise, Levenberg-Marquardt algoritması seçilmiştir. Bu algoritmanın, literatürde yer alan çalışmalarda sıklıkla kullanıldığı görülmektedir. Levenberg-Marquardt algoritması, yapay sinir ağları eğitimini kısa sürede tamamlaması sebebiyle kullanılmaktadır.

Modelin sağlıklı bir şekilde çalışabilmesi için ağın iyi eğitilmesi gerekmektedir. Literatürde verilerin genel olarak eğitim ve test verisi paylarının, %70 - %30 veya %80 - %20 şeklinde olduğu görülmektedir. Bu çalışmada, ağın iyi eğitilmesi amacıyla daha çok verinin kullanılmasına uygun en geniş zaman dilimi seçilmiştir. Modelin tüm değişkenleri için 1970 yılı ile 2023 yıllarını kapsar zaman dilimi için resmi kaynaklardan alınan veriler işlenerek MATLAB paket programında yapay sinir ağı tasarlanmıştır.

Bu çalışmadaki veri setinin eğitim, doğrulama ve test verisi payları, %70 - %15 - %15 olarak dağılmaktadır. Oluşturulan modelde sinir hücre sayısı giderek arttırılmış olup probleme en uygun olan model nihai olarak seçilmiştir. Levenberg-Marquardt algoritması ile ileri beslemeye ve geri yayılıma sahip ağ yapısı oluşturulmuştur.

Şekil 5.7’de modeldeki verilerin dağılım oranlarını gösteren kod yapısı yer almaktadır. Verilen %70’i ağın eğitimi aşamasında kullanılmakta olup diğer veriler ise ağın performansının değerlendirilmesi için önemlidir.

```
% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
```

Şekil 5.7. Veri setinin dağılım oranını gösteren kod yapısı

YSA, MATLAB programı üzerinde veri tipi olarak network biçiminde saklanabilmekte olup fitnet() fonksiyonu ile kurulmaktadır. Böylece ağın net isimli değişken üzerine atandığı görülmektedir (Balkışlı, 2022). Şekil 5.8’de yapay sinir ağları genel kod yapısı görülmektedir. Bu kod yapısında yer alan “net input process” fonksiyonu girdi verilerinin ön işlemlerini, “net output process” fonksiyonu ise çıktı verilerinin ön işlemlerini ifade etmektedir. “net divide” parametreleri ise, verilerin bölünmesi için kullanılmaktadır.

```

% Create a Fitting Network
hiddenLayerSize = NR;
net = fitnet(hiddenLayerSize,trainFcn);
net.performParam.regularization = 0.5;
net.trainParam.showWindow = 0;
% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

```

Şekil 5.8. Yapay sinir ağları genel kod yapısı

Levenberg-Marquardt algoritmasını içerir geri yayımlı ağ yapısını içerir kod yapısı ise, Şekil 5.9’da görülmektedir.

```

% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. Suitable in low memory situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

```

Şekil 5.9. Levenberg-Marquardt algoritmasını içerir geri yayımlı yapay sinir ağı kod yapısı

Literatürdeki çalışmalarda kullanılan geri yayılım algoritmalarının çeşitleri ile sahip olduğu özellikler ise, Çizelge 5.3’te gösterilmiştir (Küçükönder, 2011).

Çizelge 5.3. Geri yayılım algoritmalarının çeşitleri ve özellikleri

Algoritma	Özelliği
Dereceli Azaltma (GD)	Çalışma açısından bakıldığında yavaş olduğu bilinen algoritma, orijinal olma özelliğe de taşımaktadır.

Çizelge 5.3.(devam) Geri yayılım algoritmalarının çeşitleri ve özellikleri

Momentumlu Dereceli Azaltma (GDM)	Bu algoritma, momentumun eklenmesi ile oluşmaktadır. GD algoritmasına göre hızlı çalışma özelliğine sahiptir.
Kümelerin Adaptifli Yokuş İnmesi (GDA)	Bu algoritma, GD algoritmasına dayanmaktadır.
Kümelerin Adaptifli Momentumlu Yokuş İnmesi (GDX)	Ağın eğitimi aşamasında ağırlıkların güncellenmesi doğrultusunda kendini güncellemektedir.
Esnek Geri Yayılım (RP)	Bu algoritma, esnek bir yapıya sahip olup hem statik hem de dinamik ağırlar için kullanılmaktadır.
Fletcher-Reeves Güncelleme (CGF)	Bu algoritma, CG algoritması ile kıyaslandığında daha az sayıda işlem ile çalışmaktadır.
Polak-Ribiere Güncelleme (CGP) (P)	Bu algoritma, CGF algoritması ile kıyaslandığında çok daha fazla sayıda işlem gerektirmektedir.
Esnek Dereceli Powell-Beale CG Güncelleme (CGB)	Bu algoritma, esnek olup CGP algoritması ile kıyaslandığında çok daha fazla işlem gerektirmektedir.
Kademeli Çekim (SCG)	Bu algoritma, genel olarak eğitim amaçlı kullanılabilir.
Broyde, Fletcher, Goldfarb, ve Shanno	Az sayıda iterasyon ile çalışmaktadır.
Tek Adım Sekant (OSS)	Quasi Newton ile CG algoritmalarının birleştirilmesi ile oluşmuştur.
Levenberg-Marquardt (LM)	Orta ölçeğe sahip ağlarda hızlı şekilde çalışmakta olup ufak hafıza gerektirmektedir.
Bayesian Regularization (BR)	Levenberg-Marquardt algoritmasından türetilmiş olup türetilen bir algoritma olup genelleştirme kabiliyetini iyileştirir.

5.3.6. Yapay sinir ağlarının test edilmesi

Yapay sinir ağlarında veri setinin ayrıştırılmasıyla oluşturulan test verileri, ağın tahmin performansının belirlenmesi için kullanılmaktadır.

5.3.7. Yapay sinir ağları için performansların belirlenmesi

Bir ağ, üzerinde çalışılan probleme uygun çıktıları sunmalıdır. Kullanıcılar, çözüm aşamasından sonra performans ölçütlerini incelemelidir. Ölçütler, yapay sinir ağının tahmin konusundaki başarısının göstergesidir. Ağın hem öğrenme hem de performans kabiliyetini göstermektedir. Çizelge 5.4'te yaygın olarak kullanılan performans ölçütlerinin açılımları gösterilmektedir.

Çizelge 5.4. Performans ölçütleri ve açılımları

Ölçüt	Açılım
Hata Kareler Ortalaması (MSE)	$HKO = \frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2 = \frac{1}{n} \sum_{i=1}^n e_j^2$ t_i : i'inci birim tahmin değeri g_i : i'inci birim gerçek değeri e_j : hata (tahmin için)
Hata Kareler Ortalaması Karekökü (RMSE)	$HKOK = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_j^2}$ t_i : i'inci birim tahmin değeri g_i : i'inci birim gerçek değeri e_j : hata (tahmin için)
Hata Kareleri Toplamı (SSE)	$HKT = \sum_{i=1}^n (t_i - g_i)^2 = \sum_{i=1}^n e_j^2$ t_i : i'inci birimin tahmin değeri g_i : i'inci birimin gerçek değeri e_j : hata (tahmin için)

Çizelge 5.4. (devam) Performans ölçütleri ve açılımları

Ortalama Mutlak Hata Yüzdesi (MAPE)	$OMHY = 100x \frac{\sum_{i=1}^n (t_i - g_i)^2 / t_i}{n}$ t_i : i'inci birimin tahmin değeri g_i : i'inci birimin gerçek değeri e_j : hata (tahmin için)
-------------------------------------	---

Şekil 5.10'da MSE performans ölçütü ile ağıın performansını değerlendiren kod yapısı yer almaktadır. “train” işlevi ile eğitilen ağıın, “performance” değişkeni ile MSE ölçütünü kullanarak performansını değerlendirilir. “e” değişkeni ise, ağıın çıktıları (y) ile hedeflenen çıktılar (t) arasındaki farkı ifade etmektedir.

```

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net.plotFcns = {'plotperform', 'plottrainstate', 'ploterrhist', ...
    'plotregression', 'plotfit'};

% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y);

% Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,y);
valPerformance = perform(net,valTargets,y);
testPerformance = perform(net,testTargets,y);

```

Şekil 5.10. MSE performans ölçütü için kod yapısı

Aşağıda yer alan Şekil 5.11'de ise, ağıın eğitiminde edinilmiş olan performans sonuçları değerlendirilmektedir. Eğitim ve doğrulama performanslarına dair ortalama alınarak ilgili değerden küçükse en iyi performansa sahip model olarak kabul edilir. Bu kod, uygulanan

iterasyonlar sonucunda “BNET” hücresini elde etmektedir. Bu hücre, en iyi modeli ifade etmektedir.

```
PER=mean([valPerformance,trainPerformance]);
if PER<baseper
    PER=baseper;
    BNET{i,q}=net;
end
end
end
```

Şekil 5.11. Performans sonuçlarının değerlendirilmesi için kod yapısı

En iyi model seçiminden sonra, tahminlerin “OUT” matrisinde toplanarak grafik haline getirilmesi gerekmektedir. Şekil 5.12 ve Şekil 5.13’te grafik oluşturma ile ilgili kod yapıları verilmiştir.

```
OUT(1:N,1)=D(1:N,i);
for w=N+1:F
    OUT(w,1)=0;
    for sd=1:MS
        net=BNET{i,sd};
        if w<TR
            OUT(w,1)=OUT(w,1)+net(D(w-N:w-1,i));
        else
            OUT(w,1)=OUT(w,1)+net(OUT(w-N:w-1,1));
        end
    end
    OUT(w,1)=OUT(w,1)/MS;
end
figure(i)
OUT(1:N,1)=0;
plot(1970:2022,D(:,i)*PD+PY)
hold on
plot(1970:2040,OUT*PD+PY)
xlabel('Zaman')
% ylabel('Satış')
title(Names{i})
legend('Veri','YSA Tahmin','Location','northwest')
```

Şekil 5.12. Tahmin sonuçlarının grafiksel gösterimini ifade eden kod yapısı

```

fn=sprintf('Figure_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.png',i,N,MS,NR);
fn2=sprintf('Figure_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.fig',i,N,MS,NR);

saveas(gca,fn)
saveas(gca,fn2)

figure(i+7)
OUT(1:N,1)=0;
scatter(D(1:53,i)*PD+PY,OUT(1:53)*PD+PY)
hold on
plot(D(1:53,i)*PD+PY,D(1:53,i)*PD+PY)

xlabel('Veri')
ylabel('YSA Tahmin')


RR=corrcoef(D(1:53,i)*PD+PY,OUT(1:53)*PD+PY);
R=RR(1,2);

q=sprintf('%s; R = %0.2f',Names{i},R);
title(q)
% legend('Veri','YSA Tahmin','Location','northwest')
fn=sprintf('Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.png',i,N,MS,NR);
fn2=sprintf('Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.fig',i,N,MS,NR);

```

Şekil 5.13. Grafik çizimini gösteren kod yapısı

Şekil 5.14'te elektrik talebi değişkeninin regresyon grafikleri incelendiğinde hedef ve çıktı değerlerinin regresyon doğrusunun üzerinde kümелendiği ve R değerinin 0,99982 olduğu görülmüştür. R değerinin 1'e çok yakın bir değer olması çalışmadaki her aşamada başarılı olduğuna işaret etmektedir. Ağ ezber yapmamış olup başarılı şekilde eğitilmiştir.



Şekil 5.14. Elektrik talebi değişkeninin regresyon değerleri

Şekil 5.15'te ise, grafikler kaydedildikten sonra ölçeklendirilen verilerin “tb” olarak isimlendirilen tabloya verilerin eklenmesi işlevi gösterilmektedir.

```
saveas(gca,fn)
saveas(gca,fn2)

tb=[tb, [[D(:,i)*PD+PY;zeros(F-TR,1)],OUT*PD+PY]];

end
```

Şekil 5.15. Ölçeklendirilen verilen tabloya aktarımını gösteren kod yapısı

```
fprintf("***** \n ***** \n")
fprintf('%s \n',Names{i})
% Print the performance
fprintf('Performance (MSE) = %f\n', performance);
fprintf('Train performance (MSE) = %f\n', trainPerformance);
fprintf('Validation performance (MSE) = %f\n', valPerformance);
fprintf('Test performance (MSE) = %f\n', testPerformance);

% Print RMSE
RMSE = sqrt(performance);
fprintf('Root Mean Squared Error (RMSE) = %f\n', RMSE);
% Print MAE
MAE = mean(abs(e));
fprintf('Mean Absolute Error (MAE) = %f\n', MAE);
% Print MAPE
MAPE = mean(abs(e./t))*100;
fprintf('Mean Absolute Percentage Error (MAPE) = %f\n', MAPE);
% Print R-squared
SStot = sum((t - mean(t)).^2);
SSres = sum((t - y).^2);
Rsquared = 1 - SSres/SStot;
fprintf('R-squared = %f\n', Rsquared);
% Print RSE
RSE = SSres / SStot;
fprintf('Relative Squared Error (RSE) = %f\n', RSE);
```

Şekil 5.16. Performans ölçütlerini gösteren kod yapısı

Şekil 5.16’da determinasyon katsayısı (R^2), hata kareler ortalaması karekökü (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak hata yüzdesi (MAPE) gibi performans ölçütlerinin ekrana yazdırılması işlevini gösteren kod yapısı bulunmaktadır.

Bu çalışmada Hata Kareler Ortalaması (MSE) ve determinasyon katsayısı (R^2) performans ölçütleri ile modelin değerlendirilmesi yapılmıştır. Çizelge 5.5’te uygulamanın tahmin sonuçlarına ait performans değerleri gösterilmektedir.

Çizelge 5.5. Modelin performans değerleri


Yapay Sinir Ağı Modeli	Performans Ölçütleri	
	R^2	MSE
NR = 18	0.999125	0.000064

Yapay sinir ağıları modeli için R^2 değerinin 0,99 olarak gerçekleştiği anlaşılmıştır. Gözlemlenen değerler ile tahmin değerlerinin ne derece eşleştiğini gösteren bu oran için 1 değeri ideal olmakla birlikte çalışmadaki model için bağımsız değişkenlerin bağımlı değişkendeki değişimi açıklama gücü açısından yeterlidir. Ayrıca diğer senaryolara göre en küçük hata değerine sahip olduğu anlaşıldığından modelin geçerli olduğu görülmüştür. Çizelge 5.6’da yapay sinir ağıları yönteminin uygulanması sonucu elde edilen elektrik talep tahmini değerleri verilmektedir.

Çizelge 5.6. Modelin tahmin değerleri

Yıl	Elektrik Talep Tahmini (GWh)
2023	329.295.505
2024	312.591.058
2025	334.055.038
2026	391.826.164
2027	406.837.626
2028	398.631.582
2029	378.885.162
2030	395.850.441
2031	414.884.225
2032	440.579.178
2033	450.057.462
2034	445.503.713
2035	429.372.087
2036	433.254.586
2037	444.724.252
2038	459.557.018
2039	465.023.685
2040	463.022.097

Şekil 5.17’de ise elektrik talebi (tüketimi) değişkeninin veri-tahmin grafiği yer almaktadır.



Şekil 5.17. Veri-tahmin grafiği

5.4. Çoklu Doğrusal Regresyon Analizi

İki ya da daha fazla değişken arasındaki ilişkiyi ölçmek için regresyon analizi yapılmaktadır. Bu çalışmada birden çok değişken kullanılması nedeniyle çoklu doğrusal regresyon analizi yapılmıştır. Çalışmada hazırlanan model, elektrik talebi üzerinde etkisi olduğu düşünülen ve aşağıda gösterilen 10 bağımsız değişkenden oluşmaktadır.

Bağımlı Değişken (Y) - Elektrik Talebi

Bağımsız Değişkenler (X) - GSYH (X_1), Nüfus (X_2), İhracat (X_3), Beyaz eşya sayısı (X_4)
Taşıt s. (X_5), Cep telefonu s. (X_6), Elektrikli-hibrit araç s. (X_7)
Toplam kurulu güç (X_8), Elektrik üretimi (X_9), Sanayi (X_{10})

Çalışma için geliştirilen regresyon modelinin bağımsız değişkeni elektrik talebi ile elektrik talebinin etkilendiği bağımsız değişkenler Çizelge 5.7’de gösterilmiştir.

Çizelge 5.7. Bağımlı ve bağımsız değişkenler

Bağımlı Değişken	Bağımsız Değişkenler
Elektrik Talebi	GSYH (Milyon \$)
	Nüfus
	İhracat (Milyon \$)
	Beyaz Eşya Sayısı
	Taşıt Sayısı
	Cep Telefonu Sayısı
	Elektrikli-Hibrit Araç Sayısı
	Toplam Kurulu Güç
	Elektrik Üretimi
	Sanayi (GSMH payı)

Bir bağımlı değişken ve birden fazla bağımsız değişkenin oluşturduğu çok değişkenli regresyon tahmin modeli ise şu şekildedir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (5.5)$$

Araştırma kapsamında test edilecek hipotezler ise şu şekilde açıklanmaktadır:

H_0 : Bağımsız değişkenlerin hiçbiri bağımlı değişkeni yordamamaktadır.

H_1 : Bağımsız değişkenlerin en az biri bağımlı değişkeni yordamaktadır.

İki ya da daha fazla değişken arasındaki ilişkiyi ölçmek için regresyon analizi yapılmaktadır.

Bu çalışmada da birden çok değişken kullanılması nedeniyle çoklu doğrusal regresyon analizi yapılmıştır. Çoklu regresyon modeline ilişkin kurulan ilk model sonucunda bağımsız değişken sayısı azaltılarak yeni model kurulmuş ve sonuçları yorumlanmıştır. Veri setine ilişkin betimleyici istatistikler, Çizelge 5.8’de yer almaktadır. Çizelge 5.9’da ise, çoklu regresyon modelinin analizi sonucunda elde edilen sonuçlar yer almaktadır.

Çizelge 5.8. Tanımlayıcı istatistikler


	Ortalama	Std. Sapma	N
Elektrik Talebi	107872032,04	95883144,970	54
GSYH (Milyon \$)	362,8272	339,98666	54
Nüfus	62218015,96	15140703,089	54
İhracat (Milyon \$)	64510,67	76807,777	54
Beyaz Eşya Sayısı	9885796,37	11176188,463	54
Taşıt Sayısı	9199984,37	8287212,701	54
Cep Telefonu Sayısı	27735384,56	34210090,769	54
Elektrikli-Hibrit Araç	19859,65	73444,679	54
Toplam Kurulu Güç	31853,0757	30029,76727	54
Elektrik Üretimi	127608,411	107385,6183	54
Sanayi (GSMH payı)	27,404	3,2042	54

Çizelge 5.9. Çoklu regresyon modeli sonuçları

	Katsayılar		t	P	Çoklu Bağlantılılık	
	B	Std. Hata			Tolerance	VIF
(Sabit)	-5194247,980	7798224,986	-0,666	0,509		
GSYH (Milyon \$)	-37640,693	9960,351	-3,779	0,000	0,019	52,748
Nüfus	0,313	0,281	1,110	0,273	0,012	83,514
İhracat (Milyon \$)	230,178	87,158	2,641	0,011	0,005	206,140
Beyaz Eşya Sayısı	2,666	0,759	3,510	0,001	0,003	331,408
Taşıt Sayısı	-2,010	1,323	-1,519	0,136	0,002	552,615
Cep Telefonu Sayısı	-0,244	0,141	-1,724	0,092	0,009	107,530
Elektrikli-Hibrit Araç	75,197	18,293	4,111	0,000	0,120	8,303
Toplam Kurulu Güç	-155,654	41,213	-3,777	0,000	0,142	7,045
Elektrik Üretimi	769,889	123,431	6,237	0,000	0,001	808,124
Sanayi (GSMH payı)	-126170,956	331162,367	-0,381	0,705	0,193	5,179

Çizelge 5.9'daki çoklu bağlantılılık değerleri; bağımsız değişkenlerin birbirleriyle ilişkili olup olmadığını göstermektedir. Bağımsız değişkenlerin birbiriyle ilişkili olması çoklu

bağıllık yarattığı için modelden çıkarılması gerekmektedir. VIF değerlerinin 10'dan büyük olması bağımsız değişkenlerin birbiriyle ilişkili olmadığını göstermektedir. Şekil 5.18'de ise analiz sonucunda elde edilen dağılım diyagramı yer almaktadır.



Şekil 5.18. Dağılım diyagramı

Çizelge 5.10'da çoklu regresyon modelinin belirlilik katsayıları, Çizelge 5.11'de ise birinci modelin ANOVA testi sonuçları gösterilmektedir.

Çizelge 5.10. Modelin belirlilik katsayıları

Model	R	R ²	Düzeltilmiş R ²	Std. Tahmin Hatası
1	,999 ^a	0,999	0,999	3394460,750

Elektrik talebi için kurulan çoklu doğrusal regresyon modelinde bağımsız değişkenlerin bağımlı değişkenlerdeki değişimi açıklama gücü %99,9'dur. Dolayısıyla bu oran modelin açıklama gücü açısından yeterlidir.

Oluşturulan modelde bağımsız değişkenlerin katsayılarının tamamının sıfır ya da sıfırdan farklı olup olmadığını ANOVA^a testi açıklamaktadır.

Çizelge 5.11. Model 1 Anova testi

Model 1	Kareler Toplamı	df	Kareler Ortalaması	F	P
Regresyon	486764145297102000,00	10	48676414529710200,00	4224,516	,000 ^b
Hata	495461642621500,00	43	11522363781895,30		
Toplam	487259606939724000,00	53			

Yukarıdaki tabloda sig. değerine bakıldığında kurulan modelin %5 anlamlılık düzeyinde anlamlı olduğu görülmekle $P(,000) < 0,05$ olduğu için H_0 hipotezinin de reddedildiği anlaşılmaktadır. Yani bu modelde en az bir değişkenin bağımlı değişken üzerinde etkisi vardır.

Çizelge 5.10’da yer alan sonuçlara göre kurulan modelde bağımsız değişkenlerin bağımlı değişken üzerindeki değişiklikleri açıklama yüzdesi oldukça yüksektir ($R^2=0,99$). Kurulan ilk modele ilişkin veriler incelendiğinde ise, Çizelge 5.11’deki ANOVA testi sonuçlarına göre modelin anlamlı olduğu sonucuna varılmıştır ($p<0,05$).

Bu modelden elde edilen diğer sonuca göre; GSYH, ihracat, beyaz eşya, elektrikli-hibrit araç, elektrik üretimi, sanayi (GSMH payı) ve toplam kurulu güç değişkenlerinin, elektrik talebi üzerinde etkisi olduğu görülmektedir. Fakat GSYH, ihracat, beyaz eşya ve elektrik üretimi değişkenlerinin VIF değerleri istenilen aralıkta değildir ($VIF<10$). Dolayısıyla bu değişkenler modelden çıkarılmıştır. Yeni kurulan model ise, Çizelge 5.12’de yer almaktadır.

Çizelge 5.12. Model 2 sonuçları


Model 2	Katsayılar		t	P	VIF
	B	Std. Hata			
(Constant)	7719738,238	46336045,315	,167	,868	
Elektrikli-Hibrit Araç	396,612	79,481	4,990	,000	1,309
Toplam Kurulu Güç	2399,888	188,185	12,753	,000	1,226
Sanayi	577728,326	1711676,982	,338	,737	1,155

Çizelge 5.12’de yer alan sonuçlara göre elektrikli hibrit araç, toplam kurulu güç ve sanayi (GSMH payı) bağımsız değişkenleri elektrik talebi üzerinde etkiye sahiptir. Elektrikli hibrit

araç, toplam kurulu güç ve sanayi (GSMH payı) değişkenleri, elektrik talebini pozitif yönlü etkilemektedir. Model 2 sonuçlarına göre regresyon denklemi ise şu şekildedir;

$$\text{Elektrik Talebi} = (7719738,238) + 396,612 (\text{Elektrikli Hibrit Araç}) + 2399,888 (\text{Toplam Kurulu Güç}) + 577728,326 (\text{Sanayi})$$

Elektrikli-hibrit araç sayısındaki bir birimlik artış elektrik talebini 396,612 birim, toplam kurulu güç değerindeki bir birimlik artış elektrik talebini 2399,888 birim ve sanayinin GSMH payı değerindeki bir birimlik elektrik talebini 577728,326 birim arttırmaktadır. Regresyon denkleminde elde edilen sonuçlara göre elektrik talebi üzerinde üç bağımsız değişkenin de pozitif yönlü etki yaptığı anlaşılmaktadır. Şekil 5.19’da denklem doğrultusunda oluşturulan tahmin değerleri grafik üzerinde gösterilmektedir.




Şekil 5.19. Elektrik talebine dair gözlem ve tahmin değerleri

Model 2’nin ANOVA sonuçları incelenmiş ve çoklu regresyon modelinin çoklu korelasyon (R)=0,926 ve belirlilik katsayısı değerinin (R^2)=0,85 olarak gerçekleştiği anlaşılmıştır. Bu oranın uygulanan regresyon modelinde bağımsız değişkenlerin bağımlı değişkendeki değişimi açıklama gücü açısından yeterli olduğu ve modelin geçerli olduğu anlaşılmıştır.

Her iki uygulamadan elde edilen tahmin değerleri ise, Enerji ve Tabii Kaynaklar Bakanlığı tarafından yapılan tahminler ile karşılaştırılmıştır. Karşılaştırma için seçilen zaman aralığı, 2031 yılından sonrası için hazırlanmış resmi tahmin bulunamaması nedeniyle 2023-2031

olarak seçilmiştir. Şekil 5.20’de çoklu doğrusal regresyon analizi, yapay sinir ağları ve ETKB tahmin değerlerinin karşılaştırılması yer almaktadır.



Şekil 5.20. Tahmin değerlerinin karşılaştırılması



6. SONUÇ VE ÖNERİLER

Bu çalışmada, enerji politikalarına temel oluşturmak amacıyla Türkiye'nin 2023-2040 dönemi için elektrik enerjisi talebinin tahmin edilmesi hedeflenmiştir. Literatürdeki çalışmalarda kullanılan değişkenlere ek olarak modele yeni değişkenler eklenmiştir. Çalışmada veri seti olarak GSYH, nüfus, ihracat, beyaz eşya sayısı, taşıt sayısı, cep telefonu sayısı, elektrikli-hibrit araç sayısı, toplam kurulu güç, elektrik üretimi ve sanayi (GSMH payı) değişkenlerinin Ocak 1970-Ağustos 2023 dönemindeki değerleri kullanılmıştır. Ayrıca elektrik talebinin tahmin edilmesi için gerekli olan elektrik tüketimi değişkeninin de aynı dönemi kapsar şekilde verileri kullanılmıştır. Verilerin analizi ve tahmin değerlerinin üretilmesi için SPSS ve MATLAB paket programları kullanılarak regresyon analizi ve yapay sinir ağları yöntemleri uygulanmıştır.

Çalışma kapsamında yapay sinir ağları yönteminin uygulanması ile ağın ezber yapmadığı, hedef ve çıktı değerlerinin regresyon doğrusunun üzerinde kümелendiği görülmüştür. Bu doğrultuda Türkiye'nin 2023-2040 dönemi için uygun tahmin değerlerine ulaşılmıştır. Regresyon analizinde ise, analiz sonucu elde edilen değerler doğrultusunda farklı modeller kurulmuş olup uygun regresyon denklemi elde edilmiştir. Analiz sonucunda bağımsız değişkenlerin bağımlı değişkenlerdeki değişimi açıklama gücünün yeterli olduğu ve regresyon denklemi ile Türkiye'nin 2023-2040 dönemi için uygun tahmin değerlerinin hesaplanabildiği görülmüştür.

Yapılan çalışma neticesinde regresyon modeli ile yapay sinir ağları modelinin kabul edilebilir tahminler gerçekleştirebildiği saptanmıştır. Yapay sinir ağları modeli, insan beyninin taklit edilmesi prensibiyle çalıştığı için regresyon analizine göre daha uygun tahmin değerleri üretmiştir. Yapay sinir ağları yöntemi ile elde edilen tahmin değerleri, Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanan elektrik talep tahmin değerlerine daha yakındır. Tüm değerler karşılaştırıldığında ise, Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanan elektrik talep tahmin değerlerinin çalışma kapsamında uygulanan iki yöntemin tahmin değerlerine göre daha yüksek olduğu görülmüştür. Gelecek çalışmalarda elektrik enerjisi talebini etkileyen farklı değişkenler seçilerek uygun veri seti ile farklı modeller kurulmalıdır. Ayrıca farklı talep tahmin yöntemleri ile daha geniş zaman aralıklarına dair tahminler yapılmalıdır.



KAYNAKLAR

- Adıyaman, F. (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 3-5.
- Akan, Y., ve Tak, S. (2003). Türkiye elektrik enerjisi ekonometrik talep analizi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(1-2), 21-49.
- Akay, D., and Atak, M. (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy*, 32(9), 1670-1675.
- Akdi, Y., Gölveren, E., and Okkaoğlu, Y. (2020). Daily electrical energy consumption: Periodicity, harmonic regression method and forecasting. *Energy*, 191, 116524.
- Akgül, S. (2013). *Yapay sinir ağları ile Türkiye elektrik enerjisi talep tahmini ve diğer yöntemlerle karşılaştırmalı analizi*. Doktora Tezi, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, Erzurum, 5-174.
- Akkurt, A. (2005). *Yapay Sinir Ağları ile Türkiye Elektrik Tüketimi Tahmin Modeli*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-2.
- Akkurt, M., Demirel Ö. F., and Zaim, S. (2010). Forecasting Turkey's natural gas consumption by using time series methods. *European Journal of Economic and Political Studies*, 3(2), 1-21.
- Al-Hafid, M. S., and Al-maamary, G.H. (2012). Short term electrical load forecasting using holt-winters method. *Al-Rafidain Engineering Journal*, 20(6), 15-22.
- Al-Sahlawi, M. A. (1990). Forecasting the demand for electricity in Saudi Arabia. *Energy Journal*, 11(1), 119-126.
- Altınay, G. (2010). Aylık elektrik talebinin mevsimsel model ile orta dönem öngörüsü. *Enerji, Piyasa ve Düzenleme*, 1(1), 1-23.
- Amarawickrama, H. A., and Hunt, L. C. (2008). Electricity demand for Sri Lanka: a time series analysis. *Energy*, 33(5), 724-739.
- Anderson, K. P. (1972). Optimal growth when the stock of resources is finite and depletable. *Journal of Economic Theory*, 4(2), 256-267.
- Aras, N. (2008). Forecasting residential consumption of natural gas using genetic algorithms. *Energy Exploration and Exploitation*, 26(4), 241-266.
- Arjmand, A., Samizadeh R., and Saryazdi M. D. (2019). Improved forecasting of short term electricity demand by using of integrated data preparation and input selection methods. *Journal of Energy Management and Technology*, 3(1), 48-57.

- Atalay, M. (2013). *Makine Öğrenme Yöntemleri Yardımıyla Tüketim İstatistiklerine Göre Talep Tahmini*. Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-63.
- Avami, A., and Boroushaki, M. (2011). Energy consumption forecasting of Iran using recurrent neural networks. *Energy Sources, Part B: Economics, Planning, and Policy*, 6(4), 339-347.
- Avcı, E., and Aydın, M. (2022). Comparison of artificial recurrent neural network for load forecasting. *MAS Journal of Applied Sciences*, 7(2), 337-347.
- Aydın, G. (2014). Modeling of energy consumption based on economic and demographic factors: The case of Turkey with projections. *Renewable and Sustainable Energy Reviews*, 35(9), 382-389.
- Azadeh, A., Saberi, M., Gitiforouz, A., and Saberi, Z. (2009). A hybrid simulation-adaptive network based fuzzy inference system for improvement of electricity consumption estimation. *Expert Systems with Applications*, 36(8), 11108-11117.
- Babaoğlu, M., ve Haznedar, B. (2023). Sürü zekâsı tabanlı algoritmalar ile Türkiye'nin uzun vadeli enerji tüketim tahmini. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(2), 424-441.
- Bakırtaş, T., Karbuz, S., and Bildirici, M. (2000). An econometric analysis of electricity demand in Turkey. *METU Studies in Development*, 27(1-2), 23-34.
- Barak, S., and Sadegh S.S. (2016). Forecasting energy consumption using ensemble ARIMA-ANFIS hybrid algorithm. *Electrical Power and Energy Systems*, 82, 92-104.
- Başaran Filik, Ü., Gerek, Ö. N., and Kurban, M. (2011). A novel modeling approach for hourly forecasting of long-term electric energy demand. *Energy Conversion and Management*, 52(1), 199-211.
- Başoğlu, B., ve Bulut, M. (2017). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575-583.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*. Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 3-37.
- Bayrak, M., and Esen, Ö. (2014). Forecasting Turkey's energy demand using artificial neural networks: Future projection based on an energy deficit. *Journal of Applied Economic Sciences*, 9(2), 191-204.
- Baughman, M. L., Joskow, P. L., and Kamat, D. P. (1979). *Electric power in the united states: Models and policy analysis*. Cambridge: MIT Press, 1-276.
- Bianco, V., Manca, O. and Nardini, S. (2009). Electricity consumption forecasting in Italy using regression models. *Energy*, 34(9), 1413-1421.

- Bilgen Yaşar, M. (2018). *Türkiye Elektrik Enerjisi Tüketiminin Genetik Algoritma ve ANFIS ile Modellenmesi*. Yüksek Lisans Tezi, Osmaniye Korkut Ata Üniversitesi Sosyal Bilimler Enstitüsü, Osmaniye, 1-82.
- Bilgili, M., Şahin, B., Yaşar, A., and Şimşek, E. (2012). Electric energy demands of Turkey in residential and industrial sectors. *Renewable and Sustainable Energy Reviews*, 16(1), 404-414.
- Birim, Ş., and Tümtürk, A. (2016). Modeling and forecasting Turkey's electricity consumption by using artificial neural network. *American Scientific Research Journal for Engineering, Technology, and Sciences*, 25(1), 192-208.
- Boltürk, E. (2013). *Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-79.
- Canyurt, O. E., Ceylan, H., Öztürk, H. K., and Hepbaşlı, A. (2004). Energy demand estimation based on two-different genetic algorithm approaches. *Energy Sources*, 26(14), 1313-1320.
- Canyurt, O. E., and Öztürk, H. K. (2008). Application of genetic algorithm (GA) technique on demand estimation of fossil fuels in Turkey. *Energy Policy*, 36(7), 2562-2569.
- Canyurt, O. E., and Öztürk, H. K. (2006). Three different application of genetic algorithm (GA) search techniques on oil demand estimation. *Energy Conversion and Management*, 47(18), 3138-3148.
- Ceylan, H., and Öztürk, H. K. (2006). Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach. *Energy Conversion and Management*, 45(15-16), 2525-2737.
- Chae, Y. T., Horesh, R., Hwang, Y., and Lee, M. (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111(2016), 184-194.
- Cheng, C. H., and Wei, L. Y. (2010). One step-ahead ANFIS time series model for forecasting electricity load. *Optimization and Engineering*, 11(2), 303-317.
- Çağlar, T. (2007). *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale, 24-25.
- Çaparoğlu, Ö. F. (2021). *Yapay Sinir Ağları ile Pandemi Sürecinde Kısıtlama Stratejilerinin Etkinliğinin Belirlenmesi İçin Bir Model Önerisi*. Yüksek Lisans Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum, 18.
- Çayır Ervural, B., Beyca, Ö.F., and Zaim, S. (2016, 8-30 Ekim). *Model estimation of ARMA using genetic algorithms: A Case Study of Forecasting Natural Gas Consumption*. 12th International Strategic Management Conference, Antalya, 537-545.

- Çınar, D., Kayakutlu, G., and Daim, T. (2010). Development of future energy scenarios with intelligent algorithms: Case of hydro in Turkey. *Energy*, 35(4), 1724-1729.
- Çiçek, C., ve Kırer Silva Lecuna, H. (2019). Türkiye'deki bölgelerin elektrik tüketim etkinliklerinin veri zarflama analizi ile değerlendirilmesi. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 2(2), 27-48.
- Çunkaş, M., and Altun, A. A. (2010). Long term electricity demand forecasting in Turkey using artificial neural networks. *Energy Sources; Part B: Economics, Planning, and Policy*, 5(3), 279-289.
- Deina, C., dos Santos, J. L. F., Biuk, L. H., Lizot, M., Converti, A., Siqueira, H.V., and Trojan, F. (2023). Forecasting electricity demand by neural networks and definition of inputs by multi-criteria analysis. *Energies*, 16(4), 1712.
- Demirel, Ö., Kakilli, A., ve Tektaş, M. (2010). ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(3), 601-610.
- Dilaver, Z., and Hunt, L. C. (2011). Industrial electricity demand for Turkey: A structural time series analysis. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 33(3), 426-436.
- Ediger, V. Ş., and Akar, S. (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35(3), 1701-1708.
- Ediger, V. Ş., and Tatlıdil, H. (2002). Forecasting the primary energy demand in Turkey and analysis of cyclic patterns. *Energy Conversion and Management*, 43(4), 473-487.
- Ekinci, F. (2019). YSA ve ANFIS tekniklerine dayalı enerji tüketim tahmin yöntemlerinin karşılaştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(3), 1029-1044.
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35(2), 512-517.
- Elmas, Ç. (2003). *Yapay sinir ağları: (Kuram, mimari, eğitim, uygulama)*. Ankara: Seçkin Yayıncılık, 35-149.
- Eltony, M. N., and Hajeer, M. (1999). Electricity demand by the commercial sector in Kuwait: An econometric analysis. *OPEC Review*, 23(1), 23-32.
- Erdemci, H. (2023). *Makine Öğrenmesi Algoritmaları Kullanılarak 2040 Yılına Kadar Türkiye'nin Enerji Talep Tahmini*. Yüksek Lisans Tezi, Batman Üniversitesi Lisansüstü Eğitim Enstitüsü, Batman, 1-60.
- Erdoğan, E. (2007). Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy Policy*, 35(2), 1129-1146.
- Erdoğan, E. (2010). Natural gas demand in Turkey. *Applied Energy*, 87(1), 211-219.

- Erkınay Özdemir, M. (2021). Yapay sinir ağları kullanılarak orta dönem elektrik enerjisi tüketim tahmini: İskenderun örneği. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 489-492.
- Ertem, B. N. (2020). *Bir Yüksek Hızlı Tren Hattında Yolcu Sayısı Tahmin Modelleri Geliştirilmesi*. Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 22-23.
- Ertuğrul, Ö. F. (2016). Forecasting electricity load by a novel recurrent extreme learning machines approach. *Electrical Power and Energy Systems*, 78, 429-435.
- Es, H. A. (2013). *Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini*. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1-75.
- Es, H. A. (2020). Gri tahmin modelleri ile toplam enerji talep tahmini: Türkiye örneği. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(3), 771-782.
- Fausett, L. (1994). *Fundamentals of neural networks: Architectures, algorithms and applications*. New Jersey: Prentice-Hall International, 5.
- Fisher, F. M., and Kaysen, C.A. (1962). *A study in econometrics: the demand for electricity in the United States*. Amsterdam: North Holland Publishing Company, 1-190.
- Filippini, M. (1999). Swiss residential demand for electricity. *Applied Economics Letters*, 6(8), 533-538.
- Freeman, J. A., and Skapura, D. M. (1991). *Neural networks: Algorithms, applications and programming techniques*. USA: Addison-Wesley Publishing Company, 10-25.
- Geem, Z. W. (2011). Transport energy demand modeling of South Korea using artificial. *Energy Policy*, 39(8), 4644-4650.
- Geem, Z. W., and Roper, W. E. (2009). Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, 37(10), 4049-4054.
- Gezmez, K. Ç. (2022). *Bir İlin Elektrik Tüketim Verilerinin Makine Öğrenmesi Yöntemleri ile Analizi*. Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1-62.
- Ghosh, S. (2002). Electricity consumption and economic growth in India. *Energy Policy*, 30(2), 125-129.
- Gülcü, Ş., and Kodaz, H. (2016, 19-22 Aralık). *The estimation of the electricity energy demand using particle swarm optimization algorithm: A case study of Turkey*. 8th International Conference on Advances in Information Technology, Bangkok, 64-70.
- Gümrah, F., Katırcıoğlu, D., Aykan, Y., Okumuş S., and Kılınçer, N. (2001). Modeling of gas demand using degree-day concept: Case study for Ankara. *Energy Sources*, 23(2), 101-114.

- Günay, M. E. (2016). Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: Case of Turkey. *Energy Policy*, 90, 92-101.
- Gündüz, A. (2023). *Elektrik Talebinin Farklı Yöntemler ile Tahminlenmesi*. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, 1-104.
- Gürbüz, F., Öztürk, C., and Pardalos, P. (2013). Prediction of electricity energy consumption of Turkey via artificial bee colony: a case study. *Energy Systems*, 4(3), 289-300.
- Haldenbilen, S., and Ceylan, H. (2005). Genetic algorithm approach to estimate transport energy demand in Turkey. *Energy Policy*, 33(1), 89-98.
- Halıcıoğlu, F. (2007). Residential electricity demand dynamics in Turkey. *Energy Economics*, 2(29), 199-210.
- Halvorsen, R. (1975). Residential demand for electric energy. *The Review of Economics and Statistics*, 57(1), 12-18.
- Hamzaçebi, C., ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3), 227-233.
- Hamzaçebi, C. (2007). Forecasting of Turkey's net electricity energy consumption on sectoral bases. *Energy Policy*, 35(3), 2009-2016.
- Hamzaçebi, Ç. (2011). *Yapay sinir ağları: Tahmin amaçlı kullanımı matlab ve neurosolution uygulamalı*. Bursa: Ekin Yayınevi, 23.
- Hamzaçebi, C., and Es, H. A. (2014). Forecasting the annual electricity consumption of Turkey using an optimized grey model. *Energy*, 70(3), 165-171.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*. New Jersey: Prentice-Hall, 2.
- Hertz, J., Krogh, A., and Palmer, R. G. (1991). *Introduction to the theory of neural computation*. Colorado: Addison-Wesley Publishing Company, 6.
- Hopfield, J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554-2558.
- Hotunluoğlu, H., and Karakaya, E. (2011). Forecasting Turkey's energy demand using artificial neural networks: Three scenario applications. *Ege Akademik Bakış*, 11(5), 87-94.
- Houthakker, H. S. (1951). Some calculations of electricity consumption in Great Britain. *Journal of the Royal Statistical Society*, 114(3), 249-270.

- Hussain, A., Rahman, M., and Memon, J.A. (2016). Forecasting electricity consumption in Pakistan: the way forward. *Energy Policy*, 90, 73-80.
- İnternet: Newsham, G. R., and Birt, B. (2010). Detecting Total Building Occupancy for More Efficient Operation, Research Report. URL-1: <https://nrc-publications.canada.ca/eng/view/ft/?id=c28ecd5e-6b1e-475a-9324-4404f7263c64>, Son Erişim Tarihi: 29.10.2023
- İnternet: PWC. (2023). Türkiye Elektrik Piyasasına Genel Bakış Eylül 2023 Raporu. URL-2: <https://www.pwc.com.tr/tr/sektorler/enerji/turkiye-elektrik-piyasasina-genel-bakis-2023.pdf>, Son Erişim Tarihi: 29.10.2023
- İnternet: Toker, A. E., ve Korkmaz, O. (2009). Türkiye kısa süreli elektrik talebinin saatlik olarak tahmin edilmesi. URL-3: https://www.emo.org.tr/ekler/d6d1c493ddc8662_ek.pdf, Son Erişim Tarihi: 29.10.2023
- İnternet: Uslu, M. F., Sanlı, B., ve Temur, T. (2013). Türkiye Aylık Elektrik Talep Modeli. URL-4: <http://www.barissanli.com/calismalar/2013/mfuslu-bsanli-ttemur-AETM.pdf>, Son Erişim Tarihi: 29.10.2023
- Jiang, W., Wu, X., Gong, Y., Yu, W., and Zhong, X. (2020). Holt–Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption. *Energy*, 193(2), 116779.
- Jumbe, C. (2004). Cointegration and causality between electricity consumption and GDP: Empirical evidence from Malawi. *Energy Economics*, 26(1), 61-68.
- Kankal, M., Akpınar, A., Kömürcü, M. İ., and Özşahin, T. Ş. (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927-1939.
- Karaaslan, A., and Gezen, M. (2017). Forecasting of Turkey's sectoral energy demand by using fuzzy grey regression model. *International Journal of Energy Economics and Policy*, 7(1), 67-77.
- Karaca, C., ve Karacan, H. (2016). Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 4(3), 182-195.
- Karadede, Y., Özdemir, G., and Aydemir, E. (2017). Breeder hybrid algorithm approach for natural gas demand forecasting model. *Energy*, 141, 1269-1284.
- Karluk, R. (1999). *Türkiye ekonomisi tarihsel gelişim yapısal ve sosyal değişim* (6. Baskı). İstanbul: Beta Yayınları, 247.
- Kaur, M., Panwar, S., Joshi, A., and Gupta, K. (2021, 25-27 Şubat). *Residential electricity demand prediction using machine learning*. International Semantic Intelligence Conference, New Delhi, 331-340.

- Kavaklıoğlu, K. (2011). Modeling and prediction of Turkey's electricity consumption using support vector regression. *Applied Energy*, 88(1), 368-375.
- Kavaklıoğlu, K., Ceylan, H., Öztürk, H. K., and Canyurt, O. E. (2009). Modeling and prediction of Turkey's electricity consumption using artificial neural networks. *Energy Conversion and Management*, 50(11), 2719-2727.
- Kaynar, O., ve Taştan, S. (2009). Zaman serisi analizinde MLP yapay sinir ağları ve ARIMA modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33(161), 161-172.
- Kaysal, K., Akarslan, E., ve Hocaoglu, F. O. (2022). Türkiye kısa dönem elektrik yük talep tahmininde makine öğrenmesi yöntemlerinin karşılaştırılması. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 9(2), 693-702.
- Kaytez, F. (2020). A hybrid approach based on autoregressive integrated moving average and leastsquare support vector machine for long-term forecasting of net electricity consumption. *Energy*, 197(2), 117200.
- Kaytez, F., Taplamacıoğlu, M. C., Çam, E., and Hardalaç, F. (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *Electrical Power and Energy Systems*, 67, 431-438.
- Kell, A. J. M., McGough, A. S., and Forshaw, M. (2021). The impact of online machine-learning methods on long-term investment decisions and generator utilization in electricity markets. *Sustainable Computing: Informatics and Systems*, 30, 100532.
- Kheirkhah, A., Azadeh, A., Saberi, M., Azaron, A., and Shakouri, H. (2013). Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. *Computers & Industrial Engineering*, 64(1), 425-441.
- Kıran, M. S., Özceylan, E., Gündüz, M., and Paksoy, T. (2012). A novel hybrid approach based on particle swarm optimization and ant colony algorithm to forecast energy demand of Turkey. *Energy Conversion and Management*, 53(1), 75-83.
- Kumluca Topallı, A., and Erkmen, İ. (2003). A hybrid learning for neural networks applied to short term load forecasting. *Neurocomputing*, 51(1), 495-500.
- Küçükali, S., and Barış, K. (2010). Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach. *Energy Policy*, 38(5), 2438-2445.
- Küçükdeniz, T. (2010). Long term electricity demand forecasting: An alternative approach with support vector machines. *İstanbul Üniversitesi Mühendislik Bilimleri Dergisi*, 1, 45-53.
- Küçükönder, H. (2011). *Yapay Sinir Ağları ve Tarımda Bir Uygulama*. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş, 82-86.

- Lee, R. S., and Singh, N. (1994). Patterns in residential gas and electricity consumption: An econometric analysis. *Journal of Business & Economic Statistics*, 12(2), 233-241.
- Limanond, T., Jomnonkwao, S., and Srikaew, A. (2011). Projection of future transport energy demand of Thailand. *Energy Policy*, 39(5), 2754-2763.
- Liu, N., Babushkin, V., and Afshari, A. (2014). Short-term forecasting of temperature driven electricity load using time series and neural network model. *Journal of Clean Energy Technologies*, 2(4), 327-331.
- Mahmutoğlu, M., ve Öztürk, F. (2015, 5-6 Kasım). *Türkiye elektrik tüketimi öngörüsü ve bu kapsamda geliştirilebilecek politika önerileri*. EY International Congress on Economics II, Ankara, 537-545.
- Makas, Y., ve Karaatlı, M. (2016). Yapay sinir ağlarıyla hidroelektrik enerji üretiminin çok dönemli tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3), 757-772.
- Melikoğlu, M. (2013). Vision 2023: Forecasting Turkey's natural gas demand between 2013 and 2030. *Renewable and Sustainable Energy Reviews*, 22, 393-400.
- Mozumder, P., and Marathe, A. (2007). Causality relationship between electricity consumption and GSYH in Bangladesh. *Energy Policy*, 35(1), 395-402.
- Murat, Y. S., and Ceylan, H. (2006). Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34(17), 3165-3172.
- Nebati, E. E., Taş, M., ve Ertaş, G. (2021). Türkiye’de elektrik tüketiminde talep tahmini: Zaman seri regresyon analizi ile karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (31), 348-357.
- Ok, Y. (2010). *Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) ile Türkiye’de Orta Dönemli Elektrik Enerjisi Talep Tahmini*. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 1-104.
- Ozoh, P., Abd-Rahman, S., Labadin, J., and Apperley, M. (2014). A comparative analysis of techniques for forecasting electricity consumption. *International Journal of Computer Applications*, 88(15), 8-12.
- Özaydın, G. (2019). *Türkiye Elektrik Enerjisi Talebinin Yapay Sinir Ağları Modeli ile Tahmini*. Yüksek Lisans Tezi, İzmir Kâtip Çelebi Üniversitesi Sosyal Bilimler Enstitüsü, İzmir, 1-106.
- Özdemir, G., Aydemir, E., Olgun, M. O., and Mulbay, Z. (2016). Forecasting of Turkey natural gas demand using a hybrid algorithm. *Energy Sources Part B-Economics Planning and Policy*, 11(4), 295-302.
- Özkan, E., Güler, E., ve Aladağ, Z. (2020). Elektrik enerjisi tüketim verileri için uygun tahmin yöntemi seçimi. *Endüstri Mühendisliği Dergisi*, 31(2), 198-214.

- Öztemel, E. (2006). *Yapay sinir ağları* (2. Baskı). İstanbul: Papatya Yayıncılık, 25-27.
- Öztürk Birim, Ş., and Tümtürk, A. (2022). A novel algorithmic similarity measure for collaborative filtering: A recommendation system based on rating distances. *Academic Platform Journal of Engineering and Smart Systems*, 10(1), 57-69.
- Öztürk, H. K., Ceylan, H., Hepbaşlı A., and Utlu, Z. (2004). Estimating petroleum exergy production and consumption using vehicle ownership and GDP based on genetic algorithm approach. *Renewable and Sustainable Energy Reviews*, 8(3), 289-302.
- Öztürk, H. K., and Ceylan, H. (2005). Forecasting total and industrial sector electricity demand based on genetic algorithm approach: Turkey case study. *International Journal of Energy Research*, 29(9), 829-840.
- Öztürk, H. K., Ceylan, H., Canyurt O. E., and Hepbaşlı, A. (2005). Electricity estimation using genetic algorithm approach: A case study of Turkey. *Energy*, 30(7), 1003-1012.
- Pao, H. T. (2009). Forecasting energy consumption in Taiwan using hybrid nonlinear models. *Energy*, 34(10), 1438-1446.
- Parreño, S. J. (2022). Forecasting electricity consumption in the Philippines using ARIMA models. *International Journal of Machine Learning and Computing*, 12(6), 279-285.
- Pavlicko, M., Vojteková, M., and Blažeková, O. (2022). Forecasting of electrical energy consumption in Slovakia. *Mathematics*, 10(4), 1-20.
- Pençe, İ., Kalkan, A., ve Şişeci Çeşmeli, M. (2019). Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağları ile tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 3(2), 206-228.
- Perwez, U., and Sohail, A. (2014). Forecasting of Pakistan's net electricity energy consumption on the basis of energy pathway scenarios. *Energy Procedia*, 61, 2403-2411.
- Portabales, A. R., Nores, M. L., and Arias, J. J. P. (2021). Systematic review of electricity demand forecast using ANN-based machine learning algorithms. *Energy Procedia*, 21(13), 1-23.
- Potter, W. C., and Negnevitsky, M. (2006). Very short-term wind forecasting for Tasmanian power generation. *IEEE Transactions On Power Systems*, 21(2), 965-972.
- Puspitasari, L., Suhartono, S., Akbar, M. S., and Lee, M. H. (2012, 10-12 Eylül). *Two-level seasonal model based on hybrid ARIMA-ANFIS for forecasting short-term electricity load in Indonesia*. 2012 International Conference on Statistics in Science, Business and Engineering, Langkawi, Kedah, 1-5.
- Reşat, H. G. (2020). Sürdürülebilir enerji yönetimi için yapay sinir ağları ve ARIMA metodları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: Tütün endüstrisinde vaka çalışması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1129-1140.

- Rothe, J. P., Wandhwani, A. K., and Wadhwani, S. (2009). Short term load forecasting using multi parameter regression. *International Journal of Computer Science and Information Security*, 6(2), 303-306.
- Rufael, Y. W. (2006). Electricity consumption and economic growth : A time series experience for 17 african countries. *Energy Policy*, 34(10), 1106-1114.
- Sağıroğlu, Ş., Beşdok, E., ve Erler, M. (2003). *Mühendislikte yapay zeka uygulamaları-I : Yapay sinir ağları*. Kayseri: Ufuk Kitabevi, 30.
- Saraç, T. (2004). *Yapay sinir ağları*. Basılmamış Seminer Projesi. Gazi Üniversitesi Endüstri Mühendisliği Bölümü, Ankara, 5-35.
- Sarak, H., and Satman, A. (2003). The degree-day method to estimate the residential heating natural gas consumption in Turkey: A case study. *Energy*, 28(9), 929-939.
- Say, N. P., and Yücel, M. (2006). Energy consumption and CO2 emissions in Turkey: Empirical analysis and future projection based on an economic growth. *Energy Policy*, 34(18), 3870-3876.
- Shiu, A., and Lam, P. L. (2004). Electricity consumption and economic growth in China. *Energy Policy*, 32(1), 47-54.
- Son, H., and Kim, C. (2017). Short-term forecasting of electricity demand for the residential sector using weather and social variables. *Resources, Conservation and Recycling*, 123(9), 200-207.
- Sönmez, İ. (2015). *Seydişehir Bölgesinin Orta Vadedeki Elektrik Enerjisi Talebinin Yapay Zekâ ile Tahmini*. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 1-165.
- Sönmez, M., Akgüngör, A. P. and Bektaş, S. (2017). Estimating transportation energy demand in Turkey using the artificial bee colony algorithm. *Energy*, 122, 301-310.
- Sözen, A., Akçayol, M. A. and Arcaklıoğlu, E. (2006). Forecasting net energy consumption using artificial neural network. *Energy Sources Part B-Economics Planning and Policy*, 1(2), 147-155.
- Sözen, A., Arcaklıoğlu, E., and Özkaymak, M. (2005). Turkey's net energy consumption. *Applied Energy*, 81(2), 209-221.
- Sözen, A., Arcaklıoğlu, E., and Özalp, M. (2004). Estimation of solar potential in Turkey by artificial neural networks using meteorological and geographical data. *Energy Conversion and Management*, 45(18-19), 3033-3052.
- Sözen, A., and Arcaklıoğlu, E. (2007). Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy Policy*, 35(10), 4981-4992.

- Sultana, N., Hossain, S. M., Almuhaeni, S., and Düştögör, D. (2022). Bayesian optimization algorithm-based statistical and machine learning approaches for forecasting short-term electricity demand. *Energies*, 15(9), 1-26.
- Sümer, K. K., Göktaş, Ö., and Hepsağ, A. (2009). The application of seasonal latent variable in forecasting electricity demand as an alternative method. *Energy Policy*, 37(4), 1317-1322.
- Şahin, Ş. Ö. (2002). *Yapay Sinir Ağları Yardımı ile Dinamik Bir Senaryo Analizi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 95-96.
- Şahinler, S. (2000). En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturma'nın temel prensipleri. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 5(1-2), 57-73.
- Tarkun, S., ve Işığışok, E. (2023). Türkiye’de orta vadede elektrik talebine etki eden içsel değişkenlerin belirlenmesi. *Business, Economics and Management Research Journal*, 6(2), 202-217.
- Taylor, J. W., and Mcsharry P. E. (2008). Short-term load forecasting methods: An Evaluation based on European data. *IEEE Transactions on Power Systems*, 22(4), 2213-2219.
- Taylor, J. W., de Menezes, L. M., and Mcsharry P. E. (2006). A comparison of univariate methods for forecasting electricity demand up to a day ahead. *International Journal of Forecasting*, 22(1), 1-16.
- TDK (Türk Dil Kurumu) (1994). *Genel açıklamalı sözlük*. Ankara: TDK Yayınları, 603.
- Thompson, R. P. (1976). Weather sensitive electric demand and energy analysis on a large geographically diverse power system: Application to short term hourly electric demand forecasting. *IEEE Transactions on Power Apparatus and System*, 95(1), 383-393.
- Toksarı, M. D. (2007). Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy*, 35(8), 3984-3990.
- Toksarı, M. D. (2009). Estimating the net electricity energy generation and demand using the ant colony optimization approach: Case of Turkey. *Energy Policy*, 37(3), 1181-1187.
- Toksarı, M. D. (2010). Predicting the natural gas demand based on economic indicators: Case of Turkey. *Energy Sources Part A: Recovery, Utilization and Environmental Effects*, 32(6), 559-566.
- Toros, H., and Aydın, D. (2018). Prediction of short-term electricity consumption by artificial neural networks using temperature variables. *Avrupa Bilim ve Teknoloji Dergisi*, (14), 393-398.
- Tripathy, S. C. (1997). Demand forecasting in a power system. *Energy Conversion and Management*, 38(14), 1475-1481.

- Tunç, Z. (2018). *En Küçük Kareler ve Temel Bileşenler Regresyon Analizlerinin Karşılaştırılması*. Yüksek Lisans Tezi, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü, Malatya, 14-16.
- Tunç, M., Çamdalı, Ü., and Parmaksızoğlu, C. (2006). Comparison of Turkey's electrical energy consumption and production with some European countries and optimization of future electrical power supply investments in Turkey. *Energy Policy*, 34(1), 50-59.
- Tutun, S., Chou, C-A., and Canıyılmaz, E. (2015). A new forecasting framework for volatile behaviour in net electricity consumption: A case study in Turkey. *Energy*, 93, 2406-2422.
- Uygun, İ. (2015). *Yapay Sinir Ağları Yardımıyla Enerji Sektöründe Talep Tahmini*. Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 1-71.
- Uzlu, E. (2019). Türkiye için gri kurt optimizasyon algoritması ile yapay sinir ağlarını kullanarak enerji tüketiminin tahmini. *Gazi University Journal of Science Part C: Design and Technology*, 7(2), 245-262.
- Ülkü, H., ve Yalpir, Ş. (2021). Enerji talep tahmini için metodoloji geliştirme: 2030 yılı Türkiye örneği. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 188-201.
- Ünler, A. (2008). Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025. *Energy Policy*, 36(6), 1937-1944.
- Üreten, S. (2006). *Üretim/işlemler yönetimi, stratejik kararlar ve karar modelleri* (5. Baskı). Ankara: Gazi Kitabevi, 137-139.
- Wang, W. C., Chau, K. W., Cheng, C. T., and Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 373(3-4), 294-306.
- Wang, Y., Wang, J., Zhao, G., and Dong, Y. (2012). Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China. *Energy Policy*, 48, 284-294.
- Wei, L., and Zhen-gang, Z. (2009, 28-29 Aralık). *Based on time sequence of ARIMA model in the application of short-term electricity load forecasting*. 2009 International Conference on Research Challenges in Computer Science, Shanghai, 11-14.
- Yalçınöz, T., and Eminoğlu, U. (2005). Short term and medium term power distribution load forecasting by neural networks. *Energy Conversion and Management*, 46(9-10), 1393-1405.
- Yang, Y., Chen, Y., Wang, Y., Li, C., and Li, L. (2016). Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short term electricity demand forecasting. *Applied Soft Computing*, 49, 663-675.

- Yaşar, E., and Uçkun, A. (2017, 18-20 Mayıs). *Turkey's forecasting of energy demand with artificial neural-network*. International Renewable Energy Conference, İstanbul, 21-29.
- Yavuz, M. (2012). *Yapay Sinir Ağları ile Portföy Optimizasyonu*. Yüksek Lisans Tezi, Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, Balıkesir, 26-45.
- Yavuzdemir, M. (2014). *Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini*. Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara, 15.
- Yayar, R., Hekim, M., Yılmaz, V., and Bakırcı, F. (2011). A comparison of ANFIS and ARIMA techniques in the forecasting of electric energy consumption of Tokat province in Turkey. *Journal of Economic and Social Studies*, 1(1), 87-112.
- Yazgan, O. (2013). *Elektrik Talebi ve Elektrik Piyasası Fiyatlarının Kısa Dönemde Tahmin Edilmesi*. Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-115.
- Yetis, Y., and Jamshidi, M. (2014, 3-7 Ağustos). *Forecasting of Turkey's electricity consumption using artificial neural network*. 2014 World Automation Congress, Hawaii, 723-728.
- Ying, L. C., and Pan, M. C. (2008). Using adaptive network based fuzzy inference system to forecast regional electricity loads. *Energy Conversion and Management*, 49(2), 205-211.
- Yumurtacı, Z., and Asmaz, E. (2004). Electric energy demand of Turkey for the year 2050. *Energy Sources*, 26(12), 1157-1164.
- Yüksel Haliloğlu, E., ve Tutu, B. E. (2018). Türkiye için kısa vadeli elektrik enerjisi talep tahmini. *Yaşar Üniversitesi E-Dergisi*, 13(51), 243-255.
- Yükseltan, E., Yücekaya, A., and Bilge, A. H. (2017). Forecasting electricity demand for Turkey: Modeling periodic variations and demand segregation. *Applied Energy*, 193, 287-296.
- Yükseltan, E., Yücekaya, A., and Bilge, A. H. (2015). Forecasting electricity demand for Turkey using modulated fourier expansion. *American Scientific Research Journal for Engineering Technology and Sciences*, 14(3), 87-94.
- Zivanovic, R. (2002, 17-19 Nisan). *Nonparametric trend model for short term electricity demand forecasting*. International Conference on Power System Management and Control, London, 347-352.



EKLER

EK-1. Matlab programlama modelinin kodları

```

clc
clear

load('D.mat')
F=72;
TR=54;
D(:,1)=[];

MIND=min(D);
MAXD=max(D);

D=(D-MIND.*ones(size(D,1),size(D,2)))./(MAXD.*ones(size(D,1),size(D,2))-
MIND.*ones(size(D,1),size(D,2)));

% load('PERFORMANCE.mat');
MS=10;
N=7;
NR=18;

L=size(D,1);
tb=[];
Names = {'GSYH Veri', 'Nufus', 'Ihracat', 'B.Esya', 'Tasit','Cep Tlf',
'ElektrikliHibritAra','ToplamKuruluG','ElektrikUretimi',
'SanayiGSMHPPay','Elk.Tuketim'};

for i=1:11

PY=MIND(i);
PD=MAXD(i)-MIND(i);

clear DN

% Z=PERMAT(:,i);
%
% [a,b]=min(Z);

% NR=PER_NEU(b,i);

for j=1:L-N
    DN(j,1:N+1)=D(j:j+N,i);
end

DG{i}=DN;

X=DN(:,1:N);
Y=DN(:,N+1)

```

EK-1. (devam) Matlab programlama modelinin kodları

```

x = X';
t = Y';
for q=1:MS

    baseper=10^10;
    for k=1:10
    % Choose a Training Function
    % For a list of all training functions type: help nntrain
    % 'trainlm' is usually fastest.
    % 'trainbr' takes longer but may be better for challenging problems.
    % 'trainscg' uses less memory. Suitable in low memory situations.
    trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

    % Create a Fitting Network
    hiddenLayerSize = NR;
    net = fitnet(hiddenLayerSize,trainFcn);
    net.performParam.regularization = 0.5;
    net.trainParam.showWindow = 0;
    % Choose Input and Output Pre/Post-Processing Functions
    % For a list of all processing functions type: help nnprocess
    net.input.processFcns = {'removeconstantrows','mapminmax'};
    net.output.processFcns = {'removeconstantrows','mapminmax'};

    % Setup Division of Data for Training, Validation, Testing
    % For a list of all data division functions type: help nndivision
    net.divideFcn = 'dividerand'; % Divide data randomly
    net.divideMode = 'sample'; % Divide up every sample
    net.divideParam.trainRatio = 75/100;
    net.divideParam.valRatio = 15/100;
    net.divideParam.testRatio = 15/100;

    % Choose a Performance Function
    % For a list of all performance functions type: help nnperformance
    net.performFcn = 'mse'; % Mean Squared Error

    % Choose Plot Functions
    % For a list of all plot functions type: help nnplot
    net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
        'plotregression','plotfit'};

    % Train the Network
    [net,tr] = train(net,x,t);

    % Test the Network
    y = net(x);
    e = gsubtract(t,y);
    performance = perform(net,t,y);

```

EK-1. (devam) Matlab programlama modelinin kodları

```

% Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,y);
valPerformance = perform(net,valTargets,y);
testPerformance = perform(net,testTargets,y);

PER=mean([valPerformance,trainPerformance]);

if PER<baseper

    PER=baseper;
    BNET{i,q}=net;

end

end

end

OUT(1:N,1)=D(1:N,i);
for w=N+1:F
    OUT(w,1)=0;
    for sd=1:MS
        net=BNET{i,sd};
        if w<TR
            OUT(w,1)=OUT(w,1)+net(D(w-N:w-1,i));
        else
            OUT(w,1)=OUT(w,1)+net(OUT(w-N:w-1,1));
        end
    end
    OUT(w,1)=OUT(w,1)/MS;
end
figure (i)
OUT(1:N,1)=0;
plot(1970:2023,D(:,i)*PD+PY)
hold on
plot(1970:2041,OUT*PD+PY)
xlabel('Zaman')
% ylabel('Satış')
title(Names{i})
legend('Veri','YSA Tahmin','Location','northwest')
fn=sprintf('Figure_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.png',i,N,MS,NR);
fn2=sprintf('Figure_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.fig',i,N,MS,NR);

```

EK-1. (devam) Matlab programlama modelinin kodları

```

saveas(gca,fn)
saveas(gca,fn2)

figure (i+11)
OUT(1:N,1)=0;
scatter(D(1:53,i)*PD+PY,OUT(1:53)*PD+PY)
hold on
plot(D(1:53,i)*PD+PY,D(1:53,i)*PD+PY)

xlabel('Veri')
ylabel('YSA Tahmin')

RR=corrcoef(D(1:53,i)*PD+PY,OUT(1:53)*PD+PY);
R=RR(1,2);

q=sprintf('%s; R = %0.2f',Names{i},R);
title(q)
% legend('Veri','YSA Tahmin','Location','northwest')
fn=sprintf('Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.png',i,N,MS,NR);
fn2=sprintf('Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.fig',i,N,MS,NR);

saveas(gca,fn)
saveas(gca,fn2)

figure (i+22)
subplot(2,2,4)
plotregression(trainTargets,y,'Train',valTargets,y,'Validation',testTargets,y,'Test',t,y,'All')
fn=sprintf('Detailed_Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.png',i,N,MS,NR);
fn2=sprintf('Detailed_Regression_%0.0d_N_%0.0d_MS_%0.0d_NR_%0.0d.fig',i,N,MS,NR);
saveas(gca,fn)
saveas(gca,fn2)

tb=[tb,[[D(:,i)*PD+PY;zeros(F-TR,1)],OUT*PD+PY]];

fprintf("***** \n ***** \n")
fprintf('%s \n',Names{i})
% Print the performance
fprintf('Performance (MSE) = %f\n', performance);
fprintf('Train performance (MSE) = %f\n', trainPerformance);
fprintf('Validation performance (MSE) = %f\n', valPerformance);
fprintf('Test performance (MSE) = %f\n', testPerformance);

```

EK-1. (devam) Matlab programlama modelinin kodları

```

% Print RMSE
RMSE = sqrt(performance);
fprintf('Root Mean Squared Error (RMSE) = %f\n', RMSE);
% Print MAE
MAE = mean(abs(e));
fprintf('Mean Absolute Error (MAE) = %f\n', MAE);
% Print MAPE
MAPE = mean(abs(e./t))*100;
fprintf('Mean Absolute Percentage Error (MAPE) = %f\n', MAPE);
% Print R-squared
SStot = sum((t - mean(t)).^2);
SSres = sum((t - y).^2);
Rsquared = 1 - SSres/SStot;
fprintf('R-squared = %f\n', Rsquared);
% Print RSE
RSE = SSres / SStot;
fprintf('Relative Squared Error (RSE) = %f\n', RSE);

end

TB=array2table(tb);
Names = {'GSYH_Veri','GSYH_Veri_Tahmin', 'Nufus','Nufus_Tahmin',
'Ihracat','Ihracat_Tahmin', 'B.Esya','B.Esya_Tahmin', 'Tasit','Tasit_Tahmin',...
'Cep_Tlf','Cep_Tlf_Tahmin',
'ElektrikliHibritAra','ElektrikliHibritAra_Tahmin','ToplamKuruluG','ToplamKuruluG_Tahmin',
'ElektrikUretimi','ElektrikUretimi_Tahmin',...
'SanayiGSMHPPay','SanayiGSMHPPay_Tahmin','Elk.Tuketim','Elk.Tuketim_Tahmin'};
TB.Properties.VariableNames = Names;
fn=sprintf('Table_N_%0.0d_MS_%0.0d_NR_%0.0d.xlsx',N,MS,NR);
writetable(TB,fn)

```



Gazili olmak ayrıcalıktır