

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TÜRKİYE'NİN AYLIK ELEKTRİK TÜKETİMİNİN
YAPAY SİNİR AĞLARIYLA TAHMİNİ

EZGİ POLAT

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ PROGRAMI

DANIŞMAN
DOÇ. DR. NEZİR AYDIN

İSTANBUL, 2019

ÖNSÖZ

Yüksek lisans tez çalışmam sırasında benden desteğini ve rehberliğini esirgemeyen, her umutsuz anımda beni yüreklendiren sevgili danışmanım Doç. Dr. Nezir AYDIN'a teşekkürü borç bilirim. Her zaman yanımda olan ve beni hep seven annem Nebahat POLAT'a; desteğini, bana inancını hep hissettiğim ağabeyim Uğraş Anıl POLAT'a ve son olarak her zaman, her koşulda bana inanmış, en ufak başarımda bile benimle gururlanmış hep yanımda olduğunu hissettiğim sevgili babam Adnan POLAT'a çok teşekkür ederim.

Temmuz, 2019

Ezgi POLAT

İÇİNDEKİLER

| | Sayfa |
|--|-------|
| SİMGE LİSTESİ | vi |
| KISALTMA LİSTESİ | vii |
| ŞEKİL LİSTESİ | ix |
| ÇİZELGE LİSTESİ..... | xi |
| ÖZET | xi |
| ABSTRACT | xii |
| BÖLÜM 1 | |
| GİRİŞ | 1 |
| 1.1 Literatür Özeti | 1 |
| 1.2 Tezin Amacı..... | 3 |
| 1.3 Bulgular ve Orijinal Katkı..... | 4 |
| BÖLÜM 2 | |
| ELEKTRİK TÜKETİM TAHMİNİ LİTERATÜR ARAŞTIRMASI | 5 |
| BÖLÜM 3 | |
| YAPAY SİNİR AĞLARI | 13 |
| 3.1 Yapay Sinir Ağlarının Tarihçesi | 13 |
| 3.2 Sinir Ağlarının Biyolojik Yapısı | 14 |
| 3.3 Nöron Modeli..... | 16 |
| 3.3.1 Aktivasyon Fonksiyonu | 19 |
| 3.3.1.1 Kısmi Türevlenebilen Aktivasyon Fonksiyonları | 19 |
| 3.3.1.2 Türevlenebilen Aktivasyon Fonksiyonları | 19 |
| 3.4 Yapay Sinir Ağlarında Öğrenme Modelleri | 21 |
| 3.4.1 Öğretmenli Öğrenme | 21 |
| 3.4.2 Öğretmensiz Öğrenme..... | 22 |
| 3.5 Yapay Sinir Ağı Modelleri | 24 |
| 3.5.1 İleri Beslemeli Tek Katmanlı Yapay Sinir Ağları | 24 |
| 3.5.2 İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları..... | 24 |
| 3.5.3 Tekrarlı Ağlar | 25 |
| 3.6 Uygulamada Kullanılan Yapay Sinir Ağı Yöntemleri | 26 |

| | | |
|---|---|-----------|
| 3.6.1 | Çok Katmanlı Yapay Sinir Ağı | 26 |
| 3.6.1.1 | ÇKYSA Çalışma Esasları | 27 |
| 3.6.1.2 | ÇKYSA Eğitim Prosesi | 28 |
| 3.6.2 | NARX Ağı | 36 |
| BÖLÜM 4 | | |
| TÜRKİYE’NİN ELEKTRİK TALEBİ GÖRÜNÜMÜ | | 38 |
| 4.1 | Türkiye’de Elektrik Üretim Tarihçesi | 38 |
| 4.2 | Türkiye’nin Elektrik Görünümü | 39 |
| 4.3 | Türkiye’de Enerji ve Elektrik Üretim Politikaları | 41 |
| BÖLÜM 5 | | |
| YAPAY SİNİR AĞLARI YÖNTEMİYLE TÜRKİYE’NİN AYLIK ELEKTRİK TÜKETİMİ TAHMİNİ .. | | 43 |
| 5.1 | Kullanılan Veriler | 43 |
| 5.1.1 | Ortalama Sıcaklık | 45 |
| 5.1.2 | Ortalama Yağış Miktarı | 46 |
| 5.1.3 | Tüketici Fiyat Endeksi | 46 |
| 5.1.4 | Toplam Sanayi Üretim Endeksi | 47 |
| 5.1.5 | Toplam İthalat ve İhracat | 48 |
| 5.1.6 | Brüt Elektrik Tüketimi | 49 |
| 5.2 | Uygulanacak Yöntem Parametrelerinin Seçimi | 49 |
| 5.3 | ÇKYSA Yönteminin Uygulanması | 53 |
| 5.3.1 | ÇKYSA Uygulama Adımları | 53 |
| 5.3.2 | ÇKYSA Sonuçları | 54 |
| 5.3.2.1 | ÇKYSA Deneme Sonuçlarının Değerlendirilmesi | 57 |
| 5.4 | Girdilerin Tahmini | 58 |
| 5.4.1 | Ortalama Sıcaklık ve Ortalama Yağış Miktarı Tahmini | 59 |
| 5.4.2 | Tüketici Fiyat Endeksi Tahmini | 60 |
| 5.4.3 | Toplam Sanayi Üretimi Endeksi Tahmini | 61 |
| 5.4.4 | İthalat Miktarı Tahmini | 62 |
| 5.4.5 | İhracat Miktarı Tahmini | 63 |
| 5.5 | Girdi Değişkenleri Özet Çizelgesi | 64 |
| 5.6 | ÇKYSA ile Tahmin Sonucu | 64 |
| 5.7 | Uygulamanın Çoklu Doğrusal Regresyon Sonucu | 65 |
| BÖLÜM 6 | | |
| SONUÇ VE ÖNERİLER | | 67 |
| KAYNAKLAR | | 69 |
| ÖZGEÇMİŞ | | 75 |

SİMGE LİSTESİ

| | |
|------------------|--|
| b | Bias değeri |
| E | Karesel hata |
| E_m | Ortalama karesel hata |
| $g(.)$ | Aktivasyon fonksiyonu |
| $I_j^{(L)}$ | L katmanının j. nöronuna ait ağırlıklandırılmış girdi toplamı |
| n_x | Girdi gecikmesi |
| n_y | Çıktı gecikmesi |
| p | Eğitim seti veri adeti |
| V_j | Bias değersiz ağırlıklandırılmış girdi toplamı |
| $W_{ji}^{(L)}$ | L katmanının j. nöronunun, (L-1) katmanının i. nöronuna bağlayan ağırlık |
| x_i | i. giriş vektörü |
| $x(t)$ | t anındaki girdi sinyali |
| $Y_j^{(L)}$ | L katmanındaki j. nörona ait çıktı |
| $Y(t)$ | t anındaki çıktı sinyali |
| $\delta_j^{(L)}$ | L katmanın j. nöronuna ait yerel gradyan |
| η | Öğrenme katsayısı |

KISALTMA LİSTESİ

| | |
|----------|---|
| ADALINE | Adaptive Linear Neuron or later Adaptive Linear Element |
| ANFIS | Adaptive Neuro Fuzzy Inference System |
| AR | Autoregressive Model |
| ARMA | Autoregressive Moving Average Model |
| ARIMA | Autoregressive Integrated Moving Average Model |
| ARMAX | Autoregressive Moving Average with Exogenous Model |
| ART | Adaptive Resonance Theory |
| ÇKSYA | Çok Kriterli Yapay Sinir Ağı |
| ES | Exponential Smoothing |
| ETKB | Enerji ve Tabii Kaynaklar Bakanlığı |
| EÜAŞ | Elektrik Üretim A.Ş. |
| GA | Genetik Algoritma |
| GDA | Gradyan Düşüm Algoritması |
| GSMH | Gayri Safi Milli Hasıla |
| IHR | İhracat |
| ITH | İthalat |
| KVYT | Kısa Vadeli Yük Tahmini |
| LR | Linear Regression |
| L-M | Levenberg-Marquardt |
| MADALINE | Multiple ADALINE |
| MAPE | Mean Absolute Percentage Error |
| NAR | Nonlinear Autoregressive Models |
| NARX | Nonlinear Autoregressive Models with Exogenous Input |
| NLR | Nonlinear Regression |
| OECD | Organisation for Economic Co-operation and Development |
| OVYT | Orta Vadeli Yük Tahmini |
| PSO | Parçacık Sürü Optimizasyonu |
| SARIMA | Seasonal Autoregressive Integrated Moving Average Model |
| SOM | Self Organized Map |
| SVR | Support Vector Regression |
| T | Sıcaklık |
| TEAŞ | Türkiye Elektrik Üretim İletim A.Ş. |
| TEDAŞ | Türkiye Elektrik Dağıtım A.Ş. |
| TEİAŞ | Türkiye Elektrik İletim A.Ş. |
| TEK | Türkiye Elektrik Kurumu |

| | |
|------|------------------------------|
| TÜFE | Tüketici Fiyat Endeksi |
| TSÜE | Toplam Sanayi Üretim Endeksi |
| UVYT | Uzun Vadeli Yük Tahmini |
| Y | Yağış Miktarı |
| YSA | Yapay Sinir Ağı |
| ZG | Zaman Gecikmesi |



ŞEKİL LİSTESİ

| | Sayfa |
|------------|---|
| Şekil 3.1 | Merkezi sinir sistemi çalışma yapısı [44]15 |
| Şekil 3.2 | Sinir hücresi yapısı [46]15 |
| Şekil 3.3 | Basit bir nöron modeli [49]17 |
| Şekil 3.4 | $I_j - V_j$ grafiği [49].....18 |
| Şekil 3.5 | Nöron modelinde bias değerinin girdi olarak gösterilmesi [49].....18 |
| Şekil 3.6 | Lojistik fonksiyonunun β' ya göre değişimi [43].....20 |
| Şekil 3.7 | Hiperbolik tanjant fonksiyonunun β' ya göre değişimi [43].....20 |
| Şekil 3.8 | Lineer fonksiyon grafiği [43]21 |
| Şekil 3.9 | Öğretmenli öğrenme modeli [49]22 |
| Şekil 3.10 | Takviyeli öğrenme modeli [49]23 |
| Şekil 3.11 | Denetimsiz öğrenme modeli [49]23 |
| Şekil 3.12 | İleri beslemeli tek katmanlı nöron [49].....24 |
| Şekil 3.13 | İleri beslemeli çok katmanlı yapay sinir ağı [49]25 |
| Şekil 3.14 | Gizli katmana sahip olmayan tekrarlı ağ örneği [49]26 |
| Şekil 3.15 | Gizli katmana sahip tekrarlı ağ örneği [49]26 |
| Şekil 3.16 | Çok katmanlı sinir ağı [43]27 |
| Şekil 3.17 | ÇKYSA ileri ve geri yayılım hareketi [43]28 |
| Şekil 3.18 | ÇKYSA'da kullanılacak parametre seti [43]29 |
| Şekil 3.19 | ÇKYSA detaylı girdi ve katman gösterimi [43].....29 |
| Şekil 3.20 | ÇKYSA 2. gizli katman j. nöronun referans olarak gösterilmesi [43]33 |
| Şekil 3.21 | ÇKYSA 1. gizli katman j. nöronun referans olarak gösterilmesi [43]35 |
| Şekil 3.22 | Açık döngü (seri paralel mimari) [50]37 |
| Şekil 3.23 | Kapalı döngü (paralel mimari) [50]37 |
| Şekil 4.1 | Nisan 2019 itibariyle enerji kaynaklarına göre elektrik üretim yüzdeleri [58]40 |
| Şekil 4.2 | Sektörlere göre elektrik kullanım yüzdesi [60]41 |
| Şekil 5.1 | Türkiye aylık ortalama sıcaklık değişimi (1998-2019)45 |
| Şekil 5.2 | Türkiye aylık yağış miktarı değişimi (1998-2019)46 |
| Şekil 5.3 | Türkiye aylık TÜFE değişimi (1998-2019)47 |
| Şekil 5.4 | Türkiye aylık TSÜE değişimi (1998-2019)47 |
| Şekil 5.5 | Türkiye aylık toplam ithalat değişimi (1998-2019).....48 |
| Şekil 5.6 | Türkiye aylık toplam ihracat değişimi (1998-2019).....48 |
| Şekil 5.7 | Türkiye aylık brüt elektrik talebi değişimi (1998-2019)49 |
| Şekil 5.8 | ÇKSYA yöntemi uygulama adımları54 |
| Şekil 5.9 | 1.12 numaralı ağın mimarisi57 |
| Şekil 5.10 | 1.12 numaralı ağın performans grafiği57 |

| | | |
|------------|---|----|
| Şekil 5.11 | 12.1 numaralı ağın regresyon grafiği | 58 |
| Şekil 5.12 | 12 aylık TÜFE tahmini gösterimi | 60 |
| Şekil 5.13 | 12 aylık TSÜE tahmini gösterimi | 61 |
| Şekil 5.14 | 12 aylık ithalat miktarı tahmini gösterimi..... | 62 |
| Şekil 5.15 | 12 aylık ihracat miktarı tahmini gösterimi | 63 |
| Şekil 6.1 | Şubat 2019-Ocak 2020 arasında elektrik tüketiminin tahmini..... | 65 |



ÇİZELGE LİSTESİ

| | Sayfa |
|---|-------|
| Çizelge 4.1 Nisan 2019 ayı kurulu santral adedi ve güç miktarı [58] | 40 |
| Çizelge 5.1 Aylık elektrik tahmini çalışmalarında kullanılan değişkenler | 44 |
| Çizelge 5.2 Uygulamada kullanılan değişkenlerin özellikleri | 44 |
| Çizelge 5.3 MATLAB'ın Levenberg Marquardt algoritması için varsayılan değerleri.. | 53 |
| Çizelge 5.4 ÇKYSA'da yapılan denemeler | 55 |
| Çizelge 5.5 ÇKYSA'da yapılan denemelerin sonuçları..... | 56 |
| Çizelge 5.6 12.1 numaralı ağın performans göstergeleri | 58 |
| Çizelge 5.7 1970-2018 yılları arası sıcaklık ve yağış miktarı ortalamaları | 59 |
| Çizelge 5.8 TÜFE tahmini için eğitim parametreleri | 60 |
| Çizelge 5.9 TSÜE tahmini için eğitim parametreleri | 61 |
| Çizelge 5.10 İthalat miktarı tahmini için eğitim parametreleri | 62 |
| Çizelge 5.11 İhracat miktarı tahmini için eğitim parametreleri | 63 |
| Çizelge 5.12 Girdi değişkenleri 12 aylık tahmin değerleri | 64 |
| Çizelge 6.1 12 aylık elektrik tüketim miktarı tahmini | 65 |
| Çizelge 6.2 6 bağımsız değişkenli regresyon analizi sonuçları..... | 66 |
| Çizelge 6.3 4 bağımsız değişkenli regresyon analizi sonuçları..... | 66 |
| Çizelge 6.4 MAPE kriterinin tahmin gücü [75] | 68 |
| Çizelge 6.5 Performans kriterleri karşılaştırılması..... | 68 |

TÜRKİYE’NİN AYLIK ELEKTRİK TÜKETİMİNİN YAPAY SİNİR AĞLARIYLA TAHMİNİ

Ezgi POLAT

Endüstri Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. Nezir AYDIN

Nüfusun hızla artması, ekonomik gelişmeler ve sanayileşme faaliyetleri elektrik enerjisine ihtiyacı günden güne arttırmaktadır. Enerji kaynaklarının giderek azalması, elektriğin sürdürülebilir arzının sağlanması için tehlike oluşturmaktadır. Türkiye’de birincil enerji kaynaklarının çoğu ithal edilmekte ve bu yüzden elektrik üretim faaliyetlerinin planlı şekilde yürütülmesi önem teşkil etmektedir.

Çalışmada, Türkiye’nin aylık elektrik tüketimi, ekonomik değişkenler ve hava durumu değişkenleri bir arada kullanılarak tahmin edilmeye çalışılmıştır. Tahmin yöntemi olarak, istatistiksel tahmin yöntemlerine güçlü bir alternatif olan Yapay Sinir Ağları tercih edilmiştir.

Tezin ilk bölümünde elektrik tahminiyle ilgili literatür araştırılmış ve kullanılacak yöntemin detaylarına bu bilgiler ışığında karar verilmiştir. Sonrasında Yapay Sinir Ağlarının teorik altyapısı ve Türkiye’nin elektrik enerjisi genel görünümü incelenmiştir. Uygulama kısmında Çok Katmanlı Yapay Sinir Ağıyla Türkiye’nin Şubat 2019 ve Ocak 2020 tarihleri arasındaki aylık elektrik tüketim tahmin edilmiştir.

Anahtar kelimeler: Elektrik tüketimi, Yapay sinir ağları, Çok kriterli yapay sinir ağı, Tekrarlı sinir ağı

**PREDICTION OF TURKEY’S MONTHLY ELECTRICITY CONSUMPTION
USING ARTIFICIAL NEURAL NETWORKS**

Ezgi POLAT

Department of Industrial Engineering

MSc. Thesis

Adviser: Assoc. Prof. Dr. Nezir AYDIN

Rapid increase in population, economic developments and industrialization activities increase the need for electric energy day to day. The consistent decline in energy resources poses hazard for sustainable supply of electricity. Turkey imports most of the primary energy sources therefore it is significant to conduct planned electricity generation activities.

In this study, monthly electricity consumption, economic variables and weather conditions of Turkey has been studied together to make an estimation. As an estimation method, Artificial Neural Networks, which are a powerful alternative to statistical estimation methods, are preferred.

In the first part of the thesis, literature about electricity estimation is searched and the details of the method to be used are determined in light of this information. In the second part of the thesis, theoretical background of Artificial Neural Networks and the general overview of electrical energy in Turkey were examined. In practice, the estimation was made with Multilayer Perceptron and monthly electricity consumption of Turkey between February 2019 and January 2020 are estimated.

Keywords: Electricity consumption, Artificial neural networks, Multilayer perceptron, Recurrent networks

1.1 Literatür Özeti

Elektrik günlük hayatımızı sürdürebilmemiz, üretim ve hizmet faaliyetlerinin devam ettirilebilmesi için hayati öneme sahip bir enerji kaynağıdır. Teknolojik gelişmeler, nüfusun giderek artması, hayat standartlarının günden güne yükselmesi sonucu insanların elektriğe ihtiyacı da giderek artmıştır.

Elektrik üretiminin planlanması genel olarak, olası kesintilerin önüne geçmek, devletlerin bu konuda ayıracağı bütçenin belirlenmesi, doğalgaz gibi birincil enerji kaynaklarının depolama işlemlerinin planlanması, elektrik üretim santrallerinde yapılacak bakım faaliyetlerinin planlanması gibi konular için önemlidir.

Elektrik talep yönetimi konusunda tahmin çalışmaları 3 ana alana odaklanmaktadır: Elektrik tüketimi, elektrik üretimi ve elektrik fiyat tahmini [1]. Bu 3 alanda doğru tahmin yapılması operasyonların ve güç sistemlerinin planlanmasında önemlidir. Doğru planlama yapılmasıyla elektrik üretiminde verimlilik ve sürdürülebilirlik sağlanabilmektedir [2].

Literatürdeki çalışmalarda elektrik talep tahmini 3 farklı zaman ufkunda değerlendirilir. Kısa Vadeli Yük Tahmin (KVYT), 24 saate kadar tahmin yapılması için kullanılır. Bu tahminle üretim sürecindeki saatlik değişim, saatlik üretim, birim taahhüt edilen elektriğin takibi gibi konular planlanır ve sistem güvenliği sağlanmış olur [1]. 1 günden 1 yıl sonrasına kadar tahmin etmeyi sağlayan tahmin ufkuna Orta Vadeli Yük Tahmini (OVYT) denir. Bu tahmin bakım planlama, yakıt çizelgeleme, su depolama faaliyetleri için önemlidir. Ayrıca OVYT'ye, birincil enerji ihtiyacı ve pik dönem yük değerlerinin tahmini

için ihtiyaç duyulur. Doğru bir OVYT ile yakıt gereksinimlerinin planlanması ve bakıma- arıza nedeniyle sistem bileşenlerinin kullanılmaması durumunun planlanması kontrollü bir şekilde yapılır. Uzun Vadeli Yük Tahmin (UVYT), 1 yıldan 10 yıl sonrasının tahminine kadar bir zaman ufku içerir. Bu tahminle, iletim, dağıtım ve üretim faaliyetlerinin planlanması kontrol altına alınır [3].

Literatüre bakıldığında OVYT üzerine çalışmalar kısa ve uzun vadeliye göre daha az yer tutmaktadır. OVYT çalışmaları, talebin modellenmesi açısından 2 farklı gruba ayrılır. Birinci grup, ekonomik analiz, yönetim ve uzun dönemli planlama ve enerji politikalarına odaklanır. Bu gruptaki çalışmalar sosyoekonomik durumun değişmesinin enerji talebinde de değişime yol açtığını göstermektedir. Araştırmacılar modelleme çalışmalarında değişken olarak Gayri Safi Milli Hasıla (GSMH), Ortalama Ücret, Tüketici Fiyat Endeksi (TÜFE), Kambiyo Oranı gibi ekonomik göstergeleri; Bağlantı Sayıları, Abone Bilgileri gibi elektrik altyapı göstergelerini ve Hava Durumu göstergelerini kullanmıştır. İkinci yaklaşım ise Geçmiş Yük Değerlerini ve Hava Durumu değişkenlerini (sıcaklık, nem, güneşlenme oranı, rüzgâr hızı vb.) kullanır. Bu model yaklaşımı stabil ekonomiler için daha uygundur [4].

Literatür çalışmaları araştırıldığında elektrik tüketimin tahmininde birçok yöntem kullanılmıştır. Bunları aşağıdaki başlıklar altında toplayabiliriz.

- Çoklu Regresyon Yöntemi,
- Üssel Düzeltme Yöntemi,
- Tekrarlı Ağırlıklandırılmalı En Küçük Kareler Yöntemi,
- Stokastik Zaman Serileri Yöntemi
- Adaptif Yük Tahmini Metodu,
- Bulanık Mantık Yöntemleri,
- Yapay Sinir Ağları (YSA),
- Bilgi Tabanlı Uzman Sistemler [5].

Yapay Sinir Ağları, birçok özelliğiyle tahmin yöntemleri içinde öne çıkmaktadır. Geleneksel tahmin yöntemleriyle karşılaştırıldığında veri güdümlü ve özuyarlanabilen bir

sistemdir. YSA veri örneklerinden öğrenir ve veriler arasındaki normalde güç algılanan, tanımlanması zor fonksiyonel ilişkiyi yakalar. Bu bağlamda YSA, çok değişkenli doğrusal ve parametrik olmayan bir istatistik yöntemi olarak görülebilir. YSA'nın bir diğer özelliği de genelleştirme yeteneğidir. Örnek verilerle eğitim sürecinden sonra YSA, daha önceden görmediği örnekler için doğru çıkarsama yapabilir. Bunun dışında YSA fonksiyon kestirimi için kullanılabilir. Ağ istenilen doğruluk seviyesi için sürekli bir fonksiyona yakınsatır. YSA, lineer olmayan bir ağıdır. Tahmin, uzun bir süredir lineer istatistiğin çalışma alanı olmuş ve geleneksel zaman serisi tahmin yöntemleriyle, zaman serisinin lineer davranış gösterdiği farz edilerek hesaplama yapılmıştır. Lineer modeller kolay anlaşılır, detaylı analiz edilebilir, açıklanabilir ve kolay uygulanabilir olduklarından avantaj sağlamaktadır. Fakat tüm bu avantajlarının yanında lineer olmayan mekanizmalar için kullanımı uygun değildir. YSA ise girdi ve çıktı verileri arasında herhangi bir ilişki bilgisine sahip olmadan lineer olmayan sistemi tanımlayabilmektedir [5].

1.2 Tezin Amacı

Elektrik kullanımı dünya genelinde, yaşam standartlarının artması, nüfusun çoğalması, teknoloji ve endüstri alanındaki gelişmelerle birlikte hızlı bir şekilde artmaktadır. Toplumların tüketme istekleri gündün güne artarken; yer yüzü kaynakları da hızla azalmaktadır. Bu yüzden enerji kaynaklarının kullanımı kontrollü bir şekilde yapılmalıdır. Günlük hayatın çoğu alanında kullanılan elektrik enerjisi de hayat kalitesinin aynı ölçüde kalması için planlı bir şekilde üretilmeli ve tüketilmelidir.

Tezin çalışma konusunu Türkiye'nin Aylık Elektrik Tüketiminin Tahmini oluşturmaktadır. Türkiye enerji kaynakları bakımından ülke dışı kaynaklara bağımlıdır. Bu yüzden enerjinin kullanımı ve dolaylı olarak elektrik üretiminin planlanması elektrik arz güvenliği için önem teşkil etmektedir. Doğru planlamanın yapılabilmesi için Yapay Sinir Ağları Yönteminin yüksek güvenilirlikte sonuç vereceği düşünülmüş ve farklı ağ mimarileriyle tahmin çalışmaları yapılmıştır.

Genel olarak, yapılan çalışma sonucunda elektrik enerjisi sektörü ve tahmin yöntemleriyle ilgili kapsamlı bir literatür araştırması yapmak ve yüksek performanslı bir aylık elektrik tüketim tahmin modeli sunmak hedeflenmiştir.

1.3 Bulgular ve Orijinal Katkı

Tez konusunu, literatürde üzerinde uzun dönem ve kısa dönem elektrik tahminine göre daha az çalışma yapılmış olan aylık elektrik tüketim tahmini oluşturmaktadır ve tahmin Yapay Sinir Ağları Yöntemiyle modellenmiştir. Bu konuda yapılan çalışmalarda iklimsel değişkenlerle ekonomik değişkenlerin bir arada kullanıldığı çalışma sayısı çok azdır. Çalışmada bu yüzden bu 2 değişken tipinin birlikte kullanılması amaçlanmıştır.

Tahmin modeli oluştururken birçok farklı sinir ağı mimarisi sistematik bir şekilde denenmiştir ve en iyi sonucu veren ağ tahmin modeli olarak kullanılmıştır.

Tahmin modeli, geleneksel tahmin modellerinden biri olan çok değişkenli doğrusal regresyon modeliyle karşılaştırılmış ve YSA yöntemi daha iyi sonuç vermiştir.

ELEKTRİK TÜKETİM TAHMİNİ LİTERATÜR ARAŞTIRMASI

Saab ve arkadaşları (2001) çalışmalarında tek değişkenli modelleme yöntemiyle Lübnan'ın aylık elektrik enerjisi tüketimini tahmin etmeyi amaçlamıştır. Makalede, Otoregresif (AR), Otoregresif Entegre Hareketli Ortalama (ARIMA) ve yüksek geçirgen filtreli AR (1) konfigürasyonu olmak üzere üç farklı tek değişkenli yöntem kullanılmıştır. Çalışmanın sonunda yüksek geçirgen filtreli AR (1) konfigürasyonu diğer yöntemlere göre üstünlük sağlamıştır [6].

Yumurtacı ve Asmaz (2004), Türkiye'nin 1980-2050 yılları arası enerji talebini, hidro ve termal enerji üretimini, kişi başına düşen nüfus ve enerji tüketim değerlerini kullanarak istatistiksel yöntemlerle tahmin etmiştir [7].

Yalçınöz ve Eminoğlu (2005) makalelerinde güç dağıtım sistemlerinde kısa vadeli pik yük tahmini, kısa vadeli toplam yük tahmini ve orta vadeli aylık yük tahmini için ileri beslemeli sinir ağı modelini kullanmıştır. Çalışma Niğde ili için temin edilen gerçek verilerle yapılmıştır. İki gizli katmanlı YSA modeli aylık yük tahmini ve pik yük tahmini için daha iyi sonuç vermiştir. Tüm modellerin, hata oranları göz önünde bulundurulduğunda gerçek hayata uygulanabilir olduğu görülmüştür [8].

Demirören ve Ceylan (2006) makalelerinde, Çok Katmanlı Yapay Sinir Ağı (ÇKYSA) yöntemini kısa dönemli yük tahmininde kullanmıştır. Araştırmada Türkiye'nin Orta Anadolu Bölgesindeki 2002-2003 yılları arasındaki gerçek yük ve sıcaklık değerleri kullanılmıştır. Tahmin modelinde maksimum sıcaklık, minimum sıcaklık ve gün tipi faktörlerinden faydalanılmıştır. Tahmin sonuçları regresyon yöntemiyle karşılaştırıldığında ÇKYSA yöntemi daha iyi sonuç vermiştir [9].

Pao (2006) çalışmasında, milli gelir, nüfus, gayri safi milli hasıla ve tüketici fiyat endeksi olmak üzere dört ekonomik faktörün Tayvan'da elektrik tüketimi üzerindeki etkisini araştırmak için Yapay Sinir Ağı yöntemini, doğrusal ve doğrusal olmayan istatistiksel modelleri kullanmış ve ekonomik tahmin modeli geliştirmiştir. Çalışma sonucunda, çok miktarda veri olması durumunda Dışsal Değişken Kaynaklı Otoregresif Hareketli Ortalama (ARMAX) modelinin uygun olduğu, doğrusal modellerin veri miktarına bakılmaksızın dip ve pik noktaların kestiriminde zayıf olduğu, YSA'nın tahmin performansının diğer doğrusal modellerden daha yüksek olduğu gözlenmiştir [10]

Ediger ve Akar (2006), Otoregresif Hareketli Ortalama (ARMA) ve Mevsimsel Hareketli Ortalama yöntemlerini kullanarak Türkiye'nin 2005'ten 2020'ye kadar olan birincil elektrik talebini tahmin etmiştir [11].

Akay ve Atak (2006), Yuvarlanma Mekanizmalı Gri Tahmin Yöntemini kullanarak Türkiye'nin toplam ve endüstriyel elektrik talebini tahmin etmiştir. Tüketim tahmini, Enerji ve Tabii Kaynaklar Bakanlığı'nın (ETKB) öngördüğü sonuçlardan hem toplam tüketimde hem de endüstriyel tüketimde daha iyi sonuç vermiştir [12].

Ghiassi vd. (2006) makalelerinde, orta vadeli elektrik yükü tahmini için Dinamik Yapay Sinir Ağı Modeli geliştirmiştir. Çalışmada gelecekteki elektrik taleplerini tahmin etmek için geçmiş aylara ait sistem yüklerini kullanan bir model sunulmuştur. Ayrıca hava durumu verilerinin dahil edilmesinin yük tahmini doğruluğunu arttırdığı gösterilmiştir. Ancak bu tür modellerde elde edilmesi çok zor olan doğru hava tahminleri yapılması gerekmektedir. Bu yüzden hava durumu değişkenleri kullanılmadan alternatif mevsimsel modeller geliştirilmiştir. Tüm modeller Tayvan Enerji Kurumu'ndan sağlanan gerçek sistem yükü verileri kullanılarak doğrulanmıştır. Hem yıllık hem de mevsimsel modeller, ortalama %1'in altında Ortalama Mutlak Yüzde Hata (MAPE) değerleri üretmiş ve orta vadeli yükleri tahmin etmede etkin oldukları kanıtlanmıştır. Son olarak, sonuçlar çoklu doğrusal regresyon (MLR) ve ARIMA modelleriyle karşılaştırılmıştır [13].

Gonzalez-Romera vd. (2006) çalışmalarında, aylık elektrik talep tahmininde zaman serisini trend ve dalgalanma olarak iki ayrı seriye bölmüştür. Daha sonra bu seriler iki farklı yapay sinir ağı modelinde eğitilmiştir. Önerilen teknik, İspanya'da aylık elektrik talebinin tahmin edilmesinde kullanılmıştır. Elde edilen sonuçlar, verilerde herhangi bir

ön işlem yapmadan kullanılan YSA'ya ve ARIMA yöntemine göre daha iyi sonuç vermiştir [14].

Ucenic ve George (2006) çalışmalarında Bulanık Yapay Sinir Ağı modeliyle orta vadeli elektrik yükü tahmini yapmıştır. Çalışma sonuçları AR ve ARMA modelleriyle karşılaştırılmış ve önerilen yöntem bu iki yöntemden daha iyi sonuç vermiştir [15].

Azadeh vd. (2007), Yapay Sinir Ağları ve Genetik Algoritma (GA) yöntemlerini entegre ederek elektrik enerjisi tüketim tahmini yapmıştır. İran'ın 1981-2005 yılları arasında tarım sektöründeki enerji tüketimi, çalışmanın konusunu oluşturmuştur. Tahmin yöntemi olarak öncelikle Genetik Algoritma ve Regresyon Analizi kullanılmış; değişken olarak fiyat, katma değer, müşteri sayısı ve önceki yıllardaki enerji tüketim değerleri kullanılmıştır. Genetik Algoritma yöntemiyle yapılan tahminlerdeki hata değeri, regresyon yöntemiyle karşılaştırıldığında, önemli ölçüde küçük çıkmıştır. Sonrasında uygulanan GA ve YSA hibrit yöntemi daha iyi tahmin yaparak ve düşük MAPE değeri sağlayarak regresyon analizine üstünlük kurmuştur [16].

Toksarı (2007), enerji talebi modeli için Karınca Algoritması Optimizasyonunu kullanmıştır. Bu algoritma, karıncaların toplanma davranışlarından esinlenerek problemin optimizasyonunu sağlamaktadır. Enerji talebi tahmini için, nüfus, gayri safi yurtiçi hasıla, ithalat ve ihracat değerleri bağımsız değişken olarak kullanılmıştır. Çalışmada önerilen tüm denklemler doğrusal ve kuadrattir. Kuadratik tahmin modeli, ekonomik göstergelerdeki dalgalanmalardan dolayı daha iyi bir çözüm sağlamıştır. Tahmin sonuçları ETKB'nin tahminleriyle karşılaştırıldığında daha iyi sonuç vermiştir [17].

Al-Shobaki ve Mohsen (2008) çalışmalarında Ürdün'ün elektrik üretim ve tüketim tahmini için bir tahmin modeli geliştirmiştir. Ülkenin ulusal elektrik kurumu daha önceki yıllarda yük ve talep seviyesini tahmin ederken trend dinamiklerini hesaba katan regresyon modellerinden yararlanmaktaydı. Bu modellerle yıllık bazda sonuçlar üretiliyor; talep seviyelerindeki aylık bazda değişkenlik açıklanamıyordu. Bu çalışma, üretilen ve tüketilen enerji verilerine dayanan iki model sunmuştur. Modellerde trend, mevsimsellik ve döngü dinamikleri göz önünde bulundurulmuştur. Her iki model de ülkenin ulusal elektrik kurumunun oluşturduğu modelle karşılaştırılmış ve ihtiyaç duyulandan daha yüksek seviyelerde (%5,25 daha fazla) elektrik enerjisi üretilmekte olduğu gözlenmiştir [18].

Ghosh (2008) çalışmasında, Hindistan'ın kuzey bölgesindeki aylık pik elektrik talebini Nisan 2000 ve Şubat 2007 tarihleri arasındaki verileri kullanarak, tek değişkenli zaman serileri yöntemlerinden Mevsimsel Otoresif Entegre Hareketli Ortalama (SARIMA) ve Holt-Winters-Çarpımsal Üstel Düzleştirme yöntemleriyle tahmin etmiştir. Tahmin sonucunda MSARIMA yöntemi Üstel Düzleştirme yönteminden, ortalama karekök hatası, ortalama mutlak hata ve ortalama mutlak yüzde hata kriterleri açısından daha iyi sonuç vermiştir [19].

Gonzalez-Romera vd. (2008) çalışmalarında İspanya'nın aylık elektrik talep serisinin periyodik davranışlarını incelemiştir. Periyodik davranış Fourier serisiyle, trend ise Yapay Sinir Ağlarıyla tahmin edilmiştir. Yöntem, ARIMA ve Yapay Sinir Ağının kullanıldığı sistemlerle karşılaştırıldığında %2'den küçük çıkan MAPE değeriyle daha iyi bir sonuç vermiştir [20].

İsmail vd. (2008) çalışmalarında hava durumu değişkenleri ve tatil günlerinin Malezya'daki günlük ve aylık elektrik talebi üzerindeki etkisini incelemiştir. Talep tahmini için çoklu regresyon metodu önerilmiştir. Çalışmada MAPE değeri yaklaşık %1,71 olarak hesaplanmıştır [21].

Ekonomou (2009), Yapay Sinir Ağları yöntemini, Yunanistan'ın uzun dönemli elektrik tüketiminin tahmin edilmesinde kullanmıştır. Geliştirilen Çok Katmanlı Yapay Sinir Ağı modeliyle 2005-2008, 2010, 2012 ve 2015 yılları enerji tüketimi tahmin edilmiştir. 2005-2008 yılları arasında YSA ile tahmin sonuçları, Lineer Regresyon (LR) ve Destek Vektör Makinesi (SVM) yöntemleriyle karşılaştırıldığında gerçek enerji tüketim değerlerine daha yakın sonuçlar vermiştir [22].

Geem ve Roper (2009), Güney Kore'nin enerji talebi tahmini için Yapay Sinir Ağları Yöntemini önermiştir. Geliştirilen modelde gayrisafi yurtiçi hasıla, nüfus, ithalat ve ihracat miktarları bağımsız değişken olarak belirlenmiştir. Önerilen model, lineer regresyon ve üssel modelden Kök Ortalama Kare Hatası açısından değerlendirildiğinde daha iyi bir tahmin sonucu vermiştir [23].

Kavaklıoğlu vd. (2009), Türkiye'nin enerji tüketimini tahmin etmek ve modellemek için Yapay Sinir Ağları Yöntemini kullanmıştır. Yapay Sinir Ağı modeli olarak Geri Beslemeli öğrenme algoritmasına sahip Çok Katmanlı Yapay Sinir Ağı kullanılmıştır. Elektrik

tüketimi, nüfus, gayrisafi yurtiçi hasıla, ithalat ve ihracat değerleri gibi göstergeler tahmin modeli değişkenleri olarak kullanılmıştır. 1975 ve 2006 yılları arasındaki veriler kullanılarak Türkiye'nin 2027'ye kadar elektrik tüketimi tahmin edilmiştir [24].

Çınar vd. (2009), Türkiye'nin yıllık hidroelektrik enerjisi üretiminin tahmininde Yapay Sinir Ağları metodunu kullanmıştır. Kurulan modele Genetik Algoritma metodu eklenerek tahmin değerlerinde iyileştirilme yapılmıştır. Hibrit modelde, klasik YSA yöntemine göre test hatası önemli ölçüde azalmıştır [25].

Garcia ve Mate (2010) makalelerinde, İspanya'nın 2 yıllık aylık elektrik tüketim talebini tahmin edebilmek için Vektör Otoregresif Tahmin Modeliyle, Çok Katmanlı Sinir Ağları Modelini karşılaştırmıştır [26].

Ohtsuka ve arkadaşları (2010) makalelerinde, Japonya'daki bölgesel elektrik talebi ve bölgeler arasındaki konumsal etkileşimi Bayes yaklaşımıyla incelemiştir. Japonya'nın elektrik talebinin özelliklerini belirlemek için konumsal bir otoregresif ARMA modeli önerilmiş ve modelin parametrelerini tahmin etmek için Markov Zinciri Monte Carlo yöntemi kullanılmıştır [27].

Azadeh vd. (2010) çalışmalarında, Çin ve İran gibi gelişmekte olan ülkelerde, elektrik tüketimindeki mevsimsel ve aylık değişimlere yönelik talebi tahmin etmek için entegre bir bulanık regresyon ve zaman serisi yöntemi kullanmıştır. Sadece bulanık regresyon veya zaman serileri ile elektrik tüketiminin belirsiz davranışlarını modellemek zordur; bu tip durumlarda entegre yöntemler daha iyi sonuç verebilir. Çalışmada ilk olarak, zaman serisi modeli tahmin modelleri arasından seçilmiştir. Yöntem olarak, ARMA modeli seçilmiş, doğrusal olmayan durumun belirlenmesi için McLeod-Li testi uygulanmıştır. Bu test sonucunda doğrusal olmayan koşul karşılanmış ve doğrusal olmayan zaman serisi modeli tercihi doğrulanmıştır. Sonrasında Granger-Newbold testiyle bulanık regresyon ve zaman serisi entegre modelinin seçilmesine karar verilmiştir. Çalışmada, İran'ın Mart 1994 – Ocak 2005 arasındaki aylık elektrik tüketim verileri kullanılmıştır. Önerilen algoritmanın üstünlüğü Genetik Algoritma ve Yapay Sinir Ağları gibi yöntemlerin sonuçlarıyla karşılaştırılarak gösterilmiştir [28].

Çunkaş ve Taşkıran (2011), çalışmalarında Genetik Algoritmaları kullanarak Türkiye'nin enerji tüketimini 2008 ve 2020 yılları arasında tahmin etmiştir. Sonuçlar Regresyon

yöntemi sonuçları ve ETKB'nin tahmin sonuçlarıyla karşılaştırılmıştır. GA, diğer yöntemlere göre daha iyi sonuç vermiştir [29].

Suganthi ve Samuel (2011), enerji talebi tahmini için kullanılan tahmin modellerini incelemiştir. Çalışmada geleneksel model olarak zaman serileri, Regresyon, ARIMA gibi yöntemler; esnek hesaplama modeli olarak Bulanık Mantık, Genetik Algoritma, Yapay Sinir Ağları gibi yöntemler analiz edilmiş ve karşılaştırılmıştır [30].

Yu ve Zhu (2011), Çin'in enerji talebi tahmini için Genetik Algoritma ve Parçacık Sürü Optimizasyonunun kullanıldığı hibrit bir tahmin modeli önermiştir. Enerji talebini etkileyen faktörler, gayrisafi yurtiçi hasıla, nüfus, ekonomik yapı, kentleşme oranı, enerji yapısı olarak belirlenmiştir. Çalışma sonucunda, 2015 yılında Çin'in enerji talebinin 4,48 milyar ton-kömür eşdeğeri olacağı tahmin edilmiştir. Ayrıca, önerilen tahmin yöntemi, GA, PSO, karınca kolonisi optimizasyonu ve çoklu doğrusal regresyon gibi tekli optimizasyon yöntemlerine kıyasla üstünlük göstermiştir [31].

Bilgili vd. (2011), Yapay Sinir Ağları, Lineer Regresyon ve Lineer Olmayan Regresyon (NLR) Yöntemlerini kullanarak Türkiye'nin konut ve sanayi sektöründeki elektrik tüketimini tahmin etmiştir. Kurulu kapasite, toplam elektrik üretimi, nüfus ve toplam abone sayısı bağımsız değişken olarak seçilmiştir. Gelecekteki elektrik tüketimi tahmini için iki farklı senaryo önerilmiştir. LR, NLR ve YSA'dan elde edilen sonuçlar, Enerji ve Tabii Kaynaklar Bakanlığı'nın elektrik tüketim öngörüsü ve literatürdeki sonuçlarla karşılaştırılmıştır. Karşılaştırma sonuçları YSA'nın LR ve NLR'den daha iyi performans değerlerine sahip olduğunu göstermiştir [32].

Hong (2011) çalışmasında, Mevsimsel Tekrarlayan Destek Vektör Regresyon modeliyle Kaotik Yapay Arı Kolonisi Algoritmasını entegre ederek elektrik talebini tahmin etmiştir. Modelin ARIMA'yla karşılaştırıldığında daha iyi sonuç verdiği görülmüştür [33].

Chang vd. (2011) çalışmalarında, Evrimsel Ağırlıklandırılmış Bulanık Sinir Ağlarıyla Tayvan'ın aylık elektrik tüketim değerlerini tahmin etmiştir. Her bir faktörün farklı kurallar arasındaki önemini hesaplamak için ağırlıklandırılmış bir faktör kullanılarak Evrimsel Bulanık Sinir Ağı Yöntemi modifiye edilmiştir. Ek olarak, herhangi iki faktörün mesafesini farklı kurallar arasındaki benzerlik değerine transfer etmek için üssel bir transfer fonksiyonu kullanılmış; dolayısıyla farklı bir kural kümeleme yöntemi

geliştirilmiştir. Tayvan Enerji Kurumu tarafından belirlenmiş 7 faktör çalışmanın girdi verilerini oluşturmuş, bu tarihsel verilerle elektrik tüketimi tahmin edilmiştir. Sonuç olarak önerilen yöntem literatürde önerilen diğer yaklaşımlarla karşılaştırılmış, %6,43 MAPE değeriyle diğer yöntemlere göre daha iyi sonuç vermiştir [34].

Boltürk vd. (2012) çalışmalarında, bir Türk firmasının olası elektrik tüketiminin tahmini için 2 yıllık elektrik tüketim verisini incelemiştir. Tahmin yöntemi olarak Singh'in Bulanık Zaman Serileri Metodu seçilmiştir [1].

Oğcu vd. (2012) çalışmalarında 2010-2011 yılları arasında elektrik çıktısını tahmin etmek için Destek Vektör Makinesi ve Yapay Sinir Ağları yöntemlerini kullanmıştır. Bu çalışmada, verilerin tahmin edilmesi için mevsimsel bir SVR modeli önerilmiştir. Çalışma sonucunda mevsimsel SVR modelinin YSA modelinden daha üstün olduğunu gözlenmiş ve yakın gelecekte Türkiye'de elektrik tüketiminin artacağına dair ampirik kanıtlar sağlanmıştır [35].

Uzlu vd. (2014), Yapay Sinir Ağlarıyla, Öğretme-Öğrenme Algoritmasını birlikte kullanarak Türkiye'deki enerji tüketimini değerlendirmiştir. Gayrisafi yurtiçi hasıla, nüfus, ithalat ve ihracat verileri bağımsız değişken olarak seçilmiştir. Bu hibrit modelle, klasik geri yayımlı YSA modeli, hata kriterleri açısından karşılaştırılmıştır. Önerilen modelin klasik YSA modeline göre daha iyi tahmin yaptığı görülmüştür. Modelin en iyi konfigürasyonu belirlendikten sonra 3 farklı senaryo için tahmin yapılmıştır. Tahmin sonuçları Enerji ve Tabii Kaynaklar Bakanlığı'nın tahmin değerleriyle karşılaştırılmış ve 2020 yılı için tüm senaryolarda daha düşük enerji tüketim tahmini yapılmıştır [36].

Toksarı (2015), çalışmasında Karınca Koloni Algoritması ve Tekrarlı Lokal Arama Algoritmasını kullanarak Türkiye'nin elektrik tüketimini tahmin etmiştir. Ekonomik gösterge olarak gayrisafi yurtiçi hasıla, nüfus, ithalat ve ihracat verileri kullanılmıştır. 1990-2013 yılları arasındaki veriler kullanılmış; 2014-2030 arasındaki tüketim değerleri tahmin edilmiştir [37].

Lee ve Hong (2015) makalelerinde aylık elektrik yükünü hibrit bir yöntemle tahmin etmiştir. Bu yöntem, dinamik ve bulanık zaman serileri yaklaşımını birleştirerek hane halkı, kamu, hizmet ve sanayi sektörlerine ayrı ayrı uygulanmıştır. Hibrit model, Seul

metropol bölgesine ait gerçek yük verileri ile test edilmiştir. Çalışmanın sonucunda tüm sektörler için yapılan tahminlerde mutlak hata değeri %3'ün altında hesaplanmıştır [38].

Vu ve arkadaşları (2015) çalışmalarında aylık elektrik tahmini için çoklu regresyon modeli geliştirmiş; çoklu doğrusallık ve geriye doğru eleme süreçlerini bir arada kullanmıştır. Çalışmada öncelikle, veri setindeki bağımsız değişkenlerle yüksek doğrusal ilişkiye sahip tahmin edici hariç tutularak açıklayıcı değişkenler arasındaki eşdoğrusallık azaltılmaya çalışılmıştır. Bir sonraki adımda, geriye doğru eliminasyon regresyon analiziyle değişkenlerin düşük önem seviyesine sahip katsayılı olanları kaldırılmıştır. Çalışmada Avustralya'nın Yeni Güney Galler eyaletindeki elektrik tüketimi verileri kullanılmıştır. Veri analizi sonucunda sıcaklık, nem ve yağışlı günler gibi iklim değişkenlerinin büyük ölçüde elektrik talebini etkilediği ortaya konmuştur. Önerilen model kullanılarak elde edilen aylık tahminler, gerçek taleplerle karşılaştırıldığında elde edilen hatalar kabul edilebilir sınırlarda çıkmıştır [39].

Çevik ve Çunkaş (2015) çalışmalarında, bulanık mantık ve Adaptif Nöro-Bulanık Çıkarım yöntemiyle (ANFIS) kısa vadeli elektrik yük tahmini yapmıştır. Öncelikle veriler analiz edilmiş ve hafta içi günleri sahip oldukları yük özelliklerine göre sınıflandırılmıştır. Daha sonra tarihsel veri, sıcaklık ve mevsim girdi olarak belirlenmiştir. Bulanık mantık ve ANFIS yönteminde ortalama mutlak hata yüzdesi sırasıyla 2,1 ve 1,85 olarak hesaplanmıştır [40].

Günay (2016), Türkiye'nin yıllık elektrik talebini Çoklu Lineer Regresyon ve Yapay Sinir Ağlarıyla modellemiştir. Bağımsız değişken olarak nüfus, kişi başına düşen gayrisafi yurtiçi hasıla, enflasyon yüzdesi, ortalama yaz sıcaklığı belirlenmiştir. Çalışmada 1975-2013 yılları arasındaki veriler kullanılmış, 2007-2013 yılları arası test edilmiş ve yapılan tahminlerde yüksek doğruluk yakalanmıştır [41].

Hamzaçebi vd. (2017) makalelerinde, Türkiye'nin aylık elektrik talebini tahmin etmiştir. Mevsimselliğin ve trendin etkilerini modellemek için dört farklı YSA modeli geliştirilmiş ve üstün olanı seçilmiştir. Ayrıca, seçilen YSA modeli, modelin kabul edilebilirliğini ve güvenilirliğini arttırmak için SARIMA modeli ile karşılaştırılmıştır. Performans ölçümlerine göre başarılı ve yüksek doğrulukta tahminler yapabilen YSA modeli ile 2015 ve 2018 yılları arasında Türkiye'nin aylık elektrik talebi öngörülmüştür [42].

YAPAY SİNİR AĞLARI

3.1 Yapay Sinir Ağlarının Tarihçesi

McCulloch and Pitts tarafından 1943 yılında biyolojik nöronlardan esinlenerek ilk matematiksel model oluşturulmuş ve Yapay Sinir Ağı kavramından ilk defa bahsedilmiştir [43].

1949 yılında Yapay Sinir Ağlarını eğitmek için ilk defa Hebb Kuralı ismi verilen bir yöntem önerilmiştir. Bu yöntem nöronların fizyolojik doğasıyla ilgili gözlemlere ve varsayımlara dayandırılmıştır [43].

Diğer birçok araştırmacı, biyolojik nöronlara dayanan matematiksel modellerin geliştirilmesine devam etmiş, sonuç olarak çok sayıda topoloji ve öğrenme algoritması üretilmiştir. 1957 ile 1958 yılları arasında Rosenblatt, tek katmanlı sinir ağının (Perceptron) temel modelini oluşturan "Mark I Perceptron" adlı ilk nörobilgisayarı geliştirmiştir. Perceptron Modeli basit örüntüleri tanıma kabiliyetiyle ilgi uyandırmıştır [43].

Widrow ve Hoff 1960'ta "Adaptive Linear Element" (ADALINE) adı verilen bir ağ geliştirilmiştir. Daha sonrasında "Multiple ADALINE" (MADALINE) modeli önerilmiştir. Bu ağlar diğer bir ismi Least Mean Square (LMS) yöntemi olan Delta Kuralıyla eğitilmiştir [43].

1969'da nörobilgisayarlar, Minsky ve Papert tarafından "Perceptrons: An Introduction to Computation Geometry" adlı klasik kitabın yayımlanmasıyla büyük bir gerileme yaşadı. Yazarlar, o zamana kadar ortaya atılan Perceptron ve ADALINE gibi tek katmanlı sinir ağlarının, XOR gibi çok temel mantıksal bir fonksiyonun girdi ve çıktısı arasındaki ilişkinin

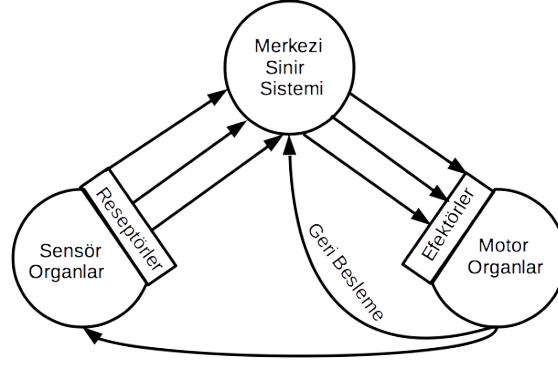
öğrenilmesinde sınırlı kaldığından bahsetmekteydi. Bu kitapta, lineer olmayan ayrılabilir sınıf örüntülerinin gruplandırılmasında Yapay Sinir Ağlarının yetersiz kaldığı vurgulanmıştır [43].

Bu yayının etkisiyle Yapay Sinir Ağları üzerine yapılan araştırmalar büyük ölçüde azalmıştır. 1974 yılında Werbos, ters gradyanları kullanarak tahmin algoritmalarının türetilmesi konusunda çalışmalar yapmıştır. Grossberg 1980’de, ART (Adaptive Resonance Theory) ağını geliştirmiştir. Kohonen tarafından 1982’de SOM (Self Organized Map) formülasyonu ortaya konulmuştur. Aynı yıl Hopfield Tekrarlı Ağları geliştirmiştir. Bu çalışma Yapay Sinir Ağlarına eski prestijini geri getirmiştir [43].

1980’lerin sonunda yukarıda bahsedilen araştırmaların da desteğiyle Yapay Sinir Ağlarına ilgi tekrar artmaya başladı. Yapay Sinir Ağlarının geri dönüşü, gelişmiş işleme ve bellek yeteneklerine sahip bilgisayarların gelişmesi, daha verimli optimizasyon algoritmalarının ve biyolojik sinir sistemiyle ilgili yeni bulguların ortaya çıkmasıyla desteklenmiştir. Bu dönemin en önemli eserlerinden biri, 1986’da yayımlanan Rumelhart, Hinton ve Williams’ın “Parallel Distributed Processing” adlı kitabı olmuştur. Bu yayın, birden fazla katmana sahip ağların ağırlık matrislerinin ayarlanmasını sağlayan bir algoritmaya ışık tutmuştur. Sonuç olarak, XOR mantıksal fonksiyonu problemi “geri yayılım” ismi verilen algoritmayla çözülmüştür [43].

3.2 Sinir Ağlarının Biyolojik Yapısı


İnsan beyni nöron ismi verilen yaklaşık 10^{11} adet işlemci elemandan oluşmaktadır. Nöronlar akson ve sinapslar arasındaki bağlantılar aracılığıyla birbirleriyle haberleşmektedirler. Her nöron diğer nöronlarla yaklaşık 10000 sinaps aracılığıyla bağlantı kurmaktadır. Nöronlar, kimyasal bir ortamda işlevlerini yerine getirirler. Bu nedenle beyni, biyokimyasal süreçlerle koşullandırılmış, yoğun bir elektriksel anahtarlama ağı olarak düşünebiliriz. Sinir ağları, karmaşık ara bağlantıları olan kompleks bir yapıya sahiptir. Sinir ağına giriş, duyuşal reseptörler tarafından sağlanır. Reseptörler, insan vücudundan veya dış çevreden gelen uyarıları elektrik impulslarına dönüştürerek sinir ağına iletir. Merkezi sinir sistemindeki bilgi işleme süreci sonunda, efektörler uyarıları, sistem çıktıları olarak algılanabilir tepkilere dönüştürür. Reseptörler, sinir ağı ve efektörlerden oluşan üçlü sistem Şekil 3.1’de görülmektedir [44].



Şekil 3.1 Merkezi sinir sistemi çalışma yapısı [44]

Şekilde görüldüğü gibi, önce bilgiler işlenir, değerlendirilir ve sonrasında merkezi sinir sisteminde saklanan bilgilerle karşılaştırılır. Gerekliğinde komutlar üretilir ve motor organlarına iletilir. Motor organlarının hareketlerinin doğruluğu geribildirim bağlantısıyla merkezi sinir sistemi tarafından denetlenmektedir. Hem iç hem de dış geribildirim, komutların uygulanmasını kontrol etmektedir. Görülebileceği gibi, genel sinir sistemi yapısı bir kapalı devre kontrol sisteminin özelliklerinin çoğuna sahiptir [44].

Tipik bir biyolojik nöron, Şekil 3.2'de gösterilen hücre gövdesi, akson ve çok sayıda dendritten oluşur. Dendritler, sinir hücrelerini gövdesini çevreleyen çok ince ipliksi yapıdadır. Aksonlar, diğer hücrelerin dendritlerine dokunan ince tüp şeklinde yapılardır. Tek bir nöronun aksonu diğer birçok nöronla sinaptik bağlantı oluşturur [45].



Şekil 3.2 Sinir hücresi yapısı [46]

Bir nöron, diğer nöronlardan çok fazla sayıda girdi alır. Girdi toplamı kritik seviyeyi aştığında, nöron hücre gövdesinden bir sonraki nörona veya diğer reseptörlere elektrik impulsunu boşaltır. Bu olaya depolarizasyon denir ve bu durumu nöronun tepkisiz kaldığı bir periyot izler. Akson ucu neredeyse bir sonraki nöronun dendritlerine veya hücre

gövdesine degecek yakınlıktadır. Bir elektrik sinyalinin bir nöron dan diğ erine aktarımı, nöron dan salın an ve reseptörlere bağ lanan nörotransmitör ismi verilen kimyasallar tarafından gerçekleştirilir. Bu bağ lantıya sinaps denir. Bir nöron dan gelen sinyalin ne zaman geç irileceğ i, mevcut nörotransmitterin miktarı, reseptörlerin sayısı ve düzeni, yeniden emilen nörotransmitter miktarı gibi parametrelere bağ lıdır [47].

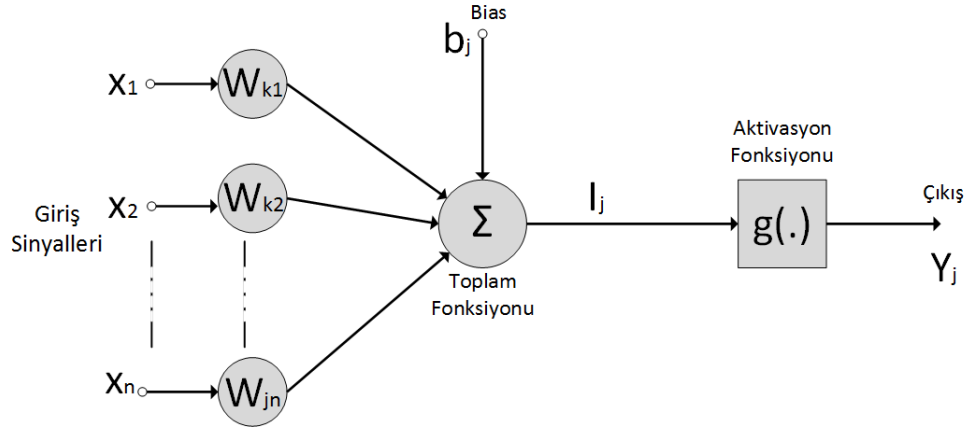
Yapay Sinir Ağ ları beynin karmaşıklığına ulaş amaz. Bununla birlikte, biyolojik ve yapay sinir ağ ları arasında iki temel benzerlik vardır. Birincisi, yapay nöronlar biyolojik nöronlardan çok daha basit olmasına rağmen, her ikisinin de temel elemanları benzer fonksiyonlara sahiptir. İkincisi, nöronlar arasındaki bağ lantıların ağ ın işlevini belirtmesidir [48].

Biyolojik nöronlar, elektrik devrelerine göre çok yavaş olsalar da beyin birçok görevi herhangi bir geleneksel bilgisayardan çok daha hızlı gerçekleştirebilmektedir. Bu biyolojik sinir ağ larının paralel çalışan yapısıyla ilgidir. Yapay Sinir Ağ ları da tüm nöronların aynı anda çalıştığı paralel yapıya sahiptir. Her ne kadar çoğ u Yapay Sinir Ağ ı, geleneksel bilgisayarlarda çalıştırılrsa da paralel yapıları, optik cihazlar ve paralel işlemciler için kullanılmaya daha uygundur [48].

3.3 Nöron Modeli

Nöron, Sinir Ağ ının çalışması için gerekli olan önemli bir bilgi işleme birimidir. Nöron, aşağıdaki 3 temel elemanla modellenir [49].

- 1- Sinaps Seti: Sinapsların her biri, ağırlık veya kendilerine ait etkinlikle karakterize edilirler. Biyolojik nörondaki sinapsın ağırlık değerinden farklı olarak, yapay bir nöronun sinaptik ağırlığı, negatif ve pozitif değerleri içeren bir aralıkta bulunabilir [49].
- 2- Toplayıcı: Nöronun sinaptik etkinliğiyle ağırlıklandırılan giriş sinyallerini toplamakla görevlidir. Toplayıcı lineer bir birleştirici görevi görür [49].
- 3- Aktivasyon Fonksiyonu: Nöronun çıkış genliğini izin verilen genlik aralığında bazı sonlu değerlere sınırlayan fonksiyondur [49].



Şekil 3.3 Basit bir nöron modeli [49]

Şekil 3.3'te gösterilen nöron modeli ayrıca harici olarak uygulanan bir bias değeri içermektedir. Bias değeri pozitifse, aktivasyon fonksiyonunun net girdisinin artırılmasında; negatifse azaltılmasında etkili olur.

(3.1) ve (3.2) denklem çiftiyle Şekil 3.3'te gösterilen nöronu matematiksel olarak ifade edebiliriz.


$$V_j = \sum_{i=1}^n W_{ji} \cdot x_i \quad (3.1)$$

$$Y_j = g(V_j + b_j) \quad (3.2)$$

x_1, x_2, \dots, x_n girdi sinyalleridir. $W_{j1}, W_{j2}, \dots, W_{jn}$ nöronların sırasıyla sinaptik ağırlıklarını oluşturur. b_j bias değerini gösterir. $g(.)$ aktivasyon fonksiyonunu formüle eder. Y_j ise nöronun çıktı sinyalidir. Bias kullanımı, nöron modelinde lineer birleştiricinin çıkış ucuna bir afin transformasyonunun uygulanması etkisine sahiptir.

$$I_j = V_j + b_j \quad (3.3)$$

Özellikle bias değerinin negatif veya pozitif olması durumuna göre, nöronun aktivasyon potansiyeli I_j ve lineer birleştirici çıktısı V_j arasındaki ilişki Şekil 3.2'de gösterildiği gibi değiştirilir. Bu dönüşümün bir sonucu olarak, $I_j - V_j$ grafiğinin artık orjinden geçmediği görülmektedir.



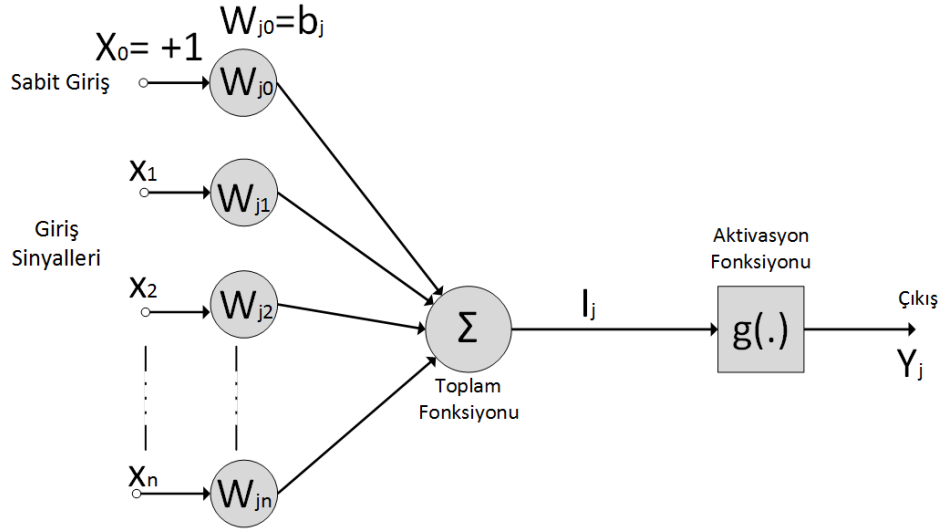
Şekil 3.4 $I_j - V_j$ grafiği [49]

Denklem (3.1), (3.2), (3.3)'in birleştirilmesiyle (3.4) ve (3.5) denklemlerini elde ederiz.

$$I_j = \sum_{i=0}^n W_{ji} \cdot x_i \quad (3.4)$$

$$Y_k = g(I_j) \quad (3.5)$$

Böylece (3.4) denkleminde girdisi $x_0 = +1$ ve ağırlığı $w_{j0} = b_j$ olan yeni bir sinaps eklenmiştir. Nöron modelini yeni formüle göre Şekil 3.5'teki gibi güncelleyebiliriz. Şekil 3.3 ve Şekil 3.5 görünüş olarak farklı; matematiksel olarak eşittir.



Şekil 3.5 Nöron modelinde bias değerinin girdi olarak gösterilmesi [49]

3.3.1 Aktivasyon Fonksiyonu

3.3.1.1 Kısmi Türevlenebilen Aktivasyon Fonksiyonları

Kısmi türevlenebilen aktivasyon fonksiyonları, birinci dereceden türevleri bulunmayan noktalara sahip fonksiyonlardır. Adım Fonksiyonu ve Bipolar Adım Fonksiyonu bu kategoriye girmektedir [43].

Adım Fonksiyonu: Adım Fonksiyonu, nöronun aktivasyon potansiyeli 0'a eşit veya büyük olduğu durumlarda 1 değerini; diğer durumda 0 değerini alır [43].

Bipolar Adım Fonksiyonu: Bu fonksiyonun sonucu, nöron aktivasyon potansiyeli sıfırdan büyük olduğunda 1 değeri; potansiyel 0 olduğunda 0 değeri ve potansiyel 0'dan küçük olduğunda -1 değerini alacaktır [43].


3.3.1.2 Türevlenebilen Aktivasyon Fonksiyonları

Türevlenebilen aktivasyon fonksiyonları, tanım kümesi içindeki tüm noktalarda birinci dereceden türevleri alınabilen fonksiyonlardır. Lojistik Fonksiyonu, Hiperbolik Tanjant Fonksiyonu ve Lineer Fonksiyon bu fonksiyon kategorisine girmektedir [43].

Lojistik Fonksiyonu: Lojistik fonksiyonu tarafından üretilen çıktı, her zaman 0 ile 1 arasında gerçek değerler almaktadır. Matematiksel ifadesi (3.6) denkleminde gösterilmiştir:

$$g(x) = \frac{1}{1+e^{-\beta x}} \quad (3.6)$$

β , fonksiyonun bükülme noktasındaki eğimiyle ilişkili olan sabit bir değerdir. Eğim parametresi β değiştiğinde, lojistik fonksiyonunun davranışındaki değişim Şekil 3.6'da görülmektedir. β değeri arttıkça fonksiyon adım fonksiyonuna benzemektedir. Öte yandan adım fonksiyonundan farklı olarak lojistik fonksiyonu tanım kümesindeki tüm noktalarda türevlenebilmektedir [43].




Şekil 3.6 Lojistik fonksiyonunun β 'ya göre değişimi [43]

Hiperbolik Tanjant Fonksiyonu: Fonksiyonun çıktısı lojistik fonksiyonundan farklı olarak her zaman -1 ile 1 arasında değerler alır. Matematiksel ifadesi (3.7) denkleminde gösterilmektedir:

$$g(x) = \frac{1-e^{-\beta \cdot x}}{1+e^{-\beta \cdot x}} \quad (3.7)$$

β , hiperbolik tanjant fonksiyonunun bükülme noktasındaki eğimiyle ilişkili olan sabit bir değerdir. Eğim parametresi β değiştiğinde, lojistik fonksiyonunun davranışındaki değişim Şekil 3.7'de görülmektedir. β değeri arttıkça fonksiyon bipolar adım fonksiyonuna benzemektedir. Öte yandan bipolar adım fonksiyonundan farklı olarak lojistik fonksiyonu tanım kümesindeki tüm noktalarda türevlenebilmektedir [43].




Şekil 3.7 Hiperbolik tanjant fonksiyonunun β 'ya göre değişimi [43]

Lineer Fonksiyon: Doğrusal aktivasyon fonksiyonu, aktivasyon potansiyeline eşit çıktılar üretir.

$$g(x) = x$$

(3.8)



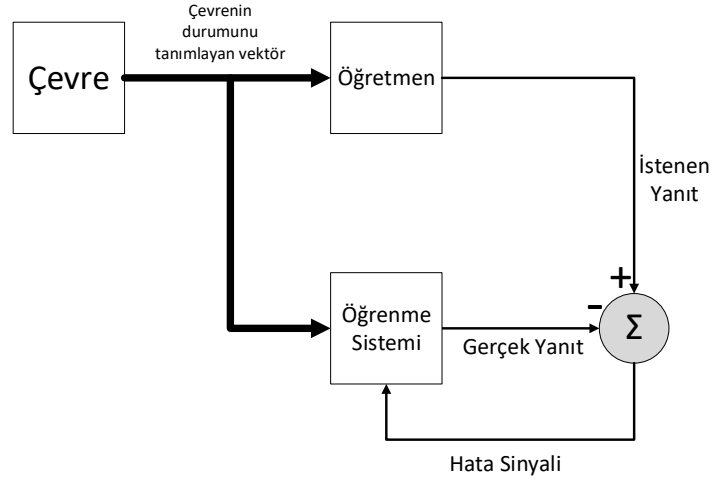
Şekil 3.8 Lineer fonksiyon grafiği [43]

3.4 Yapay Sinir Ağlarında Öğrenme Modelleri

Tıpkı insanın kendi çevresinden farklı yollarla bilgiyi öğrenebilmesi gibi Yapay Sinir Ağları da farklı öğrenme metotları kullanmaktadır. Genel anlamda öğrenme proseslerini Öğretmenli Öğrenme ve Öğretmensiz Öğrenme olarak kategorize edebiliriz. Öğretmensiz Öğrenme de Takviyeli Öğrenme ve Denetimli Öğrenme olarak alt kategorilere ayrılabilir [49].

3.4.1 Öğretmenli Öğrenme

Öğretmenli Öğrenme, Denetimli Öğrenme olarak da bilinmektedir. Şekil 3.9'daki blok diyagramı bu öğrenme tipini göstermektedir. Kavramsal olarak öğretmeni, çevredeki bilgiye sahip olan, olarak düşünebiliriz. Bu bilgi bir dizi girdi ve çıktı örneğiyle temsil edilir. Öte yandan sinir ağı çevredeki bilgiyi bilmemektedir. Şimdi öğretmenin ve sinir ağının aynı çevreden gelen bir eğitim vektörüne maruz bırakıldığını düşünelim. Öğretmenin çevre hakkında bilgisi sayesinde sinir ağı bu eğitim vektörü için istenen yanıtı verebilme yeteneğine sahip olur. Ağ parametreleri, eğitim vektörü ve hata sinyalinin ortak etkisi altında ayarlanır. Hata sinyali, istenen cevap ile ağın gerçek cevabı arasındaki fark olarak tanımlanır. Parametrelerde yapılan ayarlama, sinir ağının, öğretmeni taklit etmesi amacıyla adım adım gerçekleştirilir. Bu şekilde bilgi, sinir ağına eğitim yoluyla aktarılır ve sinaptik ağırlıklar şeklinde depolanır. Eğitilen sinir ağı artık öğretmensiz bir şekilde çevreye cevap verebilir [49].

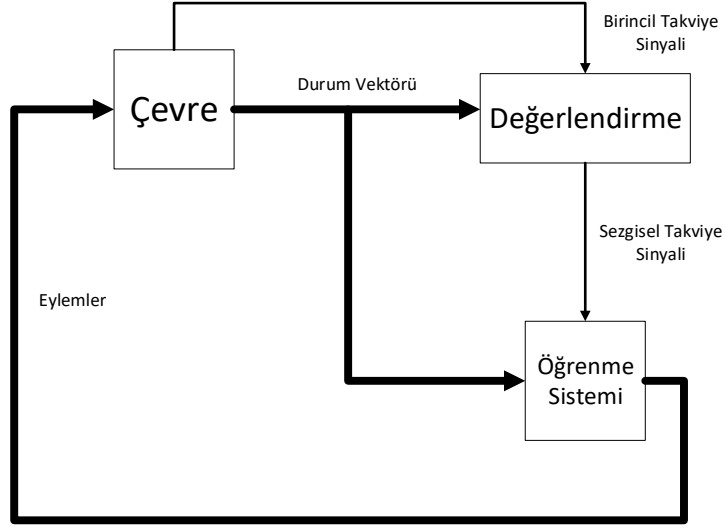


Şekil 3.9 Öğretmenli öğrenme modeli [49]

3.4.2 Öğretmensiz Öğrenme

Öğretmenli Öğrenmede, öğrenme süreci öğretmen eşliğinde gerçekleşirken; Öğretmensiz Öğrenmede adından da anlaşılacağı üzere öğrenme sürecini denetleyen bir öğretmen yoktur. Yani ağ tarafından öğrenilecek fonksiyonun örnek çıktıları bulunmamaktadır. Öğretmensiz Öğrenmeyi 2 alt kategoriye ayırabiliriz:

Takviyeli Öğrenme: Takviyeli Öğrenmede, girdi ve çıktı eşleşmesinin öğrenilmesi, çevreyle sürekli etkileşim yoluyla sağlanır. Şekil 3.10'da Takviyeli Öğrenme blok diyagramı görülmektedir. Çevreden alınan birincil takviye sinyali, değerlendirme bloğunda, yüksek kalitede takviye sinyaline dönüştürülür ve bu sinyale sezgisel destekleyici sinyal ismi verilir. Bu sistem gecikmeli bir destekle öğrenmeyi gerçekleştirecek şekilde tasarlanmıştır [49].




Şekil 3.10 Takviyeli öğrenme modeli [49]

Gecikmeli takviye öğrenmesinin iki temel nedenden dolayı gerçekleştirilmesi zordur:

- 1- Öğrenmenin her adımında istenen cevabı verecek bir öğretmen yoktur.
- 2- Birincil takviye sinyalinin oluşturulmasında meydana gelen gecikme, öğrenme makinesinin zamansal bir kredi tahsisi problemini çözmesi gerektiğini işaret eder.

Bu zorluklara rağmen, takviyeli öğrenme yaygın kullanıma sahiptir. Bu öğrenme, sistemin kendi çevresi ile etkileşime girmesi için gerekli temeli sağlar. Böylece etkileşimin sonucu olan deneyimin sonuçlarına dayanarak, öngörülen bir görevi yerine getirme becerisini öğrenmeyi geliştirir [49].

Denetimsiz Öğrenme: Denetimsiz öğrenmede, Şekil 3.11’de gösterildiği gibi öğrenme sürecini denetleyen harici bir öğretmen yoktur.



Şekil 3.11 Denetimsiz öğrenme modeli [49]


Denetimsiz öğrenmeye dayalı bir algoritmanın uygulanması, istenen çıktılar hakkında bilgi gerektirmez. Dolayısıyla tüm örnek kümesini oluşturan unsurlar arasında, benzerlikler gösteren alt kümeleri belirlerken, ağın parametreleri optimize etmesi gerekmektedir. Ağ kendi içindeki bu kümeleri öğrenmek için ağırlık ve bias

değerlerini güncellemektedir. Alternatif olarak, ağ tasarımcısı problemle ilgili bilgisini kullanarak bu olası kümelerin maksimum miktarını belirleyebilir [43].

3.5 Yapay Sinir Ağı Modelleri

3.5.1 İleri Beslemeli Tek Katmanlı Yapay Sinir Ağları

Tek katmanlı ağın en basit formunda, girdi katmanı direkt olarak çıktı katmanına (hesaplama katmanı) yönelir, bu sinir ağında ters yönlü bir yönelme mümkün değildir. Diğer bir deyişle bu tip ağlara ileri beslemeli ağlar ismi verilmektedir. Şekil 3.12’de 4 adet nörona sahip girdi katmanından ve 4 hesaplama nöronuna sahip çıktı katmanından oluşan bir sinir ağı gösterilmiştir. Bu tip ağlara Tek Katmanlı Yapay Sinir Ağları denmektedir. Bu ağlarda girdi katmanında herhangi bir hesaplama yapılmadığından, çıktı katmanı ağın tek katmanı olarak gösterilir [49].

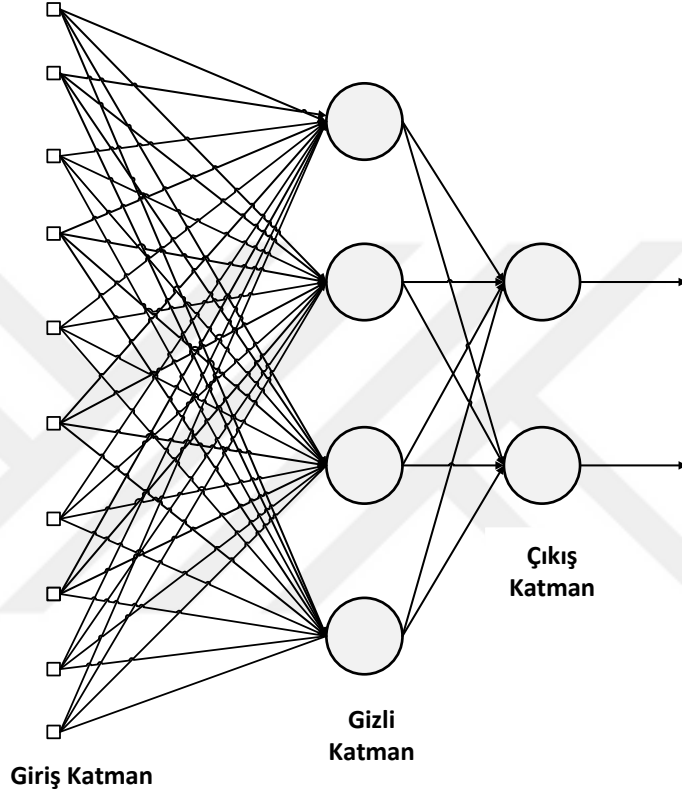


Şekil 3.12 İleri beslemeli tek katmanlı nöron [49]

3.5.2 İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında bir veya daha fazla gizli katman mevcutsa bu tip ağlara Çok Katmanlı Yapay Sinir Ağı denmekte ve bu ağlarda hesaplama prosesi gizli katmanlarda meydana gelmektedir. Ağın girdi katmanı, ikinci katmana (ilk gizli katman) girdi sinyalleri sağlar. İkinci katmanın oluşturduğu sinyaller, üçüncü katman için girdi olarak kullanılır ve ağın geri kalanı için de bu akış devam eder. Tipik olarak, ağın tüm


katmanlarındaki nöronlar kendi girdileri olarak sadece önceki katmanın çıkış sinyallerine sahiptirler. Ağın çıkış katmanındaki nöronlarının çıkış sinyalleri, ağın giriş (birinci) katmanındaki nöronlarının genel yanıtını oluşturur. Şekil 3.13'te tek bir gizli katmana sahip ileri beslemeli çok katmanlı yapay sinir ağı görülmektedir. Ağ, 10 adet nörona sahip girdi katmanından, 4 adet nörona sahip gizli katmandan ve 2 adet nörona sahip çıktı katmanından oluşmaktadır [49].



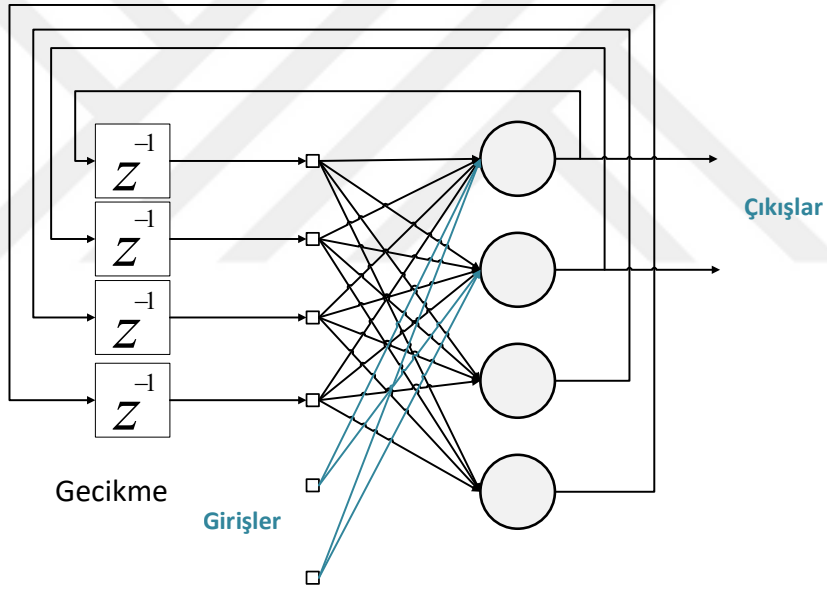
Şekil 3.13 İleri beslemeli çok katmanlı yapay sinir ağı [49]

3.5.3 Tekrarlı Ağlar

Tekrarlı Ağlar, İleri Beslemeli ağlardan en az 1 adet geri besleme döngüsüne sahip olmalarıyla ayrılır. Örneğin, tekrarlı bir ağ, her nöronun çıkış sinyalini, diğer nöronların girişlerine geri besleyen tek bir nöron katmanından oluşabilir. Şekil 3.14'te gizli katmana sahip olmayan tekrarlı bir ağ gösterilmiştir. Bu ağda çıktı sinyali kendi girdi nöronunu beslememekte; diğer nöronların girişlerine besleme yapmaktadır. Şekil 3.15'te ise gizli katmana sahip tekrarlı bir ağ görülmektedir. Bu ağda gösterilen geri besleme bağlantıları, gizli nöronlardan olduğu kadar, çıkış nöronlarından da kaynaklanmaktadır. Tekrarlı ağlarda, geri besleme döngülerinin varlığı, ağın öğrenme kapasitesi ve performansı üzerinde büyük bir etkiye sahiptir [49].



Şekil 3.14 Gizli katmana sahip olmayan tekrarlı ağ örneği [49]



Şekil 3.15 Gizli katmana sahip tekrarlı ağ örneği [49]

3.6 Uygulamada Kullanılan Yapay Sinir Ağı Yöntemleri

Bu kısımda uygulamada kullanılan YSA yöntemlerinden detaylı şekilde bahsedilecektir.

3.6.1 Çok Katmanlı Yapay Sinir Ağı

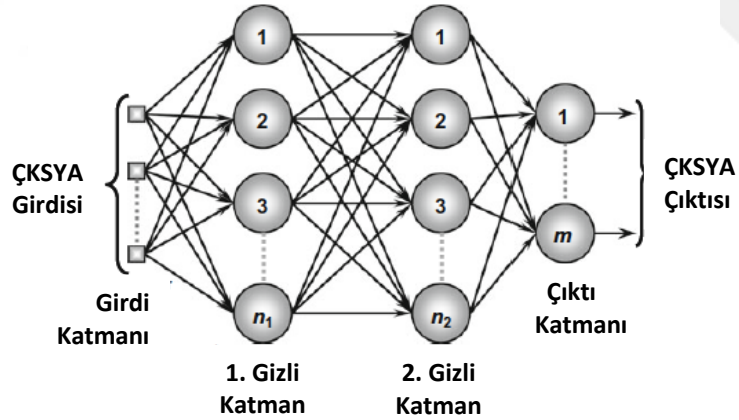
Çok Katmanlı Yapay Sinir Ağı, girdi katmanı ve çıktı katmanının arasına yerleştirilmiş en az bir adet gizli katmandan oluşur. ÇKYSA farklı alanlardan birçok problemin çözümünde

kullanılabilmektedir ve çok sayıda farklı mimariye sahip olması uygulanabilirliğini kolaylaştırmaktadır. ÇKYSYA'nın kullanıldığı alanlar arasında en önemlileri şunlardır:

- Eğri uydurma,
- Desen tanıma,
- Proses tanımlama ve kontrolü,
- Zaman serileri tahmini,
- Sistem optimizasyonu.

3.6.1.1 ÇKYSYA Çalışma Esasları

Şekil 3.16 incelendiğinde, belirli bir uygulamadan gelen sinyalleri temsil eden ağın her bir girişinin, çıkış katmanına doğru katman katman yayıldığı görülmektedir. Bu durumda, birinci gizli katman çıktıları, ikinci gizli katmanın girdileri olacaktır. Şekil 3.16'da gösterilen senaryo için, ikinci gizli katman çıktısı, çıkış katmanı nöronları için girdi olacaktır [43].



Şekil 3.16 Çok katmanlı sinir ağı [43]


ÇKYSYA'da gizli katmanların bulunması dışında, çıktı katmanında birden fazla nöron bulunabilir. Sistemin girdi ve çıktıların davranışı ile ilgili bilgiler, ÇKYSYA'yı oluşturan tüm nöronlar arasında dağılmaktadır.

ÇKYSYA topolojisinin oluşturulması, problemin yapısı, eğitim parametreleri, başlangıç ağırlık değerleri, gizli katman sayısı, gizli katmandaki nöron sayısı gibi faktörlere bağlıdır.

3.6.1.2 ÇKYSA Eğitim Prosesi

Genelleştirilmiş Delta kuralı olarak da bilinen geri yayılım algoritmasını kullanan ÇKYSA'da eğitim süreci, genellikle iki spesifik aşamanın birbirini izlemesiyle meydana gelir [43].

İlk aşama, ileri yayılım olarak da adlandırılan, eğitim setinden alınan x_1, x_2, \dots, x_n girdi sinyallerinin, çıktı üretilene kadar katmandan katmana yayılması sürecidir. Bu süreçte, nöronlara atanan ağırlık ve bias değerlerinde herhangi bir güncelleme yapmadan, ileri doğru yayılımla, ilgili girdilerin sonuçlarının hesaplanması amaçlanır. Daha sonra, ağ çıktıları tarafından üretilen cevaplar, istenen mevcut cevaplarla karşılaştırılır. Şekil 3.17'deki örneğe bakıldığında, çıktı katmanındaki n_3 adet nöron için üretilen çıktı ve istenen çıktı arasındaki sapma (hata) hesaplanır [43].




Bu hatalar kullanılarak, geri yayılım olarak da adlandırılan, öğrenme algoritmasının ikinci aşaması uygulanır. İlk aşamadan farklı olarak, ağın tüm nöron ve bias ağırlıklarının ayarlanması bu aşamada gerçekleştirilir [43].

Özetle, ileri ve geri yayılımın ağa ardışık olarak uygulanmasıyla, nöronların ağırlıklarının her bir iterasyonda otomatik olarak ayarlanması ve aynı zamanda ağ tepkileri tarafından üretilen hataların toplamının, kademeli olarak azaltılması sağlanır [43].

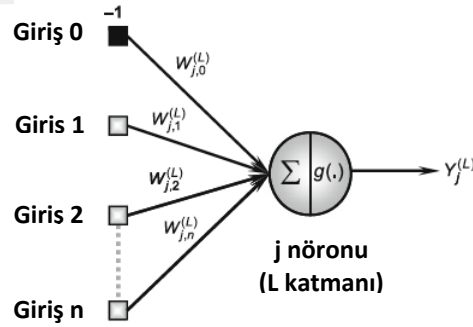
Geri Yayılım Algoritmasının Gösterimi

Geri yayılım algoritmasının çalışma prensibinin daha iyi anlaşılması için birkaç değişken ve yardımcı parametrenin tanımlanması gerekmektedir. Geri yayılım algoritmasında kullanılacak değişken seti Şekil 3.18'de gösterilmektedir.



Şekil 3.18 ÇKYSA'da kullanılacak parametre seti [43]

Şekil 3.19'da gösterilen ağ topolojisinde bulunan katmanlara (L) ait her nöron (j) yine Şekil 3.18'de verilen mimari kullanılarak konfigüre edilir. $g(\cdot)$ sürekli ve tüm tanım kümelerinde türevlenebilen bir aktivasyon fonksiyonunu simgeler. Bu fonksiyonlara lojistik veya hiperbolik tanjant aktivasyon fonksiyonları örnek verilebilir.



Şekil 3.19 ÇKYSA detaylı girdi ve katman gösterimi [43]

$W_{ji}^{(L)}$, L katmanının j. nöronunu, (L-1) katmanının i. nöronuna bağlayan ağırlık değerlerinden oluşan matrisi tanımlar. Şekil 3.18'de gösterilen topolojiye göre:

- $W_{ji}^{(3)}$, çıktı katmanının j. nöronunu, 2. katmanın i. nöronuna bağlayan ağırlığı temsil eder.
- $W_{ji}^{(2)}$, 2. gizli katmanın j. nöronunu, 1. gizli katmanının i. nöronuna bağlayan ağırlığı temsil eder.
- $W_{ji}^{(1)}$, 1. gizli katmanının j. nöronunu, girdi katmanının i. nöronuna bağlayan ağırlığı temsil eder.

$I_j^{(L)}$, L katmanının j. nöronuna ait ağırlıklandırılmış girdiyi gösteren elemanlardan oluşan vektörü tanımlar.

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \Leftrightarrow I_j^{(1)} = W_{1,0}^{(1)} \cdot x_0 + W_{1,1}^{(1)} \cdot x_1 + \dots + W_{1,n}^{(1)} \cdot x_n \quad (3.9)$$

$$I_j^{(2)} = \sum_{i=0}^{n_1} W_{ji}^{(2)} \cdot Y_i^{(1)} \Leftrightarrow I_j^{(2)} = W_{1,0}^{(2)} \cdot Y_0^{(1)} + W_{1,1}^{(2)} \cdot Y_1^{(1)} + \dots + W_{1,n_1}^{(2)} \cdot Y_{n_1}^{(1)} \quad (3.10)$$

$$I_j^{(3)} = \sum_{i=0}^{n_2} W_{ji}^{(3)} \cdot Y_i^{(2)} \Leftrightarrow I_j^{(3)} = W_{1,0}^{(3)} \cdot Y_0^{(2)} + W_{1,1}^{(3)} \cdot Y_1^{(2)} + \dots + W_{1,n_2}^{(3)} \cdot Y_{n_2}^{(2)} \quad (3.11)$$

$Y_j^{(L)}$, L katmanındaki j. nörona ait çıktığı gösteren elemanlardan oluşan vektörü tanımlar.

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (3.12)$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad (3.13)$$

$$Y_j^{(3)} = g(I_j^{(3)}) \quad (3.14)$$

En son çıktı $Y_3^{(3)}$ hesaplandıktan sonra, geri yayılım sürecine geçilir. Öncelikle üretilen çıktıyla istenen çıktı arasındaki sapmayı ölçen ortalama hata hesaplanır. Şekil 3.18’de gösterilen topolojiye göre, k. eğitim örneği dikkate alındığında karesel hata fonksiyonu çıktı nöronu tarafından üretilen cevapla ilgili lokal performansı ölçmek için kullanılır. Bu fonksiyon (3.15) denkleminde verilmiştir.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (3.15)$$

$Y_j^{(3)}(k)$, j. çıktı nöronu tarafından k. eğitim örneği için üretilen değerdir. $d_j(k)$ istenen çıktı değeridir.

Sonuç olarak, p adet örnekten oluşan bir eğitim seti olduğu varsayılırsa, geri yayılım algoritmasının global performansı, (3.16) denkleminde gösterilen “ortalama karesel hata” yoluyla hesaplanabilir:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (3.16)$$

Çıktı Katmanı Ağırlıklarının Ayarlanması

Çıktı katmanının eğitim süreci, hatayı minimize etmek için, $W_{ji}^{(3)}$ ağırlık matrisinin güncellenmesini amaçlar. Bu durumda gradyan tanımı kullanılıp fonksiyonun türevi zincir kuralına göre düzenlendiğinde (3.17) denklemi elde edilir.

$$\nabla E^{(3)} = \frac{\partial E}{\partial W_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} \quad (3.17)$$

Daha önceden tanımlanan (3.11) denklemden (3.18), (3.14) denklemden (3.19) ve (3.15) denklemden (3.20) denklemi elde edilir:

$$\frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} = Y_i^{(2)} \quad (3.18)$$

$$\frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} = g'(I_j^{(3)}) \quad (3.19)$$

$$\frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}) \quad (3.20)$$

Denklemler (3.18), (3.19) ve (3.20), denklem (3.17)'de yerine konduğunda (3.21) denklemi elde edilir.

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \cdot Y_i^{(2)} \quad (3.21)$$

W_{ji} ağırlık matrisinin ayarlanması, hatayı en aza indirmek için gradyanın ters yönünde yapılmalıdır, bu nedenle denklem (3.22) gibi düzenlenir.

$$\Delta W_{ji}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} \Leftrightarrow \Delta W_{ji}^{(3)} = \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (3.22)$$

Burada $\delta_j^{(3)}$, çıktı katmanındaki j. nörona ait yerel gradyan olarak tanımlanır ve (3.23)'teki gibi gösterilir:

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (3.23)$$

Ayrıca, (3.22) ifadesi (3.24)'teki yinelemeli prosedüre dönüştürülebilir:

$$W_{ji}^{(3)}(t+1) = W_{ji}^{(3)}(t) + \eta \cdot \delta_j^{(3)} Y_i^{(2)} \quad (3.24)$$

η , geri yayılma algoritmasının öğrenme katsayısıdır.

Orta Katman Ağırlıklarının Ayarlanması

ÇKYSA'nın çıkış katmanına ait nöronlardan farklı olarak, ara katman nöronları, çıktıları için istenen değerlere doğrudan erişime sahip değildir. Bu durumda, ağırlıkların güncellenmesi, daha önceden güncellenmiş olan çıktı katmanı nöronları tarafından üretilen çıktı hatalarının tahmini yoluyla gerçekleştirilir [43].

Şekil 3.18'deki topoloji göz önünde bulundurulduğunda, ikinci gizli katman nöron ağırlıklarının güncellenmesi çıktı katmanı nöron ağırlıklarının güncellenmesi tamamlanmadan başlamaz. Bu şartlarda ikinci gizli katman nöronlarının istenen çıktı değerleri mevcut değildir; bu yüzden bu nöronların ağırlık güncellemesi çıktı katmanı nöronlarının ağırlıklarının güncellenmesine bağlıdır [43].

Öncelikle, çıktı katmanı nöronlarının sinaptik ağırlıkları, istenen cevaplarla üretilen cevaplar karşılaştırılarak hesaplanır. Sonrasında, hesaplanan hata önceki katmanların nöronlarına geri yayılır. Sonuç olarak, gizli katman nöronlarının istenen cevabı, doğrudan bağlı olduğu ve bir önceki aşamada ağırlıkları güncellenmiş olan hemen gerisinde bulunan katmanın nöronlarına göre belirlenmektedir [43].

İkinci Gizli Katman Ağırlıklarının Ayarlanması

İkinci gizli katman için eğitim sürecinin amacı, ağ tarafından üretilen $W_{ji}^{(2)}$ ağırlık matrisinin, çıktı katmanı nöronlarının ayarlanmasıyla oluşan geri yayılım hatasına göre güncellenmesidir. Hatayla ilgili (3.25) denklemini elde ederiz:

$$\nabla E^{(2)} = \frac{\partial E}{\partial W_{ji}^{(2)}} = \frac{\partial E}{\partial Y_j^{(2)}} \cdot \frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} \cdot \frac{\partial I_j^{(2)}}{\partial W_{ji}^{(2)}} \quad (3.25)$$

Sırasıyla (3.10) ve (3.13) denklemlerinden, (3.26) ve (3.27) elde edilir:

$$\frac{\partial I_j^{(2)}}{\partial W_{ji}^{(2)}} = Y_i^{(1)} \quad (3.26)$$

$$\frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} = g'(I_j^{(2)}) \quad (3.27)$$

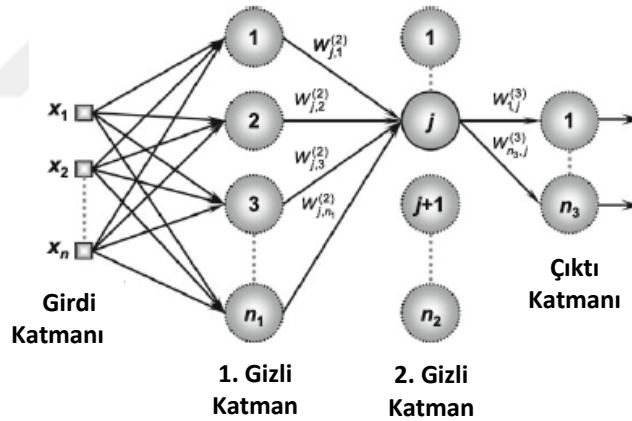
$$\frac{\partial E}{\partial Y_j^{(2)}} = \sum_{k=1}^{n_3} \frac{\partial E}{\partial I_k^{(3)}} \cdot \frac{\partial I_k^{(3)}}{\partial Y_j^{(2)}} = \sum_{k=1}^{n_3} \underbrace{\frac{\partial E}{\partial I_k^{(3)}}}_{\text{kısım(1)}} \cdot \underbrace{\frac{\partial \sum_{k=1}^{n_3} W_{kj}^{(3)} \cdot Y_j^{(2)}}{\partial Y_j^{(2)}}}_{\text{kısım(2)}} \quad (3.28)$$

2. kısmın $Y_j^{(2)}$ 'ye göre kısmi türevinin değeri $W_{kj}^{(3)}$ 'dir.

$$\frac{\partial E}{\partial Y_j^{(2)}} = \underbrace{\sum_{k=1}^{n_3} \frac{\partial E}{\partial I_k^{(3)}}}_{\text{kısım(1)}} \cdot \underbrace{W_{kj}^{(3)}}_{\text{kısım(2)}} \quad (3.29)$$

(3.29) eşitliğiyle verilen tanımlamada çıktı katmanının, ikinci gizli katmanın j nöronuyla bağlantılı olan tüm nöronlarının sinaptik ağırlıklarını ifade eden kısım (2)'nin gözlenmesi önemlidir. Şekil 3.20'de, ikinci gizli katman için nöron j'nin referans noktası olarak kullanılması gösterilmiştir.

Geri yayılım metodunun niteliğinin kavranması için, bir önceki adımda tüm $W_{ji}^{(3)}$ ağırlıklarının gerçek hata değerine bağlı olarak değiştirildiği unutulmamalıdır. Bu gerçek hata değeri ikinci gizli katman nöronlarının hesaplanmasında da kullanılacaktır.



Şekil 3.20 ÇKYSA 2. gizli katman j. nöronun referans olarak gösterilmesi [43]

(3.29) denklemindeki 1. kısım ifadesi, denklem (3.19) ve (3.20)'nin çarpılması sonucu elde edilir. Bu çarpım sonucu aynı zamanda $\delta_j^{(3)}$ 'in değerine eşittir. Dolayısıyla ifadelerin yerine konmasıyla (3.30) denklemini tanımlanır.

$$\frac{\partial E}{\partial Y_j^{(2)}} = - \sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)} \quad (3.30)$$

Sonuç olarak (3.26), (3.27) ve (3.30), (3.25)'te yerine konulursa (3.31) ifadesi elde edilir.

$$\frac{\partial E}{\partial W_{ji}^{(2)}} = - \left(\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)} \right) \cdot g' \left(I_j^{(2)} \right) \cdot Y_i^{(1)} \quad (3.31)$$

Hatayı en aza indirmek için W_{ji} ağırlık matrisinin güncellemesinin gradyanın tersi yönünde yapılması gerekir:

$$\delta_j^{(2)} = -\left(\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)}\right) \cdot g'(I_j^{(2)}) \quad (3.32)$$

(3.32) ifadesinde, $\delta_j^{(2)}$, ikinci ara katmanın j. nöronuna göre lokal gradyan olarak tanımlanır, yani:

$$\delta_j^{(2)} = -\left(\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)}\right) \cdot g'(I_j^{(2)}) \quad (3.33)$$

(3.34)'te ağırlık değişimi iteratif şekilde gösterilmiştir.

$$W_{ji}^{(2)}(t+1) = W_{ji}^{(2)}(t) + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (3.34)$$

Birinci Gizli Katman Ağırlıklarının Ayarlanması

Birinci gizli katmanın öğrenme prosesinin amacı, ikinci gizli katman nöronlarının güncellenmesiyle oluşan geri yayılım hatasıyla, ağ tarafından üretilen çıktı arasındaki hatanın minimize edilmesi için $W_{ji}^{(1)}$ ağırlık matrisinin ayarlanmasını içerir. Hatayla ilgili (3.35) denklemini elde ederiz:

$$\nabla E^{(1)} = \frac{\partial E}{\partial W_{ji}^{(1)}} = \frac{\partial E}{\partial Y_j^{(1)}} \cdot \frac{\partial Y_j^{(1)}}{\partial I_j^{(1)}} \cdot \frac{\partial I_j^{(1)}}{\partial W_{ji}^{(1)}} \quad (3.35)$$

Sırasıyla (3.9) ve (3.12) denklemlerinden, (3.36) ve (3.37) ifadeleri elde edilir.

$$\frac{\partial I_j^{(1)}}{\partial W_{ji}^{(1)}} = x_i \quad (3.36)$$

$$\frac{\partial Y_j^{(1)}}{\partial I_j^{(1)}} = g'(I_j^{(1)}) \quad (3.37)$$

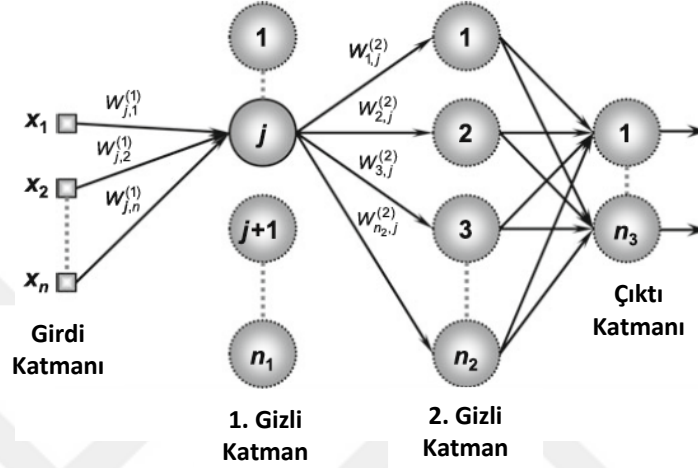
$$\frac{\partial E}{\partial Y_j^{(1)}} = \sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}} \cdot \frac{\partial I_k^{(2)}}{\partial Y_j^{(1)}} = \underbrace{\sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}}}_{\text{kısım(1)}} \cdot \underbrace{\frac{\partial(\sum_{k=1}^{n_2} W_{kj}^{(2)} \cdot Y_j^{(1)})}{\partial Y_j^{(1)}}}_{\text{kısım(2)}} \quad (3.38)$$

$$\frac{\partial E}{\partial Y_j^{(1)}} = \underbrace{\sum_{k=1}^{n_2} \frac{\partial E}{\partial I_k^{(2)}}}_{\text{kısım(1)}} \cdot \underbrace{W_{kj}^{(2)}}_{\text{kısım(2)}} \quad (3.39)$$

İkinci gizli katmanın sinaptik ağırlıklarının ayarlanması için kullanılan analiz, birinci katmanın ağırlıklarının ayarlanması için de uygulanabilir. (3.39) denklemindeki 2.kısımın

değeri, birinci gizli katmandaki j nöronuyla bağlantılı olan ikinci gizli katmanın tüm nöronlarının sinaptik ağırlıklarına bağlıdır.

W_{ji} 'nin tüm ağırlıklarının, bir önceki adımda geri yayılım hatasına dayanarak ayarlandığını ve bunun hatanın gerçek değerine göre ayarlandığını vurgulamak önemlidir. Bu durum, Şekil 3.21'de birinci gizli katmandaki nöron j , referans noktası alınarak gösterilmiştir.



Şekil 3.21 ÇKYSA 1. gizli katman j . nöronun referans olarak gösterilmesi [43]

(3.38) denklemindeki 1. kısmın değerinin elde edilmesi problemine dönersek, ifadenin (3.26) ve (3.27) çarpılarak elde edilebileceğini görmek mümkündür. Bu değer aynı zamanda $\delta_j^{(2)}$ değerine eşittir. Sonuç olarak bu tür yerine koyma işlemleri yapılarak, (3.38) ifadesi (3.40) ifadesi gibi gösterilebilir.

$$\frac{\partial E}{\partial Y_j^{(1)}} = - \sum_{k=1}^{n_2} \delta_j^{(2)} \cdot W_{kj}^{(2)} \quad (3.40)$$

(3.36), (3.37) ve (3.40), (3.35)'te yerine konduğunda (3.41) ifadesi bulunur:

$$\frac{\partial E}{\partial W_{ji}^{(1)}} = - \left(\sum_{k=1}^{n_2} \delta_j^{(2)} \cdot W_{kj}^{(2)} \right) \cdot g' \left(I_j^{(1)} \right) \cdot x_i \quad (3.41)$$

Hatayı en aza indirmek için $W_{ji}^{(1)}$ ağırlık matrisinde güncellemenin gradyanın tersi yönünde yapılması gerekmektedir:

$$\Delta W_{ji}^{(1)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(1)}} \Leftrightarrow \Delta W_{ji}^{(1)} = -\eta \cdot \delta_j^{(1)} \cdot x_i \quad (3.42)$$

Burada $\delta_j^{(1)}$, ikinci ara katmanın j . nöronuna göre lokal gradyan olarak tanımlanır, yani:

$$\delta_j^{(1)} = - \left(\sum_{k=1}^{n_2} \delta_j^{(2)} \cdot W_{kj}^{(2)} \right) \cdot g' \left(I_j^{(1)} \right) \quad (3.43)$$

ifade (3.42), ayrıca (3.44)'teki yinelemeli prosedüre dönüştürülebilir:

$$W_{ji}^{(1)}(t + 1) = W_{ji}^{(1)}(t) + \eta \cdot \delta_j^{(1)} \cdot x_i \quad (3.44)$$

Sonuç olarak, (3.44) ifadesi, ikinci gizli katman nöronlarından kaynaklanan hatanın geri-yayılımını kullanarak, birinci gizli katman nöronlarının ağırlığını ayarlar.

Ağırlık matrislerinin ayarlanması için verilen prosedürler ve denklemler, ÇKYSA'nın herhangi bir topolojisi için, ara katman sayısından bağımsız olarak genelleştirilebilir.

3.6.2 NARX Ağı

Lineer Olmayan Harici Girdili Otoregresif Sinir Ağı (NARX), geri besleme bağlantısına sahip tekrarlı bir dinamik ağıdır. NARX modeli, genelde zaman serileri modellemesinde kullanılan Harici Girdili Otoregresif Yönteme (ARX) dayanmaktadır [50].

NARX ağının birçok farklı uygulama alanı vardır. NARX metodu, girdi sinyalinin gelecek değerini tahmin etmekte kullanılabilir. Ayrıca lineer olmayan filtreleme ve lineer olmayan dinamik sistemlerin modellenmesinde NARX'la iyi sonuçlar alınabilir [50].

NARX modeli, fonksiyon kestirimi için farklı yollarla uygulansa da en kolay uygulama şekli bütünleşik hafızaya sahip İleri Beslemeli Ağların kullanılmasıdır. Bu yöntem geçmiş girdi değerlerinin ve geçmiş çıktı değerlerinin girdi olarak ağa beslenmesi sonucu fonksiyon kestirim işlemini yapmaktadır.[51]


NARX modelinin formülü (3.45)'te verilmiştir.

$$Y(t + 1) = f \left(\begin{array}{c} Y(t), Y(t - 1), \dots, Y(t - n_y + 1), x(t), x(t - 1), \dots \\ \dots, x(t - n_x + 1) \end{array} \right) \quad (3.45)$$

(3.45) eşitliğine göre bağımlı çıktı sinyali $y(t)$, çıktı sinyalinin önceki değerleri ve bağımsız harici girdi sinyalinin önceki değerleriyle formüle edilir [50]. Formülde t zamanı, n_y çıktı gecikmesini, n_x ise girdi gecikmesini göstermektedir.


NARX ağının öğrenme prosesinde, dinamik geri yayılım algoritması gradyan hesaplarken statik ağlarla karşılaştırıldığında daha yoğun bir şekilde hesaplama yapar ve ağın eğitilmesi daha fazla zaman alır. Bunun yanında dinamik ağın hata yüzeyi statik ağlara göre daha karmaşık yüzeye sahiptir ve eğitimin lokal minimuma takılması daha olasıdır [53].

NARX ađında gerek ıktı deęerleri elimizde olduęu iin geri besleme baęlantısını iptal ederek eęitime bařlanır [51]. Bu yapıya aık dng veya seri-paralel mimari ismi verilir. Aık dngde, tahmin edilen ıktının geri beslenmesi yerine gerek ıktı deęerleri girdi olarak kullanılmaktadır (řekil 3.22) [51]. Bu mimarinin 2 avantajı vardır. Biri ileri beslemeli ađın girdisinin daha kesin ve doęru saęlanmasıdır. İkinci avantajı ise mimarinin btnyle ileri beslemeli ađı temsil etmesi ve eęitim iin statik geri yayılımın kullanılabilmesidir [50],[51].



řekil 3.22 Aık dng (seri paralel mimari) [50]

řekil 3.23'e baktığımızda ise, tahmin edilen ıktı deęerleri geri beslenerek ađa tekrar girdi olarak verilmektedir. Bu yapıya kapalı dng veya paralel mimari denmektedir. Aık dngyle eęitilen ađ kapalı dngye evrilir ve bir adım ileri durumun tahmin edilmesi, geri beslemeli bu ađ mimarisiyle yapılır [50].



řekil 3.23 Kapalı dng (paralel mimari) [50]

TÜRKİYE'NİN ELEKTRİK TALEBİ GÖRÜNÜMÜ

4.1 Türkiye'de Elektrik Üretim Tarihçesi

Türkiye'de kayıt altına alınan ilk elektrik üretimi Mersin'de su değirmeni miline bağlanan 2kW'lık bir dinamoyla Avustralyalı Dörfler tarafından gerçekleştirilmiştir. Elektrik üretim hizmeti, 1913 öncesine kadar özel şirketler tarafından verilirken, İstanbul'da 15MW'lık Silahtarağa Santrali'nin kurulmasıyla kamu tarafı da hizmete dahil edilmiştir [54] [55].

Türkiye Cumhuriyeti kurulduğunda kurulu güç 30 MW olmuştur ve elektriğin aydınlatma dışı faaliyetlerde kullanılmasına başlanmıştır [56].

1935 yılında çıkarılan yasalarla Etibank, Elektrik İşleri Etüd İdaresi ve Maden Tetkik Arama kurumları faaliyete geçmiş; sonrasında Devlet Su İşleri bu hizmete dahil olmuştur [1] [2]. Bu tarihlerde 43 şehir merkezine elektrik verilebilmiş; toplam kurulu güç 126,2 MW, üretim ise 213 milyon kWh olarak kayıt altına alınmıştır. [55]

Çatalağzı Termik Santrali 1948'de faaliyete geçmiştir. 1950 yılının başında kurulu güç 407,8 MW'a; üretim ise 789,5 milyon kW'a çıkmıştır. [55]

1970 yılında çıkarılan kanunla, elektriğin üretim, iletim ve dağıtım faaliyetlerinin tek elden yürütüleceği kurumsal bir yapının gerekliliği vurgulanmış ve Türkiye Elektrik Kurumu (TEK) bu amaçla kurulmuştur [53], [55]. Kurulu güç bu tarihlerde 2234,9 MW; üretim ise 8,8 milyar kWh seviyelerine yükselmiştir [55].

Türkiye, santrallerde kullanılan yakıtlarda dışa bağımlı olması sebebiyle 1970-1983 yılları arasında yaşanan dünya enerji krizinden direkt olarak etkilenmiş ve ülkede arz talep dengesizliği yaşanmıştır. Bu dönemde yaşanan zorunlu elektrik kısıtlamalarına rağmen

kurulu güç 5118 MW'a kadar yükselmiştir [57]. Keban Barajı (1330 MW), Karakaya Barajı (1800 MW) ve Atatürk Barajı (2400 MW) bu dönemde faaliyete geçmiştir [56].

1984-2001 yılları arasında, önceki yıllarda sektörde hâkim olan kamu tekeli, elektrik arzında yaşanan problemler ve kamu kaynaklarının yetersiz kalması sonucu kaldırılmıştır. Bu dönemde Yap İşlet, Yap İşlet Devret, Otoprodüktör modelleri ile özel girişimlerin sektörde yatırım yapmalarının önü açılmıştır. Fakat bu modeller ciddi bir planlama yapılmadan ortaya koyulduğundan istenilen yatırım seviyesine ulaşılamamıştır [56].

1993 yılında alınan kararlarla TEK özelleştirme kapsamına alınmış, Türkiye Elektrik Üretim-İletim A.Ş. (TEAŞ) ve Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) olarak iki ayrı İktisadi Devlet Teşekkülüne ayrılmıştır. TEDAŞ ise 5 Şubat 2001'de çıkarılan Elektrik Piyasası Kanunu sonrasında, Elektrik Üretim A.Ş. (EÜAŞ), Türkiye Elektrik İletim A.Ş. (TEİAŞ) ve Türkiye Ticaret ve Taahhüt A.Ş. (TETAŞ) olmak üzere 3 farklı İktisadi Devlet Teşekküllü olarak teşkilatlandırılmıştır [54], [55].

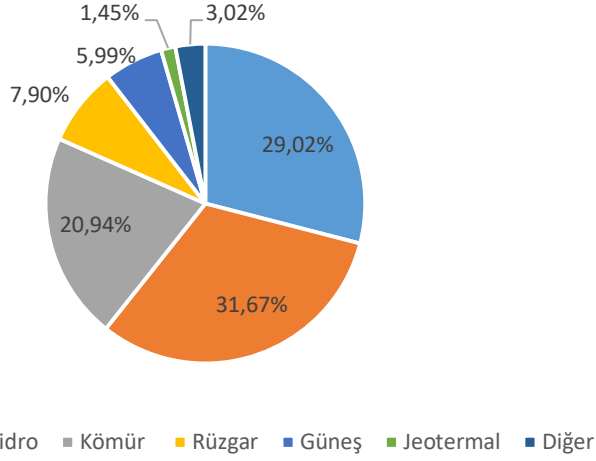
2 Mart 2001'de çıkarılan 3096 sayılı kanun kapsamında yeni piyasa modeli oluşturulmuş ve "Elektriğin yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde tüketicinin kullanımına sunulması için rekabet ortamında özel hukuk hükümlerine göre faaliyet gösterebilecek, mali açıdan güçlü, istikrarlı ve şeffaf bir elektrik piyasasının oluşturulması ve bu piyasada bağımsız bir düzenleme ve denetleme sağlanması" amaçlanmıştır [56].

4.2 Türkiye'nin Elektrik Görünümü

2019 Nisan ayı itibariyle Türkiye lisanssız birimler de dahil toplam 7842 elektrik santraline sahiptir. Ayrıca Türkiye'nin kurulu güç kapasitesi bu tarihte 89680,4 MW seviyelerine ulaşmıştır. Türkiye elektrik santrallerinin enerji kaynaklarına göre dağılımı Çizelge 4.1'de verilmiştir [58]. Çizelgedeki değerlere bakıldığında hidroelektrik ve doğalgaz santrallerinin elektrik üretiminde ilk iki sırada olduğunu görebiliriz. Nisan 2019 değerlerine göre kurulu kapasitenin kaynaklara göre yüzdelik dağılımı da Şekil 4.1'de gösterilmiştir. Şekilden fosil yakıt kaynaklı üretimin toplam üretimin yarısını oluşturduğu, hidroelektrik dışı yenilenebilir enerji kaynaklarının da yaklaşık %15'lik bir oranda kaldığı görülmektedir.

Çizelge 4.1 Nisan 2019 ayı kurulu santral adedi ve güç miktarı [58]

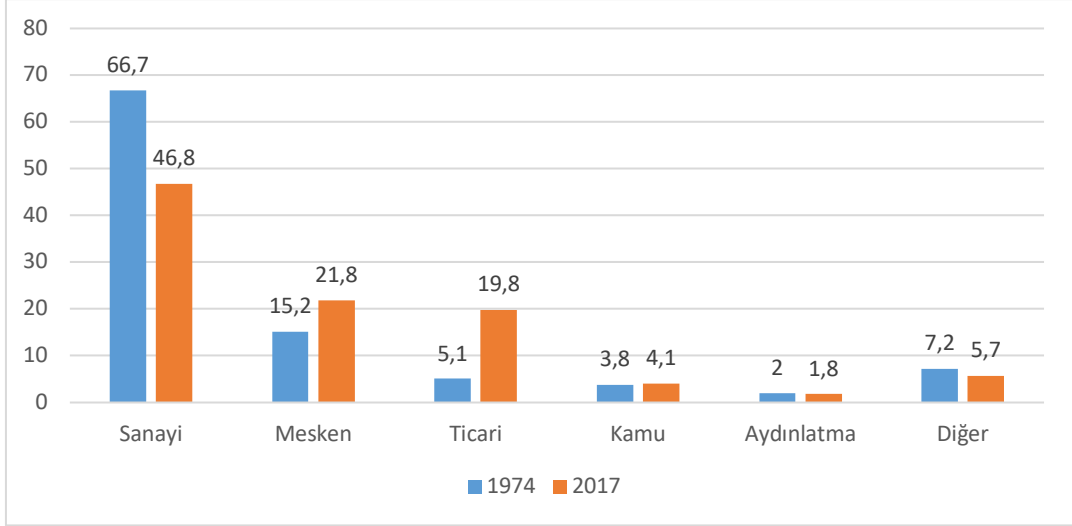
| Birincil Kaynak | Santral Adedi | Kurulu Güç [MW] |
|-----------------|---------------|-----------------|
| Doğal Gaz | 322 | 26026 |
| Hidro (Baraj) | 121 | 20554,2 |
| Hidro (Akarsu) | 540 | 7848,7 |
| Linyit | 48 | 9842 |
| İthal Kömür | 14 | 8938,9 |
| Rüzgâr | 254 | 7085,4 |
| Güneş | 6251 | 5374,6 |
| Jeotermal | 48 | 1302,5 |
| Diğer | 244 | 2708,1 |
| TOPLAM | 7842 | 89680,4 |



Şekil 4.1 Nisan 2019 itibariyle enerji kaynaklarına göre elektrik üretim yüzdeleri [58]

Türkiye yaklaşık olarak tükettiği tüm doğalgazı, çoğunluğu boru hatlarıyla olmak üzere ithal etmektedir. 2017 yılına bakıldığında Türkiye doğalgaz ithalatının %49,3'ünü Rusya'dan, %20'sini Azerbaycan'dan, %16,1'ini İran'dan, %10,3'ünü Cezayir'den, %4,4'ünü ise Katar'dan sağlamıştır [59].

Sektörlere göre elektrik tüketimi 1974-2017 yılı karşılaştırılması Şekil 4.2'de verilmiştir. Sanayi elektrik tüketimi, her iki yıl karşılaştırıldığında da en yüksek yüzdeye sahip tüketim tipi olmuştur. Nüfusun artması, hayat şartlarının iyileşmesiyle meskenlerde elektrik kullanım yüzdesi giderek artmıştır. Ticari kuruluşların elektrik kullanımı da 3. sırada önem teşkil etmektedir.



Şekil 4.2 Sektörlere göre elektrik kullanım yüzdesi [60]

4.3 Türkiye’de Enerji ve Elektrik Üretim Politikaları

Türkiye’nin doğal kaynaklara ve enerjiye olan ihtiyacı; nüfusun artması ve iktisadi olarak giderek büyümesi sebebiyle her geçen gün artmaktadır. 2019’da yayımlanan rapora göre, OECD ülkeleri arasında değerlendirildiğinde %5,5’lik büyüme oranıyla Türkiye elektrik ihtiyacında en hızlı artışı göstermiştir. Bunun yanında Türkiye konumu itibariyle dünya petrol ve doğal gaz kaynaklarının yarısından fazlasına sahip Orta Doğu ülkeleri ve Avrupa tüketici pazarı arasında jeo-stratejik bir yere sahiptir [61].

Türkiye’nin enerji politikası, enerji arz güvenliğini önde tutma, sürdürülebilir enerji, çevreyi önemseme ve yerli teknoloji geliştirme konularında şekillenmiştir. Enerji politikasında temel olarak, kaynakların çeşitlendirilmesi, kaynak arama faaliyetlerinin çoğaltılması, alt yapının güçlendirilmesi, enerjinin yüksek verimli bir halde tüketilmesi, alternatif enerji kaynaklarının ve yerli kömürün daha verimli bir şekilde kullanılması, enerji teknolojilerinde katma değeri yüksek girişimlerde bulunulması amaçlanmaktadır [62].

Enerji arz güvenliği, üretim ve ithalat, iletim, depolama ve dağıtım altyapısının sağlanması ve talebin yönetilmesi gibi alt bileşenlerden oluşmaktadır. Arz güvenliği ilk olarak akla arzın sağlanmasını getirirse de talebin arzla buluşması alt yapısında problem yaşandığında, arz güvenliğinin sağlanmasında sorunlar çıkmaktadır [54].

Türkiye, enerji ihtiyacının çoğunu ithal ederek karşılayan, düşük seviyede gaz ve petrol rezervine sahip, yurtiçi enerji tüketim miktarı üretim miktarını büyük oranda geçen bir ülkedir [59]. Doğalgazın büyük çoğunluğunun çevre ülkelerden ithal edilmesi de arz güvenliğini risk altına sokmaktadır. Bu yüzden doğalgazın elektrik üretimindeki payının azaltılması hedeflenmektedir. Bu dışa bağımlılığın azaltılması için doğalgaz arama faaliyetleri devam etmektedir. Üretimin sürekliliği açısından doğalgaz depolama faaliyetleri de önem teşkil etmektedir. Bu sebeple depolama konusunda kapasite artırımı çalışmaları yapılmaktadır [54].

Türkiye’de elektrik ve ısı üretimi açısından güneş, rüzgâr, biyokütle gibi yenilenebilir enerji kaynakları önemli bir alternatif oluşturmaktadır [54]. 2013 yılında sunulan Milli Yenilenebilir Enerji Hareket Planı’yla, ülkenin 2023 yılına kadar yenilenebilir enerji kurulu gücünün 61 GW’a (34GW hidroelektrik, 20GW rüzgâr, 5GW güneş, 1 GW biyokütle ve jeotermal) çıkarılması hedeflenmiştir. Bu planla, Türkiye’nin 2023 yılındaki enerji tüketiminin %30’unun yenilenebilir enerjiyle karşılanabileceği öngörülmüştür [59].

YAPAY SİNİR AĞLARI YÖNTEMİYLE TÜRKİYE’NİN AYLIK ELEKTRİK TÜKETİMİ TAHMİNİ

5.1 Kullanılan Veriler

Aylık elektrik tüketim tahmini çalışmaları incelendiğinde değişken seçiminin 2 farklı şekilde yapıldığı görülmektedir. Birincisi bağımsız değişken olarak elektrik tüketim verilerinin geçmiş değerlerinin kullanıldığı; diğeri ise ekonomik, demografik ve iklimsel değişkenlerin kullanıldığı çalışmalardır. Çizelge 5.1’de aylık tahmin için kullanılan değişkenler ve bu çalışmalarda önerilen değişkenler belirtilmiştir.

Çalışmalara bakıldığında iklimsel değişkenlerin, ekonomik ve demografik değişkenlerle ortak bir çalışmada kullanılmadığı görülmektedir. Bunun dışında elektrik tüketiminin geçmiş değerlerinin bağımsız değişken olarak kullanıldığı çalışmalar literatürün çoğunluğunu oluşturmaktadır.

Türkiye’nin aylık elektrik tüketiminin tahmin edilmesinde kullanılacak değişkenlere Çizelge 5.1’deki literatür araştırması ve verilerin ulaşılabilirliği birlikte değerlendirilerek karar verilmiştir. Çizelge 5.2’de seçilen değişkenlerin veri kaynakları, birimleri ve tarih aralıkları gösterilmektedir.

Çizelge 5.1 Aylık elektrik tahmini çalışmalarında kullanılan değişkenler


| 1. Aylık Elektrik Tüketimi 2. Aylık Elektrik Üretimi 3. Sıcaklık 4. Yağış Miktarı | 5. Bağlı Nem 6. Rüzgâr Hızı 7. Güneşlenme Süresi 8. Ortalama Basınç | 9. Gayri Safi Milli Hasıla 10. Nüfus 11. Tüketici Fiyat Endeksi 12. Ay Endeksi | 13. Toplam Sanayi Üretim Endeksi | | | | | 14. İthalat Miktarı 15. İhracat Miktarı | | | | | | | | | | |
|--|--|---|----------------------------------|---|---|---|---|--|---|---|---|---|----|----|----|----|----|----|
| | | | 1 | 2 | 3 | 4 | 5 | | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
| Yazar | Yöntem | | | | | | | | | | | | | | | | | |
| Islam vd. [63] | YSA | | | ✓ | ✓ | ✓ | ✓ | ✓ | | | | | | | | | | |
| Abdel-Aal vd. [64] | Abductive Sinir Ağı | | | ✓ | ✓ | | | | | | | | | | | | | |
| Saab vd. [6] | AR, ARIMA | ✓ | | | | | | | | | | | | | | | | |
| Pao [10] | YSA, ARMAX, LNREG, RSREG | | | | | | | | | | | | ✓ | ✓ | | | | |
| Yalcinoz ve Eminoglu [8] | YSA | ✓ | | | | | | | | | | | | | | | | |
| Gonzalez-Romera vd. [14] | YSA, ARIMA | ✓ | | | | | | | | | | | | | | | | |
| Ghiassi [4] | Dinamik YSA | ✓ | | | | | | | | | | | | | | | | |
| Azadeh vd. [28] | Bulanık Regresyon Modeli | ✓ | | | | | | | | | | | | | | | | |
| Al-Shobaki ve Mohsen [18] | Regresyon | ✓ | ✓ | | | | | | | | | | | | | | | |
| Zhang vd. [65] | ARIMA, YSA | ✓ | | | | | | | | | | | | | | | | |
| Hong [33] | Karar Destek Makineleri | ✓ | | | | | | | | | | | | | | | | |
| Boltürk vd. [1] | Bulanık Zaman Serisi Modeli | ✓ | | | | | | | | | | | | | | | | |
| Oğcu vd. [35] | YSA ve SVM | ✓ | | | | | | | | | | | | | | | | |
| Lee ve Hong [38] | Dinamik Bulanık zaman Serileri | ✓ | | | | | | | | | | | | | | | | |
| Chen vd. [66] | Sezgisel algoritmayla eğitilmiş YSA | | | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |
| Hamzaçebi vd. [42] | Mevsimsel YSA | ✓ | | | | | | | | | | | | | | | | |
| ÖNERİLEN MODEL | YSA (MLP) | ✓ | | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ |

Çizelge 5.2 Uygulamada kullanılan değişkenlerin özellikleri

| # | Değişken | Kısat. | Birim | Veri Kaynağı | Tarih Aralığı |
|---------|------------------------------|--------|----------|--------------|-----------------|
| Girdi 1 | Ortalama Sıcaklık | T | °C | MGM [67] | 01.1998–01.2019 |
| Girdi 2 | Ortalama Yağış Miktarı | Y | mm | MGM [68] | 01.1998–01.2019 |
| Girdi 3 | Tüketici Fiyat Endeksi | TÜFE | 2015=100 | OECD [69] | 01.1998–01.2019 |
| Girdi 4 | Toplam Sanayi Üretim Endeksi | TSÜE | 2015=100 | OECD [70] | 01.1998–01.2019 |
| Girdi 5 | Toplam İthalat | ITH | TL | OECD [71] | 01.1998–01.2019 |
| Girdi 6 | Toplam İhracat | IHR | TL | OECD [72] | 01.1998–01.2019 |
| Çıktı | Brüt Tüketim Miktarı | E | GWh | EÜİAŞ [73] | 01.1998–01.2019 |

5.1.1 Ortalama Sıcaklık

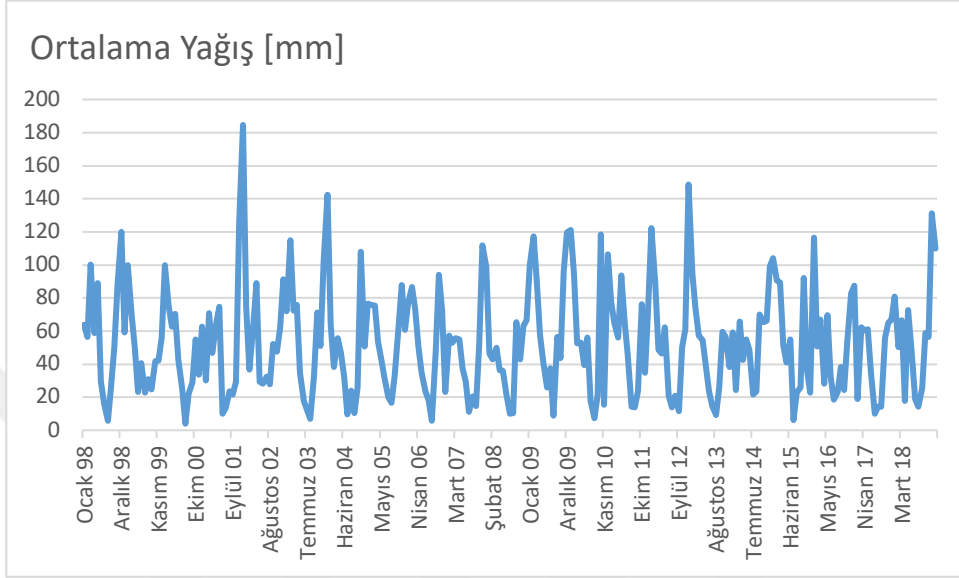
Elektrik tüketimiyle, sıcaklık değişimi arasında güçlü bir ilişki vardır. Özellikle yerleşim bölgelerinde bu daha da göze çarpmaktadır. Türkiye’de de 2017 verilerine bakıldığında elektrik tüketiminin meskenlerde kullanımı, tüketimin %22’lik gibi büyük bir kısmını oluşturmaktadır (Şekil 4.2). Şekil 5.1’de 1998-2019 yılları arasında sıcaklık değişimi gösterilmiştir.



Şekil 5.1 Türkiye aylık ortalama sıcaklık değişimi (1998-2019)

5.1.2 Ortalama Yağış Miktarı


Elektrik tüketimi tahmin çalışmalarında iklimsel değişkenler arasında sıcaklık değişkeninden sonra kullanılan en önemli göstergelerden biri de yağış miktarıdır. Şekil 5.2’de 1998-2019 yılları arasında yağış miktarı değişimi gösterilmiştir.



Şekil 5.2 Türkiye aylık yağış miktarı değişimi (1998-2019)

5.1.3 Tüketici Fiyat Endeksi


Tüketici Fiyat Endeksi (TÜFE), belirli hane grubu tarafından satın alınan bir ürün ve hizmet sepetinin fiyatlarındaki değişiklik olarak tanımlanmaktadır. TÜFE, hane halkının satın alma gücüyle ilgili bir değişkendir. Hayat standartlarının artması, alım gücünün yükselmesi gibi etkenler elektrik tüketimiyle yüksek ilişkilidir. Şekil 5.3’te 1998-2019 yılları arasında TÜFE değişimi gösterilmiştir. Bu gösterge TÜFE değişikliğini referans bir endeks yardımıyla ölçer. Elimizdeki verilerde 2015 yılı referans olarak (2015=100) alınmıştır.



Şekil 5.3 Türkiye aylık TÜFE değişimi (1998-2019)

5.1.4 Toplam Sanayi Üretim Endeksi


Toplam sanayi üretimi, madencilik, imalat, elektrik, gaz, iklimlendirme sektörlerinin toplam üretimini kapsar. 2017 verilerine göre elektrik tüketiminin %46,8'i sanayi kaynaklıdır (Şekil 4.2). Bu yüzden Toplam Sanayi Üretim Endeksi (TSÜE) elektrik tüketiminin tahmininde yüksek öneme sahiptir. TSÜE göstergesi üretim çıktısı hacmindeki değişikliği referans bir endeks yardımıyla ölçer. Elimizdeki verilerde 2015 yılı referans olarak (2015=100) alınmıştır. Şekil 5.4'te 1998-2019 yılları arasında TSÜE değişimi gösterilmiştir.




Şekil 5.4 Türkiye aylık TSÜE değişimi (1998-2019)

5.1.5 Toplam İthalat ve İhracat

Toplam ithalat ve ihracat bir ülkenin refahının ve büyümesinin ölçülmesinde önemli değişkenlerdir. Elektrik üretiminde birincil kaynakların büyük çoğunluğu ithal edilmektedir. Bu yüzden bu parametrelerdeki değişimler elektrik tüketimiyle ilişkilidir. Şekil 5.5 ve Şekil 5.6'da sırasıyla 1998-2019 yılları arasında toplam ithalat ve toplam ihracat değerlerindeki değişim gösterilmiştir.




Şekil 5.5 Türkiye aylık toplam ithalat değişimi (1998-2019)



Şekil 5.6 Türkiye aylık toplam ihracat değişimi (1998-2019)

5.1.6 Brüt Elektrik Tüketimi

Brüt Elektrik Tüketimi tahmin çalışmamızın çıktısını oluşturmaktadır. Bu değer Türkiye’de üretilen elektrik ve ithal edilen elektrikten, ihraç edilen elektriğin düşülmesiyle elde edilmiştir. Şekil 5.7’de 1998-2019 yılları arasında Türkiye’nin Brüt Elektrik Tüketimi değişimi gösterilmiştir.



Şekil 5.7 Türkiye aylık brüt elektrik talebi değişimi (1998-2019)

5.2 Uygulanacak Yöntem Parametrelerinin Seçimi

Uygulamada farklı mimarilere sahip ÇKYSA kullanılmıştır. Tüm ağ topolojileri MATLAB programlama dilinde geliştirilmiştir. Kullanılacak ağın tasarlanmasında belirlenmesi gereken parametreler aşağıda sıralanmıştır:

- Giriş Katmanı Nöron Sayısı,
- Gizli Katman Nöron Sayısı,
- Çıktı Katmanı Nöron Sayısı,
- Gizli Katman ve Gizli Katman Nöron Sayısı,
- Aktivasyon Fonksiyonu,
- Öğrenme Algoritması,
- Normalizasyon Yöntemi,

- Eğitim ve Test Verisi Ayırma Yöntemi,
- Performans Ölçüm Kriteri [74].

Aşağıda, belirtilen tüm parametrelerin seçilmesinde dikkat edilmesi gereken unsurlar ve uygulamadaki kullanılma şekilleri anlatılmıştır.

Girdi Katmanı Nöron Sayısı: Uygulama için seçilen 6 girdi değişkeni giriş katmanı için nöron sayısını oluşturmaktadır. ÇKYSA'da, tüm değişkenler teker teker girdi katmanından çıkartılarak ağ eğitilmiş ve performans kriterlerindeki değişim takip edilmiştir. Performans kriterlerindeki değişime göre girdi değişkenleri seçilmiştir.

Çıktı Katmanı Nöron Sayısı: Çıktı katmanını Elektrik Tüketimi oluşturmaktadır ve katman Elektrik Tüketimini temsilen 1 nörona sahiptir.

Gizli Katman Sayısı ve Nöron Sayısı: Gizli katman, YSA'nın verinin özelliğini öğrendiği ve girdi ile çıktı arasındaki lineer olmayan ilişkiyi yakaladığı önemli bir ağ elemanıdır. Bir adet gizli katman çoğu tahmin probleminde yetmektedir fakat bazı durumlarda 2 gizli katman daha iyi sonuç vermektedir [74].

Tek gizli katmanda tatmin edici performans için fazla sayıda nörona ihtiyaç duyulmaktadır. Bu da ağa aşırı yüklenmeye sebep olmaktadır. Gizli katmanda nöron sayısı az olduğunda ağın genelleştirme kabiliyeti artmakta ve ağın aşırı uyum problemi azalmaktadır. Fakat az nöronlu ağlarda da modelleme ve öğrenme gücü azalmaktadır [74].

Uygulamada gizli katman ve gizli katman nöron sayısına karar vermek için farklı kombinasyonlu ağ mimarileri denenmiş ve en iyi performansa sahip ağ tercih edilmiştir. Denemelerde maksimum 2 gizli katman kullanılmıştır. Her bir gizli katman nöron sayısı 1 ile 20 arasında değiştirilerek denemeler yapılmıştır.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu girdi ve çıktı arasındaki ilişkiyi belirler ve ağın lineer olmama derecesini açıklar [74]. Literatürde çoğunlukla lojistik sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu kullanılmıştır. Uygulamada her iki fonksiyon da farklı ağ mimarilerinde denenmiştir.

Öğrenme Algoritması: YSA'da öğrenme, lineer olmayan kısıtsız bir minimizasyon problemi olarak görülebilir. Ağ gerçek çıktı ile tahmin edilen çıktı arasında toplam kare

hatayı en aza indirmek için ağırlık değerlerini iteratif olarak değiştirir. Makul süre içinde global optimum sonucu garanti edecek mevcut bir öğrenme algoritması yoktur. Tüm optimizasyon problemleri için lokal optimuma yakalanma problemi kaçınılmazdır; bu durumda istenilen, global çözüm yoksa en iyi lokal optimumu veren optimizasyon yönteminin seçilmesidir [74].

Popüler olarak en çok kullanılan öğrenme algoritması bir geri yayılım algoritması olan Gradyan Düşüm Algoritmasıdır (GDA). Literatürde gradyan düşüm algoritmasının yavaş yakınsama özelliğinin geliştirilmesi için momentum faktörlü gradyan düşüm algoritmaları ortaya konmuştur. GDA parametrelerinin seçiminde literatürde farklı görüşler vardır fakat bu görüşler değerlendirildiğinde tutarlı bir seçim kriteri belirlenememiştir. Bu yüzden GDA gürbüz (robust) olmayan yetersiz bir yöntem olarak görülebilir. Geleneksel geri yayılım algoritmalarında yaşanan sorunlar sebebiyle literatürde adaptif yöntemler ve ikinci dereceden yöntemler önerilmiştir [74].

Elektrik tüketim tahmini uygulamasında birçok öğrenme algoritması denenmiştir; fakat en iyi sonucu ikinci dereceden bir yöntem olan Levenberg-Marquardt (L-M) metodu vermiştir.

Normalizasyon Yöntemi: Veri normalizasyonu, eğitim prosesi başlamadan uygulanır. Literatür incelendiğinde verilerin, [0,1] ve [-1,1] aralıklarında normalizasyonu daha çok kullanılmıştır.

[0,1] aralığı için kullanılan formül (5.1)'deki gibidir:

$$x_n = (x_0 - x_{min}) / (x_{max} - x_{min}) \quad (5.1)$$

[-1,1] aralığı için kullanılan formül (5.2)'deki gibidir:

$$x_n = [2 \cdot (x_0 - x_{min}) / (x_{max} - x_{min})] - 1 \quad (5.2)$$

Uygulamada [-1,1] aralığında normalizasyonun, hiperbolik tanjant fonksiyonuyla birlikte kullanıldığı ağlar daha iyi sonuç vermiştir.

Eğitim ve Test Verisi Ayırma Yöntemi: Uygulamada veri, eğitim, validasyon ve test olmak üzere 3 kısma ayrılmıştır. Literatür çalışmalarına bakıldığında bu ayırım sırasıyla toplam verinin %70-%15-%15'i ayrılarak veya daha az veriye sahip örneklerde toplam

verinin %80-%10-%10'u ayrılarak uygulanmıştır. Uygulamada toplam veri sayısı çok olmadığından %80-%10-%10 ayrımı kullanılmıştır.

- Verinin %80'i eğitim için kullanılmıştır.
- Verinin %10'u validasyon için kullanılmıştır. Verinin bu kısmı eğitilmemekte, ağın genelleştirildiğini doğrulamak için veya ağın aşırı uyuma (overfitting) yakalanmasını önlemek için ağı kontrol etmektedir.
- Verinin kalan %10'luk kısmı ağa daha önceden gösterilmemiş olan test kısmını oluşturur. Verinin bu kısmı ağa girdi olarak verilir ve bilinen çıktı değerleri ile ağı tahmin edilen çıktıları karşılaştırılır.

Uygulamada veri ayırma işlemi, belirlenen oranlar sabit olmak üzere sırasıyla bloklar halinde yapılabildiği gibi (divideblock); yine aynı oranlar kullanılarak rastgele (dividerand) parçalar halinde de uygulanabilir. Tüm ağ mimarileri için her iki veri ayırma tipi kullanılmış, rastgele ayırma yöntemi daha iyi sonuç vermiştir.

Performans Ölçüm Kriteri: Literatür çalışmalarına bakıldığında en çok kullanılan performans ölçüm kriterleri (5.3), (5.4), (5.5), (5.6) ve (5.7) ifadeleriyle gösterilmiştir.

$$\text{Ortalama Mutlak Hata: } MAE = \frac{\sum |e_t|}{N} \quad (5.3)$$

$$\text{Hata Kareler Toplamı: } SSE = \sum (e_t)^2 \quad (5.4)$$

$$\text{Ortalama Karesel Hata: } MSE = \frac{\sum (e_t)^2}{N} \quad (5.5)$$

$$\text{Kök Ortalama Kare Hata: } RMSE = \sqrt{MSE} \quad (5.6)$$

$$\text{Ortalama Mutlak Yüzdellik Hata: } MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| \quad (5.7)$$

Uygulamada MAPE performans ölçüm kriteri kullanılmıştır. MAPE, çoğu elektrik tüketim tahmini çalışmasında kullanıldığı için ve yüzdellik hatayı hesaplayıp karşılaştırma yaparken kolaylık sağladığı için tercih edilmiştir.

5.3 ÇKYSYA Yönteminin Uygulanması

5.3.1 ÇKYSYA Uygulama Adımları

Uygulamada ÇKYSYA'da birçok farklı parametrenin farklı değerleri denenmiştir. Bu denemeler sonunda performans kriterleri değerlendirilmiş ve en iyi ağ yapısı seçilmiştir. Şekil 5.8'de ÇKYSYA Yönteminin uygulama adımları görülmektedir.

Adım 1: Veri [-1,1] aralığında normalize edilir.

Adım 2: Veri %80-%10-%10 oranlarında Eğitim-Validasyon-Test kısımlarına ayrılır.

Adım 3.1: Eğitim Verisi eğitilmek üzere ağa verilir. Eğitim aşamasında Levenberg-Marquardt eğitim algoritması kullanılmıştır. Eğitim algoritması için MATLAB'ın varsayılan parametrelerinden faydalanılmıştır (Çizelge 5.3).

Çizelge 5.3 MATLAB'ın Levenberg Marquardt algoritması için varsayılan değerleri


| | |
|------------------------------------|-------|
| Maksimum İterasyon Sayısı | 1000 |
| Minimum Performans Gradyanı | 1e-7 |
| Başlangıç mu değeri | 0,001 |
| mu artış faktörü | 10 |
| mu düşüş faktörü | 0,1 |
| Maksimum mu | 1e10 |

Adım 3.2: Validasyon verisi eğitim verisinden farklı olarak ağ eğitilirken ağa verilir ve ağın aşırı uyuma yakalanma durumu kontrol edilir. Ağın eğitiminin yeterli olduğu ve durdurulması kararı bu adımda verilir.

Adım 3.3: Test verisi, eğitilmiş ve doğrulanmış olan ağa verilir. Bu aşamada test verisinin gerçek çıktı değeriyle, ağda hesaplanmış tahmini çıktı değeri karşılaştırılır.

Adım 4: Hata değeri istenilen düzeydeyse bir sonraki adıma geçilir; değilse süreç Adım 2'ye geri döner.

Adım 5: Döngü kapatılır ve ağ kaydedilir. Ağ, yeni girdi değerlerinin verilip çıktı değerinin tahmin edilebileceği duruma getirilmiş olur.



Şekil 5.8 ÇKSYA yöntemi uygulama adımları

5.3.2 ÇKSYA Sonuçları

ÇKSYA kullanılarak denenen ağ mimarileri Çizelge 5.4'te gösterilmiştir. Tüm denemelerde normalizasyon $[-1,1]$ arasında yapılmış, veri ayrımı oranı %80-%10-%10 olarak belirlenmiş ve öğrenme algoritması olarak Levenberg-Marquardt kullanılmıştır. Deneme yapılan ağlarda tek gizli katmanlı ağlar için 10 deneme, 2 gizli katmanlı ağlar için 5 deneme yapılmıştır.

Çizelge 5.4 ÇKYSA'da yapılan denemeler

| # | Kullanılan Girdi Değişkenleri | Veri Bölme Tipi | Akt. Fonk. [1] | Akt. Fonk. [2] | Denenen Gizli Katman Nöron Sayısı |
|------|--------------------------------------|-----------------|----------------|----------------|--|
| 1.1 | T, Y, TÜFE, TSÜE, ITH, IHR [6 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.2 | T, Y, TÜFE, TSÜE, ITH, IHR [6 Girdi] | divideblock | logsig | - | 1.....20 nöron (1.katman) |
| 1.3 | T, Y, TÜFE, TSÜE, ITH, IHR [6 Girdi] | dividerand | tansig | - | 1.....20 nöron (1.katman) |
| 1.4 | T, Y, TÜFE, TSÜE, ITH, IHR [6 Girdi] | dividerand | logsig | - | 1.....20 nöron (1.katman) |
| 1.5 | Y, TÜFE, TSÜE, ITH, IHR [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.6 | T, TÜFE, TSÜE, ITH, IHR [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.7 | T, Y, TSÜE, ITH, IHR [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.8 | T, Y, TÜFE, ITH, IHR [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.9 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.10 | T, Y, TÜFE, TSÜE, ITH [5 Girdi] | divideblock | tansig | - | 1.....20 nöron (1.katman) |
| 1.11 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | divideblock | tansig | tansig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.12 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | dividerand | tansig | tansig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.13 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | divideblock | tansig | logsig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.14 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | dividerand | tansig | logsig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.15 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | divideblock | logsig | tansig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.16 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | dividerand | logsig | tansig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.17 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | divideblock | logsig | logsig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |
| 1.18 | T, Y, TÜFE, TSÜE, IHR [5 Girdi] | dividerand | logsig | logsig | 1.....20 nöron (1.katman) 1.....20 nöron (2.katman) |

Aşağıda denemelerde parametrelerin seçimi sırasında dikkat edilen hususlar özetlenmiştir:

Model 1.1 ve 1.4 Arası

6 girdi (T, Y, TÜFE, TSEÜ, ITH, IHR), farklı aktivasyon fonksiyonları kullanılarak (logsig-tansig), farklı veri ayırma tipleriyle (divideblock-dividerand) ve tek katmanlı gizli katman nöron sayıları 1 ile 20 arasında değiştirilerek eğitilmiştir.

Model 1.5 ve 1.10 Arası

6 girdi (T, Y, TÜFE, TSEÜ, İTH, İHR) tek tek mimariden çıkarılmış ve performans kriterine etkisi incelenmiştir. Bu denemelerde tansig aktivasyon fonksiyonu, divideblock veri ayırma tipi kullanılmıştır. İthalat değişkeni girdi verisinden çıkarıldığında performans kriterinde iyileşme olduğu görülmüştür. Bu aşamadan sonraki denemelere, 5 değişken (T, Y, TÜFE, TSEÜ, İHR) kullanılarak devam edilmiştir.

Model 1.11 ve 1.18 Arası

5 girdi (T, Y, TÜFE, TSEÜ, İHR), farklı aktivasyon fonksiyonları kullanılarak (logsig-tansig), farklı veri ayırma tipleriyle (divideblock-dividerand) ve 2 katmanlı gizli katman nöron sayıları 1 ile 20 arasında değiştirilerek eğitilmiştir.

Çizelge 5.5'te denemeler sonucunda elde edilen performans kriterlerinin karşılaştırılması gösterilmiştir.

Çizelge 5.5 ÇKYSA'da yapılan denemelerin sonuçları


| Model No | 1. Katman Nöron Sayısı | 2. Katman Nöron Sayısı | MAPE (eğitim) | MAPE (validasyon) | MAPE (test) |
|----------|------------------------|------------------------|---------------|-------------------|--------------|
| 1.1 | 13 | - | 0,023 | 0,030 | 0,036 |
| 1.2 | 8 | - | 0,018 | 0,022 | 0,036 |
| 1.3 | 7 | - | 0,024 | 0,024 | 0,026 |
| 1.4 | 7 | - | 0,023 | 0,026 | 0,023 |
| 1.5 | 2 | - | 0,054 | 0,055 | 0,057 |
| 1.6 | 6 | - | 0,022 | 0,023 | 0,037 |
| 1.7 | 10 | - | 0,025 | 0,034 | 0,048 |
| 1.8 | 13 | - | 0,023 | 0,027 | 0,036 |
| 1.9 | 15 | - | 0,018 | 0,027 | 0,033 |
| 1.10 | 16 | - | 0,026 | 0,033 | 0,043 |
| 1.11 | 20 | 7 | 0,016 | 0,033 | 0,026 |
| 1.12 | 5 | 18 | 0,021 | 0,024 | 0,027 |
| 1.13 | 7 | 3 | 0,021 | 0,028 | 0,030 |
| 1.14 | 6 | 7 | 0,018 | 0,026 | 0,019 |
| 1.15 | 4 | 7 | 0,036 | 0,038 | 0,038 |
| 1.16 | 6 | 20 | 0,018 | 0,023 | 0,018 |
| 1.17 | 5 | 8 | 0,024 | 0,028 | 0,031 |
| 1.18 | 14 | 20 | 0,020 | 0,026 | 0,020 |

5.3.2.1 ÇKYSA Deneme Sonuçlarının Değerlendirilmesi

Yapılan denemeler sonucunda $MAPE_{\text{eğitim}}$, $MAPE_{\text{validasyon}}$, $MAPE_{\text{test}}$ sonuçları birlikte değerlendirildiğinde 1.12 numaralı ağın en iyi tahmin sonucunu verdiği görülmüştür. Değerlendirme yapılırken, en düşük $MAPE_{\text{test}}$ değerine sahip olan, $MAPE_{\text{eğitim}} < MAPE_{\text{validasyon}} < MAPE_{\text{test}}$ durumunu sağlayan ve bu değerlerin birbirine yakın olduğu model seçilmiştir.


1.12 Numaralı Ağ Özellikleri

Ağda girdi olarak Sıcaklık, Yağış Miktarı, TÜFE, TSÜE ve İhracat Miktarı kullanılmıştır. Veriler $[-1,1]$ aralığında normalize edilmiştir. Ağ 2 gizli katmandan oluşmaktadır. Katmanlar sırasıyla 5 ve 18 nörona sahiptir. Gizli katmanların ikisinde de aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır. Seçilen ağ mimarisini şekilde gösterilmektedir.



Şekil 5.9 1.12 numaralı ağın mimarisi

Ağ eğitimi 15. iterasyonda sonlanmış ve Şekil 5.10'daki ortalama kare hata grafiği elde edilmiştir.




Şekil 5.10 1.12 numaralı ağın performans grafiği

Ağın performans göstergeleri Çizelge 5.6'da verilmiştir ve Şekil 5.11'de regresyon grafiği gösterilmiştir.

Çizelge 5.6 12.1 numaralı ağın performans göstergeleri

| MAPE (eğitim) | MAPE (validasyon) | MAPE (test) | R ² |
|---------------|-------------------|-------------|----------------|
| 0,021 | 0,024 | 0,027 | 0,9963 |



Şekil 5.11 12.1 numaralı ağın regresyon grafiği

5.4 Girdilerin Tahmini

Uygulamada buraya kadar ÇKYSA ile farklı denemeler yapılarak bir tahmin modeli oluşturulmuştur. İleriye yönelik 12 aylık bir dönemde tahmin yapılmak istendiği için girdi verilerimizin bu 12 aylık dönemde mevcut olması gerekir. Problemimiz, bir zaman serisi problemi olduğundan bu 12 aylık verinin de ayrıca tahmin edilmesi gerekmektedir.

Tahmin için Lineer Olmayan Otoresif Sinir Ağı (NAR) yöntemi kullanılmıştır. Bu yöntem NARX yönteminin spesifik bir alt yöntemidir. Farklı olarak tek bir seri içermektedir ve tahmin için sadece girdi olarak bu serinin geçmiş değerleri kullanılabilir. NAR yönteminin formülü (5.8)'de verilmiştir.

$$y(t) = f(y(t-1), \dots, y(t-d)) \quad (5.8)$$

5.4.1 Ortalama Sıcaklık ve Ortalama Yağış Miktarı Tahmini

Ortalama Sıcaklık ve Ortalama Yağış Miktarı tahmini ayrı bir çalışma konusu olduğu için ve NAR yöntemiyle iyi sonuçlar alınmaması sebebiyle Meteoroloji Genel Müdürlüğü'nün sunduğu 1970-2018 yılları arası aylık ortalama sıcaklık ve ortalama yağış miktarı verileri girdi olarak kullanılacaktır [67], [68]. Bu veriler Çizelge 5.7'de gösterilmiştir.

Çizelge 5.7 1970-2018 yılları arası sıcaklık ve yağış miktarı ortalamaları

| Aylar | Ortalama Sıcaklık Ortalaması (°C) | Ortalama Yağış Miktarı Ortalaması (mm) |
|---------|-----------------------------------|--|
| Ocak | 2,2 | 79,3 |
| Şubat | 3,4 | 67,8 |
| Mart | 7,0 | 63,5 |
| Nisan | 12,0 | 58,4 |
| Mayıs | 16,6 | 48,6 |
| Haziran | 21,2 | 31,7 |
| Temmuz | 24,4 | 16,5 |
| Ağustos | 24,2 | 16,4 |
| Eylül | 20,1 | 25,9 |
| Ekim | 14,5 | 57,5 |
| Kasım | 8,6 | 70,9 |
| Aralık | 4,1 | 86,3 |

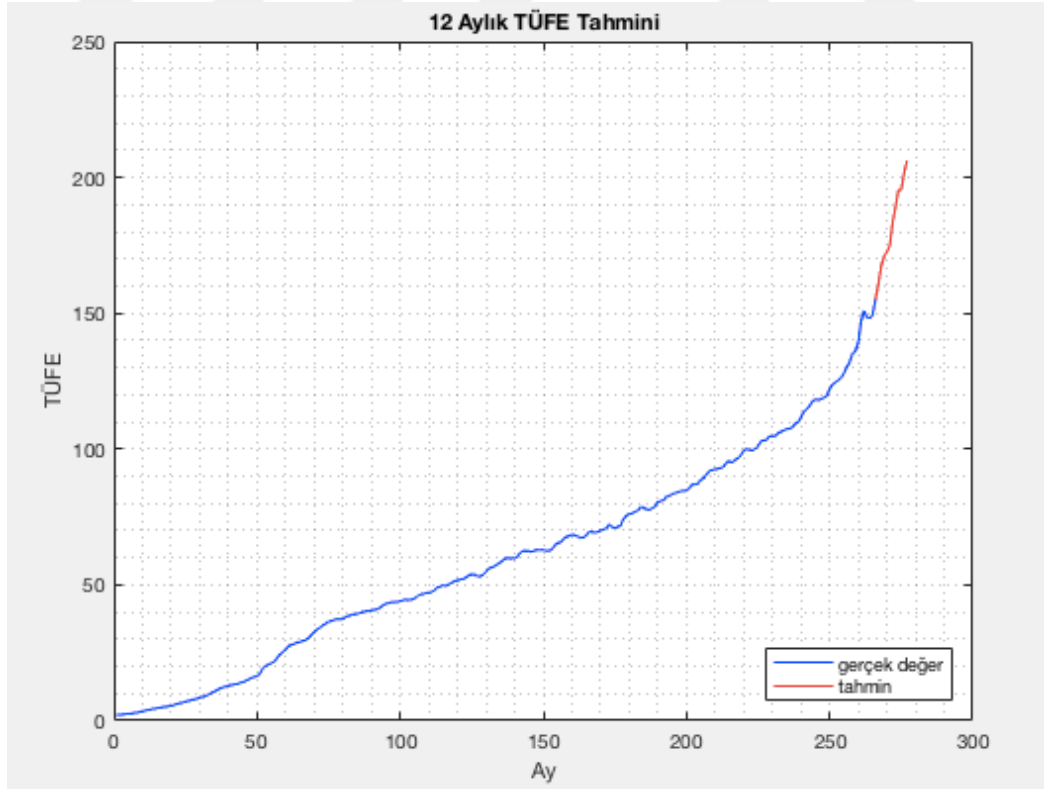
5.4.2 Tüketici Fiyat Endeksi Tahmini

TÜFE tahmini için 01.1998-01.2019 tarihleri arasındaki değerlerin kullanılmasıyla en iyi sonuç alınmıştır. Tahmin için Çizelge 5.8'deki ağ parametreleriyle, nöron sayısı (1 ile 20 arasında) ve gecikme sayısı (1 ile 20 arasında) değiştirilerek denemeler yapılmıştır.

Çizelge 5.8 TÜFE tahmini için eğitim parametreleri

| | |
|------------------------------|-------------|
| Veri Normalizasyonu | [1,-1] |
| Veri Bölme | %80-%10-%10 |
| Veri Bölme Türü | dividerand |
| Aktivasyon Fonksiyonu | tansig |
| Eğitim Algoritması | L-M |

Yapılan denemeler sonucunda açık döngü ve kapalı döngü sonuçları ayrı ayrı incelenmiştir. En iyi sonuç gizli katmanında 16 nörona sahip; gecikmesi 1:16 olan ağ tarafından verilmiştir. Şekil 5.12'de tahmin edilen 12 aylık TÜFE değeri, mevcut veriyle birlikte gösterilmiştir.



Şekil 5.12 12 aylık TÜFE tahmini gösterimi


5.4.3 Toplam Sanayi Üretimi Endeksi Tahmini

TSÜE tahmini için 01.2009- 01.2019 tarihleri arasındaki değerlerin kullanılmasıyla en iyi sonuç alınmıştır. Tahmin için Çizelge 5.9'daki ağ parametreleriyle, nöron sayısı (1 ile 20 arasında) ve gecikme sayısı (1 ile 20 arasında) değiştirilerek denemeler yapılmıştır.

Çizelge 5.9 TSÜE tahmini için eğitim parametreleri

| | |
|------------------------------|-------------|
| Veri Normalizasyonu | [1,-1] |
| Veri Bölme | %80-%10-%10 |
| Veri Bölme Türü | dividerand |
| Aktivasyon Fonksiyonu | tansig |
| Eğitim Algoritması | L-M |

Yapılan denemeler sonucunda açık döngü ve kapalı döngü sonuçları ayrı ayrı incelenmiştir. En iyi sonuç gizli katmanında 5 nörona sahip; gecikmesi 1:17 olan ağda alınmıştır. Şekil 5.13'te tahmin edilen 12 aylık TSÜE miktarı değeri, mevcut veriyle birlikte gösterilmiştir.



Şekil 5.13 12 aylık TSÜE tahmini gösterimi

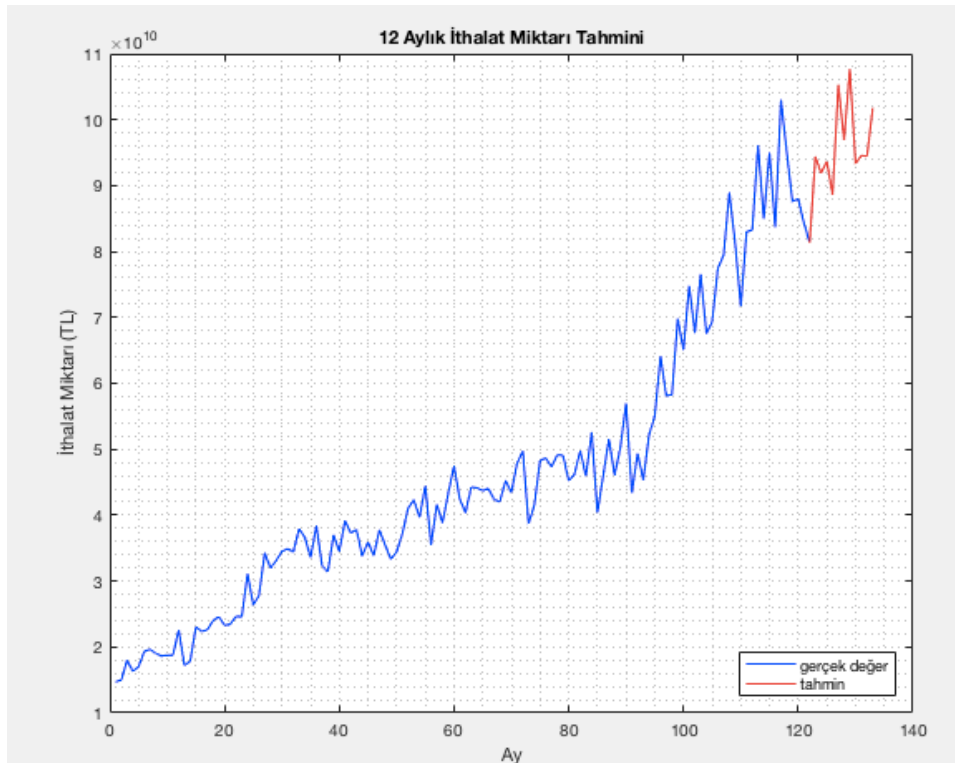
5.4.4 İthalat Miktarı Tahmini

İthalat miktarı tahmini için 01.2009-01.2019 tarihleri arasındaki değerlerin kullanılmasıyla en iyi sonuç alınmıştır. Tahmin için Çizelge 5.10'daki ağ parametreleriyle, nöron sayısı (1 ile 20 arasında) ve gecikme sayısı (1 ile 20 arasında) değiştirilerek denemeler yapılmıştır.

Çizelge 5.10 İthalat miktarı tahmini için eğitim parametreleri

| | |
|------------------------------|-------------|
| Veri Normalizasyonu | [1,-1] |
| Veri Bölme | %80-%10-%10 |
| Veri Bölme Türü | dividerand |
| Aktivasyon Fonksiyonu | tansig |
| Eğitim Algoritması | L-M |

Yapılan denemeler sonucunda açık döngü ve kapalı döngü sonuçları ayrı ayrı incelenmiştir. En iyi sonuç gizli katmanında 2 nörona sahip; gecikmesi 1:17 olan ağda alınmıştır. Şekil 5.14'te tahmin edilen 12 aylık ithalat miktarı değeri, mevcut veriyle birlikte gösterilmiştir.



Şekil 5.14 12 aylık ithalat miktarı tahmini gösterimi


5.4.5 İhracat Miktarı Tahmini

İhracat miktarı tahmini için 01.2009-01.2019 tarihleri arasındaki değerlerin kullanılmasıyla en iyi sonuç alınmıştır. Tahmin için Çizelge 5.11'deki ağ parametreleriyle, nöron sayısı (1 ile 20 arasında) ve gecikme sayısı (1 ile 20 arasında) değiştirilerek denemeler yapılmıştır.

Çizelge 5.11 İhracat miktarı tahmini için eğitim parametreleri

| | |
|------------------------------|-------------|
| Veri Normalizasyonu | [1,-1] |
| Veri Bölme | %80-%10-%10 |
| Veri Bölme Türü | dividerand |
| Aktivasyon Fonksiyonu | tansig |
| Eğitim Algoritması | L-M |

Yapılan denemeler sonucunda açık döngü ve kapalı döngü sonuçları ayrı ayrı incelenmiştir. En iyi sonuç gizli katmanında 2 nörona sahip; gecikmesi 1:14 olan ağda alınmıştır. Şekil 5.15'de tahmin edilen 12 aylık İhracat Miktarı değeri, mevcut veriyle birlikte gösterilmiştir.



Şekil 5.15 12 aylık ihracat miktarı tahmini gösterimi

5.5 Girdi Değişkenleri Özet Çizelgesi

Hesaplanan girdi tahminleri Çizelge 5.12’de verilmiştir.

Çizelge 5.12 Girdi değişkenleri 12 aylık tahmin değerleri

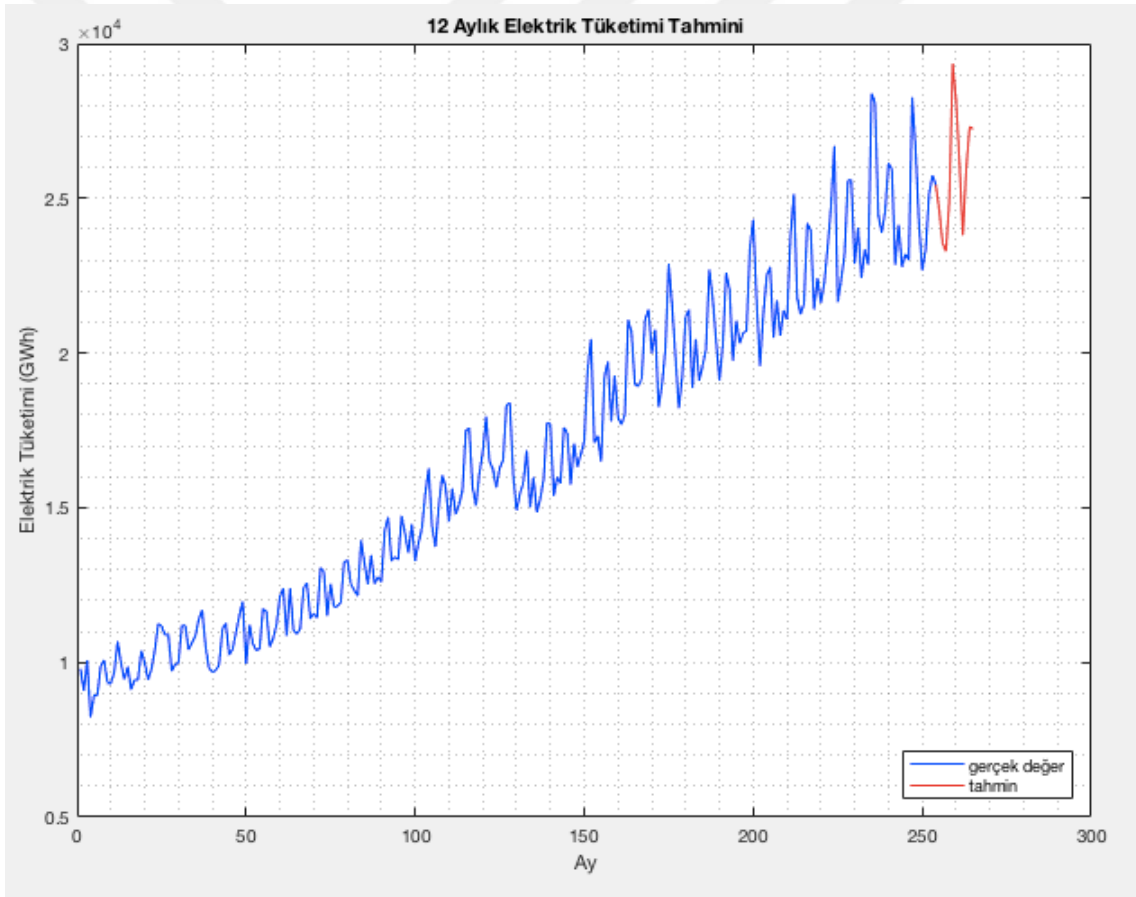
| Aylar | Sıcaklık (°C) | Yağış (mm) | TÜFE (2015=100) | TSÜE (2015=100) | İTHALAT (TL) | İHRACAT (TL) |
|--------------|---------------|------------|-----------------|-----------------|--------------------|--------------------|
| Şubat 2019 | 3,4 | 67,8 | 155,05 | 108,13 | 81.341.587.366,34 | 80.134.799.897,25 |
| Mart 2019 | 7,0 | 63,5 | 160,52 | 117,10 | 94.405.092.421,32 | 86.729.844.608,16 |
| Nisan 2019 | 12,0 | 58,4 | 167,23 | 115,37 | 91.906.336.872,63 | 82.842.460.664,22 |
| Mayıs 2019 | 16,6 | 48,6 | 170,92 | 116,52 | 93.649.850.088,97 | 84.244.589.030,71 |
| Haziran 2019 | 21,2 | 31,7 | 172,56 | 111,04 | 88.604.680.499,45 | 78.363.718.185,37 |
| Temmuz 2019 | 24,4 | 16,5 | 174,73 | 122,89 | 105.286.217.977,19 | 83.128.107.390,98 |
| Ağustos 2019 | 24,2 | 16,4 | 183,27 | 102,38 | 96.913.245.170,93 | 86.740.507.419,66 |
| Eylül 2019 | 20,1 | 25,9 | 189,08 | 121,70 | 107.651.989.548,46 | 102.146.855.985,64 |
| Ekim 2019 | 14,5 | 57,5 | 195,38 | 109,92 | 93.348.701.584,38 | 102.998.647.060,68 |
| Kasım 2019 | 8,6 | 70,9 | 195,29 | 119,12 | 94.545.788.009,36 | 101.440.321.844,00 |
| Aralık 2019 | 4,1 | 86,3 | 201,51 | 108,97 | 94.468.980.526,20 | 97.268.191.090,93 |
| Ocak 2020 | 2,2 | 79,3 | 206,08 | 103,52 | 101.762.259.687,47 | 97.601.482.633,72 |

5.6 ÇKYSA ile Tahmin Sonucu

Uygulamada Çok Katmanlı Yapay Sinir Ağı Yönteminin farklı ağ mimarileri için birçok deneme yapılmıştır. Bu denemeler sonucunda en iyi performans kriteri değerini veren ağ, tahmin modeli olarak seçilmiştir. Sonraki aşamada NAR yöntemiyle girdi değişkenlerinin önümüzdeki 12 ay için tahmini yapılmıştır. Bu 12 aylık tahmin verisi, girdi olarak ÇKYSA’ya verilmiştir ve Şubat 2019-Ocak 2020 arasındaki tüketilecek elektriğin tahmini yapılmıştır.

Çizelge 5.13 12 aylık elektrik tüketim miktarı tahmini

| Aylar | Elektrik Tüketimi (GWh) | Aylar | Elektrik Tüketimi (GWh) |
|--------------|-------------------------|--------------|-------------------------|
| Şubat 2019 | 25436,3304 | Ağustos 2019 | 28157,8812 |
| Mart 2019 | 24616,1615 | Eylül 2019 | 26140,7583 |
| Nisan 2019 | 23567,6134 | Ekim 2019 | 23809,6259 |
| Mayıs 2019 | 23283,7685 | Kasım 2019 | 25964,6642 |
| Haziran 2019 | 24940,9434 | Aralık 2019 | 27311,4767 |
| Temmuz 2019 | 29351,6499 | Ocak 2020 | 27247,6191 |



Şekil 5.16 Şubat 2019-Ocak 2020 arasında elektrik tüketiminin tahmini

5.7 Uygulamanın Çoklu Doğrusal Regresyon Sonucu

ÇKYSA ile yapılan Elektrik Tüketimi tahminini Çoklu Doğrusal Regresyon Yöntemiyle karşılaştırılmıştır. Yöntemde Sıcaklık, Yağış, TÜFE, TSÜE, İthalat Miktarı ve İhracat Miktarı

bağımsız değişken, Elektrik Tüketimi ise bağımlı değişken olarak kullanılmıştır. Yapılan regresyon analizi sonucunda aşağıdaki sonuçlar elde edilmiştir.

Çizelge 5.14 6 bağımsız değişkenli regresyon analizi sonuçları

| E ~ 1 + T+ Y + TÜFE+ TSÜE + ITH + IHR | | | | |
|--|-----------------|--|--------------|---------------|
| | Estimate | SE | tStat | pValue |
| Intercept | 6060,4 | 618,53 | 9,798 | 2,38e-19 |
| T | -5,54 | 13,94 | -0,39 | 0,69 |
| Y | -3,91 | 3,57 | -1,09 | 0,27 |
| TÜFE | 111,31 | 8,89 | 12,51 | 3,92e-28 |
| TSÜE | 61,83 | 13,05 | 4,73 | 3,67e-06 |
| ITH | 9,31e-08 | 2,55e-08 | 3,64 | 0,0003 |
| IHR | -1,65e-07 | 2,50e-08 | -6,61 | 2,35e-10 |
| R²= 0,941 | | R²_{adj}= 0,94 | | |

6 bağımsız değişkenin kullanıldığı regresyon analizi sonuçlarına bakıldığında Sıcaklık ve Yağış Miktarının pValue değerleri %5 anlamlılık düzeyinde model için anlamlı değildir. Bu iki değişken çıkarılıp 4 bağımsız değişkenle tekrar regresyon analizi yapıldığında aşağıdaki sonuçlar bulunur.

Çizelge 5.15 4 bağımsız değişkenli regresyon analizi sonuçları

| E ~ 1 + TÜFE+ TSÜE + ITH + IHR | | | | |
|---------------------------------------|-----------------|--|--------------|---------------|
| | Estimate | SE | tStat | pValue |
| Intercept | 5741,9 | 510,28 | 11,25 | 5,29e-24 |
| TÜFE | 109,94 | 8.779 | 12,52 | 3,30e-28 |
| TSÜE | 63,25 | 12,95 | 4,88 | 1,85e-06 |
| ITH | 9,52e-08 | 2,54e-08 | 3,73 | 0,00023 |
| IHR | -1,67e-07 | 2,49e-08 | -6,70 | 1,31e-10 |
| R²= 0,941 | | R²_{adj}= 0,94 | | |

Bu sonuca göre $R^2_{adj} = 0,94$ olarak hesaplanmıştır ve regresyon denklemi (5.9)'da verilmiştir.

$$E = 109,9 T\ddot{U}FE + 63,2 TS\ddot{U}E + 9,5 \cdot 10^8 ITH + 1,6 \cdot 10^{-7} IHR + 5741 \quad (5.9)$$

SONUÇ VE ÖNERİLER

Elektrik, günlük hayatımızın sürdürülebilmesi için büyük öneme sahiptir. Gelişen teknoloji, nüfusun artışı ve hayat standartlarının yükselmesiyle elektriğe olan ihtiyaç da giderek artmaktadır. Elektrik talebinin kesintisiz bir şekilde karşılanabilmesi için de elektrik üretiminin planlanması önem teşkil etmektedir.

Türkiye birincil enerji kaynakları açısından dışa bağımlı bir ülkedir. Bu yüzden elektrik üretiminin planlanması ve elektrik arz güvenliğinin sağlanması Türkiye için büyük öneme sahiptir.

Bu tezde, literatürde yapılan çalışmaların azlığı da göz önünde bulundurularak Türkiye'nin Aylık Elektrik Tüketimi tahmini üzerinde çalışılmıştır. Yöntem olarak Yapay Sinir Ağları kullanılmıştır.

Çalışmanın ilk kısmında literatür özetlenmiş, ikinci kısmında detaylı olarak literatürdeki yapılan çalışmalar incelenmiştir. Üçüncü kısımda tahmin yöntemi olarak kullanılan YSA'nın teorik altyapısından bahsedilmiştir. Dördüncü kısımda ise Türkiye'nin güncel elektrik kullanımı görünümünden bahsedilmiştir. Son kısımda da ÇKYSA mimarileri arasından $MAPE_{test}$ değeri 0,027 olan tahmin modeli seçilmiş, NAR yöntemiyle 2019 Şubat-2020 Ocak arasında girdi değişkenlerinin tahmini yapılmış ve bu girdi verileri kullanılarak ÇKYSA modeliyle yine bu tarihler arasında aylık elektrik tüketimi tahmin edilmiştir.

MAPE performans kriterinin yorumlanmasında kullanılan Lewis'in 1982 yılında önerdiği ölçek Çizelge 6.1'de verilmiştir. Bu ölçeğe göre MAPE değerinin %10'nun altında olması yüksek doğrulukta tahmin yapıldığını göstermektedir.

Çizelge 6.1 MAPE kriterinin tahmin gücü [75]

| MAPE | Tahmin Gücü |
|------------------|--------------------------|
| MAPE < %10 | Yüksek Doğrulukta Tahmin |
| %10 < MAPE < %20 | İyi Tahmin |
| %20 < MAPE < %50 | Kabul edilebilir Tahmin |
| %50 < MAPE | Zayıf Tahmin |

Tahmin modeli Çoklu Doğrusal Regresyonla karşılaştırıldığında R^2 değeri açısından Yapay Sinir Ağı'nın daha üstün bir tahmin modeli olduğu görülmüştür.

Çizelge 6.2 Performans kriterleri karşılaştırılması

| YÖNTEM | R^2 |
|--------------------------|-------|
| Yapay Sinir Ağı | 0,99 |
| Çoklu Doğrusal Regresyon | 0,94 |

Elektrik tüketiminin tahmini konusunda literatürde, farklı zaman ufukları için farklı yöntemlerle çalışmalar bulunmaktadır. İstatistiksel yöntemlere güçlü bir alternatif olan Yapay Sinir Ağları da bu yöntemlerden biridir. Çalışmalar incelendiğinde farklı yöntemlerin entegre şekilde kullanılmasının tahmin doğruluğunu güçlendirdiği görülmektedir.

Literatür çalışmalarında, elektriğin aylık tüketiminin tahmininde Genetik Algoritma ve Yapay Sinir Ağlarının ortak kullanıldığı çok çalışmaya rastlanmamıştır. Yapay Sinir Ağlarında, sinir ağı mimarisinin oluşturulması birçok parametreye bağlıdır. Bu parametrelerinin belirlenmesinde farklı yaklaşımlar sunulsa da tüm modellere etki edecek güçte ortak yaklaşım sayısı çok azdır. Genetik Algoritma kullanılarak, yapay sinir ağına başlangıç ağırlıkları, gizli katman sayısı, nöron sayısı, aktivasyon fonksiyonu seçimi gibi konularda geliştirmeler yapılabilir.

KAYNAKLAR

- [1] Boltürk, E., B. Öztayşi ve I. U. Sarı. (2012). "Electricity Consumption Forecasting Using Fuzzy Time Series", IEEE 13th International Symposium on Computational Intelligence and Informatics (CINTI), 2012:245-249
- [2] García-Ascanio, C. ve Maté, C., (2010). "Electric Power Demand Forecasting Using Interval Time Series: A Comparison Between VAR and iMLP", Energy Policy, 38(2):715-725.
- [3] Srinivasan, D. ve Lee, M. A. (1995). "Survey Of Hybrid Fuzzy Neural Approaches To Electric Load Forecasting", IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century, 5:4004-4008.
- [4] Ghiassi, M. D. K. Z., Zimbra, D. K., ve Saidane, H. (2006). "Medium Term System Load Forecasting With A Dynamic Artificial Neural Network Model", Electric Power Systems Research, 76(5):302-316.
- [5] Alfares, H. K., ve Nazeeruddin, M. (2002). "Electric Load Forecasting: Literature Survey And Classification Of Methods", International Journal of Systems Science, 33(1):23-34.
- [6] Saab, S., Badr, E. ve Nasr, G. (2001). "Univariate Modeling And Forecasting of Energy Consumption: The Case Of Electricity in Lebanon", Energy, 26(1):1-14.
- [7] Yumurtacı, Z., ve Asmaz, E. (2004). "Electric Energy Demand of Turkey for The Year 2050", Energy Sources, 26(12):1157-1164.
- [8] Yalçınöz, T. ve Eminoğlu, U. (2005). "Short Term And Medium Term Power Distribution Load Forecasting By Neural Networks", Energy Conversion and Management, 46(9-10):1393-1405.
- [9] Demirören, A. ve Ceylan, G. (2006). "Middle Anatolian Region Short-Term Load Forecasting Using Artificial Neural Networks", Electric Power Components and Systems, 34(6):707-724.
- [10] Pao, H. T. (2006). "Comparing Linear and Nonlinear Forecasts for Taiwan's Electricity Consumption", Energy, 31(12):2129-2141.
- [11] Ediger, V. Ş. ve Akar, S. (2007). "ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey", Energy Policy, 35(3):1701-1708.

- [12] Akay, D., ve Atak, M. (2007). "Grey Prediction with Rolling Mechanism for Electricity Demand Forecasting of Turkey", *Energy*, 32(9):1670-1675.
- [13] Ghiassi, M., Zimbra, D. K. ve Saidane, H. (2006). "Medium Term System Load Forecasting With a Dynamic Artificial Neural Network Model", *Electric Power Systems Research*, 76(5):302-316.
- [14] Gonzalez-Romera, E., Jaramillo-Moran, M. A. ve Carmona-Fernandez, D. (2006). "Monthly Electric Energy Demand Forecasting Based on Trend Extraction", *IEEE Transactions on Power Systems*, 21(4):1946-1953.
- [15] Ucenic, C. ve George, A. (2006). "A Neuro-Fuzzy Approach to Forecast the Electricity Demand", In *Proceedings of the 2006 IASME/WSEAS International Conference on Energy & Environmental Systems*, 2006:299-304.
- [16] Azadeh, A. ve Tarverdian, S. (2007). "Integration of Genetic Algorithm, Computer Simulation and Design of Experiments for Forecasting Electrical Energy Consumption", *Energy Policy*, 35(10):5229-5241.
- [17] Toksarı, M. D. (2007). "Ant Colony Optimization Approach to Estimate Energy Demand of Turkey", *Energy Policy*, 35(8):3984-3990.
- [18] Al-Shobaki, S. ve Mohsen, M. (2008). "Modeling and Forecasting of Electrical Power Demands for Capacity Planning", *Energy Conversion and Management*, 49(11):3367-3375.
- [19] Ghosh, S. (2008). "Univariate Time-Series Forecasting of Monthly Peak Demand of Electricity in Northern India", *International Journal of Indian Culture and Business Management*, 1(4):466-474.
- [20] González-Romera, E., Jaramillo-Morán, M. A. ve Carmona-Fernández, D. (2008). "Monthly Electric Energy Demand Forecasting with Neural Networks and Fourier Series", *Energy Conversion and Management*, 49(11):3135-3142
- [21] Ismail, Z., Jamaluddin, F. ve Jamaludin, F. (2008). "Time Series Regression Model For Forecasting Malaysian Electricity Load Demand", *Asian Journal of Mathematics and Statistics*, 1(3):139-149.
- [22] Ekonomou, L. (2010). "Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks", *Energy*, 35(2):512-517.
- [23] Geem, Z. W. ve Roper, W. E. (2009). "Energy Demand Estimation Of South Korea Using Artificial Neural Network", *Energy Policy*, 37(10):4049-4054.
- [24] Kavaklıoğlu, K., Ceylan, H., Öztürk, H. K. ve Canyurt, O. E. (2009). "Modeling and Prediction of Turkey's Electricity Consumption Using Artificial Neural Networks", *Energy Conversion and Management*, 50(11):2719-2727.
- [25] Çınar, D., Kayakutlu, G., & Daim, T. (2010). "Development of Future Energy Scenarios with Intelligent Algorithms: Case of Hydro in Turkey", *Energy*, 35(4):1724-1729.
- [26] García-Ascanio, C. ve Maté, C. (2010). "Electric Power Demand Forecasting Using Interval Time Series: A Comparison Between VAR and IMLP", *Energy Policy*, 38(2):715-725.

- [27] Ohtsuka, Y., Oga, T. ve Kakamu, K. (2010). "Forecasting Electricity Demand in Japan: A Bayesian Spatial Autoregressive ARMA Approach", *Computational Statistics & Data Analysis*, 54(11):2721-2735.
- [28] Azadeh, A., Saberi, M. ve Seraj, O. (2010). "An Integrated Fuzzy Regression Algorithm for Energy Consumption Estimation with Non-Stationary Data: A Case Study of Iran", *Energy*, 35(6):2351-2366.
- [29] Çunkaş, M. ve Taşkıran, U. (2011). "Turkey's Electricity Consumption Forecasting Using Genetic Programming", *Energy Sources, Part B: Economics, Planning, And Policy*, 6(4):406-416.
- [30] Suganthi, L. ve Samuel, A. A. (2012). "Energy Models For Demand Forecasting—A Review", *Renewable and Sustainable Energy Reviews*, 16(2):1223-1240.
- [31] Yu, S., Zhu, K. ve Zhang, X. (2012). "Energy Demand Projection of China Using a Path-Coefficient Analysis and PSO–GA Approach", *Energy Conversion and Management*, 53(1):142-153.
- [32] Bilgili, M., Sahin, B., Yasar, A. ve Simsek, E. (2012). "Electric Energy Demands of Turkey in Residential and Industrial Sectors", *Renewable and Sustainable Energy Reviews*, 16(1):404-414.
- [33] Hong, W. C. (2011). "Electric Load Forecasting by Seasonal Recurrent SVR (Support Vector Regression) with Chaotic Artificial Bee Colony Algorithm", *Energy*, 36(9):5568-5578.
- [34] Chang, P. C., Fan, C. Y. ve Lin, J. J. (2011). "Monthly Electricity Demand Forecasting Based on a Weighted Evolving Fuzzy Neural Network Approach", *International Journal of Electrical Power & Energy Systems*, 33(1):17-27.
- [35] Oğcu, G., Demirel, O. F. ve Zaim, S. (2012). "Forecasting Electricity Consumption With Neural Networks and Support Vector Regression", *Procedia-Social and Behavioral Sciences*, 58:1576-1585.
- [36] Uzlu, E., Kankal, M., Akpınar, A. ve Dede, T. (2014). "Estimates of Energy Consumption in Turkey Using Neural Networks with the Teaching–Learning-Based Optimization Algorithm", *Energy*, 75:295-303.
- [37] Toksari, M. D. (2016). "A Hybrid Algorithm Of Ant Colony Optimization (ACO) and Iterated Local Search (ILS) for Estimating Electricity Domestic Consumption: Case of Turkey", *International Journal of Electrical Power & Energy Systems*, 78:776-782.
- [38] Lee, W. J. ve Hong, J. (2015). "A Hybrid Dynamic and Fuzzy Time Series Model for Mid-Term Power Load Forecasting", *International Journal of Electrical Power & Energy Systems*, 64:1057-1062.
- [39] Vu, D. H., Muttaqi, K. M. ve Agalgaonkar, A. P. (2015). "A Variance Inflation Factor and Backward Elimination Based Robust Regression Model for Forecasting Monthly Electricity Demand Using Climatic Variables", *Applied Energy*, 140:385-394.
- [40] Çevik, H. H. ve Çunkaş, M. (2015). "Short-Term Load Forecasting Using Fuzzy Logic and ANFIS", *Neural Computing And Applications*, 26(6):1355-1367.

- [41] 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.
- [42] Hamzaçebi, C., Es, H. A. ve Çakmak, R. (2017). "Forecasting of Turkey's Monthly Electricity Demand by Seasonal Artificial Neural Network", *Neural Computing And Applications*, 2017:1-15.
- [43] Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B. ve dos Reis Alves, S. F. (2017). *Artificial Neural Networks*. Cham: Springer International Publishing.
- [44] Zurada, J. M. (1992). *Introduction to Artificial Neural Systems (Vol. 8)*. St. Paul: West Publishing Company.
- [45] Mehrotra, K., Mohan, C. K. ve Ranka, S. (1997). *Elements of Artificial Neural Networks*. MIT Press.
- [46] Yeni Biyoloji, Sinir Hücresinin Yapısı, Görevleri ve Nöron Çeşitleri, <https://www.yenibiyoloji.com/sinir-hucresinin-noronun-yapisi-gorevleri-ve-noron-cesitleri-1556/>, 16 Haziran 2019.
- [47] Orr, G., Neural Networks Course, Willamette University, <https://www.willamette.edu/~gorr/classes/cs449/brain.html>, 16 Haziran 2019.
- [48] Demuth, H. B., Beale, M. H., De Jess, O. ve Hagan, M. T. (2014). *Neural Network Design*. Martin Hagan.
- [49] Haykin, S. S., (2009). *Neural Networks And Learning Machines (Vol. 3)*. Upper Saddle River: Pearson Education
- [50] Beale M. H., Hagan M. T. ve Demuth H. B. (2016). *MATLAB Neural Networks Toolbox Documentation*. The Mathworks, Inc.
- [51] Diaconescu, E. (2008). "The Use of NARX Neural Networks to Predict Chaotic Time Series", *Wseas Transactions on Computer Research*, 3(3):182-191.
- [52] Menezes Jr, J. M. P. ve Barreto, G. A. (2008). "Long-term Time Series Prediction with the NARX Network: An Empirical Evaluation", *Neurocomputing*, 71(16-18):3335-3343.
- [53] Medsker, L. ve Jain, L. C. (1999). *Recurrent Neural Networks: Design and Applications*. CRC Press.
- [54] EÜAŞ, (2014), 2015-2019 Stratejik Planı, EÜAŞ Genel Müdürlüğü, Ankara.
- [55] Elektrik Mühendisleri Odası, Türkiye'de Elektrik Enerjisi Gelişiminin Kısa Tarihçesi ve Genel Üretim Bilgileri, http://www.emo.org.tr/ekler/0082ac261d74f5a_ek.pdf, 16 Haziran 2019.
- [56] Tutuş, A. (2006). "Türkiye'de Elektrik Enerjisinin Tarihsel Gelişimi ve Yeni Piyasa Düzeni İçerisinde Hidroelektrik Enerjinin Yeri." *TMMOB Su Politikaları Kongresi*, 2006:318-330.
- [57] Karagöl, E. T., Tür, M. R. (2017). *Türkiye'de Elektrik Enerjisi, Siyaset, Ekonomi ve Toplum Araştırmaları Vakfı*, İstanbul.

- [58] TEİAŞ, (2019), Kurulu Güç Raporu-Nisan 2019, TEİAŞ Yük Tevzi Dairesi Başkanlığı, Ankara.
- [59] The Economist Intelligence Unit, (2019), Industry Report (Energy-Turkey-1st Quarter 2019), London.
- [60] International Energy Agency, (2018), Electricity Information Report, Paris.
- [61] Türkiye Cumhuriyeti Dışişleri Bakanlığı, Türkiye'nin Enerji Profili ve Stratejisi, http://www.mfa.gov.tr/turkiye_nin-enerji-stratejisi.tr.mfa, 16 Haziran 2019.
- [62] ETKB, (2017), 2018 Yılı Bütçe Sunumu, ETKB Strateji Geliştirme Başkanlığı, Ankara.
- [63] Islam S. M.i Al-Alawi S. M. ve Ellithy KA (1995). "Forecasting Monthly Electric Load and Energy for a Fast Growing Utility Using an Artificial Neural Network", *Electric Power Systems Research*, 34(1):1-9.
- [64] Abdel-Aal, R. E., Al-Garni, A. Z. ve Al-Nassar, Y. N. (1997). "Modelling and Forecasting Monthly Electric Energy Consumption in Eastern Saudi Arabia Using Abductive Networks", *Energy*, 22(9):911-921.
- [65] Zhang, G. P. (2003). "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model", *Neurocomputing*, 50:159-175.
- [66] Chen, J. F., Lo, S. K., & Do, Q. (2017). "Forecasting Monthly Electricity Demands: An Application of Neural Networks Trained by Heuristic Algorithms", *Information*, 8(1):31.
- [67] Tarım ve Orman Bakanlığı, (2018), Türkiye Ortalama Sıcaklık Raporu, Meteoroloji Genel Müdürlüğü, Ankara.
- [68] Tarım ve Orman Bakanlığı, (2018), Türkiye Ortalama Yağış Raporu, Meteoroloji Genel Müdürlüğü, Ankara.
- [69] Organization for Economic Co-operation and Development, Consumer Price Index: All Items for Turkey [TURCPIALLMINMEI], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/TURCPIALLMINMEI>, 16 Haziran 2019.
- [70] Organization for Economic Co-operation and Development, Production of Total Industry in Turkey [TURPROINDMISMEI], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/TURPROINDMISMEI>, 16 Haziran 2019.
- [71] Organization for Economic Co-operation and Development, Imports: Value Goods for Turkey [XTIMVA01TRM664N], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/XTIMVA01TRM664N>, 16 Haziran 2019.
- [72] Organization for Economic Co-operation and Development, Exports: Value Goods for Turkey [XTEXVA01TRM664N], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/XTEXVA01TRM664N>, 16 Haziran 2019.

- [73] TEİAŞ, Türkiye Elektrik Enerjisinin Üretim-İthalat-İhracat ve Brüt Talebinin Yıllar İtibariyle Aylık Dağılımı, <https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-kayiplar-0>, 16 Haziran 2019
- [74] Zhang, G., Patuwo, B. E., ve Hu, M. Y. (1998). "Forecasting with Artificial Neural Networks: The State of the Art", *International Journal of Forecasting*, 14(1):35-62.
- [75] Lewis, C.D. (1982). *Industrial and Business Forecasting Methods*. London: Butterworths



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ezgi POLAT
Doğum Tarihi ve Yeri : 20.01.1988 / İstanbul
Yabancı Dili : İngilizce
E-posta : eezgipolat@gmail.com

ÖĞRENİM DURUMU

| Derece | Alan | Okul/Üniversite | Mezuniyet Yılı |
|--------|-----------------------|----------------------------|----------------|
| Lisans | Endüstri Mühendisliği | Yıldız Teknik Üniversitesi | 2012 |
| Lisans | Makine Mühendisliği | Yıldız Teknik Üniversitesi | 2012 |
| Lise | Fen Bilimleri | Cağaloğlu Anadolu Lisesi | 2006 |

İŞ TECRÜBESİ

| Yıl | Firma/Kurum | Görevi |
|-------------------|------------------------|---------------------|
| 2016-Devam ediyor | Nişantaşı Üniversitesi | Araştırma Görevlisi |

YAYINLARI

Bildiri

1. Polat, E. ve Aydın, N., (2018). "Forecasting Monthly Electricity Consumption in Turkey Using Artificial Neural Networks", 12th International NCMConferences: New Challenges in Industrial Engineering and Operations Management, 11-12 September 2018, Ankara.

