

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ZAMAN SERİSİ ANALİZİ İLE DEPREM TAHMİNİ

Sultan LÖK

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

ŞUBAT 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

ZAMAN SERİSİ ANALİZİ İLE DEPREM TAHMİNİ

Tez Yazarı
Sultan LÖK

Danışman
Doç. Dr. Murat KARABATAK

ŞUBAT 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Zaman Serisi Analizi ile Deprem Tahmini
Yazarı: Sultan LÖK
İlk Teslim Tarihi: 03.01.2022
Savunma Tarihi: 02.02.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Murat KARABATAK Fırat Üniversitesi, Teknoloji Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Özal YILDIRIM Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Ahmet Arif AYDIN İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Zaman Serisi Analizi ile Deprem Tahmini” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

02.02.2022

Sultan LÖK



ÖNSÖZ

Son yıllarda bilgisayar biliminin gelişmesi ile veriler de artış oluşmuştur. Bu artış beraberinde, verinin işlenmesi konusunu gündeme getirmiştir. Verilerin işlenmesi ve bilgiye dönüştürülmesi süreci için veri madenciliği yöntemleri geliştirilmiştir. Bu çalışmada veri madenciliği yöntemlerinden zaman serisi analizi kullanılmıştır zaman serisi analizi geçmiş zaman verileri kullanılarak gelecek zaman için tahminde bulunmayı sağlamaktadır. Bu tez çalışmasında zaman serisi analizi yöntemlerinden yapay sinir ağı ile Elazığ ili için deprem tahmini gerçekleştirilmiştir.

Tez çalışması süresince ilgisini hiç esirgemeyen bilgi ve tecrübesini benimle paylaşan değerli hocam ve tez danışmanım Doç. Dr. Murat KARABATAK' a saygılarımı sunar ve teşekkür ederim. Fırat Üniversitesi Teknoloji Fakültesi yazılım mühendisliği bölümünde ki tüm hocalarıma ve arkadaşlarıma katkılarından dolayı teşekkür ederim. Tüm eğitim sürecinde maddi ve manevi desteklerini hep hissettiğim sevgili aileme içtenlikle teşekkür ederim.

Sultan LÖK
ELAZIĞ, 2022

İÇİNDEKİLER

Sayfa

ÖNSÖZ	iv
ÖZET	vii
ABSTRACT.....	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
1.1. Tezin Amacı	4
1.2. Tezin Önemi	4
2. ZAMAN SERİSİ	1
2.1. Zaman Serisi Bileşenleri.....	4
2.2. Zaman Serilerinde Durağanlık Kavramı.....	6
2.3. Zaman Serilerinde Analiz Yöntemleri	8
2.3.1. Hareketli Ortalamalar Yöntemi (HO).....	8
2.3.2. Otoregresif Model (OR).....	10
2.3.3. Box-Jenkins Yöntemi	11
2.3.4. Üstel Düzleştirme Yöntemi	12
2.3.5. Yapay Sinir Ağları Yöntemi.....	13
3. YAPAY SİNİR AĞLARI	15
3.1. Yapay Sinir Ağı Özellikleri.....	16
3.2. Yapay Sinir Ağı Mimarisi	17
3.3. Yapay Sinir Ağı Türleri.....	18
3.4. Yapay Sinir Ağı Modelleri	19
3.5. Yapay Sinir Ağı'nın Doğrusal Olmayan Problem türleri ve çözümleri.....	21
4. DEPREMSELLİK	26
4.1. Dünya'nın İçyapısı	26
4.2. Levha Hareketleri	27
4.3. Deprem	27
4.4. Elâzığ İlının Depremselliği.....	28
5. DENEYSEL ÇALIŞMALAR	31
5.1. Veri Setleri	31
5.1.1. Veri Seti 1	32
5.1.2. Veri Seti 2	33
5.1.3. Veri Seti 3	33
5.1.4. Veri Seti 4	34
5.1.5. Veri Seti 5	35
5.1.6. Veri Seti 6	35
5.2. Deneysel Çalışmalar.....	36
5.2.1. Veri Seti 1'e Ait Deneysel Çalışmalar	36
5.2.2. Veri Seti 2'ye Ait Deneysel Çalışmalar	38
5.2.3. Veri Seti 3'e Ait Deneysel Çalışmalar	40

5.2.4. Veri Seti 4'e Ait Deneysel Çalışmalar	42
5.2.5. Veri Seti 5'e Ait Deneysel Çalışmalar	44
5.2.6. Veri Seti 6'ya Ait Deneysel Çalışmalar	46
6. SONUÇLAR VE TARTIŞMA.....	51
Öneriler	52
Kaynaklar.....	53
ÖZGEÇMİŞ	



ÖZET

Zaman Serisi Analizi ile Deprem Tahmini

Sultan LÖK

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Şubat 2022, Sayfa: xi + 55

Gelişen teknolojiler ile beraber, üretilen veri miktarının da artmasıyla, çok büyük veriler oluşmaya başlamıştır. Bu verilerden faydalı bilgiler elde etme amacı ile veri madenciliği yöntemleri geliştirilmiştir. Veri madenciliği, farklı yöntemler uygulanarak değerli bilgileri elde etmeyi sağlamaktadır. Bu yöntemler arasında; kümeleme, sınıflandırma, birliktelik kuralı, zaman serileri vb. gibi yöntemler yer almaktadır. Bu tez çalışmasında, zaman serisi analiz yöntemine değinilmiş ve deprem tahminine ilişkin çalışmalar yapılmıştır.

Zaman serisi analizi, geçmiş zaman verileri üzerinde çalışarak gelecek zaman hakkında tahminde bulunmayı sağlamaktadır. Tezde, zaman serisi analizi ve yapay sinir ağı kullanılarak deprem tahminine yönelik çalışmalar yapılmıştır. Yapay sinir ağları doğrusal olmayan serilerin analizinde yaygın olan olarak kullanılan yöntemlerden biridir. Yapay sinir ağının, doğrusal olmayan zaman serileri için kullanımına tezde detaylı olarak yer verilmiştir.

Deprem tahmini için Elazığ iline ait deprem verileri kullanılmıştır. Bu veriler, Boğaziçi Üniversitesi, Kandilli Rasathanesinden elde edilmiş ve bu verilerden çeşitli veri setleri oluşturularak analizler gerçekleştirilmiştir. Yapılan analizler sonucunda yapay sinir ağı yönteminin, düşük şiddetli depremlerin tahmininde başarı oranı yüksek bulunmuştur. Ancak yüksek şiddetli depremleri tahmin oranı düşük düzeyde kalmıştır. Gerçekleştirilen analizler sonucunda yapay sinir ağının doğrusal olmayan serilerde başarıyı yüksek bir yöntem olduğu sonucuna varılmıştır. Ayrıca, zaman serisinde bulunan veri eksikliği ve düzensizliğinin, deprem tahmininde istenilen başarının elde edilmesini engelleyen faktörler olduğu görülmüştür.

Anahtar Kelimeler: Veri Madenciliği, Zaman Serisi, Yapay Sinir Ağları, Deprem Tahmini

ABSTRACT

Earthquake Prediction By Time Series Analysis

Sultan LÖK

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences

Department of Software Engineering

February 2022, Pages: xi + 55

With the developing technologies, increase in the amount of produced data, very large data has begun to form. Data mining methods have been developed with the aim of obtaining useful information from these data. Data mining provides to obtain valuable information by applying different methods. Some of these methods are clustering, classification, association rule, time series etc. In this thesis, time series analysis method was mentioned and studies on earthquake prediction were made.

Time series analysis provides predictions about future by working on past data. In the thesis, studies on earthquake prediction were made by using time series analysis and artificial neural network. Artificial neural networks are one of the commonly used methods in the analysis of nonlinear series. The use of artificial neural network for nonlinear time series is given in detail in the thesis.

Earthquake data of Elazığ province were used for earthquake prediction. These data were obtained from Boğaziçi University, Kandilli Observatory and analyzes were carried out by creating various data sets from these data. As a result of the analyzes, the success rate of the artificial neural network method was found to be high in the prediction of low-intensity earthquakes. However, the prediction rate of high-intensity earthquakes remained at a low level. As a result of the analyzes carried out, it was concluded that the artificial neural network is a method with high performance in nonlinear series. In addition, it has been seen that the lack of data and irregularity in the time series are the factors that prevent the desired success in earthquake prediction.

Keywords: Data Mining, Time Series Analysis, Artificial Neural Network, Earthquake Prediction

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Sinx fonksiyonunun zaman serisi grafiği	1
Şekil 2.2. Pascal üçgeni zaman serisi grafiği.....	1
Şekil 2.3. Bir firmanın zaman göre ürün satış	2
Şekil 2.4. Bir otobüs firmasının yıllara göre yolcu sayısı.....	2
Şekil 2.5. Bir uçak firmasının zamana göre kar payı.....	3
Şekil 2.6. Bir alanda gerçekleşen 100 depremin şiddet değerleri	3
Şekil 2.7. Çarpımsal ayrıştırmaya göre zaman serisi bileşenlerinin gösterimi	6
Şekil 2.8. Durağan zaman serisi	7
Şekil 2.9. Durağan olmayan zaman serisi.....	7
Şekil 3.1. Bir sinir hücresinin yapısı ve bileşenleri	15
Şekil 3.2. Bir sinir hücresinin matematiksel formülü	16
Şekil 3.3. Yapay sinir ağı katmanları	17
Şekil 3.4. YSA eğitim adımlarının akış şeması	18
Şekil 3.5. YSA gizli katman seçimine örnek.....	19
Şekil 3.6. YSA modelleri	20
Şekil 3.7. Problem Tipi 1' e ait zaman serisi.....	21
Şekil 3.8. Problem Tipi 2'ye ait zaman serisi.....	22
Şekil 3.9. Problem Tipi 3'e ait zaman serisi.....	22
Şekil 3.10. Problem Tipi 1'e ait zaman serisi için ağ modeli	23
Şekil 3.11. Problem Tipi 2'e ait zaman serisi için ağ modeli	23
Şekil 3.12. Problem Tipi 3'e ait zaman serisi için ağ modeli	24
Şekil 4.1. Dünya'nın katmanları.....	26
Şekil 4.2. Elazığ ili depremsellik haritası	28
Şekil 4.3. Elazığ ili zemin yapısı	29
Şekil 5.1. Deprem kayıtları.....	31
Şekil 5.2. 100 deprem kaydına ait üç boyutlu uzaklık haritası	34
Şekil 5.3. Veri Seti 1'e ait YSA eğitim sonuçları.....	37
Şekil 5.4. Veri Seti 1'e ait hata histogramı	38
Şekil 5.5. Veri Seti 2'ye ait YSA eğitim performansı	39
Şekil 5.6. Veri Seti 3'e ait en iyi performans grafiği.....	41
Şekil 5.7. Veri Seti 3'e ait değişken N/G ile en iyi eğitim sonuçları	42

Şekil 5.8. Veri Seti 4'e ait en iyi YSA eğitim sonuçları grafiği	43
Şekil 5.9. Veri Seti 5'e ait en iyi performans grafiği.....	44
Şekil 5.10. Veri Seti 5'e ait hata histogramı.....	46
Şekil 5.11. Veri Seti 6'ya ait performans grafiği.....	48
Şekil 5.12. Veri Seti 6'ya ait hata histogramı.....	49



TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. YSA parametreleri, türleri ve açıklamaları	19
Tablo 5.1. Deprem Kayıtları	32
Tablo 5.2. Veri Seti 1'e ait kayıt örnekleri.....	33
Tablo 5.3. Veri Seti 2'ye ait kayıt örnekleri.....	33
Tablo 5.4. Veri Seti 4'e ait kayıt örnekleri.....	34
Tablo 5.5. Veri Seti 5'e ait kayıt örnekleri.....	35
Tablo 5.6. Veri Seti 6'ya ait kayıt örnekleri.....	35
Tablo 5.7. Veri Seti 1'e ait YSA eğitim performansı.....	37
Tablo 5.8. Veri Seti 2'ye ait YSA eğitim performansı.....	39
Tablo 5.9. Veri Seti 3'e ait eğitimin sabit N/G değerine göre başarımlı performansı.....	40
Tablo 5.10. Veri Seti 3'e ait değişken N/G değerlerine göre eğitim performansı.....	41
Tablo 5.11. Veri Seti 4'e ait değişken N/G değerlerine göre eğitim performansı.....	43
Tablo 5.12. Veri Seti 5'e ait deneysel sonuçlar.....	45
Tablo 5.13. Veri Seti 6'ya ait deneysel sonuçlar.....	47
Tablo 5.14. Veri setlerinin en iyi deneysel sonuçları.....	50

SİMGELER VE KISALTMALAR

Kısaltmalar

AHO	: Ağırlıklı Hareketli Ortalama
B	: Bias
BRA	: Bayesian Regularization Algoritması
BHO	: Basit Hareketli Ortalama
BP	: Back Propagation(Geri Yayılma Algoritması)
BÜD	: Basit Üstel Düzeltme
ÇÜD	: Çift Üstel Düzeltme
DD	: Deprem Düzeyi
DVM	: Destek Vektör Makinaları
EWMA	: Üstel Ağırlıklı Hareketli Ortalama
G	: Gecikmeler
GPS	: Global Positioning System (Küresel Konumlama Sistemi)
GSYİH	: Gayri Safi Yurtiçi Hâsıla
HO	: Hareketli Ortalama
KHO	: Kümülatif Hareketli Ortalama
LMA	: Levenberg- Marquardt Algoritması
Mb	: Cisim Dalgası Şiddeti
Ms	: Yüzey Dalgası Şiddeti
Mw	: Moment Şiddeti
MD	: Süre Şiddeti
ML	: Yerel Şiddet
MLP	: Çok Katmanlı Algılayıcı
N	: Nöronlar
NOR-SA	: Nonlineer Otoregresif Sinir Ağı
OKH	: Ortalama Kare Hatası
OR	: Otoregresif Model
OREHO	: Otoregresif Entegreli Hareketli Ortalama Modeli
ORHO	: Otoregresif Hareketli Ortalama Modeli
PSO	: Parçacık Sürü Optimizasyonu
R	: Regresyon
SCGA	: Scaled Conjugate Gradient Algoritması
SRNN	: Structurel Recurrent Neural Network(Yapısal Tekrarlı Sinir Ağları)
UKVH	: Uzun Kısa Vadeli Hafıza
ÜAHO	: Üstel Ağırlıklı Hareketli Ortalama
W	: Ağırlıklandırma
xM	: En Büyük Şiddet Değeri
VAR	: Vektör Otoregresyon Modeli
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Günümüzde dijital veri miktarı hızlı bir şekilde artış göstermektedir. Artan verilerle beraber, bu verilerin kullanılarak faydalı bilgiler elde etme konusu gündeme gelmiştir. Verileri bilgiye dönüştürebilmek için verilerin türlerine göre veri madenciliği yöntemleri geliştirilmiştir. Bu yöntemler sınıflandırma, kümeleme, birliktelik kuralları ve zaman serisi analizi olarak belirtilmektedir. Bu çalışmada, zaman verileri temel alınarak gelecek veriler hakkında tahmin yapmaya olanak sağlayan zaman serisi analizi ele alınmıştır. Hemen hemen her alanda zaman verilerini barındıran büyük miktarda seriler bulunmaktadır. Zaman serileri, çoğunlukla doğada sayısal olarak tanımlanmış, düzenli veya düzensiz zaman esasına göre kaydedilen olayların veya gözlemlerin dizisi olarak belirtilmektedir [1].

Zaman serisi verileri, farklı alanlarda, çok çeşitli uygulamalarda üretilmektedir. Örneğin, borsadaki günlük dalgalanmalar, bir bilgisayar kümesi tarafından üretilen izler, tıbbi ve biyolojik deneysel gözlemler, sensör ağlarından elde edilen okumalar, hareketli nesnelerin konum tabanlı hizmetlerdeki konum güncellemeleri vb. serilerdir. Zaman serileri verilerinin çoğalması ile birlikte, bu verileri yönetmek, analiz etmek, dönüştürmek ve görselleştirmek için yeni metodolojiler ve teknolojiler hakkında çok sayıda çalışma yapılmıştır. Bu çalışmalara, literatürde birçok örnek bulunmaktadır.

Güven ve Ayvaz, 1990-2014 yıllarını kapsayan yıllık enflasyon ve işsizlik bilgilerini içeren zaman serisi verilerini kullanmışlardır. Enflasyon ve işsizlik arasındaki kısa ve uzun dönemli ilişkileri incelemişlerdir. Enflasyon ve işsizlik arasındaki ilişkiyi belirlemek için sırasıyla; durağanlık testi, eş bütünleştirme testi, granger nesnellik testi ve VAR (Vektör Otoregresyon Modeli) analizi yapmışlardır. Analizler sonucunda enflasyon ve işsizlik arasında güçlü bir ilişki olduğunu saptamışlardır [1].

Akıncı, Erkal ve Yılmaz, Türkiye’de 1995-2013 dönemi için yoksulluğun ekonomik özgürlüklerle ilişkisini negatif/pozitif olarak tespit etmeyi amaçlamışlardır. Bu amaçla zaman serisi verilerine Johansen-Julius eş bütünleştirme ve granger nesnellik analizi uygulamışlardır. Analizler sonucunda yoksulluk ve ekonomik özgürlükler arasında uzun dönemli ilişki tespit etmişlerdir. Ayrıca yoksulluktan mali, mesleki, mülkiyet özgürlüklerine doğru tek yönlü nesnellik tespit etmişlerdir [2].

Narayanakumar ve Raja, BP (Geri Yayılma) ve MLP (Çok Katmanlı Algılayıcı) sinir ağı tekniklerinin, depremleri tahmin performansını değerlendirmişlerdir. Sinir ağları için girdi haline dönüştürmek üzere olay zamanı, enlem, boylam, derinlik ve şiddet verileri alınmıştır. Uygulamalar sonucunda BP sinir ağı yönteminin, önceki çalışmalardan 3 ile 5 büyüklüğündeki depremler için daha iyi bir tahmin doğruluğu sağlayabildiğini, ancak yeterli veri bulunmamasından dolayı 5 ile 8 büyüklüğündeki depremler için iyi sonuçlar sağlayamadığını göstermişlerdir [3].

Sheng, Mu, Zhang ve Lv, Çin'in Kuzey Sismik Bölgesi'nde YSA (Yapay Sinir Ağları) yöntemi kullanılarak deprem tahmini gerçekleştirmişlerdir. Bu tahminler yapılırken büyük bölgeler daha küçük bölgelere bölünmüş ve farklı bölgeler için farklı girdi parametreleri belirlenmiştir. Belirlenen parametreler farklı zaman aralığında (7-15-30 gün) analiz edilmiştir. 30 gün için yapılan analizlerde daha iyi sonuçlar elde etmişlerdir [4].

Li ve Liu, bu çalışmada BP sinir ağı ve PSO (Parçacık Sürü Optimizasyonu) algoritmasını birleştirerek deprem büyüklüğünü tahmin etmeyi amaçlamışlardır. PSO'nun özelliklerini geliştirmek için, lineer azalan atalet ağırlık stratejisini önermişlerdir. Bu öneri ile geliştirilmiş PSO-BP sinir ağının, BP sinir ağından ve normal PSO-BP sinir ağından daha hızlı yakınsama hızına ve daha iyi öngörücü etkiye sahip olduğunu göstermektedir. PSO algoritması tarafından optimize edilen BP sinir ağı, deprem büyüklüğünü tahmin etmek için daha iyi bir başarıma sahip olduğu belirtilmiştir [5].

Mahmoudi, Arjomand, Rezaei ve Mohammadi, depremlerin büyüklüğünü tahmin etmek için bir MLP ağı kullanmışlardır. MLP ağında, farklı değişken sayıları, farklı hata oranları temel alınarak gizli katmanda farklı katman sayıları uygulanarak çevrimiçi ve yığın olmak üzere iki model oluşturulmuştur. Bu modellerin ortalama doğruluk tahmini yaklaşık %72 olarak tespit edilmiştir [6].

Çelik, Atalay ve Bayer, YSA ve DVM (Destek Vektör Makinaları) yöntemi kullanarak sismik darbelerden deprem tahmini üzerine çalışmışlardır. Türkiye'nin güneybatısında yoğun sismik aktiviteye sahip dört farklı bölgeye ait deprem verilerini kullanılarak YSA'yı eğitmişlerdir. Yapay Sinir Ağları ile %83 oranında erken tespit saptanmıştır. Destek Vektör Makineleri ile sınıflandırmada %91 oranında erken tespit sağlanmıştır [7].

Kamışlıoğlu ve Külahcı, Radon gazı verileri ile zaman serisi analizi gerçekleştirmişlerdir. Osmaniye iline ait bir yıllık 15 dakikalık aralıklarla ölçülen radon gazı verilerini ARIMA (Bütünleşik Ototoregressif Hareketli Ortalama(OREHO)) modeli oluşturmuşlardır. Modeli analiz ederek zaman serisinin otokorelasyona sahip olduğuna ve Radon gazı verilerinin durağan olmadığına ulaşmışlardır. Zaman serisinin hatalarının gelecek ölçümler ile desteklenerek gözlemlenebileceğini belirtmişlerdir [8].

Balkaslıoğlu ve Yıldırım, derin UKVH ağ modeli kullanarak bölgesel deprem tahmini gerçekleştirmişlerdir. Bingöl ilinin, merkez orta nokta kabul edilerek 50 km yarıçap içerisinde 1950-2017 yılları arasında oluşan depremleri veri seti olarak kullanmışlardır. Bu veri setini 5 katmanlı UKVH modeli oluşturarak analiz etmişlerdir. Bu analiz sonucunda, tahmin edilen deprem değerleri ile gerçek depremler arasında küçük farklılıklar tespit etmişlerdir [9].

Ulutaş, Çakmak ve Altaş, Zaman serilerinde benzerlik analizi tabanlı YSA ile saatlik Güneş ışıınımı kestirimi çalışmasını gerçekleştirmişlerdir. Trabzon ilinin, 1 Ocak 2015 ve 31 Aralık 2017 tarihleri arasında toplam güneş ışıınımı, bağıl nem ve sıcaklık verileri kullanılmıştır. Mevsimsel

olarak güneş ışınlamı deęerlerinin farklı olacaęı göz önüne alınarak deneme yanılma yoluyla YSA modeli oluřturulmuř ve analiz edilmiřtir. Bu analiz sonucunda güneř ışınlamı tahmini kabul edilebilir hata deęerine ulařmıřlardır [10].

Doęan ve Demir, yapısal tekrarlı YSA ile Türkiye’de deprem tahmini gerekleřtirmiřlerdir. Türkiye’de 1970- 2019 yılları arasında oluřan 4 ve üzeri deprem verilerini kullanmıřlardır. Bu verileri ilerlemeli basit ortalamalar (SMA-BHO), uzun-kısa süreli bellek (LSTM-UKVH) ve yapısal tekrarlayan sinir aęları (SRNN) ile analiz etmiřlerdir. Bu analiz sonucunda SRNN modelinin dięer modellere göre pozitif ve negatif deęerlerin tahmininde daha bařarılı olduęunu belirlemiřlerdir [11].

Özden ve Öztürk, YSA ve zaman serileri yöntemi ile elektrik eneręisi ihtiya tahminini gerekleřtirmiřlerdir. Ankara ilinde bir firmanın 2014-2016 yılları arasında alıřma günlerine ait eneręi tüketimi, sıcaklık, ortalama elektrik tüketimi verileri kullanılmıřtır. Bu veriler YSA ve doęrusal olmayan otoregresif sinir aęı (NOR-SA) ile analiz edilmiřtir. Analiz sonucunda YSA’nın NORSA’ya göre tahmin bařarımının yüksek olduęunu belirlemiřlerdir [12].

am ve Duman, YSA ile deprem tahmini gerekleřtirmiřlerdir. Türkiye’nin Batı Anadolu fay hattı üzerinde 4 farklı bölge üzerinde alıřmıřlardır. Bu bölgelerin 2000-2012 yılları arasında gerekleřen depremler ait; enlem, boylam, yıl, ay, gün, saat, dakika, süre, derinlik ve řiddet deęerlerinin bulunduęu veri setini oluřturmuřlardır. Bu veri setini ileri beslemeli geri yayılımlı YSA ile analiz etmiřlerdir. Analiz sonucunda, tahminler belli bir bařarım saęlamıř olsa da ok yüksek oranlı depremlerin tahminin de yeterli olmadıęını belirtmiřlerdir [13].

Kumař, Ayan, Akyüz ve Güngör, meteorolojik verileri ile YSA kullanarak hava sıcaklıęı tahmini gerekleřtirmiřlerdir. Antalya iline ait 2000-2016 yıllarına ait aylık ortalama nispi nem, aylık ortalama buhar basıncı, ay ve yıl verileri elde edilmiřtir. Bu veriler YSA yöntemi ile analiz edilmiřtir. Bu analiz sonucunda aylık ortalama sıcaklık deęerlerinin YSA’nın tahmin deęerleri ile uyum saęladıęı belirtilmiřtir [14].

Can ve řahin, YSA ile günlük ię noktası sıcaklıęı tahmini gerekleřtirmiřlerdir. Muęla iline ait 2019 yılındaki günlük baęıl nem oranı, basın ve hava sıcaklıęı verilerini Geri yayılımlı YSA yöntemi ile analiz etmiřlerdir. Bu analiz sonucunda, gerek deęerler ile tahmini deęerler arasındaki en yüksek hata deęeri %3,8 olarak belirlenmiřtir [15].

Tařyürek ve elik, Toplu tařıma kullanan insanların durakta bekleme sürelerini azaltmak için ara seyahat süresini birleřik YSA ile tahmin etmiřlerdir. Kayseri büyükřehir belediyesine ait 800 farklı otobüs hattının GPS verilerini kullanmıřlardır. Otobüslerin hat özellikleri göz önüne alınarak yedi tane parametre belirlemiřlerdir (hat numarası, hat yönü, haftanın günü vb.). Bu parametreler ile Birleřik YSA ve lineer regresyon analizi gerekleřtirmiřlerdir. Analiz sonucunda birleřik YSA yönteminin lineer regresyon yöntemine göre daha doęru tahminler yaptıęını belirlemiřlerdir [16].

Kırbaş, istatistiksel metotlar ve YSA kullanarak kısa dönem çok adımlı rüzgâr hızı kestirimi gerçekleştirmiştir. Bu çalışma kapsamında, Antalya ilinde 14-30 Nisan 2016 tarihleri arasında 5 dakikalık aralıklarla ölçülen rüzgâr hızları ile veri seti oluşturmuşlardır. Bu veri seti ARIMA ve YSA modelleri oluşturularak analiz edilmiştir. Bu analizler sonucunda, rüzgâr hızı tahmininde geriye dönük ilişkinin az olduğunu tespit etmiştir. ARIMA ve YSA'nın kısa dönemli rüzgâr hızı tahmininde güvenilir olduğunu belirtmiştir [17].

Sütçü, Kaynaklı imalat operasyon sürelerinin matlab platformu üzerinde YSA ile tahminini gerçekleştirmiştir. Tahmin kapsamında, imal edilecek malzemelerin montaj adedi, ağırlığı, ebatı ve üretim süresi verilerini bulunduran veri setini oluşturmuştur. Veri seti YSA ile eğitilmiş ve analiz edilmiştir. Bu analiz sonucunda gruplandırma yapılmadan yapılan eğitimde hata oranı yüksekken, ağırlıklarına göre gruplandırıldığında tutarlı sonuçlar elde etmiştir [18].

1.1. Tezin Amacı


Zaman serileri analizinde kullanılan yapay sinir ağı yönteminin, durağan olmayan verilerde doğruluk yüzdesi göz önüne alınarak depremin tahmin edilmesi amaçlanmıştır. Deprem tahmini için Elâzığ ili deprem verileri kullanılmıştır. Elâzığ ili deprem verileri düzenlenerek YSA ile analizi gerçekleştirilmiştir. Analiz sonuçları tartışılmış ve tahmin başarımını artırıcı öneriler belirtilmiştir.

1.2. Tezin Önemi

Bu tez çalışmasında, deprem tahmini yapılmıştır. Son yıllarda ülkemizde gerçekleşen depremler yüzünden maddi ve manevi birçok olumsuz durumlarla karşılaşmıştır. Bu olumsuz durumların etkisinin azaltılması ve/veya ortadan kaldırılması için deprem tahmini gerçekleştirilmiştir.


2. ZAMAN SERİSİ

Zaman serileri, bir değişkenin zaman içindeki hareketini gözlemleyen, gözlem sonuçlarının kronolojik olarak görüntülediği serilerdir [19]. Örneğin; bir yıl içerisindeki yağış miktarı değişimleri, para birimlerindeki zamana göre değişimler, kalp ritmi ölçümlerinin anlık değişimleri vb. ile elde edilen serilerdir. Bu serilerin grafiksel örnekleri aşağıdaki şekiller ile gösterilmektedir.




Şekil 2.1. Sinx fonksiyonunun zaman serisi grafiği

Şekil 2.1’de Sinx fonksiyonunun aldığı değerler (-1 ile 1 arasında) ile doğrusal zamanda (0-150) oluşturduğu zaman serisi grafiği gösterilmektedir. Sin x fonksiyonunun zaman serisinde 49. sırada yaklaşık -1 değeri aldığı gözlenmektedir. Ayrıca 100. Sırada yaklaşık 0 değeri civarında olduğu anlaşılmaktadır.




Şekil 2.2. Pascal üçgeni zaman serisi grafiği

Şekil 2.2’de Pascal üçgeninin adım sayısı (0-140) doğrultusunda aldığı değerlerin(0-7000) zaman içerisinde oluşturduğu zaman serisi grafiği verilmiştir. Bu zaman serisinde 120. sayısında yaklaşık 1 değeri bulunurken, 130. sayısı yaklaşık 6500 değeri bulunmaktadır.




Şekil 2.3. Bir firmanın zaman göre ürün satış

Şekil 2.3’te bir firmanın 1965-1970 yılları arasında ürün satış miktarı 0-1000 arasında sürekli bir artış gösterdiği görülmektedir. Ayrıca bu zaman serisi yıllık olarak incelendiğinde mevsimsel artış ve düşüşler olduğu gözlemlenmektedir.




Şekil 2.4. Bir otobüs firmasının yıllara göre yolcu sayısı

Şekil 2.4'te Bir otobüs firmasının 1949-1950 yılları arasında taşıdığı yolcu sayısının zaman serisi grafiği gözlemlenmektedir. Bu zaman serisi grafiğinde yıllar ile doğru orantılı olarak yolcu sayısında artış olduğu görülmektedir.



Şekil 2.5. Bir uçak firmasının zamana göre kar payı

Şekil 2.5'te bir uçak firmasında 1950-1960 yılları arasında gelir/gider dengesindeki yükseliş ve azalış değişimleri zaman serisi grafiğinde verilmiştir. Bu zaman serisi grafiğinde uçak firmasının 1960 yılında kar payının -40 değerlerinden +40 değerlerine kadar değişim yaşandığı gözlemlenmektedir.



Şekil 2.6. Bir alanda gerçekleşen 100 depremin şiddet değerleri

Şekil 2.6’da bir alanda oluşan 100 depremin şiddet değerlerine göre zaman serisi grafiği verilmiştir. Bu zaman serisinde oluşan depremlerin şiddet değerlerinin 2,5 ile 6,0 arasında olduğu gözlemlenmektedir.

Zaman serileri değişken sayısına ve ölçüm şekline göre sınıflandırılmaktadır. Tek bir değişkenin kayıtlarını içeren bir zaman serisi tek değişkenli olarak adlandırılmaktadır. Birden fazla değişkenin kayıtlarını içeren zaman serisi, çok değişkenli olarak adlandırılmaktadır. Bir zaman serisi sürekli veya ayrık olarak da sınıflandırılmaktadır. Sürekli bir zaman serisinde gözlemler her zaman ölçülürken, ayrık bir zaman serisi ayrık zaman noktalarında ölçülen gözlemleri içermektedir [19]. Sıcaklık okumaları, kalp ritim verileri, bir nehrin akışı, kimyasal bir işlemin yoğunlaşması vb. seriler sürekli zaman serisini oluşturmaktadır. Belirli bir şehrin nüfusu, bir şirketin üretimi, iki farklı para birimi arasındaki döviz kurları vb. seriler ayrık zaman serilerini belirtmektedir. Genellikle ayrık bir zaman serisinde ardışık gözlemler saatlik, günlük, haftalık, aylık veya yıllık zaman ayrımları gibi eşit aralıklı zaman aralıklarında kaydedilmektedir. Bu kayıtlar, zaman serisi analizini uygulamayı sağlamaktadır.

Zaman serisi analizi, var olan verileri kullanarak, zaman serisinin yapısını belirlemeyi sağlamaktadır. Zaman serisi analizi; üretim sistemleri, kimyasal işlemler, robotik ve havacılık sistemleri de dâhil olmak üzere çeşitli sistemlerin analizi, simülasyonu, izlenmesi ve kontrolü için önem arz etmektedir. Zaman serisi analizi, birçok amaca hizmet edebilmektedir. Bu amaçlardan birisi de tahminde bulunmaktır. Tahmin, bir veya daha fazla zaman serisinin geçmiş değerlerinin kullanılarak, zaman serisinin gelecekteki olası değer veya olası değere en yakın değer bulunmasıdır [19, 20]. Örneğin, bir finansal analist bir hisse senedinin, tahvilin veya başka bir finansal aracın gelecekteki değerini tahmin etmek isteyebilir. Bir mühendis bir jet motorunun olası arızasını tahmin etmek isteyebilir. Bu ve benzeri durumların tahmin analizleri gerçekleştirilerek tahmin değerleri elde edilmektedir. Tahmin değeri ile gerçek değer karşılaştırılarak başarımların değerleri belirtilmektedir.

Bir zaman serisinde tahmin değerinin gerçek değere yakınlığının optimum olabilmesi için uygun bir analiz modelinin seçilmesi gerekmektedir. Zaman serisi analiz modelinin en doğru şekilde seçilmesi için zaman serisinin yapısı hakkında bilgi edinilmesi gerekmektedir. Bu amaçla alt başlıklarda zaman serisinin bileşenlerine, durağanlık kavramına, önişlem sürecine yer verilmiştir. Zaman serisi analiz modeli için matematiksel modellerin belirlenmesine değinilmiştir. Zaman serisi analizi için kullanılan algoritma ve yöntemleri açıklanmıştır.

2.1. Zaman Serisi Bileşenleri

Zaman serileri yapılarına göre bir veya birden fazla bileşenden etkilendiği belirtilmektedir. Bu bileşenler; trend (eğitim yüzdeleri), mevsimsel dalgalanma, döngüsel (konjonktür) dalgalanma, düzensiz rastgele hareket (hata terimi) olarak ifade edilmektedir [19, 20].

Trend: Zaman serilerinde uzun süre gözlemlenen yükseliş veya düşüş durumundan sonra kararlılık halidir. Dolayısıyla, trendin bir zaman serisinde uzun vadeli bir hareket olduğu söylenebilmektedir. Trend doğrusal ve doğrusal olmayan trend şeklinde ikiye ayrılmaktadır. Doğrusal trend, zaman içerisinde değişkende gözlemlenen düzenli bir yükseliş veya düşüş gerçekleşmesi durumudur [19, 20]. Örneğin, nüfus artışı, şehirdeki ev sayısı vb. ile ilgili seriler artış eğilimi gösterirken, ölüm oranları, salgınlar, vb. ile ilgili serilerde düşüş eğilimi gözlenebilmektedir. Doğrusal olmayan trend, zaman içerisinde değişkende düzenli olmayan yükseliş veya düşüş gerçekleşmesi durumu olarak ifade edilmektedir.

Mevsimsel dalgalanma: Zaman serilerinde mevsimsel zamanlarda gözlemlenen yükseliş veya düşüş yönündeki hareketliliktir [19]. Örneğin; Kış aylarında kar yağışının grafiksel gösteriminde yükseliş olması, yaz aylarında tatil oranlarında yükseliş gözlenirken, kar/yağış oranlarında düşüş olması olarak ifade edilmektedir. Mevsimsel değişimler iş adamları, üreticiler ve ticaret işi ile uğraşan kişiler için uygun gelecek planları yapmada önemli bir faktör oluşturmaktadır.

Döngüsel dalgalanma: Zaman serisinde mevsimsel olmayan ancak önemli unsurlar doğrultusunda gerçekleşen yükseliş veya düşüş yönündeki hareketliliği ifade etmektedir [20]. Örneğin; ekonomik kriz dönemlerinde turist sayısında artış olması, terör saldırılarından sonra turist sayısında düşüş olması gibi durumlarda gözlemlenmektedir. Döngüsel dalgalanma, mevsimsel dalgalanmaya oranla gözlem süresi daha uzun olmaktadır. Bu gözlem süresinin uzunluğu, genellikle iki veya daha fazla yıl olarak belirlenmektedir.

Düzensiz rasgele hareket: Zaman serilerinde mevsimsel veya döngüsel dalgalanma dışında kalan, düzensiz olarak gerçekleşen tahmin edilemeyen yükseliş ve düşüş hareketleridir. Bu hareketliliğe hata terimi de denilmektedir. Bu hata terimlerine savaş, grev, deprem, sel vb. gibi olaylar neden olmaktadır. Bu olaylar (hata terimi), serileri yanıltıcı hareketlerdir. Bir zaman serisinde hata terimini ölçmek için tanımlanmış istatistiksel bir teknik bulunmamaktadır [19, 20, 21].


Bu dört bileşenin etkileri düşünüldüğünde, genellikle bir zaman serisi için iki farklı model kullanılmaktadır. Bu modellere geleneksel zaman serisi ayrışım modelleri de denilmektedir. Bunlar çarpımsal ve toplamsal modellerdir.

$$\text{Çarpımsal Modeli: } G(t) = T(t) \times M(t) \times D(t) \times H(t)$$

$$\text{Toplamsal Modeli: } G(t) = T(t) + M(t) + D(t) + H(t)$$

Burada $G(t)$ gözlemdir ve $T(t)$, $M(t)$, $D(t)$ ve $H(t)$ sırasıyla t zamanında trend, mevsimsel dalgalanma, döngüsel dalgalanma ve düzensiz rastgele hareketi ifade etmektedir. Çarpımsal model, bir zaman serisinin dört bileşeninin, mutlaka bağımsız olmadığı ve birbirlerini etkileyebileceği varsayımına dayanmaktadır; buna karşılık Toplamsal modelde dört bileşenin

birbirinden bağımsız olduğu varsayılmaktadır [20]. Şekil 2.7’de çarpımsal ayrıştırmaya göre zaman serisi bileşenlerinin gösterilmektedir.



Şekil 2.7. Çarpımsal ayrıştırmaya göre zaman serisi bileşenlerinin gösterimi

Şekil 2.7’de zamana göre verilen verinin çarpımsal ayrıştırmaya göre bileşen ayrımı yapılmıştır. Veri; trend, mevsimsel dalgalanma ve kalan olarak ayrıştırılmıştır. Trend verinin artış grafiğini göstermektedir. Mevsimsel, veri içerisindeki mevsimsel dalgalanma grafiğini belirtmektedir. Kalan (beyaz gürültü), döngüsel dalgalanma ve hata terimini içerisinde barındıran verinin trend ve mevsimsel dışında kalan bileşenini göstermektedir.

2.2. Zaman Serilerinde Durağanlık Kavramı

Zaman serisi değerlerinin belli bir değere yaklaşması ya da beklenen değeri etrafında dalgalanmasına durağanlık denilmektedir. Durağan bir zaman serisi gözlemlerinde; mevsimsel etkiler, eğilimler ve zaman endeksine bağlı diğer yapılar görülmemektedir. Zaman serisinin durağan olması; ortalama, varyans ve kovaryans gibi istatistiksel özelliklerin zaman içerisinde sabit değer almasıdır [21,22]. Yt serisinin durağanlığı, matematiksel olarak aşağıdaki denklemlerle ifade edilmektedir.

$$\text{Ortalama: } E(Y_t) = \mu$$


$$\text{Varyans: } \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$\text{Kovaryans: } \forall k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$$

Burada k gecikme ile kovaryans, Y_t ile Y_{t+k} arasındaki, yani aralarında k dönem fark olan iki Y arasındaki kovaryanstır. Eğer $k=0$ ise, γ_0 bulunur ki bu da Y 'nin varyansıdır ($=\sigma^2$); $k = 1$ ise, γ_1 , Y 'nin ardışık iki değeri arasındaki kovaryanstır [21, 22].


Y 'nin sıfır noktasını Y_t 'den Y_{t+m} 'ye kaydıracağımızı düşünelim. Eğer Y_t durağansa, Y_{t+m} 'nin ortalaması, varyansı ve ortak varyansı Y_t 'ninkilerle aynı olmalıdır. Kısaca, eğer bir zaman serisi durağansa, ortalaması, varyansı ve (çeşitli gecikmelerdeki) ortak varyansı her zaman ölçümlerde aynı kalmaktadır [21].

Şekil 2.8'de durağan zaman serisinin grafiği verilmiştir. Şekil 2.9'da durağan olmayan zaman serisinin grafiği verilmiştir.



Şekil 2.8. Durağan zaman serisi

Şekil 2.8'de zaman serisinin değişimleri zaman içerisinde ortalama ve varyans değerlerinin sabit olduğu görülmektedir. Bu zaman serisinin ortalama değerinin yaklaşık 0 olduğu gözlemlenmektedir. Ortalama değerine bağlı olarak varyans ve kovaryansın da bu zaman serisi için sabit olduğu belirlenmektedir.



Şekil 2.9. Durağan olmayan zaman serisi

Şekil 2.9’da zaman serisinin değişimlerinin zaman içerisinde ortalama ve varyans değerinin değişken olduğu sabit olmadığı görülmektedir. Bu zaman serisinin ortalama değeri belirlenemezken, ortalama değerine bağlı olarak varyans ve kovaryansın da bu zaman serisi için sabit olmadığı gözlemlenmektedir.

Zaman serileri başlığı altında incelediğimiz zaman serisi grafiklerinin durağan olma durumu incelendiğinde; Şekil 2.1’de verilen Sin x fonksiyonunun ve Şekil 2.5’te verilen bir uçak firmasının yıllara göre kar payı zaman serilerinin grafikleri incelendiğinde durağan olduğu belirlenmiştir. Ancak Şekil 2.2’de verilen pascal üçgeni, Şekil 2.3’te verilen bir firmanın ürün satışı, Şekil 2.4’te verilen bir otobüs firmasının taşıdığı yolcu sayısı ve Şekil 2.6’da verilen bir alanda gerçekleşen depremlerin şiddeti zaman serilerinin grafikleri incelendiğinde durağan olmadığı belirlenmektedir.

Zaman serisinin grafiği incelendiğinde, serinin artış ve azalış düzensizliğine göre serinin durağan olup olmadığı söylenebilmektedir [22]. Zaman serilerinin durağanlık analizinden sonra, durağanlık durumuna göre zaman serisi analiz yöntemi belirlenmektedir.

2.3. Zaman Serilerinde Analiz Yöntemleri

Zaman serisi yöntemleri, son yıllarda araştırmacıların dikkatini çeken bir araştırma alanıdır. Zaman serisi yöntemlerinin temel amacı, serinin doğal yapısını tanımlayan uygun bir yöntem geliştirmek için bir zaman serisinin geçmiş gözlemlerini dikkatlice toplamak ve titizlikle incelemek olarak belirtilmektedir. Bu yöntem daha sonra seriler için gelecekteki değerleri üretmek, yani tahmin yapmak için kullanılmaktadır. Bu nedenle zaman serisine uygun bir yöntem seçme, tahmin başarımı için önem arz etmektedir. Uzun yıllar boyunca araştırmacılar tarafından, uygun zaman serisi tahmin yöntemlerinin geliştirilmesi ve iyileştirilmesi için çalışmalar gerçekleştirilmiştir. Geliştirilen yöntemlere aşağıdaki başlıklarda yer verilmiştir.

2.3.1. Hareketli Ortalamalar Yöntemi (HO)

Hareketli ortalama, kısa vadeli dalgalanmaları düzeltmek ve uzun vadeli eğilimleri veya döngüleri vurgulamak için zaman serisi verileriyle yaygın olarak kullanılmaktadır. Kısa ve uzun vadeli eşik, uygulamaya bağımlıdır ve hareketli ortalamanın parametreleri buna göre ayarlanmaktadır [20]. Örneğin, banka hesapları, krediler veya işlem hacimleri gibi finansal verilerin teknik analizinde sıklıkla kullanılmaktadır. Ekonomide gayri safi yurtiçi hasılat, istihdam veya diğer makroekonomik zaman serilerini incelemek için kullanılmaktadır. Hareketli ortalamanın denklemi aşağıda verilmiştir.

$$X_t = \delta + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

Denklemden δ , serinin ortalamasını ifade etmektedir. θ modelin parametrelerini simgelemektedir. ϵ beyaz gürültü hata terimlerini göstermektedir. Hareketli ortalamalar yöntemi, serinin ortalama alma durumuna göre gruplandırılmaktadır. Bu gruplandırmalara alt başlıklarda değinilmiştir.

Basit Hareketli Ortalama (BHO)

Ortalama, merkezi değerin her iki tarafındaki eşit sayıda veriden elde edilmektedir. Basit hareketli ortalama ise ortalama içinde varyasyonların zaman içinde kaydırmak yerine verilerdeki değişimlerle ayarlanmasını sağlamaktadır [23]. Örneğin, n günlük kapanış fiyatı için eşit ağırlıklı ortalaması, önceki n günlük kapanış fiyatlarının ortalaması ile aynı bilgiyi ifade etmektedir. Bu fiyatlar, $p_m + p_{m-1} + \dots + p_{m-(n-1)}$ ise denklem aşağıda verilmiştir.

$$\check{p}_{sm} = \frac{p_m + p_{m-1} + \dots + p_{m-(n-1)}}{n} = \frac{1}{n} \sum_{i=0}^{n-1} p_{m-i}$$

Ardışık değerleri hesaplarken, yeni bir değer toplanmaktadır ve en eski değer silinmektedir. Bu durumda hesaplamalar için her seferinde tam bir toplamın gerekli olmadığı anlamına gelmektedir:

$$\check{p}_{sm,yeni} = \check{p}_{sm,eski} + \frac{1}{n}(p_m - p_{m-n})$$

Bir BHO, eski veri noktalarının düşmesi veya yeni verilerin gelmesinden de etkilenebilmektedir. BHO'nun bir özelliği de verilerin mevsimsel dalgalanması varsa, o dönemin bir BHO'sunun uygulanması ile mevsimsel dalgalanmanın ortadan kaldırılması anlamına gelmektedir [23].

Kümülatif Hareketli Ortalama (KHO)

Kümülatif hareketli ortalama, veriler sıralı bir veri akışına ulaşması ile birlikte, kullanıcı geçerli veri noktasına kadar, tüm verilerin ortalamasını almaktadır [23]. Örneğin, bir yatırımcı belirli bir hisse senedi için tüm hisse senedi işlemlerinin ortalama fiyatını şimdiki zamana kadar isteyebilir. Kümülatif hareketli ortalamalar, $x_1, \dots, x_n$ verilerinin bulunduğu n tane değer bulunan serinin ortalaması aşağıdaki denklem kullanılarak hesaplanabilmektedir.

$$KHO_n = \frac{x_1 + x_2 + \dots + x_n}{n}$$

BHO yöntemi ile seriye eklenen her yeni değer için, depolanan tüm değerlerle toplayıp tekrar bölme işlemi yapmaktadır [23]. Ancak, kümülatif hareketli ortalama yeni bir değer eklendiğinde güncelleme aşağıdaki denklem ile yapılmaktadır.

$$KHO_{n+1} = \frac{x_{n+1} + n * KHO_n}{n + 1}$$

Yeni kümülatif hareketli ortalama, yeni referans noktası ile eski KHO değerinin tüm değerlerin sayısı ile çarpımının toplamının, yeni toplam değer sayısına bölünerek elde edilmektedir.

Ağırlıklı Hareketli Ortalama (AHO)

Ağırlıklı hareketli ortalama, farklı yakınlık konumlarındaki verilere farklı ağırlıklar vermek için çarpma faktörlerine sahip bir ortalama olarak belirtilmektedir. Verilerin analizinde, ağırlıklı hareketli ortalama (AHO), aritmetik ilerlemede azalan ağırlıkların özel bir anlamlılığa sahip olması anlamına gelmektedir [23]. Örneğin, 10 günlük bir seri seçildiğinde bugün ki hareketin kapanış fiyatı 10 ile çarpılırken bir önceki hareketin kapanış fiyatı 9 ile çarpılmaktadır. 10 gün önceki hareketin kapanış fiyatına ise ağırlık verilmemektedir. Böylece geçmiş hareketin daha yakın zamanı etkileme oranı aza indirgenmeye çalışılmaktadır. Bir n günlük AHO'da son günün ağırlığı n, ikinci en son n-1, vb. ağırlıklara sahip olacak şekilde denklem haline getirilmiştir. AHO denklemi aşağıdaki gibi belirtilmiştir.

$$AHO_m = \frac{np_M + (n-1)p_{M-1} + \dots + 2p_{(M-n+2)} + p_{(M-n+1)}}{n + (n-1) + \dots + 2 + 1}$$

2.3.2. Otoregresif Model (OR)

Bir işlemin değerinin doğrusal olarak aynı işlem içerisinde geçmiş değerlere bağlı olduğu fikrine dayandırılmıştır. Bu yöntemde, işlemin gerçek değeri, önceki değerlerinin ve beyaz gürültü değerinin nitel doğrusal birleşiminin toplamı olarak ifade edilmektedir [24].

$$(1) y_t = \beta_0 + \beta_1 y_{t-1} + \epsilon_t$$

Bu denklemde, y_t t zamanında y değerinin kaç olacağını hesaplamaktadır. y_{t-1} , y değerinin bir önceki zamanda kaç olduğunu β gecikme değerleri ile belirlenmektedir. Beyaz gürültü değeri ϵ_t , hesaba katılarak tahmin gerçekleştirilmektedir.

OR modelde, birden fazla (önceki zaman dilimine ait) değerler kullanılabilir. Bu durumda OR modeli derecelendirilmektedir. Önceki denklemde model OM (1) simgesi ile yazılan

birinci dereceden bir otoregresif model olarak ifade edilmektedir. OM modelinin derecelendirilmesi, önceki zaman dilimlerine göre belirlenmektedir. Örneğin; bu yıl ülkede yapılan üretim miktarını (y_t) önceki iki yıldaki üretim miktarı ölçümlerini (y_{t-1} , y_{t-2}) kullanarak tahmin etmek istiyorsak, bunu yapmak için otoregresif model şöyle olmaktadır:

$$(2) y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \epsilon_t$$

Bu model, OM (2) olarak yazılan ikinci dereceden bir otoregresiftir. Çünkü t zamanı, t-1 ve t-2 zamanlarındaki değerlerden tahmin edilmektedir. Genel olarak, bir k dereceden oto regresyon, OM (k) olarak yazılarak, herhangi bir zamanda t serisinin değerinin, t-1, t-2, ..., t-k zamanlarındaki değerlerin doğrusal bir fonksiyonu olduğu çoklu doğrusal regresyon olarak belirtilmektedir [24].

2.3.3. Box-Jenkins Yöntemi

Box-Jenkins modeli, zaman serisini oluşturan işlemin bir otoregresif hareketli ortalama(ORHO) modeli veya sabit değilse bir otoregresif entegreli hareketli ortalama(OREHO) modeli kullanılarak tahmin edilebileceği varsayımı ile başlamaktadır. Box ve Jenkins, durağanlık elde etmek için sabit olmayan serilerin bir veya daha fazla kez yinelenmesini önermektedir [25]. Bu yinleme işlemleri üç adımda gerçekleştirilmektedir. Bunlar;

- I. Tanımlama: Verilerin grafikleri, oto korelasyonlar, kısmi oto korelasyonlar ve diğer bilgileri kullanarak, basit bir OREHO modelleri sınıfı seçilmektedir. Bu, p, d ve q için uygun değerlerin hesaplanması anlamına gelmektedir.
- II. Tahmin: Verileri, seçilen modelin parametrelerini eğitmek için kullanılmaktadır.
- III. Kontrol: Model, serilerin oto korelasyonları (kalan veya hata serileri) dikkate alınarak yetersizlik açısından kontrol edilmektedir [25].

OREHO modelinde tahmin doğruluğun en yüksek olmasını sağlamak için en önemli adım tanımlama aşaması olarak belirtilmektedir. OREHO modelinde tanımlama aşaması üç bölümden oluşmaktadır:

- 1) Otoregresif bölümü(p), veri serisinin geçmiş değerlerini gelecekteki değerlerle ilişkilendiren doğrusal bir regresyonu ifade etmektedir.
- 2) Entegre bölümü(d), sabit bir seri elde etmek için veri serisinin kaç kez farklı olması gerektiğini göstermektedir.
- 3) Hareketli ortalamalar bölümü(q), geçmiş tahmin hatalarını veri serilerinin gelecekteki değerleriyle ilişkilendirmektedir.

OREHO (p, d, q) olarak simgelenmektedir ve OREHO (1,1,1) modelinin denklemi aşağıda verilmiştir;

$$x_t = (1 + \beta_1)x_{t-1} - \beta_1x_{t-2} + \delta + a_1\varepsilon_{t-1} + \varepsilon_t$$

Bu denklem, zaman serisini en iyi yansıtacak şekilde p, d ve q değerleri ile düzenlenmektedir. OREHO denklemi ile tahminler oluşturulmaktadır. Tahmin aşamasından sonra kontrol aşamasında modelde herhangi bir gelişme sağlanmayana kadar yinelemeli olarak yöntem adımları uygulanmaktadır [26].

2.3.4. Üstel Düzleştirme Yöntemi

Üstel düzeltme, bir zaman serisinde önemli bir nicel tahmin tekniğidir. Üstel düzeltme, en son ve eski gözlemlere sırasıyla maksimum ve minimum ağırlıklar eklemektedir. Başka bir deyişle, veri noktalarına geriye döndüğümüzde ağırlık katlanarak azalmaktadır. Düzgünleştirme parametresinin veya düzeltme sabitinin α değeri, öngörmenin doğruluğunu belirler, yani katsayının α uygun değer seçimi doğru öngörüye yol açmaktadır. Üstel düzeltme ile tahmin oldukça güvenilir ve hızlı olduğundan, bu modeli kullanmak geniş kapsamlı uygulamalarda büyük bir avantaj sağlamaktadır [27].

Basit Üstel Düzleştirme

Basit üstel düzeltme (BÜD) modeli, kısa vadeli tahmin için en uygun model olarak belirtilmektedir. Genellikle bu model, bir ay içerisindeki verilerden gelecekteki bir değer tahmini için kullanılmaktadır. BÜD modeli bir tür ağırlıklı hareketli ortalamadır ve genellikle üstel ağırlıklı hareketli ortalama (ÜAHO) modeli olarak bilinmektedir [27]. BÜD'nin basitliği, sadece bir parametrenin tahmin edilmesi ve bu parametrenin düzeltme sabiti α olmasıdır. BÜD denklemi aşağıdaki biçimde temsil edilebilmektedir:

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

Bu denklemde F_t, F_{t-1} zaman serisi için bir tahmini, önceki t-1 dönemi için tahmin değerini temsil etmektedir ve a , bir düzeltme sabitidir. F_{t-1} değeri F_t 'ye eklendiğinde, şu denklem elde edilmektedir:

$$(1) \quad F_t = ay_t + (1 - a)[ay_t + (1 - a)F_{t-2}]$$

$$(2) \quad F_t = ay_t + a(1 - a)ay_{t-1} + (1 - a)^2F_{t-2}$$

$$(3) \quad F_t = ay_t + a(1 - a)y_{t-1} + a(1 - a)^2y_{t-2} + a(1 - a)^3y_{t-3} + \dots + (1 - a)^tF_0$$

Denklem (3) şu şekilde ifade edilebilir:

$$F_t = a \sum_{r=0}^{n=1} (1 - a)^r y_{t-r} + (1 - a)^t y_0$$

Bu denklemde F_0 düzgün işlemin başlangıç değeridir ve $(1 - \alpha)^r$ bir önceki dönemin ağırlık dizisidir ve bu ağırlıklar zaman içinde giderek azaldığı görülmektedir.

Düzleştirilmiş seriler, ikinci gözlemin düzleştirilmiş versiyonuyla başlamaktadır. BÜD tahmin sürecinde, F_{t+1} 'in hesaplanması için F_1 'in bilinmesi gerekmektedir. F_t için BÜD denklemi aşağıda verilmiştir. Herhangi bir t zaman periyodu için, beklenen değer aşağıdaki gibi belirlenmiştir.

$$\text{Yeni tahmin} = \alpha (\text{mevcut gözlem}) + (1 - \alpha) (\text{son tahmin})$$

veya denklem ile:

$$F_{t+1} = \alpha * D_t + (1 - \alpha) * F_t$$

Bu denklemde D_t , t periyodu için gerçek değeri, $0 \leq \alpha \leq 1$, mevcut gözlem üzerine yerleştirilen nispi ağırlığı belirleyen düzeltirme sabiti olarak adlandırılmaktadır. Serinin orijinal ve düzleştirilmiş sürümleri $\alpha = 1$ olduğunda benzer olduğu saptanmıştır. $\alpha = 0$ olduğunda ise seri düzleştirilme işlemi uygulanmaktadır [27].

Çift Üstel Düzleştirme (ÇÜD)

Holt-Winters yöntemi olarak da bilinen çift üstel düzeltirme (ÇÜD) yöntemi, trend ve mevsimsel zaman serilerinde ve verilerde bir eğilim olduğu durumlarda kullanmak için üstel düzeltirmenin genişletilmesidir [27]. ÇÜD, seviye ve trend bileşenlerini güncellemek için iki düzeltirme parametresi kullanmaktadır. Bu öngörme işleminde üç denklem kullanılmaktadır. İlk denklem zaman serilerini düzeltirmek için, ikinci denklem eğilimleri düzeltirmek için ve üçüncü denklem yukarıdaki iki denklemin kombinasyonu için kullanılmaktadır.

Bu denklemler:

$$S_t = \alpha * D_t + (1 - \alpha) * (S_{t-1} + b_{t-1}) \quad 0 < \alpha < 1$$

$$b_t = \beta * (S_t - S_{t-1}) + (1 - \beta) * b_{t-1} \quad 0 < \beta < 1$$

$$F_{t+1} = S_t + b_t$$

Tek bir üstel düzeltirme denkleminde kullanılan tüm karakterler, görünen bir çift üstel düzeltirme denkleminde aynı anlamı temsil etmektedir. α düzeltirme sabiti, β bir eğilim düzeltirme sabiti, S_t t periyodu için düzleştirilmiş sabit değeri ve b_t t periyodu için düzleştirilmiş eğilim değeridir [27].

2.3.5. Yapay Sinir Ağları Yöntemi

Box – Jenkins veya OREHO gibi geleneksel zaman serisi yaklaşımları, incelenen zaman serilerinin doğrusal süreçlerden üretildiğini varsaymaktadır. Bununla birlikte, seri mekanizması doğrusal değilse bu yöntemler uygun olmayabilmektedir. Gerçek dünya sistemlerinin genellikle


doğrusal olamamasından kaynaklanan ihtiyaç ile yapay sinir ağıları geliştirilmiştir. Yapay sinir ağıları (YSA), çok karmaşık doğrusal olmayan bağımlılıkları yeniden üretmeyi sağlayan güçlü bir biyolojik aracı temsil etmektedir [17]. YSA, var olan örneklerden öğrenme ve tahmin modelini gerçekleştirmektedir. Model, verileri tahmin yönteminde en doğru ve yaygın olarak kullanılan tahmin modelleri arasında yer almaktadır. Modelin, incelenen sorunlara ilişkin var olan bir varsayımı bulunmamaktadır. Model, bir dizi verileri alarak öğrenme sürecine başlamaktadır. Modele sunulan veriler öğrenildikten sonra, verilerin yapısını bulmaya/çıkarmaya çalışmaktadır. Yapay sinir ağıları konusu üçüncü başlıkta ayrıntılı olarak ele alınmıştır.



3. YAPAY SİNİR AĞLARI

Yapay sinir ağı (YSA), zaman serisi tahminine alternatif bir teknik olarak önerilmiş ve son yıllarda büyük bir popülerlik kazanmıştır. YSA, insan beyninin makineler tarafından taklit edilebilmesi için geliştirilmiş bir modeldir [17, 28]. İnsan beyninin çalışmasına benzer şekilde, YSA'lar girdi verilerindeki düzeni ve kalıpları tanımaya, verilerden öğrenmeye ve daha sonra verilerden genelleştirilmiş sonuçlar ile bilgi elde etmeye çalışmaktadır.

Yapay sinir ağı; insan beyninden esinlenerek, bir sinir hücresinin(nöron) matematiksel modellenmesi olarak ifade edilmiştir [17, 28] İlk yapay sinir ağı modeli 1943 yılında bir sinir hekimi olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından oluşturulmuştur [28]. YSA biyolojik sinir ağlarını taklit eden sentetik elemanlardan oluşmaktadır.



Şekil 3.1. Bir sinir hücresinin yapısı ve bileşenleri


Şekil 3.1’de bir sinir hücresinin yapısı ve bileşenleri gösterilmiştir. Sinir hücresinin bileşenleri şu şekilde açıklanabilir [28, 29];

Akson: Nörona Giriş/Çıkış bileşenidir. Dentritlerden alınan uyarıyı başka bir nöronun dentritine gönderir.

Sinaps: Nöronların aksonlarının diğer nöronun dentritine ağırlıklı bağlantı sağlamaktadır.

Dentrit: Nöronlardan gelen aksonları hücre gövdesine taşıyan bağlantı kollarıdır.

Hücre gövdesi: Giriş aksonlarını işleyerek, çıkış aksonlarının elde edildiği alandır.



Şekil 3.2. Bir sinir hücresinin matematiksel formülü

Biyolojik sinir hücresinin matematiksel modeli Şekil 3.2’de verilmiştir. x_0 , diğer nöronlardan gelen ve dendritler tarafından yakalanan aksonları(sinyalleri) temsil etmektedir. w_0 , ağırlıkları iki nöronu birbirine bağlayan sinapsların yoğunluğunu ifade etmektedir. Sinaps, akson ara bağlantılarına dayanan ağırlık girdilerini belirlemektedir. Ağırlıklar pozitif (uyarıcı) veya negatif (engelleyici) olabilmektedir. Dendrit, giriş aksonunu ve sinaps ağırlıklarını hücre gövdesine iletmektedir. Hücre gövdesinde yer alan işlemler, nöronun aktif olması için aşması gereken eşik fonksiyonudur; toplam fonksiyonu olarak da ifade edilmektedir. Toplam fonksiyonuna örnek olarak çarpım, minimum, maksimum, çoğunluk, kümeli toplam, vb. verilebilir. Aktivasyon fonksiyonu, giriş aksonlarını ve mevcut aktivasyon esas alınarak yeni aktivasyon seviyesinin belirleyen bir fonksiyondur. Bu fonksiyon genelde doğrusal olmamaktadır. Fonksiyonun doğru seçilmesi çok önemlidir. Çünkü sonuç performansını etkilemektedir. Aktivasyon fonksiyonuna örnek olarak sigmoid, adım, lineer, sinüs, tanjant, hiperbolik, vb. verilebilir. Çıktı aksonu, nöronda işlem gören giriş aksonunun sıradaki nörona gönderilecek son (işlem görmüş) halidir [28].

3.1. Yapay Sinir Ağı Özellikleri

YSA’nın zaman serisi analizi ve tahmini için alternatif bir teknik olmasını sağlayan belirgin özellikleri bulunmaktadır [29]. Bu özellikler;

- I. YSA veri güdümlü ve kendiliğinden uyarlanabilir niteliktedir [29, 30]. YSA’nın bu özelliği sayesinde, bir model formunu belirtmeye veya verilerin istatistiksel dağılımı hakkında önceden varsayım yapmaya ihtiyaç duyulmamaktadır; istenen model verilerden sunulan özelliklere göre uyarlanabilir şekilde oluşturulmaktadır.
- II. YSA doğrusal değildir, geleneksel lineer yaklaşımların aksine karmaşık veri modellerini modellemede daha pratik ve doğru sonuçlar elde etmektedir [29, 30]. YSA çeşitli lineer


modellerden daha iyi analiz ve tahmin yaptıklarını gösteren birçok durum literatür taramalarında gözlemlenmiştir.

- III. YSA evrensel fonksiyonel yaklaşımlardır. Bir ağı herhangi bir sürekli işlevi, istenen herhangi bir hassasiyete yaklaştırabileceğini göstermişlerdir [29, 30]. YSA, yüksek doğruluk derecesine sahip büyük bir işlev sınıfına yaklaşmak için verilerden gelen bilgilerin paralel işlenmesini sağlamaktadır. Ayrıca, girdi verilerinin hatalı, eksik veya bulanık olduğu durumlarla başa çıkabilmektedir.

3.2. Yapay Sinir Ağı Mimarisi


Bir sinir ağı, birden fazla yapay nöron içeren, bir dizi katman halinde düzenlenmiş yazılım yapılarıdır. Bu katmanlar Şekil 3.3'te verilmiştir ve gösterilen sinir ağı katmanları ve işlevleri aşağıdaki maddelerde açıklanmıştır. Bunlar;

- Girdi katmanı: Dış dünyadan verilerin/girdilerin alındığı katmandır. Verilerin ara katmana iletimi gerçekleştirilmektedir. Bu katmanda herhangi bir bilgi işleme gerçekleştirilmemektedir [29, 30].
- Ara (gizli) katmanlar: Girdi katmanından gelen veriler, bu katmanda işleme alınmaktadır. Bir ara katman ile birçok problemi çözmek mümkündür. Eğer ağı öğrenmesi istenilen problemin girdi/çıkı arasında ilişkisi doğrusal olmaz ve karmaşıklık artarsa birden fazla sayıda ara katmanda kullanılmaktadır. Ağı öğrenmesi tamamlandıktan sonra elde edilen bilgiler çıktı katmanına iletilmektedir [29, 30].
- Çıktı katmanı: Ara katmandan gelen bilgileri işleyerek ağı girdi katmanından sunulan girdi için ağı ürettiği çıktıyı bulmaktadır. Bu çıktı dış dünyaya iletilmektedir [29, 30].



Şekil 3.3. Yapay sinir ağı katmanları

YSA katmanları ve işlevleri temel alınarak veriler üzerinde eğitimler yapılmaktadır. Eğitimlerin performansına göre YSA'nın ağı öğrenme başarımı ölçülebilmektedir. YSA'nın eğitim performansını ölçmek için eğitim bittikten sonra ağı eğitim sırasında görmediği örnekler ağı gösterilerek bunlar hakkında ağı kararına bakılmaktadır. Eğer ağı görmediği örneklere doğru cevaplar üretebiliyorsa o zaman performansı iyidir ve ağı öğrenmiştir denilmektedir. Yapay sinir ağlarının eğitilmesi için izlenen adımlar Şekil 3.4'te akış diyagramı şeklinde verilmiştir.



Şekil 3.4. YSA eğitim adımlarının akış şeması

3.3. Yapay Sinir Ağı Türleri


Yapay sinir ağları, ağı eğitimini kolaylaştırmak için türlere ayrılmıştır. Bağlantı modeline, gizli katman sayısına, ağırlıklarının doğasına ve bellek birimine göre türlere ayrılmaktadır [29, 30, 31]. Tablo 3.1'de YSA parametreleri, türleri ve açıklamaları belirtilmiştir.

Tablo 3.1. YSA parametreleri, türleri ve açıklamaları

Parametre	Türleri	Açıklaması
Bağlantı modeline göre	İleri Beslemeli	Döngülerde geri bildirim yoktur.
	Geri Beslemeli	Döngülerde geri bildirim vardır.
Gizli Katman sayısına göre	Tek Katmanlı	Bir gizli katmana sahiptir.
	Çok Katmanlı	Birden fazla gizli katmana sahiptir.
Ağırlıkların doğasına göre	Sabit	Ağırlıklar önceliklidir ve iç değişmezler.
	Düzenlemeli	İşlem sırasında ağırlıklar güncellenir ve değiştirilir.
Bellek Birimine göre	Statik	Hafızasız birim olarak ifade edilir. Akım çıkışı akım girişine bağlıdır.
	Dinamik	Bellek ünitesi olarak ifade edilir. Çıkış, akım çıkışının yanı sıra akım girişine de bağlıdır.

3.4. Yapay Sinir Ağı Modelleri

Yapay sinir ağları çok güçlü tahmin modelleri oluşturmaya imkân tanımaktadır. Doğrusal olmayan bağımlılıklarla başa çıkma yeteneği, diğer tahmin yöntemlerine kıyasla büyük bir avantaj sağlamaktadır. Doğrusal olmayan serilerin YSA’da eğitilmesi için, ağın yapısına uygun model seçilmesi gerekmektedir. Uygun YSA modelinin belirlenmesi, model performansında başarımlı performansını artırmaktadır [30]. Model seçiminin önemine Şekil 3.5’te değinilmiştir.




Şekil 3.5. YSA gizli katman seçimine örnek

Şekil 3.5’te bir, iki ve üç gizli katmanlı model oluşturulmuştur. Verilerin dört kümeye ayrılmış olduğu grafiklerde anlaşılmaktadır. Ağın eğitilmesi ve verinin analiz başarımının yüksek

olması için modeller denenmiştir. Ağı en iyi başarımının, üç gizli katmanı olan modelde elde edildiği gözlemlenmiştir.

YSA'da uygun modeli bulmak için yapılan çalışmalarla, YSA'nın türleri temel alınarak modeller oluşturulmuştur [28, 30]. Bu modellerden bazıları Şekil 3.6'da verilmiştir. Şekil 3.6'da verilen modeller ve özellikleri aşağıda verilmiştir.



1. Tek Katmanlı Algılayıcı Modeli, sinir ağı iki giriş birimine ve gizli katmanları olmayan bir çıkış birimine sahiptir. Bunlar aynı zamanda Perceptron Modeli olarak da adlandırılmaktadırlar [28, 29].
2. Radyal Temelli Ağ Modeli, bu ağlar, nöronların aktivasyon fonksiyonu olarak radyal temel fonksiyonu kullanılması dışında, ileri beslemeli sinir ağına benzer özellikler taşımaktadır [31].
3. Çok Katmanlı Algılayıcı Modeli, Bu ağlar, tek katmanlı algılayıcının aksine, birden fazla gizli nöron katmanı kullanılmaktadır. Bunlar Derin İleri Beslemeli Sinir Ağları olarak da bilinmektedir [29, 31].


4. Geri Beslemeli Sinir Ağı, gizli katman nöronlarının kendi kendine bağlantıları olan sinir ağı türüdür. Geri beslemeli sinir ağları belleğe sahiptir. Her durumda, gizli katman nöronu alt katman aktivasyonunun yanı sıra önceki aktivasyon değerini de almaktadır [29].
5. Uzun Kısa Süreli Bellek Geri Beslemeli Sinir Ağı, bellek hücresinin gizli katman nöronlarına dâhil edildiği sinir ağı tipine UKVH ağı denir [30, 31].
6. Hopfield Ağı, her bir nöronun diğer nöronlara bağlı olduğu, tamamen birbirine bağlı bir nöron ağıdır. Bu ağ, nöronların bir değerini istenen değere ayarlayarak giriş değeri ile eğitilmektedir. Sonra ağırlıkları hesaplanmaktadır. Ağırlıklar değişmez. Bir veya daha fazla model için eğitildikten sonra, ağ öğrenilen modellerle birleştirilmektedir [28, 30].
7. Boltzmann Makinası Sinir Ağı, bazı nöronların girilmesi dışında Hopfield ağına benzerken, diğerleri doğada gizlidir. Ağırlıklar rastgele başlatılır ve geri yayılım algoritmasıyla öğrenilmektedir [30].

3.5. Yapay Sinir Ağının Doğrusal Olmayan Problem türleri ve çözümleri

Uzun yıllar boyunca, lineer modeller çoğu alanda öncü rol oynamıştır. Lineer modeller, atanmış görevlerle tatmin edici bir şekilde başa çıkmış birçok iyi tasarlanmış ve optimize edilmiş yöntemleri bulunmaktadır. Ancak, doğrusal yaklaşımın yetersiz kaldığı problemler de yeni çözümlere ihtiyaç olmuştur. Bu problemlerin çözümü için araştırmacılar YSA'yı önermişlerdir. Yapay sinir ağları, çok karmaşık doğrusal olmayan problemleri çözümleyebilmektedir [29, 31].

Yapay sinir ağları, üç tür doğrusal olmayan zaman serisi problemini çözmeyi sağlamaktadır. Bunlar;

1. Birinci tür zaman serileri probleminde (Problem Tipi 1), $y(t)$ zaman serisinin gelecekteki değerlerini o zaman serisinin geçmiş değerlerinden ve ikinci zaman serisinin geçmiş değerlerinden $x(t)$, tahmin edilebilmektedir [32]. Bu tahmin biçimine, harici giriş ile doğrusal olmayan otoregressif denilmektedir ve Şekil 3.7'de gösterilmektedir:




Şekil 3.7. Problem Tipi 1'e ait zaman serisi

Bu model, işsizlik oranları, GSYİH vb. gibi ekonomik değişkenlere dayalı olarak bir hisse senedinin veya tahvilin gelecekteki değerlerini tahmin etmek için kullanılabilir. Ayrıca, kimyasallar gibi dinamik sistemleri temsil etmek için geliştirilen modellerin kullanıldığı sistem

tanımlaması için de kullanılabilir. Bunlar; süreçler, üretim sistemleri, robotik, havacılık araçları vb.


2. İkinci zaman serisi probleminde, sadece bir seri bulunmaktadır (Problem Tipi 2). $y(t)$ zaman serisinin gelecekteki değerleri sadece o serinin geçmiş değerlerinden tahmin edilmektedir [32]. Bu tahmin biçimine doğrusal olmayan otoregressif denilmektedir ve aşağıda Şekil 3.8’de gibi gösterilmektedir:



Şekil 3.8. Problem Tipi 2’ye ait zaman serisi

Bu model, harici bir girdi içermeyen bir ağ modeli olduğu için bu ağ modelinde, öğrenme ve test aşamasında herhangi bir veri kullanılmadan sadece geçmiş değerleri girdi olarak kullanılmıştır. Bu model finansal verileri tahmin etmek için de kullanılabilir.

3. Üçüncü zaman serileri problemi birinci zaman serisi modeline benzerdir (Problem Tipi 3), çünkü iki serinin katılımıyla, bir giriş serisi $x(t)$ ve bir çıkış serisi $y(t)$ bulunmaktadır. Bu durumda, önceki $y(t)$ değerlerini bilmeden, önceki $x(t)$ değerlerinden $y(t)$ değerlerini tahmin edilmektedir [32]. Bu giriş / çıkış modeli Şekil 3.9’da gösterilmektedir:



Şekil 3.9. Problem Tipi 3’e ait zaman serisi


Bu model, önceki $y(t)$ değerlerinin bulunamayacağı bazı durumlar/ uygulamalar olabilir. Bu durumda/ uygulamada giriş-çıkış modelini kullanılmak daha iyi tahminler sağlamaktadır.

Problem türü seçildikten sonra veri seti seçimi yapılmaktadır. Veri seti seçiminden sonra ön işlemler tamamlanarak uygulama adımına geçilmektedir. Uygulama aşamasında, üç çeşit hedef zaman serisi analiz adımı bulunmaktadır. Bunlar; eğitim, doğrulama ve test adımlarıdır. Eğitim, veriler eğitim sırasında ağa sunulmaktadır ve ağın verileri öğrenimini gerçekleştirmektedir. Doğrulama, ağ genellemesini ölçmek ve genellenin iyileştirilmesi durduğunda eğitimi

durdurmak için kullanılmaktadır. Test, bu adımın eğitim üzerinde hiçbir etkisi yoktur ve bu nedenle eğitim sırasında ve sonrasında bağımsız bir ağ performansı ölçümü sağlamaktadır.


Eğitim, doğrulama ve test değerleri belirlendikten sonra ağ modeli oluşturulmaktadır. Ağ modelinde, gizli katman sayısına ve gecikme sayısına değer verilmektedir. Bu değerlerin verilmesi için herhangi bir kesinlik bulunmamaktadır. Deneme-Yanılma yöntemi ile en iyi sonuç bulunmaya çalışılmaktadır.

Ağ modelinin belirlenmesi ile doğrusal olmayan üç problem için, ağ modeli belirlenmiştir. Bu ağ modelleri Şekil 3.10, Şekil 3.11 ve Şekil 3.12’de gösterilmiştir.




Şekil 3.10. Problem Tipi 1'e ait zaman serisi için ağ modeli

Şekil 3.10'da birinci problem türüne göre oluşturulan ağ modelidir. Giriş elemanları olarak hem $x(t)$ serisi hem de $y(t)$ serisi alınmaktadır. İki serisinde gecikme değerleri (1:2) alınıp ağırlıklandırma (W) yapıp bias (b) değeri ile gizli katmanda (10) seçilecek algoritma ile analiz edilmektedir. Analiz çıkış katmanında bias değerini sağlayana kadar devam eder ve bias değerini sağlayan değer çıkış elemanını $y(t)$ serisini oluşturmaktadır.



Şekil 3.11. Problem Tipi 2'e ait zaman serisi için ağ modeli

Şekil 3.11'de ikinci problem türüne göre oluşturulan ağ modelidir. Giriş elemanı olarak $y(t)$ serisi alınmaktadır. Serinin gecikme değeri (1:2) alınıp ağırlıklandırma (W) yapıp bias (b) değeri ile gizli katmanda (10) seçilecek algoritma ile analiz edilmektedir. Analiz çıkış katmanında bias değerini sağlayana kadar devam eder ve bias değerini sağlayan değer çıkış elemanını $y(t)$ serisini oluşturmaktadır.



Şekil 3.12. Problem Tipi 3'e ait zaman serisi için ağ modeli

Şekil 3.12'de üçüncü problem türüne göre oluşturulan ağ modelidir. Giriş elemanı olarak $x(t)$ serisi alınmaktadır. Serinin gecikme değeri (1:2) alınıp ağırlıklandırma (W) yapıp bias (b) değeri ile gizli katmanda (10) seçilecek algoritma ile analiz edilmektedir. Analiz çıkış katmanında bias değerini sağlayana kadar devam eder ve bias değerini sağlayan değer çıkış elemanını $y(t)$ serisini oluşturmaktadır.

Giriş serisi, gizli katman sayısı, gecikme değeri ve çıkış serisi seçimleri ile YSA modeli seçildikten sonra, ağı eğitimi için kullanılan algoritmalar seçilmektedir. YSA'nın eğitimi için kullanılabilecek algoritmalar [17, 32];

- Levenberg- Marquardt Algoritması(LMA): Bu algoritma genellikle daha fazla bellek ancak daha az zaman gerektirmektedir. Doğrulama örneklerinin ortalama kare hatasının artmasıyla belirtildiği gibi, genelleme düzeldiğinde eğitim otomatik olarak durmaktadır.
- Bayesian Regularization Algoritması(BRA): Bu algoritma tipik olarak daha fazla zaman gerektirmektedir, ancak zor, küçük veya gürültülü veri kümeleri için iyi genelleme sağlayabilmektedir. Düzenlemeli ağırlık minimizasyonuna göre eğitim durmaktadır.
- Scaled Conjugate Gradient Algoritması(SCGA): Bu algoritma daha az bellek gerektirmektedir. Doğrulama örneklerinin ortalama kare hatasının artmasıyla belirtildiği gibi, genelleme düzeldiğinde eğitim otomatik olarak durmaktadır.

YSA modeli eğitim işleminden sonra, performans ölçütleri kullanılarak karşılaştırma yapılmaktadır. Performans ölçütleri olarak, Ortalama Kare Hatası (OKH) ve Regresyon (R) ölçütleri kullanılmaktadır [18].

- **OKH:** Ortalama Kare Hatası: çıktılar ve hedefler arasındaki ortalama kare farkı olarak ifade edilmektedir. Sıfıra yakın değerler, başarımın daha iyi olduğunu belirtmektedir. Sıfır, hata olmadığı anlamına gelmektedir.
- **R:** Regresyon, çıktılar ve hedefler arasındaki korelasyonu ölçmektedir. R değeri 1 ise yakın ilişki, 0 ise rastgele ilişki anlamına gelmektedir.

Bu ölçütlere göre eğitim, doğrulama ve test verilerinin eğitimini başarımlı değeri değeriendirilmektedir. Eğitimin başarımlını hem değeri hem grafik olarak incelenebilmektedir. Sonuç grafikleri; performans, eğitim durumu, hata histogramı, regresyon, zaman serisi sonuçları, hata oto korelasyonu, giriş-hata çapraz korelasyonu bulunmaktadır. Yapay sinir ağı eğitimlerinin sonuç değeriğine ve/veya sonuç grafiklerine göre eğitime devam edilmesi ya da tamamlanması kararı alınabilmektedir.




4. DEPREMSELLİK

Dünya'nın oluşumundan itibaren zeminde gerçekleşen soğumalar ve ısınmalar sebebiyle hep hareketlilik yaşanmaktadır. Bu hareketliğe deprem adı verilmiştir. Deprem, bir levhanın diğer levhaya uyguladığı baskıya dayanamaması sonucunda kaya kütlelerinin yamulması/kırılması ile oluşan sismik dalgalardan oluşmaktadır [33]. Sismik dalgaların oluşumu, Dünyanın içyapısı ve levha hareketleri bağlı olarak gerçekleşmektedir.

4.1. Dünya'nın İçyapısı

Dünya yaklaşık 4,6 milyar yıl önce Güneş'i çevreleyen toz ve gazların bir kısmının, yer çekiminin gücü ile bir araya gelmesiyle oluşmuştur [34]. Dünya oluşuktan kısa bir süre sonra katmanlara ayrılmıştır. Bu katmanlar Şekil 4.1' de verilmiştir. Bu katmanlar; demir elementiyile dolu yoğun bir çekirdek, ısı hareketlerinin gerçekleştiği bir manto ve onun üzerinde kıtalar ve okyanuslar bulunan bir yer kabuğu yer almaktadır [35].



Şekil 4.1. Dünya'nın katmanları

Çekirdek: 2900 km derinlikteki en iç tabaka çekirdek olarak adlandırılmaktadır. Sıvı dış çekirdek ve katı iç çekirdek olarak ikiye ayrılmaktadır. Dış çekirdek yaklaşık 2300 km olup başlıca nikel ve demir alaşımından oluşmaktadır. İç çekirdek yaklaşık 1200 km kalınlığında olup çoğunlukla demirden oluşmaktadır [34, 36].

Manto: yer kabuğunun altında, 2900 km derinliğe kadar uzanan başlıca ferro, magnezyum, silikadan oluşan tabakadır. Alt ve üst manto olarak ikiye ayrılmaktadır. Isısal hareketler bu

tabakada gerçekleşmektedir. Bu hareketlere konveksiyonel akım denilmektedir. Bu akımlar levha tektoniğini tetiklemektedir[34, 36].

Yer kabuğu: Bu kırılğan en dış tabaka kıtaları ve okyanus tabanını kapsamaktadır. Bu tabakanın kalınlığı kıtaların altında 35 ile 70 km ve okyanusların altında 5 ile 10 km arasında değişmektedir. Yer kabuğunu oluşturan başlıca madde alüminyum, silikadır[34, 36].

Dünya, içyapısındaki kimyasal elementler ve sıcaklık değerlerinde zamanla değişimler gerçekleşmektedir. Bu değişimler sonucu manto da tektonik hareketler oluşmaktadır. Bu hareketler, yer kabuğunda bölünmelere sebep olarak levhaların oluşmasını sebep olmuştur.

4.2. Levha Hareketleri

Dünya, tektonik hareketlerden dolayı, yüzeyinde hareket eden birçok levhaya bölünmüştür. Bu levhaların bazılarının dünya yüzeyine yönelik hareketleri varken diğerlerinin çekirdeğe doğru hareketleri mevcuttur. Bu hareketler levhaların birbirine temas eden bölgelerinde baskıya (enerji sıkışmasına) sebep olmaktadır. Bu baskının sınır aşımında, yüzeye çıkmaya çalışan enerjinin oluşturduğu yamulması/kırılması deprem olarak ifade edilmektedir [37]. Deprem, büyüklüğü ile doğru orantılı olarak hasar bırakmaktadır.

1932’de Charles Richter, deprem büyüklüğünü ölçmek için ilk şiddet ölçeğini tasarlamıştır. Bu ölçek, Richter ölçeği olarak bilinmektedir. Richter, bir referans olayı belirlemek için Kaliforniya’daki depremlerin gözlemlerini kullanmıştır; bir depremin büyüklüğü, sinyalin maksimum genliği ile belirli bir mesafedeki bu referans olayı karşılaştırılarak hesaplanmaktadır. Richter Ölçeği logaritmiktir, yani 6,0 büyüklüğündeki bir depremin genliği 5,0 büyüklüğündeki bir depremden on kat daha büyüktür [37]. Deprem şiddetlerine ve deprem etkilerini artıran durumlar Bölüm 4.3’te verilmiştir.

4.3. Deprem

Dünya’nın oluşumundan itibaren gerçekleşen depremlerin olumsuz etkilerini indirmek için birçok çalışma yapılmıştır. Bu çalışmalarla birlikte deprem hakkında birçok bilgi elde edilmiştir. Bu bilgiler ışığında depremi türlerine göre sınıflandırmışlardır. Bunlar [33];

Derinliklerine göre;

0-70 km Sığ

70-300 km Orta

300-700 km Derin depremlerdir.

Uzaklıklarına göre (etkiledikleri yüzey alanı);

100 km>... Yerel

100-1000 km Yakın

1000-5000 km Bölgesel

5000 km<... Uzak depremlerdir.

Şiddetlerine göre;

8,0<... Çok Büyük

7,0- 8,0 Büyük

5,0- 7,0 Orta

3,0- 5,0 Küçük


1,0- 3,0 Mikro

1,0>... Ultra Mikro depremlerdir.

Depremlerin türlerine göre etki alanları değişmektedir. Depremin etki alanları çerçevesinde yer hareketleri düzeyleri değişiklik göstermektedir. Yer hareketleri düzeyleri dörde ayrılmaktadır. Spektral şiddetlerin 50 yılda aşılma olasılığına göre sırasıyla DD1, DD2, DD3 ve DD4 olarak belirlenmiştir. DD1 yer hareketi 50 yılda aşılma olasılığı %2'dir ve 2475 yılda, DD2 yer hareketi 50 yılda aşılma olasılığı %10'dur ve 475 yılda, DD3 yer hareketi 50 yılda aşılma olasılığı %50'dir ve 72 yılda, DD4 yer hareketi 50 yılda aşılma olasılığı %68'dir ve 43 yılda deprem tekrarlamaları gerçekleşmektedir [38]. Bu tekrarlanmaların en büyük etkisi levhaların birbirine uyguladığı baskılardır. Bu baskılar sonucunda oluşan kırılmalara fay denilmektedir. Türkiye'de üç büyük fay hattı bulunmaktadır. Kuzey Anadolu, Batı Anadolu ve Doğu Anadolu fay hatlarıdır [39].

4.4. Elâzığ İlinin Depremselliği

Doğu Anadolu fay hattı üzerinde yer alan Elâzığ ili birinci ve ikinci derece deprem bölgesi olarak belirtilmektedir. Şekil 4.2'de Elâzığ ilinin depremsellik haritası verilmiştir [40]. Haritada, Elazığ'ın Alacakaya, Arıcak, Maden, Sivrice, Karakoçan ve Kovancılar ilçelerinden geçen diri fayların olduğu görülmektedir. Elâzığ tektonik olarak aktif bir bölge olduğu için birçok çalışma yapılmıştır.



Şekil 4.2. Elazığ ili depremsellik haritası

Şekil 4.2’de görüldüğü gibi Elâzığ ili birinci ve ikinci dereceden depremleri oluşturan tektonik yapıya sahiptir. Bu depremleri oluşturan diri faylarda 8,0 şiddetine kadar büyük depremler olabileceği bilinmektedir. Oluşan depremler, Elazığ’ın toprak yapısından dolayı, Elazığ’ı ve komşu illerini büyük ölçüde etkilemektedir. Bu etkiler ve toprak yapısı hasarları artırmaktadır. Elâzığ ili için yapılan çalışmalarla zemin yapısı oluşturulmuştur. Elâzığ ili zemin yapısı Şekil 4.3’te verilmiştir.

ÜS SİSTEM	SİSTEM	SERİ	KAT	LİTOLOJİ BİRİMLERİ	LİTOLOJİ	SİMGE	AÇIKLAMALAR
SENOZOYİK	NEOJEN	PLEYİSTOSEN			Qal ₂ , Qal ₃ , Qal ₁	Qal ₁ Qal ₂ Qal ₃	Siltli kil Kumlu çakıllı kil Kum - çakıl
	NEOJEN	ÜST MİYOSEN - ALT PLİYOSEN		KARABAKIR FORMASYONU	Tkb ₃ , Tkb ₂ , Tkb ₁	Tkb ₃ Tkb ₂ Tkb ₁	Çakıltaşı - kumtaşı ardalanması Killi kireçtaşı - kıltaşı; killi kireçtaşı ve kıltaşı ardalanması Volkanitler; bazalt, andezit ve bunların cürufanları
	PALEOJEN	ORTA EOSEN - ÜST OLIĞOSEN		KIRKGEÇİT FORMASYONU	Tk ₁ , Tk ₂ , Tk ₃	Tk ₁ Tk ₂ Tk ₃	Marn Kumtaşı - marn ardalanması Çakıltaşı - kumtaşı ardalanması
MESOZOYİK	KRETASE	ÜST KRETASE	ÜST MEASTRİTİYEN	HARAMİ FORMASYONU	Kh	Kh	Masif kireçtaşı
			SENONİYEN	ELAZIĞ MAĞMATİTLERİ	Ke ₁ , Ke ₂	Ke ₁ Ke ₂	Volcano - sedimenterkayaçlar; volkanik kumtaşı ve çamurtaşı Bazalt, bazaltik yastık lav, andezit ve bunları kesen dasit daykaları
	PERMO - TRIYAS			KEBAN METAMORFİTLERİ	PzMzk	PzMzk	Kristalize kireçtaşı

Şekil 4.3. Elazığ ili zemin yapısı

Şekil 4.3’te Elazığ’ın zemin yapısına göre altı birimden oluşmaktadır. Bu birimler; Keban metamorfitleri, Elâzığ mağmatitleri, Harami formasyonu, Kırkgeçit formasyonu, Karabakır


formasyonu ve alüvyonlardır [41]. Elâzığ zemin birimlerinde bulunan toprak yapısı görülmektedir. Toprak yapısında yer alan siltli kil, kumlu çakıllı kil, killi kireçtaşı ve kireçtaşı toprakların deprem büyütme etkisi ile büyük depremler de tüm şehre zarar vermesi beklenmektedir.

Literatür de depremin etkilerini azaltmak ve/veya ortadan kaldırmak için yapılan birçok çalışma bulunmaktadır. Bu çalışmalardan biri de depremin tahmin edilmesidir. Bu tez çalışmasında Elâzığ ilini etkileyen Doğu Anadolu fay hattında gerçekleşen veriler ele alınmıştır. Deprem verilerine Veri madenciliği yöntemlerinden zaman serisi analizi gerçekleştirilmiştir. Zaman serisi analizi yöntemlerinden Yapay Sinir Ağları yöntemi kullanılarak doğrusal olmayan deprem verilerinde en yüksek tahmin başarımları hedeflenmiştir.



5. DENEYSEL ÇALIŞMALAR

Bu çalışmada Doğu Anadolu fay hattı üzerinde bulunan Elâzığ ilini etkileyen deprem verileri incelenmiştir. Veriler Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü'nden elde edilmiştir. Deprem verileri, 38,35 enlem 39,15 boylamında başlayan, 70 kilometre yarıçaplı dairesel alandaki depremleri içermektedir. Veri setinde, 21.10.1900 tarihi ile 21.10.2020 tarihi arasında 0-500 derinlik ve 0,0-9,0 şiddet arasındaki tüm depremleri içeren 8216 kayıt bulunmaktadır. Bu kayıtlar Şekil 5.1'de verilmiştir.



Şekil 5.1. Deprem kayıtları

Şekil 5.1'de Elâzığ ilini etkileyen fay çevresinin deprem yoğunluğu, Elâzığ Sivrice ilçesinden Malatya Pütürge ilçesine kadar devam etmektedir. Gerçekleşen her depremin konum ve büyüklüğü değişmektedir. Bu bölümde elde edilen veriler veri setleri haline getirilerek deneysel çalışmalar yapılmıştır. Yapılan deneysel çalışmaların sonuçları tablolar ve grafikler yardımıyla anlatılmıştır.

5.1. Veri Setleri

Veri seti, Elazığ ili ve çevresindeki deprem kayıtlarına ait tarih, saat, enlem, boylam, derinlik (km), şiddet (xM, MD, ML, Mw, Ms, Mb), tip ve şehir gibi verileri içermektedir. Örnek kayıt Tablo 5.1'de verilmiştir. Tablo 5.1'in ilk satırındaki depreme ait veriler; Elâzığ ilinde 16 Mayıs 2020

tarihinde saat 12:11’de 3,9 km derinliğinde ve 1,2 şiddet ile gerçekleşen depreme ait verilerdir. Tablo 5.1’in 10. satırında bulunan deprem ise Malatya ilinde 15 Mayıs 2020 tarihinde saat 16:37’de 17,8 km derinliğinde ve 1,6 şiddet ile gerçekleşmiştir.

Tablo 5.1. Deprem Kayıtları

Tarih	Saat	Enlem	Boylam	Der	xM	MD	ML	Mw	Ms	Mb	Tip	Şehir
2020.05.16	12:11	38,45	39,25	3,9	1,2	0	1,2	0	0	0	Ke	Elazig
2020.05.16	10:53	38,49	38,72	3,3	1,8	0	1,8	0	0	0	Ke	Elazig
2020.05.16	10:49	38,41	39,16	4,8	1,2	0	1,2	0	0	0	Ke	Elazig
2020.05.16	02:35	38,43	39,22	2,4	2,8	0	2,8	0	0	0	Ke	Elazig
2020.05.16	02:08	38,26	39,37	16,8	1,5	0	1,5	0	0	0	Ke	Diyarbakir
2020.05.16	02:03	38,28	38,75	3,8	2,6	0	2,6	0	0	0	Ke	Malatya
2020.05.16	02:01	38,26	39,40	9,4	1,3	0	1,3	0	0	0	Ke	Diyarbakir
2020.05.15	22:24	38,42	39,24	9,5	1,8	0	1,8	0	0	0	Ke	Elazig
2020.05.15	17:32	38,43	39,14	14,2	1,4	0	1,4	0	0	0	Ke	Elazig
2020.05.15	16:37	38,33	38,85	17,8	1,6	0	1,6	0	0	0	Ke	Malatya
...		...	...	...		...	...	...	...	...	...	

Elâzığ ilini etkileyen deprem kayıtlarına çeşitli ön işlemler uygulanmıştır. Bu ön işlemler; her kayıt için veri olmadığı için MD, ML, Mw, Ms, Mb boyutları ve tip bilgileri silinmiştir. Ayrıca, deprem türü (patlama) olmayan 16 kayıt da veri setinden temizlenmiştir. Şehir bilgisine göre; 5563 Elazığ, 2085 Malatya, 204 Adıyaman, 30 Şanlıurfa, 229 Diyarbakır, 86 Tunceli verisi bulunmaktadır. Şehir bilgisi olmayan 3 kayıt veri setinden silinmesi ve gürültülü verilerin veri setinden çıkarılması ile ön işlemler tamamlanmıştır.

Tez çalışmasında, Tablo 5.1’de gösterilen kayıtlar kullanılarak farklı hipotezler üretilmiş ve her bir hipoteze ait yeni veri setleri oluşturulmuştur. Toplamda 6 farklı veri seti elde edilmiş ve Yapay Sinir Ağı kullanılarak bu veri setlerine zaman serisi analizi yapılmıştır. Veri setleri sırasıyla ilerleyen bölümde anlatılmıştır.

5.1.1. Veri Seti 1

Bu veri setinde, Elazığ’da gerçekleşen depremlerin etkisinin diğer illere göre farklı etki oluşturabileceği düşünülmüştür. Bu etkiyi analiz edebilmek için ‘Şehir’ niteliğine göre sınıflandırılma yapılmıştır. Bu sınıflandırmaya göre; ‘Şehir’ niteliğinde Elâzığ olan kayıtlar 1, diğer kayıtlar 0 olarak belirlenmiştir. Veri Seti 1’e ait örnek kayıtlar Tablo 5.2’de verilmiştir.

Tablo 5.2. Veri Seti 1'e ait kayıt örnekleri

Tarih	Saat	Enlem	Boylam	Derinlik	Şiddet	Şehir
8.02.1930	05:20	38,52	39,40	100	5,3	1
9.01.1931	07:01	38,00	38,50	30	5,2	0
23.09.1940	19:30	38,96	39,32	80	5,2	0
18.08.1948	19:06	38,51	39,25	10	5,3	1
25.04.1949	23:09	38,27	38,99	80	5,5	0
...	...	...	...	...	...	...

Tablo 5.2’de ilk kayıt Elâzığ ilinde 8.02.1930 tarihinde 05:20 saatinde 100 km derinliğinde 5,3 şiddet ile gerçekleşen depremi belirtmektedir. İkinci kayıt Malatya ilinde 9.01.1931 tarihinde 07:01 saatinde 30 km derinliğinde ve 5,2 şiddet ile gerçekleşen depremi ifade etmektedir.

5.1.2. Veri Seti 2

Bu veri setinde, sıcaklık değişimlerinin deprem oluşumuna etkisi olup olmadığı analiz edilmek için oluşturulmuştur. Bu analiz için, gün içerisinde sıcaklık değerlerinin gece, sabah ve akşam saatlerinde farklı olduğu varsayılarak veriler saat verisine göre düzenlenmiştir. Saat Verisi; gece (0-7) saatleri 1, sabah saatleri (8-18) 2 ve akşam saatleri (19-24) 3 olarak sınıflandırılmıştır (Saat D. sütunu) ve Veri Seti 2 oluşturulmuştur. Veri Seti 2’ye ait örnek kayıtlar Tablo 5.3’te verilmiştir.

Tablo 5.3. Veri Seti 2’ye ait kayıt örnekleri

Tarih	Saat D.	Enlem	Boylam	Derinlik	Şiddet	Şehir
8.02.1930	1	38,52	39,40	100	5,3	1
9.01.1931	1	38,00	38,50	30	5,2	0
23.09.1940	3	38,96	39,32	80	5,2	0
18.08.1948	3	38,51	39,25	10	5,3	1
25.04.1949	3	38,27	38,99	80	5,5	0
...	...	...	...	...	...	...

Tablo 5.3’te ilk kayıt Elâzığ ilinde 8.02.1930 tarihinde gece saatlerinde 100 km derinliğinde 5,3 şiddet ile gerçekleşen depremi belirtmektedir. İkinci kayıt Malatya ilinde 9.01.1931 tarihinde gece saatlerinde 30 km derinliğinde ve 5,2 şiddet ile gerçekleşen depremi ifade etmektedir.

5.1.3. Veri Seti 3

Bu veri setinde, 24 Ocak 2020’de meydana gelen 6,8 büyüklüğündeki Elazığ depremi ve sonrasında meydana gelen artçı sarsıntılar eğitim sonuçlarını etkileyebileceğinden; 24 Ocak 2020 sonrasında gerçekleşen depremler Veri Seti 2’den çıkarılarak Veri Seti 3 oluşturulmuştur. Veri Seti


3'te 4100 kayıt bulunmaktadır. Veri Seti 3 tablosu, Veri Seti 2 tablosuna benzer olup sadece kayıt sayısı farklıdır.

5.1.4. Veri Seti 4

Bu veri setinde, Veri Seti 3'te bulunan kayıtlara ait 'Şehir' niteliği Veri Seti 4'e dâhil edilmemiştir. Veri Seti 4'e iki deprem arasındaki üç boyutlu mesafeler (Uzaklık sütunu) eklenmiştir. Veri Seti 4'e ait kayıt örnekleri Tablo 5.4'te verilmiştir. Şekil 5.2'de Aralık 2019- Ocak 2020 tarihleri arasında gerçekleşen 100 kayda ait, üç boyutlu deprem kayıtları örnek olarak verilmiştir. Şekilde kırmızı renk ile belirtilen kayıt, Elazığ'da 24 Ocak 2020 yılında gerçekleşen 6,8 şiddet ile gerçekleşen depremi göstermektedir. Sarı ile gösterilen simgeler şiddeti 5,0 üzeri olan depremleri ifade etmektedir.

Tablo 5.4. Veri Seti 4'e ait kayıt örnekleri

Tarih	Saat D.	Enlem	Boylam	Derinlik	Şiddet	Uzaklık
8.02.1930	1	38,52	39,40	100	5,3	0
9.01.1931	1	38,00	38,50	30	5,2	130,10
23.09.1940	3	38,96	39,32	80	5,2	133,26
18.08.1948	3	38,51	39,25	10	5,3	80,57
25.04.1949	3	38,27	38,99	80	5,5	78,54
...	...	...	...	...	...	...



Şekil 5.2. 100 deprem kaydına ait üç boyutlu uzaklık haritası

Tablo 5.4'te ilk kayıt 8.02.1930 tarihinde gece saatlerinde 38,52 enlemi, 39,40 boylamında 100 km derinliğinde 5,3 şiddet ile meydana gelen depremdir. Bu depremden önce kayıt bulunmadığı için uzaklık değeri 0 kabul edilmiştir. İkinci kayıt ise 9.01.1930 tarihinde gece

saatlerinde 38,00 enlemi, 38,50 boylamında 30 km derinliğinde 5,2 şiddet ile meydana gelen depremdir. İlk deprem ile aralarındaki üç boyutlu uzaklık 130,10 km olarak hesaplanmıştır.

5.1.5. Veri Seti 5

Bu veri setinde, deprem kayıtları incelendiğinde 1993 yılının öncesinde deprem kayıtlarının az olması ve geçmiş deprem verilerinin günümüz deprem verilerine etkisi az olabileceği varsayılarak Veri Seti 5 oluşturulmuştur. Bu veri setinde 25.03.1993-22.01.2020 tarihleri arasındaki 3,0 ve üzeri şiddetli gerçekleşen deprem kayıtları yer almaktadır. Veri Seti 5'te 4053 kayıt bulunmaktadır. Tablo 5.5'te Veri Seti 5'e ait kayıt örnekleri verilmiştir.

Tablo 5.5. Veri Seti 5'e ait kayıt örnekleri

Tarih	Saat D.	Enlem	Boylam	Derinlik	Şiddet	Uzaklık
25.03.1993	2	38,08	38,54	20	4,4	56,81
6.07.1993	3	37,89	39,31	47	4,8	91,14
29.07.1993	3	38,05	39,24	15	3,5	35,75
1.06.1994	2	38,37	39,52	29	4,3	44,01
1.07.1994	3	38,16	38,98	11	4,7	65,19
...	...	...	...	...	...	...

Tablo 5.5'te ikinci kayıt ise 6.07.1993 tarihinde akşam saatlerinde 37,89 enlemi, 39,31 boylamında 47 km derinliğinde 4,8 şiddeti ile meydana gelen depremdir. İlk deprem ile aralarındaki üç boyutlu uzaklık 91,14 km olarak hesaplanmıştır.

5.1.6. Veri Seti 6

Bu veri setinde, bir ayda gerçekleşen tüm depremlerin sayısı ve en büyük şiddetli deprem değeri verileri ile deprem tahmininin başarı sonuçlarını test etmek için Veri Seti 6 oluşturulmuştur. Bu veri setinde Ocak 1993-Temmuz 2020 tarihleri arasında gerçekleşen şiddeti 3,0 ve üzeri depremler aylık olarak sınıflandırılmıştır. Her aya ait toplam deprem sayısı (Sayı sütunu) ve en büyük şiddet değerli deprem verileri bulunmaktadır. Veri Seti 6'a ait örnek kayıtlar Tablo 5.6'da verilmiştir.

Tablo 5.6. Veri Seti 6'ya ait kayıt örnekleri

Yıl	Ay	Saat D.	Enlem	Boylam	Derinlik	En Büyük Şiddet	Sayı
2019	Kas	2	38,35	38,96	3,4	3,9	1
2019	Ara	1	38,35	38,98	4,5	5,1	5
2020	Oca	2	38,39	39,08	5,0	6,7	153
2020	Şub	3	38,27	38,77	5,2	5,1	41
2020	Mar	2	38,38	39,09	5,4	5,2	25
...	...	...	...	...	...	...	...

Tablo 5.6’da 2020 yılının Mart ayında gerçekleşen 25 tane deprem arasında en büyük deprem; 38,38 enlemi, 39,09 boylamında 5,4 km derinliğinde 5,2 şiddetinde gerçekleşen depremdir.

5.2. Deneysel Çalışmalar

Yapay sinir ağları, doğrusal olmayan problemlerin çözümünde geleneksel yöntemlere göre daha iyi sonuçlar elde etmeyi sağlamaktadır. Bu bölümde yapay sinir ağlarının örnekler üzerinde performansını resimler ve tablolar ile açıklanmaya çalışılmıştır.

Yapay sinir ağlarının doğrusal olmayan problemlerin çözümünde uygulama adımları bulunmaktadır. Bu uygulama adımları;

1. Veri toplama
2. Eğitim ve test setlerine ayırma
3. Bir ağ yapısı tanımlama
4. Bir öğrenme algoritması seçilmesi
5. Parametre ve değerlerin ayarlanması, ağırlıkların sıfırlanması
6. Verileri ağ girişlerine dönüştürülmesi
7. Eğitimin başlatılması, ağırlıkların belirlenmesi ve gözden geçirilmesi
8. Dur ve test
9. Uygulama: ağı yeni durumlarla kullanma

Bu çalışma kapsamında Doğu Anadolu fay hattı üzerinde Elâzığ ilini etkileyen depremler incelenmiştir. Bu kayıtlar depremin tarih, saat, enlem, boylam, derinlik (km), şiddet bilgilerini içermektedir. Kayıtların gürültülü verileri ve kayıt bilgileri düzenlenmiştir. Düzenlemeler sonucunda elde edilen veriler ile Veri Seti 1 oluşturulmuştur.

5.2.1. Veri Seti 1’e Ait Deneysel Çalışmalar


YSA eğitimi, Veri Seti 1 kullanılarak doğrusal olmayan problem türleri ile gerçekleştirilmiştir. Ham verilerdeki eğitim performansı, Veri Seti 1’e ait tüm problem türleri ve eğitim algoritmaları (sabit eğitim/doğrulama/testler ve gizli nöronlar(N)/gecikmeler(G)) ile test edilmiştir. Veri Seti 1’in YSA eğitim performansı sonuçları Tablo 5.7’de verilmiştir.

Tablo 5.7’de doğrusal olmayan 1., 2. ve 3. Problem Tipine göre yapılan Veri Seti 1 analizi sonuçları gösterilmiştir. Bu sonuçlara göre gizli nöron sayısının 10, gecikme sayısının 2 olduğu ve LMA, BRA, SCGA algoritmalarında en iyi sonuçların 2. Problem Tipi ile elde edildiği gözlemlenmektedir. Veri Seti 1’e ait YSA eğitiminde 2. Problem Tipi, LMA algoritması ile yapılan analiz sonuçları Şekil 5.3’te verilmiştir.


Tablo 5.7. Veri Seti 1'e ait YSA eğitim performansı

Problem Tipi	N/G	Algoritma	OKH	R
1	10/2	LMA	$2,97e^{-1}$	$6,98e^{-1}$
1	10/2	BRA	$2,89e^{-1}$	$6,98e^{-1}$
1	10/2	SCGA	$3,25e^{-1}$	$6,59e^{-1}$
2	10/2	LMA	$7,33e^{-0}$	$9,87e^{-1}$
2	10/2	BRA	$6,88e^{-0}$	$9,88e^{-1}$
2	10/2	SCGA	$8,31e^{-0}$	$9,86e^{-1}$
3	10/2	LMA	$3,06e^{-1}$	$6,85e^{-1}$
3	10/2	BRA	$2,89e^{-1}$	$6,97e^{-1}$
3	10/2	SCGA	$3,26e^{-1}$	$6,61e^{-1}$

Şekil 5.3'te Veri Seti 1'e ait performans sonuçları gözlemlenmektedir. Bu sonuçlara göre hedef veri ve çıkış verisi arasında oldukça büyük farklar bulunan değerler göze çarpmaktadır. 2200. etrafında gözlemlenen bir veride, hedef 5,4 şiddetinde olması beklenirken 3,0 şiddetinin altında bir çıktı vermiştir. Hedef ve çıktı doğrultusunda hata oranı 3,0 şiddetinden fazladır. Veri Seti 1'e ait YSA eğitim sonuçlarının hata histogramı Şekil 5.4'te verilmiştir.



Şekil 5.3. Veri Seti 1'e ait YSA eğitim sonuçları



Şekil 5.4. Veri Seti 1'e ait hata histogramı

Şekil 5.4'te verilen hata grafiğine göre, 8197 verinin tamamında hedef ve çıktı arasında hata bulunmaktadır. Bu verilerden yaklaşık 1000 tanesinin hata oranı 0,830 değerinden fazladır. Ayrıca eğitim, doğrulama ve test arasındaki hata payları da fazla olarak gözlemlenmektedir.

Veri Seti 1'e ait YSA eğitim sonuçları incelendiğinde istenilen başarı sağlanamamıştır. Bu sebeple sıcaklığın eğitim başarısına etkisini belirlemek için veri setindeki 'Saat' niteliğine göre sınıflandırma yapılmıştır. Bu sınıflandırma Bölüm 5.1.2'de ayrıntılı olarak anlatılmıştır ve örnek kayıtları tablo ile verilmiştir. Bölüm 5.2.2'de Veri Seti 2'ye ait deneysel çalışmalar yer almaktadır.

5.2.2. Veri Seti 2'ye Ait Deneysel Çalışmalar


YSA eğitimi, Veri Seti 2 kullanılarak verilerdeki eğitim performansı, tüm problem türleri ve eğitim algoritmaları (sabit eğitim/doğrulama/testler ve gizli nöronlar (N)/gecikmeler (G)) ile test edilmiştir. Veri Seti 2'nin YSA eğitim performansı sonuçları Tablo 5.8'de verilmiştir.

Tablo 5.8'de YSA eğitimleri sonucunda Problem Tipi 1 ve Problem Tipi 2 ile Veri Seti 2'de en yüksek performansı LMA ve BRA algoritmaları sağlamaktadır. Şekil 5.5'te Veri Seti 2'nin Problem Tipi 1'e göre LMA ile elde edilen YSA eğitim sonuçları verilmiştir.

Şekil 5.5'te verilen grafiğe göre yanlış tespit edilen birçok kayıt bulunmaktadır. Hata oranı -2,0 ile 3,0 değerleri arasında değişmektedir. Hemen hemen tüm kayıtlarda hata oranı bulunmaktadır. Hata oranlarının her kayıta ve yüksek olması nedeniyle eğitim performansı istenilen başarı seviyesini sağlayamamıştır.

Tablo 5.8. Veri Seti 2'ye ait YSA eğitim performansı

Problem Tipi	N/G	Algoritma	OKH	R
1	10/2	LMA	$3,04e^{-1}$	$6,98e^{-1}$
1	10/2	BRA	$2,98e^{-1}$	$6,93e^{-1}$
1	10/2	SCGA	$3,32e^{-1}$	$6,52e^{-1}$
2	10/2	LMA	$3,00e^{-1}$	$6,86e^{-1}$
2	10/2	BRA	$3,07e^{-1}$	$6,84e^{-1}$
2	10/2	SCGA	$3,15e^{-1}$	$6,76e^{-1}$
3	10/2	LMA	$3,07e^{-1}$	$6,89e^{-1}$
3	10/2	BRA	$2,96e^{-1}$	$6,95e^{-1}$
3	10/2	SCGA	$3,22e^{-1}$	$6,56e^{-1}$



Şekil 5.5. Veri Seti 2'ye ait YSA eğitim performansı

Veri Seti 2'nin eğitim grafikleri incelendiğinde 24 Ocak 2020 tarihinden sonra meydana gelen artçı sarsıntılar nedeniyle veri eğitiminin kesintiye uğradığı görülmektedir. Ayrıca Elazığ bölgesinde yüksek şiddetteki depremlere çok sık rastlanmadığı için bu kayıtlar düzensiz veri olarak algılanmaktadır. Bu verileri, veri setinden çıkarılarak test edilmesi ihtiyacı doğmuştur. Bu gereksinimleri Veri Seti 1'den 24 Ocak 2020 tarihinden sonrası çıkarılarak Veri Seti 3 oluşturulmuştur.

5.2.3. Veri Seti 3'e Ait Deneysel Çalışmalar

YSA eğitimi, tüm Problem Tipi ve eğitim algoritmaları (sabit eğitim/doğrulama/testler ve gizli nöronlar(N)/gecikmeler(G)) ile Veri Seti 3 eğitim performansı test edilmiştir. Bu eğitimler sonucunda Veri Seti 3'ün Veri Seti 2'ye göre performansında artış gözlemlenmiştir. Eğitim sonuçlarına göre deprem verileri için -2,0 ile 2,0 değerleri arasında hata oranı bulunmaktadır. Eğitim sonuçları ve başarımların performansı sonuçları Tablo 5.9'da gösterilmiştir.

Tablo 5.9. Veri Seti 3'e ait eğitimin sabit N/G değerine göre başarımların performansı

Problem Tipi	N/G	Algoritma	OKH	R
1	10/2	LMA	$1,72e^{-1}$	$7,45e^{-1}$
1	10/2	BRA	$1,76e^{-1}$	$7,31e^{-1}$
1	10/2	SCGA	$1,85e^{-1}$	$7,29e^{-1}$
2	10/2	LMA	$1,40e^{-1}$	$7,94e^{-1}$
2	10/2	BRA	$1,92e^{-1}$	$7,03e^{-1}$
2	10/2	SCGA	$1,91e^{-1}$	$7,05e^{-1}$
3	10/2	LMA	$1,90e^{-1}$	$7,19e^{-1}$
3	10/2	BRA	$1,93e^{-1}$	$7,09e^{-1}$
3	10/2	SCGA	$1,87e^{-1}$	$7,35e^{-1}$

Tablo 5.9'da görüldüğü gibi, tüm algoritmalarda ve Problem Tipi, OKH ve R ölçütlerine göre YSA eğitim performansı artmıştır. Ancak performans artışına rağmen tüm deprem verilerinde hata oranı vardır. Bu hata oranları $[-2, +2]$ değerleri aralığında gerçekleşmiştir. Tablo 5.9'da en iyi performans değeri R ölçütünde $7,03e^{-1}$ olduğu durumda elde edilmiş olup bu sonuca ait performans grafiği Şekil 5.6'da verilmiştir.

Şekil 5.6'da 500-1000 arasındaki verilerde hata oranları görülmektedir. Hemen hemen tüm verilerde tahmin performansında hatalar meydana gelmiştir. Bu hata oranları deprem verileri için kabul edilebilir değildir. Bu nedenle gizli nöronların değerleri ve gecikme verileri en doğru sonuçları verecek şekilde değiştirilmiştir (N:35 G:15, N:25 G:15, N:35 G:5, N:50 G:15) (sabit eğitim/doğrulama/ testler). Bu değerlerle Veri Seti 3'e ait performans sonuçları Tablo 5.10'da gösterilmektedir.




Şekil 5.6. Veri Seti 3'e ait en iyi performans grafiği

Tablo 5.10. Veri Seti 3'e ait değişken N/G değerlerine göre eğitim performansı

Problem Tipi	N / G	Algoritma	OKH	R
1	35/15	LMA	$1,30e^{-1}$	$8,24e^{-1}$
1	25/15	LMA	$1,38e^{-1}$	$8,00e^{-1}$
1	35/5	LMA	$1,26e^{-1}$	$8,20e^{-1}$
1	50/15	LMA	$2,30e^{-1}$	$6,50e^{-1}$
1	35/15	BRA	$2,36e^{-1}$	$9,96e^{-1}$
1	25/15	BRA	$1,22e^{-1}$	$9,83e^{-1}$
1	35/5	BRA	$9,00e^{-2}$	$8,78e^{-1}$
1	50/15	BRA	$8,18e^{-4}$	$9,98e^{-1}$
2	35/15	LMA	$1,72e^{-1}$	$7,45e^{-1}$
2	25/15	LMA	$1,76e^{-1}$	$7,31e^{-1}$
2	35/5	LMA	$1,85e^{-1}$	$7,29e^{-1}$
2	50/15	LMA	$1,40e^{-1}$	$7,94e^{-1}$
2	35/15	BRA	$1,49e^{-1}$	$7,81e^{-1}$
2	25/15	BRA	$1,91e^{-1}$	$7,05e^{-1}$
2	35/5	BRA	$1,90e^{-1}$	$7,19e^{-1}$
2	50/15	BRA	$1,93e^{-1}$	$7,09e^{-1}$

Tablo 5.10’da Veri Seti 3’e ait verilerin değişen N ve G değerleri ile daha yüksek performans elde edilmiştir. En yüksek performans, farklı N ve G değerleri ile Problem Tipi 1’de elde edilmiştir. Problem Tipi 1, N:25 G:15 ile Bayesian düzenleme algoritması ile elde edilen sonuçlar Şekil 5.7’de verilmiştir.



Şekil 5.7. Veri Seti 3’e ait değişken N/G ile en iyi eğitim sonuçları

Şekil 5.7’de görüldüğü gibi, Şekil 5.6’ya göre hata oranları azalsa da çok yüksek hatalar bulunmaktadır. Bu hata oranları az da olsa tüm verilerde görülmektedir. Deprem tahminindeki bu hataları azaltmak için Veri Seti 3’e depremler arasındaki üç boyutlu mesafeler eklenmiştir. Eklenen mesafe verileriyle Veri Seti 4 oluşturulmuştur.


5.2.4. Veri Seti 4’e Ait Deneysel Çalışmalar

Veri Seti 4 ve Problem Tipi, N ve G değerleri ile eğitim analizleri BRA ve LMA algoritmaları ile yapılmıştır. Eğitimlerin sonuçları Tablo 5.11’de verilmiştir.

Tablo 5.11’de Bayesian düzenleme algoritması ile eğitimin daha başarılı olduğu görülmektedir. En başarılı eğitim olarak OKH ve R ölçütlerinde iyi olan eğitim sonucu seçilmiştir. Bu sonuca göre Veri Seti 4’te Problem Tipi 1’e göre N:25 G:15 olan BRA algoritması ile R ölçütü $9,77e^{-1}$ olarak analiz edilmiştir. Bu analiz sonucunun grafiği Şekil 5.8’de verilmiştir.

Tablo 5.11. Veri Seti 4'e ait deęişken N/G deęerlerine g re eęitim performansı

Problem Tipi	N / G	Algoritma	OKH	R
1	35/15	LMA	$1,11e^{-1}$	$8,58e^{-1}$
1	25/15	LMA	$1,98e^{-1}$	$7,21e^{-1}$
1	35/5	LMA	$1,44e^{-1}$	$8,10e^{-1}$
1	50/15	LMA	$7,05e^{-2}$	$9,07e^{-1}$
1	35/15	BRA	$1,13e^{-3}$	$9,98e^{-1}$
1	25/15	BRA	$1,66e^{-2}$	$9,78e^{-1}$
1	35/5	BRA	$8,75e^{-2}$	$8,82e^{-1}$
1	50/15	BRA	$7,32e^{-1}$	$9,99e^{-1}$




Şekil 5.8. Veri Seti 4'e ait en iyi YSA eęitim sonuları grafięi

Şekil 5.8'e g re, k  k Őiddetdeki depremler, deprem verilerinin eęitiminde 0,0/0,1/0,2 fark ile tahmin edilmektedir. K  k Őiddetli depremlerin tahmininde yapay sinir aęı eęitim performansı y ksektir. Ancak b y k Őiddetli depremlerin tahminin de YSA analizinin hata oranı y ksektir. YSA'nın b y k depremler iin tahmin performansı d ř k olduęundan k  k Őiddetli depremleri ıkararak Veri Seti 5 oluřturulmuřtur.

5.2.5. Veri Seti 5'e Ait Deneysel Çalışmalar

YSA eğitimi, Veri Seti 5 kullanılarak verilerdeki eğitim performansı, tüm Problem Tipi ve eğitim algoritmaları ile analiz edilmiştir. Bu analizde gizli nöronların değerleri ve gecikme verilerine farklı değerler veriler verilmiştir (N:35 G:15, N:25 G:15, N:35 G:5, N:50 G:15) (sabit eğitim/doğrulama/ testler). Bu değerlerle Veri Seti 5'e ait YSA eğitimi performans sonuçları Tablo 5.12'de gösterilmektedir.

Tablo 5.12 incelendiğinde, Veri Seti 5'in başarı oranı Veri Seti 4'e göre daha düşüktür. Tüm problem tiplerinde yapılan eğitimlerde OKH'da çok yüksek hata oranları görülmektedir. Bu eğitimler sonucunda en kötü sonuç; Problem Tipi 2'de, nöron sayısı 35, gecikme sayısı 5, SCGA algoritmasında, OKH ölçütünün $148,91e^0$ olduğu R ölçütünün $8,30e^{-1}$ 'dir. En iyi sonuç ise; Problem Tipi 3'te, nöron sayısı 25, gecikme sayısı 15, BRA algoritmasında, OKH ölçütü $2,13e^{-2}$, R ölçütü $9,69e^{-1}$ 'dir. En iyi sonuca ait performans grafiği Şekil 5.9'da verilmiştir.




Şekil 5.9. Veri Seti 5'e ait en iyi performans grafiği

Tablo 5.12. Veri Seti 5'e ait deneysel sonuçlar

Problem Tipi	N / G	Algoritma	OKH	R
1	35/15	LMA	1,62e ⁻¹	7,65e ⁻¹
1	25/15	LMA	1,63e ⁻¹	7,63e ⁻¹
1	35/5	LMA	1,71e ⁻¹	7,19e ⁻¹
1	50/15	LMA	1,93e ⁻¹	7,46e ⁻¹
1	35/15	BRA	1,81e ⁻¹	6,98e ⁻¹
1	25/15	BRA	1,70e ⁻²	9,75e ⁻¹
1	35/5	BRA	1,95e ⁻¹	6,68e ⁻¹
1	50/15	BRA	1,75e ⁻¹	7,05e ⁻¹
1	35/15	SCGA	1,99e ⁻¹	6,66e ⁻¹
1	25/15	SCGA	1,92e ⁻¹	6,70e ⁻¹
1	35/5	SCGA	2,02e ⁻¹	6,48e ⁻¹
1	50/15	SCGA	1,72e ⁻¹	7,17e ⁻¹
2	35/15	LMA	135,76e ⁻⁰	8,44e ⁻¹
2	25/15	LMA	114,80e ⁻⁰	8,72e ⁻¹
2	35/5	LMA	114,17e ⁻⁰	8,73e ⁻¹
2	50/15	LMA	164,27e ⁻⁰	8,09e ⁻¹
2	35/15	BRA	1,60e ⁻¹	7,40e ⁻¹
2	25/15	BRA	1,90e ⁻¹	6,75e ⁻¹
2	35/5	BRA	1,88e ⁻¹	6,89e ⁻¹
2	50/15	BRA	1,87e ⁻¹	6,83e ⁻¹
2	35/15	SCGA	135,24e ⁻⁰	8,46e ⁻¹
2	25/15	SCGA	135,79e ⁻⁰	8,43e ⁻¹
2	35/5	SCGA	148,91e ⁻⁰	8,30e ⁻¹
2	50/15	SCGA	140,81e ⁻⁰	8,37e ⁻¹
3	35/15	LMA	1,52e ⁻¹	7,72e ⁻¹
3	25/15	LMA	1,75e ⁻¹	7,06e ⁻¹
3	35/5	LMA	1,58e ⁻¹	7,51e ⁻¹
3	50/15	LMA	1,66e ⁻¹	7,59e ⁻¹
3	35/15	BRA	1,20e ⁻¹	8,11e ⁻¹
3	25/15	BRA	2,13e ⁻²	9,69e ⁻¹
3	35/5	BRA	8,96e ⁻²	8,66e ⁻¹
3	50/15	BRA	1,59e ⁻¹	8,80e ⁻¹
3	35/15	SCGA	1,88e ⁻¹	6,78e ⁻¹
3	25/15	SCGA	1,83e ⁻¹	6,90e ⁻¹
3	35/5	SCGA	2,09e ⁻¹	6,36e ⁻¹
3	50/15	SCGA	2,72e ⁻¹	4,95e ⁻¹

Şekil 5.9'da verilen grafik incelendiğinde Veri Seti 4'e ait YSA eğitiminde elde edilen sonuçlar ile benzer oldukları görülmektedir. Küçük şiddetli depremlerin veri setinden çıkarılması daha iyi sonuçlar üretmezken daha kötü sonuçlar da üretmemiştir. Bununla beraber küçük şiddetli depremlerin tahmin hata oranlarında azalmalar oluşmuştur. Bu veri seti için oluşan hata oranlarını Şekil 5.10'da verilmiştir.



Şekil 5.10. Veri Seti 5'e ait hata histogramı

Şekil 5.10'da görüldüğü gibi, verilerin büyük bir çoğunluğu 0 değerine yakın hata oranlarıyla tahmin edilmiştir. Ancak kalan verilerin hata oranlarının $[-0,4000$ ve $+0,4000]$ aralığında olduğu durumlar bulunmaktadır. Bu durumlar, YSA eğitim sonuçlarının 5,0 ve üzeri şiddetli depremleri tahmininde yetersiz olduğunu göstermektedir.

Veri Seti 5'in YSA eğitiminden elde edilen sonuçlar ışığında yüksek şiddetli depremlerin tahmini için depremleri aylık veriler şeklinde gruplandırılarak Veri Seti 6 oluşturulmuştur. Veri Seti 6'ya ait deneysel sonuçlar Bölüm 5.2.6'da yer verilmiştir.

5.2.6. Veri Seti 6'ya Ait Deneysel Çalışmalar


YSA eğitimi, Veri Seti 6 kullanılarak verilerdeki eğitim performansı; aylık deprem verileri olarak gruplandırılmıştır. Bu gruplandırmada o ay gerçekleşen en yüksek şiddetli deprem, istenen çıktı olarak belirlenmiştir. Veriseti ve çıktı ile YSA eğitimi gerçekleştirilmiştir. YSA eğitimi tüm Problem Tipi ve eğitim algoritmaları kullanılarak analiz edilmiştir. Bu analizde gizli nöronların değerleri ve gecikme verilerine farklı değerler veriler verilmiştir (N:35 G:15, N:25 G:15, N:35 G:5, N:50 G:15) (sabit eğitim/doğrulama/ testler). Bu değerlerle Veri Seti 6'ya ait YSA eğitim performansının sonuçları Tablo 5.13'te gösterilmektedir.

Tablo 5.13. Veri Seti 6'ya ait deneysel sonuçlar

Problem Tipi	N / G	Algoritma	OKH	R
1	35/15	LMA	$4,27e^{-2}$	$9,92e^{-1}$
1	25/15	LMA	$2,61e^{-0}$	$6,23e^{-1}$
1	35/5	LMA	$4,55e^{-1}$	$9,21e^{-1}$
1	50/15	LMA	$1,83e^{-9}$	$9,99e^{-1}$
1	35/15	BRA	$2,14e^{-0}$	$4,89e^{-1}$
1	25/15	BRA	$2,20e^{-0}$	$4,36e^{-1}$
1	35/5	BRA	$2,29e^{-0}$	$4,90e^{-1}$
1	50/15	BRA	$2,29e^{-0}$	$4,67e^{-1}$
1	35/15	SCGA	$1,58e^{-0}$	$6,90e^{-1}$
1	25/15	SCGA	$1,12e^{-0}$	$7,79e^{-1}$
1	35/5	SCGA	$1,56e^{-0}$	$6,78e^{-1}$
1	50/15	SCGA	$1,40e^{-0}$	$7,48e^{-1}$
2	35/15	LMA	$5,06e^{-0}$	$8,71e^{-1}$
2	25/15	LMA	$112,63e^{-0}$	$7,77e^{-1}$
2	35/5	LMA	$96,55e^{-0}$	$8,11e^{-1}$
2	50/15	LMA	$20,51e^{-0}$	$9,63e^{-1}$
2	35/15	BRA	$1,09e^{-3}$	$9,99e^{-1}$
2	25/15	BRA	$5,42e^{-3}$	$9,99e^{-1}$
2	35/5	BRA	$3,87e^{-0}$	$9,92e^{-1}$
2	50/15	BRA	$1,49e^{-4}$	$9,99e^{-1}$
2	35/15	SCGA	$88,19e^{-0}$	$8,29e^{-1}$
2	25/15	SCGA	$91,60e^{-0}$	$8,18e^{-1}$
2	35/5	SCGA	$146,83e^{-0}$	$7,04e^{-1}$
2	50/15	SCGA	$44,85e^{-0}$	$9,17e^{-1}$
3	35/15	LMA	$2,88e^{-1}$	$9,64e^{-1}$
3	25/15	LMA	$1,18e^{-1}$	$9,85e^{-1}$
3	35/5	LMA	$8,95e^{-1}$	$8,60e^{-1}$
3	50/15	LMA	$7,05e^{-3}$	$9,99e^{-1}$
3	35/15	BRA	$2,38e^{-0}$	$4,50e^{-1}$
3	25/15	BRA	$2,15e^{-0}$	$4,96e^{-1}$
3	35/5	BRA	$2,45e^{-0}$	$4,25e^{-1}$
3	50/15	BRA	$2,03e^{-0}$	$5,17e^{-1}$
3	35/15	SCGA	$1,10e^{-0}$	$7,57e^{-1}$
3	25/15	SCGA	$2,13e^{-0}$	$5,12e^{-1}$
3	35/5	SCGA	$1,82e^{-0}$	$6,34e^{-1}$
3	50/15	SCGA	$2,60e^{-0}$	$5,35e^{-1}$

Tablo 5.13 incelendiğinde, Veri Seti 6'ya ait YSA eğitim sonuçlarının başarı oranının düşük olduğu görülmüştür. Veri Seti 5'te olduğu gibi tüm problem tiplerinde yapılan eğitimlerde OKH'da çok yüksek hata oranları görülmektedir. Ayrıca R değerlerinde de düşüklüklerin olduğu gözlemlenmektedir. Bu hata oranları doğrultusunda YSA eğitim sonuçlarında en kötü sonuç; Problem Tipi 2'de, nöron sayısı 35, gecikme sayısı 5, SCGA algoritmasında, OKH ölçütünde $146,83e^{-0}$ olduğu R ölçütünde $7,04e^{-1}$ olduğu değerdir. En iyi sonuç ise; Problem Tipi 3'te, nöron

sayısı 25, gecikme sayısı 15, LMA algoritmasında, OKH ölçütü $1,18e^{-1}$, R ölçütü $9,85e^{-1}$ olduğu durumdur. En iyi sonuca ait performans grafiği Şekil 5.11’de verilmiştir.




Şekil 5.11. Veri Seti 6’ya ait performans grafiği

Şekil 5.11’de Veri Seti 6’da oluşturulan aylık gruplandırılmış deprem verilerinin YSA eğitim sonuçları gözlemlenmektedir. Bu sonuçlar doğrultusunda hata oranların diğer veri setlerine oranla yükseldiği belirlenmiştir. Grafikte hata oranlarının, $[-5, +5]$ değer aralığında değiştiği görülmektedir. Tüm verilere ait hata oranlarının grafiği Şekil 5.12’de verilmiştir.

Şekil 5.12’de Veri Seti 6’ya ait hata histogramını göstermektedir. Bu histogramda tüm verilerde en az hata oranı 0,0312 olarak belirlenmiştir. Bu verilerden yaklaşık 200 tanesi en az hata oranına sahipken, yaklaşık 50 veri 0,409 hata oranına sahiptir. Kalan verilerin hata oranları ise 1 ile 5 değerleri arasında değişiklik göstermektedir.

Veri Seti 6’da gerçekleştirilen analizler sonuçları grafiklerle değerlendirilmiştir. Bu değerlendirme sonucunda deprem verilerinde aylık gruplandırmanın tahmin başarısını düşürdüğü belirlenmiştir. YSA eğitimlerinin tahmin başarısının düşük olma sebebi, tüm aylarda deprem olmamasından kaynaklandığı düşünülmektedir.



Şekil 5.12. Veri Seti 6'ya ait hata histogramı

Tüm veri setleri sonuçlarını değerlendirildiğinde, Veri Seti 1 ile gerçekleştirilen YSA analizleri sonucunda tüm verilerde hata oranları bulunmuştur. Bu hata oranları çok yüksek seviyelere ulaşmıştır. Bu hatalar içerisinde, küçük şiddetli depremler de dahi büyük hatalar bulunmuştur. Bu hataların giderilmesi için Veri Seti 2 oluşturulmuştur. Veri Seti 2'ya ait YSA eğitim sonucunun performansı değerlendirilmiştir. Bu sonuçlarda en yüksek başarı performansı, Problem Tipi 1 ve Problem Tipi 2, Levenberg ve Bayesian algoritmalarında elde edildiği görülmüştür. Bu sonuçlarına rağmen küçük şiddetli depremlerde bile hatalar oluşturduğu tespit edilmiştir. Bu hataların yüksek olması nedeniyle 24 Ocak 2020 Elâzığ depreminden sonra veri setinden çıkarılmış ve Veri Seti 3 oluşturulmuştur. Veri Seti 3'e gizli nöronlar ve gecikme değerlerinin eklenmesi ile başarı oranı artmış ancak yüksek şiddetli depremlerde saptanan hata oranları nedeniyle yeterli bulunmamıştır. Veri Seti 3 depremlerinin verilerine iki deprem arasındaki üç boyutlu uzaklık bilgisi eklenerek, Veri Seti 4 oluşturulmuştur. Veri Seti 4'teki YSA eğitimlerinin küçük depremlerde hata oranlarının çok düşük olması sebebiyle başarılı olduğu, ancak büyük depremlerde karşılaşılan hata oranlarının yüksek olması sebebiyle başarılı olmadığı gözlemlenmiştir. Büyük şiddetli depremlerin tahmininde başarı oranını artırmak için, Veri Seti 4'ten 3,0 şiddetinin altında gerçekleşen tüm depremler çıkarılarak Veri Seti 5 oluşturulmuştur. Veri Seti 5'in YSA eğitim analizleri, büyük şiddetli depremlerin tahmininde başarı oranını yükseltmeyi

sağlayamamıştır. Büyük şiddetli depremlerin tahmin başarımını artırmak için Veri Seti 6 oluşturulmuştur. Bu veri setinde aylık depremler olarak gruplandırılmış ve o ay içerisinde gerçekleşen en yüksek şiddetli deprem çıktı olarak belirlenmiştir. Yapılan YSA eğitimi sonuçlarında hata oranlarının 4 değerinin üzerine çıktığı durumlar oluşmuştur. Veri Seti 6'nın eğitimi kötü sonuçlar vermiştir ve deprem tahmininde yetersiz kalmıştır.

Tüm veri setlerine uygulanan eğitimler sonucunda elde edilen en iyi sonuçlar Tablo 5.14'te verilmiştir.

Tablo 5.14. Veri setlerinin en iyi deneysel sonuçları

Veri Seti	Problem Tipi	N / G	Algoritma	OKH	R
1	2	10/2	BRA	$6,88e^{-1}$	$9,88e^{-1}$
2	1	10/2	BRA	$2,98e^{-1}$	$6,93e^{-1}$
3	1	35/15	BRA	$2,36e^{-1}$	$9,96e^{-1}$
4	1	35/15	LMA	$1,11e^{-1}$	$8,58e^{-1}$
5	3	25/15	BRA	$2,13e^{-2}$	$9,69e^{-1}$
6	3	25/15	LMA	$1,18e^{-1}$	$9,85e^{-1}$

Tablo 5.14'te görüldüğü gibi Veri Seti 1'de 'Şehir' niteliğine göre Problem Tipi 2 ve BRA ile gerçekleştirilen YSA eğitiminde OKH değerlerine göre başarı performansı düşük bulunmuştur. 'Şehir' niteliği YSA eğitimlerinde yetersiz kalmıştır. Veri Seti 2'de 'Saat D.' niteliğine göre Problem Tipi 1 ve BRA ile gerçekleştirilen YSA eğitiminde OKH ve R ölçütlerine göre başarı performansı yetersiz bulunmuştur. 'Saat D.' niteliğinin depreme etkisi olmadığı belirlenmiştir. Veri Seti 3'te kayıt düzenlemesi, gizli nöron sayısı ve gecikme değeri eklenerek gerçekleştirilen YSA eğitiminde, Problem Tipi 1 ve N:35 G:15 değeri ile BRA ile başarımlar artırılmıştır. Veri Seti 4'te 'Uzaklık' niteliği ile Problem Tipi 1 ve N:35 G:15 değeri ile LMA ile OKH ölçütüne göre başarımın yükseldiği belirlenmiştir. Veri Seti 5'te 1993- 2020 yıllarında 3,0 üzeri depremlerde en iyi başarımlar Problem Tipi 3'te elde edilmiştir. OKH ölçütüne göre başarı değeri, Veri Seti 4'e göre azalırken R ölçütüne göre başarı değerine göre artış göstermiştir. Veri Seti 6'da aylık verilere göre sınıflandırmada en iyi başarımlar LMA'ya ait YSA eğitiminde Problem Tipi 3'te elde edilmiştir.

6. SONUÇLAR VE TARTIŞMA

Son yıllarda, artan teknolojiler ve dijital kayıtlar, bilgi elde etme ihtiyacını artırmıştır. Bu ihtiyaç üzerine verilerden bilgi elde etmeyi sağlayacak yöntemler geliştirilmiştir. Bu yöntemlerden bir tanesi de zaman serisi analizidir. Zaman serisi analizi, zamana bağlı verileri analiz ederek gelecek veriler hakkında tahmin yapmayı sağlamaktadır. Zaman serisi analizinde birçok tahmin yöntemi bulunmaktadır. Bu tahmin yöntemleri, doğrusal ve doğrusal olmayan yöntemler olarak ayrılmaktadır. Doğrusal yöntemlerde, OR, HO, Box-jenkins ve Üstel düzleştirme zaman serisi yöntemleri hakkında bilgi verilmiştir. Doğrusal yöntemlerin çözemediği, doğrusal olmayan verileri modellemek ve analiz etmek için doğrusal olmayan yöntemler geliştirilmiştir. Bu yöntemlerden biri de zaman serilerinde yapay sinir ağlarıdır.

YSA'ların doğrusal olmayan verilerin eğitiminde kullanım alanları her geçen gün artmaktadır. Bu nedenle bu tez çalışmasında, doğrusal olmayan deprem verileri YSA ile eğitilerek tahmin performansı test edilmiştir. Deprem verileri için, Elazığ ilini etkileyen Doğu Anadolu fay hattına ilişkin deprem verileri, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü'nden elde edilmiştir. Deprem verilerindeki eksik veriler silinerek düzenlemeler yapılmıştır. Yapılan düzenlemeler sonucunda elde edilen veri setlerine (Veri Seti 1, Veri Seti 2, Veri Seti 3, Veri Seti 4, Veri Seti 5 ve Veri Seti 6) dönüştürülmüştür. Bu veri setleri, YSA Zaman Serisi yöntemi ile eğitilmiştir. Eğitim aşamasında YSA'ya ait parametrelerin belirlenmesine yönelik net bir kural olmadığı için eğitimler farklı parametrelerle (Problem Tipi, Nöronlar, Gecikmeler ve eğitim algoritmaları için) birçok kez test edilmiştir. Belirlenen değerler ve veri setleri üzerinde yapılan eğitimler sonucunda elde edilen tüm sonuçlar değerlendirilmiştir.

Yapılan YSA eğitimlerinin deneysel sonuçları doğrultusunda 'Şehir' ve 'Saat D.' Niteliğinin deprem tahmininde etkisinin olmadığı belirlenmiştir ve 'uzaklık' niteliğinin olumlu bir etkisinin olduğu belirlenmiştir. Tüm YSA eğitim sonuçları değerlendirildiğinde, küçük şiddetli depremlerin tahmininde küçük hata oranlarıyla başarılı olduğu gözlemlenmiştir. Ancak tüm veri setlerinde yapılan yapay sinir ağı eğitimlerine rağmen, büyük şiddetli deprem verilerinin az olması ve depremlere dair matematiksel modeli olmamasından dolayı, büyük şiddetli depremlerin tahmininde yetersiz kaldığı belirlenmiştir.

ÖNERİLER

Deprem verileriyle yapılan YSA eğitimleri sonucunda, büyük şiddete sahip depremlerin tahmin edilmesinde başarımın yetersiz olduğu tespit edilmiştir. Bunun sebebi olarak büyük şiddete sahip deprem verilerinin yetersiz olduğu söylenebilir. Yeterli miktarda veri olması durumunda deprem tahminine yönelik çalışmaların başarı oranlarının artması beklenmektedir. Ayrıca veri olarak; fay kayma hızları ve miktarları, radon gazı ölçümleri, zemin etki katsayısı, faya yakınlık ve aktiflik oranları da veri setine eklenebilir. Tüm fay üzerinde gerçekleşen deprem verileri ile çalışmak başarımı etkileyebilecektir.

Bölgesel çalışmalarda deprem tahmin başarı oranını iyileştirmek için fay hattı boyunca gerçekleşen tüm deprem verileri ile yapılan çalışmalar daha başarılı sonuçlar sağlayabilir. Dünya’da gerçekleşen tüm depremlerin birbirini etkilemesi olması sebebiyle kıtasal hareketlerin ve tüm fay hatlarının hareket durumları göz önüne alınarak oluşturulacak sistemlerin daha başarılı sonuçlar oluşturulabileceği düşünülmektedir.

KAYNAKLAR

- [1] E. T. A. Güven ve Y. Y. Ayvaz, “Türkiye’de Enflasyon ve İşsizlik Arasındaki İlişki: Zaman Serisi Analizi”, Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi, Cilt: 13, sayı: 1, 2016
- [2] M. Akıncı, G. Erkal ve Ö. Yılmaz, “Ekonomik Özgürlükler ve Yoksulluk İlişkisi: Türkiye için bir Zaman Serisi Analizi”, Hak İş Uluslararası Emek ve Toplum Dergisi, cilt: 4, sayı: 8, sayfa: 144-165, 2015
- [3] S. Narayanakumar and K. Raja. “A bp artificial neural network model for earthquake magnitude prediction in himalayas, india”, Circuits and Systems, 7(11):3456, 2016.
- [4] J. Sheng, D. Mu, H. Zhang ve H. Lv, “Seismotectonics Considered Artificial Neural Network Earthquake Prediction in Northeast Seismic Region of China”, The Open Civil Engineering Journal, 2015, 9, s. 522-528.
- [5] C. Li and X. Liu. “An improved pso-bp neural network and its application to earthquake prediction”, In Control and Decision Conference (CCDC), Chinese, 2016, s. 3434–3438.
- [6] J. Mahmoudi, M. A. Arjomand, M. Rezaei, and M. H. Mohammadi, “Predicting the earthquake magnitude using the multilayer perceptron neural network with two hidden layers”, Civil Engineering Journal, 2016, 2(1):1–12.
- [7] E. Çelik, M. Atalay ve H. Bayer, “Yapay Sinir Ağları ve Destek Vektör Makineleri ile Deprem Tahmininde Sismik Darbelerin Kullanılması”, IEEE 22nd Signal Processing And Communications Applications Conference, 23-25 Nisan 2014, Trabzon, s. 730-733.
- [8] M. Kamışhoğlu ve F. Külahcı, “Osmaniye Bölgesinden Alınan ^{222}Rn Gazı Ölçümlerinin Zaman Serisi Analizi”, 23. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU), IEEE, 2015, s. 1138-1141.
- [9] Ş. Balkasoğlu ve Ö. Yıldırım, “Derin UKVH Ağ Modeli Kullanarak Bölgesel Deprem Tahmini”, Akıllı Sistemler ve Uygulamalarda Yenilikler Konferansı (ASYU) , IEEE, 2018. s. 1-5.
- [10] A. Ulutaş, R. Çakmak ve İ. H. Altaş, "Zaman Serilerinin Benzerlik Analizine Dayalı Yapay Sinir Ağı ile Saatlik Güneş Işınlaması Tahmini", Akıllı Sistemler ve Uygulamalarda Yenilikler Konferansı (ASYU) , s. 1-6, 2018.
- [11] A. Doğan ve E. Demir, "Yapısal Tekrarlayan Sinir Ağları ile Türkiye’de Deprem Tahmini", 28. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU) , 2020, s. 1-4.
- [12] S. Özden ve A. Öztürk, “Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini”, Bilişim Teknolojileri Dergisi, Cilt: 11, Sayı: 3, Temmuz 2018, s. 225.
- [13] H. Çam ve O. Duman , “Yapay Sinir Ağı Yöntemiyle Deprem Tahmini: Türkiye Batı Anadolu Fay Hattı Uygulaması”, Gümüşhane Üniversitesi, Sosyal Bilimler Enstitüsü, Cilt: 7, Sayı: 17, 2016.
- [14] K. Kumaş, M. Ayan, A. Ö. Akyüz ve A. Güngör, “Antalya İli Meteorolojik Verileri Yardımıyla Hava Sıcaklığının Yapay Sinir Ağları Metodu ile Tahmini”, Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2020, 10(1), 146-154.

- [15] N. S. Can ve A. Ş. Şahin, “Yapay sinir ağları metodu ile günlük çiğ noktası sıcaklığı tahmini”, Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi (GÜFBED), 2021, 11 (4): s. 1154-1163.
- [16] M. Taşyürek ve M. Çelik, “Akıllı Durak Sistemindeki Araç Seyahat Sürelerinin Birleşik Yapay Sinir Ağları Kullanarak Tahmini”, Avrupa Bilim ve Teknoloji Dergisi, 2020, s. 72-79.
- [17] İ. Kırbaş, “İstatistiksel Metotlar ve Yapay Sinir Ağları Kullanılarak Kısa Dönem Çok Adımlı Rüzgâr Hızı Tahmini”, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2018, 22(1), s. 24-38.
- [18] E. Sütçü, “Kaynaklı İmalat Operasyon Sürelerinin Matlab Yapay Sinir Ağları ile Tahmin Edilmesi”, Gazi Mühendislik Bilimleri Dergisi (GMBD) 4, 2018: s. 16-24.
- [19] S. Oğhan, “Zaman Serisi Analiz Yöntemlerinin Karşılaştırılması”, Yüksek Lisans Tezi, 15 Şubat 2010, İzmir, s. 1-7.
- [20] H. Y. Bozkurt, "Zaman Serisi Analizi", Genişletilmiş 2. Baskı Kitabı, s. 6-26.
- [21] A.W. Van der Vaart, “Time Series”, VU Üniversitesi, Amsterdam, Ders Notu, 1995-2010, s. 2-21.
- [22] A. Yılmaz, “Zaman Serisi Analizi (Birim Kökler ve Kointegrasyon)” kitabı, 2010, s. 47-119.
- [23] S. E. Şeker, “Zaman Serileri Analizi (Time Series Analysis)”, Yönetim Bilişim Sistemleri Ansiklopedi, 2015, 2:4, s. 23-31.
- [24] U. Fırat, S.N. Engin, M. Saraçlar ve A.B. Ertuzun, “Wind Speed Forecastings Based on Second Order Blind Identification and Autoregressive Model”, Ninth International Conference on Machine Learning and Applications, 2010, s. 686-691.
- [25] O. Kaynar ve S. Taştan, “Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA modelinin Karşılaştırılması”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 2009, 33: s. 161-172.
- [26] K. Yunus, T. Thiringer ve P. Chen, “ARIMA based Frequency- Decomposed Modeling of Wind Speed Time Series”, IEEE Transactions on Power Systems, 2015, 31(4): 2546-2556.
- [27] T. Çağlar, “Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması”, Yüksek Lisans Tezi, Kasım 2007, s. 39-45.
- [28] M.F. Keskenler ve E.F. Keskenler, “Geçmişten günümüze yapay sinir ağları ve tarihçesi”, Rize, Takvim-i Vekayi, ISSN.2148-0087, Cilt 5, No: 2., s. 8-18., 2017.
- [29] E. Öztemel, “Yapay Sinir Ağları”, Papatya Yayıncılık, İstanbul, 2013.
- [30] T.Z. Khalaf, “Hibrid PSO-ANN VE PSO Modellerinin İnşaat Projelerinin Maliyet ve Sürelerinin Tahminine Dayalı Yaklaşımı”, Yüksek Lisans Tezi, Kastamonu Üniversitesi, 2020.
- [31] A. Lasfer, “Performance analysis of artificial neural networks in forecasting financial time series”, Yüksek Lisans Tezi, American University of Sharjah, 2013.
- [32] F.S. Çakır, “Yapay Sinir Ağları: MATLAB kodları ve MATLAB Toolbox Çözümleri”, Nobel Akademik Yayıncılık, 2019.
- [33] URL <https://www.erbakan.edu.tr/storage/files/department/insaatmuhendisligi/editor/DersSayfaları/depremMuhGir/deprem%20hareketi.pdf> 15.09.21 erişilmiştir.
- [34] E. Canbay, U. Ersoy, G. Özcebe, H. Sucuoğlu ve S.T. Wasti, “Binalar için Deprem Mühendisliği Temel İlkeler”, Bizim Büro Basımevi, Ankara, 2008.
- [35] B. Çokcan ve S. B. Çokcan, “Deprem ile Yaşamak”, Dünya yayıncılık, 2003.

- [36] URL- https://www.usgs.gov/natural-hazards/earthquake-hazards/science/science-earthquakes?qt-science_center_objects=0#qt-science_center_objects, 06.09.2021 erişilmiştir.
- [37] K. Rubin, “Volcanoes ve Eartquekes”, Weldon Owen Pty Ltd, 2007.
- [38] Y. Fahyan, “Türk Bina Deprem Yönetmeliği(TBDY, 2017) Tabanlı Tasarım Spektrumları”, Seminer, TMMOB, İzmir, 2017.
- [39] Y. N. Aydın, “Zaman ve Magnitud Kestirilebilir Model ve Türkiye’de Uzun Dönem Deprem Kestirimi”, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Trabzon, 2016.
- [40] URL <https://www.e-sehir.com/turkiye-haritasi/elazig-deprem-fay-hatti-riskharitasi.html>, 07.09.21 erişilmiştir.
- [41] M. Palutoğlu ve E. Tanyolu, “Elazığ İl Merkezi Yerleşim Alanlarının Depremselliği”, Fırat Üniv. Fen ve Müh. Bil. Dergisi, 18(4), 535-546, Elazığ, 2006.



ÖZGEÇMİŞ

Sultan LÖK

[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]

AKADEMİK FAALİYETLER

Makaleler:

S. Lök ve M. Karabatak, “Earthquake Prediction By Using Time Series Analysis”, 9th International Symposium on Digital Forensics and Security (ISDFS), IEEE, 2021.

Bildiriler:

S. Lök, S. Karabatak ve M. Karabatak, “Yazılım Mühendisliği Temel Derslerinde Öğrenci Başarı Durumlarının Değerlendirilmesi: Fırat Üniversitesi Örneği ”, 1.Uluslararası Battalgazi Multi Disipliner Çalışmalar Kongresi, Tam Metin Kitabı cilt 2, s. 1288, Malatya, 2018. 1.