



GİRESUN
ÜNİVERSİTESİ



Yüksek Lisans Tezi

FEN BİLİMLERİ ENSTİTÜSÜ

ZAMAN SERİSİ ÖNGÖRÜSÜNDE DENDRİT YAPAY SİNİR
AĞLARI İÇİN PARÇACIK SÜRÜ OPTİMİZASYONUNA
DAYALI DAYANIKLI ÖĞRENME ALGORİTMASI

İSTATİSTİK
ANABİLİM DALI

Yüksek Lisans Tezi

Ayşe YILMAZ
172114020

2020

GİRESUN

Ayşe YILMAZ

2020

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ZAMAN SERİSİ ÖNGÖRÜSÜNDE DENDRİT YAPAY SİNİR
AĞLARI İÇİN PARÇACIK SÜRÜ OPTİMİZASYONUNA
DAYALI DAYANIKLI ÖĞRENME ALGORİTMASI**

YÜKSEK LİSANS TEZİ

Öğrencinin Adı SOYADI : Ayşe YILMAZ
ORCID : 0000-0002-8149-6962
Tezin Enstitüye Verildiği Tarih : 5 Ocak 2021

Enstitü Anabilim Dalı : İstatistik Anabilim Dalı

Tez Danışmanı : Prof. Dr. Ufuk YOLCU
ORCID : 0000-0002-0172-3353

Ocak 2021

GİRESUN

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ZAMAN SERİSİ ÖNGÖRÜSÜNDE DENDRİT YAPAY SİNİR
AĞLARI İÇİN PARÇACIK SÜRÜ OPTİMİZASYONUNA
DAYALI DAYANIKLI ÖĞRENME ALGORİTMASI**

YÜKSEK LİSANS TEZİ

Ayşe YILMAZ

Enstitü Anabilim Dalı

: İstatistik Anabilim Dalı

Bu tez 22/12/2020 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

**Doç. Dr. Cem KOÇAK
Jüri Başkanı**

**Doç. Dr. Eren BAŞ
Üye**

**Prof. Dr. Ufuk YOLCU
Üye**

**Doç. Dr. Bahadır KOZ
Enstitü Müdürü**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Ayşe YILMAZ

22/12/2020

ÖNSÖZ

Hazırlamış olduğum “Zaman Serisi Öngörüsünde Dendrit Nöron Model İçin Parçacık Sürü Optimizasyonuna Dayalı Dayanıklı Yapay Sinir Ağları” başlıklı yüksek lisans tezimin teorik ve uygulama aşamalarının hazırlanmasında ve tamamlanmasında yardımlarını esirgemeyen danışmanım Prof. Dr. Ufuk Yolcu’ya içtenlikle teşekkür ederim.

Öğrenim hayatımın ilk gününden bugüne kadar destekleri ve sevgileri ile hep yanımda olan Aileme teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖNSÖZ.....	i
ŞEKİLLER LİSTESİ.....	iv
TABLolar LİSTESİ	vii
ÖZET.....	viii
SUMMARY	ix
BÖLÜM 1. GİRİŞ	1
BÖLÜM 2. YAPAY SİNİR AĞLARI.....	7
BÖLÜM 3. DENDRİT NÖRON MODEL YAPAY SİNİR AĞLARI	17
3.1. Sinaptik Tabaka	19
3.2. Dendrit Tabakası.....	19
3.3.Membrane Tabaka	20
3.4.Soma Tabakası	20
BÖLÜM 4. PARÇACIK SÜRÜ OPTİMİZASYONU	22
BÖLÜM 5. ÖNERİLEN YÖNTEM	25
BÖLÜM 6. UYGULAMA	31
6.1. Avusturalya Bira Tüketim Zaman Serisi Çözümlemesi.....	31
6.1.1. Çözümleme Orijinal AUST.....	33
6.1.2. Çözümleme Kirletilmiş AUST – 5 Kat – Tek Aykırı Gözlem.....	35
6.1.3. Çözümleme Kirletilmiş AUST – 5 Kat – İki Aykırı Gözlem	38
6.1.4. Çözümleme Kirletilmiş AUST – 5 Kat – Üç Aykırı Gözlem.....	40
6.1.5. Çözümleme Kirletilmiş AUST – 10 Kat – Tek Aykırı Gözlem.....	42
6.1.6. Çözümleme Kirletilmiş AUST – 10 Kat – İki Aykırı Gözlem	44
6.1.7. Çözümleme Kirletilmiş AUST – 10 Kat – Üç Aykırı Gözlem.....	46
6.2. FTSE Zaman Serisi Çözümlemesi.....	48
BÖLÜM 7. SONUÇLAR VE TARTIŞMA.....	77
KAYNAKÇA	80
ÖZGEÇMİŞ	84

SİMGELER VE KISALTMALAR LİSTESİ

AUST	: Avusturalya Bira Tüketim
ÇKA	: Çok Katmanlı Algılayıcı
ÇK-YSA	: Çok Katmanlı Yapay Sinir Ağı
ÇK-YSA PSO	: Parçacık Sürü Optimizasyonu ile Eğitilen Çok Katmanlı Yapay Sinir Ağı
ÇNM	: Çarpımsal Nöron Model
DGA	: Diferansiyel Gelişim Algoritması
DNM-YSA	: Dendritik Nöron Model Yapay Sinir Ağı
E-YSA	: Elman Yapay Sinir Ağı
FTSE	: Londra Borsası Endeks
GA	: Genetik Algoritma
GBEST	: Global En İyi Çözüm
GMNM	: Genelleştirilmiş Ortalama Nöron Model
G-MNM	: Geometrik Ortalama Nöron Model
HKOK	: Hata Kareler Ortalaması Karekök
L-NL-YSA	: Lineer ve Lineer Olmayan Yapay Sinir Ağı
MDP-YSA	: Medyan ve Çarpımsal Nöron Modele Dayalı Yapay Sinir Ağı
MD-YSA	: Medyan Nöron Modele Dayalı Yapay Sinir Ağı
OMYH	: Ortalama Mutlak Yüzdelik Hata
PBEST	: Parçacığın En İyi Uygunluk Değeri
PSO	: Parçacık Sürü Optimizasyonu
PS-YSA	: Pi-Sigma Yapay Sinir Ağı
RT-YSA	: Radyal Temelli Yapay Sinir Ağı
SARIMA	: Mevsimsel Otoregresif Hareketli Ortalamalar
TÇNM	: Tek Çarpımsal Nöron Model
TÇ-YSA-PSO	: Tek Çarpımsal Sinir Hücresine Sahip Yapay Sinir Ağı
WMES	: Winters'ın Çarpımsal Üstel Düzleştirme
YSA	: Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

Şekil 2.1: Sinir Hücresi Genel Yapısı.....	7
Şekil 2.2: McCulloch Pitts Nöron Model.....	8
Şekil 2.3. Rosenbalt'ın basit algılayıcısı.....	9
Şekil 2.4. ADALINE yapay sinir ağı.....	9
Şekil 2.5. Çok Katmanlı Algılayıcı Mimari Yapısı	11
Şekil 2.6. Mc-Culloch ve Pitts nöron modeli	14
Şekil 2.7. Çarpımsal nöron model.....	15
Şekil 2.8. Medyan nöron model	15
Şekil 2.9. Budanmış ortalama nöron model	16
Şekil 3.1: DNM Yapısı	21
Şekil 5.1. Bir parçacığın yapısı	27
Şekil 6.1. AUST zaman serisi.....	32
Şekil 6.2. Orijinal AUST zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri .	34
Şekil 6.3. Orijinal AUST zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	35
Şekil 6.4. Kirlenilmiş AUST (5 Kat – Tek Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	37
Şekil 6.5. Kirlenilmiş AUST (5 Kat – Tek Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	37
Şekil 6.6. Kirlenilmiş AUST (5 Kat – İki Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	39
Şekil 6.7. Kirlenilmiş AUST (5 Kat – İki Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	39
Şekil 6.8. Kirlenilmiş AUST (5 Kat – Üç Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	41
Şekil 6.9. Kirlenilmiş AUST (5 Kat – Üç Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	41

Şekil 6.10. Kirlenilmiş AUST (10 Kat – Tek Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	43
Şekil 6.11. Kirlenilmiş AUST (10 Kat – Tek Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	43
Şekil 6.12. Kirlenilmiş AUST (10 Kat – İki Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	45
Şekil 6.13. Kirlenilmiş AUST (10 Kat – İki Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	45
Şekil 6.14. Kirlenilmiş AUST (10 Kat – Üç Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri.....	47
Şekil 6.15. Kirlenilmiş AUST (10 Kat – Üç Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği.....	47
Şekil 6.16. FTSE-2010 zaman serisi	49
Şekil 6.17. FTSE-2011 zaman serisi	49
Şekil 6.18. FTSE-2012 zaman serisi	50
Şekil 6.19. FTSE-2013 zaman serisi	50
Şekil 6.20. FTSE-2014 zaman serisi	51
Şekil 6.21. Orijinal FTSE çözümlemeleri D-D-YSA performans değerlendirmesi.....	67
Şekil 6.22. Beş kat-tek aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	68
Şekil 6.23. Beş kat-iki aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	68
Şekil 6.24. Beş kat-üç aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	69
Şekil 6.25. On kat-tek aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	69
Şekil 6.26. On kat-iki aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	70
Şekil 6.27. On kat-iki aykırı FTSE çözümlemeleri D-D-YSA performans değerlendirmesi	70

Şekil 6.28. Beş kat-tek aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	71
Şekil 6.29. Beş kat-iki aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	72
Şekil 6.30. Beş kat-üç aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	72
Şekil 6.31. Beş kat aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	73
Şekil 6.32. On kat-tek aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	73
Şekil 6.33. On kat-iki aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	74
Şekil 6.34. On kat-üç aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	74
Şekil 6.35. Beş kat aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	75
Şekil 6.36. Kirlenmiş FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi	75

TABLÖLAR LİSTESİ

Tablo 2.1. Mimari Yapı Sınıflandırılması.....	10
Tablo 2.2: Aktivasyon Fonksiyonları	12
Tablo 6.1. Orijinal AUST analiz sonuçları	34
Tablo 6.2. Kirletilmiş AUST (5 Kat – Tek Aykırı) analiz sonuçları	36
Tablo 6.3. Kirletilmiş AUST (5 Kat – İki Aykırı) analiz sonuçları	38
Tablo 6.4. Kirletilmiş AUST (5 Kat – Üç Aykırı) analiz sonuçları	40
Tablo 6.5. Kirletilmiş AUST (10 Kat – Tek Aykırı) analiz sonuçları	42
Tablo 6.6. Kirletilmiş AUST (10 Kat – İki Aykırı) analiz sonuçları	44
Tablo 6.7. Kirletilmiş AUST (10 Kat – Üç Aykırı) analiz sonuçları	46
Tablo 6.8. FTSE2010 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları.....	57
Tablo 6.9. FTSE2010 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları.....	58
Tablo 6.10. FTSE2011 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları.....	59
Tablo 6.11. FTSE2011 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları	60
Tablo 6.12. FTSE2012 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları.....	61
Tablo 6.13. FTSE2012 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları.....	62
Tablo 6.14. FTSE2013 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları.....	63
Tablo 6.15. FTSE2013 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları.....	64
Tablo 6.16. FTSE2014 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları.....	65
Tablo 6.17. FTSE2014 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları.....	66

ZAMAN SERİSİ ÖNGÖRÜSÜNDE DENDRİT YAPAY SİNİR AĞLARI İÇİN PARÇACIK SÜRÜ OPTİMİZASYONUNA DAYALI DAYANIKLI ÖĞRENME ALGORİTMASI

ÖZET

Zaman serisi öngörüsü, farklı alanlarda karşılaşılan önemli bir problemidir. Literatürde çok sayıda yöntem olmasına rağmen, bu yöntemler olasılıksal ve olasılıksal olmayan yöntemler olarak iki temel başlık altında incelenebilirler. Özellikle, hesaplama dayalı zaman serisi öngörü yöntemleri olarak, literatürde farklı türlerde yapay sinir ağları yaygın bir şekilde ve başarıyla kullanılmaktadır. Bunlardan bazıları, nöron modeli yapılarında, toplamsal birleştirme fonksiyonu kullanırken bazıları ise çarpımsal birleştirme fonksiyonu kullanırlar. Son yıllarda ortaya atılan dallantılı (dendrit) yapay sinir ağları ise yapılarında hem toplamsal hem de çarpımsal nöron modellerini birlikte içerirler. Bu tür bir yapay sinir ağının öngörü performansının, yapısındaki nöron modeli dolayısıyla, ilgilenilen zaman serisinin içerebileceği aykırı değerlerden olumsuz olarak etkilenmeleri kaçınılmazdır. Bu tez çalışmasında, literatürde ilk olarak, dendrit yapay sinir ağı eğitimi için bir dayanıklı öğrenme algoritması önerilmiştir. Önerilen dayanıklı öğrenme algoritması, Huber'in kayıp fonksiyonunu uygunluk fonksiyonu olarak kullanmaktadır. Dayanıklı öğrenme algoritmasının yinelemeli süreci, bir yapay zekâ optimizasyon algoritması olan parçacık sürü optimizasyonu tarafından gerçekleştirilmektedir. Önerilen dayanıklı öğrenme algoritması ile eğitilen dendrit yapay sinir ağının performansını farklı gerçek hayat zaman serileri ve bunlara farklı sayıda ve ölçekte aykırı değerlerin enjekte edilmesi ile elde edilen kirlenmiş zaman serilerinin analizleri ile ortaya konmuştur. Elde edilen sonuçlar göstermektedir ki hem aykırı değer içeren hem de aykırı değer içermeyen zaman serilerinin analizinde önerilen dayanıklı öğrenme algoritması ile eğitilen dendrit yapay sinir ağı tatmin edici öngörü sonuçları üretmektedir.

Anahtar kelimeler: Dendrit Nöron Model, Zaman Serileri, Parçacık Sürüsü Optimizasyonu, Öngörü, Dayanıklı Öğrenme Algoritması, Huberin Kayıp Fonksiyonu

ROBUST LEARNING ALGORITHM BASED ON PARTICLE SWARM OPTIMIZATION FOR DENDRITIC ARTIFICIAL NEURAL NETWORKS IN TIME SERIES FORECASTING

SUMMARY

Time series forecasting is a crucial problem encountered in a variety of fields. Although there are a great number of methods in the literature, they can be reviewed under two basic title as probabilistic and non-probabilistic methods. Especially, as computational-based time series forecasting methods, different kinds of artificial neural networks (ANNs) have been widely and successfully used in the literature. While some of them use additive aggregation function, some of them use multiplicative aggregation function in the structure of their neuron models. Dendritic Neural Networks, proposed in recent years, have also both additional and multiplicative neuron models, together. It is inevitable that the forecasting performance of such an artificial neural network will be negatively affected by the outliers that the time series of interest may contain due to the neuron model in its structure. In this thesis, a robust learning algorithm is proposed for dendritic artificial neural network training for the first time in the literature. The proposed robust learning algorithm uses Huber's loss function as a fitness function. The iterative process of the robust learning algorithm is carried out by particle swarm optimization, an artificial intelligence optimization algorithm. The performance of the dendritic artificial neural network trained with the proposed robust learning algorithm has been demonstrated by the analysis of different real-life time series and the analysis of the contaminated time series obtained by injecting different numbers and scales of outliers. The obtained results show that the dendritic artificial neural network trained by the proposed robust learning algorithm produces satisfactory predictive results in the analysis of time series with and without outliers.

Keywords: Dendritic Neuron Model, Time Series, Particle Swarm Optimization, Forecasting, Robust Learning Algorithm, Huber's Loss Function

BÖLÜM 1. GİRİŞ

Kronolojik sırayla elde edilen verilere sahip değişkenlere zaman serisi adı verilmektedir. Genel olarak zaman serisi, T örneklem büyüklüğü olmak üzere z_t , $t = 1, 2, \dots, T$ biçiminde gösterilir. Buna göre ilk gözlemlenen veri z_1 ; ikinci gözlemlenen veri z_2 ; son gözlemlenen veri z_T ile ifade edilir. Zaman içinde sürekli olarak kaydedilebilen verilere sahip serilere sürekli zaman serileri, sadece belli aralıklarda elde edilebilen verilere sahip serilere de kesikli zaman serileri adı verilmektedir. Elektrik sinyalleri, voltaj, ses titreşimleri gibi mühendislik alanlarına ait seriler sürekli zaman serileri iken; faiz oranı, satış hacmi, üretim miktarı gibi iktisadi seriler kesikli zaman serileridir. Ekonomik araştırmaların en önemli aşamalarından birisi, ekonomik modeli meydana getiren değişkenlerin rakamlarla ifade edilebilir hale getirilmesidir. Veri sağlanamayan konularda ampirik çalışmaların yapılması zor olacağı için öncelikle verilerin sınırları belirlenmelidir.

Doğada meydana gelen olaylar başlangıçtan beri merak konusu olmuş ve insanlar meydana gelen bu olayları düşünce, akıl ve hisleriyle anlamaya çalışmış ve teknolojinin el verdiği ölçüde ilerleme sağlamışlardır. Böylece pek çok yöntem geliştirmişlerdir.

Kurum, kuruluş ve hatta ülkelerin geleceğe ilişkin strateji ve politikalarını belirlemede, değişen koşullara uyum gösterme ve kalıcı olabilmeye, geçmiş verilerden yararlanarak gelecekle ilgili doğru öngörülerde bulunabilmeleri hayati bir önem taşımaktadır. Bu bakımdan, öngörü problemi; üzerinde yoğun bir şekilde çalışılan ve birçok farklı yaklaşım ve yöntemin geliştirildiği bir alan olarak bilimsel literatürde yerini almaktadır.

Geliştirilen öngörü modelleri, olasılıksal ve olasılıksal olmayan modeller olmak üzere, temel olarak iki ana başlıkta incelenebilir. Olasılıksal modeller ve yöntemler gözlem sayısı, durağanlık, standart model gibi bazı katı varsayımları içermeleri nedeniyle, bu varsayımların sağlanmadığı gerçek hayat problemlerinde ilgilenilen zaman serilerinin öngörülmesinde yetersiz kalabilmektedir. Olasılıksal olmayan modeller, özellikle hesaplamalı yaklaşımlar

içeren farklı yapay sinir ağı (YSA) modelleri, ise bu tür katı varsayımları içermediklerinden hemen hemen tüm zaman serilerinin analizinde, son birkaç on yılda, başarıyla kullanılmaktadır (Aladag, Egrioglu ve Yolcu, 2014).

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalar olarak tanımlanabilir (Öztemel, 2008). İnsan sinir sisteminin basit bir taklidi olan YSA günümüzde, matematik, mühendislik, tıp, ekonomi gibi alanlarda sıklıkla kullanılmaktadır.

YSA yapısı nöronlardan oluşur ve bu nöronları birbirine bağlayan ve veri işlemlerini gerçekleştiren ağırlıkların en iyi değerlerinin elde edilme süreci ağı eğitimi olarak anılır. Bir veri kaynağını kullanarak eğitilebilmesi ve öğrenebilir bir yapıya sahip olması ise YSA'nın en önemli özelliği olarak görülebilir. Ağı eğitimi süreci bir öğrenme algoritması tarafından gerçekleştirilir ve belirli bir ölçüte göre ağırlıkların en iyi değerlerine adım adım yaklaştırılması prensibine dayanır. Bu işlem, her bir adımda ağı ağırlıklarının değişimi bittiğinde sonlandırılır.

YSA'nın eğitimi gerçekte bir optimizasyon problemidir. Bu optimizasyon problemi için farklı eğitim algoritmaları kullanılmaktadır. Bunlardan en yaygın olanları geri yayılım öğrenme algoritması ve Levenberg-Marquardt öğrenme algoritmalarıdır. Ancak özellikle son yıllarda, parçacık sürü optimizasyonu (PSO), genetik algoritma (GA) ve diferansiyel gelişim algoritması (DGA) gibi sezgisel optimizasyon algoritmaları da yaygın bir şekilde kullanılmakta ve tatmin edici sonuçlar üretmektedirler (Gao ve ark., 2019).

Warren McCulloch ve Walter Pitts (1943) ilk YSA modelini ortaya koymuşlardır (Todo ve ark., 2014). İlk YSA modelleri yalnızca girdi ve çıktı tabakalarından oluşmaktaydı. Birden çok girdi ve tek bir çıktı birimi bulunan bu ağlar doğrusal bir çıktı fonksiyonu kullandıklarından, doğrusal olmayan ilişkileri içeren problemlerin çözümünde kullanılamamaktadır. Rumelhart ve ark. (1986) çok katmanlı algılayıcı (ÇKA) modelini geliştirmiş ve doğrusal olmayan problemlerin de çözümünü gerçekleştirmişlerdir

(Rumelhart DE, Hinton GE, 1986). Rumelhart ve ark. (1986) tarafından geliştirilen bu model yayılım (backpropagation network) olarak da bilinmektedir (Aladag, Egrioglu ve Yolcu, 2014). ÇKA bir girdi ve çıktı tabakasının yanı sıra bir ya da birden çok gizli tabaka içermektedir. Broomhead ve Lowe, uyarlanabilir katmanlı ağlarda "öğrenme" ile verilerin yüksek boyutlu yüzeylere uydurulması arasındaki ilişkiyi tartışmışlardır (Broomhead, 1988). Hill uyarlanabilir prosedürleri, halka açık bir veri tabanından birçok ikili ayrımcılık problemini kullanan doğrusal programlama yöntemleriyle karşılaştırmıştır (Hill, 1999). Labib XOR problemi gibi doğrusal olmayan kalıpları tanıyabilen tek bir nöron için yeni bir yapının geçerliliğini inceledi (Richard Labib, 1999). Plate sigma pi birimleri hakkında çalışmıştır (Plate, 2000). Zhang, Zhao ve Wang giriş iletkenlikleri üzerindeki tek nöron yerel aritmetik ve mantık işlemlerini keşfetmek için faz analizine odaklandı (Zhang, Zhao ve Wang, 2000). Daha sonra, genelleştirilmiş ortalama nöron modeli (GNM) (Yadav, Kalra ve John, 2007), geometrik ortalama nöron modeli (GeoNM) ve tek çarpımsal nöron modeli (SMNM) (Yadav, Kalra ve John, 2007; Legenstein ve Maass, 2011), bronkospastik plastik nöron modeli (Yadav, Kalra ve John, 2007; Legenstein ve Maass, 2011; Yolcu, Egrioglu ve Aladag, 2013; Schiess, Urbanczik ve Senn, 2016) da tanıtıldı. Yukarıda bahsedilen YSA'lar nöron modelleri açısından ele alındığında, hepsinin farklı toplama fonksiyonlarından birini toplamsal bazlı, çarpımsal bazlı veya ortalamaya dayalı olarak kullandıkları söylenebilir. Tüm bu nöron modellerine sahip YSA'lar genellikle zaman serisi tahminlerinde kullanılır. Ayrıca, zaman serisi tahmin problemlerinde, çarpım tabanlı ve toplamaya dayalı toplama işlevleriyle (Ghosh, J, Shin, 1992) nöron modellerinin bir kombinasyonunu kullanan bir tür YSA, sigma-pi sinir ağı (SPNN) kullanılır. Bununla birlikte, bu modeller, kümelenme kapsamlarını tanımlamak için sinapslar arasındaki ağırlıkları kullanan McCulloch-Pitts nöron modelinin yapısına bağlıdır.

Farklı nöron modellerine sahip olsalar da bu YSA modellerinin tamamı ortalamaya dayalı bir birleştirme fonksiyonu kullandıklarından, ilgilenilen verinin içerebileceği aykırı değerlerden olumsuz olarak etkilenmeleri kaçınılmazdır. Bu durum, YSA çıktılarının verinin genel yapısından uzaklaşmasına ve YSA'nın aykırı değer ya da değerlere yakın çıktılar üretmesine neden olacaktır. Böylece YSA, aykırı değer yapısına bağlı olarak, hedeflenen

değerden farklı olarak daha küçük ya da daha büyük çıktılar üretmesi anlamına gelmektedir (Yolcu ve ark., 2015).

Bir öngörü probleminde, zaman serisinin içerdiği ve verinin genel özelliklerini yansıtmayan aykırı değerlerin ÇKA'nın öngörü performansı üzerinde olumsuz bir etkiye sahip olduğu ve bazı problemlere neden olabileceği Hill, Zhang ve Chuang tarafından ortaya konmuştur (Hill T., Marquez L., O'Connor M., 1994; Zhang G., Eddy Patuwo, B.Y., 1998; Chuang C.C., Su S.F., 2000).

Aykırı değerlerin YSA performansı üzerindeki olumsuz etkilerini azaltmak ve verinin aykırı değer ya da değerlere sahip olduğu durumlarda da güvenilir ve etkin sonuçlar elde etmek amacıyla farklı modeller ortaya konmuştur. Bu yaklaşımlar “dayanıklı” ya da “sağlam” olarak isimlendirilen yaklaşımlara dayalıdır.

Dayanıklılık kavramı ilk olarak istatistik alanında Box tarafından ortaya atılmış bir kavramdır ve istatistiksel varsayımlardan sapmaların olduğu durumlarda dahi istenilen özelliklere sahip tahmin sonuçları üretebilen istatistikler dayanıklı olarak addedilmiştir. Özellikle regresyon çalışmalarında, dayanıklı tahmin ediciler üzerine Tukey, Huber ve Andrews farklı yaklaşımlar ortaya koymuşlardır (Huber P.J., 1964; Andrews D.F., 1974; Statistics, 2002).

YSA literatüründe dayanıklılık kavramı, Boscovich tarafından önerilen en küçük mutlak sapmalar ve ya L_1 tahmin yöntemi üzerine kurulmuştur (Roger Joseph Boscovich, 1757). Dayanıklı öğrenme algoritmalarını içeren YSA modelleri ve farklı nöron modelleri içeren dayanıklı mimari yapıya sahip YSA modelleri üzerinden, iki farklı açıdan değerlendirilebilir. Chen ve Jain, Lee ve ark. ve Bas ve ark. YSA öğrenme algoritmasında uygunluk değeri olarak Huber'in (1964) M tipi tahmin edicisini kullanarak dayanıklı birer öğrenme algoritması ortaya koymuşlardır (Chen ve Jain, 1994; Doyle ve ark., 1998; Egrioglu ve ark., 2015). El Melegly ve ark. ve Rusiecki ise en küçük medyan karelere dayalı bir uygunluk fonksiyonunu kullanan dayanıklı bir öğrenme algoritması önermişlerdir (El-melegly, Essai ve Ali, 2009; Rusiecki, 2012). Ayrıca Thomas çok katmanlı algılayıcı için dayanıklı öğrenme

algoritmasını geliştirmiştir. Bu çalışmaların dışında pek çok araştırmacı farklı YSA türleri için farklı dayanıklı öğrenme algoritmaları ortaya koymuşlardır (Chen ve Jain, 1994; Connor, Martin ve Atlas, 1994; Neubauer A., 1995; Sanchez V.D.A., 1995; Liano K., 1996; Mili ve Coakley, 1996; Umasuthan M., 1996; Wang C., Wu H.C., 1996; McDowall T.M., 1997; Huang L., Zhang B.L., 1998; R. Labib, 1999; Basu M., 1999; Chuang C.C., Su S.F., 2000; Juanyin, Q., Wei, W., Pan, 2004; Pernía-Espinoza ve ark., 2005; Zhao, L., Yang, 2009; Aladağ C.H., Eğrioğlu E., 2010; Shibblee Md., Chandra B., 2010; Hans A., ve Udluft, 2010; Aladağ C.H., Yolcu, U., Eğrioğlu, 2014; Yolcu ve ark., 2015; Zhou ve ark., 2016; Chen ve ark., 2017). Dayanıklı öğrenme algoritmalarını içeren çeşitli YSA türlerinin dışında, farklı nöron modellere içeren dayanıklı mimari yapıya sahip YSA türleri de özellikle son yıllarda zaman serisi öngörü amacıyla ortaya konmuştur. Aladağ ve ark. medyan nöron modele dayalı sağlam bir YSA türü ortaya koymuşlardır. Yolcu ve ark. ise budanmış ortalama nöron modele dayalı ileri beslemeli bir YSA önermişlerdir. Eğrioğlu ve ark. yine medyan nöron modele dayalı bir dayanıklı YSA mimarisi önermişlerdir.


Zaman serisi analizi amacıyla kullanılan bir diğer sinir ağı dallantılı (dendrit) nöron model yapay sinir ağları (D-YSA) Koch ve ark. tarafından ortaya konulan dendrit mekanizmasının en ilkel formunun gelişmiş bir modelidir. D-YSA hem toplamsal hem de çarpımsal fonksiyonları kullanan bir mimari yapıya sahiptir. 2014 yılında Y.Todo ve ark. tarafından lineer olmayan sinapslar için dendrit nöron model önerilmiştir. Ayrıca 2015 yılında Z. Sha ve ark. tarafından akciğer kanseri sınıflaması için, 2016 yılında T.Zhou ve ark. tarafından finansal zaman serilerinde dendrit nöron modelin kullanılmasıyla ilgili çalışmalar yapılmıştır. Ayrıca L.Abbott ve ark. (2004), A.Destexhe ve ark. (2004), W. Chen ve ark (2017), R.Caze ve ark. (2017) dendrit nöron model ile ilgili çalışmalarda bulunmuşlardır. Bu tez kapsamında, literatürde ilk olarak, D-YSA eğitiminde kullanılan bir dayanıklı öğrenme algoritması önerilmiştir. Önerilen dayanıklı öğrenme algoritması, Huber'in kayıp fonksiyonunu uygunluk fonksiyonu olarak kullanmaktadır. Dayanıklı öğrenme algoritmasının yinelemeli süreci, bir yapay zekâ optimizasyon algoritması olan parçacık sürü optimizasyonu (PSO) tarafından gerçekleştirilmektedir. D-YSA'nın eğitimi için önerilen dayanıklı öğrenme algoritmasının performansı literatürde sıklıkla kullanılan zaman serilerinin ve bunların aykırı değerlerle kirlenmiş türevlerinin analizi üzerinden

değerlendirilmiştir. Elde edilen karşılaştırmalı bulgular, önerilen dayanıklı öğrenme algoritmasının orijinal zaman serileri için rekabet edebilir bir öngörü performansı ortaya koyduğunu göstermektedir. Ayrıca, aykırı değerli zaman serileri için de performansın aykırı değerlerden etkilenmeyerek, orijinal veri çözümlemelerine oldukça yakın analiz sonuçları ürettiği gözlemlenmiştir.

Tezin ikinci bölümünde yapay sinir ağlarına ilişkin temel kavramlar, üçüncü bölümde D-YSA'nın temel mimarisi ve hesaplama detayları verilmektedir. Dördüncü bölümünde ise dayanıklı öğrenim algoritmasını gerçekleştirmede kullanılan PSO tanıtılmaktadır. Beşinci bölümde ise D-YSA'nın eğitimi için önerilen dayanıklı öğrenme algoritması adım adım işlenmektedir. Altıncı bölümde, farklı gerçek hayat zaman serileri ve bunlara farklı sayıda ve ölçekte aykırı değerlerin enjekte edilmesi ile elde edilen kirletilmiş zaman serilerinin analizlerini ve bu analizlerin sonuçlarını içeren uygulama detayları verilmektedir. Son bölümde ise elde edilen sonuçlar ve geleceğe yönelik görüşler özetlenecektir.


BÖLÜM 2. YAPAY SİNİR AĞLARI

Yapay sinir ağı, insan sinir sisteminin basit bir taklididir ve sinir sisteminin modellenmesiyle meydana gelmiştir. İnsan beynine özgü özelliklerden olan; bilgileri alıp işleyerek doğrudan öğrenme yolunu kullanır ve yeni bilgileri ortaya çıkarır ve keşfeder. İnsan beyninin çalışma prensibini örnek alır. Temel yapısını Şekil 2.1 ile verilen sinir hücresi oluşturur.



Şekil 2.1: Sinir Hücresi Genel Yapısı

İlk yapay sinir ağı modeli McCulloch ve Pitts tarafından 1943 yılında ortaya konmuştur. Eşik değer baz alınarak oluşturulmuş bir modeldir. Modelin açık şekli şekil 2.2'deki gibidir. (1) numaralı eşitlik ile formüle edilir. Bu modelde gelen her sinyal sinir hücresinde olduğu gibi ileri aktarılmamakta, yalnızca eşik değeri üzerindeki bilgiler iletilmektedir.




Şekil 2.1: McCulloch Pitts Nöron Model

$$o^{k+1} = \begin{cases} 1, & \text{Eğer } \sum_{i=1}^n w_i x_i^k \geq T \\ 0, & \text{Eğer } \sum_{i=1}^n w_i x_i^k < T \end{cases} \quad (1)$$


Burada x_i girdileri ($i = 1, 2, \dots, n$), k anındaki girdi değerinin olup olmamasına bağlı olarak sırasıyla 1 ya da 0 değerini alırlar. o nöronun çıktı değerini sembolize etmektedir. Bu model için öncelikle $k + 1$ anında elde edilecek bir çıktı değeri hesaplanır. Burada, diğer nöronların çıktısı olan her bir x_i girdi değeriyle karşılık gelen w_i ağırlıkları ($w_i \pm 1, i = 1, 2, \dots, n$) çarpılarak toplanır. Elde edilen değer T gibi bir eşik değerinden büyükse, nöronun $k + 1$ anındaki o^{k+1} çıktısı 1 değerini alır. T eşik değerinden küçükse çıktı 0 değerini alır.

Rosenbalt (1958) tarafından geliştirilen basit algılayıcı (simple perceptron), literatürde yaygın bir şekilde kullanılan çok tabakalı algılayıcının (multi-layer perceptron) temelini oluşturur. Basit algılayıcı McCulloch ve Pitts nöron modelinin eğitimi için önerilen bir öğrenme algoritmasına dayalıdır ve yapısı Şekil 2.3'te verilmiştir.



Şekil 2.3. Rosenbalt'ın basit algılayıcısı

Witrow ve Hoff ise 1959 yılında, tek katmanlı bir yapay sinir ağı olarak uyarlamalı doğrusal nöron modeli (ADALINE) geliştirmiştir. Bu model basit algılayıcıdan farklı amaçlar içinde kullanılabilmektedir. Yapısı Şekil 2.4 ile verilen ADALINE sınıflandırma problemi için basit algılayıcı gibi çalışmaktadır.



Şekil 2.4. ADALINE yapay sinir ağı


Literatürde farklı problemler için farklı yapay sinir ağları ortaya konmuştur. Genel olarak mimari yapı, nöron modeli, aktivasyon fonksiyonu ve öğrenme algoritması gibi dört temel bileşenden oluşurlar.

Mimari yapı bir ya da daha fazla nöronun işlevsel olarak bir araya getirilmesi ile oluşur ve nöronların hiyerarşik yapısının belirlenmesi ile ilgilidir. Mimari yapılar Tablo 2.1’de verildiği gibi farklı şekillerde sınıflandırılabilir.

Tablo 2.1. Mimari Yapı Sınıflandırılması

Sınıflama Şekli	Sınıf	Örnek
İçerdikleri nöron sayısı	Tek Nöronlu	- Basit Algılayıcı - Tek Nöronlu çarpımsal nöron model YSA
	Çok Nöronlu	- Çok Katmanlı Algılayıcı - Pi-Sigma - Dendritik Nöron Model YSA
Nöronların bağlantı yönü	İleri Beslemeli	- Tüm bağlantıların ileri yönlü olduğu Çok Katmanlı Algılayıcı, - Pi-Sigma YSA - Dendritik Nöron Model YSA
	Geri Beslemeli	- Elman - Jordan - Geri Beslemeli Çarpımsal Nöron Model YSA - Geri Beslemeli Pi-Sigma YSA
İçerdiği tabaka sayısı	Tek Tabakalı	- Basit Algılayıcı, - Tek Nöronlu çarpımsal nöron model YSA
	Çok tabakalı	- Çok Katmanlı Algılayıcı - Pi-Sigma YSA - Dendritik Nöron Model YSA

Çok katmanlı bir YSA mimari örneği Şekil 2.5'te verilmiştir.



Şekil 2.5. Çok Katmanlı Algılayıcı Mimari Yapısı

Aktivasyon fonksiyonları girdi ile çıktı arasındaki en iyi eşleşmenin bulunmasını sağlar. Aynı ağın içinde nöronlarda farklı aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonunun doğru seçilmesi ağın performansı açısından oldukça önemlidir. Aktivasyon fonksiyonlarından bazıları Tablo 2.2’de verilmiştir.

Öğrenme algoritması YSA’nın bir diğer önemli bileşenidir. Ağın girdi değerleri ve hedef değerleri arasındaki en iyi eşleşme öğrenme algoritmalarıyla elde edilir. Öğrenme işlemi, ağın eğitimi olarak da anılır ve ağırlıkların en iyi değerinin bulunmaya çalışıldığı bir algoritma vasıtasıyla gerçekleştirilir. Öğrenme işlemi eğitim, geçerlilik ve test aşamalarını içeren bir süreçtir. Öğrenme, denetimli ve denetimsiz olmak üzere iki farklı şekilde gerçekleşebilir. Denetimli öğrenme; elde edilecek çıktının karşılığı olarak önceden belirlenen bir hedef değeri içermesi durumudur. Burada amaç; YSA çıktı değeri ile hedef değeri arasındaki farkı minimize etmektir. Denetimsiz öğrenmede ise; çıktı değerine karşılık

gelen bir hedef değeri yoktur. Amaç YSA çıktısının girdi verisindeki istatistiksel düzeni en iyi şekilde yakalayacak ağırlıkları belirlemektir. YSA literatüründe en sık kullanılan öğrenme algoritmaları Geri Yayılım ve Levenberg-Marquardt öğrenme algoritmaları olmasına karşın özellikle son birkaç on yılda genetik algoritma (GA), parçacık sürü optimizasyonu (PSO), yapay arı kolonisi, tavlama benzetimi, diferansiyel gelişim algoritması gibi yapay zekâ optimizasyon algoritmaları da YSA eğitiminde başarıyla kullanılmaktadır (Gao ve ark., 2019).

Tablo 2.2: Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Fonksiyon Eşitliği
Doğrusal	$f(\text{net}) = \alpha(\text{net})$
Eşik	$f(\text{net}) = \begin{cases} \alpha & \text{net} > \theta \\ \beta & \text{net} \leq \theta \end{cases}$
Rampa	$f(\text{net}) = \begin{cases} \alpha & ; \text{net} \geq \alpha \\ \frac{\gamma - \delta}{\alpha - \beta} \text{net} + \frac{\alpha\delta + \beta\gamma}{\alpha - \beta} & ; \beta \leq \text{net} \leq \alpha \\ \delta & ; \text{net} \leq \beta \end{cases}$
Gauss	$f(\text{net}) = \exp\left(-\frac{\text{net}^2}{\sigma^2}\right)$
Hiperbolik tanjant	$f(\text{net}) = \frac{\exp(\text{net}) - \exp(-\text{net})}{\exp(\text{net}) + \exp(-\text{net})}$
Lojistik (sigmoid)	$f(\text{net}) = \frac{1}{1 + \exp(-\lambda \times \text{net})}$

Geri yayılım öğrenme algoritması genellikle sınıflama, tanımlama ve genelleme yapmayı gerektiren durumlarda kullanılır. ADALINE ve Basit algılayıcı geliştirilerek elde edilmiş bir modeldir. Algoritmanın amacı minimum hata elde etmektir. Geri Doğru Hesaplama (Back-Propagation) ve İleri Doğru Hesaplama (Feed-Forward) olarak iki çeşittir. Geri yayılım öğrenme algoritması hatayı minimize etmeye çalışır ve bunu yaparken de ağırlık değişimi yapar. Her ağırlık değiştiğinde hata da $\nabla \epsilon$ kadar bir azalma olur. Ancak çözümde her zaman hatayı en az veren ağırlık vektörünü yakalamak mümkün olmayabilir. Yanlış parametre

seçimi, başlangıç ağırlıkları seçiminde yapılan hatalar, mimari yapı hataları buna sebep olabilir. Bu durumda uygulamacılar ϵ kadar bir hatayı kabul ederler ve bunun altındaki her değer öğrenilmiştir denir. Bazı durumlarda ise eğitilen ağ tüm örneklerle hatasız yanıt verirken test setindekiler için doğru sonuçlar üretmez. Bu durumun nedeni ağıın öğrenmesi değil ezberlemesidir. Gereğinden fazla eğitim durumunda ortaya çıkar. Bu sorunu gidermek için Momentum terimi, Öğrenme parametresi adaptasyonu ve Quickprop algoritması geliştirilmiştir (Gao ve ark., 2019).


Levenberg-Marguardt öğrenme algoritması 1944 ve 1963 yıllarında birbirlerinden bağımsız olarak önerilmiştir. Bu yöntemde Taylor serisi açılımının ilk terimi kullanılmaktadır. Amaç fonksiyonu ikinci dereceden bir polinom ile yaklaştırılmakta ve ikinci dereceden türevler kullanılmaktadır. Bu sebeple bu ikinci dereceden bir eğitim algoritmasıdır. Geri yayılım öğrenme algoritmasından farkı ağırlıklar bir devirde bir kez değiştirilir.

Darwin'ın doğal seçim ve evrim teorisi ilkelerine dayanan GA, YSA eğitiminde en sık kullanılan bir arama ve optimizasyon yöntemidir. İlk olarak Holland tarafından kullanılan GA'nın temel prensibi; doğada yaşamlarını sürdürmek isteyen bireylerin güçlü ve daha iyi nesiller üretmesi ve iyi bireylerin hayatta kalması üzerine kuruludur(Holland, 1987). Gen, kromozom, popülasyon gibi birimleri olan GA, çaprazlama, mutasyon ve doğal seleksiyon gibi temel işlemlere dayalı olarak eğitimi gerçekleştirir. YSA eğitimi için başarı ile uygulanan bir diğer algoritma PSO'dur. PSO, Kennedy ve Eberhart tarafından, yaşamlarını sürü halinde sürdüren canlıların bazı temel ihtiyaçlarını giderirken sergiledikleri hareketlerden esinlenilerek ortaya atılmış bir optimizasyon algoritmasıdır(Kennedy, J, Eberhart, 1995). Parçacık ve sürü gibi birimleri olan PSO, sürüdeki her bir bireyin diğer bireyleri etkilediği ve böylece sürünün amacına daha kolay ulaşabileceği prensibine dayalıdır (Yolcu, Egrioglu ve Aladag, 2013).

Farklı YSA yapılarında farklı nöron modelleri kullanılmaktadır. İlk nöron modeli olan McCulloch ve Pitts nöron modelinin birleştirme fonksiyonu toplamsaldır. Bu nöron model

yapısı Şekil 2.6 ile verilmiştir. Burada Σ simgesi toplamsal birleştirme fonksiyonunu temsil etmekte ve ağırlık ve yan değerleri vektörü $\Theta = (w_1, w_2, \dots, w_m, b)$ ve girdi vektörü $(x_1, x_2, \dots, x_m)$ şeklinde ifade edilmektedir. Nöronun çıktısı (net) ise 2 numaralı eşitlikte verildiği gibi elde edilebilir.


$$\text{net} = \sum_{i=1}^m w_i x_i + b \quad (2)$$



Şekil 2.6. Mc-Culloch ve Pitts nöron modeli

Bir diğer nöron model birleştirme işlemcisi olarak çarpım işlemini kullanan çarpımsal nöron modeldir (ÇNM). ÇNM yapısı Şekil 2.7’de verildiği gibidir ve nöron çıktısı (net) 3 numaralı eşitlikle elde edilebilir. Ağırlık ve yanlar $\Theta = (w_1, w_2, \dots, w_m, b_1, b_2, \dots, b_m)$ ve girdiler ise $(x_1, x_2, \dots, x_m)$ vektörü ile temsil edilir. m girdili $(x_i, i = 1, 2, \dots, m)$ bir modelde $2m$ adet ağırlık bulunmaktadır.


$$\text{net} = \prod_{i=1}^m (w_i x_i + b_i) \quad (3)$$



Şekil 2.7. Çarpımsal nöron model


Ayrıca, YSA çıktısının aykırı değerlerden olumsuz etkilenmesinin önüne geçebilmek adına medyan nöron model ve budanmış ortalama nöron model birer dayanıklı nöron model olarak ortaya konmuştur. Bu nöron modellerde sırasıyla medyan fonksiyonu ve budanmış ortalama fonksiyonu birleştirme işlemcisi olarak kullanılmaktadır. Medyan ve budanmış ortalama nöron model yapıları sırasıyla Şekil 2.8 ve 2.9 ile verilebilirken her bir nöronun çıktısı eşiklik 4 ve 5'teki gibi hesaplanabilir.

$$\text{net} = \text{Medyan}(w_1x_1, w_2x_2, \dots, w_mx_m, b) \quad (4)$$



Şekil 2.8. Medyan nöron model

$$\text{net} = \text{Budanmış Ort.}(w_1x_1, w_2x_2, \dots, w_mx_m, b; \alpha) \quad (5)$$



Şekil 2.9. Budanmış ortalama nöron model

BÖLÜM 3. DENDRİT NÖRON MODEL YAPAY SİNİR AĞLARI

Zaman serisi analizinde kullanılan klasik istatistiksel modellerden, hareketli ortalamalar modeli, otoregresif model ve hareketli otoregresif model gibi zaman serisi modellerinin genellikle lineer olmayan ve düzensiz zaman serilerinde başarılı sonuçlar üretemediği gözlemlenmiştir. Bu nedenle son yıllarda doğal yapılardan esinlenen ve modern makine öğrenmesini baz alan yapay sinir ağı modeli (YSA) geliştirilmiştir. Yıllar içinde pek çok farklı türde zaman serisi önerilmiş, ancak veri için model seçimi her zaman bir zor olmuştur. Örneğin, çok katmanlı algılayıcı (ÇKA) yaygın olarak kullanılmasına rağmen hemen her zaman serisi için başarılı olduğunu söyleyebilmek zordur. Kısacası, farklı YSA modellerinin farklı zaman serisi problemlerinde başarılı sonuçlar verdiği söylenebilir. Ayrıca hemen tüm YSA modelleri birden fazla nöron ve/veya birden fazla ara katman içerdiklerinden karmaşık bir mimari yapıya sahiptirler (Zhou ve ark., 2016).

Yapay sinir ağları insan beyninin bilgi kontrol mekanizmasını sınıflama, sıralama ve tahmin gibi pek çok alan da taklit eden bir sinir ağı örneğidir. Geleneksel sinir ağları birçok alanda başarıyla kullanılıyor olmalarına karşın, zor anlaşılan problemler, yavaş ve zor eğitim problemleri gibi pek çok problemi çözmekte etkisiz kalabilmektedir (Jia ve ark, 2019). Araştırmalar göstermiştir ki, dendritler bu tür problemlerin çözümde anahtar rol oynamışlardır. Bu sebeple araştırmacılar bu tür problemleri çözmek için dendrit nöron model yapay sinir ağını (D-YSA) geliştirmişlerdir.

Nöronların özellikleri üzerine yapılan son yıllardaki araştırmalara dayalı olarak, dendrit yapılarda sinaptik lineer olmayan yapıya sahip tek bir nöronun gerçekçi bir hesaplama şekli ortaya konulmuştur. D-YSA, doğrusal olmayan yapıyı, sigmoid fonksiyonla modelleyerek, lineer olarak ayrılamayan fonksiyonu hesaplayabilir ve böylece herhangi karmaşık sürekli fonksiyona yaklaştırabilir. Dendrit yapıdaki lineer olmayan etkileşim Boolean mantığıyla ifade edilir. Karmaşık fonksiyonlar yerine AND (birlikte), OR (ayırıtım), ya da NOR (eksiklik) ifadeleri kullanılır (Zhou ve ark., 2016).

Lineer eşik kapısı modeli olarak da bilinen, ilk yapay sinir ağı modeli, McCulloch Pitts nöron modelin kesin bir matematiksel tanımı vardır. Ancak bu model oldukça basit bir modeldir ve yalnızca iki elemanlı karışık eşik değer oluşturabilir. Koch ve ark. (1982) sinir hücrelerini baz alarak dendrit mekanizmasının en ilkel şeklini inşa etmişlerdir. Bu model ise mantıksal operatörleri kullanarak köklerde bulunan girdi sinyallerini somaya aktarır ve oradan mantıksal operatöre bağlı bir sonuç elde ederler. Geleneksel Koch modeline dayanarak, bir nöronun mantıksal çalışması aşağıda verilen adımlarla geliştirilebilir (Zhou ve ark., 2016).

Adım 1. Giriş ve çıkış tipleri, 0 veya 1 değerleriyle tanımlanır.

Adım 2. Dendritin şekli rastgeledir. Başlatıldığında, dendritlere keyfi bir karar verilir.

Adım 3. İlk aşamada tüm sinapslar arasında temel bir etkileşim vardır.

Adım 4. Bir mantık ağı, dendritteki doğrusal olmayan etkileşimleri ifade edebilir.

Adım 5. Bir öğrenme dönemi için dendritin şekli ve sinapslar arasındaki etkileşim türleri uygun bir durumda tespit edilebilir.

Koch ve ark. tarafından inşa edilen modelin geliştirilmesiyle dendrit (dallantılı) nöron model (D-YSA) ortaya konmuştur. D-YSA'nın temel özellikleri şu şekilde özetlenebilir: (Gao ve ark., 2019)

1. Mimari yapısı hem Pi-Sigma hem de Çarpımsal Nöron Modele benzerdir. Çok katmanlı bir mimari yapısı vardır ve sinyaller ileri beslemeli olarak iletilir.
2. Çarpımsallık, lineer olmayan sinir sistemlerinde basit ve yaygın olarak kullanılmaktadır.
3. Sigmoid fonksiyonu kullanır.
4. Sinapstaki parametrelerin değerlerine bağlı olarak, bir nöronun morfolojisinin belirlenmesi için faydalı olan sinaps çıktısı; engelleyici ve uyarıcı olarak nitelendirilir ve 0 ve 1 sabitleriyle temsil edilir.

Literatürde ortaya konmuş çalışmalarda D-YSA'nın eğitimde gradiyente dayalı geri yayılım öğrenme algoritmasından yararlanılmaktadır.

D-YSA dört katmanlı yapıdan oluşur. Sinaptik katmanda gelen sinyaller sigmoid fonksiyon içinde tutulur. Sigmoid fonksiyondan geçen sinyallerin çıktısı dendrit tabakasına iletilir ve burada her bir girdi için elde edilen çıktılar çarpımsal fonksiyona girerler. Üçüncü tabaka olan membrane(zar) tabakasında ise dendrit tabakası çıktıları toplamsal fonksiyonda işlenir. Son olarak soma tabakasına gelen çıktılar tekrar sigmoid fonksiyona sokulur ve nihai çıktı elde edilir (Gao ve ark., 2019).

3.1. Sinaptik Tabaka

Sinapslar iki dendrit arasında ya da bir dendrit ile bir soma arasında bağlantı kurar. Sinyaller ileri beslemeli olarak aktarılır. Sinaptik tabaka (1) numaralı fonksiyonda ifade edildiği gibidir.

$$Y_{ij} = \frac{1}{1 + \exp(-k(w_{ij}x_i - \theta_{ij}))} \quad (1)$$

burada Y_{ij} , jinci sinaptik tabakadaki iinci sinaptik girdiye karşılık gelen çıktıyı temsil eder. k ise pozitif bir sabittir. x_i , bir sinapsın iinci girdisidir ve $x_i \in [0,1]$. w_{ij} ve θ_{ij} sırasıyla ağırlık ve eşik değerini ifade eder.

3.2. Dendrit Tabakası

Çeşitli sinaptik tabakalardaki sinapslardan gelen çıktıların çarpımsal fonksiyonunu gösterir. (2) numaralı fonksiyonla ifade edilir.

$$Z_j = \prod_{i=1}^N Y_{ij} \quad (2)$$

Çarpımsal operasyonlar lineer olmayan sinapslarda başarılıdır. Bu sebeple model dendrit tabakasında çarpımsal operatörleri kullanmaktadır. Çarpımsallık mantıksal ‘ve’ ile benzerdir, çünkü dendritin girdi ve çıktı değerleri 0 veya 1 ile ilişkilidir.

3.3.Membrane Tabaka

Membrane tabaka dendrit dallarından gelen sinyalleri birbirine bağlar. Dendrit dallarından alınan sinyaller toplamsal fonksiyonda hesaplanır. Toplamsallık mantıksal ‘veya’ ile benzerdir. Sonuç çıktısı soma tabakasını aktive etmek üzere diğer tabakaya geçer. (3) numaralı fonksiyonla formüle edilir.


$$V = \sum_{j=1}^N Z_j \quad (3)$$

3.4.Soma Tabakası

Nihayet, ağın çıktısı soma tabakasında işleme konulan bir sigmoid (lojistik) aktivasyon fonksiyonuna girer ve eğer çıktı eşik değer üzerindeyse iletim gerçekleşir. Kullanılan sigmoid fonksiyon (4) numara formül ile ifade edilir.

$$o = \frac{1}{1 + \exp(-k_s(V - \theta_s))} \quad (4)$$

burada k_s pozitif bir sabit ve θ_s ,[0,1] aralığında değiştirilen bir eşik değerini ifade eder.



Şekil 3.1: DNM Mimari Yapısı

Buradaki şekil dendrit nöron modelin mimari yapısını bize açıkça göstermektedir. Öncelikle her bir dendritte bulunan $x_1, x_2, \dots, x_n$ girdi sinyalleri sinaptik tabakadaki karşılıklarını bulurlar. Daha sonra her bir dendritteki çıktılar dendrit tabakasında çarpımsal fonksiyona girerler ve yeni çıktılar elde edilir. Üçüncü aşamada ise dendrit tabakasından gelen çıktılar membrane tabasında toplanır. Son olarak soma tabasına gelen sinyaller sayesinde D-YSA'nın sonucu hesaplanır.

BÖLÜM 4. PARÇACIK SÜRÜ OPTİMİZASYONU

Popülasyon temelli bir optimizasyon tekniği olan Parçacık sürü optimizasyonu, 1995 yılında Eberthart ve Kennedy tarafından kuş sürülerinin davranışlarından esinlenerek geliştirilmiştir. Bu yöntemi diğerlerinden ayırt eden özelliği, global en iyi (optimum) seviyeye ulaşmak için aynı anda pek çok farklı çözüm alanı araştırmasıdır. Bu özelliği sayesinde, yerel optimum tuzakları önlenabilir. Amacı, küresel optimum noktasını bulmaktır. Tasarlanma sebebi doğrusal olmayan problemlerin çözümünü sağlamaktır. Ancak çok parametrelili ve çok değişkenli optimizasyon problemlerinin çözümünde de kullanılmaktadır. PSO türev bilgisine ihtiyaç duymaz. Bu onu klasik optimizasyon tekniklerinden ayıran önemli bir özelliktir. Bunun yanında kullandığı parametre sayısının azlığı da onu kullanım kolaylığı olan bir yöntem haline getirir.

PSO daha önce de belirtildiği gibi parçacıkların sürü halindeki toplu hareketlerinden yararlanan bir tekniktir. Popülasyon sürüyü, parçacıklar ise sürüdeki bireyleri temsil etmektedir. Parçacıklar çok boyutlu araştırma uzayı boyunca hareketli bir akış içerisinde bulunurlar ve her bir parçacığın pozisyonu kendi ve diğer bireylerin (parçacıkların) tecrübelerine dayanarak belirlenmektedir. PSO’da her bir parçacığın pozisyon bilgisi bir çözümü temsil eder. Her bir yinelemede parçacığın pozisyon değiştirme miktarı ise parçacığın hızı olarak anılır. Her bir parçacığın pozisyon değerleri başka bir ifadeyle arama uzayındaki çözüm uygunluk fonksiyonuna bağlı olarak değerlendirilir. Bütün parçacıklar kendi keşfettikleri en iyi pozisyon (çözüm) değerini ve sürüde keşfedilen en iyi pozisyon değerine sahip parçacığı referans alarak optimum çözüme ulaşmaya çalışırlar.

PSO, bir grup rastgele çözümle (parçacık sürüsü) başlatılır ve güncellemelerle optimum çözüm bulunmaya çalışılır. Her yinelemede (iterasyonda) parçacık konumları, iki en iyi pozisyona göre güncellenir. Bunlardan ilki; o ana kadar parçacığın elde ettiği en iyi uygunluk değerine karşılık gelen pozisyonlardır ve “pbest” ile temsil edilebilir. pbest her bir iterasyonda hafızada saklanmaktadır. İkincisi ise, popülasyonda o ana kadar tüm parçacıklar

tarafından elde edilen en iyi uygunluk değerine karşılık gelen pozisyonlardır. Bu global en iyi çözümü temsil eder ve “gbest” ile temsil edilir.

PSO algoritması sırasında farklı parametre değerlerinin belirlenmesi gerekmektedir. Bunlardan en temel ikisi; bilişsel (c_1) ve sosyal (c_2) parametreler (öğrenme faktörleri) olup, her parçacığı pbest ve gbest pozisyonlarına doğru çeken, olasılıksal hızlanma terimlerini ifade eden sabitlerdir. c_1 , parçacığın kendi tecrübelerine göre hareket etmesini, c_2 ise sürüdeki diğer parçacıkların tecrübelerine göre hareket etmesini sağlar. Bu parametrelerin düşük değerler seçilmesi parçacıkların hedef bölgeye doğru çekilmeden önce, bu bölgeden uzak yerlerde dolaşmalarına imkân verir. Ancak hedefe ulaşma süresi uzayabilir. Diğer taraftan, yüksek değerler seçilmesi ise, hedefe ulaşmayı hızlandırırken, beklenmedik hareketlerin oluşmasına ve hedef bölgenin es geçilmesine sebep olabilir. Bu tür yakınsama problemlerinin üstesinden gelebilmek adına eylemsizlik ağırlığı (w) PSO çalışma sürecine eklenmiştir. Diğer bir katkı ise c_1 , c_2 ve w katsayılarının değerlerinin iterasyonlar içinde doğrusal olarak değiştirilmesidir.

PSO’nun adım adım çalışma prensibi Algoritma 1 ile verilebilir.

Algoritma 1.

Adım 1: PSO parametreleri belirlenir.

pn	: Parçacık sayısı
vmaks	: Hız için üst sınır
c_{1i}	: Bilişsel katsayı için alt sınır
c_{1f}	: Bilişsel katsayı için üst sınır
c_{2i}	: Sosyal katsayı için alt sınır
c_{2f}	: Sosyal katsayı için üst sınır
w_1	: Eylemsizlik parametresi için alt sınır
w_2	: Eylemsizlik parametresi için üst sınır
maxitr	: Maksimum yineleme (iterasyon) sayısı

Adım 2: Her bir parçacığın başlangıç pozisyonları ve başlangıç hızları belirlenir.

Adım 3: Problem için değerlendirme fonksiyonu hesaplanır.

Adım 4: Değerlendirme fonksiyonuna göre pbest ve gbest belirlenir.

Adım 5: Hızlar ve pozisyonlar (5),(6),(7) numaralı formüllerle güncellenir. Ancak hız ve pozisyonlar, sosyal katsayı, bilişsel katsayı ve eylemsizlik parametresine bağlı olduğu için öncelikle (2),(3),(4) numaralı formüllerle sosyal katsayı, bilişsel katsayı ve eylemsizlik parametresi güncellemesi yapılır.

$$c_1^t = (c_{1f} - c_{1i}) \frac{t}{\text{maxitr}} + c_{1i} \quad (2)$$

$$c_2^t = (c_{2f} - c_{2i}) \frac{t}{\text{maxitr}} + c_{2i} \quad (3)$$

$$w^t = (w_2 - w_1) \frac{\text{maxitr} - t}{\text{maxitr}} + w_1 \quad (4)$$

Böylece hız ve pozisyon güncellemeleri $y = 1, 2, \dots, \text{maxitr}$; $l = 1, 2, \dots, \text{pn}$; $r = 1, 2, \dots, d$ olmak üzere sırasıyla;

$$V_{l,r}^{y+1} = [w^y \times V_{l,r}^y + c_1^y \times \text{rand}_1 \times (Pb_{l,r}^y - P_{l,r}^y) + c_2^y \times \text{rand}_2 \times (Pg_r^y - P_{l,r}^y)] \quad (5)$$

$$V_{l,r}^{y+1} = \min(\text{vmaps}, \max(-\text{vmaps}, V_{l,r}^{y+1})) \quad (6)$$

$$P_{l,r}^{y+1} = P_{l,r}^y + V_{l,r}^{y+1} \quad (7)$$

Adım 5: Durdurma koşulu kontrol edilir. Durdurma koşulu araştırmacı tarafından önceden belirlen bir iterasyon sayısı veya her iki iterasyon arasındaki değerlendirme fonksiyonu değerleri farkının belli bir değer altında kalması olabilir. Durdurma koşu sağlanmadığında algoritma Adım 3'ten devam ettirilir. Durdurma koşulu sağlanıyor ise en son iterasyonda belirlenen gbest'in pozisyonları en iyi çözüm olacaktır.

BÖLÜM 5. ÖNERİLEN YÖNTEM

Farklı YSA türleri zaman serisi öngörü problemleri için sıklıkla kullanılmaktadır. ÇKA, TÇNM-YSa ve PS-YSa zaman serisi literatüründe yaygın bir şekilde kullanılıyor olmasına karşın D-YSa'nın da kullanıldığı az sayıda çalışma da bu literatürde mevcuttur. Tüm bu YSA'lar zaman serisi problemlerinde başarılı sonuçlar üretmelerine rağmen çözülmesi gereken bazı problemlere de sahiptirler. Bunlardan biri; aykırı değer durumunda öngörü performansının olumsuz yönde etkilenmesidir. Bu problemi ortadan kaldırmak adına literatürde iki farklı yaklaşım üzerinde durulmuştur. Birinci yaklaşım, ağın eğitimi için dayanıklı bir eğitim algoritmasının kullanılmasıdır. Bu yaklaşımda, ağın eğitimi sırasında uygunluk fonksiyonu olarak dayanıklı bir fonksiyon kullanılarak, aykırı değerden kaynaklı oluşan hatanın uygunluk fonksiyonunun değerine olan olumsuz etkisinin azaltılması amaçlanmaktadır. Ayrıca, aykırı değerın etkisini yok etmek, en azından azaltmak, adına YSA'nın mimarisinde dayanıklı fonksiyonların kullanıldığı nöron modellerden de faydalanılmaktadır. Bu yaklaşım dayanıklı nöron modeline sahip bir dayanıklı YSA mimarisi ortaya koyacaktır. Literatürde, her iki yaklaşım da ÇKA, TÇNM-YSa ve PS-YSa'ları için ortaya konmuş olmasına karşın D-YSa için henüz dayanıklı bir öğrenme algoritması ya da mimari yapı ortaya konmamıştır. Bu tez kapsamında birinci yaklaşım üzerinde durularak, zaman serisi öngörü probleminde D-YSa için dayanıklı bir öğrenme algoritması önerilmiştir. Bu kapsamda, ağın eğitimi sırasında uygunluk fonksiyonu olarak Huber'in kayıp fonksiyonu uygunluk fonksiyonu olarak kullanılmış ve aykırı değerden kaynaklı aykırı bir hatanın eğitim algoritması üzerindeki etkisi azaltılmıştır. Böylece literatürde ilk olarak bir dayanıklı D-YSa modeli ortaya konmuş ve ağın eğitimi PSO tarafından gerçekleştirilmiştir. D-YSa için ortaya konan dayanıklı öğrenme algoritması adım adım aşağıdaki gibi verilebilir.


Algoritma

Adım 1. D-PSO parametreleri belirlenir.

p_n	: Parçacık sayısı
v_{maps_1}	: Ağırlık ve ağ parametreleri için hızların üst sınırı
v_{maps_2}	: Ölçek parametresi için hızların üst sınırı
c_{1i}	: Bilişsel katsayı için alt sınır
c_{1f}	: Bilişsel katsayı için üst sınır
c_{2i}	: Sosyal katsayı için alt sınır
c_{2f}	: Sosyal katsayı için üst sınır
w_1	: Eylemsizlik parametresi için alt sınır
w_2	: Eylemsizlik parametresi için üst sınır
$maxitr$	: Maksimum yineleme (iterasyon) sayısı

Adım 2. Her bir parçacığın başlangıç pozisyon ve hızları belirlenir.

Her bir parçacığın pozisyonu ağın ağırlıklarından (w_{ij}) ve sırasıyla dendrit ve soma tabakalarında bulunan k ve θ parametrelerinden oluşmaktadır. Bunun yanında Huber'in kayıp fonksiyonu ölçek tahmin edicisi parametresi (c) parçacığın son pozisyonunu oluşturmaktadır. Tüm pozisyonların açık yapısı Şekil 5.1'de gösterilmektedir.



Şekil 5.1. Bir parçacığın yapısı

Bir parçacık toplam $d = 2NM + 4$ pozisyona sahiptir. Bunların, $N \times M$ tanesi ağırlıkları (w_{ij}), $N \times M + 1$ tanesi θ parametreleri, 2 tanesi ise k parametresi ve 1 tanesi de ölçek tahmin edicisi parametresidir (c). İlk $2NM + 3$ pozisyon için başlangıç değerleri (0,1) parametrelili ve son pozisyon için ise literatürdeki diğer çalışmalar göz önünde bulundurularak (6,10) parametrelili düzgün dağılımdan üretilir. Hızların başlangıç değerleri ise $(-v_{maps}, v_{maps})$ parametrelili düzgün dağılımdan üretilir.

Adım 3. Uygunluk fonksiyonu hesaplanır.

Ağın eğitimde uygunluk fonksiyonu olarak Huber'in kayıp fonksiyonu kullanılır. Bu aşamada i . parçacığın pozisyonları kullanılarak üretilen çıktı değerleri ve ölçek tahmin edicisinin parametresi kullanılarak Huber'in kayıp fonksiyonu uygunluk değeri olarak elde edilir. İlk olarak e_t , t . öğrenme örneği için hata değeri olmak üzere beta değeri Eşitlik (2) ile elde edilir.

$$e_t = d_t - o_t \quad (1)$$

$$\text{beta} = c \times \text{medyan}_t(e_t - \text{medyan}_t(e_t)) \quad (2)$$

Burada, d_t , t. öğrenme örneği için hedeflenen değer, o_t ise t. öğrenme örneği için çıktı değeridir. Huber'in hata değeri ise bu bilgiler kullanılarak Eşitlik 3'te verildiği gibi hesaplanabilir.

$$\tilde{e}_t = \begin{cases} e_t^2/2 & , \text{ Eğer } |e_t| \leq \text{beta} \\ \text{beta} |e_t - \text{beta}^2/2| & , \text{ Aksi Halde} \end{cases} \quad (3)$$

Buna göre i. parçacık için, uygunluk fonksiyonu olarak, Huber'in kayıp fonksiyonu Eşitlik (4) ile hesaplanabilir.

$$\text{fitness}_i = \sum_{t=1}^n \tilde{e}_t \quad (4)$$

Adım 4. Pbest ve Gbest belirlenir.

Pbest, ilgili parçacığın mevcut yinelemeler içinde en iyi bireysel performansına ait pozisyon değerlerini temsil ederken, Gbest ise tüm sürüde mevcut yinelemeler içinde en iyi performansa sahip parçacığın pozisyonlarını temsil eder. En iyi performansın ölçüsü en düşük değerli uygunluk değeridir.

Adım 5. Hızlar ve pozisyonlar güncellenir.

Hız ve pozisyonlar, bilişsel ve sosyal katsayılar ile eylemsizlik parametresine bağlı olarak güncellenebileceğinden, öncelikle bu değerlerin güncellenmesi Eşitlik (5), (6) ve (7)'de verildiği şekilde gerçekleştirilir.

$$c_1^t = (c_{1f} - c_{1i}) \frac{t}{\text{maxitr}} + c_{1i} \quad (5)$$

$$c_2^t = (c_{2f} - c_{2i}) \frac{t}{\text{maxitr}} + c_{2i} \quad (6)$$

$$w^t = (w_2 - w_1) \frac{\text{maxitr}-t}{\text{maxitr}} + w_1 \quad (7)$$

Böylece hız ve pozisyon güncellemeleri $y = 1, 2, \dots, \text{maxitr}$; $l = 1, 2, \dots, \text{pn}$; $r = 1, 2, \dots, d$ olmak üzere sırasıyla Eşitlik (9) ve (10) ile verilebilir.

$$V_{l,r}^{y+1} = [w^y \times V_{l,r}^y + c_1^y \times \text{rand}_1 \times (Pb_{l,r}^y - P_{l,r}^y) + c_2^y \times \text{rand}_2 \times (Pg_r^y - P_{l,r}^y)] \quad (8)$$

$$V_{l,r}^{y+1} = \min(\text{vmaps}, \max(-\text{vmaps}, V_{l,r}^{y+1})) \quad (9)$$

$$P_{i,r}^{y+1} = P_{i,r}^y + V_{i,r}^{y+1} \quad (10)$$

Burada,

$P_{l,r}^y$; yinci yinelemede linci parçacığın rinci pozisyonunu

$Pb_{l,r}^y$; yinci yinelemede linci parçacık için belirlenen Pbest'in rinci pozisyonunu

Pg_r^y ; yinci yinelemede linci parçacık için belirlenen Gbest'in rinci pozisyonunu temsil eder.

Adım 6. Durdurma koşulu kontrol edilir.

Eğer maksimum yineleme sayısına ulaşılmış ya da ardışık iki yinelemede elde edilen Gbest'lere ilişkin kayıp fonksiyon değerleri önceden belirlenmiş bir değerden daha küçük ise algoritma durdurulur. Bu durumda son yinelemede elde edilen Gbest'e ilişkin pozisyonlar optimal ağırlık ve parametre değerlerini oluşturacaktır. Aksi takdirde Adım 3'e

geri dönölerek yeni pozisyonlara baęlı olarak her bir parçacık için kayıp fonksiyonu hesaplanarak algoritma durdurma koşulu saęlanıncaya kadar sürdürölür.




BÖLÜM 6. UYGULAMA

Bu tez kapsamında D-YSA için önerilen dayanıklı öğrenme algoritmasının aykırı değer(ler) içeren ve içermeyen zaman serilerinin öngörülmesindeki performansı iki farklı gerçek hayat zaman serisinin analizi ile incelenmiştir. Bu zaman serileri, 1956 ve 1994 yılları arasında çeyreklik olarak gözlemlenen Avusturalya Bira Tüketim (AUST) zaman serisi ve 2010-2014 yılları arasındaki 5 yıla ilişkin günlük gözlemlenen Londra Borsası Endeks (FTSE-Financial Times Stock Exchange Index) zaman serileridir. Dayanıklı öğrenme algoritmasının öngörü yeteneği ilk olarak, öncelikle, aykırı değer(ler) içermeyen, orijinal zaman serisi üzerinden değerlendirilmiştir. Ayrıca ilgili zaman serisinde bulunan en yüksek değerli gözlemin 5 ve 10 katı alınarak üretilen aykırı değer(ler)in, belirli gözlemlerin yerine, orijinal zaman serisine enjekte edilmesiyle oluşturulan kirletilmiş zaman serileri de ele alınacaktır. Zaman serilerinin kirletme aşamasında enjekte edilen aykırı değer sayısı 1, 2 ve 3 olarak belirlenmekte ve böylece, her bir veri seti için, farklı sayı ve özellikte aykırı değer(ler) içeren 6 farklı zaman serisi çözümlemesi gerçekleştirilmektedir.

6.1. Avusturalya Bira Tüketim Zaman Serisi Çözümlemesi

Dayanıklı öğrenme algoritmasının öngörü yeteneği, ilk olarak, 153 gözlem içeren AUST zaman serisi üzerinde değerlendirilmiştir. Bu değerlendirme, 1 orijinal (Çözümleme 1) ve 6 adet aykırı değer ya da değerler içeren durum (Çözümleme 2-7) olmak üzere 7 farklı veri setinin çözümlenmesi ile gerçekleştirilmiştir. Tüm çözümlemelerde son 16 gözlem test kümesi olarak alınmış ve D-D-YSA için sinaptik tabaka birim sayısı, başka bir ifadeyle girdi sayısı, (s) ve dendrit sayısı (d) 2 ile 12 arasında değerler için çözümlemeler gerçekleştirilmiştir. Ayrıca, eğitim algoritması parametreleri ise aşağıda verildiği gibi belirlenmiştir.

p_n	: 30 (Parçacık sayısı)
v_{maps_1}	: 10 (Ağırlık ve ağ parametreleri için hızların üst sınırı)
v_{maps_2}	: 0.1 (Ölçek parametresi için hızların üst sınırı)
c_{1i}	: 1 (Bilişsel katsayı için alt sınır)
c_{1f}	: 2 (Bilişsel katsayı için üst sınır)
c_{2i}	: 1 (Sosyal katsayı için alt sınır)
c_{2f}	: 2 (Sosyal katsayı için üst sınır)
w_1	: 0.4 (Eylemsizlik parametresi için alt sınır)
w_2	: 0.9 (Eylemsizlik parametresi için üst sınır)
$maxitr$	: 100 (Maksimum yineleme sayısı)



Şekil 6.1. AUST zaman serisi

6.1.1. Çözümleme Orijinal AUST

D-YSA için önerilen dayanıklı eğitim algoritmasının orijinal AUST öngörüsündeki performansı, Winters'ın çarpımsal üstel düzleştirme (WMES) ve Mevsimsel otoregresif hareketli ortalamalar (SARIMA) olmak üzere 2 geleneksel zaman serisi yöntemi ve çok katmanlı yapay sinir ağı (ÇK-YSA), parçacık sürü optimizasyonu ile eğitilen çok katmanlı yapay sinir ağı (ÇK-YSA-PSO), tek çarpımsal sinir hücresine sahip yapay sinir ağı (TÇ-YSA), eğitimi parçacık sürü optimizasyonu ile gerçekleştirilen tek çarpımsal sinir hücresine sahip yapay sinir ağı (TÇ-YSA-PSO), radyal temelli yapay sinir ağı (RT-YSA), Elman yapay sinir ağı (E-YSA) ve dayanıklı bir öğrenme algoritmasına sahip tek çarpımsal sinir hücresine sahip yapay sinir ağı (D-TÇ-YSA) olmak üzere 7 farklı YSA modeli ile birlikte değerlendirilmiştir. Tüm bu alternatif YSA modelleri için de girdi ve gizli tabaka birim sayıları önerilen modele paralel olarak 2 ile 12 arasında değiştirilerek çözümlerler gerçekleştirildi.


Önerilen D-YSA için önerilen dayanıklı eğitim algoritması $s = 4$ ve $d = 7$ olduğu durum için gerçekleştirilen çözümlemede en iyi öngörü sonuçlarını üretmiştir. Orijinal AUST zaman serisinin analizine ilişkin sonuçlar öncelikle hata kareler ortalaması karekök (HKOK) ve ortalama mutlak yüzdelik hata (OMYH) kriterlerine göre değerlendirildi ve bulgular Tablo 6.1 ile özetlendi.

Tablo 6.1 incelendiğinde, önerilen dayanıklı öğrenim algoritmasına dayalı D-YSA'nın öngörü performansının diğer klasik ve YSA modellerine göre daha üstün olduğu, hem HKOK (16.3695) hem de OMYH (2.95%) hata kriterlerine göre söylenebilir. Önerilen dayanıklı modelin test kümesine ilişkin öngörülerini ile zaman serisine ait gözlemlerin yüksek uyumu ise Şekil 6.2'den açıkça görülmektedir. Ayrıca, bu uyum Şekil 6.3 ile verilen saçılım diyagramı ile de gözlemlenebilir. Böylesi bir saçılım grafiğinde, zaman serisinin test kümesine ilişkin gözlemleri ile öngörülerin bir doğru üzerinde ya da bu doğruya oldukça yakın olması öngörü performansının başarısının bir ölçüsü olarak değerlendirilebilir ki, Şekil


6.3, önerilen dayanıklı D-YSA'nın başarılı öngörü sonuçları ürettiğine işaret eden bu bulguları taşımaktadır.

Tablo 6.1. Orijinal AUST analiz sonuçları

Yöntem	HKOK	HKOK İçin Sıra	OMYH	OMYH İçin Sıra
SARIMA	47.0367	9	9.49%	9
WMES	53.3295	10	10.72%	11
ÇK-YSA	24.1052	5	4.76%	5
ÇK-YSA-PSO	44.7780	8	8.56%	8
TÇ-YSA	74.2551	11	9.83%	10
TÇ-YSA-PSO	26.7831	6	4.98%	6
RT-YSA	41.7000	7	6.86%	7
E-YSA	22.6581	4	4.36%	4
D-TÇ-YSA	17.7761	2	2.97%	2
D-YSA	17.8554	3	2.99%	3
Önerilen D-D-YSA	16.3609	1	2.95%	1



Şekil 6.2. Orijinal AUST zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.3. Orijinal AUST zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği

Önerilen D-D-YSA'nın aykırı değer(ler) içeren zaman serilerini öngörme performansı, bir başka bakış açısıyla bir zaman serisi öngörü aracı D-D-YSA'nın ele alınan zaman serisinde bulunabilecek aykırı değer ya da değerlerden nasıl ve ne ölçüde etkileneceği 6 farklı durum üzerinden incelenmiştir.


6.1.2. Çözümleme Kirlenmiş AUST – 5 Kat – Tek Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 5 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15. gözleminin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirlenmiş zaman serisinin çözülmesi sonucunda elde edilen bulgular Tablo 6.2'de özetlenmiştir.


Tablo 6.2. Kirletilmiş AUST (5 Kat – Tek Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	176.5654	70.4099	18.8008	18.5804
OMYH	38.27%	8.63%	3.15%	3.13%

Tablo 6.2 dikkate alındığında, 5 kat-tek aykırı değerle kirletilmiş AUST zaman serisi öngörüsünde, D-D-YSA'nın performansının diğer YSA modellerine göre daha üstün olduğu, hem HKOK (18.5804) hem de OMYH (3.13%) hata kriterlerine göre, söylenebilir. Bunun yanı sıra, orijinal AUST zaman serisi analiz sonuçları ile karşılaştırıldığında, önerilen D-D-YSA'nın diğer YSA modellerine göre aykırı değerden oldukça az etkilendiği ve halen tatmin edici öngörü sonuçları ürettiği görülür. Bu bulgular, önerilen dayanıklı modelin test kümesine ilişkin öngörülerini ile zaman serisine ait gözlemlerin yüksek uyumunu görselleştiren Şekil 6.4 ile de desteklenmektedir. Ayrıca, bu uyumun diğer bir kanıtı Şekil 6.5 ile verilen saçılım diyagramı ile de gözlemlenebilir ki bu diyagram ilgili gözlemler ile öngörülerin doğru üzerine oldukça yakın ikililer oluşturduğunu görselleştirerek bu uyuma bir kanıt sunmaktadır.



Şekil 6.4. Kirlenilmiş AUST (5 Kat – Tek Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.5. Kirlenilmiş AUST (5 Kat – Tek Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği


6.1.3. Çözümleme Kirlenmiş AUST – 5 Kat – İki Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 5 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15. ve 75. gözlemlerinin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirlenmiş zaman serisinin çözülmesi sonucunda elde edilen bulgular Tablo 6.3'te özetlenmiştir.


Tablo 6.3. Kirlenmiş AUST (5 Kat – İki Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	284.1976	79.0784	20.1621	16.5414
OMYH	63.20%	11.40%	3.26%	2.68%

Tablo 6.3 dikkate alındığında, 5 kat - iki aykırı değerle kirlenmiş AUST zaman serisi öngörüsünde, D-D-YSA'nın performansının diğer YSA modellerine göre daha üstün olduğu, hem HKOK (16.5414) hem de OMYH (2.68%) hata kriterlerine göre söylenebilir. Bunun yanı sıra, orijinal AUST zaman serisi analiz sonuçları ile karşılaştırıldığında, önerilen D-D-YSA'nın diğer YSA modellerine göre aykırı değerden hemen hemen hiç etkilenmediği ve yine tatmin edici ve rekabetçi öngörü sonuçları ürettiği görülür. Bu bulgular, önerilen dayanıklı modelin test kümesine ilişkin öngörülerini ile zaman serisine ait gözlemlerin yüksek uyumunu gösteren Şekil 6.6 ile de desteklenmektedir. Bu yüksek uyumun diğer bir kanıtı olarak, gözlemler ile öngörülerin bir doğru üzerine oldukça yakın noktalar oluşturduğunu görselleştiren ve Şekil 6.7 ile sunulan bir saçılım diyagramı verilebilir.



Şekil 6.6. Kirlenilmiş AUST (5 Kat – İki Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.7. Kirlenilmiş AUST (5 Kat – İki Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği


6.1.4. Çözümleme Kirlenilmiş AUST – 5 Kat – Üç Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 5 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15, 75 ve 120. gözlemlerinin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirlenilmiş zaman serisinin çözülmesi sonucunda elde edilen bulgular Tablo 6.4'te özetlenmiştir.


Tablo 6.4. Kirlenilmiş AUST (5 Kat – Üç Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	328.3296	67.8867	18.6250	18.7551
OMYH	72.55%	13.51%	2.94%	3.20%

Tablo 6.4 dikkate alındığında, 5 kat - üç aykırı değerle kirlenilmiş AUST zaman serisi öngörüsünde, D-D-YSA'nın performansının D-TÇSH-YSA dışında diğer YSA modellerine göre daha üstün olduğu, hem HKOK (18.7551) hem de OMYH (3.20%) hata kriterlerine göre, söylenebilir. Önerilen D-D-YSA'nın D-TÇSH-YSA'nın öngörü sonuçlarına oldukça yakın sonuçlar üretmesi, onu halen rekabet edebilir ve tatmin edici sonuçlar üreten bir öngörü aracı olarak kılmaktadır. Bunun yanı sıra, orijinal AUST zaman serisi analiz sonuçları ile karşılaştırıldığında, önerilen D-D-YSA'nın diğer tüm YSA modellerine göre aykırı değerden oldukça az etkilendiği görülür. Bu bulguların bir destekleyicisi olarak, önerilen dayanıklı modelin test kümesine ilişkin öngörülleri ile zaman serisine ait gözlemlerin yüksek uyumunu görselleştiren bir grafik Şekil 6.8 ile verilebilir. Bunun yanı sıra, Şekil 6.9 ile verilen saçılım grafiği de bu yüksek uyumun diğer bir kanıtı olarak sunulmaktadır.



Şekil 6.8. Kirlenmiş AUST (5 Kat – Üç Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.9. Kirlenmiş AUST (5 Kat – Üç Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği


6.1.5. Çözümleme Kirletilmiş AUST – 10 Kat – Tek Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 10 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15. gözleminin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirletilmiş zaman serisinin çözümü sonucunda elde edilen bulgular Tablo 6.5’te özetlenmiştir.


Tablo 6.5. Kirletilmiş AUST (10 Kat – Tek Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	188.1847	70.1409	18.4853	16.2590
OMYH	41.07%	10.12%	3.07%	2.88%

Tablo 6.5 incelendiğinde, 10 kat-tek aykırı değerle kirletilmiş AUST zaman serisi öngörüsünde, D-D-YSA’nın performansının diğer YSA modellerine göre daha üstün olduğu, hem HKOK (16.2590) hem de OMYH (2.88%) hata kriterlerine göre, söylenebilir. Bunun yanı sıra, orijinal AUST zaman serisi analiz sonuçları ile karşılaştırıldığında, önerilen D-D-YSA’nın diğer YSA modellerine göre aykırı değerden etkilenmediği ve halen üstün öngörü sonuçları ürettiği görülür. Bu bulgular, önerilen dayanıklı modelin test kümesine ilişkin öngörülleri ile zaman serisine ait gözlemlerin yüksek uyumunu görselleştiren Şekil 6.10 ile de desteklenmektedir. Ayrıca, bu yüksek uyum Şekil 6.11 ile verilen saçılım diyagramı ile de gözlemlenebilir.



Şekil 6.10. Kirlenmiş AUST (10 Kat – Tek Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.11. Kirlenmiş AUST (10 Kat – Tek Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği


6.1.6. Çözümleme Kirlenmiş AUST – 10 Kat – İki Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 10 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15. ve 75. gözlemlerinin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirlenmiş zaman serisinin çözülmesi sonucunda elde edilen bulgular Tablo 6.6’de özetlenmiştir.


Tablo 6.6. Kirlenmiş AUST (10 Kat – İki Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	224.7867	73.3807	19.3856	18.8324
OMYH	49.39%	15.30%	2.95%	2.73%

Tablo 6.6 ile özetlenen sonuçlar göstermektedir ki, 10 kat - iki aykırı değerle kirlenmiş AUST zaman serisi öngörüsünde, HKOK (18.8324) hata kriterlerine göre D-D-YSA’nın performansı diğer YSA modellerinin performanslarından daha üstündür. OMYH (2.73%) hata kriterlerine göre ise, D-TÇSH-YSA modeline çok yakın bir performans sergilediği görülmektedir. Bunun yanı sıra, orijinal AUST zaman serisi analiz sonuçları ile karşılaştırıldığında, önerilen D-D-YSA’nın diğer tüm YSA modellerine göre aykırı değerden oldukça az etkilendiği ve bu durumda da tatmin edici ve rekabetçi öngörü sonuçları ürettiği söylenebilir. Önerilen D-D-YSA’nın rekabetçi ve tatmin edici performansı, test kümesine ilişkin öngörüler ile zaman serisine ait gözlemlerin yüksek uyumunu görselleştiren Şekil 6.12 ile de kanıtlanabilir. Bu üstün performansın bir diğer gösterimi ise, gözlemler ile öngörülerin bir doğru üzerine oldukça yakın noktalar oluşturduğu ve Şekil 6.13 ile verilen saçılım diyagramıdır.



Şekil 6.12. Kirlenmiş AUST (10 Kat – İki Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.13. Kirlenmiş AUST (10 Kat – İki Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği


6.1.7. Çözümleme Kirlenmiş AUST – 10 Kat – Üç Aykırı Gözlem

AUST zaman serisine ait en büyük gözlemin 10 katı ile oluşturulan aykırı gözlemin, zaman serisinin 15, 75 ve 120. gözlemlerinin yerine veriye enjekte edilmesiyle oluşturulan aykırı değerli kirlenmiş zaman serisinin çözülmesi sonucunda elde edilen bulgular Tablo 6.7’de özetlenmiştir.


Tablo 6.7. Kirlenmiş AUST (10 Kat – Üç Aykırı) analiz sonuçları

Test verisi	ÇK-YSA	ÇK-YSA-PSO	D-TÇ-YSA	Önerilen D-D-YSA
HKOK	244.2329	104.9389	18.5871	18.5290
OMYH	53.47%	22.33%	2.88%	2.79%

Tablo 6.7 incelendiğinde, 10 kat - üç aykırı değerle kirlenmiş AUST zaman serisi öngörüsünde, D-D-YSA’nın performansının diğer tüm YSA modellerine göre daha üstün olduğu, hem HKOK (18.5290) hem de OMYH (2.79%) hata kriterlerine göre, söylenebilir. Önerilen dayanıklı D-D-YSA’nın performansının aykırı değerlerden oldukça az etkilenmesi, onu aykırı değerli zaman serilerinin öngörülmesinde de güvenilir, rekabet edebilir ve tatmin edici sonuçlar üreten bir öngörü aracı olarak kullanılabilir kılmaktadır. Bu bulgular, Şekil 6.14 ile verilen ve önerilen dayanıklı modelin test kümesine ilişkin öngörülleri ile zaman serisine ait gözlemlerin yüksek uyumunu görselleştiren bir grafik ile de desteklenmektedir. Ayrıca, Şekil 6.15 ile verilen saçılım grafiği de bu yüksek uyumun diğer bir kanıtı olarak sunulmaktadır.



Şekil 6.14. Kirlenmiş AUST (10 Kat – Üç Aykırı) test kümesine ilişkin öngörü ve gözlem değerleri



Şekil 6.15. Kirlenmiş AUST (10 Kat – Üç Aykırı) zaman serisi test kümesine ilişkin öngörü ve gözlem değerleri saçılım grafiği

Yukarıda bahsedilen bulgular ve bu bulgulara ilişkin sunulan tablo ve grafikler bir bütün olarak ele alındığında, önerilen D-D-YSA'nın orijinal AUST zaman serisi için etkin, rekabetçi ve tatmin edici sonuçlar üreten bir öngörü aracı olmasının yanı sıra, 6 farklı


özellikte kirlenmiş, aykırı değer ya da değerler içeren AUST zaman serileri için de güvenilir ve halen rekabetçi ve tatmin edici öngörü performansına sahip bir öngörü aracı olarak kullanılabileceği söylenebilir.

6.2. FTSE Zaman Serisi Çözümlemesi


D-D-YSA'nın performansının değerlendirilmesinde bir diğer aşama, 2010-2014 yıllarını içeren 5 farklı yıla ait ve günlük olarak gözlemlenen FTSE zaman serisinin analizidir. Bu analiz sürecinde orijinal FTSE zaman serisinin (Çözümleme 1) yanı sıra yine 6 farklı durumda oluşturulan kirlenmiş FTSE zaman serilerinin (Çözümleme 2-7) çözümü gerçekleştirilmiştir. İlgili yıllara ait FTSE zaman serileri sırasıyla 252, 251, 252, 253 ve 253 gözlemden oluşmaktadır ve bu veri setlerine ilişkin grafikler Şekil 6.16-6.20 ile verilmiştir. Çözümlemede kullanılan test kümesi gözlem sayıları ise her bir yıla ilişkin FTSE zaman serisi için 10 (son iki hafta), 20 (son dört hafta) ve 40 (son sekiz hafta) olmak üzere 3 farklı şekilde alınmıştır. Böylece her bir zaman serisi için $3 \times 1 = 3$ orijinal, $3 \times 6 = 18$ kirlenmiş olmak üzere 21 ve tüm FTSE zaman serileri düşünüldüğünde $3 \times 5 = 15$ orijinal ve $18 \times 5 = 90$ kirlenmiş olmak üzere toplamda 105 çözümleme gerçekleştirilmiştir. Tüm çözümlemelerde DNM-YSA için sinaptik tabaka birim sayısı, başka bir ifadeyle girdi sayısı, (s) ve dendrit sayısı (d) 2 ile 5 arasında alınmıştır. Ayrıca, eğitim algoritması parametreleri ise aşağıda verildiği gibi belirlenmiştir.

pn	: 30 (Parçacık sayısı)
vmaps ₁	: 100 (Ağırlık ve ağ parametreleri için hızların üst sınırı)
vmaps ₂	: 0.1 (Ölçek parametresi için hızların üst sınırı)
c _{1i}	: 1 (Bilişsel katsayı için alt sınır)
c _{1f}	: 2 (Bilişsel katsayı için üst sınır)
c _{2i}	: 1 (Sosyal katsayı için alt sınır)


c_{2f} : 2 (Sosyal katsayı için üst sınır)
 w_1 : 0.4 (Eylemsizlik parametresi için alt sınır)
 w_2 : 0.9 (Eylemsizlik parametresi için üst sınır)
maxitr : 100 (Maksimum yineleme sayısı)




Şekil 6.16. FTSE-2010 zaman serisi




Şekil 6.17. FTSE-2011 zaman serisi



Şekil 6.18. FTSE-2012 zaman serisi



Şekil 6.19. FTSE-2013 zaman serisi



Şekil 6.20. FTSE-2014 zaman serisi

D-D-YSA için önerilen dayanıklı eğitim algoritmasının FTSE zaman serilerinin öngörülmesindeki performansı aşağıda belirtilen 10 farklı YSA modeli ile birlikte değerlendirilmiştir. Bu YSA modellerinde 4'ü dayanıklı öğrenme algoritmasına ya da dayanıklı mimari yapıya sahip YSA modelleridir.

L-NL-YSA : Lineer ve lineer olmayan yapay sinir ağı (Yolcu, Egrioglu ve Aladag, 2013)

ÇK-YSA : Çok katmanlı yapay sinir ağı (Rumelhart DE, Hinton GE, 1986)

Md-YSA : Medyan nöron modele dayalı yapay sinir ağı (Aladag, Egrioglu ve Yolcu, 2015)

MdP-YSA : Medyan ve çarpımsal nöron modele dayalı yapay sinir ağı (Egrioglu ve ark., 2019)

PS-YSA : Çarpımsal (Pi) ve toplamsal (Sigma) nöron modele dayalı yapay sinir ağı (Plate, 2000)

R-YSA : Radyal temelli yapay sinir ağı (Broomhead, 1988)

TÇ-YSA : Tek çarpımsal nöron modele dayalı yapay sinir ağı (Yadav, Kalra ve John, 2007)

D-TÇ-YSA : Dayanıklı eğitim algoritmasına dayalı tek çarpımsal nöron model yapay sinir ağı (Yadav, Kalra ve John, 2007; Legenstein ve Maass, 2011)

TRM-YSA : Kırpılmış ortalama nöron modele dayalı yapay sinir ağı (Yolcu ve ark., 2015)

D-D-YSA : Dendrit nöron modele dayalı yapay sinir ağı (Koch, C, Poggio, T, Torre, 1983)

Tüm bu alternatif YSA modelleri için de girdi ve gizli tabaka birim sayıları önerilen modele paralel olarak 2 ile 5 arasında değiştirilerek çözümlerler gerçekleştirildi. Tüm orijinal ve kirletilmiş veri çözümlerlerini içeren analizlere ilişkin HKOK değeri ve her bir YSA'nın kirletilmiş veriler için ürettiği öngörü sonuçlarının orijinal veri için ürettikleri sonuçlara göre ne yönde değişim gösterdiğine ilişkin bulgular Tablo 6.8-6.17 ile özetlenmiştir. Önerilen D-D-YSA'nın FTSE zaman serseri çözümlerindeki performansı detaylı olarak ele alındığında aşağıdaki bulgulara ulaşılabilir.

2010 yılı orijinal veri için test kümesi gözlem sayısının 10 ve 40 olduğu durumda önerilen D-D-YSA, HKOK kriterine göre en üstün öngörü performansına sahipken (HKOK=31.3873; HKOK=52.6651), test kümesi gözlem sayısının 20 olduğu durumda ise üçüncü en iyi öngörü performansına sahiptir (HKOK=37.7129). FTSE2010 verisinin 5 kat ve tek aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının 20 olduğu durumda, orijinal verideki performansına göre 0.76% değişimle, aykırı gözlemden en az etkilenen YSA olarak en iyi performansı sergilerken (HKOK=37.9996), test kümesi gözlem sayısının 10 ve 40 olduğu durumda ise aykırı gözlemden diğer YSA modellerine göre nispeten daha fazla etkilenerek üçüncü en iyi performansa sahip olabilmektedir. FTSE2010 verisinin 5 kat ve iki aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının tüm farklı durumlarında en iyi performansı sergilerken, test kümesi gözlem sayısının 10 ve 20 olduğu durumda, orijinal verideki performansına göre aykırı değerlerden olumsuz şekilde en az etkilenen, test kümesi gözlem sayısının 40 olduğu durumda ise ikinci en az etkilenen YSA

olmuştur. FTSE2010 verisinin 5 kat ve üç aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının tüm farklı durumlarında hem en iyi performansı sergilemekte hem de orijinal verideki performansına göre aykırı değerlerden olumsuz şekilde en az etkilenen YSA olmuştur. FTSE2010 verisinin 10 kat ve tek aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının 20 ve 40 olduğu durumlarda, en üstün öngörü proforması sahip olmasının yanı sıra orijinal verideki performansına göre, aykırı gözlemden en az etkilenen YSA olduğu gözlemlenmiştir. Test kümesi gözlem sayısının 10 olduğu durumda ise hem öngörü performansı hem de aykırı değerlere karşı dayanıklılık bakımından ikinci olduğu gözlenmiştir. FTSE2010 verisinin 10 kat ve iki aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının tüm farklı durumlarında orijinal verideki öngörü performansına göre aykırı değerlerden olumsuz şekilde en az etkilenen YSA olarak, test kümesi gözlem sayısının 20 olduğu durumda orijinal veride gösterdiği en iyi üçüncü öngörü performansını ikinci sıraya taşıırken, diğer test kümeleri için en üstün öngörü performansa sahip olma özelliğini de korumuştur. FTSE2010 verisinin 10 kat ve üç aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının tüm farklı durumlarında hem en iyi performansı sergilemekte hem de orijinal verideki performansına göre aykırı değerlerden olumsuz şekilde en az etkilenen YSA olmuştur.

2011 yılı orijinal veri için test kümesi gözlem sayısının 40 olduğu durumda önerilen D-D-YSA, HKOK kriterine göre en üstün öngörü performansına sahipken (HKOK=65.8484), test kümesi gözlem sayısının 10 ve 20 olduğu durumda ise ikinci en iyi öngörü performansına sahiptir (HKOK=40.3531; HKOK=53.1080). FTSE2011 verisinin 5 kat ve tek aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının 10 ve 40 olduğu durumda orijinal verideki performansına göre, aykırı gözlemden olumsuz şekilde en az etkilenen, test kümesi gözlem sayısının 20 olduğu durumda ise ikinci en az etkilenen YSA olarak, test kümesi gözlem sayısının 10 ve 20 olduğu durumda en iyi öngörü performansını ele geçirmiş ve test kümesi gözlem sayısının 40 olduğu durumda ise en üstün öngörü performansına sahip olma özelliğini korumuştur. FTSE2011 verisinin 5 kat ve iki aykırı gözlemle kirletildiği durumda, test kümesi gözlem sayısının tüm farklı durumlarında orijinal verideki performansına göre aykırı değerlerden olumsuz şekilde en az etkilenen model olmuştur ve

böylece test kümesi gözlem sayısının yine tüm durumlarında en iyi öngörü performansını sergilemiştir. FTSE2010 verisinin 5 kat ve üç aykırı gözlemle kirletildiği durumda tıpkı 5 kat ve iki aykırı gözlemle kirletildiği durumda olduğu gibi test kümesi gözlem sayısının tüm farklı durumlarında hem öngörü performansı hem de aykırı değerlere olan duyarlılık bakımından diğer tüm YSA modellerine üstünlük sağlamıştır. FTSE2011 verisinin 10 kat aykırı gözlemle kirletildiği her üç durum için de benzer yorumlar yapılabilir. Yani her üç kirletme oranını içeren test kümesi gözlem sayısının tüm durumlarında önerilen model en üstün öngörü performansı sergilemesinin yanı sıra bir durum dışında tüm durumlarda aykırı gözlemlere daha az duyarlılık sergilemiştir ki bu durumda da en az duyarlı ikinci YSA modeli olarak göze çarpar.

2012 yılı orijinal veri için test kümesi gözlem sayısının her üç farklı durumunda da D-D-YSA, HKOK kriterine göre en üstün öngörü performansına sahip olmamasına rağmen en iyi öngörü performansı gösteren YSA modelleri ile kıyaslandığında rekabet edebilir bir öngörü aracı olarak kullanılabileceği görülmektedir. FTSE2012 verisinin 5 kat ve tek aykırı gözlemle kirletildiği durumda, önerilen D-D-YSA modelinin, test kümesi gözlem sayısının 10 ve 20 olduğu durumda orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı olduğu ve böylece öngörü performansını diğer YSA modelleri ile kıyaslandığında orijinal veri çözümleme sonuçlarına göre daha ileri taşıdığı ve öngörü performansını sırasıyla ikinci ve üçüncü sıraya taşıdığı gözlemlenmiştir. FTSE2012 verisinin 5 kat ve iki aykırı ve ayrıca 5 kat ve üç aykırı gözlemle kirletildiği durumlarda, test kümesi gözlem sayısı 10 ve 20 olduğunda önerilen YSA modelinin orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı YSA modeli olduğu ve böylece öngörü performansını birinci sıraya taşıdığı görülmektedir. FTSE2012 verisi için test kümesi gözlem sayısının 40 olduğu durumda her üç farklı kirletme oranı için de en üstün öngörü performansı ve aykırı değerlere karşı en az duyarlılığı sergileyememiş olmasına karşın, D-D-YSA halen rekabetçi bir öngörü aracı olma özelliğini korumaktadır. FTSE2012 verisinin 10 kat ve tek aykırı gözlemle kirletildiği durumda, önerilen D-D-YSA modelinin, test kümesi gözlem sayısının 10 olduğu durumda orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı olduğu ve böylece öngörü performansını birinci sıraya taşıdığı gözlemlenmiştir. Test kümesi gözlem

sayısının 20 ve 40 olduđu durumda ise öngörü performansını ikinci sıraya taşımıştır. FTSE2012 verisinin 10 kat ve iki aykırı ve ayrıca 10 kat ve üç aykırı gözlemle kirletildiđi durumlarda ise, test kümesi gözlem sayısının her üç durumunda da önerilen YSA modelinin orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı YSA modeli olduđu ve böylece öngörü performansını birinci sıraya taşıdığı görölmektedir.

2013 yılı orijinal veri için test kümesi gözlem sayısının 20 olduđu durumda önerilen D-D-YSA, HKOK kriterine göre en üstün öngörü performansına sahipken test kümesi gözlem sayısının 10 ve 40 olduđu durumlarda ikinci en üstün öngörü performansına sahip olup en üstün öngörü performansı gösteren D-YSA modeline çok yakın sonuçlar üretmiştir. FTSE2013 verisinin 5 kat ve tek aykırı ve ayrıca 5 kat ve üç aykırı gözlemle kirletildiđi durumda, önerilen D-D-YSA modelinin, test kümesi gözlem sayısının 20 olduđu durum dışında orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı olduđu ve dahası test kümesi gözlem sayısının her üç durumunda da öngörü performansı bakımından diğer tüm YSA modellerinden daha üstün öngörü performansları ortaya koyduđu görölmektedir. FTSE2013 verisinin 5 kat ve iki aykırı gözlemle kirletildiđi durumda ise, D-D-YSA hem aykırı değerlere duyarlılık hem de öngörü performansı bakımından en üstün model olarak öne çıkmaktadır. FTSE2013 verisinin kirletildiđi her üç durumda da önerilen D-D-YSA modelinin, test kümesi gözlem sayısının 10 ve 40 olduđu durumlarda orijinal verideki performansına göre, aykırı gözlemlere en az duyarlı olduđu ve böylece öngörü performansını birinci sıraya taşıdığı gözlemlenmiştir. Test kümesi gözlem sayısının 20 olduđu durumda ise FTSE2012 verisinin 10 kat ve iki aykırı ve ayrıca 10 kat ve üç aykırı gözlemle kirletildiđi durumlarda, önerilen YSA modelinin orijinal verideki performansına göre, aykırı gözlemlere ikinci en az duyarlı YSA modeli olmasına karşın öngörü performansı bakımından en üstün model olduđu ve ayrıca orijinal verinin 10 kat ve tek aykırı gözlemle kirletildiđi durumda ikinci en iyi öngörü performansına sahip olduđu görölmektedir.

2014 yılı orijinal veri için test kümesi gözlem sayısının her üç farklı durumunda da önerilen YSA modeli, HKOK kriterine göre en üstün öngörü performansına sahip olmamasına rağmen en iyi öngörü performansı gösteren YSA modelleri ile kıyaslandığında halen rekabet

edebilir bir öngörü aracı olarak kullanılabileceği görülmektedir. FTSE2014 verisinin 5 ve 10 kat ve tek, iki ve üç aykırı gözlemle kirletildiği her üç durumda da önerilen D-D-YSA modelinin, test kümesi gözlem sayısının 20 ve 40 olduğu durumda orijinal verideki performansına göre, aykırı gözlemlere olan az miktardaki duyarlılığı sayesinde öngörü performansını diğer YSA modellerinden daha ileri taşıyarak en üstün öngörü sonuçlarını ürettiği, test kümesi gözlem sayısının 10 olduğu durumda ise benzer şekilde her üç kirletme oranı için öngörü performansı bakımından diğer YSA modelleri ile rekabet edebilirlik özelliğini koruduğu gözlenmiştir.



Tablo 6.8. FTSE2010 orijinal ve kirlenmiş (5 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10			20			40						
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d				
Orijinal	L-NL-YSA	31.4096	2	4/5	38.8305	9	3/4	54.0420	7	3/2				
	CK-YSA	32.2458	7	5/2	39.4832	11	3/2	53.7846	6	2/2				
	Md-YSA	32.1644	5	2/3	38.7866	7	2/2	54.3673	10	2/4				
	MdP-YSA	32.2834	8	2/4	38.6920	6	5/2	53.2685	3	2/5				
	PS-YSA	32.5007	10	4/5	38.8004	8	2/3	53.3511	4	2/4				
	R-YSA	31.9216	4	4/4	36.4636	2	4/3	53.5412	5	2/4				
	TC-YSA	32.2160	6	5/5	38.9707	10	2/4	54.0867	9	2/5				
	D-TC-YSA	32.3464	9	5/5	38.6815	5	2/4	55.1226	11	5/3				
	TrM-YSA	32.8163	11	5/3	38.6494	4	2/5	54.0611	8	2/4				
	D-YSA	31.5439	3	5/4	36.3522	1	2/3	52.8475	2	5/2				
D-D-YSA	31.3873	1	3/2	37.7129	3	2/5	52.6651	1	2/5					
5 Kat	Tek Aykırı	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-YSA	33.9048	5	7.94%	9	39.7594	4	2.39%	2	55.5359	7	2.76%	4
		CK-YSA	32.9136	2	2.07%	1	40.4997	10	2.57%	3	55.3014	6	2.82%	5
		Md-YSA	34.0317	7	5.81%	5	39.8204	5	2.67%	4	56.0098	9	3.02%	6
		MdP-YSA	36.5674	11	13.27%	11	40.0517	6	3.51%	5	58.8473	10	10.47%	11
		PS-YSA	34.8433	9	7.21%	7	40.2767	8	3.80%	7	54.1964	1	1.58%	3
		R-YSA	33.3976	4	4.62%	4	39.2356	3	7.60%	10	56.0008	8	4.59%	9
		TC-YSA	34.7031	8	7.72%	8	40.4546	9	3.81%	8	54.6277	4	1.00%	1
		D-TC-YSA	35.8878	10	10.95%	10	42.0034	11	8.59%	11	58.9345	11	6.92%	10
		TrM-YSA	33.9648	6	3.50%	3	40.1054	7	3.77%	6	54.7628	5	1.30%	2
	D-YSA	32.4756	1	2.95%	2	38.0400	2	4.64%	9	54.4931	2	3.11%	7	
	D-D-YSA	33.2112	3	5.81%	6	37.9996	1	0.76%	1	54.6268	3	3.72%	8	
	İki Aykırı	L-NL-YSA	36.9101	10	17.51%	11	40.0242	5	3.07%	5	56.7350	8	4.98%	6
		CK-YSA	34.7244	4	7.69%	4	40.8103	8	3.36%	6	54.9042	2	2.08%	1
Md-YSA		35.6807	6	10.93%	6	41.3435	10	6.59%	9	58.0731	9	6.82%	9	
MdP-YSA		37.4812	11	16.10%	10	41.1000	9	6.22%	8	82.9499	11	55.72%	11	
PS-YSA		36.5038	9	12.32%	8	39.4506	3	1.68%	2	56.3372	5	5.60%	7	
R-YSA		33.4816	3	4.89%	2	40.0507	6	9.84%	11	56.5748	7	5.67%	8	
TC-YSA		35.8445	7	11.26%	7	40.0807	7	2.85%	4	56.3829	6	4.25%	4	
D-TC-YSA		36.4072	8	12.55%	9	42.4591	11	9.77%	10	59.7331	10	8.36%	10	
TrM-YSA		35.4877	5	8.14%	5	39.4865	4	2.17%	3	56.3215	4	4.18%	3	
D-YSA		33.3057	2	5.59%	3	37.9985	2	4.53%	7	55.3445	3	4.72%	5	
D-D-YSA	32.8510	1	4.66%	1	37.9984	1	0.76%	1	54.7110	1	3.88%	2		
Üç Aykırı	L-NL-YSA	43.1906	11	37.51%	11	43.1973	10	11.25%	9	58.9371	4	9.06%	5	
	CK-YSA	39.2719	8	21.79%	8	43.6427	11	10.53%	8	57.8544	2	7.57%	3	
	Md-YSA	35.9454	4	11.76%	4	41.0451	4	5.82%	4	58.3010	3	7.24%	2	
	MdP-YSA	42.7100	10	32.30%	10	43.1745	9	11.59%	10	82.9499	11	55.72%	11	
	PS-YSA	38.2910	6	17.82%	6	40.6626	3	4.80%	2	63.5013	10	19.03%	10	
	R-YSA	34.4737	3	7.99%	3	42.7105	8	17.13%	11	59.4107	6	10.96%	6	
	TC-YSA	39.2124	7	21.72%	7	41.6048	5	6.76%	5	61.6643	9	14.01%	9	
	D-TC-YSA	37.0217	5	14.45%	5	42.6441	7	10.24%	7	60.0050	7	8.86%	4	
	TrM-YSA	40.1661	9	22.40%	9	41.7429	6	8.00%	6	60.3841	8	11.70%	7	
	D-YSA	33.4671	2	6.10%	2	38.4186	2	5.68%	3	59.1089	5	11.85%	8	
D-D-YSA	33.2584	1	5.96%	1	38.0017	1	0.77%	1	54.6146	1	3.70%	1		

Tablo 6.9. FTSE2010 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10				20				40				
		HKOK	Sıra		s/d	HKOK	Sıra		s/d	HKOK	Sıra		s/d	
Orijinal	L-NL-YSA	31.4096	2		4/5	38.8305	9		3/4	54.0420	7		3/2	
	ÇK-YSA	32.2458	7		5/2	39.4832	11		3/2	53.7846	6		2/2	
	Md-YSA	32.1644	5		2/3	38.7866	7		2/2	54.3673	10		2/4	
	MdP-YSA	32.2834	8		2/4	38.6920	6		5/2	53.2685	3		2/5	
	PS-YSA	32.5007	10		4/5	38.8004	8		2/3	53.3511	4		2/4	
	R-YSA	31.9216	4		4/4	36.4636	2		4/3	53.5412	5		2/4	
	TÇ-YSA	32.2160	6		5/5	38.9707	10		2/4	54.0867	9		2/5	
	D-TÇ-YSA	32.3464	9		5/5	38.6815	5		2/4	55.1226	11		5/3	
	TrM-YSA	32.8163	11		5/3	38.6494	4		2/5	54.0611	8		2/4	
	D-YSA	31.5439	3		5/4	36.3522	1		2/3	52.8475	2		5/2	
	D-D-YSA	31.3873	1		3/2	37.7129	3		2/5	52.6651	1		2/5	
10 Kat		HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
	L-NL-YSA	37.2960	10	18.74%	10	40.3755	5	3.98%	4	57.4294	5	6.27%	5	
	ÇK-YSA	34.7083	5	7.64%	4	41.3417	6	4.71%	6	56.2751	4	4.63%	3	
	Md-YSA	36.4498	9	13.32%	9	42.6510	8	9.96%	8	60.1564	10	10.65%	10	
	MdP-YSA	39.3381	11	21.85%	11	42.4674	7	9.76%	7	82.9499	11	55.72%	11	
	PS-YSA	35.3616	6	8.80%	6	39.6455	3	2.18%	2	57.8814	6	8.49%	7	
	R-YSA	33.1697	1	3.91%	1	43.1792	10	18.42%	11	58.9420	8	10.09%	9	
	TÇ-YSA	34.5001	4	7.09%	3	43.9197	11	12.70%	10	58.8280	7	8.77%	8	
	D-TÇ-YSA	36.0558	8	11.47%	8	43.1268	9	11.49%	9	59.3291	9	7.63%	6	
	TrM-YSA	35.4880	7	8.14%	5	40.0791	4	3.70%	3	56.2283	3	4.01%	2	
	D-YSA	34.3990	3	9.05%	7	38.0453	2	4.66%	5	56.0041	2	5.97%	4	
	D-D-YSA	33.2643	2	5.98%	2	38.0004	1	0.76%	1	54.7219	1	3.91%	1	
10 Kat	İki Aykırı	L-NL-YSA	50.5200	11	60.84%	11	48.6911	11	25.39%	11	66.9641	8	23.91%	8
		ÇK-YSA	43.1212	8	33.73%	8	46.7713	10	18.46%	9	62.5017	4	16.21%	4
		Md-YSA	38.3268	5	19.16%	5	43.8283	8	13.00%	7	63.5867	5	16.96%	5
		MdP-YSA	45.2749	9	40.24%	9	42.8294	5	10.69%	5	71.2603	10	33.78%	10
		PS-YSA	43.0595	7	32.49%	7	41.0799	3	5.87%	3	71.4056	11	33.84%	11
		R-YSA	36.0198	3	12.84%	2	43.5926	7	19.55%	10	66.2767	7	23.79%	7
		TÇ-YSA	39.9929	6	24.14%	6	43.1760	6	10.79%	6	68.4610	9	26.58%	9
		D-TÇ-YSA	37.8832	4	17.12%	4	42.7348	4	10.48%	4	60.3910	3	9.56%	2
		TrM-YSA	46.5230	10	41.77%	10	44.2344	9	14.45%	8	64.0242	6	18.43%	6
		D-YSA	35.9874	2	14.09%	3	37.8248	1	4.05%	2	59.2878	2	12.19%	3
		D-D-YSA	33.2609	1	5.97%	1	38.0134	2	0.80%	1	54.6759	1	3.82%	1
	Üç Aykırı	L-NL-YSA	68.8525	11	119.21%	11	51.6251	10	32.95%	9	84.3294	9	56.04%	9
ÇK-YSA		44.7068	5	38.64%	5	49.0682	7	24.28%	6	71.7286	4	33.36%	4	
Md-YSA		50.4807	8	56.95%	8	44.2839	4	14.17%	4	77.0690	5	41.76%	5	
MdP-YSA		52.2474	9	61.84%	9	45.7925	5	18.35%	5	82.9499	8	55.72%	8	
PS-YSA		49.9144	6	53.58%	6	50.6217	9	30.47%	8	88.0639	10	65.06%	10	
R-YSA		41.9290	4	31.35%	4	48.8589	6	33.99%	10	78.3120	6	46.26%	6	
TÇ-YSA		49.9968	7	55.19%	7	49.2531	8	26.39%	7	98.7107	11	82.50%	11	
D-TÇ-YSA		38.3200	3	18.47%	3	42.9819	3	11.12%	2	62.4809	2	13.35%	2	
TrM-YSA		62.4126	10	90.19%	10	55.9869	11	44.86%	11	80.8130	7	49.48%	7	
D-YSA		33.4400	2	6.01%	2	41.0004	2	12.79%	3	68.2117	3	29.07%	3	
D-D-YSA		33.2643	1	5.98%	1	38.0134	1	0.80%	1	54.7219	1	3.91%	1	

Tablo 6.10. FTSE2011 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği											
		10			20			40					
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d			
Orijinal	L-NL-YSA	40.4747	3	2/4	55.4417	8	5/4	67.8332	8	2/5			
	ÇK-YSA	45.1569	8	3/2	54.3843	7	3/2	70.5921	10	4/4			
	Md-YSA	41.9183	6	5/2	53.6807	5	4/2	66.1659	4	4/2			
	MdP-YSA	41.7232	5	5/2	55.2500	7	5/2	66.9888	7	5/3			
	PS-YSA	46.8995	10	4/2	64.6970	11	3/2	72.3449	11	3/4			
	R-YSA	39.1941	1	4/4	53.4982	4	5/2	66.2098	5	3/4			
	TÇ-YSA	47.6880	11	2/3	53.4897	3	5/2	66.0115	3	5/5			
	D-TÇ-YSA	44.2912	7	4/5	60.0122	9	5/5	70.4380	9	4/4			
	TrM-YSA	45.8084	9	4/3	62.2729	10	5/4	66.2420	6	5/3			
	D-YSA	40.6724	4	5/4	53.1015	1	5/4	66.0096	2	5/5			
	D-D-YSA	40.3531	2	5/2	53.1080	2	4/3	65.8484	1	4/4			
5 Kat		HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra
Tek Aykırı	L-NL-YSA	41.3309	2	2.12%	4	58.3339	7	5.22%	10	69.0601	8	1.81%	5
	ÇK-YSA	53.4175	10	18.29%	10	62.6160	8	15.14%	11	73.1294	10	3.59%	9
	Md-YSA	42.5214	4	1.44%	3	53.7346	2	0.10%	1	66.7921	4	0.95%	3
	MdP-YSA	43.1624	6	3.45%	6	56.0708	6	1.49%	3	68.9099	6	2.87%	8
	PS-YSA	47.1376	9	0.51%	2	66.5408	11	2.85%	6	75.3608	11	4.17%	11
	R-YSA	42.0762	3	7.35%	9	55.9753	5	4.63%	8	68.9576	7	4.15%	10
	TÇ-YSA	61.0660	11	28.05%	11	55.0829	4	2.98%	7	66.5648	2	0.84%	2
	D-TÇ-YSA	47.0578	8	6.25%	8	63.1266	9	5.19%	9	72.0471	9	2.28%	6
	TrM-YSA	46.9559	7	2.50%	5	63.6246	10	2.17%	4	67.7883	5	2.33%	7
	D-YSA	43.1140	5	6.00%	7	54.2782	3	2.22%	5	66.7701	3	1.15%	4
	D-D-YSA	40.4126	1	0.15%	1	53.4146	1	0.58%	2	66.1618	1	0.48%	1
İki Aykırı	L-NL-YSA	43.4732	4	7.41%	6	58.4403	6	5.41%	7	69.4411	6	2.37%	3
	ÇK-YSA	53.7427	10	19.01%	10	63.1103	8	16.05%	11	74.6098	10	5.69%	9
	Md-YSA	44.7161	5	6.67%	5	55.8701	3	4.08%	4	68.6616	5	3.77%	6
	MdP-YSA	45.0570	6	7.99%	7	59.4093	7	7.53%	9	70.1543	7	4.73%	8
	PS-YSA	49.1891	9	4.88%	3	67.2392	11	3.93%	3	79.9089	11	10.46%	11
	R-YSA	43.1391	3	10.07%	9	57.7060	5	7.87%	10	70.1720	8	5.98%	10
	TÇ-YSA	61.4991	11	28.96%	11	56.1559	4	4.98%	6	68.3439	2	3.53%	5
	D-TÇ-YSA	47.9972	8	8.37%	8	63.5078	9	5.82%	8	71.2314	9	1.13%	2
	TrM-YSA	47.6655	7	4.05%	2	64.4868	10	3.56%	2	68.3574	3	3.19%	4
	D-YSA	42.9926	2	5.70%	4	55.5772	2	4.66%	5	68.6434	4	3.99%	7
	D-D-YSA	41.2258	1	2.16%	1	53.1454	1	0.07%	1	66.1622	1	0.48%	1
Üç Aykırı	L-NL-YSA	45.2595	4	11.82%	8	62.0971	7	12.00%	8	71.7177	6	5.73%	4
	ÇK-YSA	56.5780	10	25.29%	10	64.8175	9	19.18%	10	76.7030	10	8.66%	8
	Md-YSA	45.6846	5	8.98%	3	59.4278	3	10.71%	6	71.1650	4	7.56%	6
	MdP-YSA	46.3158	6	11.01%	6	60.0748	5	8.73%	4	73.2165	9	9.30%	9
	PS-YSA	51.5400	9	9.89%	4	87.1668	11	34.73%	11	81.0305	11	12.01%	11
	R-YSA	44.0669	2	12.43%	9	60.1209	6	12.38%	9	70.2173	3	6.05%	5
	TÇ-YSA	65.0310	11	36.37%	11	59.6826	4	11.58%	7	72.1565	7	9.31%	10
	D-TÇ-YSA	48.7318	7	10.03%	5	64.4462	8	7.39%	3	72.4334	8	2.83%	2
	TrM-YSA	49.2398	8	7.49%	2	68.1518	10	9.44%	5	71.4433	5	7.85%	7
	D-YSA	45.2384	3	11.23%	7	56.7876	2	6.94%	2	69.5602	2	5.38%	3
	D-D-YSA	40.9022	1	1.36%	1	53.3748	1	0.50%	1	66.1603	1	0.47%	1

Tablo 6.11. FTSE2011 orijinal ve kirlenmiş (10 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10				20				40				
		HKOK	Sıra		s/d	HKOK	Sıra		s/d	HKOK	Sıra		s/d	
Orijinal	L-NL-	40.4747	3		2/4	55.4417	8		5/4	67.8332	8		2/5	
	ÇK-YSA	45.1569	8		3/2	54.3843	6		3/2	70.5921	10		4/4	
	Md-YSA	41.9183	6		5/2	53.6807	5		4/2	66.1659	4		4/2	
	MdP-	41.7232	5		5/2	55.2500	7		5/2	66.9888	7		5/3	
	PS-YSA	46.8995	10		4/2	64.6970	11		3/2	72.3449	11		3/4	
	R-YSA	39.1941	1		4/4	53.4982	4		5/2	66.2098	5		3/4	
	TÇ-YSA	47.6880	11		2/3	53.4897	3		5/2	66.0115	3		5/5	
	D-TÇ-	44.2912	7		4/5	60.0122	9		5/5	70.4380	9		4/4	
	TrM-	45.8084	9		4/3	62.2729	10		5/4	66.2420	6		5/3	
	D-YSA	40.6724	4		5/4	53.1015	1		5/4	66.0096	2		5/5	
	D-D-	40.3531	2		5/2	53.1080	2		4/3	65.8484	1		4/4	
10 Kat	Tek Aykırı	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-	45.0016	5	11.18%	8	58.4598	6	5.44%	6	69.7253	6	2.79%	2
		ÇK-YSA	54.7196	10	21.18%	10	62.7967	9	15.47%	11	75.1776	10	6.50%	10
		Md-YSA	42.6857	3	1.83%	2	55.4840	2	3.36%	3	68.8984	4	4.13%	6
		MdP-	43.1199	4	3.35%	6	58.9115	7	6.63%	8	70.0504	7	4.57%	8
		PS-YSA	48.0671	8	2.49%	4	73.3489	11	13.37%	10	77.1082	11	6.58%	11
		R-YSA	45.6106	6	16.37%	9	56.8728	5	6.31%	7	70.1137	8	5.90%	9
		TÇ-YSA	61.8978	11	29.80%	11	56.0622	4	4.81%	5	69.0239	5	4.56%	7
		D-TÇ-	48.2619	9	8.97%	7	64.0350	10	6.70%	9	73.2986	9	4.06%	5
		TrM-	46.9559	7	2.50%	5	62.5237	8	0.40%	1	68.2726	2	3.07%	3
		D-YSA	41.5017	2	2.04%	3	55.6333	3	4.77%	4	68.4392	3	3.68%	4
		D-D-	40.5204	1	0.41%	1	53.4147	1	0.58%	2	66.1622	1	0.48%	1
	İki Aykırı	L-NL-	49.2452	7	21.67%	8	70.6399	11	27.41%	10	74.9756	6	10.53%	6
		ÇK-YSA	62.5237	10	38.46%	10	69.5845	10	27.95%	11	77.4853	7	9.76%	5
		Md-YSA	46.1053	4	9.99%	5	64.3306	5	19.84%	8	78.4550	8	18.57%	9
		MdP-	45.3907	3	8.79%	4	61.4082	3	11.15%	6	79.7038	10	18.98%	10
		PS-YSA	50.2163	9	7.07%	3	69.0079	9	6.66%	3	81.6056	11	12.80%	8
		R-YSA	49.7471	8	26.92%	9	65.6934	7	22.80%	9	74.4898	5	12.51%	7
		TÇ-YSA	71.9621	11	50.90%	11	61.9897	4	15.89%	7	79.6317	9	20.63%	11
		D-TÇ-	49.0248	6	10.69%	7	64.9340	6	8.20%	5	73.4083	4	4.22%	3
		TrM-	48.8154	5	6.56%	2	66.0971	8	6.14%	2	69.9627	3	5.62%	4
		D-YSA	44.9230	2	10.45%	6	57.1742	2	7.67%	4	66.9147	2	1.37%	2
		D-D-	41.2803	1	2.30%	1	53.1399	1	0.06%	1	66.1459	1	0.45%	1
	Üç Aykırı	L-NL-	53.1499	6	31.32%	7	68.0414	3	22.73%	3	83.5008	5	23.10%	6
		ÇK-YSA	75.0394	10	66.17%	10	82.3908	9	51.50%	10	96.8598	11	37.21%	8
		Md-YSA	54.0414	7	28.92%	6	79.4696	6	48.04%	8	96.7757	10	46.26%	11
		MdP-	58.9138	9	41.20%	9	83.0074	11	50.24%	9	90.0467	7	34.42%	7
		PS-YSA	52.2235	5	11.35%	4	80.7494	8	24.81%	4	85.0065	6	17.50%	4
		R-YSA	54.8332	8	39.90%	8	72.0671	5	34.71%	7	77.5559	3	17.14%	3
		TÇ-YSA	86.5515	11	81.50%	11	82.5759	10	54.38%	11	95.3631	9	44.46%	10
		D-TÇ-	50.5479	4	14.13%	5	66.3431	2	10.55%	2	74.8267	2	6.23%	2
		TrM-	49.2051	3	7.42%	3	79.6365	7	27.88%	5	92.0608	8	38.98%	9
		D-YSA	42.3782	2	4.19%	2	68.8314	4	29.62%	6	80.1642	4	21.44%	5
		D-D-	41.0718	1	1.78%	1	53.4148	1	0.58%	1	66.1620	1	0.48%	1

Tablo 6.12. FTSE2012 orijinal ve kirlenmiş (5 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10			20			40						
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d				
Orijinal	L-NL-	19.0516	11	4/3	16.2880	11	5/2	35.7101	6	4/4				
	ÇK-YSA	18.6945	9	3/4	16.1506	9	3/4	35.5415	5	3/4				
	Md-YSA	18.5624	8	3/5	15.6624	3	5/4	35.0555	3	4/5				
	MdP-YSA	18.0454	5	5/4	15.4230	2	5/5	35.9417	7	4/4				
	PS-YSA	17.5527	2	5/4	15.3681	1	5/5	34.3466	1	5/4				
	R-YSA	18.2136	7	3/2	15.7547	5	5/2	35.9515	8	5/5				
	TÇ-YSA	18.1355	6	4/5	16.1661	10	4/4	36.8855	11	5/3				
	D-TÇ-	17.8061	3	4/3	16.0416	7	5/2	36.4192	10	3/5				
	TrM-YSA	18.8041	10	3/2	16.1228	8	3/3	36.1970	9	4/4				
	D-YSA	16.7820	1	3/3	15.7235	4	5/4	34.7903	2	3/3				
	D-D-YSA	18.0384	4	3/3	15.9027	6	5/2	35.4134	4	3/2				
5 Kat	Tek Aykırı	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-	20.7926	11	9.14%	9	17.5954	9	8.03%	8	38.1324	10	6.78%	11
		ÇK-YSA	19.6544	8	5.13%	4	17.7658	10	10.00%	10	36.7457	5	3.39%	5
		Md-YSA	20.2974	9	9.35%	10	15.7598	1	0.62%	2	35.6638	1	1.74%	2
		MdP-YSA	19.3553	6	7.26%	7	18.0505	11	17.04%	11	37.2472	9	3.63%	6
		PS-YSA	18.7449	4	6.79%	5	16.7648	7	9.09%	9	36.4391	2	6.09%	10
		R-YSA	19.5659	7	7.42%	8	15.8815	2	0.80%	3	36.8409	7	2.47%	4
		TÇ-YSA	20.5583	10	13.36%	11	17.1275	8	5.95%	7	38.6656	11	4.83%	8
		D-TÇ-	18.6689	3	4.85%	3	16.3623	5	2.00%	4	36.7484	6	0.90%	1
		TrM-YSA	19.1920	5	2.06%	2	16.5711	6	2.78%	5	36.8564	8	1.82%	3
		D-YSA	17.9941	1	7.22%	6	16.1974	4	3.01%	6	36.6823	3	5.44%	9
	D-D-YSA	18.3858	2	1.93%	1	15.9169	3	0.09%	1	36.7267	4	3.71%	7	
İki Aykırı	L-NL-	23.0911	8	21.20%	7	17.6772	8	8.53%	7	39.3414	11	10.17%	10	
	ÇK-YSA	23.7098	9	26.83%	8	18.3685	10	13.73%	9	37.9051	7	6.65%	8	
	Md-YSA	21.5970	6	16.35%	5	16.5093	4	5.41%	5	35.9974	1	2.69%	3	
	MdP-YSA	19.5843	3	8.53%	3	17.2394	6	11.78%	8	38.3529	9	6.71%	9	
	PS-YSA	22.4791	7	28.07%	10	18.2868	9	18.99%	10	38.2397	8	11.33%	11	
	R-YSA	21.1671	5	16.22%	4	16.1318	2	2.39%	2	36.8749	5	2.57%	2	
	TÇ-YSA	25.4567	11	40.37%	11	20.1493	11	24.64%	11	38.7684	10	5.10%	7	
	D-TÇ-	19.0412	2	6.94%	2	16.6851	5	4.01%	4	36.6091	4	0.52%	1	
	TrM-YSA	23.9776	10	27.51%	9	17.3145	7	7.39%	6	37.6095	6	3.90%	5	
	D-YSA	19.9061	4	18.62%	6	16.2422	3	3.30%	3	36.3823	2	4.58%	6	
	D-D-YSA	18.4699	1	2.39%	1	15.9241	1	0.13%	1	36.5494	3	3.21%	4	
Üç Aykırı	L-NL-	25.6264	8	34.51%	7	19.6992	7	20.94%	7	41.1046	11	15.11%	10	
	ÇK-YSA	27.0573	10	44.73%	10	20.5992	8	27.54%	8	40.1623	6	13.00%	9	
	Md-YSA	23.5386	6	26.81%	5	17.1469	4	9.48%	5	37.6383	3	7.37%	4	
	MdP-YSA	20.6336	3	14.34%	3	18.2365	6	18.24%	6	40.2591	7	12.01%	7	
	PS-YSA	22.7566	5	29.65%	6	20.7915	9	35.29%	10	40.4265	8	17.70%	11	
	R-YSA	21.1978	4	16.38%	4	17.1606	5	8.92%	4	37.7192	4	4.92%	3	
	TÇ-YSA	28.3085	11	56.09%	11	22.7749	11	40.88%	11	40.7605	10	10.51%	6	
	D-TÇ-	18.7046	2	5.05%	2	16.5808	2	3.36%	2	36.6746	1	0.70%	1	
	TrM-YSA	26.3202	9	39.97%	8	21.2066	10	31.53%	9	40.6938	9	12.42%	8	
	D-YSA	24.0076	7	43.06%	9	17.0418	3	8.38%	3	37.9312	5	9.03%	5	
	D-D-YSA	18.4429	1	2.24%	1	15.9241	1	0.13%	1	36.8542	2	4.07%	2	

Tablo 6.13. FTSE2012 orijinal ve kirlenmiş (10 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10				20				40				
		HKOK	Sıra		s/d	HKOK	Sıra		s/d	HKOK	Sıra		s/d	
Orijinal	L-NL-YSA	19.0516	11		4/3	16.2880	11		5/2	35.7101	6		4/4	
	ÇK-YSA	18.6945	9		3/4	16.1506	9		3/4	35.5415	5		3/4	
	Md-YSA	18.5624	8		3/5	15.6624	3		5/4	35.0555	3		4/5	
	MdP-YSA	18.0454	5		5/4	15.4230	2		5/5	35.9417	7		4/4	
	PS-YSA	17.5527	2		5/4	15.3681	1		5/5	34.3466	1		5/4	
	R-YSA	18.2136	7		3/2	15.7547	5		5/2	35.9515	8		5/5	
	TÇ-YSA	18.1355	6		4/5	16.1661	10		4/4	36.8855	11		5/3	
	D-TÇ-YSA	17.8061	3		4/3	16.0416	7		5/2	36.4192	10		3/5	
	TrM-YSA	18.8041	10		3/2	16.1228	8		3/3	36.1970	9		4/4	
	D-YSA	16.7820	1		3/3	15.7235	4		5/4	34.7903	2		3/3	
	D-D-YSA	18.0384	4		3/3	15.9027	6		5/2	35.4134	4		3/2	
10 Kat		HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
	L-NL-YSA	20.8593	10	9.49%	6	17.4315	9	7.02%	8	42.6059	11	19.31%	11	
	ÇK-YSA	21.7967	11	16.59%	11	17.5812	10	8.86%	10	38.0239	7	6.98%	8	
	Md-YSA	20.5434	7	10.67%	8	15.8308	1	1.08%	2	36.1426	1	3.10%	2	
	MdP-YSA	19.4652	6	7.87%	4	16.3058	5	5.72%	7	37.9617	6	5.62%	6	
	PS-YSA	19.3247	5	10.10%	7	18.0501	11	17.45%	11	38.4419	9	11.92%	10	
	R-YSA	19.2884	4	5.90%	2	16.0976	3	2.18%	4	37.1359	3	3.29%	3	
	TÇ-YSA	20.8054	9	14.72%	10	16.8750	7	4.39%	6	38.3256	8	3.90%	4	
	D-TÇ-YSA	18.8964	2	6.12%	3	16.3840	6	2.13%	3	37.4491	4	2.83%	1	
	TrM-YSA	20.5538	8	9.31%	5	17.2999	8	7.30%	9	38.4766	10	6.30%	7	
	D-YSA	18.9926	3	13.17%	9	16.2031	4	3.05%	5	37.8333	5	8.75%	9	
	D-D-YSA	18.4988	1	2.55%	1	15.9241	2	0.13%	1	36.8142	2	3.96%	5	
	İki Ayrık	L-NL-YSA	25.9822	6	36.38%	6	22.1162	7	35.78%	6	49.3691	11	38.25%	11
		ÇK-YSA	30.4122	8	62.68%	8	26.1545	9	61.94%	9	43.7921	9	23.21%	9
		Md-YSA	27.5760	7	48.56%	7	17.6878	3	12.93%	3	39.3250	3	12.18%	4
		MdP-YSA	21.9924	4	21.87%	4	28.5242	11	84.95%	11	41.8555	6	16.45%	6
		PS-YSA	49.2955	11	180.84%	11	21.6945	6	41.17%	7	44.7521	10	30.30%	10
		R-YSA	21.8216	3	19.81%	3	18.3568	4	16.52%	4	39.9384	5	11.09%	3
		TÇ-YSA	33.4317	10	84.34%	10	26.2381	10	62.30%	10	43.3612	7	17.56%	7
		D-TÇ-YSA	18.7416	2	5.25%	2	16.6143	2	3.57%	2	37.7444	2	3.64%	2
		TrM-YSA	31.2333	9	66.10%	9	25.7553	8	59.74%	8	43.6672	8	20.64%	8
		D-YSA	22.2729	5	32.72%	5	18.4283	5	17.20%	5	39.8678	4	14.59%	5
		D-D-YSA	18.3370	1	1.66%	1	15.9240	1	0.13%	1	36.6562	1	3.51%	1
	Üç Ayrık	L-NL-YSA	34.6623	7	81.94%	7	26.8518	5	64.86%	5	54.0933	10	51.48%	10
		ÇK-YSA	41.4401	11	121.67%	10	35.6833	10	120.94%	10	52.1736	7	46.80%	7
		Md-YSA	32.8289	6	76.86%	6	22.0970	4	41.08%	4	45.7467	5	30.50%	5
		MdP-YSA	25.7738	5	42.83%	5	29.0730	8	88.50%	8	47.0524	6	30.91%	6
		PS-YSA	39.1801	9	123.21%	11	27.2089	6	77.05%	7	53.2446	9	55.02%	11
		R-YSA	23.0523	4	26.57%	4	21.1233	3	34.08%	3	41.7490	3	16.13%	3
		TÇ-YSA	39.0169	8	115.14%	9	32.2490	9	99.49%	9	55.4050	11	50.21%	9
		D-TÇ-YSA	18.8389	2	5.80%	2	16.7218	2	4.24%	2	38.1071	2	4.63%	2
		TrM-YSA	39.5873	10	110.52%	8	37.6068	11	133.25%	11	53.2001	8	46.97%	8
		D-YSA	20.7755	3	23.80%	3	27.7020	7	76.18%	6	42.4311	4	21.96%	4
		D-D-YSA	18.4795	1	2.45%	1	15.9131	1	0.07%	1	36.8565	1	4.07%	1

Tablo 6.14. FTSE2013 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10			20			40						
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d				
Orijinal	L-NL-YSA	48.5849	8	5/3	45.4083	8	2/5	39.9737	9	3/2				
	ÇK-YSA	48.6955	10	3/3	45.4418	9	5/5	39.9822	10	2/2				
	Md-YSA	47.6280	6	3/2	44.9664	7	5/3	39.7398	5	5/2				
	MdP-YSA	47.5980	5	2/5	43.9541	3	4/4	39.6526	3	3/4				
	PS-YSA	47.1394	4	3/5	45.5532	10	4/3	39.7837	7	2/5				
	R-YSA	46.7936	3	5/2	44.8970	6	4/4	39.7631	6	5/4				
	TÇ-YSA	49.2691	11	3/5	44.8753	5	4/4	39.8478	8	4/5				
	D-TÇ-	48.6220	9	3/3	44.8627	4	4/2	39.6861	4	5/2				
	TrM-YSA	48.5779	7	3/3	45.8443	11	4/2	40.1241	11	2/4				
	D-YSA	44.9409	1	5/5	43.1340	2	4/5	39.3741	1	5/5				
D-D-YSA	45.5871	2	5/4	43.0454	1	4/3	39.4878	2	3/3					
5 Kat	Tek Aykırı	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-YSA	49.3000	4	1.47%	2	47.3801	8	4.34%	6	42.4075	8	6.09%	8
		ÇK-YSA	50.6506	7	4.02%	5	46.7815	7	2.95%	5	41.0665	5	2.71%	4
		Md-YSA	49.2743	3	3.46%	4	45.9438	4	2.17%	3	40.8578	3	2.81%	5
		MdP-YSA	224.0367	11	370.68%	11	55.7184	9	26.76%	10	42.4479	9	7.05%	9
		PS-YSA	50.2874	6	6.68%	9	59.4919	11	30.60%	11	41.7877	7	5.04%	7
		R-YSA	50.7145	8	8.38%	10	46.0914	5	2.66%	4	43.9544	10	10.54%	10
		TÇ-YSA	51.8312	10	5.20%	8	56.1797	10	25.19%	9	61.8392	11	55.19%	11
		D-TÇ-	51.0290	9	4.95%	7	45.8033	3	2.10%	2	41.4932	6	4.55%	6
		TrM-YSA	50.0530	5	3.04%	3	46.5616	6	1.56%	1	40.9809	4	2.14%	3
		D-YSA	46.8116	2	4.16%	6	45.3398	2	5.11%	8	39.8596	2	1.23%	2
		D-D-YSA	46.1063	1	1.14%	1	45.2146	1	5.04%	7	39.8482	1	0.91%	1
	İki Aykırı	L-NL-YSA	51.1221	7	5.22%	7	48.5694	10	6.96%	9	42.1600	5	5.47%	3
		ÇK-YSA	52.2990	10	7.40%	10	48.0376	7	5.71%	7	44.1701	10	10.47%	10
		Md-YSA	50.5697	5	6.18%	8	46.8996	5	4.30%	5	43.8454	7	10.33%	9
		MdP-YSA	224.0367	11	370.68%	11	53.4344	11	21.57%	11	42.3599	6	6.83%	6
		PS-YSA	48.7471	4	3.41%	2	48.1014	9	5.59%	6	44.6176	11	12.15%	11
		R-YSA	48.6345	3	3.93%	3	45.9727	4	2.40%	3	42.0673	4	5.79%	5
		TÇ-YSA	51.7963	8	5.13%	5	48.0667	8	7.11%	10	43.8936	8	10.15%	8
		D-TÇ-	52.1401	9	7.24%	9	45.8583	2	2.22%	2	41.8575	3	5.47%	4
		TrM-YSA	50.7249	6	4.42%	4	47.7780	6	4.22%	4	43.9385	9	9.51%	7
		D-YSA	47.2878	2	5.22%	6	45.9618	3	6.56%	8	41.3067	2	4.91%	2
		D-D-YSA	45.8972	1	0.68%	1	43.6054	1	1.30%	1	39.8508	1	0.92%	1
	Üç Aykırı	L-NL-YSA	52.1473	8	7.33%	7	50.0974	7	10.33%	7	47.5276	8	18.90%	7
		ÇK-YSA	53.1421	10	9.13%	10	50.9444	9	12.11%	8	47.7631	9	19.46%	8
		Md-YSA	50.0121	4	5.01%	5	47.9143	6	6.56%	6	46.3588	5	16.66%	5
		MdP-YSA	70.1601	11	47.40%	11	51.9852	11	18.27%	11	47.4901	7	19.77%	9
		PS-YSA	49.5251	3	5.06%	6	51.4004	10	12.84%	10	48.3015	10	21.41%	10
		R-YSA	50.5151	6	7.95%	8	46.3362	4	3.21%	3	42.6094	4	7.16%	4
		TÇ-YSA	51.1055	7	3.73%	3	50.5193	8	12.58%	9	48.4866	11	21.68%	11
		D-TÇ-	52.6428	9	8.27%	9	46.1214	3	2.81%	2	41.9821	3	5.79%	2
		TrM-YSA	50.2135	5	3.37%	2	47.0276	5	2.58%	1	47.1273	6	17.45%	6
		D-YSA	46.7219	2	3.96%	4	45.6197	2	5.76%	5	41.7635	2	6.07%	3
		D-D-YSA	45.9681	1	0.84%	1	45.5180	1	5.74%	4	39.8354	1	0.88%	1

Tablo 6.15. FTSE2013 orijinal ve kirletilmiş (10 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10				20				40				
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d				
Orijinal	L-NL-YSA	48.5849	8	5/3	45.408	8	2/5	39.973	9	3/2				
	ÇK-YSA	48.6955	10	3/3	45.441	9	5/5	39.982	10	2/2				
	Md-YSA	47.6280	6	3/2	44.966	7	5/3	39.739	5	5/2				
	MdP-YSA	47.5980	5	2/5	43.954	3	4/4	39.652	3	3/4				
	PS-YSA	47.1394	4	3/5	45.553	10	4/3	39.783	7	2/5				
	R-YSA	46.7936	3	5/2	44.897	6	4/4	39.763	6	5/4				
	TÇ-YSA	49.2691	11	3/5	44.875	5	4/4	39.847	8	4/5				
	D-TÇ-YSA	48.6220	9	3/3	44.862	4	4/2	39.686	4	5/2				
	TrM-YSA	48.5779	7	3/3	45.844	11	4/2	40.124	11	2/4				
	D-YSA	44.9409	1	5/5	43.134	2	4/5	39.374	1	5/5				
	D-D-YSA	45.5871	2	5/4	43.045	1	4/3	39.487	2	3/3				
10 Kat	Tek Aykırı	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-YSA	52.2594	7	7.56%	5	46.160	5	1.66%	1	49.219	10	23.13%	10
		ÇK-YSA	52.0651	6	6.92%	7	48.252	7	6.19%	8	43.937	6	9.89%	6
		Md-YSA	58.2433	8	22.29%	4	45.904	4	2.09%	2	44.761	7	12.64%	7
		MdP-YSA	224.0367	11	370.68%	11	77.838	11	77.09%	11	47.490	9	19.77%	9
		PS-YSA	49.7991	3	5.64%	10	62.401	10	36.99%	10	46.716	8	17.43%	8
		R-YSA	210.9599	10	350.83%	6	47.345	6	5.45%	5	42.358	4	6.53%	4
		TÇ-YSA	59.0327	9	19.82%	9	56.278	9	25.41%	9	57.881	11	45.26%	11
		D-TÇ-YSA	51.8727	5	6.69%	3	45.841	3	2.18%	3	41.973	3	5.76%	3
		TrM-YSA	51.5313	4	6.08%	8	48.599	8	6.01%	6	43.490	5	8.39%	5
		D-YSA	47.1636	2	4.95%	2	44.817	1	3.90%	4	39.912	2	1.37%	2
	D-D-YSA	46.1027	1	1.13%	1	45.660	2	6.07%	7	39.846	1	0.91%	1	
	İki Aykırı	L-NL-YSA	50.4195	3	3.78%	2	50.552	5	11.33%	5	52.469	7	31.26%	7
		ÇK-YSA	57.7699	10	18.63%	10	54.971	9	20.97%	9	53.883	8	34.77%	8
		Md-YSA	56.0765	8	17.74%	8	53.487	7	18.95%	7	54.564	9	37.31%	9
		MdP-YSA	62.2249	11	30.73%	11	58.389	11	32.84%	11	50.699	5	27.86%	5
		PS-YSA	51.0900	4	8.38%	5	54.718	8	20.12%	8	55.739	10	40.11%	10
		R-YSA	51.8835	5	10.88%	6	49.844	3	11.02%	4	47.763	4	20.12%	4
		TÇ-YSA	54.9924	7	11.62%	7	55.638	10	23.99%	10	71.608	11	79.70%	11
		D-TÇ-YSA	52.0052	6	6.96%	3	46.168	2	2.91%	1	42.066	2	6.00%	2
		TrM-YSA	57.3515	9	18.06%	9	49.933	4	8.92%	3	51.473	6	28.29%	6
		D-YSA	48.1301	2	7.10%	4	50.882	6	17.96%	6	46.964	3	19.28%	3
		D-D-YSA	46.4456	1	1.88%	1	45.660	1	6.07%	2	39.821	1	0.85%	1
	Üç Aykırı	L-NL-YSA	53.8544	6	10.85%	5	58.594	6	29.04%	6	60.593	6	51.58%	6
		ÇK-YSA	58.0323	7	19.17%	7	64.756	10	42.50%	10	66.735	9	66.91%	9
		Md-YSA	58.2922	8	22.39%	9	51.153	4	13.76%	4	52.294	4	31.59%	4
		MdP-YSA	104.1231	11	118.75%	11	58.958	7	34.14%	7	65.650	8	65.56%	8
		PS-YSA	53.4567	5	13.40%	6	63.743	9	39.93%	9	70.827	11	78.03%	11
		R-YSA	82.9327	10	77.23%	10	55.694	5	24.05%	5	56.316	5	41.63%	5
		TÇ-YSA	60.1099	9	22.00%	8	67.079	11	49.48%	11	70.006	10	75.68%	10
		D-TÇ-YSA	52.8924	4	8.78%	4	46.027	2	2.60%	1	42.766	2	7.76%	2
		TrM-YSA	51.9743	3	6.99%	2	50.068	3	9.21%	3	64.466	7	60.67%	7
		D-YSA	48.3825	2	7.66%	3	58.961	8	36.69%	8	49.437	3	25.56%	3
		D-D-YSA	46.0998	1	1.12%	1	45.868	1	6.56%	2	39.608	1	0.31%	1


Tablo 6.16. FTSE2014 orijinal ve kirletilmiş (5 kat) veri analiz sonuçları

Durum	Yöntem	Test Kümesi Genişliği												
		10			20			40						
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d				
Orijinal	L-NL-YSA	59.6425	2	3/2	74.3192	2	2/4	59.2592	1	5/4				
	ÇK-YSA	60.9573	4	2/4	79.8660	7	4/3	61.7078	6	4/4				
	Md-YSA	59.9361	3	2/4	75.8450	3	5/4	62.2902	10	3/3				
	MdP-YSA	76.2321	9	2/5	82.2600	11	2/3	63.2815	11	2/3				
	PS-YSA	61.4235	6	2/3	80.1860	8	4/2	61.9639	9	5/2				
	R-YSA	68.5561	8	5/5	78.6870	5	4/2	61.0732	4	3/4				
	TÇ-YSA	76.6356	10	2/5	80.2881	10	4/3	61.7838	7	5/3				
	D-TÇ-YSA	77.6762	11	2/4	79.7005	6	5/5	61.4975	5	5/4				
	TrM-YSA	66.5524	7	2/5	80.2165	9	4/5	61.7962	8	4/3				
	D-YSA	58.2269	1	2/5	72.2373	1	4/5	59.5605	3	2/4				
D-D-YSA	61.1748	5	3/3	76.4216	4	2/3	59.4208	2	4/5					
5 Kat	Tek Ayrık	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	
		L-NL-YSA	70.5075	4	18.22%	10	82.2514	4	10.67%	10	62.7136	3	5.83%	11
		ÇK-YSA	71.1523	5	16.72%	9	82.6723	8	3.51%	5	63.2498	8	2.50%	6
		Md-YSA	65.1695	2	8.73%	6	82.6314	7	8.95%	9	65.5115	11	5.17%	10
		MdP-YSA	228.4453	11	199.67%	11	88.4479	11	7.52%	8	64.7629	10	2.34%	5
		PS-YSA	71.2271	7	15.96%	8	83.6197	10	4.28%	7	63.0800	6	1.80%	1
		R-YSA	72.4572	8	5.69%	3	81.7964	3	3.95%	6	62.8375	4	2.89%	8
		TÇ-YSA	82.1895	10	7.25%	5	83.0082	9	3.39%	3	62.9045	5	1.81%	2
		D-TÇ-YSA	79.5363	9	2.39%	1	82.4407	6	3.44%	4	63.8517	9	3.83%	9
		TrM-YSA	71.2112	6	7.00%	4	82.2632	5	2.55%	2	63.1651	7	2.22%	3
	D-YSA	61.0883	1	4.91%	2	81.2703	2	12.50%	11	60.9463	2	2.33%	4	
	D-D-YSA	68.0023	3	11.16%	7	77.9498	1	2.00%	1	60.9409	1	2.56%	7	
İki Ayrık	L-NL-YSA	67.3706	3	12.96%	8	82.4645	6	10.96%	9	62.9475	5	6.22%	10	
	ÇK-YSA	69.2182	5	13.55%	9	81.0820	4	1.52%	1	62.5700	4	1.40%	2	
	Md-YSA	70.1645	6	17.07%	10	79.5464	2	4.88%	8	64.2122	10	3.09%	6	
	MdP-YSA	228.4453	11	199.67%	11	93.5717	11	13.75%	11	67.8065	11	7.15%	11	
	PS-YSA	68.6936	4	11.84%	7	83.5758	10	4.23%	6	63.3896	6	2.30%	3	
	R-YSA	73.1350	8	6.68%	4	82.2720	5	4.56%	7	63.5262	8	4.02%	7	
	TÇ-YSA	79.9694	10	4.35%	2	83.5730	9	4.09%	5	63.4768	7	2.74%	4	
	D-TÇ-YSA	79.9662	9	2.95%	1	82.9267	7	4.05%	4	64.1090	9	4.25%	8	
	TrM-YSA	71.8529	7	7.96%	5	83.3234	8	3.87%	3	62.1228	2	0.53%	1	
	D-YSA	62.9373	1	8.09%	6	80.9513	3	12.06%	10	62.2448	3	4.51%	9	
D-D-YSA	65.1003	2	6.42%	3	77.6738	1	1.64%	2	61.0851	1	2.80%	5		
Üç Ayrık	L-NL-YSA	64.9124	3	8.84%	8	84.0977	7	13.16%	9	65.0616	7	9.79%	10	
	ÇK-YSA	66.8997	5	9.75%	9	83.2884	5	4.29%	2	64.2974	4	4.20%	3	
	Md-YSA	67.1690	6	12.07%	10	82.1789	2	8.35%	8	66.2887	10	6.42%	9	
	MdP-YSA	228.4453	11	199.67%	11	101.6202	11	23.54%	11	73.9428	11	16.85%	11	
	PS-YSA	65.8389	4	7.19%	6	85.9561	10	7.20%	7	65.6182	9	5.90%	6	
	R-YSA	73.0127	8	6.50%	5	83.1101	4	5.62%	4	62.9170	2	3.02%	1	
	TÇ-YSA	77.1691	9	0.70%	1	85.5333	9	6.53%	6	65.5093	8	6.03%	7	
	D-TÇ-YSA	80.1176	10	3.14%	3	83.2911	6	4.51%	3	65.0357	6	5.75%	5	
	TrM-YSA	67.2249	7	1.01%	2	84.8912	8	5.83%	5	65.0047	5	5.19%	4	
	D-YSA	62.9124	1	8.05%	7	82.3768	3	14.04%	10	63.3380	3	6.34%	8	
D-D-YSA	63.7520	2	4.21%	4	77.6738	1	1.64%	1	61.6249	1	3.71%	2		

Tablo 6.17. FTSE2014 orijinal ve kirlenmiş (10 kat) veri analiz sonuçları


Durum	Yöntem	Test Kümesi Genişliği											
		10				20				40			
		HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d	HKOK	Sıra	s/d
Orijinal	L-NL-YSA	59.6425	2	3/2	74.3192	2	2/4	59.2592	1	5/4			
	ÇK-YSA	60.9573	4	2/4	79.8660	7	4/3	61.7078	6	4/4			
	Md-YSA	59.9361	3	2/4	75.8450	3	5/4	62.2902	10	3/3			
	MdP-YSA	76.2321	9	2/5	82.2600	11	2/3	63.2815	11	2/3			
	PS-YSA	61.4235	6	2/3	80.1860	8	4/2	61.9639	9	5/2			
	R-YSA	68.5561	8	5/5	78.6870	5	4/2	61.0732	4	3/4			
	TÇ-YSA	76.6356	10	2/5	80.2881	10	4/3	61.7838	7	5/3			
	D-TÇ-YSA	77.6762	11	2/4	79.7005	6	5/5	61.4975	5	5/4			
	TrM-YSA	66.5524	7	2/5	80.2165	9	4/5	61.7962	8	4/3			
	D-YSA	58.2269	1	2/5	72.2373	1	4/5	59.5605	3	2/4			
	D-D-YSA	61.1748	5	3/3	76.4216	4	2/3	59.4208	2	4/5			
5 Kat		HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra	HKOK	Sıra	Değişim	Sıra
	L-NL-YSA	66.9474	5	12.25%	10	82.3826	2	10.85%	10	63.4248	4	7.03%	10
	ÇK-YSA	64.1048	3	5.16%	5	84.4719	8	5.77%	6	64.2974	9	4.20%	8
	Md-YSA	62.8113	2	4.80%	3	83.6441	7	10.28%	8	67.8360	11	8.90%	11
	MdP-YSA	228.4453	11	199.67%	11	90.9404	11	10.55%	9	64.5146	10	1.95%	1
	PS-YSA	67.4795	6	9.86%	9	84.9103	10	5.89%	7	64.1397	7	3.51%	3
	R-YSA	73.8202	8	7.68%	8	82.6869	3	5.08%	4	63.3515	3	3.73%	6
	TÇ-YSA	78.4552	9	2.37%	1	84.6611	9	5.45%	5	64.2153	8	3.94%	7
	D-TÇ-YSA	80.0387	10	3.04%	2	83.0564	6	4.21%	3	63.7731	6	3.70%	5
	TrM-YSA	70.0169	7	5.21%	6	82.8277	4	3.26%	1	63.6999	5	3.08%	2
	D-YSA	61.3566	1	5.37%	7	82.9191	5	14.79%	11	62.9738	2	5.73%	9
	D-D-YSA	64.3132	4	5.13%	4	79.4092	1	3.91%	2	61.5632	1	3.61%	4
	L-NL-YSA	64.2688	6	7.76%	9	85.9164	6	15.60%	10	66.8380	5	12.79%	10
	ÇK-YSA	62.0506	2	1.79%	2	88.4163	9	10.71%	7	67.5071	8	9.40%	8
	Md-YSA	63.5392	3	6.01%	6	85.7854	5	13.11%	9	67.4087	7	8.22%	5
	MdP-YSA	228.4453	11	199.67%	11	92.6411	11	12.62%	8	69.1630	11	9.29%	7
	PS-YSA	64.2398	5	4.59%	4	88.6666	10	10.58%	6	67.2246	6	8.49%	6
	R-YSA	79.1166	9	15.40%	10	84.7207	3	7.67%	3	64.0616	2	4.89%	2
	TÇ-YSA	77.2268	8	0.77%	1	88.2243	8	9.88%	5	65.8380	4	6.56%	4
	D-TÇ-YSA	81.0260	10	4.31%	3	83.8570	2	5.22%	2	64.6263	3	5.09%	3
	TrM-YSA	71.2229	7	7.02%	8	87.1937	7	8.70%	4	68.5843	10	10.98%	9
	D-YSA	61.8335	1	6.19%	7	84.7846	4	17.37%	11	68.2073	9	14.52%	11
	D-D-YSA	64.0960	4	4.78%	5	79.7666	1	4.38%	1	60.4047	1	1.66%	1
	L-NL-YSA	63.0177	3	5.66%	3	92.8901	5	24.99%	10	74.8176	6	26.25%	11
	ÇK-YSA	63.4606	4	4.11%	2	95.5756	9	19.67%	6	76.5069	10	23.98%	10
	Md-YSA	61.2179	1	2.14%	1	92.9168	6	22.51%	8	68.9178	4	10.64%	4
	MdP-YSA	179.3633	11	135.29%	11	118.9813	11	44.64%	11	77.7220	11	22.82%	8
	PS-YSA	65.8175	6	7.15%	7	96.0043	10	19.73%	7	75.1802	8	21.33%	6
	R-YSA	80.5842	8	17.54%	10	86.4488	3	9.86%	3	66.8971	3	9.54%	3
	TÇ-YSA	81.7731	9	6.70%	6	94.7334	8	17.99%	5	74.8792	7	21.20%	5
	D-TÇ-YSA	82.3028	10	5.96%	4	84.0601	2	5.47%	2	65.9103	2	7.18%	2
	TrM-YSA	71.9921	7	8.17%	9	93.3719	7	16.40%	4	75.6645	9	22.44%	7
	D-YSA	62.9724	2	8.15%	8	89.9694	4	24.55%	9	73.5916	5	23.56%	9
	D-D-YSA	65.1792	5	6.55%	5	78.9543	1	3.31%	1	60.8494	1	2.40%	1

Önerilen D-D-YSA modelinin orijinal ve kirletilmiş FTSE zaman serisi verileri için performansının karşılaştırmalı bir değerlendirmesi, hem tüm durumlarda modelin gösterdiği öngörü performansı hem de aykırı değerlere olan duyarlılık bakımından diğer YSA modelleri içindeki sıralaması dikkate alınarak gerçekleştirilebilir. Bu amaçla öngörü performansları ile ilgili sıralamalara ilişkin grafikler Şekil 6.21-6.27 ile verilebilir.




Şekil 6.21. Orijinal FTSE çözümleri D-D-YSA performans değerlendirmesi

Şekil 6.21 ele alındığında, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin 5 orijinal veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 4'ünde (26.67%), en üstün öngörü sonuçları üretirken, 5'inde (33.33%) en iyi ikinci, 1'inde (6.67%) ise en iyi üçüncü performansa sahip olduğu gözlenmiştir.




Şekil 6.22. Beş kat-tek aykırı FTSE çözümlmeleri D-D-YSA performans değeriendirmeesi

Şekil 6.22 ele alındığında, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan tek aykırı değeri kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümllemenin 9'unda (60.00%) en üstün öngörü sonuçları üretirken, 1'inde (6.67%) en iyi ikinci, 4'ünde (26.67%) ise en iyi üçüncü performansa sahip olduğu gözlenmiştir.




Şekil 6.23. Beş kat-iki aykırı FTSE çözümlmeleri D-D-YSA performans değeriendirmeesi

Şekil 6.23 incelendiğinde, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan iki aykırı değeri kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümllemenin 13'ünde (86.67%) en üstün öngörü sonuçları üretirken, birer çözümlmede (6.67%) ise en iyi ikinci ve en iyi üçüncü performansa sahip olduğu gözlenmiştir.



Şekil 6.24. Beş kat-üç aykırı FTSE çözümlmeleri D-D-YSA performans değeriendirmesi


Şekil 6.24 ile sunulan bilgiler doğrultusunda, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan üç aykırı değeri kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlmenin 13'ünde (86.67%) en üstün öngörü sonuçları üretirken, 2 çözümlmede (13.33%) ise en iyi ikinci performansa sahip olduğu söylenebilir.



Şekil 6.25. On kat-teş aykırı FTSE çözümlmeleri D-D-YSA performans değeriendirmesi


Şekil 6.25 dikkate alındığında, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan tek aykırı değeri kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlmenin 10'unda (66.67%)

en üstün öngörü sonuçları üretirken, 4'ünde (26.67%) en iyi ikinci, 1'inde (26.67%) ise en iyi dördüncü performansa sahip olduğu gözlenmiştir.



Şekil 6.26. On kat-iki aykırı FTSE çözümleri D-D-YSA performans değerlendirmesi


Şekil 6.26 incelendiğinde, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan iki aykırı değerle kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 13'ünde (86.67%) en üstün öngörü sonuçları üretirken, birer çözümlemeye (6.67%) ise en iyi ikinci ve en iyi üçüncü performansa sahip olduğu gözlenmiştir.



Şekil 6.27. On kat-üç aykırı FTSE çözümleri D-D-YSA performans değerlendirmesi


Şekil 6.27 ile sunulan bilgiler doğrultusunda, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan üç aykırı değerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 14'ünde (93.33%) en üstün öngörü sonuçları üretirken, 1 çözümlemede (6.67%) ise en iyi beşinci performansa sahip olduğu söylenebilir.

Kirlenmiş FTSE zaman serisi verilerinin çözümlerinde, önerilen D-D-YSA modelinin aykırı değerlere olan duyarlılığı bakımından değerlendirilmesi amacıyla diğer YSA modelleri içindeki sıralamasına ilişkin grafikler ise Şekil 6.28-6.36 ile verilebilir.




Şekil 6.28. Beş kat-tek aykırı FTSE çözümleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi

Şekil 6.28 ele alındığında, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan tek aykırı değerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 8'inde (53.33%) en düşük duyarlılığa sahipken, 1'inde (6.67%) en düşük ikinci duyarlılığa sahip olduğu gözlenmiştir.




Şekil 6.29. Beş kat-iki aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değeri

Şekil 6.29 incelendiğinde, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan iki aykırı değerle kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 10'unda (66.67%) aykırı değerlere en düşük duyarlılığı gösterirken, 2 çözümlemelerde (13.33%) en düşük ikinci ve 1 çözümlemelerde (6.67%) ise en düşük üçüncü duyarlılığa sahip olduğu görülmektedir.




Şekil 6.30. Beş kat-üç aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değeri

Şekil 6.30 ile sunulan bilgiler doğrultusunda, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan üç aykırı değerle kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 11'inde (73.33%) aykırı değerlere en düşük duyarlılığı gösterirken, 2 çözümlemelerde (13.33%) ise en düşük ikinci duyarlılığa sahip olduğu söylenebilir.



Şekil 6.31. Beş kat aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değeri


Önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 5 katından oluşan aykırı değerlerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 45 analiz 29’unda (64.44%) aykırı değerlere en düşük duyarlılığı gösterirken, 5 çözümlemede (11.11%) en düşük ikinci ve 1 çözümlemede (2.22%) ise en düşük üçüncü duyarlılığa sahip olduğu Şekil 6.31 deki veriler ile gözlenmiştir.



Şekil 6.32. On kat-tek aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değeri


Şekil 6.32 incelendiğinde, önerilen YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan tek aykırı değerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 8’inde (53.33%) en düşük

duyarlılığa sahipken, 3'ünde (20.00%) en düşük ikinci duyarlılığa sahip olduğu gözlenmiştir.




Şekil 6.33. On kat-iki aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi

Şekil 6.33 ele alındığında, önerilen dayanıklı YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan iki aykırı değerle kirletilmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 13'ünde (86.67%) aykırı değerlere en düşük duyarlılığı gösterirken, 1 çözümlemede (6.67%) ise en düşük ikinci duyarlılığa sahip olduğu görülmektedir.




Şekil 6.34. On kat-üç aykırı FTSE çözümlmeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi

Şekil 6.34 ile verilen bilgiler ışığında, önerilen D-D-YSA modelinin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan üç aykırı değerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 15 çözümlemenin 13'ünde (86.67%) aykırı değerlere en düşük duyarlılığı gösterirken, 1 çözümlemede (6.67%) ise en düşük ikinci duyarlılığa sahip olduğu söylenebilir.



Şekil 6.35. On kat aykırı FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi

Önerilen dayanıklı modelin, FTSE zaman serisine ilişkin maksimum gözlemin 10 katından oluşan aykırı değerlerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 45 analizin 34'ünde (75.56%) aykırı değerlere en düşük duyarlılığı gösterirken, 5 çözümlemede (11.11%) ise en düşük ikinci duyarlılığa sahip olduğu Şekil 6.35 ile verilen bilgiler ışığında söylenebilir.



Şekil 6.36. Kirlenmiş FTSE çözümlemeleri D-D-YSA aykırı değerlere duyarlılık değerlendirmesi

Ayrıca, FTSE zaman serisine ilişkin maksimum gözlemin 5 ve 10 katından oluşan aykırı değerlerle kirlenmiş 5 veri setinin üç farklı test kümesi gözlem sayısı ile gerçekleştirilen toplam 90 analiz dikkate alındığında; önerilen dayanıklı YSA modelinin bu analizlerin 64'ünde (71.11%) aykırı değerlere en düşük duyarlılığı gösterirken, 9 analiz (10.00%) için ise en düşük ikinci duyarlılığa sahip olduğu Şekil 6.36 ile verilen bilgiler ışığında söylenebilir.



BÖLÜM 7. SONUÇLAR VE TARTIŞMA

Birçok alanda karar vericilerin karşılaştığı zaman serisi öngörü problemleri için farklı çözümleme ve öngörü araçları geliştirmek amacıyla birçok bilimsel çalışma ortaya konmuştur. Bu çalışmalarla ortaya konan çözümleme ve öngörü araçları istatistiksel yaklaşımlara dayalı olasılıksal modeller ve bulanık küme teorisine ve bazı hesaplamalı yaklaşımlara dayalı olasılıksal olmayan modeller olmak üzere iki grup altında incelenebilir. Olasılıksal modeller son yıllara kadar ve hatta günümüzde dahi zaman serisi problemlerinde yaygın bir şekilde kullanılmalarına karşın, bazı katı varsayımlar gerektirmeleri dolayısıyla oluşan sınırlılıklar nedeniyle kimi zaman serisi öngörü problemlerinde yeterli ve güvenilir sonuçlar üretememektedirler. Bu noktada oluşan boşluk literatürde, olasılıksal modellerin gereksinim duyduğu katı varsayımları içermeyen, olasılıksal olmayan farklı öngörü araçları ile doldurulmaya çalışılmıştır. Yapay sinir ağları da olasılıksal olmayan ve hesaplamalı yaklaşımlara dayalı birer öngörü aracı olarak son yıllarda etkin bir şekilde kullanılmaktadır. Farklı nöron yapılarına sahip YSA arasında, dallantılı (dendrit) YSA'ları hem toplamsal hem de çarpımsal birleştirme fonksiyonlarını içeren nöron modellerini kullanan YSA'lardır. D-YSA'nın özellikle toplamsal birleştirme fonksiyonunu yanında çarpımsal birleştirme fonksiyonunu da mimari yapısında bulundurması, öngörülmesi amaçlanan zaman serisi bünyesinde bulunabilecek ve zaman serisinin genel karakteristiğini yansıtmayan aykırı değerlerden olumsuz etkilenmesine ve böylece tatmin edici bir öngörü performansı ortaya koymamasına neden olabilir.

Bu tez kapsamında, literatürde ilk olarak, D-YSA eğitiminde Huber'in kayıp fonksiyonunun uygunluk fonksiyonu olarak kullanıldığı bir dayanıklı öğrenme algoritması önerilmiştir. Dayanıklı öğrenme algoritmasının yinelemeli süreci, bir yapay zekâ optimizasyon algoritması olan PSO tarafından gerçekleştirilmektedir ki bu özelliği literatürde bir ilktir.

Tez kapsamında önerilen dayanıklı D-YSA'nın performansının değerlendirilmesi amacıyla öncelikle 153 gözlem içeren AUST zaman serisi hem kirletilmemiş hem de farklı oran ve

sayılardaki aykırı değerlerle kirletilmiş olarak çözümlenmiş ve elde edilen bulgular, aralarında dayanıklı öğrenme algoritmalarına da sahip olan farklı YSA modelleri ve bazı klasik zaman serisi öngörü modelleri ile elde edilen çözümleme sonuçları ile birlikte değerlendirilmiştir. AUST zaman serisinin hem orijinal hem de kirletilmiş çözümlemelerinde elde edilen bulgular, önerilen D-D-YSA öngörü modelinin literatürde mevcut diğer bazı YSA ve klasik zaman serisi öngörü modellerine göre daha üstün öngörü sonuçları ürettiği gözlenmiştir. Ayrıca önerilen D-D-YSA modelinin AUST zaman serisi çözümlemesinde aykırı değerlerden olumsuz yönde hemen hemen hiç etkilenmediği ve orijinal zaman serisinin çözümlenmesindeki öngörü performansını koruduğu gözlenmiştir.

D-D-YSA'nın performansının değerlendirilmesinde bir diğer aşama, 2010-2014 yıllarını içeren 5 farklı yıla ait ve günlük olarak gözlemlenen FTSE zaman serisinin hem kirletilmemiş hem de kirletilmiş durumlarda analizidir. 90'ı kirletilmiş durumlar için olmak üzere toplam 105 farklı çözümlemenin sonuçları literatürde bulunan ve bazıları dayanıklı öğrenme algoritmalarına ve bazıları da dayanıklı mimari yapılara sahip farklı YSA modelleri tarafından ortaya konan öngörü performansları ile birlikte değerlendirilmiş ve önerilen dayanıklı eğitim algoritması parçacık sürü optimizasyonu tarafından gerçekleştirilen D-D-YSA öngörü modelinin orijinal FTSE zaman serisi çözümlemelerinde tatmin edici ve rekabetçi öngörü sonuçları üretmesinin yanı sıra kirletilmiş FTSE zaman serisi verileri için de, aykırı değerlerden olumsuz yönde hemen hemen hiç ya da az miktarda etkilenecek orijinal durumda ürettiği tatmin edici öngörü sonuçlarını koruduğu gözlemlenmiştir.

Tüm bu bulgular ışığında, önerilen D-D-YSA öngörü modelinin hem aykırı değer içeren hem de aykırı değer içermeyen zaman serilerinin analizinde tatmin edici öngörü sonuçları üretebileceği ve diğer bazı klasik zaman serisi yöntemleri ve YSA modelleri ile kıyaslandığında rekabetçi bir öngörü aracı olarak kullanılabileceği sonucunda varılmıştır.

Gelecek çalışmalarda, D-YSA modelinin farklı yapay zekâ optimizasyon algoritmaları ile eğitildiği ve farklı dayanıklı kayıp fonksiyonlarının kullanıldığı dayanıklı eğitim

algoritmaları ile eğitiminin gerçekleştirildiği durumlarda göstereceği öngörü performansları araştırılabilir.



KAYNAKÇA

- Abbott, L. , Regehr, W.G. 2004. Synaptic computation. *Nature* 431(7010): 796–803.
- Aladağ C.H., Eğrioğlu E., Yolcu U. 2010. Forecast combination by using artificial neural Networks. *Neural Process Letters*,32(3): 269–276.
- Aladağ C.H., Yolcu, U., Eğrioğlu, E. 2014. Robust multilayer neural network based on median neuron model. *Neural Computing and Applications*. 24: 945-956.
- Andrews D.F. 1974. A robust method for multiple linear regression. *Technometrics*. 16: 523–531.
- Basu M., H. T. K. 1999. Learning behavior of single neuron classifiers onlinearly separable or nonseparable inputs. In *IEEE LICNN'99*.
- Broomhead, D. 1988. Multivariable functional interpolation and adaptive networks. *Complex Systems*. 2: 321–355.
- Cazé, R. D. , Jarvis, S. , Foust, A. J. , Schultz, S. R. 2017. Dendrites enable a robust mechanism for neuronal stimulus selectivity. *Neural Comput.* 29(9): 2511–2527.
- Chen, D. S. , Jain, R. C. 1994. A Robust Back Propagation Learning Algorithm for Function Approximation. *IEEE Transactions on Neural Networks*. 5(3): 467–479.
- Chen, W. 2017. Using a single dendritic neuron to forecast tourist arrivals to Japan. *IEICE Transactions on Information and Systems*. E100D(1): 190–202.
- Chuang C.C., Su S.F., H. C. C. 2000. The annealing robust backpropagation learning algorithm. *IEEE Trans. Neural Networks*. 11(5): 1067-1077.
- Connor, J. T., Martin, R. D. , Atlas, L. E. 1994. Recurrent Neural Networks and Robust Time Series Prediction. *IEEE Transactions on Neural Networks*. 5(2): 240–254.
- Destexhe, A. , Marder, E. 2004. Plasticity in single neuron and circuit computations. *Nature*. 431(7010): 789–795.
- Doyle, J. , Zhou, K. 1998. *Essencial of Robust Control*. October. 43(10): 1480–1484.
- Egrioglu, E. , Yolcu, U. 2015. A New Adaptive Network Based Fuzzy Inference System for Time Series Forecasting. *Aloy Journal of Soft Computing and Applications*. 2(1): 25–32.
- Egrioglu, E. , Yolcu, U. , Bas, E. , Dalar, A.Z. 2019. Median-Pi artificial neural network for forecasting. *Neural Computing and Applications*. *Neural Computing and Applications*. 31(1): 307–316.
- El-melegy, M. T., Essai, M. H. , Ali, A. A. 2009. Robust training of artificial feedforward neural networks. *Studies in Computational Intelligence*. 201: 217–242.
- Gao, S. 2019. Dendritic Neuron Model with Effective Learning Algorithms for Classification, Approximation, and Prediction. *IEEE Transactions on Neural Networks and Learning Systems*. *IEEE*. 30(2): 601–614.

- Ghosh, J, Shin, Y. 1992. Efficient Higher-order Neural Networks for Classification and Function Approximation. *Int J Neural Syst* 3: 323–350.
- Hans A., , Udluft, S. 2010. Ensembles of neural networks for robust reinforcement learning. *ICMLA Washington, DC, USA*, 401-406.
- Hill, M. 1999. The Learning Behavior of Single Neuron Classifiers on Linearly Separable. 1259–1264.
- Hill T., Marquez L., O'Connor M., R. W. 1994. Artificial neural networks for forecasting and decision making. *International Journal of Forecasting*. 10: 5–15.
- Holland 1987. Study of permutation crossover operators on the traveling salesman problem.
- Huang L., Zhang B.L., H. Q. 1998. Robust interval regression analysis using neural network. *Fuzzy Sets Syst*. 337–347.
- Huber P.J. 1964. Robust estimation of a location parameter. *Annals of Mathematical Statistics*. 35: 73-101.
- Jia, D. 2019. A Dendritic Neuron Model with Nonlinearity Validation on Istanbul Stock and Taiwan Futures Exchange Indexes Prediction. *Proceedings of 2018 5th IEEE International Conference on Cloud Computing and Intelligence Systems, CCIS 2018*. IEEE. 242–246.
- Juanyin, Q., Wei, W., Pan, W. 2004. Robust learning of neural networks ensemble for modeling. *Intelligent Control and Automation, 2004. WCICA 2004. Fifth World Congress on*. 3: 1927-1930.
- Kennedy, J, Eberhart, R. 1995. Particle swarm optimization. *Proceedings of IEEE international conference on neural networks, Piscataway, NJ, USA*. IEEE. 1942–1948.
- Koch, C, Poggio, T, Torre, V. 1983. Nonlinear interactions in a dendritic tree: Localization, timing, and role in information processing. *Proc. Nat. Acad. Sci. USA*, vol. 80, no. 9. 2799–2802.
- Labib, R. 1999. New single neuron structure for solving non-linear problems. In *IEEE IJCNN*. 99: 617–620.
- Labib, Richard 1999. New single neuron structure for solving nonlinear problems. *Proceedings of the International Joint Conference on Neural Networks*. 1: 617–620.
- Legenstein, R. , Maass, W. 2011. Branch-specific plasticity enables self-organization of nonlinear computation in single neurons. *Journal of Neuroscience*. 31(30): 10787–10802.
- Liano K. 1996. Robust error measure for supervised neural network learning with outliers. *IEEE Trans. Neural Networks*. 7: 246-250.
- McDowall T.M., H. F. M. 1997. Robust partial least-squares regression: A modular neural network approach. 3077: 344–355.
- Mili, L. and Coakley, C. W. 1996. Robust estimation in structured linear regression. *Annals of Statistics*. 24(6): 2593–2607.

- Neubauer A. 1995. Robust learning algorithms for multi-layer perceptrons with discretized synaptic weights. IEEE International Conference, Dept. of Commun. Eng., Duisburg Gerhard-Mercator-Univ., Germany.
- Öztemel, E. 2008. Yapay Sinir Ağları, papatyabilim.com.tr NNNN. Available at: http://papatyabilim.com.tr/PDF/yapay_sinir_aglari.pdf.
- Pernía-Espinoza, A. V. 2005. TAO-robust backpropagation learning algorithm. Neural Networks. 18(2): 191–204.
- Plate, T. 2000. Randomly connected sigma-pi neurons can form associator networks. Network: Computation in Neural Systems. 11(4): 321–332.
- Roger Joseph Boscovich 1757. Elementorum Universae Matheseos.
- Rumelhart DE, Hinton GE, W. R. 1986. Learning representations by backpropagating errors. Nature. 323(6188): 533–536.
- Rusiecki, A. 2012. Robust learning algorithm based on iterative least median of squares. Neural Processing Letters. 36(2): 145–160.
- Sanchez V.D.A. 1995. Robustization of learning method for RBF networks. Neurocomput. 9: 85–94.
- Schiess, M., Urbanczik, R. , Senn, W. 2016. Somato-dendritic Synaptic Plasticity and Error-backpropagation in Active Dendrites. PLoS Computational Biology. 12(2): 1–18.
- Sha, Z. , Hu, L. , Todo, Y. , Ji, J. , Gao, S. and Tang, Z. 2015. A breast cancer classifier using a neuron model with dendritic nonlinearity. IEICE Trans. Inf. Syst. 7: 1365–1376.
- Shibblee Md., Chandra B., K. P. K. 2010. Learning of geometric mean neuron model using resilient propagation algorithm. Expert Systems with Applications. 37: 7449-7455.
- Statistics, M. 2002. John W . Tukey ' s Contributions to Robust Statistics Author (s): Peter J . Huber Source : The Annals of Statistics , Dec . , 2002 , Vol . 30 , No . 6 (Dec . , 2002), pp . 1640-1648 Published by : Institute of Mathematical Statistics Stable URL : <https://>. 30(6): 1640–1648.
- Todo, Y. 2014. Unsupervised learnable neuron model with nonlinear interaction on dendrites. Neural Networks. Elsevier Ltd. 60: 96–103.
- Umasuthan M., W. A. M. 1996. Outlier removal and discontinuity preserving smoothing of range data. Proc. Inst. Elect. Eng. Vis. Image Signal Process. 191- 200.
- Wang C., Wu H.C., P. J. C. 1996. A cost function for robust estimation of PCA. Proc. SPIE. 2760: 120–127.
- Yadav, R. N., Kalra, P. K. , John, J. 2007. Time series prediction with single multiplicative neuron model. Applied Soft Computing Journal. 7(4): 1157–1163.
- Yolcu, U. ,Bas, E. ,Egrioglu, E. , Aladag , C.H. 2015. A new multilayer feedforward network based on trimmed mean neuron model. Neural Network World. 25(6): 587–602.
- Yolcu, U., Egrioglu, E. , Aladag, C. H. 2013. A new linear & nonlinear artificial neural network model for time series forecasting. Decision Support Systems. Elsevier B.V. 54(3): 1340–1347.

- Zhang, C. N., Zhao, M. , Wang, M. 2000. Logic operations based on single neuron rational model. *IEEE Transactions on Neural Networks*. 11(3): 739–747.
- Zhang G., Eddy Patuwo, B.Y., H. M. 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*. 14 (1): 35-62.
- Zhao, L., Yang, Y. 2009. PSO-based single multiplicative neuron model for time series prediction. *Expert Systems with Applications*. 36: 2805-2812.
- Zhou, T. , Gao, S. , Wang, J. , Chu, C. , Todo, Y. , Tang Z. 2016. Financial time series prediction using a dendritic neuron model. *Knowledge-Based Systems*. Elsevier B.V. 105: 214–224.



ÖZGEÇMİŞ

Ayşe Yılmaz 1990 yılında Gölyaka’da doğdu. İlk, orta ve lise eğitimini Giresun’da tamamladı. 2008 yılında Giresun Keşap Anadolu Öğretmen Lisesi’nden mezun oldu. 2009 yılında başladığı Gazi Üniversitesi İstatistik Bölümü’nü 2013 yılında bitirdi. 2017 yılında Giresun Üniversitesi İstatistik Anabilim Dalında yüksek lisans eğitimine başladı.

