

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

**ARCH YAPILI BASAMAKLI YAPAY SİNİR AĞI
MODELİ İLE ZAMAN SERİSİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Öğrencinin Adı SOYADI

: Radwan Mahamoud ADEN

Tezin Enstitüye Verildiği Tarih

: .../.../2021

Enstitü Anabilim Dalı

: İstatistik

Tez Danışmanı

: Prof. Dr. Ufuk YOLCU

**Ocak 2022
GİRESUN**

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

**ARCH YAPILI BASAMAKLI YAPAY SİNİR AĞI
MODELİ İLE ZAMAN SERİSİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Radwan Mahamoud ADEN

Enstitü Anabilim Dalı : İstatistik

Bu tez 07/01/2022 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

**Doç. Dr.
Necati Alp ERİLLİ
Jüri Başkanı**

**Dr. Öğr. Üyesi
Ali Zafer DALAR
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.

Radwan Mahamoud ADEN

TEŞEKKÜR

Yüksek lisans eğitimim boyunca beni sabırla dinleyen ve her türlü bilgiye ulaşmada bana yardımcı olan, yol gösteren, kıymetli hocam Prof. Dr. Ufuk YOLCU ya sonsuz teşekkür ediyorum.

Ders süresince göstermiş oldukları ilgi, hoşgörü ve eğitimlerinden dolayı Giresun Üniversitesi İstatistik Bölümü akademisyenlerine de minnettarım.

Aileme daima bana desteklerinden dolayı çok teşekkür ediyorum.



İÇİNDEKİLER

TEŞEKKÜR.....	I
İÇİNDEKİLER	II
ŞEKİLLER LİSTESİ	VI
TABLolar LİSTESİ.....	VII
ÖZET.....	IX
SUMMARY	X
BÖLÜM 1. GİRİŞ.....	1
BÖLÜM 2. KAYNAK ARAŞTIRMASI.....	7
2.1. ZAMAN SERİLERİ	7
2.1.1. Zaman Serisinin Bileşenleri	8
2.1.2. Durağanlık.....	8
2.1.3. Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları.....	9
2.1.4. Otoregresif Model	10
2.1.5. Hareketli Ortalama Modeli	11
2.1.6. Otoregresif Hareketli Ortalama Modeli	11
2.1.7. Box ve Jenkins Yöntemi	12
2.1.8. ARCH-GARCH Modelleri.....	13
2.1.8.1. ARCH MODELİ	14
2.1.8.2. GARCH MODELİ	15
2.2. YAPAY SİNİR AĞLARI	17
2.2.1. Biyolojik Nöron	17

2.2.2. Yapay Nöron	18
2.2.3. Aktivasyon Fonksiyonu	19
2.2.4. Öğrenme.....	21
2.2.4.1. DENETİMLİ ÖĞRENME	21
2.2.4.2. DENETİMSİZ ÖĞRENME	21
2.2.4.3. TAKVİYE ÖĞRENME	22
2.2.5. Mimari Yapı.....	22
2.2.6. İleri Beslemeli Yağay Sinir Ağları.....	22
2.2.6.1. TEK KATMANLI ALGILAYICI.....	22
2.2.6.2. ÇOK KATMANLI ALGILAYICI.....	23
2.2.7. Geri Beslemeli/Yinelenen Ağlar	24
2.2.8. Öğrenme Algoritması.....	25
2.3. GENETİK ALGORİTMA	26
2.4. BASAMAKLI (CASCADE) YAPAY SİNİR AĞI	29
BÖLÜM 3. MATERYAL VE YÖNTEM.....	30
BÖLÜM 4. ARAŞTIRMA BULGULARI.....	36
4.1. BIST-100 zaman serisi analizi	36
4.2. Uluslararası zaman serisi öngörü yarışması CIF2016 zaman serileri analizi .	42
BÖLÜM 5. SONUÇ VE ÖNERİLER.....	43
KAYNAKLAR	46
EKLER.....	50
EK 1	50

EK 2	62
ÖZGEÇMİŞ	67



SİMGELER VE KISALTMALAR LİSTESİ

AR	: Otoregresif
ARCH	: Otoregresif Koşullu Değişen Varyans
ARIMA	: Otoregresif Butunleşik Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
BIST 100	: Borsa İstanbul 100
CIF2016	: 2016 yılı uluslararası Zaman Serisi Öngörü Yarışması
CKA	: Çok Katmanlı Algılayıcı
EGARCH	: Ussel GARCH
GA	: Genetik Algoritma
GARCH	: Genelleştirilmiş Otoregresif Koşullu Değişen Varyans
GARCH-M	: Ortalama GARCH
MA	: Hareketli Ortalama
PSO	: Parçaçık Sürü Optimizasyonu
YSA	: Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 2.1. Biyolojik nöron

Şekil 2.2. McCulloch-Pitts nöron modeli

Şekil 2.3. Tek katmanlı bir ağın mimarisi

Şekil 2.4. Çok katmanlı bir ağın mimarisi

Şekil 2.5. Geri beslemeli öğrenme algoritması

Şekil 2.6. Genetik algoritmanın kavramları

Şekil 2.7. GA' nin diyagramı

Şekil 2.8. Basit bir B-YSA mimarisi

Şekil 3.1. ARCH-B-YSA mimarisi

Şekil 3.2. Bir kromozom yapısı

Şekil 4.1. 2011 yılı BIST-100 zaman serisi (01.03.2011-05.31.2011)

Şekil 4.2. 2012 yılı BIST-100 zaman serisi (01.02.2012-05.31.2012)

Şekil 4.3. 2013 yılı BIST-100 zaman serisi (01.02.2013-05.31.2013)

Şekil 4.4. Öngörü ve gerçek değerler - BIST-2011 – 7 test kümesi

Şekil 4.5. Öngörü ve gerçek değerler - BIST-2011 – 15 test kümesi

Şekil 4.6. Öngörü ve gerçek değerler - BIST-2012 – 7 test kümesi

Şekil 4.7. Öngörü ve gerçek değerler - BIST-2012 – 15 test kümesi

Şekil 4.8. Öngörü ve gerçek değerler - BIST-2013 – 7 test kümesi

Şekil 4.9. Öngörü ve gerçek değerler - BIST-2013 – 15 test kümesi

Şekil 5.1. YSA modellerinin CIF-2016 zaman serileri analizi performans dağılımları.

TABLÖLAR LİSTESİ

Tablo 2.1. Biyolojik nöronlar ve yapay nöronlar arasındaki ilişki verilmektedir

Tablo 4.1 BIST-100 analiz sonuçları

Tablo Ek.4.2. CIF2016/ZS1 için ortalama HKOK değerleri

Tablo Ek.4.3. CIF2016/ZS2 için ortalama HKOK değerleri

Tablo Ek.4.4. CIF2016/ZS3 için ortalama HKOK değerleri

Tablo Ek.4.5. CIF2016/ZS4 için ortalama HKOK değerleri

Tablo Ek.4.6. CIF2016/ZS5 için ortalama HKOK değerleri

Tablo Ek.4.7. CIF2016/ZS6 için ortalama HKOK değerleri

Tablo Ek.4.8. CIF2016/ZS7 için ortalama HKOK değerleri

Tablo Ek.4.9. CIF2016/ZS8 için ortalama HKOK değerleri

Tablo Ek.4.10. CIF2016/ZS9 için ortalama HKOK değerleri

Tablo Ek.4.11. CIF2016/ZS10 için ortalama HKOK değerleri

Tablo Ek.4.12. CIF2016/ZS11 için ortalama HKOK değerleri

Tablo Ek.4.13. CIF2016/ZS12 için ortalama HKOK değerleri

Tablo Ek.4.14. CIF2016/ZS13 için ortalama HKOK değerleri

Tablo Ek.4.15. CIF2016/ZS14 için ortalama HKOK değerleri

Tablo Ek.4.16. CIF2016/ZS15 için ortalama HKOK değerleri

Tablo Ek.4.17. CIF2016/ZS16 için ortalama HKOK değerleri

Tablo Ek.4.18. CIF2016/ZS17 için ortalama HKOK değerleri

Tablo Ek.4.19. CIF2016/ZS18 için ortalama HKOK değerleri

Tablo Ek.4.20. CIF2016/ZS19 için ortalama HKOK değerleri

Tablo Ek.4.21. CIF2016/ZS20 için ortalama HKOK değerleri

Tablo Ek.4.22. CIF2016/ZS21 için ortalama HKOK değerleri

Tablo Ek.4.23. CIF2016/ZS22 için ortalama HKOK değerleri

Tablo Ek.4.24. CIF2016/ZS23 için ortalama HKOK değerleri

Tablo Ek.4.25. CIF2016/ZS24 için ortalama HKOK değerleri

Tablo Ek.4.26. CIF2016/ZS25 için ortalama HKOK değerleri

Tablo Ek.4.27. CIF2016/ZS26 için ortalama HKOK değerleri

Tablo Ek.4.28. CIF2016/ZS27 için ortalama HKOK değerleri

Tablo Ek.4.29. CIF2016/ZS28 için ortalama HKOK değerleri

Tablo Ek.4.30. CIF2016/ZS29 için ortalama HKOK değerleri

Tablo Ek.4.31. CIF2016/ZS30 için ortalama HKOK değerleri
Tablo Ek.4.32. CIF2016/ZS31 için ortalama HKOK değerleri
Tablo Ek.4.33. CIF2016/ZS32 için ortalama HKOK değerleri
Tablo Ek.4.34. CIF2016/ZS33 için ortalama HKOK değerleri
Tablo Ek.4.35. CIF2016/ZS34 için ortalama HKOK değerleri
Tablo Ek.4.36. CIF2016/ZS35 için ortalama HKOK değerleri
Tablo Ek.4.37. CIF2016/ZS36 için ortalama HKOK değerleri
Tablo Ek.4.38. CIF2016/ZS37 için ortalama HKOK değerleri
Tablo Ek.4.39. CIF2016/ZS38 için ortalama HKOK değerleri
Tablo Ek.4.40. CIF2016/ZS39 için ortalama HKOK değerleri
Tablo Ek.4.41. CIF2016/ZS40 için ortalama HKOK değerleri
Tablo Ek.4.42. CIF2016/ZS41 için ortalama HKOK değerleri
Tablo Ek.4.43. CIF2016/ZS42 için ortalama HKOK değerleri
Tablo Ek.4.44. CIF2016/ZS43 için ortalama HKOK değerleri
Tablo Ek.4.45. CIF2016/ZS44 için ortalama HKOK değerleri
Tablo Ek.4.46. CIF2016/ZS45 için ortalama HKOK değerleri
Tablo Ek.4.47. CIF2016/ZS46 için ortalama HKOK değerleri
Tablo Ek.4.48. CIF2016/ZS47 için ortalama HKOK değerleri
Tablo Ek.4.49. CIF2016/ZS48 için ortalama HKOK değerleri

ARCH YAPILI BASAMAKLI YAPAY SINIR AĞI MODELİ İLE ZAMAN SERİSİ ÖNGÖRÜSÜ

ÖZET

Zaman serisi öngörüsü problemleri olasılıksal ve olasılıksal olmayan yaklaşımlar olarak iki başlıkta incelenebilir. Olasılıksal modeller, istatistiksel yaklaşımları temel alan Otoregresif (AR), Hareketli Ortalama (MA), Otoregresif Hareketli Ortalama (ARMA), Otoregresif Koşullu Değişen Varyans Modeli (ARCH) ve Genelleştirilmiş Otoregresif Koşullu Değişen Varyans Modeli (GARCH) gibi yaklaşımlardır. Bunun yanı sıra, bir zaman serisi tahmin aracı olarak, olasılıksal olmayan zaman serisi tahmin modellerinden, hesaplamalı yöntemler olarak da bilinen, Yapay Sinir Ağları (YSA) yaygın ve başarılı bir şekilde kullanılmaktadır. Bu çalışmada, ARCH yapılı bir yapay sinir ağı modeliyle girdiler ile çıktılar arasındaki doğrusal ve doğrusal olmayan ilişkileri birlikte, eş zamanlı tek bir süreç içerisinde, modelleyebilen bir zaman serisi öngörü aracı ortaya konmuştur. Bu tez kapsamında, Basamaklı-İleri Beslemeli-Yapay Sinir Ağı (B-YSA-Cascade Forward Artificial Neural Network) tekrarlayan (recurrent) bir yapıya dönüştürülerek kullanılmış ve ağın eğitimi genetik algoritma ile gerçekleştirilmiştir. Bu tez kapsamında önerilen ARCH-B-YSA'nın performansı ortaya konması adına, 106 gözlemden oluşan, (Borsa İstanbul'da işlem gören piyasa ve işlem hacmi açısından en yüksek 100 hisse senedinin) oluşturduğu zaman serisi (BIST-100) ve CIF2016 (2016 yılı Uluslararası Zaman Serisi Öngörü Yarışması=International Time Series Forecasting Competition) kapsamında kullanılan 48 zaman serisi . BIST-100 zaman serileri için gerçekleştirilen 6 analiz sonucunda önerilen modelin tatmin edici ve üstün öngörü sonuçları ürettiği görülmüştür. Ayrıca, CIF2016 zaman serileri için 288 analizin her biri için gerçekleştirilen 50 tekrar sonucunda, önerilen ARCH-B-YSA modelinin tüm durumların %71 inde en iyi ve diğerlerinde ise rekabetçi öngörü sonuçları ürettiği görülmüştür.

Anahtar Kelimeler: ARCH-GARCH Modelleri, Yapay Sinir Ağları, Zaman Serisi öngörüsü, Genetik Algoritma.

TIME SERIES FORECASTING VIA ARCH-TYPE CASCADE ARTIFICIAL NEURAL NETWORK MODEL

SUMMARY

Time-series prediction problems can be under two approaches: probabilistic and non-probabilistic approaches. Probabilistic models are approaches based on statistical approaches such as Autoregressive (AR), Moving Average (MA), Autoregressive Moving Average (ARMA), Autoregressive Conditional Variance Model (ARCH), and Generalized Autoregressive Conditional Variance Model (GARCH). In addition, Artificial Neural Networks (ANN), one of the non-probabilistic time series forecasting models, also known as computational methods, are widely and successfully used as a time series forecasting tool. In this study, a time series prediction that can model linear and non-linear relationships between inputs and outputs together in a single simultaneous process with an ARCH structured artificial neural network model has been introduced. Within the scope of this thesis, the Cascade Forward Artificial Neural Network was transformed into a recurrent structure and the training of the network was studied with a genetic algorithm. To demonstrate the performance of the ARCH-Cascade Forward-ANN proposed within the scope of this thesis, the time series (BIST-100) and CIF2016 (2016) consisting of 106 observations (the highest 100 stocks traded in Borsa Istanbul in terms of market and trading volume) 48-time series used within the scope of the International Time Series Forecasting Competition. As a result of 6 analyzes performed for the BIST-100 time series, it was seen that the proposed model produced satisfactory and superior prediction results. In addition, as a result of 50 iterations performed for each of the 288 analyzes for the CIF2016 time series, it was seen that the proposed ARCH-CF-ANN model produced the best results in 71% of all cases and competitive prediction results in the others.

Keywords: ARCH-GARCH models, Artificial Neural Networks, Time Series Prediction, Genetic Algorithm.

BÖLÜM 1. GİRİŞ

Bir zaman serisi, zamana göre indekslenmiş sonlu bir veri dizisi ($X_1, X_2, \dots, X_n$) olarak ifade edilebilir. Zaman serisi, zamana bağlı bir indekstir: dakika, saat, gün, yıl. Söz konusu zaman serilerinin analizi; tahmin, modelleme ve karakterizasyondan oluşmaktadır. Tahminin amacı, zaman serilerinin kısa vadeli evrimini doğru bir şekilde ortaya koyabilmektir ve modelleme, uzun vadeli davranışın özelliklerini belirlemeyi amaçlar, karakterizasyon ise bir zaman serisinin temel özelliklerini belirlemeyi amaçlar. Zaman serilerinin tahmininin esas olarak 1970 lerde başladığı, tarım, meteoroloji, otomasyon ve finans gibi çeşitli alanlar için dinamik sistemlerin evrimini tahmin etmek için birçok teknik geliştirildiği bilinmektedir. Doğrusal zaman serisi modelleri farklı stokastik süreçleri temsil eder ve önceki veri noktalarına doğrusal olarak bağlı olan otoregresif modeller (AR), entegre modeller (I) ve hareketli ortalama modeller (MA) gibi farklı modeller ortaya koyarlar. Bu modellerin kombinasyonları, Otoregresif Hareketli Ortalama (ARMA) ve Otoregresif Entegre Hareketli Ortalama (ARIMA) gibi yeni modeller üretir. Ayrıca, bazı durumlarda çok yararlı olabilecek birçok karmaşık model veya yaklaşım vardır ve diğer doğrusal olmayan zaman serisi modellerinin yanı sıra, zaman içindeki varyanstaki değişiklikleri de belirtmek için bazı farklı modeller de ortaya konmuştur. Bu amaçla ortaya konan Stokastik varyans modelleri olarak da bilinen ARCH (Otoregresif Koşullu Değişen Varyans-AutoRegressive Conditional Heteroskedastic) ve GARCH (Genelleştirilmiş Otoregresif Koşullu Değişen Varyans - Generalized ARCH) modelleri, sırasıyla, Engle (1982) ve Bollerslev (1986) tarafından geliştirilmiştir.

Literatürde bu konu ile ilgili birçok çalışma bulunmaktadır. Engle nin (1982) çalışması koşulsuz varyansı koşullu varyanstan ayıran ilk çalışmadır. ARCH modellerine göre, mevcut hata teriminin varyansı, önceki dönemin hata terimlerinin bir fonksiyonudur. Bollerslev (1986), ARCH modelinin koşullu varyans denkleminde uzun bir gecikmeye sahip olduğuna işaret etmektedir. Varyans parametrelerinin negatif tahmin problemlerinden kaçınmak için Bollerslev'in çözümü ARCH modelini genelleştirmekti. Nelson (1991), asimetric etkilerin varlığını hesaba katmak için EGARCH modelini önerdi. Glosten ve diğerleri (1993), yeniden düzenlenmiş GARCH-M modelini kullanarak, koşullu beklenen aylık getiri ile aylık getirilerin

koşullu varyansı arasında negatif bir ilişki olduğunu göstermiştir. Fong (1997), ARCH ve SWARCH yöntemlerini kullanarak Japon hisse senedi getirilerinin oynaklığını tahmin etmiş ve sonuçları karşılaştırmıştır. Hagerud (1997) ESTGARCH modelini önerdi. Poon ve Granger (2003), asimetrik etkileri dikkate alan modellerin oynaklık ve şoklar arasındaki negatif ilişki nedeniyle daha iyi tahminler sağlayabildiğini belirtmişlerdir. Ederington ve Guan (2005), finansal piyasanın GARCH (1,1) modelinin açıkladığından daha uzun bir hafızaya sahip olduğunu göstermiştir. Awrtani ve Corradi (2005), asimetrik modellerin GARCH (1,1) modelinden daha iyi çalıştığını bulmuşlardır. Köksal (2009), farklı oynaklık modellerini karşılaştırdıktan sonra en iyi sonuçları EGARCH (1.1)'in elde ettiğini bulmuştur. Bracker ve Smith (1999) bakır vadeli işlem piyasasının oynaklığını incelemiş ve GARCH ve EGARCH modellerinin bu piyasanın oynaklığına en iyi şekilde karşılık geldiği sonucuna varmıştır. Carvalho ve diğerleri ile (2006), EGARCH modelini kullanırken asimetrik etkilere dair kanıtlar bulmuş. Ancak, tüm ampirik çalışmalar bu sonuçlarla aynı fikirde değildir. Ramasamy ve Munisamy (2012) GARCH modellerinin bir serinin oynaklığını tahmin etmede daha iyi olduğunu ve EGARCH modelinin tahminlerin kalitesini iyileştirmede bulmuşlardır. Marcucci (2005), GARCH modelinin uzun bir süre boyunca diğer modellerden çok daha iyi performans gösterdiğini, ancak kısa bir süre içinde olmadığını bulmuştur. Bildirici ve diğerleri (2007), İMKB deki günlük getiri değişkenliğini hesaplamak için ARCH/GARCH ailesinden modeller kullanmışlardır.

Doğrusal ve doğrusal olmayan ilişkiler barındıran ve değişen varyans gibi farklı özellikler barındıran zaman serilerinin analizinde geleneksel olarak adlandırabileceğimiz ve yukarıda literatürü özetlenen tahmin modellerin kullanılmasının yanı sıra özellikle son yıllarda bilgisayar teknolojisinin gelişimi ile farklı tahmin araçları ortaya konmuştur. Yapay sinir ağları (YSA) bu çağdaş ya da modern araçlardan biri belki de en yaygın ve etkin olanıdır. YSA, sistem girdileri ve çıktıları hakkında ön bilgiye ihtiyaç duymadan, veriye dayalı olarak öğrenmeyi gerçekleştirebilir ve zaman serilerine ilişkin doğrusal ve/veya doğrusal olmayan ilişkileri daha esnek ve etkin bir şekilde modelleyebilir.

Yapay sinir ağlarının geliştirilmesinin arkasındaki ana varsayım, akıllı davranışın bir dizi zihinsel mekanizma tarafından desteklendiğidir. Bu nedenle, bu mekanizmalar

nörofizyolojik süreçlere dayandığından, merkezi sinir sisteminin yapısının akıllı davranışın gelişiminin temeli olduğu varsayılır. Yapay sinir ağları, insan beyninin yeni bilgi üretme, yeni bilgiler oluşturma ve bunları öğrenme yoluyla keşfetme gibi yeteneklerini herhangi bir yardım almadan doğrudan yürütmek amacıyla geliştirilen algoritmalar olarak tanımlanmaktadır. Son on yılda, yapay sinir ağlarının kullanımı birçok disiplinde (ekonomi, ekoloji ve çevre, biyoloji ve tıp) gelişmiştir. Özellikle sınıflandırma, tahmin, optimizasyon, örüntü tanıma ve ilişkisel bellek problemlerini çözmek için yaygın ve etkin olarak kullanılmaktadırlar.

McCulloch ve Pitts (1943), şekilsel sinir hücresinin basitleştirici fikrini ve sinapslar ile birbirine bağlanan ikili bir işlem ortaya koydu. Hebb (1949), ‘sinaptik esneklik’ kavramını, ortaya attı ve “*Hebb Kuralı*” olarak anılan, sinir ağları içindeki nöronal bağlantıların ağırlığını güncellemek için bir algoritma önerdi. Rosenblatt (1958), Hebb ve McCulloch ve Pitts tarafından ortaya konan fikirleri uygulayarak sinir ağlarının ilk operasyonel modelini tanımladı. Minsky ve Papert (1969), belirli mantıksal işlevleri hesaplamayı öğrenebilen algılayıcının teorik sınırlarını gösterdi, ancak teoremin derinleşmemesi ve yapay zekanın rekabet eden hareketi, yapay sinir ağı literatüründe oldukça uzun bir uyku dönemine yol açtı. 1970 ile 1980 yılları arasında YSA ile ilgili nispeten az sayıda bilimsel makale yayınlandı. Bununla birlikte, az sayıdaki bu çalışmalar belirli bir sürekliliğe ve böylece, 1980'lerin başlarında YSA ile ilgili çalışmaların çarpıcı bir şekilde yeniden canlanmasının tohumları olarak hizmet ettiler. İlk çok katmanlı algılayıcı (ÇKA) Werbos (1974) tarafından ortaya konmuş ve katmanlardaki organizasyona ve bir bilgisayardaki dijital simülasyona dayanan YSA'nın kullanımını Hopfield (1982) detayları ile açıklamıştır. 1986'da Rumelhart, Hinton ve Williams, çok katmanlı bir sinir ağının parametrelerini optimize eden *Hata Geri Yayılım Algoritması*ni ortaya koydular.

Literatürde en çok kullanılan YSA türlerinden biri çok katmanlı algılayıcıdır, ilk sinir ağları doğrusal olmayan problemleri çözmemiştir; bu sınırlama, Paul Werbos (1974) tarafından önerilen ve on iki yıl sonra, 1986'da Rumelhart tarafından kapsamlı bir çalışmadan sonra geliştirilen çok katmanlı sistemlerde hata gradyanının geri yayılması yoluyla kaldırıldı. Çok katmanlı algılayıcı olan bu model, tek nörondan oluşan basit ağ yapısı ile YSA'nın dezavantajlarından biri olan gizli katman birim

sayısının belirlenmesi sorununu ortadan kaldırmaktadır. Yadav ve diğerleri (2007), çarpımsal nöron modelinin tahmin sonuçlarının literatürde önerilen bazı YSA modellerinden daha iyi olduğunu göstermiş ve bu model üstün tahmin performansı nedeniyle literatürde sıklıkla kullanılmaktadır. Zaman serisi tahmin problemi için, Zhang ve diğerleri (1998) ve Zhang (2003) yapay sinir ağları ile ilgili literatürü özetlemiştir. Eğrioğlu ve diğerleri (2008), Aladağ ve diğerleri (2010) ve Aladağ (2011) gizli ve giriş katmanlarındaki nöron sayısını belirlemek için belirli yöntemler kullanmışlardır. Literatürde Yadav ın çarpımsal sinir modelini kullanan farklı YSA modelleri önerilmiştir. Yolcu ve diğerleri (2013) doğrusal ve doğrusal olmayan yapıların bir arada bulunduğu çarpımsal nöron modeline dayalı bir hibrit YSA modeli önermiş ve bu modelin eğitiminde PSO algoritmasını kullanmıştır. Aladağ ve diğerleri (2012) mevsimsel zaman serilerinin çözümü için çarpımsal nöronlar modeline dayalı bir YSA sunmuş ve bu YSA nın eğitiminde PSO algoritmasını kullanmıştır. Ayrıca Aladağ (2013) bulanık zaman serilerinde çarpımsal nöron modellerinin çalışmalarına bir örnektir. Alparslan ve diğerleri ile (2015) ayrıca geri yayılım, PSO ve yapay arı kolonisi algoritmalarının örnek içi ve örnek dışı performansları karşılaştırılmıştır.

Karşılaşılan birçok zaman serisi probleminde ilgilenilen ve özellikle de finansal zaman serilerinin doğrusal ilişkilerin yanı sıra doğrusal olmayan ilişkileri içermesi ve dahası, zaman içinde varyansının sabit olmaması hem geleneksel zaman serisi modellerini hem de değişen varyans problemini dikkate almayan YSA modellerini tatmin edici tahmin sonuçları üretmede yetersiz kılacaktır. Bu noktadan hareketle Çorba (2017) tez çalışmasında ve Çorba ve diğerleri. (2020) yayımladıkları bilimsel makalede, doğrusal yapıda olmayan ve değişen varyans özelliği içeren zaman serilerinin analizi için ARCH yapısı içeren bir YSA modeli (ARCH-TÇSH-YSA) ortaya koymuşlardır. Bu YSA modelinde artıkların karelerini modele girdi olarak besleyerek ARCH yapısı oluştursalar da, kullandıkları tek çarpımsal sinir hücresine sahip YSA modeli nedeniyle çıktıları girdilerin doğrusal olmayan bir fonksiyonu olarak elde ederler. Oysa ki, zaman serisinin gecikmeli değişkenleri ve artıkların karelerinden oluşan gridiler ile çıktılar (zaman serisi tahmin değerleri) arasında doğrusal ve doğrusal olmayan ilişkiler birlikte bulunabilir. Bu tez çalışmasında, literatürde henüz çözümlenmemiş bu problemin üstesinden gelmek adına, ARCH yapıları bir modelde girdiler ile çıktı arasındaki doğrusal ve doğrusal olmayan ilişkileri

birlikte modelleyebilen bir YSA ortaya konulması amaçlanmıştır. Bu amaçla, girdiler ile çıktı arasında doğrusal ve doğrusal olmayan ilişkileri birlikte eş zamanlı olarak çözümleyebilen bir YSA modeli olan Basamaklı-İleri Beslemeli-Yapay Sinir Ağı (B-YSA - Cascade Forward Artificial Neural Network) tekrarlayan (recurrent) bir yapıya dönüştürülerek kullanılmıştır. Burada “*tekrarlama*” işlevi artıkların karelerinin girdi tabakasına iletilmesi ve birer YSA girdisi olarak beslenmesi ile ARCH yapısının oluşumunu sağlamaktadır (ARCH-B-YSA). Oluşturulan ARCH-B-YSA’nın eğitimi ise genetik algoritma gerçekleştirilmiştir.

Bu tez ile önerilen ARCH-B-YSA’nın tahmin performansı farklı zaman serilerinin analizi ile ortaya konmuştur. Öncelikle, 2011, 2012 ve 2013 yıllarında 106 gözlemden oluşan, Borsa İstanbul’da işlem gören piyasa ve işlem hacmi açısından en yüksek 100 hisse senedinin oluşturduğu “BIST 100 endeksi” zaman serisi (BIST-100) iki farklı test kümesi üzerinden performans değerlendirmesi yapılmak üzere çözümlenmiştir. Elde edilen sonuçlar, üç farklı performans ölçütü kullanılarak bazı geleneksel zaman serisi tahmin modellerinin yanı sıra farklı YSA ve bulanık zaman serisi modelleri ile birlikte karşılaştırmalı olarak değerlendirilmiştir. Ayrıca, CIF2016 (2016 yılı Uluslararası Zaman Serisi Öngörü Yarışması=International Time Series Forecasting Competition) kapsamında kullanılan 48 zaman serisi farklı YSA parametreleri ile çözümlenerek, elde edilen sonuçlar, ARCH-TÇSH-YSA, tek çarpımsal sinir hücresi YSA (TÇSH-YSA) ve klasik çok katmanlı algılayıcı -ileri beslemeli- YSA (ÇKA-YSA) ile performans ölçütü ortalamaları bakımından karşılaştırmalı olarak ele alınmıştır.

Tezin ikinci bölümünde zaman serisi temel tanım ve kavramlarından bahsedilmiş, ayrıca Box-Jenkins modelleri ile ilgili temel kavramlar özetlenmiştir. Üçüncü bölüm, bu tez kapsamında önerilen YSA modelinin fikir özünü oluşturan ve özellikle ekonometrik-finansal zaman serilerinin modellenmesinde kullanılan ARCH-GARCH modellerini içermektedir. Dördüncü bölüm YSA hakkında temel bilgiler sunmaktadır. Beşinci bölümde, materyal ve yöntem başlığı altında, bu tez kapsamında önerilen, ARCH yapılı Basamaklı-İleri Beslemeli-Yapay Sinir Ağı modelinin temelini oluşturan B-YSA, önerilen modelin eğitiminde kullanılan genetik algoritma ve önerilen modelin çalışma prensibine ilişkin temel olgular ortaya konmuştur. Altıncı

bölüm, yukarıda belirtilen farklı zaman serilerinin çözümülenmesi ve sonuçların derlenerek karşılaştırmalı yorumlanmasına ayrılmıştır. Son olarak elde edilen bulgular sonuçlar ve öneriler başlığı ile özetlenmiştir.



BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Zaman Serileri

Zaman serileri, zaman içinde kronolojik bir yapıda elde edilen verilerin toplanmasıdır. Bu nedenle, zaman serisi analizinde genellikle iki ilişkili değişkenden söz edilebilir (verinin bağlı olduğu nicel bir değişken ve zaman değişkeni). Zaman serileri, istatistik, ekonometri, matematik finansmanı, hava tahmini, astronomi, iletişim mühendisliği ve büyük ölçüde zamansal ölçümler içeren herhangi bir uygulamalı bilim ve mühendislik alanı gibi çok çeşitli alanlarda kullanılmaktadır. Bir zaman serisi, zamansal bir sıraya göre sıralanmış bir veri noktaları dizisi olarak da anılabilir. Zaman serilerinde veriler genellikle eşit aralıklıdır.

Olasılıksal modellerin zaman serileri analizinde kullanımı deterministik ve stokastik modeller olmak üzere iki farklı şekilde söz konusudur.

i. Zaman serisinin zaman değişkeni (t) ile açıklanmaya çalışıldığı modeller:

$$X_t = f(t) + e_t \quad (2.1.1)$$

Bu gruptaki modeller zamanı doğrudan açıklayıcı değişken olarak kullandığından bunlara deterministik zaman serisi modelleri de denir. Ancak, bu deterministik modellerin gerçekte olasılıksal modeller olduğu da göz ardı edilmemelidir.

ii. Zaman serilerinin aralıklı değişkenlerle açıklanmaya çalışıldığı modeller :

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-p}) + e_t \quad (2.1.2)$$

Bu gruptaki modeller olasılıksal süreçlere dayanan modeller olduğu için bunlara stokastik veya olasılıksal modeller de denir. Bu tez kapsamında önerilen yapay sinir ağı modelinin fikri ARCH-GARCH modellerine dayandığından stokastik modeller de ele alınacaktır.

Bu bölümde zaman serilerinde en çok kullanılan yöntemler ve temel kavramlar açıklandıktan sonra zaman serisi modellenmesinde kullanılan farklı model sınıfları (AR, MA, ARMA), BOX-Jenkins modelleri ve son olarak da farklı otoregresif koşullu değişen varyans modelleri (ARCH ve GARCH) özetle incelenecektir.

2.1.1. Zaman Serisinin Bileşenleri

Zaman serisi bileşenleri eğilim (trend), mevsimsel, döngüsel ve kalan (hata terimi) ya da düzensiz hareketler bileşeni olmak üzere dört bileşenlerden oluşur.

Eğilim (Trend) bileşen: Zaman içinde ortaya çıkan uzun bir süre boyunca artış veya azalış eğilimini ifade eder. Aynı zamanda, serinin ortalama seviyesinde aşağı veya yukarı eğrinin genel hareketidir.

Mevsimsel bileşen: Kısa bir süre içinde periyodik olarak tekrarlanan davranıştır. Ortalama düzeyin üstünde veya altında ve kısa sürelerle aralıklarla tekrar eden bir dalgalanmadır.

Döngüsel bileşen: Uzun bir süre boyunca periyodik olarak tekrar eden ve zamanla ancak uzun süreler boyunca tekrar eden bir davranıştır.

Kalan (hata terimi) bileşen: Çalışılan zamansal fenomenin yapılandırılmamış kısmını da temsil eden düzensiz ve öngörülemez bir varyasyondur.

2.1.2. Durağanlık

Bir zaman serisinin durağanlık tanımı ; ortalama, varyans ve otokorelasyon yapısının zaman içerisinde değişmeme özelliğine sahip olmasını ifade eder. Durağanlık, bir zaman serisi regresyonunun geçerliliği için anahtar bir kavramdır. İstatistiksel bir bakış açısından, durağanlık, geçmişin şimdiki zaman ve gelecekle karşılaştırılabilir olduğunu varsayar. Durağanlık kesin matematiksel terimlerle tanımlanabilir, ve eğilimsiz, sabit bir varyans, sabit bir otokorelasyon yapısı ve periyodik dalgalanmalar (mevsimsellik) olmayan düz görünümlü bir seriyi ifade eder.

Zaman serilerinde iki tip durağanlık vardır (güçlü durağanlık ve zayıf durağanlık), zayıf durağanlık özelliklerinin yanında dağılım biçiminin zaman içerisinde değişmemesi özelliğine sahip olması onun aynı zamanda güçlü durağanlık özelliğine sahip olduğu anlamına gelir. Bu güçlü durağanlık tanımı, ortak dağılımın ($y_{t+1}, y_{t+2}, \dots, y_{t+n}$)'ye bağlı olmadığını ima eder; aksi taktirde, y_t 'nin durağan olmadığı

sonucuna varılır. Ayrıca (durağanlığın zayıf tanımı), bir zaman serisi y_t için aşağıdaki gibi gösterilir :

$$E[y_t] = \mu \quad (2.1.3)$$

$$\text{var}[y_t] = E(y_t^2) = \sigma^2 \quad (2.1.4)$$

$$\text{cov}[y_t, y_{t+k}] = E[(y_t - \mu)(y_{t+k} - \mu)] = \gamma_k \quad (2.1.5)$$

Uygulamada, zaman serisinin durağan olup olmadığına korelogramına bakarak karar verilebileceği gibi, daha derin bir inceleme yapılmak istenilirse durağanlık testlerinden faydalanılabilir. Dickey ve Fuller (1979), bir zaman serisinin durağan olmayışını tespit eden bir test önermektedir. Y_t ile gösterilen bir zaman serisini göz önünde bulundurarak, Dickey ve Fuller (DF) testi, birim kökün (veya durağan olmama) boş hipotezini tahmin eden bir birim kök testidir. Otokorelasyon testi daha sonra gecikmeli değişkenleri tanıtarak modelleri tahmin etmekten oluşur. Durağan olmayan zaman serileri için: fark alma yöntemi ile ya da varyans sabit değilse, varyansı stabilize etmek için serinin logaritmasını veya karekökünü alma gibi teknikler kullanılarak durağanlık koşulu sağlandıktan sonra analizler yapılmaktadır.

2.1.3. Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları

Bir otokorelasyon fonksiyonu, k periyot kaydırılmış serinin kendisiyle korelasyonunu ölçen, r_h ile belirtilen fonksiyondur. Form eşitlik (2.6) ile verildiği gibidir:

$$r_h = \frac{\sum_{n=h+1}^N (x_n - \bar{x})(x_{n-h} - \bar{x})}{\sum_{n=h+1}^N (x_n - \bar{x})^2} \quad (2.1.6)$$

burada,

x_n : Orjinal zaman serisi

x_{n-h} : h dönem erken zaman serisi

$\bar{x}$: Zaman serisi ortalaması

Otokorelasyon fonksiyonu (ACF), gecikmeli değerleri ile herhangi bir serinin otomatik korelasyon değerlerini veren (tam) bir otomatik korelasyon fonksiyonudur. Basit bir ifadeyle, serinin mevcut değerinin geçmiş değerleriyle ne kadar ilişkili olduğunu açıklar. Bir zaman serisinde eğilim, mevsimsellik, döngüsel ve artık gibi bileşenler bulunabilir. ACF, korelasyonları bulurken tüm bu bileşenleri dikkate alır, bu yüzden 'tam bir otomatik korelasyon'u ifade eder.

(PACF) kısmi bir oto-korelasyon fonksiyonudur. Temel olarak, mevcut otokorelasyon gibi gecikmelerle korelasyonlar bulmak yerine, artıkların (daha önceki gecikmeler tarafından zaten açıklanmış olan etkiler kaldırıldıktan sonra kalan) bir sonraki gecikme değeriyle olan korelasyonu temsil eder.

2.1.4. Otoregresif Model

Otoregresif (AR) modeli süreçte X 'nin t dönemindeki değeri, bir önceki dönemde aldığı değer ile bir rastsal terime bağlıdır ve temel olarak zaman serisinin kendi üzerine gerilemesi olarak görülebilir. Burada, mevcut değer bir miktar gecikmeyle önceki değerlerine bağlı olduğu varsayılır. AR modelinin derecesi, kısmi otokorelasyon grafiğine bakılarak tespit edilebilir.

p : Modele dahil edilen ve gecikme sırası olarak da adlandırılan gecikmeli gözlemlerin sayısı. Genel olarak, $AR(p)$ süreci, bu form modelinin bir çözümü olarak tanımlanabilir:

$$X_t = \sum_{i=1}^p \theta_i X_{t-i} + \varepsilon_t \quad (2.1.7)$$

$$X_t = c + \theta_1 X_{t-1} + \theta_2 X_{t-2} + \dots + \theta_i X_{t-i} + \varepsilon_t \quad (2.1.8)$$

Burada, θ_i ($i = 1, 2, \dots, n$) modelin parametrelerini oluşturur. ε_t ise bağımsız ak gürültü sürecidir.

2.1.5. Hareketli Ortalama Modeli

Hareketli ortalama (*MA*) modelleri zaman serisi değerlerinin önceki döneme ilişkin tahmin hatalarına bağlı olarak ifade edilebilirler. Hareketli ortalama modeli $MA(q)$, en büyük gecikmeyi temsil eden q parametresini alır ve otokorelasyon grafiğinde sonraki gecikmelere ilişkin korelasyonlar önemli değildir.

q : Hareketli ortalama derecesi olarak da adlandırılan hareketli ortalama penceresinin boyutu olmak üzere, $MA(q)$ modelinin genel tanımı:

$$X_t = \sum_{i=1}^p \alpha_i \varepsilon_{t-i} + \varepsilon_t \quad (2.1.9)$$

$$X_t = c + \alpha_1 \varepsilon_{t-1} + \alpha_2 \varepsilon_{t-2} + \dots + \alpha_i \varepsilon_{t-i} + \varepsilon_t \quad (2.1.10)$$

Şeklinde verilebilir. Burada, α_i ($i = 1, 2, 3, \dots, n$) modelin parametrelerini oluşturur ve ε_t bağımsız ak gürültü sürecidir.

2.1.6. Otoregresif Hareketli Ortalama Modeli

Otoregresif hareketli ortalama modeli (*ARMA*) tahminler yapmak için serinin kendisinde bulunan bilgilerin yanı sıra zaman serisi değerlerinin önceki döneme ilişkin tahmin hatalarını kullanan bir tahmin yöntemidir. *ARMA* modelleri esas olarak Yule ve Slutsky tarafından vurgulanan otoregresif ve hareketli ortalama ilkelerine dayanmaktadır. Daha sonra 1970 yılında, Box ve Jenkins tarafından iki *ARMA* prensibi birleştirilerek geliştirildi, bu sürecin birçok alana uygulanabileceğini ve uygulanmasının kolay olduğu gösterildi. Bu metodoloji, incelenen veri serilerini temsil eden farklı *ARMA* model sınıfları arasında bir model seçebilmenin çok verimli bir yolu olarak basit otokorelasyonların ve "korrelogram" olarak adlandırılan kısmi otokorelasyonların grafik sunumunun incelenmesini önermektedir. .

Hem *AR* hem de *MA* modellerini birleştirilerek *ARMA* modelleri elde edilir. Genel olarak, bir $ARMA(p, q)$ modeli ile tahmin aşağıdaki denklem kullanılarak

açıklanır. Genel olarak, $ARMA(p, q)$, süreci, bir form modelinin bir çözümü olarak tanımlanabilir:

$$X_t = \sum_{i=1}^p \theta_i X_{t-i} + \sum_{i=1}^q \beta_i \varepsilon_{t-i} + \varepsilon_t \quad (2.1.11)$$

θ_i ($i = 1, 2, 3, \dots, p$) ve β_i ($i = 1, 2, 3, \dots, q$) modelin parametrelerini oluştururken ε_t ise bağımsız ak gürültü sürecidir.

2.1.7. Box ve Jenkins Yöntemi

Bu bölümde, durağan zaman serileri için Box ve Jenkins (1970) tarafından ortaya konan ve ampirik otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonlarını kullanmayı öneren metodolojiden kısaca bahsedilecektir. Box-Jenkins yöntemi, birkaç adım içeren ve bir zaman serisini doğru bir şekilde temsil edebilen bir ARMA modelinin seçilmesine izin veren bir yöntemdir. Bu yöntem, zaman serilerinin durağan olduğu kanıtlandıktan sonra veya durağan olmayan zaman serilerinin stabilizasyonundan/durağanlaştırıldıktan sonra uygulanır, çünkü durağan olmayan bir seriye bu yöntem uygulanamamaktadır. Serinin durağanlığı gösterildikten sonra, aşağıdaki 3 adımı izleyerek Box-Jenkins algoritması uygulanır.

➤ Modelin tanımlanması :

Tanımlama aşaması en önemli ve en zor olanıdır, araştırmacı görsel olarak zaman serisinin grafiğini, otokorelasyon fonksiyonunu, kısmi otokorelasyon fonksiyonunu değerlendirir. Bu adım ARMA modelleri ailesinde uygun modelin belirlenmesinden oluşur. Bu değerlendirme araştırmacıya zaman serilerindeki uç değerler, eksik değerler ve yapısal kırılmalar hakkında bilgi verir. Bu adımda, farkın zaman serilerinin durağanlığının bir fonksiyonu olarak alınıp alınmadığı, gecikmelerin dereceleri belirlenir.

➤ Modelin tahmin edilmesi :

Tahmin yöntemleri ya da modelin tahmin edilmesi, teşhis edilen işlemin türüne göre farklılık gösterir. Bu aşamada önemli olan stabil bir model seçmektir. AR (p)

modeli söz konusu olduğunda, en küçük kareler yöntemini uygulayabiliriz veya otokorelasyonlar ile model katsayıları arasındaki mevcut ilişkileri kullanabiliriz (Yule-walker denklemleri). Bir MA (q) modelinin parametrelerinin tahmini daha karmaşıktır. Box ve Jenkins, bu durumda, yinelemeli tarama tipi bir prosedür kullanılmasını önerir.

➤ Model doğrulama (uygunluk testleri ve hata kontrolü):

Model doğrulama aşaması çok önemlidir, modelin yeteri kadar iyi olup olmadığı ve aynı zamanda, model için önemli olmayan değişkenlerin modele dâhil edilip edilmediği, dâhil edilmesi gereken değişkenlerin modelde yer alıp almadığı değerlendirilir ve tahmin edilen model parametreleri ile tanımlama aşamasına geri dönüş gerektirir, tahmin sonuçları incelenir.

- Modelin katsayıları, sıfırdan önemli ölçüde farklı olmalıdır. Bu sınama içint-student testi klasik şekilde uygulanır. Bir katsayı 0'dan önemli ölçüde farklı değilse, geçersiz AR veya MA modelinin sırasını ortadan kaldırarak yeni bir spesifikasyon test edilmelidir.
- Kalıntı analizi karşılanması gereken iki kriter temelinde gerçekleştirilir:
 - Ortalama sıfırdır, aksi takdirde modele bir sabit eklenmelidir ;
 - Kalıntı bir ak gürültüdür. Box-Pierce ve Ljung-Box'ın Q istatistiği bu hipotezi test etmeye izin verir. Kalan ak gürültü değilse, bu model spesifikasyonunun eksik olduğu anlamına gelir.

2.1.8. ARCH-GARCH Modelleri

Bu tez kapsamında, zaman serisi öngörüsü için ARCH yapılı bir basamaklı yapay sinir ağı modeli önerilmektedir. Bu bakımdan hem ARCH hem de GARCH modelleri temel bilgiler doğrultusunda ele alınacaktır. ARCH ve GARCH (Otoregresif Koşullu Değişen Varyans ve Genelleştirilmiş Otoregresif Koşullu Değişen Varyans) modelleri, finansal serilerin tanımlanmasında anahtar rol oynayan modellerdir. 1982'de Profesör Robert Engle tarafından İngiltere için enflasyon değişimi üzerine

yapılan bir çalışmada önerilen Otomatik Gerilimli Koşullu Değişkenlik kavramı, çok sayıda zaman serisinin mevsimsel oynaklığını daha iyi modellemeyi mümkün kılmıştır.

ARCH modelinin temel fikri, hatanın t zamanındaki varyansının, önceki dönemlerin hatalarının karesinin önemine bağlı olmasıdır. ARCH modeli, hata teriminin koşullu varyansı zamanla değişebildiği zaman doğrusal modelin bir uzantısıdır ve bu nedenle, finansal seriler alanında düzenli olarak kullanılan teknikler ARCH ve GARCH modelleridir, bu modellerin herhangi bir finansal seriyi tahmin edecek kadar sağlam olduğu gösterilmiştir. Bu metodoloji, hem tanımlayıcı hem de öngörücü avantajları olduğu için hızla yayıldı. ARCH ve GARCH modelleri hisse senedi endeksleri veya opsiyonlarının finansal piyasalarındaki oynaklığın anlaşılmasını kolaylaştırır, portföy yönetiminin risk tahminlerini veya hisse senedi getirilerinin oynaklığının analizini geliştirir.

2.1.8.1.ARCH modeli

Bilinen zaman serileri modellemesi hata terimlerinin sabit varyanslılık varsayımını ileri sürerler. Buna karşılık Engle (1982), hata terimlerinin varyansının sabit olmadığını, İngiltere enflasyon verilerini inceleyerek göstermiştir. İncelenen verinin bu varsayımı sağlamaması durumunda Engle'in yapmış olduğu çalışmalar ARCH adını alarak literatüre girmiştir. Çok hızlı bir gelişmenin ardından ARCH modellerine ayrılan literatür, günümüzde etkileyici bir boyuta ulaştı ve çok geniş bir alanı kapsıyor.

Genel olarak, tek değişkenli bir ARCH süreci, bir form modelinin bir çözümü olarak tanımlanabilir.

➤ *ARCH* (1):

$$X_t = Z_t \sqrt{\alpha_0 + \alpha_1 X_{t-1}^2} \quad (2.1.12)$$

X_t denklemi eğer X_{t-1} büyükse, X_t 'nin koşullu varyansının da büyük olduğunu ve bu nedenle büyük olma eğiliminde olduğunu gösterir.

➤ Beklenen Değeri ve Varyans

$$E(X_t) = 0 \quad (2.1.13)$$

$$V(X_t) = \frac{\alpha_0}{1-\alpha_1} \quad (2.1.14)$$

➤ *ARCH* (p):

$$X_t = Z_t \sqrt{\alpha_0 + \sum_{i=1}^q \alpha_i X_{t-i}^2} \quad (2.1.15)$$

➤ Beklenen Değeri ve Varyans

$$E(X_t) = 0 \quad (2.1.16)$$

$$V(X_t) = \alpha_0 + \sum_{i=1}^q \alpha_i X_{t-i}^2 \quad (2.1.17)$$

2.1.8.2. GARCH modeli

Birçok uygulama için, *ARCH* (p) modelinin koşullu varyans denkleminde çok sayıda gecikmenin eklenmesi, belirli parasal ve finansal serileri karakterize eden oynaklığın uzun belleğini hesaba katmak için gereklidir. Bu çok sayıda parametre, varyansın negatif olmayan kısıtlamasının ihlaline yol açabilir ve tahmin problemleri ortaya çıkarabilir. Bu perspektifte, Bollerslev (1986) tarafından önemli bir uzantı olan Genelleştirilmiş Koşullu Heteroskedastik Otoresif Model (*GARCH*) önerilmiştir. Bu yaklaşım, şok kalıcılığı fenomenini modellemek için *ARCH* (p) formülasyonundan daha az parametrenin tahmin edilmesini gerektirir. İncelenen değişkenin koşullu varyansı, p geçmiş hata terimlerinin karesiyle ve q gecikmeli koşullu varyanslarla belirlenir.

➤ *GARCH* (p, q):

$$\varepsilon_t = z_t \sqrt{h_t} \quad (2.1.18)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (2.1.19)$$

➤ Beklenen Değeri ve Varyans :

$$E(X_t) = 0 \quad (2.1.20)$$

$$V(X_t) = h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (2.1.21)$$

GARCH (1,1), volatilité modelleri ailesinin en basit ve en sağlam olanıdır. Bununla birlikte, model birçok şekilde genişletilebilir ve değiştirilebilir. Literatürde bulunabilecek volatilité modellerinin sayısı artık oldukça sıra dışı olmasına rağmen, kısaca üç modifikasyondan bahsedeceğim. *GARCH* (1,1) modeli, bir *GARCH* (p, q) modeline, yani ek gecikme terimlerine sahip bir modele genelleştirilebilir. Bu tür üst düzey modeller, birkaç on yıllık günlük veriler veya bir yıllık saatlik veriler gibi uzun bir veri aralığı kullanıldığında genellikle yararlıdır.

➤ *GARCH* (1,1):

$$\varepsilon_t = z_t \sqrt{h_t} \quad (2.1.22)$$

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (2.1.23)$$

➤ Beklenen Değeri ve Varyans :

$$E(X_t) = 0 \quad (2.1.24)$$


$$V(X_t) = \frac{\alpha_0}{1 - \alpha_1 - \beta_1} \quad (2.1.25)$$

2.2. YAPAY SİNİR AĞLARI

Yapay sinir ağıları biyolojik sinir ağlarını esas alan, birbirine bağlı birimlerden oluşan ve bir girdi desenine karşılık bir çıktı deseni üretebilen işlemcilerdir. Temel birimi ise biyolojik nöron yapısının bir resterasyonu olan yapay nöron/birimlerden oluşur.

2.2.1. Biyolojik Nöron

Biyolojik keşifler, teknoloji uzmanlarına biyolojik sistemleri yansıtan yapay sistemleri modelleme ve tasarlama konusunda ilham vermiştir. Bu bakımdan YSA'nın temel bileşenleri olan nöron ya da birimler insan beyinde 10^{11} adet bulunan sinir hücrelerinden esinlenerek oluşturulmuştur. Bir biyolojik sinir hücresi Şekil 2.1 ile verildiği gibi hücresel gövde, akson, dendrite ve sinapslar olmak üzere dört bölümden oluşur.



Şekil 2.1. Biyolojik nöron

Hücresel Gövde: Genellikle "Soma" olarak adlandırılan, kendisine ulaşan bilgilerin toplamını gerçekleştirir, aynı bilgiyi işler ve sonucu akson aracılığıyla diğer nöronlara elektrik sinyalleri şeklinde geri gönderir.

Akson: Nöronun uzun lifli bir uzantısıdır, nöronlar arasındaki bağlantıyı gerçekleştirir ve sinir uyarılarına öncülük eder.

Dendrite: Sensör görevi görür çünkü dışarıdan gelen bilgiyi hücre gövdesine doğru alır.

Sinapslar: İki nöron arasında yer alan ve bilginin birinden diğerine iletilmesini sağlayan bir alandır.


Biyolojik nöronun temel rolü sinyalleri almak, göndermek ve iletmektir. Dendritler, diğer nöronlardan elektrik sinyali şeklinde bilgi alırlar, hücre gövdesine (Soma) ve daha doğrusu "sinaptik ağırlıklar" adı verilen ağırlıkları etkilerken dendritlere gelen akışları toplayacak olan çekirdeğe gönderilirler.

Sonuç olarak, akson boyunca sinaptik sonlara doğru ilerler ve sinyalin gelişyle birlikte, sinaptik veziküller, nörotransmitterleri serbest bırakmak için hücre zarı ile birleşir.

2.2.2. Yapay Nöron

Biyolojik nöron gibi, yapay nöron da basit bir hesaplama sürecidir, giriş sinyallerinin ağırlıklı toplamını yukarı akış seviyesine ait nöronlardan alır ve bu toplamın bir fonksiyonunu çıkarır. Sinir ağları, zaman serisi tahmini problemine uygulanan ve büyük başarılarla imza atan akıllı araçlardan biridir. Beyin, yapay sinir ağları için biyolojik ilham kaynağıdır. Her yapay nöron temel bir işlemcidir. Bir parçası olduğu makineyi oluşturan yukarı akış nöronlarından veya sensörlerden değişken sayıda girdi alır. Girdilerinin her biri, bağlantının gücünün ağırlık temsilcisiyle ilişkilidir.

Yapay nöronun ilk matematiksel ve bilgisayar modeli 1943'te Mac Culloch ve Pitts tarafından ortaya kondu.



Şekil 2.2. McCulloch-Pitts nöron modeli

Şekil 2.2 de olduğu gibi, her bir yapay nöronun giriş bağlantıları vardır ve tek çıkışlı bir işlem biriminden oluşur. $(x_1, x_2$ ve $x_3)$ *girdileri*, $(w_1, w_2$ ve $w_3)$ ağırlıkları ve f aktivasyon fonksiyonunu temsil eder. o , çıktı değeri aşağıdaki denklemle verilir :

$$o = f(\sum_{i=1}^n w_i x_i) \quad (2.2.1)$$

Tablo 2.1 biyolojik nöronlar ve yapay nöronlar arasındaki ilişki verilmektedir

Biyolojik nöron	Yapay nöron
Sinaps	Bağlantı ağırlığı
Akson	çıkış sinyali
Dendrit	giriş sinyali
soma	aktivasyon fonksiyonu

2.2.3. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu (veya transfer fonksiyonu), bir nöronun girdilerinin ağırlıklı toplamının sonucunu (*net*) bir çıktı değerine dönüştürmek için kullanılır; bu dönüşüm, nöronun *net* değerinin hesaplanmasıyla doğrusal olmayan bir işlev getirilerek gerçekleştirilir.

Sapma (b) bir eşik rolü oynar, ağırlıklı toplamın sonucu bu eşığı aştığında, transfer fonksiyonunun argümanı pozitif veya sıfır olur; aksi takdirde negatif kabul edilir.

Son olarak, ağırlıklı toplamın sonucu:

- Eşğin altında, nöronun aktif olmadığı kabul edilir.
- Eşğin etrafında, nöronun bir geçiş aşamasında olduğu kabul edilir.
- Eşğin üzerinde, nöronun aktif olduğu kabul edilir.

Farklı birkaç tür transfer işlevi vardır. YSA'larda sıklıkla kullanılan aktivasyon fonksiyonları aşağıda gösterilmiştir:

- Doğrusal

$$f(x) = x \quad (2.2.2)$$

- Eşik

$$f(x) = \begin{cases} 0, & x > 0 \\ 1, & x < 0 \end{cases} \quad (2.2.3)$$

- Sigmoid

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.2.4)$$

- Lojistik (λ eğim parametresi)

$$f(x) = \frac{1}{1+e^{\lambda-x}} \quad (2.2.5)$$

- Hiperbolik tanjant

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2.6)$$

- Sinüs

$$f(x) = \sin(x) \quad (2.2.7)$$

- Kosinüs

$$f(x) = \cos(x) \quad (2.2.8)$$

2.2.4. Öğrenme

Öğrenme, bir sinir ağının geliştirilmesinde çok önemli bir aşamadır; bu sırada, ağın davranışı, istenen davranış elde edilene kadar yinelemeli olarak değiştirilir. Öğrenme aynı zamanda ağın eğitimi için kullanılan veriler arasındaki uygunlukların çıkarılmasından ibarettir, ancak öğrenmenin temel amacı problemin tahmin ya da sınıflandırma yoluyla çözülmesidir. Bir YSA için öğrenme, ağın deneyime ve örneklerle yanıtını ayarlamak için ağ içindeki ağırlıkları güncelleme süreci olarak da görülebilir.

Denetimli öğrenme, takviye öğrenme ve denetimsiz öğrenme olmak üzere üç kategoriye ayrılabilen birkaç tür öğrenme kuralı vardır.

2.2.4.1. Denetimli öğrenme

Bir öğrenmenin, ağ belirli bir son duruma yaklaşmaya zorlandığında, aynı zamanda bir modelle sunulduğunda denetlendiği söylenir. Genel olarak, denetimli yapay öğrenme, girdi örneklerini ve ilgili istenen çıktıları içeren bir öğrenme tabanından bir tahmin modeli (sınıflandırma veya tahmin) oluşturmayı içerir.

Model parametreleri, böylece her seferinde elde edilen çıktılar ile istenen çıktıları karşılaştırarak uyarlanmaktadır. Model bir eğitim üssü tarafından elde edildikten sonra, eğitim sırasında kullanılmayan yeni örnekler de dahil olmak üzere bir test tabanının kullanılması, yöntemin performansının ölçülmesine izin verir.

2.2.4.2. Denetimsiz öğrenme

Denetimli öğrenmeden farklı olarak, bu tür öğrenme, belirli girdiler için istenen çıktılar hakkında önceden bilgi bulunmadığında seçilir. Aslında ağ, girdilerle birlikte sunulduğunda herhangi bir son duruma yaklaşma durumu serbest bırakılmıştır.

2.2.4.3. Takviye öğrenme

Güçlendirilmiş öğrenme, ağa istenen sonuçları sağlamak yerine ağın birkaç yinelemeden sonra ne kadar iyi performans gösterdiğinin bir ölçüsü olan bir not (veya puan) verilmesi farkıyla, denetimli öğrenmeye benzer bir tekniktir. Gelişmiş öğrenme prosedürünü kullanan algoritmalar esas olarak kontrol sistemleri alanında kullanılır.

2.2.5. Mimari Yapı

Mimari yapı, YSA ların sınıflandırılmasında belirleyici bir rol oynayan çok önemli bir kavramdır. Her mimarinin çok özel uygulamalara uyarlanmış kendi organizasyonu vardır.


2.2.6. İleri Beslemeli Yağay Sinir Ağları

Bu tür bir ağın özelliği, bilginin herhangi bir geri bildirim olmaksızın (girdilerden çıktılara) tek yönde yayılmasıdır yada bilginin katmandan katmana geri gitmeden art arda yayıldığı ağlardır. Bu tür ağlar, hataların düzeltilmesiyle, nöronların ağırlıklarını güncellemek için hata sinyalinin girişlere doğru geri yayıldığı denetimli bir öğrenme kullanır.

2.2.6.1. Tek Katmanlı Algılayıcı

Bir giriş katmanı ve bir çıkış katmanından oluşan bileşimi sayesinde çok basit bir ağ olan tek katmanlı algılayıcıyı tanımlar. Algılayıcı, en basit sinir ağı türü olarak görülebilir. Bu ağ doğrusal olarak ayrılabilir sorunları çözebilir

Ağ, giriş bilgilerinin alınmasıyla tetiklenir. Bu ağdaki veri işleme, tümü birbirine bağlı olan giriş katmanı (x_1, x_2 ve x_3) ile çıktı katmanı (o) arasında gerçekleşir.




Şekil 2.3. Tek katmanlı bir ağıın mimarisi

2.2.6.2.Çok katmanlı algılayıcı

Basit algılayıcıdan farklı olarak, çok katmanlı algılayıcı, giriş katmanı ile çıkış katmanı arasında bir veya daha fazla gizli katmana sahiptir. Bu nedenle, çok katmanlı bir algılayıcı, doğrusal olmayan sorunları çözümler. Çok katmanlı YSA temelde üç tür katman içerirler:


- *Giriş Katmanı:* Bu katmandaki nöronlar, ağdan giriş değerlerini alır ve bunları gizli nöronlara iletir. Her nöron bir değer alır, bu nedenle bir toplama eklemes.
- *Gizli katmanlar:* Bu katmandaki her nöron, önceki katmandan bilgi alır, ağırlıklı toplamayı gerçekleştirir, ardından bunu genellikle sigmoid bir işlev olan aktivasyon işlevine göre dönüştürür ve bir sonraki katmandaki nöronlara gönderir.
- *Çıktı Katmanı:* Gizli katmanlarla aynı rolü oynar, bu iki katman türü arasındaki tek fark, çıktı katmanındaki nöronların çıktısının başka bir nörona bağlı olmamasıdır.



Şekil 2.4. Çok katmanlı bir ağın mimarisi

2.2.7. Geri Beslemeli/Yinelenen Ağlar

Bu tür ağlar, bilginin kısmen veya tamamen yinelemeli olarak dolaşımına izin verme gücü ile karakterize edilir. "Yinelenen ağlar" olarak da adlandırılırlar ve geri dönmenin mümkün olduğu ağlardır.



Şekil 2.5. Geri beslemeli öğrenme algoritması

2.2.8. Öğrenme Algoritması

Öğrenme algoritması, ağın istenen görevi gerçekleştirmesini sağlayacak bir çözüme yaklaşmak için bağlantıların ağırlıklarını değiştirecek matematiksel yöntemdir. Öğrenme algoritması, bir veya daha fazla girdi değeri verilen bir hedef değer "tahmin edilmesini" mümkün kılar. Çoğu zaman, bir dizi geçmiş değere karşılık gelen bir veya daha fazla gelecekteki değerin tahminini temsil eder. Öğrenme algoritmasının amacı, elde edilen modelin matematiksel temsili olan f fonksiyonunu bulmaktır. Bu soruna yanıt vermek için birçok yöntem geliştirilmiştir. Bir yöntem, f fonksiyonunu tanımladığımız bir model ve bu fonksiyonun belirlendiği bir öğrenme algoritması ile tanımlanabilir. Tahmin alanında, gradyan geri yayılım algoritması en iyi bilinendir. Ancak son yıllarda yapay sinir ağlarının eğitiminde parçacık sürü optimizasyonu ve genetik algoritmalar gibi farklı yapay zeka optimizasyon algoritmaları sıklıkla kullanılmaktadır. Bu tez çalışmasında önerilen ARCH-B-YSA için de eğitim algoritması olarak genetik algoritma tercih edilmiştir.

2.3. GENETİK ALGORİTMA

Genetik algoritma, evrimsel algoritmalar ailesine aittir. Bu algoritmanın temel amacı, kesin bir yöntem olmadığında (veya çözüm bilinmediğinde) bir optimizasyon problemine yaklaşık bir çözüm elde etmektir. Genetik algoritma, doğal seçim kavramını alır ve bunu belirli bir probleme yönelik potansiyel çözümler popülasyonuna uygular.

Literatür ile ilgili, bu algoritma araştırmacı Holland (1975) tarafından yapılmıştır. GA konusunda birçok çalışma yapılmıştır ve ilk çalışmalar uluslararası konferansların kataloglarında yayınlanmıştır. Daha sonra çeşitli GA kitapları yayınlanmaya başlandı. En çok başvuru alan kaynak kitaplar; Holland (1975), Goldberg (1989), Michalewicz (1992), Mitchell (1996), Gen ve Cheng (1997), Vose (1999) ve Back ve diğerleri. (2000) olarak sıralanabilir.

Genetik algoritmalar, doğal genetik kelime dağarcığını kullanır. Popülasyon adı verilen bir grup birey üzerinde çalışırlar. Bir bireyin fenotip ve genotip olarak adlandırılan iki temsili vardır. Fenotip, problemin orijinal formülasyonu kullanılarak optimize edilecek problemin potansiyel bir çözümünü temsil eder. Genotip, bir kromozom formunda potansiyel bir çözümün kodlanmış bir temsilini verir. Bir kromozom, lineer bir dizi halinde düzenlenmiş genlerden oluşur ve her gen, alel adı verilen birkaç değeri alabilir. genetik algoritmanın 4 kavramı vardır (Popülasyon, Birey, Kromozom ve Gen kavramlarını).

Popülasyon: olası çözümler kümesidir.


Birey: bir çözümü temsil eder.

Kromozom: çözümün bir parçasıdır ya da bir değerler zinciri oluşturmak için birbirine bağlanan bir dizi parametredir.

Gen: bir özellik, bir özelliktir.

Bir kromozom, 0 lar ve 1 ler dizisinden oluşur. Sembollerin sırası ve alfabelerin permütasyonu gibi daha karmaşık formlar, optimize edilecek problemin kromozomlarını tanımlamak için seçilir.

Her bireyin, bireyin yerel çevresine uyumunu ölçen bir amaç f fonksiyonu (fitness fonksiyonu) vardır. Darwinci teori, bir popülasyondaki bireyler arasında, yerel çevreye en iyi adapte olanın hayatta kalma ve daha fazla sayıda torun sahibi olma şansının en yüksek olduğunu gösterir: En uygun olanın hayatta kalması kuralıdır. Böylece, optimizasyon probleminin f amaç fonksiyonu, bir uyarılma kriteri rolünü oynar. Genetik algoritmaların en önemli noktalarından biri amaç fonksiyonundaki esnekliktir.



Şekil 2.6. genetik algoritmanın kavramları.

Genetik algoritmalar (GA), aşağıdakileri uygulayan doğal üreme fenomenlerine dayanır: çaprazlama, mutasyon ve seçim. Uygun kodlama yoluyla, sınırlı bir süre içinde karmaşık optimizasyon problemlerine iyi çözümler bulmayı sağlarlar. Bir genetik algoritma şu üç operatörü kullanır: seçme, çaprazlama ve mutasyon.


Seçim: En uygun bireylerin seçimi. Seçim, bir popülasyondan bireylerin, yeni bir popülasyon oluşturmak için maliyet değerlerine veya uygunluk işlevine göre seçildiği bir süreçtir. Bireyler, nesiller adı verilen ardışık seçim yinelemeleri yoluyla gelişirler. Her birey kendi "uygunluk" işleviyle orantılı olarak seçilir, bu nedenle, "uygunluk" işlevi yüksek olan bir bireyin, "uygunluk" değeri düşük olan bir başkasına göre seçilme olasılığı daha yüksek olacaktır. Bu fonksiyon, bir kişinin maksimize etmek istediği bir kâr veya kalite ölçüsü olarak görülebilir.

Çaprazlama: Seçilen bireylerin özelliklerinin çoğaltılması yoluyla karışım. Melezleme bir rekombinasyon operatörüdür. Bir popülasyondaki bireyler, ebeveynleri temsil eden çiftler halinde rastgele eşleştirilir. Her birey çifti, aşağıda açıklanan

çaprazlamadan geçer: Çaprazlama, ebeveyn olarak adlandırılan iki bireyin genotipleri (yani kromozomlar) üzerinde çalışır. Genleri bir veya diğer ebeveynden miras alınan çocuk adı verilen yeni bireyler (genellikle iki) üretir. Bu, iki kromozomun her birini parçalara ayırarak ve onları yeni kromozomlar oluşturmak üzere yeniden birleştirerek yapılabilir.

Çaprazlanacak kromozom çiftlerinin seçimi GA'nın işleyişinde önemli bir yere sahiptir. Literatürde farklı seçim yöntemleri önerilmiştir. En çok kullanılan seçim yöntemleri; Uygunlukla orantılı seçim (Goldberg 1989), rulet çemberi seçimi (Goldberg 1989), sıralama seçimi (Baker 1985), turnuva seçimi (Joines ve Houck 1994) ve değiştirmesiz seçim (Goldberg 1989) olarak sıralanabilir.


Mutasyon: Bir bireyin özelliklerinin rastgele değişmesi. Mutasyon, tek bir bireyin genotipi üzerinde çalışır. Doğada, kromozom kopyalandığında ve yeniden üretildiğinde meydana gelen bir hataya karşılık gelir. Sayısal bir yaklaşımda, bir ikili zincir için, örneğin 0 ve 1 arasında bir alel değişimi yapmaktan ibarettir. Kesin kopyalar her zaman garanti ediliyorsa, mutasyon oranı sıfırdır. Ancak gerçek hayatta, gürültü etkisi gibi çeşitli durumlarda kopyalama hatası meydana gelebilir. Mutasyon, bazı genlerin değerlerini düşük bir olasılıkla değiştirir. Genellikle çözümleri iyileştirmez, ancak onarılamaz bir çeşitlilik kaybını önler.



Şekil 2.7. GA'nın diyagramı

2.4. BASAMAKLI (CASCADE) YAPAY SİNİR AĞI


Basamaklı yapay sinir ağı (B-YSA) Demuth (Demuth & Raelle, 2009) tarafından Fahlman (S. Fahlman, 1990), ve Fahlman ve Lebiere (S. E. Fahlman & Lebiere, 1992) tarafından ortaya atılan basamak korelasyon yaklaşımı (cascade correlation approach) temel alınarak önerilen bir çeşit çok katmanlı ileri beslemeli yapay sinir ağıdır. Tıpkı diğer klasik ileri-beslemeli yapay sinir ağları gibi, B-YSA mimarisi de girdi, çıktı ve gizli katman(lar)dan oluşur. B-YSA'yı diğer ileri beslemeli YSA'lardan farklı kılan yönü her katmanın kendinden önceki tüm katmanlarla bağlantılı olmasıdır. B-YSA'yı diğerlerinden ayıran ve üstün kılan bir diğer özelliği ise girdiler ve çıktılar arasındaki doğrusal ve doğrusal olmayan ilişkileri birlikte ve eş zamanlı olarak modelleyebilmesidir. Bu özelliğe gizli katmanda kullandığı sigmoid aktivasyon fonksiyonu ve çıkış katmanında kullandığı doğrusal aktivasyon fonksiyonu sayesinde sahip olur. İki gizli katmana sahip basit bir B-YSA mimarisi Şekil 5.1'de verilebilir.



Şekil 2.8. Basit bir B-YSA mimarisi

BÖLÜM 3. MATERYAL VE YÖNTEM

Birçok YSA modeli ve yaklaşımının ortaya konduğu zaman serisi öngörü literatüründe halen aşılması ve çözümlenmesi gerekli bazı problemlerin varlığından söz edilebilir. Literatürde mevcut YSA modellerinin hemen hemen tamamı, zaman serisinin barındırdığı doğrusal ya da doğrusal olmayan ilişkileri çözümlemeye yönelmişlerdir. Doğrusal ve doğrusal olmayan ilişkilerin birlikte çözümlenebildiği az sayıda YSA modeli zaman serisi literatüründe mevcut olmasına karşın bunlar da özellikle finansal zaman serisi öngörü problemlerinde karşılaşılan, değişen varyans problemini göz ardı ederler. Değişen varyans özelliği içeren zaman serilerinin analizi için ARCH yapısı içeren bir YSA modeli önerilmiş olmasına karşın bu modelde de yalnızca doğrusal yapıda olmayan ilişkiler modellenebilmektedir. Bu bakımdan, literatür incelendiğinde, hem değişen varyans sorununu dikkate alan ve hem de girdiler ile çıktı arasında doğrusal ve doğrusal olmayan ilişkileri bir arada modelleyebilecek bir YSA türünün eksikliği göze çarpmaktadır. Literatürdeki bu boşluğu doldurmak adına, bu tez çalışmasında, artıkların karelerini model girdisi olarak besleyerek ARCH yapısı oluşturan ve girdiler ile çıktı arasında doğrusal ve doğrusal olmayan ilişkileri birlikte eş zamanlı olarak çözümleyebilen bir YSA modeli olan Basamaklı-İleri Beslemeli-Yapay Sinir Ağı, tekrarlayan (recurrent) bir yapıya dönüştürülerek kullanılmıştır. Burada “tekrarlama” işlevi artıkların karelerinin girdi tabakasına iletilmesi ve birer YSA girdisi olarak beslenmesi ile ARCH yapısının oluşumunu sağlamaktadır (ARCH-B-YSA). Oluşturulan ARCH-B-YSA mimarisi Şekil 3.1 ile verilebilir.



Şekil 3.1. ARCH-B-YSA mimarisi

Ortaya konan bu ARCH-B-YSA'nın eğitim algoritması olarak genetik algoritma tercih edilmiştir. Genetik algoritma ile eğitimi gerçekleştirilen ARCH-B-YSA'nın çalışma prensibi iki algoritma ile verilebilir. İlk algoritma ARCH-B-YSA'nın girdilere karşılık çıktı üretme sürecini içerirken, diğeri ARCH-B-YSA'nın eğitim sürecini içerir.

Algoritma 1: ARCH-B-YSA modelinin çıktı üretme süreci

Şekil 6.1 ile verilen mimari yapıya sahip ARCH-B-YSA'nın girdileri zaman serisinin p adet gecikmeli değişkenin yanı sıra artıklara ilişkin karesel ifadelerin m adet gecikmeli değerlerinden oluşmaktadır. Böylece, T adet öğrenme örneğinden oluşan bir zaman serisi verisi için ARCH-B-YSA $p + m$ adet girdiye sahiptir. Ayrıca, bu girdiler ile gizli tabaka birimleri arasında bağlantıları gösteren w_t^{ij} ($i = 1, 2, \dots, K; j = 1, 2, \dots, p; t = 1, 2, \dots, T$) ve $e w_t^{il}$ ($i = 1, 2, \dots, K; l = 1, 2, \dots, m; t = 1, 2, \dots, T$)

ağırlıkları ve her bir gizli tabaka birimi için b_t^i ($i = 1, 2, \dots, K$; $t = 1, 2, \dots, T$) yanları söz konusudur. Gizli tabaka birimleri ile çıktı tabakası birimi arasındaki bağlantıyı sağlayan ağırlıklar ${}^H w_t^i$ ($i = 1, 2, \dots, K$; $t = 1, 2, \dots, T$) ile temsil edilirken çıktı tabakası biriminin yanı b_t^o ($t = 1, 2, \dots, T$) ile temsil edilir. Son olarak girdi tabakası ile çıktı tabakası arasında bağlantıları sağlayan ${}^I W_t = [{}^I w_t^1 \ {}^I w_t^2 \ \dots \ {}^I w_t^{p+m}]$ ağırlık vektörü girdilerin direkt olarak çıktı tabakasına olan bağlantılarını sağlar.

Adım 1. İterasyon sayıcı k ($k = 0$) oluşturulur.

Adım 2. İterasyon sayıcı k , $k = k + 1$ olacak şekilde yeniden ayarlanır. k 'inci öğrenme örneği için çıktı hesabı gerçekleştirilir.

$k = 1$ olduğunda model girdileri $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ gecikmeli zaman serisi değişkenlerinin yanı sıra artıkların karelerine ilişkin $e^2(t-1), e^2(t-2), \dots, e^2(t-m)$ gecikmeli değişkenleri temsilen $1 \times m$ boyutlu bir sıfır vektörünün ($[0 \ 0 \ \dots \ 0]$) elemanlarından oluşur. $k = 2$ olduğunda ise $e^2(t-1)$ hesaplanabilir ve artıkların karelerine ilişkin girdiler $[e^2(t-1) \ 0 \ \dots \ 0]$ vektörünün elemanlarından oluşur. $k \leq m$ olduğu durumlarda elemanları artıkların karelerine ilişkin girdileri oluşturan vektörün son $m - k$ elemanı yine sıfır (0) olacaktır. $k > m$ olduğu durumlarda ise artıkların karelerine ilişkin girdiler hesaplanan $e^2(t-l)$ değerlerinden oluşacaktır. Böylece k 'inci öğrenme örneği için i 'inci gizli tabaka birimine ait *net* değeri denklem (6.1) ile hesaplanır.

$$net_i^k = \left(\sum_{j=1}^p y_{t-j} w_t^{ij} \right) + \left(\sum_{l=1}^m e^2(t-l) {}^e w_t^{il} \right) + b_t^i; \quad i = 1, 2, \dots, K \quad (3.1)$$

i 'inci gizli tabaka birimine ait *çıktı* değeri ise doğrusal olmayan *sigmoid* (lojistik) aktivasyon fonksiyonu f_1 vasıtasıyla denklem (6.2) de verildiği gibi hesaplanır.

$${}^H cıktı_i^k = f_1(net_i^k) = \frac{1}{1 + \exp(-net_i^k)} \quad (3.2)$$

k 'inci öğrenme örneği için çıktı tabakası birimine ait *net* değeri ise hem gizli tabakadan gelen değerler hem de girdi tabakasından direk çıktı tabakasına beslenen girdiler kullanılarak denklem (6.3) ile hesaplanır.

$$net_t^o = \left(\sum_{j=1}^p y_{t-j} {}^I w_t^j \right) + \left(\sum_{l=1}^m e^2(t-l) {}^I w_t^l \right) + \left(\sum_{i=1}^K {}^H cıktı_i^k {}^H w_t^i \right) + b_t^o \quad (3.3)$$

Nihayet k 'ıncı öğrenme örneği için ARCH-B-YSA çıktısı doğrusal aktivasyon fonksiyonu f_2 vasıtasıyla (6.4) ile verildiği gibi hesaplanır.

$$çiktı_t = f_2(net_t^o) = net_t^o \quad (3.4)$$

Adım 3. Bir sonraki öğrenme örneği için girdi olarak kullanılmak üzere artıkların karelerine ilişkin $e^2(t)$ değerinin hesabı gerçekleştirilir.

$$e^2(t) = (hedef_t - çiktı_t)^2 \quad (3.5)$$

Adım 4. Eğer $k \leq T$ ise Adım 2'ye dönülerek iterasyon sayıcı k , $k = k + 1$ olacak şekilde yeniden ayarlanır, aksi halde algoritma sonlandırılır.

ARCH-B-YSA modelinin genetik algoritma ile eğitimi bir algoritma ile adım-adım bir süreç halinde verilebilir.

Algoritma 2: ARCH-B-YSA modelinin eğitim süreci

Adım 1. Süreç parametreleri belirlenir.

ps : Popülasyon genişliği - kromozom sayısı (*tez kapsamında 200 alınmıştır*)

ss : Seleksiyon operatörü uygulanacak kromozom genişliği - gelecek nesile aktarılması uygun olmayan ve direkt olarak popülasyondan çıkarılarak yerlerine yeni bireyler (kromozomlar) üretilecek bireyler (*tez kapsamında $0.05 \times ps$ alınmıştır*)

es : Elit kromozom genişliği -gelecek nesile aktarılması garanti olan kromozom sayısı (*tez kapsamında $0.05 \times ps$ alınmıştır*)

co : Çaprazlama oranı - (*tez kapsamında 0.80 alınmıştır*)

mo : Mutasyon oranı - (*tez kapsamında 0.01 alınmıştır*)

$MaxG$: Maksimum nesil ya da iterasyon sayısı - (*tez kapsamında karar değişkeni sayısı $\times 100$ alınmıştır*)

Adım 2. Başlangıç popülasyonu oluşturulur.

Populasyonu oluşturan her bir kromozom;

Girdi-Gizli Tabaka Birimleri Arası Ağırlıklar için: $(p + m) \times K$ adet


Gizli Tabaka Birimleri Yanlar için: K adet

Gizli-Çıktı Tabaka Birimleri Arası Ağırlıklar için: K adet

Girdi-Çıktı Tabaka Birimleri Arası Ağırlıklar için: $(p + m)$ adet

Çıktı Tabaka Birimi Yanı için: 1 adet

olmak üzere toplamda : $(p + m) \times (K + 1) + 2K + 1$ gene sahiptir. Bir kromozomun yapısı Şekil 6.2



Şekil 3.2. Bir kromozom yapısı

Tez kapsamında tüm bireylere ilişkin genlerin rastgele üretilmesi $[-1, 1]$ aralığından düzgün dağılımdan sayı üretme stratejisi ile gerçekleştirilmiştir.

Adım 3. Her bir birey için uygunluk değeri hesaplanır ve sıralanır

Tez kapsamında uygunluk fonksiyonu olarak (3.6) ile verilen hata kareler ortalaması karekökü (HKOK) fonksiyonu kullanılmıştır. Populasyonu oluşturan her bir kromozom;

$$HKOK = \sqrt{\frac{1}{T} \sum_{t=1}^T (hedef_t - çıktı_t)^2} \quad (3.6)$$

Adım 4. Durdurma kriteri kontrol edilir

Durdurma kriteri olarak önceden belirlenmiş bir nesil (iterasyon) sayısı ($MaxG$) belirlenir. Eğer $MaxG$ sağlanmış ise algoritma Adım 9 ile devam eder, aksi halde bir sonraki adıma geçilir.

Adım 5. Doğal seleksiyon yaklaşımı uygulanır

Belirlenen $ss = 0.05 \times 200 = 10$ adet kadar en kötü uygunluk değerine sahip birey popülasyondan atılarak yerine aynı sayıda yeni birey üretilir.

Adım 6. Elitizm yaklaşımı uygulanır

En iyi uygunluk değerine sahip olan $es = 0.05 \times 200 = 10$ adet *elit* kromozom belirlenir ve bir sonraki nesile direkt olarak aktarılır.

Adım 7. Çaprazlama prosedürü uygulanır

Çaprazlama oranı $co = 0.80$ ve çaprazlama prosedürüne göre *Rulet Tekerleği* yöntemi vasıtasıyla oluşturulan eşleştirme havuzları kullanılarak çaprazlama işlemi uygulanır.

Adım 8. Mutasyon prosedürü uygulanır

Mutasyon oranı $mo = 0.01$ ve mutasyon prosedürüne göre belirlenen bireyler için mutasyon işlemi uygulanır.

Adım 9. Optimal ağırlık ve yanlar belirlenir

Popülasyondaki en iyi uygunluk değerine sahip kromozoma ait genler optimal ağırlık ve yan değerleri olarak belirlenir.


BÖLÜM 4. ARAŞTIRMA BULGULARI

Önerilen ARCH-B-YSA modelinin zaman serisi öngörü performansı farklı zaman serilerinin çözülmesi ve elde edilen sonuçların farklı öngörü model sonuçları ile birlikte değerlendirilmesi ile ortaya kondu. Bu amaçla 2011-2013 yıllarında gözlenmiş BIST-100 indeksi zaman serisi ve “*Uluslararası Zaman Serisi Öngörü Yarışması - CIF2016*” kapsamında kullanılan toplam 72 zaman serisinden 108 gözlemlilik 48 adet zaman serisinin analizi gerçekleştirilmiştir.


4.1. BIST-100 zaman serisi analizi

Uygulamada ilk olarak, sırasıyla Şekil 7.1-7.3 ile grafikleri verilmiş, 2011, 2012 ve 2013 yıllarında gözlenmiş 106 gözlemlilik 3 farklı BIST-100 zaman serisi çözülmiştir.


Çözümlemede her bir zaman serisine ilişkin test kümesi son 7 ve son 15 gözlemden oluşacak şekilde iki farklı boyutta belirlenmiş ve böylece toplamda 6 farklı analiz gerçekleştirilmiştir.



Şekil 4.1. 2011 yılı BIST-100 zaman serisi (01.03.2011-05.31.2011)



Şekil 4.2. 2012 yılı BIST-100 zaman serisi (01.02.2012-05.31.2012)



Şekil 4.3. 2013 yılı BIST-100 zaman serisi (01.02.2013-05.31.2013)

Analizler sonucunda elde edilen sonuçlar aşağıda verilen ve bazı klasik yaklaşımların yanı sıra bazı farklı bulanık küme tabanlı ve YSA tabanlı modelleri içeren 7 farklı öngörü modelinin sonuçları ile birlikte değerlendirilmiştir. Bu değerlendirme HKOK kriterinin yanı sıra, eşitlik (4.1) ile verilen, zaman serisinin biriminden bağımsız yüzdelik bir hata ölçütü olan (OMYH) ortalama mutlak yüzdelik hata kriterleri üzerinden gerçekleştirilmiş ve bulgular Tablo 4.1 ile özetlenmiştir.

ARIMA	: Otoregresif bileşik hareketli ortalama modeli
GARCH	: Genelleştirilmiş Otoregresif Koşullu değişen varyans
ES	: Üstel düzeltme modeli.
ÇKA-YSA	: Çok katmanlı algılayıcı yapay sinir ağı.
SC	: Zamanla değişmez bulanık zaman serisi öngörü modeli (Song-Chissom, 1993)
FF	: Tip 1 bulanık fonksiyonlar yaklaşımı (Türkşen, 2008)
ARCH-TÇNM	: ARCH yapılı tek çarpımsal nöron model YSA (Corba, 2020)


$$OMYH = \frac{1}{T} \sum_{t=1}^T \left| \frac{hedef_t - \hat{c}lktl_t}{hedef_t} \right| \quad (4.1)$$

Tablo 4.1 incelendiğinde bu tez kapsamında önerilen ARCH-B-YSA modelinin BIST-100 zaman serileri için gerçekleştirilen 6 farklı analizin 5'inde hem HKOK hem de OMYH kriterleri bakımından en üstün öngörü performansını sergilediği görülmektedir. En üstün performansı sergileyemediği 2013 yılında gözlemlenmiş ve test kümesi genişliğinin 7 gözlemde olduğu çözümleme için de her iki hata ölçütü bakımından ikinci en üstün performansı sergilediği ve ayrıca %0.79 OMYH değerine sahip öngörüler ürettiği dikkate alındığında oldukça başarılı ve diğer modellerle rekabet edebilir bir performans sergilediği söylenebilir. Ayrıca, her bir çözümleme için önerilen ARCH-B-YSA modelinin ne düzeyde bir öngörü performansı ilerlemesi sağladığı incelendiğinde, BIST-2011 verisi için HKOK hata ölçütü bakımından, test kümesi genişliğinin 7 ve 15 olduğu durumlar için sırasıyla, yaklaşık %17 ve %13 düzeyinde bir öngörü performansı ilerlemesinden söz edilebilir. Yine BIST-2012 verisi için bu ilerleme oranları test kümesi genişliğinin 7 ve 15 olduğu durumlar için sırasıyla yaklaşık %28 ve %7 olarak ortaya çıkmıştır.


Her bir çözümleme sonucunda elde edilen öngörüler ile birlikte zaman serisine ilişkin gözlenmiş değerlerin birlikte grafikleri ise Şekil 4.4-4.9 ile verilmiştir.

Tablo 4.1 BIST-100 analiz sonuçları


Zaman Serisi	Test Kümesi Genişliği	ARIMA		GARCH		ES		ÇKA-YSA		SC		FF		ARCH-TÇNM		ARCH-B-YSA		
		Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	Kriter Değeri	Sıra No	
BIST-2011	7	1058	5	1155	7	1057	4	920	2	1396	8	1083	6	932	3	764	1	HKOK
		1.44%	4	1.47%	6	1.44%	4	1.28%	3	2.00%	8	1.53%	7	1.24%	2	1.06%	1	OMYH
	15	1130	4	3769	8	1130	4	1096	3	1360	7	1146	6	1054	2	914	1	HKOK
		1.50%	4	5.45%	8	1.50%	4	1.46%	3	1.89%	7	1.56%	6	1.38%	2	1.24%	1	OMYH
BIST-2012	7	651	3	1907	8	651	3	775	5	1292	7	1034	6	565	2	408	1	HKOK
		0.84%	3	3.42%	8	0.84%	3	1.11%	5	1.83%	7	1.62%	6	0.82%	2	0.66%	1	OMYH
	15	621	3	2770	80	621	3	783	5	1047	7	1038	6	612	2	571	1	HKOK
		0.88%	2	4.40%	8	0.88%	2	1.17%	5	1.53%	6	1.61%	7	0.89%	4	0.77%	1	OMYH
BIST-2013	7	1362	4	4926	8	1362	4	1315	3	1450	6	1512	7	709	1	877	2	HKOK
		1.16%	5	5.12%	8	1.16%	5	1.09%	4	1.08%	3	1.31%	7	0.71%	1	0.79%	2	OMYH
	15	1269	3	2733	8	1269	3	1233	2	1931	7	1279	5	1427	6	1189	1	HKOK
		1.09%	4	2.61%	8	1.09%	4	1.07%	2	1.76%	7	1.08%	3	1.27%	6	1.00%	1	OMYH
ORTALAMA SIRA		3.67		19.83		3.50		3.33		7.00		6.00		2.67		1.17		HKOK
		3.67		7.67		3.67		3.67		6.33		6.00		2.83		1.17		OMYH
		3.67		13.75		3.58		3.50		6.67		6.00		2.75		1.17		GENEL




Şekil 4.4. Öngörü ve gerçek değerler - BIST-2011 – 7 test kümesi




Şekil 4.5. Öngörü ve gerçek değerler - BIST-2011 – 15 test kümesi




Şekil 4.6. Öngörü ve gerçek değerler - BIST-2012 – 7 test kümesi



Şekil 4.7. Öngörü ve gerçek değerler - BIST-2012 - 15 test kümesi



Şekil 4.8. Öngörü ve gerçek değerler - BIST-2013 - 7 test kümesi



Şekil 4.9. Öngörü ve gerçek değerler - BIST-2013 - 15 test kümesi

Şekil 7.4-7.9 incelendiğinde, önerilen ARCH-B-YSA modelinin ürettiği öngörülerin BIST-100 zaman serisine ilişkin gözlenmiş değerler ile oldukça uyumlu olduğu ve bu grafiklerin önerilen ARCH-B-YSA modelinin üstün öngörü performansının bir diğer kanıtı ya da destekleyicisi olduğu söylenebilir.

4.2. Uluslararası zaman serisi öngörü yarışması CIF2016 zaman serileri analizi

Önerilen ARCH-B-YSA modelinin öngörü performansının değerlendirilmesi amacıyla ikinci bir uygulama süreci olarak 2016 yılında gerçekleştirilen “uluslararası zaman serisi öngörü yarışması CIF-2016” kapsamında kullanılan 72 zaman serisinden 108 gözlemlili ilk 48 adet zaman serisinin analizi gerçekleştirilmiştir. 48 zaman serisine (CIF2016/ZS1- CIF2016/ZS48) ilişkin grafikler Ek Şekil 4.1-48 ile verilmiştir. Bu grafikler incelendiğinde, 48 zaman serisinin bazılarının artan, azalan, doğrusal ya da doğrusal olmayan trend içerdikleri ve ayrıca bazılarının ise durağanlık özelliğine sahip oldukları görülmektedir ki bu durum, önerilen ARCH-B-YSA modelinin farklı özelliklere sahip zaman serileri üzerindeki performansının ortaya konabilmesi açısından önemlidir. Tüm zaman serilerinde son 12 gözlem modellerin performansını değerlendirmek amacıyla test kümesi için ayrılmıştır. Çözümlemelerde, Çorba (2017) tarafından ortaya konan tez çalışmasında olduğu gibi, zaman serisi gecikmeli değişkeni sayısı 2, 4 ve 12 ve gecikmeli karesel artık sayısı da 1 ve 2 olarak alınmıştır. Böylece her bir zaman serisi için 6 ve toplamda 288 çözümleme gerçekleştirilmiştir. Ayrıca her bir zaman serisi için tüm çözümlemeler 50 kez tekrarlanmış ve elde edilen sonuçlar Çorba (2017) tarafından ortaya konan tez çalışmasında verilen sonuçlarla birlikte değerlendirilmiştir. Sonuçlara ilişkin ortalama HKOK değerleri Ek Tablo 7.2-49 ile verilmiştir. Ek Tablo 4.2-49 ile verilen özet sonuçlar incelendiğinde toplam 50 kez gerçekleştirilmiş 288 çözümlemeden 204’ünde önerilen ARCH-B-YSA, 47’sinde ARCH-TÇNM, 10’unda TÇNM ve 27’sinde ÇKA-YSA modeli ortalama HKOK değerleri bakımından en üstün performansa sahiptir.

BÖLÜM 5. SONUÇ VE ÖNERİLER


Zaman serisi öngörü problemi bir çok alanda karşılaşılan ve karar vericilerin ve bilim insanlarının üzerinde yoğun bir şekilde çalıştıkları bir konu olarak ön plandadır. Zaman serisi öngörü literatüründe klasik olarak değerlendirilebilecek farklı yaklaşımların yanı sıra Box-Jenkins prosedürü ile ortaya konan ARIMA modelleri yaygın bir şekilde kullanılmaktadır. Bunun yanı sıra özellikle finansal zaman serilerinin modellenmesinde ortaya çıkabilen değişen varyans sorununu dikate alan ve hataları ve/veya hataların karelerinin modelleme sürecine dahil eden ARCH-GARCH modelleri de yaygın ve başarılı bir şekilde kullanılmaktadır. Bu yaklaşımlar farklı avantajlara sahip olmasına karşın belirli bir model kalıbı içermesi dolayısıyla doğrusal olmayan zaman serilerini modellemede yetersiz kalabilmektedirler.

Yapay sinir ağları ise doğrusal ve doğrusal olmayan zaman serilerini modelleme konusundaki üstün yeteneklerinin yanı sıra bir model kalıbı gereksinimi duymamaları nedeniyle özellikle son birkaç on yıl içerisinde en popüler zaman serisi modelleme araçları olarak literatürde yerini almıştır. Bu alanda kullanılan bir çok yapay sinir ağı türü, zaman serisinin sahip olduğu doğrusal ya da doğrusal olmayan ilişkileri modelleyebilmesine karşın, bir çok zaman serisi hem doğrusal hem de doğrusal olmayan ilişkileri birlikte içermektedirler ve bu ilişkilerin eş zamanlı olarak tek bir sürecin içerisinde modellenmesi daha üstün öngörü performansları doğuracaktır.

Bununla birlikte, zaman serisi modelleme sürecindeki diğer bir problem, özellikle finansal zaman serilerinde karşılaşılan volatilité kaynaklı değişen varyans problemidir ki bu problemi çözme amaçlı ARCH yapısı içeren literatürde tek bir yapay sinir ağı türü önerilmiştir. Önerilen bu yapay sinir ağı ise girdiler ile çıktılar arasında yalnızca doğrusal olmayan bir model oluşturur.

Bu tez kapsamında, ARCH yapılı bir yapay sinir ağı modeliyle girdiler ile çıktılar arasındaki doğrusal ve doğrusal olmayan ilişkileri birlikte eş zamanlı tek bir süreç içerisinde modelleyebilen bir zaman serisi öngörü aracı ortaya konmuştur. Bu doğrultuda, Basamaklı-İleri Beslemeli-Yapay Sinir Ağı (B-YSA - Cascade Forward Artificial Neural Network) tekrarlayan (recurrent) bir yapıya dönüştürülerek kullanılmış ve ağıın eğitimi genetik algoritma ile gerçekleştirilmiştir. Önerilen ARCH-

B-YSA'nın öngörü performansını değerlendirmek amacıyla öncelikle BIST-100 zaman serisi için 3 farklı yıla ilişkin veri setleri iki farklı test kümesi genişliği için analiz edilmiştir. 6 farklı çözümleme sonucunda ARCH-B-YSA, ikinci en iyi performansı sergilediği bir durum dışında en üstün öngörü performansını üretmiştir. Ayrıca, önerilen yöntemin öngörü performansı “uluslararası zaman serisi öngörü yarışması CIF-2016” kapsamında kullanılan 72 zaman serisinden 108 gözlemlilik 48 adet zaman serisinin analizi ile de test edilmiş ve her bir zaman serisi için 6 farklı durum için gerçekleştirilen 50 çözümleme sonucunda elde edilen hata ortalama ölçüt değerleri bakımından bir değerlendirme gerçekleştirilmiştir. Değerlendirme sonucunda toplamda 288 çözümleme için elde edilen ve Şekil 5.1 ile verilen sonuçlara ilişkin dağılım incelendiğinde, önerilen ARCH-B-YSA'nın tüm çözümlemelerin yaklaşık %71'inde ortalama HKOK bakımından en başarılı öngörü modeli olduğu görülmekle birlikte, GARCH-TÇNM ise çözümlemelerin %16'sında, ÇKA-YSA %9'unda ve TÇNM ise yalnızca %4'ünden en başarılı sonuçları ürettiği görülür.



Şekil 5.1. YSA modellerinin CIF-2016 zaman serileri analizi performans dağılımları

Sonuç olarak, basamaklı ileri beslemeli yapay sinir ağının hem doğrusal hem de doğrusal olmayan ilişkileri birlikte eş zamanlı tek bir süreç içerisinde modelleyebilmesi ve karesel hataların dikkate alındığı ARCH yapılı bir modelleme ile

değişen varyans sorununa çözüm üretebilmesi sayesinde ilgili zaman serilerinin çözümlenmesinde üstün bir başarı sergilediği görülmektedir.

Geleceğe ilişkin, oluşturulan ARCH-B-YSA'nın eğitiminin farklı algoritmalarla gerçekleştirilmesi ile performansın daha ileri taşınıp taşınamayacağı ve ayrıca zaman serilerinin içerebileceği aykırı değerler durumunda performansın ne düzeyde ve yönde etkileneceği araştırılabilir ve olası olumsuz etkilerin ortadan kaldırılması adına güçlü/dayanıklı bir eğitim algoritması ya da mimari yapısı ortaya konabilir.



KAYNAKLAR

Aladağ, C.H. 2011. A new architecture selection method based on tabu search for artificial neural networks. *Expert Systems with Applications*. 38 : 3287–3293.

Aladağ, C.H., 2013. Using multiplicative neuron model to establish fuzzy logic relationships. *Expert Syst Appl*. 40 (3): 850-853.

Aladağ, C.H., Eğrioglu, E., Günay, S., Başaran, M.A. 2010. Improving weighted information criterion by using optimization. *Journal of Computational and Applied Mathematics*. 233 : 2683 2687.

Aladağ, C.H., Yolcu, U., Eğrioglu, E., Dalar, A. Z. 2012. A new invariant fuzzy time series forecasting method based on particle swarm optimization. *Appl Soft Comput*. 12 : 3291-3299.

Alpaslan, F., İltar, D., Dalar, A. Z., Eğrioglu, E. 2015. Çarpımsal sinir hücresi modeline dayalı yapay sinir ağının yapay arı kolonisi algoritması ile eğitimi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 30(5): 363-375.

Awartani, M.A., Corradi, V. 2005. Predicting the Volatility of the S&P500 Stock Index via GARCH Models: The Role of Asymmetries. *International Journal of Forecasting*. 21 (1) : 167-183.

Back, T., Fogel, D.B., Michalewicz, Z. 2000. *Evolutionary computation 1: Basic algorithms and operators*.

Baker, J.E. 1985. Adaptive Selection Methods for Genetic Algorithms, In *Proceedings of an International Conference of Genetic Algorithms and Their Applications*. 101-111.

Bildirici, M., Oktay, S., Aykaç, E. 2007. İMKB’ de getiri değişkenliğinin hesaplanmasında ARCH/GARCH ailesi modellerinin kullanılması. 8. Türkiye Ekonometri ve İstatistik Kongresi. İnönü Üniversitesi. Malatya. 24-27 Mayıs.

Bollerslev, T. 1986. Generalized Autoregressive Conditional Heteroscedasticity. *J. Econ*. 31.

Box, G.E.P., Jenkins, G.M. 1970. Time series analysis: Forecasting and control. San Francisco: Holden-Day.

Bracker, K., Smith, K. L. 1999. Detecting and modeling volatility in the copper futures market. Journal of Futures Markets. 19 (1) : 79–100.

Carvalho, A. F., da Costa, J. S., Lopes, J. A. 2006. A systematic modeling strategy for futures markets volatility. Applied Financial Economics. 16 : 819-833.

Çorba, B. S. 2017. Zaman serisi öngörüsü için ar - arch tipli yapay sinir ağıları.

Çorba, B. S., Eğrioğlu, E., Dalar, A. Z. 2020. AR-ARCH Type Artificial Neural Network for Forecasting. Neural Process. 51(1): 819-836.

Demuth, H. B., Ruele, M. H., 2009. Neural Network Toolbox User's Guide for use with Matlab.

Dickey, D.A., Fuller, W.A. 1979. Distribution of the estimators for autoregressive time series with a unit root. Journal of the American Statistical Association. 74: 427–431.

Ederington, H. L., Guan, W. 2005 Forecasting volatility. Journal of Futures Markets. 25(5): 465-490.

Eğrioğlu, E., Aladağ, Ç.H., Günay, S. 2008. A new model selection strategy in artificial neural network, Applied Mathematics and Computation. 195 : 591- 597.

Engle, R.F. 1982. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom Inflation. Economica. 50 : 987-1007.

Fahlman, S., Lebiere, C. 1990 The Cascade-Correlation Learning Architecture. 524-532.

Fong, W.M. 1997. Volatility persistence on switching ARCH in Japanese Markets. Financial Engineering and the Japanese Markets. 4 : 37-57.

Gen, M., Cheng, R. 1997. Genetic algorithms and engineering design. John Wiley & Sons. New-York.

Glosten, L., Jaganathan, R., Runkle, D. 1993. On the relationship between the expected value and the volatility of the nominal excess return on shocks, *The journal of finance*. 48 (5) : 1779-1801.

Goldberg, D.E. 1989. *Genetic Algorithms in Search. Optimization and Machine Learning*, Addison Wesley. Reading. MA.

Hagerud, G. E. 1997. A new non-linear GARCH model. PHD thesis. IFE. Stockholm School of Economics.

Hebb, D. 1949. *The organization of behavior*. Wiley. NewYork.

Holland, J. 1975. *Adaptation in Natural and Artificial System: an Introduction with Application to Biology. Control and Artificial Intelligence*. University of Michigan Press. Ann Arbor.

Hopfield, J. J. 1982. Neural networks and physical systems with emergent collective computational abilities. 79(8): 2554-2558.

Joines, J., Houck, C. 1994. On the use of non-stationary penalty functions to solve non-linear constrained optimization problems with GAs, the *Proceedings of the First IEEE Conference on Evolutionary Computation*. 98-108.

Köksal, B. 2009. A Comparison of Conditional Volatility Estimators for the ISE National 100 Index Returns. *Journal of Economic and Social Research*. 11(2) : 1-28.

Marcucci, J. 2005. *Forecasting Stock Market Volatility with Regime-Switching GARCH Models*. Department of Economics. University of California. San Diego.

McCulloch, W.S., Pitts, W. A. 1943. A logical calculus of ideas immanent in nervous activity. *Buttetin of Mathematics and Biophysics*. 5 : 115-133.

Michalewicz, Z. 1992. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer. Berlin/Heidelberg.

Minsky, M.L., Papert, S.A. 1969. *Perceptrons*. MIT Press. Cambridge.

Mitchell, M. 1996. *An Introduction to Genetic Algorithms*. Massachusetts Institute of Technology. Cambridge. London.

Nelson, D. B. 1991. Conditional heteroskedasticity in asset returns. A new approach. *Econometric*. 59 : 347–370.

Poon, S.H., Granger, C. W. J. 2003. Forecasting volatility in financial markets: A review. *Journal of Economic Literature*. 41 : 478-539.

Ramasamy, R., Munisamy, S. 2012. Predictive Accuracy of GARCH, GJR and EGARCH Models Select Exchange Rates Application. *Global Journal of Management and Business Research*. 12 (15) : 81.

Rosenblatt, F. 1958. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(386).

Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. Learning representations by backpropagating errors. 323 : 533-536.

Vose, M.D. 1999. The simple genetic algorithm: foundations and theory. 12 : 1-350.

Werbos, P.J. 1974. Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. Thesis. Harvard University. Cambridge.

Yadav, R.N., Kalra, P.K., John, J. 2007. Time series prediction with single multiplicative neuron model. *Applied Soft Computing*. 7 : 1157-1163.

Yolcu, U., Egrioglu, E., Aladag, C. H. 2013. A new linear & nonlinear artificial neural network model for time series forecasting. *Decision Support Systems*. 54(3) : 1340–1347.

Zhang, G., Patuwo, B.E., Hu, Y.M. 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*. 14 : 35-62.

Zhang, G.P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 50 : 159-175.

EKLER

EK 1

TABLO EK.4.2. CIF2016/ZS1 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	54.6745	142.3805	139.4804	199.3769	62.2760	141.8414	138.7395	185.9537
4	58.8987	137.9364	132.9426	177.8827	58.7724	136.8555	135.5286	166.5065
12	55.4692	152.3217	146.1915	157.8093	63.2047	153.5617	149.0911	166.3679

TABLO EK.4.3. CIF2016/ZS2 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	15.0160	34.2638	33.2453	41.0847	14.7202	35.1576	32.2604	46.4708
4	16.7354	31.4889	30.7270	38.7227	17.3548	31.8354	31.9710	45.7092
12	18.0522	31.6985	31.4969	36.7992	19.7399	31.2402	31.6625	32.6057

TABLO EK.4.4. CIF2016/ZS3 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	51.2523	98.7025	100.6416	139.5388	54.6641	164.9464	107.9493	130.8550
4	53.3247	100.5721	105.2140	133.2303	55.4551	98.7177	104.8006	115.0119
12	52.2807	91.8702	111.9497	123.4169	55.8258	92.8094	111.0775	110.6458

TABLO EK.4.5. CIF2016/ZS4 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	64.9413	150.3306	151.9801	180.7273	87.7913	148.3629	150.6965	187.6428
4	79.8113	152.4024	156.6307	162.5887	95.5568	152.4024	156.6307	162.5887
12	66.9767	150.5321	147.8209	148.2229	104.1596	152.9780	148.4934	151.1460

TABLO EK.4.6. CIF2016/ZS5 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	49.1335	18.4738	16.3838	16.6834	52.8384	17.0093	16.3838	16.7247
4	48.5769	19.69606	17.3143	15.9914	51.1333	19.1190	17.3108	16.3443
12	48.3385	18.4632	17.0282	16.8226	55.8871	19.3875	16.5668	16.5483

TABLO EK.4.7. CIF2016/ZS6 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	86.0386	177.4342	181.3486	181.7090	80.1418	177.2444	181.8153	190.7899
4	88.5955	181.3284	183.0057	193.2949	91.4914	181.6532	182.7048	186.2275
12	84.0759	192.1411	202.1120	205.0300	90.8536	194.4862	193.6238	199.4454

TABLO EK.4.8. CIF2016/ZS7 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	19.7846	24.8352	22.0262	46.11298	20.7429	25.2863	21.6372	39.2254
4	21.9206	25.5533	22.2883	43.7007	23.3511	25.2253	22.9171	35.5783
12	21.7388	26.0532	34.3346	36.4490	22.0246	23.4571	33.3680	28.8784

TABLO EK.4.9. CIF2016/ZS8 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	9.2908	6.1544	6.5968	25.9124	8.8913	6.1310	6.6159	14.9595
4	9.2065	6.4233	6.7675	10.9486	8.6246	6.4895	7.3175	12.1294
12	9.3690	6.5047	10.2497	11.3110	9.7306	6.8721	9.9912	13.1795

TABLO EK.4.10. CIF2016/ZS9 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	28.2617	26.6943	31.2628	67.1166	34.8747	26.2399	33.3686	92.1575
4	29.8948	27.6095	35.4859	70.1501	32.7769	27.0354	36.1986	73.1288
12	29.5557	29.1119	37.6579	65.4028	31.9348	27.8829	39.5464	70.5274

TABLO EK.4.11. CIF2016/ZS10 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	2.4980	3.0069	3.0025	3.2342	2.5455	2.9839	2.9944	3.1931
4	2.6053	3.0784	3.1723	3.3302	2.4518	3.1559	3.0905	3.2741
12	2.3986	3.0608	3.1396	3.6313	2.4172	3.1184	3.1063	3.5208

TABLO EK.4.12. CIF2016/ZS11 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	9.5012	15.0052	16.4423	12.0043	10.9394	14.8278	16.6894	11.8275
4	10.4927	16.9504	20.752	12.3651	10.2715	17.7111	21.3913	12.9595
12	9.1099	17.5239	29.6741	18.9128	10.3499	18.5637	27.0115	17.8301

TABLO EK.4.13. CIF2016/ZS12 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	31.7231	36.3269	36.1969	53.5139	32.7836	36.6175	35.6459	60.9376
4	23.8595	37.221	36.623	47.5751	33.7661	37.7175	34.6469	50.3813
12	25.2941	34.2574	40.6444	42.9917	30.4907	34.4516	38.7167	49.8928

TABLO EK.4.14. CIF2016/ZS13 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	119.4843	122.7538	123.7002	128.566	120.5898	127.4729	124.3997	129.2047
4	124.7234	106.2376	108.0882	92.6005	126.6815	109.2236	113.5706	93.2193
12	110.2812	67.1134	72.3176	80.7517	115.0602	55.8751	72.0465	89.2664

TABLO EK.4.15. CIF2016/ZS14 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	107.0821	122.4098	122.5412	120.9972	105.0931	111.1793	118.7500	130.4271
4	101.9152	104.1411	108.4519	112.1439	100.6408	98.1393	102.4559	112.8757
12	94.3741	75.1634	75.1635	97.0022	93.0944	77.3605	78.2545	98.3942

TABLO EK.4.16 CIF2016/ZS15 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	238.8948	296.8945	299.7496	256.8407	251.6464	294.7557	305.0226	274.1668
4	283.7462	340.2826	304.3335	248.6775	306.0189	321.8177	303.0529	259.4571
12	213.0702	108.3830	189.0086	232.6667	218.3621	109.4236	212.2879	236.2112

TABLO EK.4.17. CIF2016/ZS16 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	236.5330	318.8336	323.9369	359.7318	245.8573	318.7497	324.0075	357.3692
4	239.0976	228.4494	314.4288	361.8027	238.4353	223.4941	315.0099	372.3046
12	234.6272	243.2014	217.7587	348.2124	235.8740	240.5731	226.8047	348.351

TABLO EK.4.18. CIF2016/ZS17 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	68.7514	70.9575	76.4898	74.4234	58.7773	67.7357	75.2443	73.9479
4	59.7063	60.0055	62.3742	62.7044	56.2751	57.9791	65.424	59.4112
12	67.7587	28.4451	36.7505	46.6203	57.9117	37.2059	35.5611	48.9870

TABLO EK.4.19. CIF2016/ZS18 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	222.8831	228.8197	234.6846	225.4411	213.6733	244.2012	234.6846	227.2624
4	208.2440	214.0321	227.6679	252.2402	216.3220	237.8478	227.5313	254.9329
12	214.0611	154.257	170.251	215.8397	216.1789	149.5684	173.902	220.4083

TABLO EK.4.20. CIF2016/ZS19 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	218.3325	218.8243	220.5694	191.5940	218.8221	221.8684	219.8234	206.2363
4	193.9572	209.0446	198.0742	166.2805	184.5439	190.5156	191.5386	171.1575
12	165.0701	84.7112	125.0377	137.9775	153.1061	94.7373	123.5060	147.7279

TABLO EK.4.21. CIF2016/ZS20 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	138.6107	145.5194	135.0000	142.3865	131.9246	133.0438	142.7824	143.9063
4	116.6275	122.0785	132.6075	131.1958	114.5333	132.9213	128.7699	138.7035
12	103.064	79.3728	90.377	119.505	98.98134	86.1172	89.6231	113.2472

TABLO EK.4.22. CIF2016/ZS21 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	36.23769	51.4240	54.0000	49.6822	32.13733	61.7719	53.4484	51.3037
4	26.4963	31.2565	37.1275	42.5924	25.1954	31.0245	35.4913	39.049
12	43.9369	17.0226	30.0708	38.3264	39.7596	16.1905	29.2047	37.9433

TABLO EK.4.23. CIF2016/ZS22 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	40.44748	45.2203	45.0000	43.6217	41.22572	44.3074	44.8050	43.0750
4	35.26852	38.7979	38.2214	39.1895	34.32589	38.8184	37.5667	36.6635
12	49.23299	49.8252	49.1536	44.1243	51.68657	49.6495	48.1017	45.4023

TABLO EK.4.24. CIF2016/ZS23 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	26.5432	26.5451	27.0000	25.7137	26.0687	26.2606	27.1639	26.0704
4	26.9117	24.0086	26.5762	25.6711	26.9296	23.0242	26.5272	25.8926
12	15.0481	18.9965	24.7407	20.1018	14.7003	19.1106	24.0795	20.0378

TABLO EK.4.25. CIF2016/ZS24 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	25.1593	30.4400	27.0000	26.6205	27.1453	30.8087	27.2700	27.2259
4	23.1155	26.2867	27.7346	28.3311	23.4209	24.5709	28.5388	26.4425
12	19.7036	11.4171	16.7133	19.4631	19.9076	10.1341	17.3515	19.2741

TABLO EK.4.26. CIF2016/ZS25 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	75.6592	97.6370	91.0000	113.5097	75.5682	92.2174	93.1607	115.9639
4	85.6564	82.7159	84.6744	117.8167	85.3043	81.5501	84.2651	101.0656
12	100.0474	94.2092	87.2002	96.076	96.5826	90.6025	93.1722	93.7761

TABLO EK.4.27. CIF2016/ZS26 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	72.5818	87.3476	92.0000	80.4239	72.2108	86.1633	89.8665	86.8186
4	74.6928	94.9804	91.6238	80.0887	76.0966	91.8088	91.0660	81.5189
12	74.6415	91.7801	92.5229	70.2562	79.1650	93.3301	89.6559	77.8503

TABLO EK.4.28. CIF2016/ZS27 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	116.9539	118.5797	118.0000	128.6707	118.0944	116.7532	116.1863	131.839
4	112.5814	114.8438	118.875	120.7135	113.7664	112.3205	121.9803	110.3255
12	104.0588	112.0643	160.4586	110.5473	100.8354	114.0727	151.1455	103.3445

TABLO EK.4.29. CIF2016/ZS28 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	258.3028	444.6356	444.0000	338.9843	279.0361	410.2302	441.1831	400.6879
4	269.2260	425.9556	431.1195	378.3835	270.7622	423.693	429.9331	378.3067
12	257.7284	426.3646	418.9737	368.5542	269.4270	429.1956	417.9739	377.2617

TABLO EK.4.30. CIF2016/ZS29 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	47.3369	49.5526	49.0000	49.2078	49.4819	47.3449	48.9251	49.7030
4	56.5169	51.6316	51.6977	52.0359	61.2390	52.9269	51.8935	51.7769
12	53.0038	55.6820	58.6355	53.5545	55.2241	58.6952	59.2995	52.2031

TABLO EK.4.31. CIF2016/ZS30 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	57.1128	66.4310	76.0000	79.8954	59.0144	65.8251	77.1305	78.5480
4	51.0751	51.1708	68.1397	64.8724	50.7455	57.8928	66.6619	62.1441
12	62.1596	89.8954	104.8888	56.9971	62.3109	81.3316	114.708	54.0859

TABLO EK.4.32. CIF2016/ZS31 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	25.0861	27.8039	31.0000	30.9536	25.0899	27.6164	29.9477	32.0198
4	25.7256	29.8957	29.4245	29.2469	24.3621	30.4384	30.2597	30.5425
12	24.4692	33.2895	36.0935	30.7762	25.0156	34.1393	34.9222	25.6176

TABLO EK.4.33. CIF2016/ZS32 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	47.7518	51.5695	51.0000	50.4307	51.7791	52.3383	52.3637	48.7035
4	48.5268	52.7161	56.235	46.5047	50.2223	54.3365	57.0464	48.9181
12	47.3384	49.3688	53.6142	43.9652	51.2308	48.7503	51.4767	44.2021

TABLO EK.4.34. CIF2016/ZS33 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	250.1148	375.0579	367.0000	367.1384	247.2800	142.1213	141.9028	164.7926
4	197.9530	140.5469	140.3163	151.157	49.6457	13.6444	10.0555	39.1440
12	112.4704	132.4956	136.6271	142.9214	116.6528	125.1896	129.1211	133.4766

TABLO EK.4.35. CIF2016/ZS34 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	221.0246	250.8089	247.0000	234.9000	230.6723	247.4279	246.3341	234.3437
4	206.8167	286.943	290.6621	251.3994	228.8048	285.1601	299.0257	243.3386
12	211.1874	336.2212	340.2232	278.553	230.3791	331.2024	339.3828	286.4061

TABLO EK.4.36. CIF2016/ZS35 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	23.8324	26.3628	25.0000	25.4956	24.3969	25.7826	26.2024	26.4666
4	25.4255	25.7826	27.6731	26.5249	26.7732	28.8621	26.8622	26.0830
12	27.5089	24.0721	36.5989	27.4667	27.7953	23.7538	36.4384	26.8544

TABLO EK.4.37. CIF2016/ZS36 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	41.0444	53.2460	54.0000	69.4355	39.8535	51.5919	54.6115	65.3143
4	44.6850	54.9758	51.7316	51.7122	44.6778	55.7731	50.7984	57.5825
12	48.3725	51.4144	50.2012	51.4671	49.6132	50.1248	50.9556	59.1766

TABLO EK.4.38. CIF2016/ZS37 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	247.2385	268.2227	256.0000	247.0124	255.2471	281.7022	263.6508	255.9194
4	245.3347	267.7528	252.6273	263.3812	252.5274	266.1461	267.6606	259.1668
12	168.5192	190.6866	184.6900	250.3726	177.2797	179.0098	189.6698	228.7927

TABLO EK.4.39. CIF2016/ZS38 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	46.1395	53.8574	55.0000	49.9380	46.4295	61.8503	54.6838	49.3227
4	40.9814	45.4915	48.3286	49.3599	52.4155	50.9156	49.0437	48.9377
12	41.9191	42.5871	39.9236	40.448	40.1052	42.9098	41.0884	43.9494

TABLO EK.4.40. CIF2016/ZS39 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	323.2572	454.4107	446.0000	347.9982	318.1281	455.1688	447.6269	352.1514
4	290.2899	398.3807	363.9089	291.3926	284.3839	416.2812	375.3367	303.7985
12	223.9900	247.1547	343.8361	271.6196	247.0199	265.0588	328.1218	283.1083

TABLO EK.4.41. CIF2016/ZS40 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	203.2160	212.9266	238.0000	231.1978	206.9061	300.1942	237.9012	230.8333
4	210.1882	232.0975	229.9083	216.5546	207.7445	272.483	228.7978	210.1416
12	131.8712	164.1030	151.3533	173.3058	157.5092	173.1581	162.1031	162.2407

TABLO EK.4.42. CIF2016/ZS41 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m = 1$				$m = 2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	3.5099	5.2067	5.8214	5.4536	3.2511	5.1927	5.8214	5.4303
4	3.5142	4.6933	5.2312	5.2745	3.3349	4.6669	5.1904	5.2640
12	3.6144	3.8588	3.7638	4.2163	3.4202	3.6236	3.6689	4.2507

TABLO EK.4.43. CIF2016/ZS42 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m=1$				$m=2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	210.3240	305.4146	297.3392	290.7284	212.8739	325.4251	297.6655	291.0216
4	211.0682	241.9432	256.2488	264.9495	212.9389	246.0623	257.3194	265.0332
12	206.7840	189.4464	228.2761	229.1416	219.4067	200.6551	225.1263	237.5178

TABLO EK.4.44. CIF2016/ZS43 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m=1$				$m=2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	35.7518	40.2369	49.7126	52.2405	34.6465	39.5874	47.3564	51.8923
4	34.8614	53.5560	52.3066	44.7465	34.0600	51.3410	52.6782	44.0455
12	34.6817	30.4769	39.6976	35.3794	33.0766	33.8987	38.4972	33.4996

TABLO EK.4.45. CIF2016/ZS44 İÇİN ORTALAMA HKOK DEĞERLERİ

p	$m=1$				$m=2$			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	6.6830	9.8094	9.7785	10.0572	6.1481	9.9492	9.6026	10.3657
4	6.3354	11.3920	9.9892	10.9472	6.7664	12.5590	10.0073	10.8088
12	6.5855	9.0000	9.7329	10.6976	6.2986	8.8298	9.9057	10.3671

TABLO EK.4.46. CIF2016/ZS45 İÇİN ORTALAMA HKOK DEĞERLERİ

p	m=1				m=2			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	231.7291	383.7479	381.8899	382.7811	223.4118	395.6075	384.5653	371.2642
4	216.8325	319.8594	329.5567	323.7723	229.8382	316.4779	335.9623	340.0153
12	192.9038	257.6054	332.5272	283.7353	213.5907	258.8277	348.7749	315.0269

TABLO EK.4.47. CIF2016/ZS46 İÇİN ORTALAMA HKOK DEĞERLERİ

p	m = 1				m = 2			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	196.6694	243.1587	242.1353	262.0245	234.9202	248.9311	242.7304	262.0501
4	179.0014	190.4646	187.7093	189.0364	176.2701	184.3562	186.8227	191.4583
12	189.3963	223.9210	227.3585	228.7934	192.0257	211.7418	229.9822	210.1919


TABLO EK.4.48. CIF2016/ZS47 İÇİN ORTALAMA HKOK DEĞERLERİ

p	m = 1				m = 2			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	43.2314	57.0578	55.4640	55.9702	45.2638	57.0105	55.4366	56.8065
4	43.0505	53.7701	53.2553	52.1157	46.1382	54.0781	52.4575	51.5175
12	44.3573	45.3788	47.5957	46.5644	46.5845	43.9111	48.6399	46.7570


TABLO EK.4.49. CIF2016/ZS48 İÇİN ORTALAMA HKOK DEĞERLERİ

p	m = 1				m = 2			
	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA	ARCH-B-YSA	ARCH-TÇNM	TÇNM	ÇKA-YSA
2	302.6115	375.0779	366.5014	367.1384	316.1058	389.1253	368.3547	368.8263
4	307.1241	346.1643	330.6270	301.7659	317.0882	355.1994	332.462	306.1746
12	111.5581	184.4086	177.4423	302.2099	112.4769	187.5039	172.7079	281.7288


EK 2




Şekil Ek.4.1. CIF2016/ZS1




Şekil Ek.4.2. CIF2016/ZS2




Şekil Ek.4.3. CIF2016/ZS3




Şekil Ek.4.4. CIF2016/ZS4




Şekil Ek.4.5. CIF2016/ZS5




Şekil Ek.4.6. CIF2016/ZS6




Şekil Ek.4.7. CIF2016/ZS7




Şekil Ek.4.8. CIF2016/ZS8




Şekil Ek.4.9. CIF2016/ZS9




Şekil Ek.4.10. CIF2016/ZS10




Şekil Ek.4.11. CIF2016/ZS11




Şekil Ek.4.12. CIF2016/ZS12




Şekil Ek.4.13. CIF2016/ZS13




Şekil Ek.4.14. CIF2016/ZS14




Şekil Ek.4.15. CIF2016/ZS15




Şekil Ek.4.16. CIF2016/ZS16




Şekil Ek.4.17. CIF2016/ZS17




Şekil Ek.4.18. CIF2016/ZS18




Şekil Ek.4.19. CIF2016/ZS19




Şekil Ek.4.20. CIF2016/ZS20




Şekil Ek.4.21. CIF2016/ZS21




Şekil Ek.4.22. CIF2016/ZS22




Şekil Ek.4.23. CIF2016/ZS23




Şekil Ek.4.24. CIF2016/ZS24




Şekil Ek.4.25. CIF2016/ZS25




Şekil Ek.4.26. CIF2016/ZS26




Şekil Ek.4.27. CIF2016/ZS27




Şekil Ek.4.28. CIF2016/ZS28




Şekil Ek.4.29. CIF2016/ZS29




Şekil Ek.4.30. CIF2016/ZS30




Şekil Ek.4.31. CIF2016/ZS31




Şekil Ek.4.32. CIF2016/ZS32




Şekil Ek.4.33. CIF2016/ZS33




Şekil Ek.4.34. CIF2016/ZS34




Şekil Ek.4.35. CIF2016/ZS35




Şekil Ek.4.36. CIF2016/ZS36




Şekil Ek.4.37. CIF2016/ZS37




Şekil Ek.4.38. CIF2016/ZS38




Şekil Ek.4.39. CIF2016/ZS39




Şekil Ek.4.40. CIF2016/ZS40




Şekil Ek.4.41. CIF2016/ZS41




Şekil Ek.4.42. CIF2016/ZS42




Şekil Ek.4.43. CIF2016/ZS43




Şekil Ek.4.44. CIF2016/ZS44




Şekil Ek.4.45. CIF2016/ZS45



Şekil Ek.4.46. CIF2016/ZS46



Şekil Ek.4.47. CIF2016/ZS47



Şekil Ek.4.48. CIF2016/ZS48

ÖZGEÇMİŞ

Radwan Mahamoud Aden İlk, orta ve lise eğitimini Cibuti’de tamamladı. 2015 yılında Balbala Lisesi’nden mezun oldu. 2015 yılında başladığı Cibuti Üniversitesi İstatistik Bölümü’nü 2018 yılında bitirdi. 2019 yılında Giresun Üniversitesi İstatistik Anabilim Dalında yüksek lisans eğitimine başladı.

