



## Optimized ARIMA-ANN hybrid model for time series analysis

Mahmut Burak Erturan<sup>1\*</sup>, Fahriye Merdivenci<sup>2</sup>

<sup>1</sup>Akdeniz University, Institute of Social Sciences, Department of Econometrics, 07070, Antalya, Turkey

<sup>2</sup>Akdeniz University, Faculty of Applied Sciences, Department of International Trade and Logistics, 07070, Antalya, Turkey

### Highlights:

- A novel ARIMA-ANN hybrid model for time series analysis based on least squares optimization
- Performance comparison with seven other models by applying to three well known time series data
- High forecasting performance, especially for relatively shorter term forecasting horizons

### Keywords:

- Time series analysis
- ARIMA
- Artificial neural networks
- Optimized ARIMA-ANN hybrid model
- Least squares optimization

### Graphical/Tabular Abstract

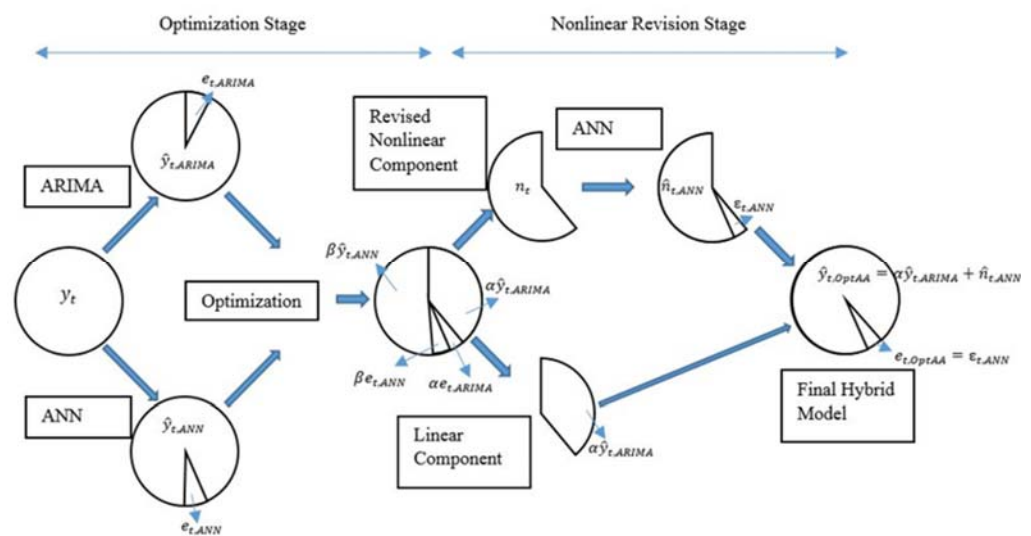


Figure A. Graphic Illustration of Optimized ARIMA-ANN Hybrid Model

**Purpose:** The purpose of this study is to present a novel ARIMA-ANN hybrid model for time series analysis. Proposed optimized ARIMA-ANN (OptAA) hybrid model is applied to three well-known time series data with varying forecasting horizons. For determination of the forecasting performance, results are compared with the results of other models.

### Theory and Methods:

Proposed model uses a least squares optimization of ARIMA and ANN models of the time series data to decompose it into linear and nonlinear components. After the first decomposition, error series of the linear part is transferred to the nonlinear component to revise the nonlinear part, which is then remodeled with ANN. The sum of the ARIMA model forecast of the linear part and ANN forecast of the revised nonlinear part is the final forecast of the hybrid model. Three time series data, Wolf's sunspot, Canadian lynx and GBP/USD exchange rate are used for forecasting performance comparison purposes. Proposed hybrid model's forecasting performance is compared with four major ARIMA-ANN hybrid models, ARIMA, ANN and random walk model.

### Results:

Obtained results show that OptAA hybrid model is a very powerful methodology for time series forecasting. Especially for short term forecasting horizons proposed hybrid model shows better performance than other compared models.

### Conclusion:

OptAA hybrid model is open for further research. Testing the model with different neural network parameters such that learning algorithm, network architecture, activation functions etc. is possible. Also applying the model to different time series and forecasting horizons helps to improve the generalization of the model.

### Article Info:

Research Article  
Received: 03.03.2021  
Accepted: 05.09.2021

### DOI:

10.17341/gazimmfd.889513

### Correspondence:

Author: Mahmut Burak Erturan  
e-mail:  
burak.erturan@gmail.com  
phone: +90 553 605 7540



## Zaman serileri analizi için optimize ARIMA-YSA melez modeli

Mahmut Burak Erturan<sup>1\*</sup>, Fahriye Merdivenci<sup>2</sup>

<sup>1</sup>Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Bölümü, 07070, Konyaaltı, Antalya, Türkiye

<sup>2</sup>Akdeniz Üniversitesi, Uygulamalı Bilimler Fakültesi, Uluslararası Ticaret ve Lojistik Bölümü, 07070, Konyaaltı, Antalya, Türkiye

### Ö N E Ç I K A N L A R

- Zaman serileri analizi için en küçük kareler optimizasyonu tabanlı özgün bir ARIMA-YSA melez model
- İyi bilinen üç zaman serisi verisine uygulanarak, yedi farklı model ile performans karşılaştırması
- Yüksek tahmin performansı, özellikle görece kısa dönem tahmin ufku için

### Makale Bilgileri

Araştırma Makalesi

Geliş: 03.03.2021

Kabul: 05.09.2021

DOI:

10.17341/gazimmfd.889513

### Anahtar Kelimeler:

Zaman serisi analizi,  
ARIMA, yapay sinir ağları,  
optimize ARIMA-YSA  
melez model,  
en küçük kareler  
optimizasyonu

### ÖZ

Zaman serileri analizi alanında son yıllarda birden çok modelin bir arada kullanıldığı melez modeller ortaya konulmaktadır. Literatürde yer alan en önemli melez model sınıflarından biri ARIMA-Yapay Sinir Ağları (YSA) melez model sınıfıdır. ARIMA modeli yapısı gereği doğrusal bir model olduğu halde, YSA modelleri doğrusal olmayan zaman serilerinin modellenmesinde oldukça başarılıdır. Gerçek hayatta karşılaşılan zaman serilerinin genellikle doğrusal ve doğrusal olmayan özellikleri bir arada taşınması, ARIMA-YSA melez modellerin tahmin performanslarının yüksek olmasını sağlamaktadır. Bu çalışmada optimizasyon tabanlı özgün bir ARIMA-YSA melez model ortaya konulmaktadır. İleri sürülen Optimize ARIMA-YSA (OptAA) melez model, zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı olarak varsaymaktadır. İki aşamalı modelin ilk aşamasında, doğrusal ve doğrusal olmayan bileşenlerin elde edilmesi amacıyla ARIMA ve YSA modelleri ile gerçek seri bir en küçük kareler optimizasyonu sürecinden geçmektedir. İkinci aşamada ise doğrusal bileşenin hataları doğrusal olmayan bileşene aktararak doğrusal olmayan bileşen revize edilmekte ve YSA ile tekrar modellenmektedir. Tahmin performansının tespiti için literatürde sıklıkla başvurulan Wolf'un güneş lekesi, Kanada vaşak ve GBP/USD döviz kuru veri setleri kullanılmaktadır. Uygulama sonucu elde edilen sonuçlar OptAA melez modelin özellikle görece kısa dönem tahmin performansının diğer modellere göre yüksek olduğunu ve zaman serisi analizi alanında oldukça güçlü bir yöntem olduğunu göstermektedir.

## Optimized ARIMA-ANN hybrid model for time series analysis

### H I G H L I G H T S

- A novel ARIMA-ANN hybrid model for time series analysis based on least squares optimization
- Performance comparison with seven other models by applying to three well known time series data
- High forecasting performance, especially for relatively shorter term forecasting horizons

### Article Info

Research Article

Received: 03.03.2021

Accepted: 05.09.2021

DOI:

10.17341/gazimmfd.889513

### Keywords:

Time series analysis,  
ARIMA,  
Artificial neural networks,  
Optimized ARIMA-ANN  
hybrid model,  
Least squares optimization

### ABSTRACT

In recent years, hybrid models, using more than one models together, are presented in the field of time series analysis. One of the most important hybrid model classes is ARIMA-Artificial Neural Networks (ANN) hybrids. ARIMA is a linear model according to its structure, whereas ANN models are quite successful on modeling nonlinear time series. Time series encountered in real life usually carry linear and nonlinear characteristics together, which causes high forecasting performance of ARIMA-ANN hybrid models. In this study, a novel optimization based ARIMA-ANN hybrid model is presented. Proposed Optimized ARIMA-ANN (OptAA) hybrid model assumes time series is the sum of linear and nonlinear two series. In the first stage of the two staged model, ARIMA and ANN models with real time series pass through a least squares optimization process to obtain linear and nonlinear components. In the second stage, error values of the linear component are transferred to nonlinear component, nonlinear component is revised and remodeled with ANN. To determine the forecasting performance, Wolf's sunspot, Canadian lynx and GBP/USD exchange rate data sets, which are applied often in the literature, are used. Results obtained from the application show that OptAA hybrid model has higher performance than other models especially in relatively short term forecasting and is a very powerful methodology in time series analysis field.

## 1. GİRİŞ (INTRODUCTION)

Zaman serileri analizi bir değişkenin geçmiş değerlerinin modellenerek gelecekte alabileceği değerler için tahmin yapılmasını sağlayan, literatürde birçok disiplin tarafından kullanılan oldukça önemli bir yöntemdir. Ekonomi, finans, mühendislik, meteoroloji gibi alanlarda farklı özellikte olguların açıklanabilmesi için zaman serileri analizine sıklıkla başvurulmaktadır [1]. Özellikle nedensel ilişkilerin net olmadığı durumlarda zaman serileri analizi oldukça etkilidir. Literatürde zaman serileri modellemesi için birçok farklı yöntem yer almaktadır. Her yöntemin kendine has varsayımları, güçlü ve zayıf yanları bulunmaktadır. Günlük hayatta karşılaşılan zaman serilerinin her birinin farklı karakteristik özellikleri olduğu gibi, geliştirilen zaman serisi modelleri de bazı zaman serileri için başarılı sonuç verirken bazıları için yetersiz kalabilmektedir.

Tek değişkenli zaman serisi modelleri serinin şimdiki zaman değerini geçmiş zamanlara ait değerlerin bir fonksiyonu olarak açıklamaktadır. Doğrusal modeller şimdiki zaman değerini gecikmeli değerlerin doğrusal bir fonksiyonu olarak ele alırken, doğrusal olmayan modeller bu değeri geçmiş değerlerin doğrusal olmayan bir fonksiyonu olarak varsayar [2]. Örneğin, ARIMA modeli şimdiki zaman değerini gecikmeli değerler ve gecikmeli hata değerlerinin doğrusal bir fonksiyonuyla açıklarken, YSA modelleri doğrusal olmayan aktivasyon fonksiyonları kullanarak seriyi gecikmeli değerlerin doğrusal olmayan bir fonksiyonu olarak ortaya koymaktadır. ARIMA modelinde zaman serisi ardışık fark alma yoluyla durağan hale getirilmekte, ardından elde edilen seri değerleri geçmiş zaman değerleri ve geçmiş zaman hata değerleriyle açıklanmaktadır. ARIMA modeli yapısı gereği doğrusal bir modeldir ve özellikle doğrusal zaman serilerinde çok başarılı sonuçlar vermektedir. Ancak gerçek hayatta karşılaşılan zaman serileri genellikle doğrusal ve doğrusal olmayan karakter özellikleri bir arada taşımakta ve ARIMA modeli bu serileri açıklamakta tek başına çoğu zaman yetersiz kalmaktadır [3].

Doğrusal olmayan zaman serilerinin modellenmesi konusunda önemli yöntemlerden biri yapay sinir ağlarıdır. YSA modelleri tahmin doğruluğu açısından diğer doğrusal olmayan modeller arasında öne çıkmaktadır. YSA modelleri esnek ve veri tabanlı yapılarıyla zaman serisinin geçmiş gözlem değerlerini kullanmakta, eğitim ve öğrenme süreçleriyle birlikte olgunun altında yatan zamansal ilişki üzerine tahminde bulunmaktadır [4]. YSA modellerinde kullanılan doğrusal olmayan yapıdaki aktivasyon fonksiyonları yöntemin doğrusal olmayan zaman serilerinin modellenmesinde başarılı olmasındaki en önemli etkendir [5]. Diğer taraftan, gerçek hayatta karşılaşılan serilerin karmaşık doğrusal/doğrusal olmayan yapıları YSA modellerinin başarısını kısıtlamaktadır [4].

Son yıllarda zaman serileri analizi alanında, modelleme ve tahmin performansının geliştirilebilmesi için birden fazla modelin bir arada kullanıldığı melez modeller ortaya

konulmaktadır. Teorik ve deneysel kanıtlar özellikle birbirinden farklı modellerin bir arada kullanılmasının tahmin performansını artırmak için etkili bir yol olduğunu göstermektedir [6]. Melez model kullanımının başlıca faydaları tahmin doğruluğunun artması, uygun olmayan model kullanımı riskinin azaltılması ve model seçim işleminin basitleştirilmesi olarak gösterilmektedir [7]. Son yıllarda özellikle makine öğrenimi alanının gelişmesiyle birlikte, klasik istatistiksel yöntemler ve makine öğrenimi metodlarının bir arada kullanıldığı çok sayıda melez model geliştirilmiştir. Bağımsız bileşen analizi/geçitli yinelemeli sinir ağları [8], yapay arı kolonisi algoritması/çoklu doğrusal regresyon [9], ARIMA/aykırı değer aşırı öğrenme makinesi [10], en küçük kareler destek vektör makinesi/ARIMA [11], mevsimsel ARIMA/destek vektör makineleri [12], ARIMA/lojistik regresyon/YSA [13], dalgacık dönüşümü/ARIMA/YSA [14] gibi melez modeller örnek olarak verilebilir.

En önemli melez model sınıflarından biri ARIMA-YSA melez model sınıfıdır. ARIMA modelinin doğrusal karakterli zaman serileri için oldukça güçlü bir model olması ve YSA modelinin doğrusal olmayan zaman serilerindeki başarısı araştırmacıları her iki modelin bir arada kullanıldığı melez modeller ortaya koymaya yöneltmektedir. Gerçek hayatta karşılaşılan zaman serilerinin genellikle doğrusal ve doğrusal olmayan özellikleri bir arada bulundurmaları ARIMA-YSA melez modellerinin gerek modelleme ve gerek tahmin performanslarının yüksek olmasındaki en önemli sebeplerdendir [15].

ARIMA ve YSA birbirinden farklı özelliklere sahiptir. ARIMA doğrusal bir model olduğu halde, YSA doğrusal olmayan bir modeldir. ARIMA modeli doğası gereği parametrik olduğu halde, YSA parametrik bir model değildir. ARIMA kullanılırken problemin genel yapısı bilinmemekte, YSA modelinde ise böyle bir bilgiye gerek duyulmamaktadır. ARIMA modellerinin geliştirilmesinde istatistiksel teoriler kullanılır ve modelin uygunluğu istatistiksel yöntemlerle tespit edilir. Ancak, YSA'da model oluşturmak için ön tanımlı herhangi bir teknik bulunmamaktadır. Ayrıca, ARIMA anlamak ve uygulamak için daha basit bir model olduğu halde YSA modeli oldukça karmaşıktır [16].

Gerçekte karşılaşılan zaman serilerinin doğrusal olup olmadıklarının sınılanması amacıyla portmanteau, Lagrange çarpanı, benzerlik oranı gibi testler geliştirilmişse de; testlerin iç içe geçmiş hipotezlerden oluşması ve genellikle belli bir tipte doğrusal olmayan yapıyı araması sebebiyle, doğrusallık testleri soruna genel bir çözüm sunmamaktadır [17]. Bu sebeple, genellikle gerçekte karşılaşılan zaman serilerinin doğrusal olup olmadıkları kesin olarak bilinmemektedir [3, 4]. ARIMA ve YSA modellerinin bir arada kullanılmasının başlıca sebebi olarak, karşılaşılan zaman serilerinin doğrusal mı yoksa doğrusal olmayan mı olduğunun kesin olarak bilinmemesi ve zaman serilerinin çoğunlukla hem doğrusal hem de doğrusal olmayan karakteri bir arada taşınması gösterilebilir [3, 4]. ARIMA modelleri

özellikle karmaşık doğrusal olmayan problemlerde yeterli performans gösteremezken, YSA modelleri de doğrusal serilere uygulandığında karmaşık sonuçlar verebilmektedir [3]. Bu sebeple, çoğu zaman ARIMA ve YSA tek başına tatmin edici sonuçlar vermediği halde bir arada kullanıldıklarında daha iyi sonuçlar elde edilmektedir [18]. ARIMA-YSA melez modeller literatürde meteoroloji [16], enerji [19], turizm [20], su kalitesi [6], finans [21], tedarik zinciri yönetimi [22] gibi birçok alanda kullanılmaktadır.

Literatürde yer alan ARIMA-YSA melez modeller için genel uygulama ilgilenilen zaman serisini doğrusal ve doğrusal olmayan iki serinin bir fonksiyonu olarak ele almaktır. Çalışmalarda zaman serisi, doğrusal ve doğrusal olmayan iki serinin toplamı [3], çarpımı [23] veya doğrusal seriden elde edilen değerlerin ve gerçek serinin doğrusal olmayan bir fonksiyonu [24] gibi farklı şekillerde ele alınmaktadır. Diğer taraftan, melez modelleri birbirinden ayıran en önemli yöntem farklarından biri doğrusal ve doğrusal olmayan bileşenlerin tespit şeklidir. ARIMA-YSA melez modellerin gücü doğrusal ve doğrusal olmayan bileşenlere farklı işlem uygulamasından kaynaklanmaktadır. Bu sebeple bileşenlere ayırma kritik önem taşımaktadır [25]. Örneğin, Zhang [3] ve Wang vd. [23] ilk olarak doğrusal bileşeni tespit etmekte ve bunun için gerçek serinin ARIMA ile modellenen geçmiş kestirim değerlerini kullanmaktadır. Doğrusal serinin tespitinden sonra doğrusal olmayan bileşen gerçek zaman serisi kullanılarak elde edilmektedir. Diğer taraftan Babu ve Reddy [21] ise zaman serisini bir hareketli ortalama filtresinden geçirerek doğrusal ve doğrusal olmayan iki seriyi ayırmaktadır.

Bu çalışmada zaman serileri analizi için optimizasyon tabanlı bir melez ARIMA-YSA modeli ortaya konulmaktadır. Optimize ARIMA-YSA (OptAA) melez modeli, Zhang [3]'in çalışmasında olduğu gibi zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı olarak ele almaktadır. Modelin ilk aşamasında, Zhang [3]'in modelinden farklı olarak, doğrusal bileşen, gerçek serinin ARIMA ve YSA ile modellenen geçmiş kestirim değerleri birlikte kullanılarak bulunmaktadır. Bu aşamada amaç zaman serisinin doğrusal ve doğrusal olmayan serilere en iyi şekilde (en az hata ile) ayrılmasıdır. Hatanın en küçüklenmesine dayanan en küçük kareler optimizasyonu ile doğrusal ve doğrusal olmayan bileşenler elde edilmektedir. İkinci aşamada doğrusal bileşenin hata serisi, içerisinde doğrusal olmayan ilişkiler barındırabileceği düşüncesiyle, doğrusal olmayan seriyi eklenmekte, doğrusal olmayan bileşen revize edilmekte ve YSA ile yeniden modellenmektedir. Diğer bir anlatımla, doğrusal bileşen gerçek seriden çıkarılarak elde edilen seri YSA ile yeniden modellenmektedir. Bu aşama yöntem olarak Zhang [3]'in modelinin ikinci aşamasıyla aynıdır.

İkinci bölümde ARIMA ve YSA modelleri ile birlikte literatürde yer alan diğer başlıca ARIMA-YSA melez modelleri ile ilgili bilgi verilmekte ve OptAA melez modeli açıklanmaktadır. Üçüncü bölümde OptAA melez modelin, ARIMA, YSA, diğer ARIMA-YSA modelleri ve rassal

yürüyüş modeli ile tahmin performansları karşılaştırılmaktadır. Ortaya konulan OptAA melez modelin tahmin performansının değerlendirilebilmesi için diğer ARIMA-YSA melez model çalışmaları dikkate alınarak literatürde sıkça kullanılan ve iyi bilinen üç zaman serisi seçilmiştir. Dördüncü bölümde ise elde edilen bulgular değerlendirilmekte ve sonuçlar tartışılmaktadır.

## 2. YÖNTEM (METHODOLOGY)

### 2.1. ARIMA-YSA melez modelleri (ARIMA-ANN hybrid models)

Literatürde ilk melez ARIMA-YSA modeli Zhang [3] tarafından ortaya konulmuştur. Sonraki yıllarda ARIMA ve YSA modelini bir arada kullanan çok sayıda melez model çalışması üretilmiştir [4, 13-15, 18, 21, 23-26]. Zaman serileri için üretilmiş melez modeller ve ARIMA-YSA melez modelleri ile ilgili ayrıntılı bir literatür taraması için Hajirahimi ve Khashei [7]'nin çalışmasına başvurulabilir. Bu çalışmada performans karşılaştırması amacıyla, özellikle literatürde en çok başvurulan başlıca dört ARIMA-YSA melez modeli ele alınmaktadır. Bunlar; Zhang [3], Khashei ve Bijari [24], Wang vd. [23], Babu ve Reddy [21]'nin çalışmalarıdır.

#### 2.1.1. Zhang'in toplamsal ARIMA-YSA melez modeli (Zhang's additive hybrid model)

Zhang [3] tarafından ortaya konulan ve toplamsal model olarak da adlandırılan model, zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı olarak ele alır. İlk aşamada gerçek seri  $y_t$ , ARIMA ile modellenmektedir. Modelleme sonucu elde edilen kestirim değerleri ( $\hat{y}_{t,ARIMA}$ ) serinin doğrusal bileşen kestirimleridir ( $\hat{L}_t$ ). İkinci aşamada ARIMA modelinden kalan artık serisi ( $e_{t,ARIMA}$ ) doğrusal olmayan bileşen ( $N_t$ ) olarak kabul edilmekte, YSA ile modellenmekte, doğrusal olmaya kestirim ( $\hat{N}_{t,YSA}$ ) ve hata değerleri ( $\epsilon_{t,YSA}$ ) bulunmaktadır. Melez modelin kestirim değerleri ( $\hat{y}_t$ ), ARIMA ve YSA modellerinden elde edilen kestirim değerlerinin toplamıdır. YSA modelinden elde edilen hata değerleri ise melez modelin hata değerleri ( $e_t$ ) olmaktadır. Benzer şekilde, gelecek tahmin değerleri de her iki modelden gelen tahmin değerlerinin toplamıdır. Zaman serisi  $y_t$ 'nin doğrusal bileşeni  $L_t$  ve doğrusal olmayan bileşeni  $N_t$  olmak üzere, Zhang [3]'in toplamsal modeli Eş. 1-Eş. 7'de gösterilmektedir.

$$y_t = L_t + N_t \quad (1)$$

$$y_t = ARIMA(y_t) = \hat{y}_{t,ARIMA} + e_{t,ARIMA} \quad (2)$$

$$\hat{L}_t = \hat{y}_{t,ARIMA} \quad (3)$$

$$N_t = y_t - \hat{L}_t = e_{t,ARIMA} \quad (4)$$

$$N_t = YSA(N_t) = \hat{N}_{t,YSA} + \epsilon_{t,YSA} \quad (5)$$

$$\hat{y}_t = \hat{y}_{t,ARIMA} + \hat{N}_{t,YSA} \quad (6)$$

$$e_t = \epsilon_{t,YSA} \quad (7)$$

### 2.1.2. Khashei ve Bijari'nin ARIMA-YSA melez modeli (Khashei and Bijari's hybrid model)

Khashei ve Bijari [24] tarafından ortaya atılan melez model diğer ARIMA-YSA melez modellerden yöntem olarak farklıdır. Model [24] zaman serisini doğrusal ve doğrusal olmayan bileşenlere ayırmamaktadır. Bunun yerine, zaman serisini ARIMA modelinden elde edilen değerler ile gerçek zaman serisinin değerlerinin doğrusal olmayan bir fonksiyonu olarak kabul etmektedir. Zaman serisi ilk olarak ARIMA ile modellenmektedir. Bu modelleme sonucunda ARIMA kestirim ( $\hat{y}_{t,ARIMA}$ ) ve hata ( $e_{t,ARIMA}$ ) değerleri elde edilir. İkinci aşamada, elde edilen gecikmeli ARIMA hata değerleri ( $e_{t-1,ARIMA}, e_{t-2,ARIMA}, \dots, e_{t-n,ARIMA}$ ), gecikmeli gerçek değerler ( $y_{t-1}, y_{t-2}, \dots, y_{t-m}$ ) ve  $t$  zamanı için elde edilen ARIMA kestirim değeri ( $\hat{y}_{t,ARIMA}$ ) girdiler olmak üzere bir YSA modeli kurularak melez modelin  $t$  zamanı için kestirim ( $\hat{y}_{t,YSA}$ ) ve hata ( $e_{t,YSA}$ ) değeri bulunur.  $n$  adet gecikmeli ARIMA hata değeri ve  $m$  adet gecikmeli gerçek değer kullanıldığı bir YSA modelinde girdi sayısı  $n+m+1$  olmaktadır. Khashei ve Bijari [24]'nin melez modeli Eş. 8, Eş. 9'da yer almaktadır

$$y_t = ARIMA(y_t) = \hat{y}_{t,ARIMA} + e_{t,ARIMA} \quad (8)$$

$$\begin{aligned} y_t &= YSA(e_{t-1,ARIMA}, \dots, e_{t-n,ARIMA}, \hat{y}_{t,ARIMA}, \\ y_{t-1}, \dots, y_{t-m}) &= \hat{y}_{t,YSA} + e_{t,YSA} \end{aligned} \quad (9)$$

### 2.1.3. Wang vd.'nin çarpımsal ARIMA-YSA melez modeli (Wang et al.'s multiplicative hybrid model)

ARIMA-YSA melez model literatüründe yer alan bir diğer yöntem Wang vd. [23] tarafından ortaya konulan çarpımsal modeldir. Modele göre zaman serisi ( $y_t$ ) doğrusal ( $L_t$ ) ve doğrusal olmayan ( $N_t$ ) iki serinin çarpımıdır. Birinci aşamada doğrusal bileşenin bulunması amacıyla zaman serisi ARIMA ile modellenmektedir. ARIMA ile yapılan modelleme sonucu bulunan kestirim değerleri ( $\hat{y}_{t,ARIMA}$ ) doğrusal bileşenin kestirim değerlerini ( $\hat{L}_t$ ) verir. Doğrusal olmayan bileşenin bulunması için, ikinci aşamada gerçek zaman serisi, ARIMA kestirim değerlerine bölünmektedir. Bulunan doğrusal olmayan seri ( $n_t$ ), YSA ile modellenmekte ve doğrusal olmayan bileşen için kestirim değerleri ( $\hat{n}_{t,YSA}$ ) bulunmaktadır. Melez modelin kestirim değerleri ARIMA ve YSA ile bulunan kestirim değerlerinin çarpımıdır. Eş. 10-Eş. 15'te modelin matematiksel ifadesi yer almaktadır.

$$y_t = L_t N_t \quad (10)$$

$$\hat{L}_t = \hat{y}_{t,ARIMA} \quad (11)$$

$$n_t = y_t / \hat{y}_{t,ARIMA} \quad (12)$$

$$n_t = YSA(n_t) = \hat{n}_{t,YSA} + \epsilon_{t,YSA} \quad (13)$$

$$\hat{y}_t = \hat{L}_t \hat{N}_t = \hat{y}_{t,ARIMA} \hat{n}_{t,YSA} \quad (14)$$

$$\hat{y}_t = \hat{y}_{t,ARIMA} \hat{n}_{t,YSA} \quad (15)$$

### 2.1.4. Babu ve Reddy'nin hareketli ortalama filtreli toplamsal ARIMA-YSA melez modeli

(Babu and Reddy's moving average filtered additive hybrid model)

Babu ve Reddy [21] modelinde, Zhang [3]'in çalışmasında olduğu gibi zaman serisi doğrusal ve doğrusal olmayan iki serinin toplamı olarak kabul edilmektedir. Zhang [3]'in modelinden farklı olarak zaman serisinin doğrusal bileşeni ARIMA modeliyle değil, bir hareketli ortalama filtresiyle ortaya konulmaktadır. Buna göre zaman serisi yüksek volatiliteli doğrusal olmayan bir seri ile düşük volatiliteli doğrusal bir serinin toplamıdır. Zaman serisi bir hareketli ortalama filtresinden geçirilerek yüksek ( $h_t$ ) ve düşük ( $l_t$ ) volatiliteli iki bileşene ayrılmaktadır. Düşük volatiliteli bileşen doğrusal bileşeni ifade ederken, yüksek volatiliteli bileşen doğrusal olmayan bileşendir. Düşük volatiliteli doğrusal bileşen ARIMA ile, yüksek volatiliteli bileşen ise YSA ile modellenir. Melez modelin kestirim değerleri ( $\hat{y}_t$ ) her iki modelden gelen kestirim değerlerinin toplamı olmaktadır. Model aşamaları Eş. 16-Eş. 25'de gösterilmektedir. Eş. 16-Eş. 25'de,  $y_t$  gerçek zaman serisi,  $y_{tr}$  hareketli ortalama filtresi ile elde edilen seri ve  $y_{res}$  gerçek seriden filtrelenmiş serinin çıkarılması ile bulunan zaman serisini ifade etmektedir. Düşük volatiliteli serinin ( $l_t$ ) ARIMA ile modellenmesi sonucu elde edilen kestirim ve hata değerleri sırasıyla  $\hat{l}_t$  ve  $\epsilon_t$ ; yüksek volatiliteli bileşenin ( $h_t$ ) YSA ile elde edilen kestirim ve hata değerleri  $\hat{h}_t$  ve  $\epsilon_t$  ile gösterilmektedir.

$$y_t = l_t + h_t \quad (16)$$

$$y_{tr} = \frac{1}{m} \sum_{i=t-m+1}^t y_i \quad (17)$$

$$y_{res} = y_t - y_{tr} \quad (18)$$

$$l_t = y_{tr} \quad (19)$$

$$h_t = y_{res} \quad (20)$$

$$l_t = ARIMA(l_t) = \hat{l}_t + \epsilon_t \quad (21)$$

$$h_t = YSA(h_t) = \hat{h}_t + \epsilon_t \quad (22)$$

$$\hat{l}_t = \hat{l}_{t,ARIMA} \quad (23)$$

$$\hat{h}_t = \hat{h}_{t,YSA} \quad (24)$$

$$\hat{y}_t = \hat{l}_t + \hat{h}_t \quad (25)$$

### 2.2. Optimize ARIMA-YSA melez modeli (Optimized ARIMA-ANN hybrid model)

Bu çalışmada ortaya konulan Optimize ARIMA-YSA melez modeli, [3, 21] çalışmalarında olduğu gibi zaman serisini doğrusal ve doğrusal olmayan iki bileşenin toplamı olarak ele almaktadır. Zhang [3]'in çalışmasında zaman serisi

ARIMA ile modellenmekte ve elde edilen kestirim serisi doğrusal bileşen olarak kabul edilmektedir. Model doğrusal bileşene öncelik tanımakta ve seriyi mümkün olduğunca doğrusal bir modelle açıklamaktadır. İkinci aşama olarak hata serisi YSA ile modellenmektedir. Burada temel düşünce doğrusal modelin artık (hata) serisinde doğrusal olmayan ilişkiler olabileceğidir. Bu çalışmada ortaya konulan OptAA melez modeli seriyi bileşenlere ayırmada ARIMA modeline öncelik tanımak yerine, [3]'den farklı olarak, ARIMA ve YSA modellerini bir arada kullanmaktadır.

Zaman serisini en iyi açıklayan doğrusal seri, gerçek serinin ARIMA ile elde edilen modeli olsun. Benzer şekilde, seriyi en iyi açıklayan doğrusal olmayan seri de gerçek serinin YSA ile elde edilen kestirim serisi olsun. Zaman serisi bu iki serinin belli oranlarda birleşimi olarak ifade edilebilir. Zaman serisini en iyi açıklayan birleşimi bulabilmek için ARIMA ve YSA ile elde edilen kestirim serileri, bir en küçük kareler optimizasyonundan geçirilir. Burada amaç ARIMA ve YSA modeliyle elde edilen, doğrusal ve doğrusal olmayan olduğu kabul edilen iki seriyi kullanarak gerçek seriyi en iyi açıklayan (hata kare toplamı en küçük) seriyi elde etmektir.

Optimizasyon sonucunda elde edilen model ARIMA ve YSA kestirim değerlerinin belli oranlarda toplamıdır. Modelin hatası da benzer şekilde ARIMA ve YSA model hatalarının aynı oranda toplamı olmaktadır. Bu noktada, Zhang [3]'in modelinde faydalandığı düşünceden yola çıkılarak modelin iyileştirilmesi mümkündür. Zhang [3], çalışmasında doğrusal modelin hata serisinde doğrusal olmayan ilişkiler olabileceğinden yola çıkarak hata serisini YSA ile modellemektedir. Bu çalışmada öne sürülen modelde de ARIMA ile elde edilen model hatalarında doğrusal olmayan ilişkiler bulunabileceği düşünülmektedir. Bu amaçla, ikinci aşamada, doğrusal bileşenin hata serisi daha önce doğrusal olmayan olarak tespit edilen bileşene eklenerek doğrusal olmayan bileşen revize edilir ve YSA ile yeniden modellenir. Diğer bir anlatımla, bulunan en iyi doğrusal bileşen gerçek seriden çıkarılarak kalan seri YSA ile modellenmektedir. Doğrusal olmayan bileşenin YSA ile modellenmesi sonucu elde edilen hata değerleri OptAA melez modelin hata değerleri olmaktadır.

Pratikte OptAA melez modeli, Zhang [3]'in melez modelinden doğrusal bileşenin bulunması aşamasında farklılık göstermektedir. Birinci aşamada en iyi doğrusal bileşen bulunduktan sonra, ikinci aşamada serinin kalan kısmı YSA ile modellenmektedir. Böylece, doğrusal olmayan bileşenin elde edilmesi, Zhang [3]'in çalışmasıyla aynı şekilde yapılmaktadır. OptAA melez model iki temel aşamadan oluşmaktadır. İlk aşamada en iyi doğrusal ve doğrusal olmayan bileşenler bulunmaktadır. İkinci aşamada ise doğrusal olmayan bileşen revize edilmekte ve yeniden modellenmektedir.

### 2.2.1. Optimizasyon Aşaması (Optimization stage)

İlk aşamada amaç, ARIMA modelinden elde edilen doğrusal zaman serisi ile YSA modelinden elde edilen doğrusal

olmayan zaman serisinden faydalanarak gerçek seriyi doğrusal ve doğrusal olmayan iki serinin toplamı olarak en iyi şekilde ifade etmektir.

$y_t$  bir zaman serisi olmak üzere; gerçek seriyi en iyi açıklayan doğrusal seri, ARIMA ile bulunan kestirim serisi  $\hat{y}_{t,ARIMA}$ ; ve seriyi en iyi açıklayan doğrusal olmayan seri, YSA ile bulunan kestirim serisi  $\hat{y}_{t,YSA}$  olsun. Gerçek seri, ARIMA ve YSA modelleriyle bulunan kestirim serilerinin belli oranlarda toplamı olarak ifade edilebilir. Gerçek seri ARIMA ile modellendiğinde, ARIMA kestirim serisi ve ARIMA hata serisi elde edilmektedir (Eş. 26).

$$y_t = ARIMA(y_t) = \hat{y}_{t,ARIMA} + e_{t,ARIMA} \quad (26)$$

Benzer şekilde, gerçek seri YSA ile modellendiğinde YSA kestirim serisi ile YSA hata serisi elde edilir (Eş. 27).

$$y_t = YSA(y_t) = \hat{y}_{t,YSA} + e_{t,YSA} \quad (27)$$

Gerçek seri, toplamı 1'e eşit olmak üzere iki katsayı kullanılarak her iki modelin belli oranlarda toplamı (karışımı) olarak gösterilebilir.  $0 \leq \alpha \leq 1$ ,  $0 \leq \beta \leq 1$ ,  $\alpha + \beta = 1$  olmak üzere gerçek seri Eş. 28'deki gibidir

$$y_t = \alpha ARIMA(y_t) + \beta YSA(y_t) \quad (28)$$

Eş. 26-Eş. 28'de yerine konulursa, gerçek serinin son hali Eş. 29'daki gibi olur.

$$y_t = \alpha \hat{y}_{t,ARIMA} + \beta \hat{y}_{t,YSA} + (\alpha e_{t,ARIMA} + \beta e_{t,YSA}) \quad (29)$$

Doğrusal ve doğrusal olmayan serilerin gerçek seriyi en iyi şekilde açıklayabilmesi için hatanın en aza indirgenmesi gerekmektedir. Hata kareler toplamı en küçüklenerek gerçek seriyi en iyi şekilde ayırıştırın  $\alpha$  ve  $\beta$  katsayıları elde edilir. Eş. 29 için hata değerleri  $e_t$  Eş. 30'daki gibi yazılabilir.

$$e_t = \alpha e_{t,ARIMA} + \beta e_{t,YSA} = y_t - \alpha \hat{y}_{t,ARIMA} - \beta \hat{y}_{t,YSA} \quad (30)$$

Bu durumda, en küçük kareler optimizasyonu Eş. 31, Eş. 32'de gösterilmektedir.

$$\text{Min } \sum(e_t^2) = \text{Min } \sum(y_t - \alpha \hat{y}_{t,ARIMA} - \beta \hat{y}_{t,YSA})^2 \quad (31)$$

$$\text{s. t. } \alpha + \beta = 1, 0 \leq \alpha \leq 1, 0 \leq \beta \leq 1 \quad (32)$$

Hata kareler toplamının en küçüklenmesi yoluyla bulunan optimum  $\alpha$  ve  $\beta$  değerleri modelin doğrusal ve doğrusal olmayan bileşenlere olabilecek en iyi şekilde ayrılmasını sağlamaktadır.

### 2.2.2. Doğrusal olmayan revize aşaması (Nonlinear revision stage)

Melez modelin birinci aşamasında elde edilen  $\alpha$  ve  $\beta$  katsayıları ile birlikte modelin son hali Eş. 33'teki gibi olmaktadır.

$$y_t = \alpha \hat{y}_{t,ARIMA} + \alpha e_{t,ARIMA} + \beta \hat{y}_{t,YSA} + \beta e_{t,YSA} \quad (33)$$

Eş. 33'te eşitliğin sağ tarafındaki birinci terimin ( $\alpha \hat{y}_{t,ARIMA}$ ) doğrusal bir seri olduğu bilinmektedir. Üçüncü terim ( $\beta \hat{y}_{t,YSA}$ ) doğrusal olmayan bir seri ve dördüncü terim ( $\beta e_{t,YSA}$ ) YSA modelinin hata serisidir. Bu noktada Zhang [3]'in modelinden esinlenilerek doğrusal modelin hata serisi ( $\alpha e_{t,ARIMA}$ ) içerisinde doğrusal olmayan ilişkiler aramak mümkündür. Hata serisi ( $\alpha e_{t,ARIMA}$ ), olduğu gibi bırakılmak yerine doğrusal olmayan bileşene eklenerek, elde edilen serinin YSA ile yeniden modellenmesi uygun olacaktır. Bu, aynı zamanda, gerçek seriden birinci aşamada bulunan doğrusal bileşenin çıkarılarak kalan serinin YSA ile modellenmesi demektir. Böylece, OptAA melez modelin ikinci aşaması amaç olarak Zhang [3]'in modeliyle aynıdır. Doğrusal olmayan ilişkilerin aranacağı yeni zaman serisi ( $n_t$ ) Eş. 34'te olduğu gibi yazılabilir.

$$n_t = y_t - \alpha \hat{y}_{t,ARIMA} = \alpha e_{t,ARIMA} + \beta \hat{y}_{t,YSA} + \beta e_{t,YSA} = \alpha e_{t,ARIMA} + \beta y_t \quad (34)$$

Revize edilen yeni seri ( $n_t$ ), gerçek seriden ( $y_t$ ) hatadan arındırılmış doğrusal bileşenin ( $\alpha \hat{y}_{t,ARIMA}$ ) çıkarılmasıyla bulunabileceği gibi; optimizasyon sonucu elde edilen doğrusal olmayan bileşene ( $\beta y_t = \beta \hat{y}_{t,YSA} + \beta e_{t,YSA}$ ) doğrusal bileşen hatalarının ( $\alpha e_{t,ARIMA}$ ) eklenmesiyle de bulunabilir. Bir sonraki aşamada revize edilen serinin YSA ile modellenmesi ile kestirim ve hata değerleri elde edilir (Eş. 35).

$$YSA(n_t) = \hat{n}_{t,YSA} + \varepsilon_{t,YSA} \quad (35)$$

Doğrusal olmayan bileşenin revize edilmesi ve YSA ile tekrar modellenmesiyle birlikte Optimize ARIMA-YSA melez modelin son hali Eş. 36'daki gibidir.

$$y_t = OptAA(y_t) = \alpha \hat{y}_{t,ARIMA} + \hat{n}_{t,YSA} + \varepsilon_{t,YSA} \quad (36)$$

Melez modelin doğrusal bileşen için kestirim değerleri  $\hat{L}_t$ , doğrusal olmayan bileşenin kestirimleri  $\hat{n}_t$  ve modelin hata serisi  $e_t$  ile ifade edilirse, OptAA melez model Eş. 37-Eş. 43'teki gibi gösterilebilir.

$$y_t = \hat{L}_t + \hat{n}_t + e_t \quad (37)$$

$$\hat{L}_t = \alpha \hat{y}_{t,ARIMA} \quad (38)$$

$$\hat{n}_t = \hat{n}_{t,YSA} \quad (39)$$

$$e_t = \varepsilon_{t,YSA} \quad (40)$$

$$OptAA(y_t) = \hat{y}_{t,OptAA} + e_{t,OptAA} \quad (41)$$

$$\hat{y}_{t,OptAA} = \alpha \hat{y}_{t,ARIMA} + \hat{n}_{t,YSA} \quad (42)$$

$$e_{t,OptAA} = \varepsilon_{t,YSA} \quad (43)$$

OptAA melez modelin her iki aşaması da oldukça önemlidir. Model, birinci aşamadan sonra bırakılır ve ikinci aşama uygulanmazsa, pratikte ARIMA ve YSA modellerinin kullanıldığı bir tahmin kombinasyonu halini alacaktır. Diğer taraftan, modeli diğer melez modellerden ayıran en önemli aşama doğrusal bileşenin bulunduğu birinci aşamadır. Doğrusal bileşenin bulunması için sadece ARIMA modelinden değil, aynı zamanda YSA modelinden ve her iki model kestirimlerinin kullanıldığı bir optimizasyon sürecinden faydalanılmaktadır. OptAA melez modelin uygulama süreci iki aşama halinde aşağıdaki gibi özetlenebilir:

- Birinci Aşama: Gerçek zaman serisi  $y_t$ , ARIMA ve YSA ile modellenerek kestirim ve hata değerleri bulunur. Zaman serisi  $y_t$ , ARIMA ve YSA modellerinin belli oranlarda toplamı olarak kabul edilir. Oranların en iyi değerlerinin bulunması için hata kareler toplamının en küçüklenmesine dayalı bir optimizasyon problemi çözülerek en iyi  $\alpha$  ve  $\beta$  katsayıları bulunur. Elde edilen  $\alpha \hat{y}_{t,ARIMA}$  serisi gerçek serinin doğrusal bileşen kestirimidir.
- İkinci Aşama: Doğrusal modelin hataları ( $\alpha e_{t,ARIMA}$ ) doğrusal olmayan bileşene ( $\beta \hat{y}_{t,YSA} + \beta e_{t,YSA}$ ) eklenerek doğrusal olmayan kısım revize edilir. Elde edilen doğrusal olmayan bileşen ( $n_t$ ) YSA ile yeniden modellenir. Modelleme sonucu doğrusal olmayan bileşen için kestirim değerleri ( $\hat{n}_{t,YSA}$ ) ve hata değerleri ( $\varepsilon_{t,YSA}$ ) elde edilir. Melez modelin kestirim değerleri birinci aşamada bulunan doğrusal kestirim değerleri ile ikinci aşamada bulunan doğrusal olmayan kestirim değerlerinin toplamıdır ( $\hat{y}_{t,OptAA} = \alpha \hat{y}_{t,ARIMA} + \hat{n}_{t,YSA}$ ). Melez modelin hata serisi ise ikinci aşamada elde edilen hata serisidir ( $e_{t,OptAA} = \varepsilon_{t,YSA}$ ). OptAA melez modelin gelecek tahmin değerleri birinci aşamada bulunan doğrusal bileşenin tahmin değerleri ile ikinci aşamada revize edilerek tekrar modellenen doğrusal olmayan bileşenin tahmin değerlerinin toplamıdır. OptAA melez modelin grafik gösterimi Şekil 1'de yer almaktadır.

### 3. UYGULAMA (APPLICATION)

#### 3.1. Veri seti (Data set)

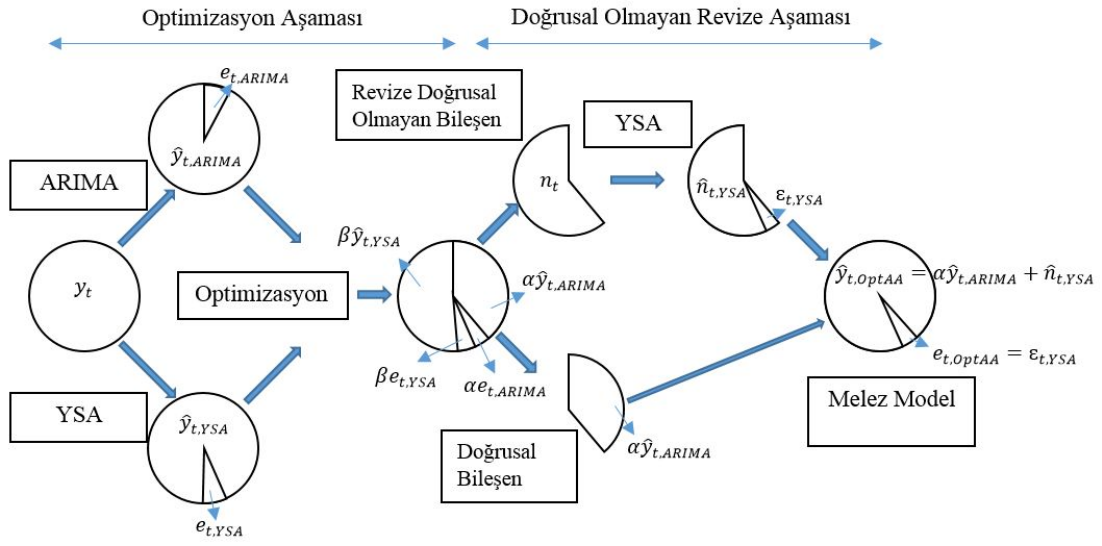
Bu çalışmada, ortaya konulan OptAA melez modelin etkinliğinin ve geçerliliğinin gözlemlenebilmesi için uygulama amacıyla, zaman serisi literatüründe iyi bilinen üç veri seti kullanılmaktadır. Bunlar; Wolf'un güneş lekesi veri seti, Kanada vaşak veri seti ve GBP/USD döviz kurudur. Her üç veri seti de hem farklı alanlardan gelmekte, hem de istatistik ve yapay sinir ağı modelleriyle literatürde yoğun olarak kullanılmaktadır [27, 3, 23]. Ayrıca, literatürde yer alan diğer başlıca ARIMA-ANN melez model çalışmalarında da sıklıkla bu veri setlerine başvurulmaktadır. Zhang [3] çalışmasında her üç veri setini de kullanırken, Wang vd. [23] ile Kashei ve Bijari [24] çalışmalarında güneş lekeleri ve vaşak setlerini kullanmaktadır. Babu ve Reddy [21] ise melez modelin etkinliğini saptamak ve diğer modellerle

karşılaştırmak için güneş lekesi veri setinden faydalanmaktadır.


Güneş lekesi veri seti 1700-1987 yılları arası gözlemlenmiş yıllık güneş lekesi sayısını içermekte ve toplam 288 veriden oluşmaktadır. Güneş aktivitesi özellikle jeofizik, çevre bilim ve iklim bilim açısından önem taşımaktadır. Güneş lekesi veri setine doğrusal olmayan modellerin etkinliğini ölçmek için sıklıkla başvurulmaktadır [3]. Veri setinin grafik gösterimi Şekil 2’de yer almaktadır.

Vaşak veri seti, Kuzey Kanada Mackenzie Nehri civarında tuzağa yakalanan yıllık vaşak sayısını göstermektedir. Veri


seti 1821-1934 yılları arasında kapsamakta ve 114 veriyi içermektedir. Vaşak zaman serisi literatürde doğrusal olmayan modellerin uygulandığı önemli serilerden biridir [23]. Veri seti Şekil 3’te gösterilmektedir. Son olarak, GBP/USD döviz kuru veri setinde İngiliz Poundu/Amerikan Doları döviz kurunun 1821-1934 yılları arasında aldığı haftalık değerler yer almakta, veri seti toplam 731 veri noktasından oluşmaktadır. Döviz kuru tahmini özellikle uluslararası finans açısından önemli ve zor bir konudur. Çok sayıda doğrusal ve doğrusal olmayan model geliştirilmiş olsa da, basit rassal yürüyüş modelinden daha başarılı sonuçlar veren model sayısı oldukça azdır [3]. Veri seti Şekil 4’te yer almaktadır. Karşılaştırılan çalışmaları [3, 21, 23, 24] takiben,



Şekil 1. OptAA melez model (OptAA hybrid model)



Şekil 2. Wolf'un güneş lekesi veri seti (Wolf's sunspot dataset)



Şekil 3. Kanada vaşak veri seti (Canadian lynx dataset)




Kanada vaşak veri seti ve GBP/USD döviz kuru için uygulama, veri setlerinin logaritmik dönüşümü (10 tabanında) üzerinden yapılmaktadır. Kullanılan veri setleri için tanımlayıcı istatistikler Tablo 1’de verilmektedir.

### 3.2. Uygulama detayları (Application details)

Bu çalışmada ARIMA modellemeleri için R Statistical Software (version 3.5.1) yazılımı kullanılmaktadır. En uygun ARIMA modeli seçimi Hyndman ve Khandakar [28]’in çalışmasında ortaya konulan otomatik arama (auto.ARIMA) fonksiyonu ile bulunmaktadır. auto.ARIMA fonksiyonu ARIMA (p,d,q) modelleme sürecini otomatik hale getirmektedir. Zaman serisi durağanlık ve mevsimsellik testlerine tabi tutulmakta, durağan olmayan seriler ardışık fark alma yöntemiyle durağan hale getirilmekte, mevsimsellik tespit edilen seriler için parametreler mevsimsel ARIMA (SARIMA (p,d,q)(P,D,Q)m) modeli olarak genişletilmektedir. Bu aşama ile “d” ve (mevsimsellik durumuna göre) “D” değerleri bulunan model için bundan sonra model arama aşamasına geçilmektedir. Bu çalışmada da, karşılaştırma yapılan diğer çalışmalarda [3, 21, 23, 24] olduğu gibi serilerde herhangi bir mevsimselliğe rastlanmamaktadır. En iyi modelin bulunması aşaması, seçilen bilgi kriterine göre adım adım arama yöntemiyle gerçekleştirilebilir. Adım adım arama yöntemi en iyi modelin hızlı bir şekilde bulunmasını sağlamaktadır. Diğer taraftan belli parametre aralıklarındaki tüm modellerin bilgi kriteri esas alınarak karşılaştırılması da mümkündür. Bu çalışmada en iyi model için kısıt AICc (Düzeltilmiş Akaike Bilgi Kriteri) olarak seçilmiştir. Otomatik arama fonksiyonunun arama alanı, karşılaştırılan melez model çalışmalarında [3, 21, 23, 24] aynı seriler için seçilen ARIMA modellerini de içerecek şekilde geniş tutularak, p=[0-15] ve q=[0-15] aralıkları olarak belirlenmiş ve bu aralıklardaki tüm modeller karşılaştırılmıştır. auto.ARIMA fonksiyonu ile ilgili daha fazla bilgi için Hyndman ve

Khandakar [28]’in çalışmasına başvurulabilir. ARIMA modellerinde önemli aşamalardan biri sürecin son aşaması olan artıkların kontrolü aşamasıdır. Artıkların kontrol edilmesinin amacı, artık serinin beyaz gürültü özelliği gösterip göstermediğinin kontrolüdür. Bu sebeple, artık seride gecikmeli değerlerle otokorelasyon olup olmadığına bakılmalıdır. Artık serinin kontrolü amacıyla R yazılımı içerisinde yer alan checkresiduals() fonksiyonu kullanılmaktadır. Bu fonksiyon ile artık serinin Ljung Box test sonuçlarını ve otokorelasyon fonksiyonu (ACF) grafiğini gözlemlemek mümkündür. Artıkların kontrolü ve checkresiduals() fonksiyonu ile ilgili daha ayrıntılı bilgi için Hyndman ve Athanasopoulos [29]’un çalışması incelenebilir. Bu çalışmada, seçilen tüm modeller için artık serileri checkresiduals() fonksiyonu ile kontrol edilmiş, artıkların beyaz gürültü özelliği gösterdiği ve gecikmeli değerlerle otokorelasyon bulunmadığı tespit edilmiştir.

YSA modelleri için Alyuda Neurointelligence (version 2.2 (577)) yazılımı kullanılmaktadır. Ağ mimarisi; bir girdi, bir gizli ve bir çıktı olmak üzere toplam üç katmanlıdır. Öğrenme algoritması Levenberg-Marquardt; aktivasyon fonksiyonu ise gizli katman için hiperbolik tanjant ve çıktı katmanı için lojistik fonksiyonlardır. Tahmin yöntemi tüm YSA modelleri için bir adım öte tahmin olduğundan çıktı katmanı nöron sayısı 1’dir. Zaman serileri için kullanılan YSA modellerinde en önemli parametrelerden biri girdi sayısıdır. Girdi sayısı serinin kaç adet gecikmeli değere bağlı olduğuyula ilgilidir ve literatürde en çok kullanılan yöntemlerden biri serinin AR (Oto regresyon) katsayısını kullanmaktır [30]. Bu çalışmada da, girdi katmanındaki nöron sayısının belirlenmesi için zaman serisini en iyi açıklayan oto regresif modelden faydalanılmaktadır. Diğer bir deyişle, zaman serisi için en iyi AR(p) modeli bulunmakta, böylece serinin kaç adet gecikmeli değere bağlı olarak modellenebildiği tespit edilmektedir. Burada elde edilen “p” değeri YSA modelinin girdi sayısı olarak



Şekil 4. GBP/USD döviz kuru veri seti (GBP/USD exchange rate dataset)

Tablo 1. Veri setleri için tanımlayıcı istatistikler (Descriptive statistics for datasets)

	Wolfun Güneş Lekesi	Kanada Vaşak	GBP/USD Döviz Kuru
Veri Sayısı	288	114	731
En Küçük	0,00	39	1,0648
En Büyük	190,20	6991	2,4373
Ortanca	39,00	771	1,6559
Ortalama	48,43	1538,02	1,6856
Std. Sapma	39,36	1578,87	0,2791

alınmaktadır. Zaman serisinin durağan olmadığı durumlarda ( $d > 0$ ), karşılaştırılan diğer çalışmalarda [3, 21, 23, 24] seçilmiş olan girdi düğüm sayısı dikkate alınmaktadır.

YSA için bir diğer önemli parametre olan gizli katman nöron sayısı konusunda literatürde birçok başparmak kuralı bulunmaktadır. En sık başvurulan uygulama bazı başparmak kuralları kullanılarak aday yapıların bulunması ve bu mimariler arasında deneme yanılma yoluyla performans karşılaştırması yapılmasıdır. Literatürde, girdi nöron sayısı  $n$ , çıktı nöron sayısı  $m$  ve gizli nöron sayısı  $h$  olan üç katmanlı bir YSA modeli için önerilen başlıca başparmak kuralları:  $h = \sqrt{nm}$  [31],  $h = (n+m)/2$  [32],  $h = 2/3(n+m)$  ve  $m \leq h \leq n$  [33] olarak gösterilebilir. Bu çalışmada gizli nöron sayısının tespiti için bahsedilen başparmak kurallarının hepsini içeren ve en kapsayıcı olan  $m \leq h \leq n$  [33] kuralı seçilmiştir. Buna göre, gizli nöron sayısı girdi ve çıktı sayısı arasında olan tüm mimariler karşılaştırılmakta ve en iyi model seçilmektedir. En iyi modelin seçimi için her mimarinin 500 iterasyon sonucu aldığı değerler karşılaştırılmakta ve kıstas olarak ortalama mutlak hata (mean absolute error) ve korelasyon katsayısı (R) kullanılmaktadır. Tüm YSA modellemelerinde, kullanılan yazılım tarafından veri setinin %80'i eğitim ve %20'si doğrulama setine kronolojik olarak ayrılmaktadır.

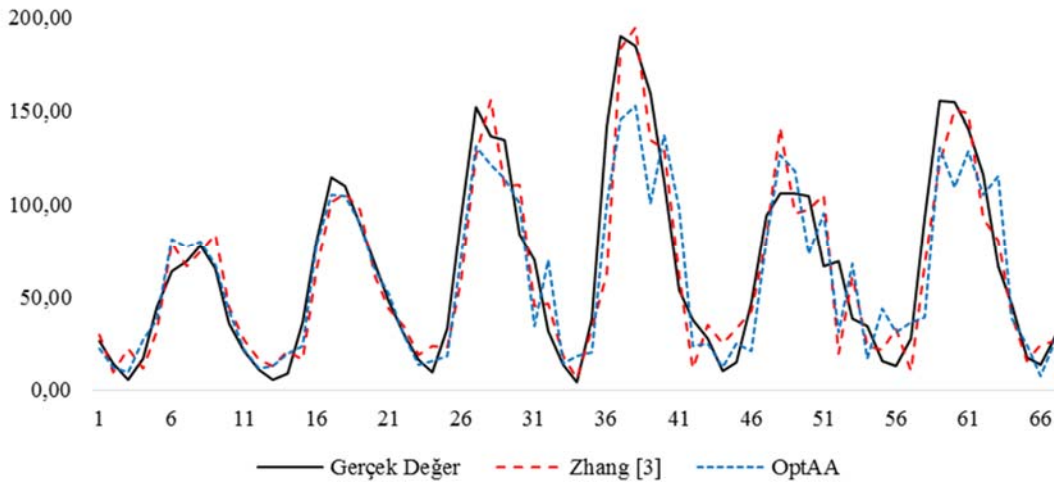
Çalışmanın uygulama aşamasında, ortaya konulan OptAA melez modelin tahmin performansı 7 ayrı model ile karşılaştırılmaktadır. Bunlar; literatürde yer alan diğer başlıca ARIMA-ANN melez modeller, ARIMA, YSA ve rassal yürüyüş (naïve) modelidir. Rassal yürüyüş modelinde gelecek tahmini son gözlemlenen değere eşittir ( $\hat{y}_{t+1} = y_t$ ). Özellikle finansal zaman serilerinde başarılı olduğu bilinen naïve model, zaman serisi modellerinin başarısını kıyaslamada referans olarak kullanılmaktadır [34]. Modellerin tahmin performansları, ortalama hata kare (OHK (MSE - mean squared error)), ortalama mutlak sapma (OMS (MAD - mean absolute deviation)), ortalama mutlak yüzde

hata (OMYH (MAPE - mean absolute percentage error)) ve belirlilik katsayısı (BK (CD - coefficient of determination -  $R^2$ )) kriterlerine göre değerlendirilmektedir.

### 3.3. Bulgular (Findings)

Tüm veri setleri için, karşılaştırma yapılan diğer melez model çalışmaları [3, 21, 23, 24] örnek alınmış, eğitim ve test setleri bu çalışmalarda olduğu gibi belirlenmiştir. Güneş lekeleri veri setinin ilk 221 veri noktası modelleme amacıyla kullanılmakta, modellerin sonraki 35 ve 67 veri noktası için tahmin sonuçları karşılaştırılmaktadır. Tablo 2'de güneş lekeleri veri seti için OptAA modeli ile alınan sonuçlar; ARIMA, YSA ve diğer ARIMA-YSA melez model sonuçları ile karşılaştırmalı olarak verilmektedir. Tablo 2 incelendiğinde, 35 adım öte performanslar kıyaslandığında OptAA melez modelin en iyi sonuçları verdiği görülmektedir. Ancak, 67 adım öte performanslar karşılaştırıldığında en iyi sonuçları Zhang [3]'ün melez modelinin verdiği anlaşılmaktadır. Şekil 5'te gerçek değerler ile birlikte Zhang [3] ve OptAA melez model tahmin sonuçları yer almaktadır. Zaman serisi için en iyi ARIMA modeli ARIMA(7,0,6) ve en iyi YSA mimarisi 9-7-1 ileri beslemeli sinir ağı olarak elde edilmektedir. Serinin doğrusal bileşeni belirlendikten sonra ikinci aşamada, revize edilen doğrusal olmayan bileşen için en iyi YSA mimarisi 9-6-1 olarak bulunmaktadır.

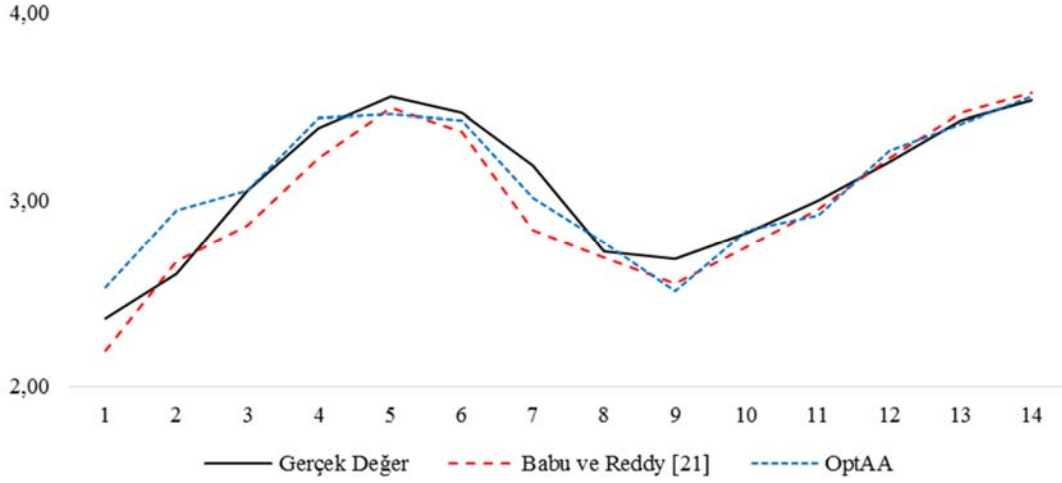
Kanada vaşak veri seti için ilk 100 veri modelleme için kullanılırken son 14 veri tahmin doğruluğunun ölçümü için test seti olarak kullanılmaktadır. Tablo 3'te vaşak veri seti elde edilen sonuçlar karşılaştırmalı olarak verilmektedir. Kanada vaşak veri seti için en iyi tahmin performansını OptAA melez model sağlamaktadır. Diğer taraftan, karşılaştırılan diğer melez modeller arasında en başarılı modelin Babu ve Reddy [21]'nin modeli olduğu görülebilir. Şekil 6'da gerçek değerler, Babu ve Reddy [21] ve OptAA melez model tahminleri birlikte gösterilmektedir. Veri seti



**Şekil 5.** Wolf'un güneş lekeleri veri seti için gerçek değer ile Zhang [3] ve OptAA melez modellerin 67 adım öte tahminleri (Real values and 67 steps ahead forecasts of Zhang [3] and OptAA hybrid models for Wolf's sunspot dataset)

**Tablo 2.** Wolf'un güneş lekesi veri seti için 35 ve 67 adım öte tahmin performansları  
(35 and 67 steps ahead forecast performances for Wolf's sunspot dataset)

	35 Adım				67 Adım			
	OHK (MSE)	OMS (MAD)	OMYH (MAPE)	BK (CD)	OHK (MSE)	OMS (MAD)	OMYH (MAPE)	BK (CD)
ARIMA	211,44	11,55	35,43%	0,880	402,13	14,97	36,57%	0,846
YSA	193,19	10,45	35,95%	0,887	432,27	15,72	42,90%	0,845
Zhang [3]	201,32	11,50	40,37%	0,880	378,58	14,66	39,69%	0,848
Khashei ve Bijari [24]	204,78	11,31	40,18%	0,880	506,38	16,94	49,63%	0,803
Wang vd. [23]	251,08	12,18	35,48%	0,871	496,15	16,21	36,09%	0,825
Babu ve Reddy [21]	258,86	12,43	59,41%	0,848	491,10	16,66	51,82%	0,817
OptAA	181,68	9,82	36,92%	0,894	488,61	16,52	39,54%	0,808
Rassal Yürütüş	638,31	20,35	60,98%	0,655	920,73	22,96	54,84%	0,660

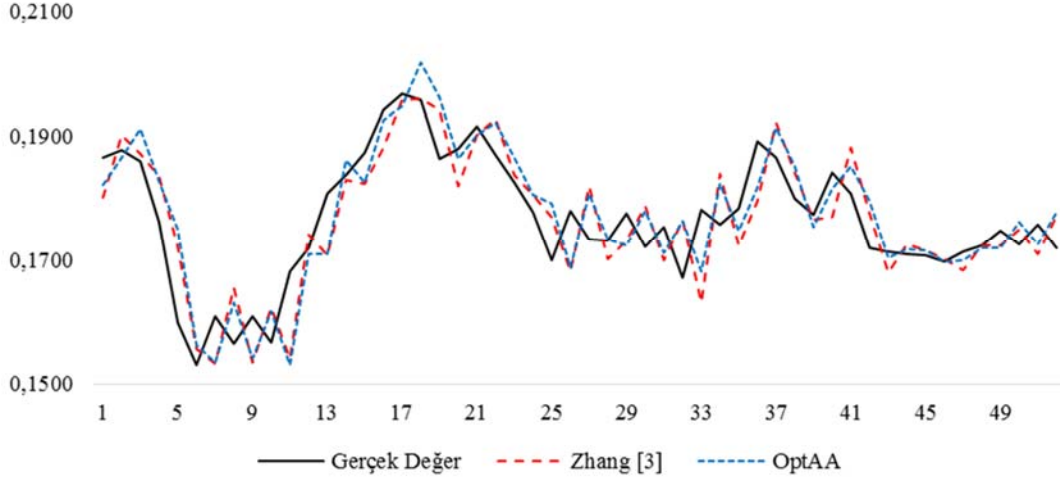
**Şekil 6.** Kanada vaşak veri seti için gerçek değer ile Babu ve Reddy [21] ve OptAA melez modellerin 14 adım öte tahminleri (Real values and 14 steps ahead forecasts of Babu and Reddy [21] and OptAA hybrid models for Canadian lynx dataset)**Tablo 3.** Kanada vaşak veri seti için 14 adım öte tahmin performansları  
(14 steps ahead forecast performances for Canadian lynx dataset)

	OHK (MSE)	OMS (MAD)	OMYH (MAPE)	BK (CD)
ARIMA	0,0254	0,1317	4,45%	0,844
YSA	0,0194	0,1118	3,66%	0,904
Zhang [3]	0,0216	0,1184	4,01%	0,862
Khashei ve Bijari [24]	0,0350	0,1377	4,76%	0,778
Wang vd. [23]	0,0244	0,1271	4,31%	0,848
Babu ve Reddy [21]	0,0188	0,1064	3,55%	0,924
OptAA	0,0168	0,0931	3,29%	0,879
Rassal Yürütüş	0,0687	0,2309	7,77%	0,695

için en iyi ARIMA modeli ARIMA(2,0,3) ve en iyi YSA mimarisi 11-6-1 olarak bulunmaktadır. İkinci aşamada, doğrusal olmayan bileşen için bulunan en iyi YSA mimarisi ise 12-6-1 ileri beslemeli ağıdır.

GBP/USD döviz kuru zaman serisi toplam 731 veri noktasından oluşmakta, ilk 679 veri model için kullanılırken son 52 veri tahmin amacıyla test edilmektedir. Modellerin 1 aylık (4 adım), 6 aylık (26 adım) ve 1 yıllık (52 adım) tahmin performansları karşılaştırılmaktadır. Tablo 4'te GBP/USD veri seti için OptAA modeli ile alınan sonuçlar; ARIMA,

YSA, diğer ARIMA-YSA melez modeller ve rassal yürütüş modeli sonuçları ile karşılaştırmalı olarak verilmektedir. Üç farklı tahmin ufku için elde edilen sonuçlar incelendiğinde melez modeller arasında en başarılı olanların OptAA melez model ve Zhang [3]'in modeli olduğu görülmektedir. Şekil 7'de OptAA melez model ve Zhang [3]'in modeli tahminleri gerçek seri değerleriyle birlikte verilmektedir. Zaman serisi için en iyi ARIMA modeli ARIMA(2,1,0) olarak elde edilmektedir. Seri doğrusal olmayan yapıda olduğundan otoregresif (AR(p)) olarak modellenememekte, bu sebeple en iyi YSA modeli için girdi sayısı konusunda aynı seriyi



**Şekil 7.** GBP/USD döviz kuru veri seti için gerçek değer ile Zhang [3] ve OptAA melez modellerin 52 adım öte tahminleri (Real values and 52 steps ahead forecasts of Zhang [3] and OptAA hybrid models for GBP/USD exchange rate dataset)

**Tablo 4.** GBP/USD döviz kuru veri seti için 1 ay (4 adım), 6 ay (26 adım) ve 12 ay (52 adım) öte tahmin performansları (4, 26 and 52 steps ahead forecast performances for GBP/USD exchange rate dataset)

	1 Ay				6 Ay				12 Ay			
	OHK (MSE)	OMS	OMYH (MAPE)	BK (CD)	OHK (MSE)	OMS	OMYH (MAPE)	BK (CD)	OHK (MSE)	OMS	OMYH (MAPE)	BK (CD)
ARIMA	3,56	4,77	2,63%	0,000	4,38	5,45	3,15%	0,766	3,77	5,03	2,88%	0,674
YSA	2,53	4,14	2,28%	0,078	5,18	6,26	3,58%	0,721	4,10	5,37	3,06%	0,633
Zhang [3]	2,58	4,34	2,38%	0,101	4,36	5,49	3,17%	0,765	4,02	5,27	3,02%	0,656
Khashei ve Bijari [24]	2,70	4,67	2,57%	0,211	4,61	5,63	3,27%	0,766	4,25	5,35	3,08%	0,665
Wang vd. [23]	3,45	5,33	2,92%	0,027	5,00	5,88	3,38%	0,748	4,90	5,81	3,31%	0,619
Babu ve Reddy [21]	4,84	5,70	3,15%	0,302	17,31	10,00	6,00%	0,717	15,62	10,53	6,19%	0,633
OptAA	2,22	4,29	2,35%	0,185	4,65	5,65	3,26%	0,771	3,54	4,87	2,79%	0,708
Rassal Yürüyüş	3,78	5,01	2,76%	0,029	4,50	5,73	3,30%	0,751	3,45	4,78	2,73%	0,682

kullanan daha önceki melez model çalışmalarına [3, 23] başvurulmaktadır. Farklı girdi ve gizli nöron sayılarıyla yapılan karşılaştırmalar sonucu zaman serisi için en iyi YSA modelinin 7-6-1 ileri beslemeli ağ olduğu sonucuna varılmaktadır. Benzer şekilde, zaman serisinin doğrusal olmayan bileşeni için elde edilen mimari de yine 7-6-1 ileri beslemeli sinir ağıdır.

#### 4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada Optimize ARIMA-YSA melez modeli (OptAA) ortaya konulmakta ve literatürde iyi bilinen üç farklı zaman serisine uygulanmaktadır. Elde edilen tahmin performans sonuçları; ARIMA, YSA, diğer başlıca ARIMA-YSA melez modeller [3, 21, 23, 24] ve rassal yürüyüş modeliyle karşılaştırılmaktadır.

Güneş lekeli zaman serisi ile yapılan uygulama ile modellerin 35 ve 67 adım öte performansları karşılaştırılmaktadır. Ortalama hata kare, ortalama mutlak sapma ve belirlilik katsayısı dikkate alındığında, OptAA melez modelin 35 adım öte performansının diğer modellerden daha iyi olduğu gözlemlenmektedir. Ancak aynı tahmin periyodu için hata kriteri ortalama mutlak yüzde hata olarak alındığında en iyi modelin ARIMA olduğu görülmektedir. Hedef tahmin aralığı 67 adıma

yükseltildiğinde ise Zhang [3]'ün melez modelinin oldukça başarılı olduğu saptanmaktadır. Ayrıca ortalama mutlak yüzde hata açısından Wang vd. [23] tahminleri başarılıdır. Güneş lekeli zaman serisi için karşılaştırılan tüm modellerin 35 ve 67 adım öte tahmin performanslarının rassal yürüyüş modelinden daha iyi olduğu gözlemlenmektedir.

Kanada vaşak veri seti için 14 adım öte performanslar karşılaştırılmakta ve elde edilen sonuçlara göre OptAA melez model en küçük ortalama hata kare, ortalama mutlak sapma ve ortalama mutlak yüzde hata değerlerine sahiptir. Performans ölçütü belirlilik katsayısı olarak alınırsa, Babu ve Reddy [21]'nin melez modelinin en iyi sonucu verdiği görülmektedir. Babu ve Reddy [21]'nin melez modeli diğer hata kriterleri için de OptAA melez modele en yakın sonuçları veren modeldir. Güneş lekeli veri setiyle yapılan uygulamada olduğu gibi, Kanada vaşak zaman serisi uygulamasında da tüm karşılaştırılan modellerin rassal yürüyüş modelinden daha başarılı olduğu görülmektedir.

Uygulama için seçilen en karmaşık ve tahmin edilmesi zor [3] zaman serisi GBP/USD döviz kurudur. GBP/USD döviz kuru serisi için 1 ay (4 adım öte), 6 ay (26 adım öte) ve 1 yıllık (52 adım öte) tahmin performansları karşılaştırılmaktadır. 1 aylık tahmin performansları karşılaştırıldığında en iyi modellerin OptAA melez model ve

YSA modeli olduğu görülmektedir. Tahmin zaman aralığı 6 aya yükseltildiğinde Zhang [3]'in melez modeli ve ARIMA modelleri en iyi sonuçları vermektedir. Ancak belirlilik katsayısı kıstasına göre OptAA melez modelin en iyi performansı gösterdiği de dikkat çekmektedir. 12 aylık tahmin performansları karşılaştırıldığında ise rassal yürüyüş modelinin tüm modellerden daha başarılı olduğu ortaya çıkmaktadır. Özellikle finansal zaman serileri için rassal yürüyüş modelinin başarılı olduğu bilinmektedir. Diğer taraftan 12 aylık tahmin performansı olarak rassal yürüyüş modeline en yakın sonuçları OptAA melez modelin verdiği ve diğer melez modellere göre daha başarılı olduğu görülmektedir. Karşılaştırılan modellerin 1 aylık tahmin hedefi için genelde rassal yürüyüş modelinden daha iyi oldukları, hedef zaman aralığı büyüdükçe rassal yürüyüş modeline göre performanslarının düştüğü ve tahmin aralığı 12 aya yükseldiğinde işlevselliklerini kaybettikleri görülmektedir.

Elde edilen karşılaştırmalı sonuçlar incelendiğinde, bu çalışmada ortaya konulan OptAA melez modelin zaman serisi analizi için oldukça güçlü bir yöntem olduğu anlaşılmaktadır. Özellikle görece daha kısa dönem tahmin hedefleri için ve ortalama hata kare temel alındığında OptAA melez model diğer modellere göre çok daha iyi sonuçlar vermektedir. Optimizasyon aşamasında hata karelerin en küçüklenmesini hedefleyen OptAA melez model tahmin sonuçlarına göre ortalama hata kare açısından oldukça iyi bir performans göstermektedir. Özellikle kısa dönem için çok daha iyi tahmin performansı gösteren modelin uzun dönemler için de iyi derecede tahmin performansına sahip olduğu söylenebilir. Elde edilen bulgular incelendiğinde, rassal yürüyüş (naïve) modeli referans alınır, karşılaştırılan tüm modellerin tahmin performansı açısından oldukça kullanışlı olduğu görülmektedir. Naïve modelin en güçlü olması beklenen GBP/USD döviz kuru örneğinde dahi 4 adım öte ve 26 adım öte tahminler açısından karşılaştırılan tüm modeller çok iyi sonuçlar vermektedir.

Bu çalışmada ortaya konulan OptAA melez model daha fazla araştırmaya açıktır. Gelecekte yapılacak benzer çalışmalarda, modelde kullanılan YSA parametrelerinin değiştirilmesi ile elde edilecek farklı sonuçlar gözlemlenebilir. Modelin, farklı öğrenme algoritmaları, farklı aktivasyon fonksiyonları veya farklı mimariler ile alabileceği farklı performans değerleri incelenebilir. Benzer şekilde OptAA melez modelin farklı zaman serilerine uygulanarak elde edilen sonuçların incelenmesi modelin geliştirilmesi açısından faydalı olacaktır.

#### KAYNAKÇA (REFERENCES)

1. Box, G.E.P., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., Time Series Analysis: Forecasting and Control, John Wiley & Sons, New Jersey, A.B.D., 2015.
2. Huang, R., Xu, F., Chen, R., General expression for linear and nonlinear time series models, Front. Mech. Eng. China, 4 (1), 15-24, 2009.
3. Zhang, G.P., Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing, 50, 159-175, 2003.
4. Santos Júnior, D.S. de O., de Oliveira J.F.L., de Mattos Neto, P.S.G., An intelligent hybridization of ARIMA with machine learning models for time series forecasting, Knowl.-Based Syst., 175, 72-86, 2019.
5. Somers, M.J. ve Casal, J.C., Using Artificial Neural Networks to Model Nonlinearity The Case of the Job Satisfaction-Job Performance Relationship, Organ. Res. Methods, 12 (3), 403-417, 2009.
6. Yan, H. ve Zou, Z., Application of a Hybrid ARIMA and Neural Network Model to Water Quality Time Series Forecasting, J. Converg. Inf. Technol., 8 (4), 59-70, 2013.
7. Hajirahimi, Z. ve Khashei, M., Hybrid structures in time series modeling and forecasting: A review, Eng. Appl. Artif. Intell., 86, 83-106, 2019.
8. E, J., Ye, J., Jin, H., A novel hybrid model on the prediction of time series and its application for the gold price analysis and forecasting, Physica A, 527, 121454, 2019.
9. Adak, M.F. ve Akpınar, M., A Hybrid Artificial Bee Colony Algorithm using Multiple Linear Regression on Time Series Datasets, 2018 3rd International Conference on Smart and Sustainable Technologies (SpliTech), Split-Croatia, 1-5, 26-29 Haziran, 2018.
10. Lotfi, K., Bonakdari, H., Ebtehaj, I., Mjalli, F.S., Zeynoddin, M., Delatolla, R., Gharabaghi, B., Predicting wastewater treatment plant quality parameters using a novel hybrid linear-nonlinear methodology, J. Environ. Manage., 240, 463-474, 2019.
11. Kaytez, F., A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption, Energy, 197, 117200, 2020.
12. Xu, S., Chan, H.K., Zhang, T., Forecasting the demand of the aviation industry using hybrid time series SARIMA-SVR approach, Transp. Res. Part E Logist. Transp. Rev., 122, 169-180, 2019.
13. Saxena, H., Aponte, O., McConky, K.T., A hybrid machine learning model for forecasting a billing period's peak electric load days, Int. J. Forecasting, 35, 1288-1303, 2019.
14. Khan, M.M.H., Muhammad, N.S., El-Shafie, A., Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting, J. Hydrol., 590, 125380, 2020.
15. Safari, A. ve Davallou, M., Oil price forecasting using a hybrid model, Energy, 148, 49-58, 2018.
16. Mahalakshmi, N., Umarani, P.R., Selvaraj, R.S., Forecasting the Tamil Nadu Rainfall Using Hybrid ARIMA-ANN Model, Int. J. Recent Sci. Res., 5 (3), 566-569, 2014.
17. Corduas, M., Nonlinearity tests in time series analysis, J. It. Statist. Soc., 3, 291-313, 1994.
18. Suhermi, N., Suhartono, Prastyo, D.D., Ali, B., Roll motion prediction using a hybrid deep learning and

- ARIMA model, *Procedia Comput. Sci.*, 144, 251-258, 2018.
19. Wang, X. ve Meng, M., A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting, *J. Comput.*, 7 (5), 1184-1190, 2012.
  20. Hwang, K.P. ve Day, Y.J., Tourism Revenue Forecasting: A Hybrid Model Approach, *Actual Probl. Econ.*, 141 (3), 473-483, 2013.
  21. Babu, C.N. ve Reddy, B.E., A Moving-Average Filter Based Hybrid ARIMA-ANN Model for Forecasting Time Series Data, *Appl. Soft Comput.*, 23, 27-38, 2014.
  22. Aburto, L., ve Weber, R., Improved Supply Chain Management Based on Hybrid Demand Forecasts, *Appl. Soft Comput.*, 7 (1), 136-144, 2007.
  23. Wang, L., Zou, H., Su, J., Li, L., Chaudrhy, S., An ARIMA-ANN Hybrid Model for Time Series Forecasting, *Syst. Res. Behav. Sci.*, 30, 244-259, 2013.
  24. Khashei, M. ve Bijari, M., A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting, *Appl. Soft Comput.*, 11, 2664-2675, 2011.
  25. Büyükşahin Ü.Ç., Ertekin Ş., A feature-based hybrid ARIMA-ANN model for univariate time series forecasting, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (1), 467-478, 2020.
  26. Reşat H.G., Design and development of hybrid forecasting model using artificial neural networks and ARIMA methods for sustainable energy management systems: A case study in tobacco industry, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1129-1140, 2020.
  27. Akpınar, M., Adak, M.F., Yumuşak, N., Time series forecasting using artificial bee colony based neural networks, 2017 International Conference on Computer Science and Engineering (UBMK), Antalya-Turkey, 554-558, 5-8 Ekim, 2017.
  28. Hyndman, R.J. ve Khandakar, Y., Automatic Time Series Forecasting: The Forecast Package for R, *J Stat. Softw.*, 27 (3), 1-22, 2008.
  29. Hyndman, R.J. ve Athanasopoulos, G., *Forecasting: principles and practice*, OTexts, Melbourne, Avustralya, 2018.
  30. Zhang, G.P., Patuwo, B.E., Hu, M.Y., A simulation study of artificial neural networks for nonlinear time-series forecasting, *Comput. Oper. Res.*, 28, 381-396, 2001.
  31. Kaastra, I. ve Boyd, M., Designing a Neural Network For Forecasting Financial and Economic Time Series, *Neurocomputing*, 10, 215-236. 1996.
  32. Chakra, C.N.C., Song, K.Y., Saraf, D.N., Gupta, M.M., Production Forecasting of Petroleum Reservoir Applying Higher-Order Neural Networks (HONN) With Limited Reservoir Data, *Int. J. Comput. Appl.*, 72 (2), 23-35, 2013.
  33. Panchal, G., Ganatra, A., Kosta, Y.P., Panchal, D., Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers, *Int. J. Comput. Theory Eng.*, 3 (2), 332-337, 2011.
  34. Makridakis, S., Spiliotis, E., Assimakopoulos, V., The M4 Competition: 100,000 time series and 61 forecasting methods, *Int. J. Forecasting*, 36, 54-74, 2020.