

**T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
İSTATİSTİK ANA BİLİM DALI**



**DENEYSEL MOD AYRIŞIMI İLE ZAMAN SERİSİ ÖNGÖRÜSÜ  
MODELLERİNİN KARŞILAŞTIRILMASI**

Doktora Tezi

**Mehmet Arif DEMİRCİ**

Danışman

**Prof.Dr. Vedide Rezan USLU**

SAMSUN  
2022

## TEZ KABUL VE ONAYI

Mehmet Arif DEMİRCİ tarafından, Prof. Dr. Vedide Rezan USLU danışmanlığında hazırlanan “DENEYSEL MOD AYRIŞIMI İLE ZAMAN SERİSİ ÖNGÖRÜSÜ MODELLERİNİN KARŞILAŞTIRILMASI” başlıklı bu çalışma, jürimiz tarafından 5.9.2022 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Doktora Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Başkan	Prof. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Doç. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Prof. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
Üye	Prof. Dr. XXXX XXXX Ondokuz Mayıs Üniversitesi ..... Anabilim Dalı		<input type="checkbox"/> Kabul <input type="checkbox"/> Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY

... / ... / ...

Prof. Dr. Ali BOLAT  
Enstitü Müdürü

## BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Doktora tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet  (Gerekli ise ekler kısmına ekleyiniz)

Hayır

05 /09/ 2022

Mehmet Arif DEMİRCİ

## TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

**Tez Başlığı:** DENEYSEL MOD AYRIŞIMI İLE ZAMAN SERİSİ ÖNGÖRÜSÜ MODELLERİNİN KARŞILAŞTIRILMASI

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 22.06.2022 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 8

Tek kaynak oranı : % 1 çıkmıştır.

05 /09 / 2022

Prof. Dr. Vedide Rezan USLU

## ÖZET

### DENEYSEL MOD AYRIŞIMI İLE ZAMAN SERİSİ ÖNGÖRÜSÜ MODELLERİNİN KARŞILAŞTIRILMASI

Mehmet Arif DEMİRCİ  
Ondokuz Mayıs Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
İstatistik Ana Bilim Dalı  
Doktora, Haziran/2022  
Danışman: Prof.Dr. Vedide Rezan USLU

Zaman serileri, zamana bağlı olarak değişkenlik gösteren ve gözlem değerlerinin art arda ve eşit aralıklı bir şekilde ölçüldüğü dizilerdir. Zaman serilerinde aynı dönemlerde art arda gelen gözlem değerlerinin birbirine bağımlı olduğu kabul edilir. Bu sayede gelecek dönem öngörü değerleri geçmiş dönemlerde gözlenen değerler ile hesaplanabilir.

Bir zaman değişkeni hakkında öngörüde bulunmak, değişkenin geçmiş dönemlerdeki hareketleri gözlemlenerek oluşturulan modeller yardımıyla mümkündür. Öngörüler bu modeller vasıtasıyla yapılacağı için model kurma işlemi oldukça önemlidir. Doğru kurulan bir model gerçek değerlere yakın öngörüler yani hatası az tahminler üretmeyi sağlar.

Artan baz istasyonlarının sayısına bağlı olarak canlılar gün geçtikçe daha fazla elektromanyetik radyasyona (EMR) maruz kalmaktadır. EMR'ye sebep olan cihazların canlılar üzerindeki olumsuz etkileri bilinmesine rağmen bu cihazları hayatımızdan tamamı ile çıkarmak mümkün görünmemektedir. Bu bağlamda bir ortamda bulunan elektrik alan şiddeti (EMA) miktarının gözlenmesi, modellenmesi ve öngörüde bulunulması önem arz etmektedir. Bu çalışmada EMA ölçüm değerleri üzerinde, düzleştirme parametreleri ve başlangıç değerlerinin Diferansiyel Gelişim Algoritması (DGA) ile optimize edildiği Holt Winters üstel düzleştirme yöntemi ile Deneysel Mod Ayırıştırma (DMA) yöntemine dayalı Yapay Sinir Ağları (DMA-YSA) ve Uyarlamalı Ağ tabanlı Bulanık Çıkarım Sistemi (DMA-ANFİS) modelleri önerilmiştir. Performans karşılaştırmasında önerilen yöntemlerin kendi sınıfında bulunan diğer yöntemlerden daha iyi sonuçlar verdiği gözlenmiştir.

**Anahtar Sözcükler:** Holt Winters üstel düzleştirme yöntemi, Diferansiyel gelişim algoritması, Deneysel mod ayırıştırma, Yapay sinir ağları, Uyarlamalı ağ tabanlı bulanık çıkarım sistemi

## ABSTRACT

### COMPARISONS OF EMPIRICAL MODE DECOMPOSITION WITH TIME SERIES FORECASTING MODELS

Mehmet Arif DEMİRCİ  
Ondokuz Mayıs University  
Institute of Graduate Studies  
Department of Statistics  
Ph.D., June/2022

Supervisor: Prof. Dr. Vedide Rezan USLU

Time series vary depending on the time in which sequence of observations are measured successively and at equal intervals. In time series, successive observations in the same period are considered to be independent. Thus, future time prediction values can be calculated with the values observed in the past times.

Forecasting about a time variable is possible with the help of models created by observing the movements of the variable in the past. The model-building process is crucial because forecasts will be made through these models. The model built to fit the time series enables to produce forecasts close to actual values with minimum error.

Living things are exposed to more and more electromagnetic radiation (EMR) day by day due to the increasing number of base stations. Although the negative impacts of devices that cause EMR on living things are known, it does not seem possible to completely remove it from our lives. In this sense, it is important to observe, model, and predict the amount of electric field intensity (EMI) in an environment. In this study, Holt-Winters exponential smoothing method, in which smoothing parameters and initial values are optimized by Differential Evolution Algorithm and Artificial Neural Networks and Adaptive Network-based Fuzzy Inference System models based on Empirical Mode Decomposition method are proposed on EMI measurement values. In the performance comparison, it is observed that the proposed methods give better results than other methods in their class.

**Keywords:** Holt Winters exponential smoothing, Differential evolution algorithm, Empirical mode decomposition, Artificial neural networks, Adaptive network-based fuzzy inference system

## ÖN SÖZ VE TEŞEKKÜR

Bu çalışmada olduğu gibi tüm akademik çalışmalarında bilgi ve tecrübeleri ile ışık tutan, yol gösteren, maddi manevi desteği ile her zaman yanımda olan kıymetli danışmanım Sayın Prof. Dr. Vedide Rezan USLU'ya en içten sevgi ve saygılarımı sunarım.

Değerli hocalarım Sayın Doç. Dr. Pelin KASAP ve Sayın Doç. Dr. Çetin KURNAZ'a çalışmama yapmış oldukları katkılarından dolayı teşekkür ederim. Ayrıca değerli meslektaşım Arş. Gör. Dr. Keziban KILIÇ TOPAL'a teşekkür ederim.

Bugünlere gelmemi sağlayan hayat boyu her zaman yanımda olan kıymetli anne ve babama sonsuz teşekkür ederim. Tez yazım sürecinde zorlandığım anlarda bana manevi güç veren ve üzerimdeki yükleri hafifleten hayat arkadaşım sevgili eşime ve moral kaynağım kızıma şükranlarımı sunarım.

Mehmet Arif DEMİRCİ

# İÇİNDEKİLER

TEZ KABUL VE ONAYI .....	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI.....	ii
ÖZET.....	iii
ABSTRACT.....	iv
ÖNSÖZ VE TEŞEKKÜR.....	v
İÇİNDEKİLER.....	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	viii
TABLolar DİZİNİ.....	ix
1. GİRİŞ.....	10
2. ZAMAN SERİSİ ANALİZİ.....	12
2.1. Olasılığa Dayalı Yöntemler .....	12
2.1.1. Otoresif Bütünleşik Hareketli Ortalamalar-ARIMA.....	12
2.1.2. Üstel Düzleştirme Yöntemleri .....	15
2.1.2.1. Diferansiyel Gelişim Algoritması .....	18
2.2. Öğrenmeye Dayalı Yöntemler .....	19
2.2.1. Yapay Sinir Ağları-YSA.....	19
2.2.1.1. Tek Katmanlı Algılayıcılar .....	21
2.2.1.2. Çok Katmanlı Algılayıcılar .....	22
2.2.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi-ANFİS .....	26
3. DENEYSEL MOD AYRIŞTIRMA YÖNTEMİ.....	31
4. ÇALIŞMADA KULLANILAN YAKLAŞIM.....	35
5. UYGULAMA .....	37
6. SONUÇ VE ÖNERİLER.....	64
KAYNAKÇA .....	66
EKLER.....	69

## SİMGELER VE KISALTMALAR

AIC	: Akaike Bilgi Kriteri
ANFIS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama
BIC	: Bayesci Bilgi Kriteri
ÇHW	: Çarpımsal Holt Winters
DGA	: Diferansiyel Gelişim Algoritması
DMA	: Deneysel Mod Ayırıştırma
EMA	: Elektrik Alan Şiddeti
EMR	: Elektromanyetik Radyasyon
HKOK	: Hata Kareler Ortalaması Karekökü
HW	: Holt Winters
L	: Mevsimsel periyod uzunluğu
NHKOK	: Normalleştirilmiş Hata Kareler Ortalaması Karekökü
OMYH	: Ortalama Mutlak Yüzde Hata
SARIMA	: Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama
THW	: Toplamsal Holt Winters
YSA	: Yapay Sinir Ağları
$I_t$	: Mevsimsel bileşen için düzeltme faktörü,
$S_t$	: Serinin ortalama düzeyine ait düzeltme faktörü,
$y_t$	: Orijinal veri seti,
$\alpha$	: Serinin ortalama düzeyine ilişkin düzeltme parametresi,
$\beta$	: Mevsimselliği düzeltmek için kullanılan mevsimsel düzeltme parametresi,
$\gamma$	: Trend bileşeni için düzgünleştirme parametresi,

## ŞEKİLLER DİZİNİ

Şekil 2.1. Biyolojik sinir hücresinin yapısı .....	20
Şekil 2.2. Tek katmanlı yapay sinir hücresinin yapısı .....	22
Şekil 2.3. Çok katmanlı Ağ Mimarisi .....	23
Şekil 2.4. ANFİS için örnek bir mimari.....	27
Şekil 3.1. DMA akış şeması.....	33
Şekil 5.1. EMA ölçümlerinin zaman serisi grafiği.....	37
Şekil 5.2. Uygulama Şeması .....	38
Şekil 5.3. SARIMA ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği	41
Şekil 5.4. SARIMA ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği.....	42
Şekil 5.5. Bir kromozom örneği.....	43
Şekil 5.6. HW-DGA yöntemi ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği .....	44
Şekil 5.7. HW-DGA yöntemi ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği .....	45
Şekil 5.8. Girdi değişken sayısına göre HKOK'daki değişimler (logsig).....	46
Şekil 5.9. Girdi değişken sayısına göre HKOK'daki değişimler (tansig) .....	47
Şekil 5.10. YSA ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği (logsig).....	48
Şekil 5.11. YSA ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği (logsig).....	48
Şekil 5.12. Girdi ve çıktı üyelik fonksiyonlarından elde edilen HKOK kutu grafikleri .....	51
Şekil 5.13. ANFİS ile eğitim kümesi için ölçüm değerleri ile öngörülen değerlerin birlikte grafiği .....	52
Şekil 5.14. ANFİS ile test kümesi için ölçüm değerleri ile öngörülen değerlerin birlikte grafiği .....	53
Şekil 5.15. DMA yöntemi ile öngörü şeması.....	55
Şekil 5.16. DMA yöntemi ile elde edilen İMF bileşenleri ve artıkların zaman serisi grafiği	55
Şekil 5.17. Test kümesi için İMF bileşenleri ve öngörülerinin birlikte grafiği.....	57
Şekil 5.18. Eğitim kümesi için ölçüm değerleri ile DMA-YSA yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği.....	58
Şekil 5.19. Test kümesi için ölçüm değerleri ile DMA-YSA yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği.....	58
Şekil 5.20. Test kümesi için İMF bileşenleri ve öngörülerinin birlikte grafiği.....	59
Şekil 5.21. Eğitim kümesi için ölçüm değerleri ile DMA-ANFİS yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği.....	60
Şekil 5.22. Test kümesi için ölçüm değerleri ile DMA-ANFİS yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği.....	61
Şekil 5.23. Test kümesi için yöntemlerden elde edilen öngörülerin gerçek EMA değerleri ile regresyonu .....	62

## TABLULAR DİZİNİ

Tablo 2.1. YSA'nın önemli özellikleri.....	21
Tablo 2.2. YSA'da kullanılan birleştirme fonksiyonları.....	24
Tablo 2.3. YSA'da en çok kullanılan aktivasyon fonksiyonları .....	25
Tablo 2.4. Girdi üyelik fonksiyonları ve grafikleri.....	28
Tablo 5.1. D=0 olduğu durumda AIC bilgi kriterine göre en iyi modellere ait sonuçlar .....	39
Tablo 5.2. D=0 olduğu durumda BIC bilgi kriterine göre en iyi modellere ait sonuçlar .....	39
Tablo 5.3. D=1 olduğu durumda AIC bilgi kriterine göre en iyi modellere ait sonuçlar.....	40
Tablo 5.4. D=1 olduğu durumda BIC bilgi kriterine göre en iyi modellere ait sonuçlar .....	40
Tablo 5.5. Öngörü performansı en iyi olan SARIMA modeline ait sonuçlar .....	41
Tablo 5.6. HW-DGA Sonuçları .....	43
Tablo 5.7. HW-DGA yönteminden elde edilen öngörülerin performans sonuçlar .....	44
Tablo 5.8. YSA ile kurulan farklı modellere ait HKOK değerleri.....	46
Tablo 5.9. YSA ile kurulan en iyi modellere ait performans sonuçları.....	47
Tablo 5.10. YSA modeli çapraz doğrulama.....	49
Tablo 5.11. ANFİS ile kurulan modellerin performansları.....	51
Tablo 5.12. ANFİS modeli çapraz doğrulama .....	53
Tablo 5.13. Doğrudan uygulama ile elde edilen sonuçlar.....	54
Tablo 5.14. İMF bileşenleri ve artığın öngörülerine ait HKOK değerleri .....	56
Tablo 5.15. DMA-YSA modelinin öngörü performans sonuçları .....	57
Tablo 5.16. İMF bileşenleri ve artığın öngörülerine ait HKOK değerleri .....	59
Tablo 5.17. DMA-ANFİS modelinin öngörü performans sonuçları.....	60
Tablo 5.18. Yöntemlerin performans karşılaştırılması .....	61

## 1. GİRİŞ

Zaman serileri, zamana bağılı olarak değişen ve ölçümlerin sürekli veya belli aralıklarla gözlemlenerek kaydedildiği değişkenlerin oluşturduğu serilerdir. Zaman serilerinde geçmişe ait gözlem değerleri kullanılarak gelecek hakkında öngörüle bulunmak ve planlama yapmak mümkün olmaktadır.

Zaman serisi analizi, zaman serilerinin zaman içerisindeki davranışını gözlemleyerek gelecek dönem gözlem değerlerini minimum hata ile tahmin etmeye imkân sağlayan bir dizi istatistiksel yöntemi içerir. Bu yöntemleri tek ve çok değişkenli olmak üzere farklı kategorilerde sınıflamak mümkün olabilir. Bu tez çalışmasında tek değişkenli zaman serileri analizi kullanılmıştır. Tek değişkenli zaman serileri analizinde sıklıkla kullanılan Box-Jenkins yöntemleri ilgili zaman serisinin durağan durağan olmasını gerektirir. Zaman serisinin durağan olmadığı durumlarda ise fark alma işlemi ve trend analizi gibi uygulamalar ile durağanlaştırma sağlanabilir.

Zaman serisi analizleri içerisinde yer alan ve daha klasik sayılabilen yöntemler Üstel Düzleştirme yöntemleri olarak bilinmektedir. Veri setinde trend ve mevsimsellik olma durumuna göre farklı üstel düzleştirme yöntemleri önerilmektedir. Zaman serisi trend ve mevsimsel bileşenlere sahip değilse Basit Üstel Düzleştirme yöntemi, sadece trend bileşenine sahip ise Holt (iki parametrelili) Üstel Düzleştirme yöntemi, hem trend hem de mevsimsel bileşene birlikte sahipse veya bazen de sadece mevsimsel bileşene sahipse Holt Winters (üç parametrelili) Üstel Düzleştirme yöntemi uygulanır.

Günümüzde hemen hemen bütün alanlarda kullanılan ve önemi giderek artan yapay zekâ teknikleri ile insan zekasının en önemli özelliklerinden birisi olan öğrenme kabiliyeti modellenenmektedir. Yapay zekâ teknikleri, öğrenme tabanlı öngörüle bulunmayı da kolaylaştırmaktadır. Bu tekniklerden bir tanesi yapay sinir ağları (YSA) bir diğeri ise YSA ve bulanık çıkarım sistemlerinin birlikte kullanıldığı melez bir yöntem olan uyarlamalı ağ tabanlı bulanık çıkarım sistemi- ANFİS'dir.

Zaman serilerinde geleneksel yöntemler ile yapay zeka tekniklerinin hibrit edildiği modeller yardımıyla öngörü elde edilmesini amaçlayan bir çok çalışma yapılmaktadır. Hibrit yöntemlerin uygulanması genellikle iki şekilde gerçekleştirilmektedir. Bunlardan birisi gelekneksel yöntemler içerisinde yer alan, ne olacağı kesitirilemeyen ve öngörü üzerinde önemli etkiye sahip parametrelerin genetik algoritma, diferansiyel gelişim algoritması, parçacık sürü optimizasyonu vb. yapay

zeka algoritmaları ile optimize edilmesidir. Diđeri ise hibrit edilen yöntemlerin aşamalı bir şekilde uygulandıđı ve yöntemlerden elde edilen öngörülerin birlikte orijinal seri öngörüsünü oluşturduđu yöntemlerdir.

Gelişen teknoloji ve kablosuz cihazların kullanımının artması elektromanyetik radyasyonun olumsuz etkilerini de artırmaktadır. Bu bağlamda bir ortamda bulunan elektrik alan şiddetinin dođru bir şekilde modellenmesi ve ileriye yönelik tahminde bulunulması önem arz etmektedir (Kurnaz ve Korunur Engiz, 2018).

Bu çalışmada kullanılan elektrik alan şiddeti veri seti üzerinde iki yöntem önerilmiştir. Birincisi Holt Winters Üstel Düzleştirme yönteminde öngörü performansını önemli derecede etkileyen düzleştirme parametreleri ve başlangıç değerlerinin diferansiyel gelişim algoritması ile belirlenmesidir. İkincisi ise deneysel mod ayrıştırma yöntemi ile kendi içinde durađan bileşenlere ayrıştırılan veri setleri üzerinden hem YSA hem de ANFİS yöntemleri ayrı ayrı uygulanarak öngörülerin elde edilmesidir.

## 2. ZAMAN SERİSİ ANALİZİ

Bir zaman serisi trend, mevsimsel dalgalanma, döngüsel (konjonktürel) dalgalanma ve düzensiz (tesadüfi) hareketler olmak üzere 4 bileşenden oluşmaktadır (Kadılar, 2020).

**Trend:** Zaman serilerinde trend, serinin uzun süreli artış veya azalış göstermesi ile oluşur. Zaman serisi grafiğine bakılarak veri setinin trendde sahip olup olmadığına karar vermek mümkündür.

**Mevsimsel dalgalanma:** Sabit bir periyod ile dalgalanma sergileyen zaman serileri mevsimsel ya da periyodik seri olarak adlandırılır. Mevsimsel dalgalanmanın uzunluğu periyod uzunluğu (s) olarak ifade edilir ve genellikle oniki ay, altı ay, üç ay, bir ay, bir hafta, bir gün ve bir saat gibi dönemleri kapsayabilir. Yine zaman serisi grafiğine bakılarak veri setinin mevsimsel bileşene sahip olup olmadığına karar verilebilmektedir.

**Döngüsel (konjonktürel) dalgalanma:** Mevsimsel dalgalanmaya benzer şekilde hareket sergileyen fakat sabit bir periyoda sahip olmayan bu seriler genellikle 5-10 yılda bir tekrarlanırlar.

**Düzensiz (tesadüfi) hareketler:** Serinin hareketi trend, mevsimsellik ya da döngüsel dalgalanma olarak ifade edilemiyor yani belirli bir yapıya uymuyor ve dolayısıyla modellenemiyorsa bu tür seriler düzensiz (tesadüfi) hareketler olarak adlandırılır. Düzensiz hareketler sergileyen bir seri açıklanamadığından bu tür serilerin öngörüsünü yapmak mümkün değildir. Doğal felaketler, önceden kestirilemeyen artışlar ve azalışlar düzensiz hareketleri oluşturur.

### 2.1. Olasılığa Dayalı Yöntemler

#### 2.1.1. Otoregresif Bütünleşik Hareketli Ortalamalar-ARIMA

Zaman serilerinde en yaygın kullanılan yöntemlerden birisi ARIMA modelidir (Box ve Jenkins, 1970). ARIMA otoregresif (AR(p)) ve hareketli ortalama (MA(q)) modellerinin birleşiminden oluşmaktadır. AR(p) modeli zaman değişkeninin herhangi bir dönemdeki değerinin, söz konusu dönemdeki hata terimi ile p sayıda geçmiş dönem değerlerinin bir fonksiyonu olarak ifade edilmektedir. MA(q) modeli ise zaman değişkeninin herhangi bir dönemdeki değerinin, o dönemdeki hata terimi ve q sayıda geçmiş dönem hata terimlerinin bir fonksiyonu olarak ifade edilmektedir. Yöntem

durağan olmayan serilerin durağanlaştırılması için fark alma işlemini de içermektedir.  $d$  sayıda fark alındıktan sonra durağan olan otoregresif bütünleşik hareketli ortalamalar modeli ARIMA( $p,d,q$ ) ile ifade edilir. AR( $p$ ), MA( $q$ ) ve ARIMA( $p,d,q$ ) modelleri kapalı biçimi sırasıyla eşitlik 2.1. ve eşitlik 2.2. eşitlik 2.3. de gösterilmektedir.

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) y_t = c + \varepsilon_t \quad (2.1)$$

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \varepsilon_t \quad (2.2)$$

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - L)^d y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \varepsilon_t \quad (2.3)$$

Burada  $y_t$ :  $t$  anındaki gözlem değerini,  $c$ : Sabit terimi,  $\varepsilon_t$ :  $t$  anındaki hata terimini,  $\phi_1, \phi_2, \dots, \phi_p$ : AR modelinin parametrelerini,  $\theta_1, \theta_2, \dots, \theta_q$ : MA modelinin parametrelerini,  $Ly_t = y_{t-1}$ ,  $L^2 y_t = y_{t-2}$ ,  $L^p y_t = y_{t-p}$ ,  $L^q y_t = y_{t-q}$  göstermektedir.

Mevsimsel otoregresif bütünleşik hareketli ortalamalar yöntemi ise hem otoregresif hem de hareketli ortalamaların mevsimsel etkilerinin de dahil edildiği model  $SARIMA(p, d, q)(P, D, Q)_s$  olarak ifade edilmektedir. Burada  $p$  otoregresif (AR) modelinin derecesi,  $d$  fark alma işlem sayısı,  $q$  hareketli ortalama (MA) modelinin derecesi,  $P$  mevsimsel otoregresif (SAR) modelinin derecesi,  $D$  mevsimsel fark alma işlem sayısı,  $Q$  mevsimsel hareketli ortalama (SMA) modelinin derecesi,  $s$ : periyodu göstermektedir.  $SARIMA(1,1,1)(1,1,1)_s$  modeli eşitlik 2.4 gösterilmektedir.

$$(1 - \phi_1 L)(1 - \Phi_s L^s)(1 - L)(1 - L^s) y_t = c + (1 + \theta_1 L)(1 + \Theta_s L^s) \varepsilon_t \quad (2.4)$$

Burada  $\Phi_s$ : SAR(1) modelinin parametresini,  $\Theta_s$ : SMA(1) modelinin parametresini göstermektedir.

Fark alma işlemi Box-Jenkins yöntemlerinin varsayımlarından birisi olan durağan olma koşulu sağlanmadığı durumda seriyi durağanlaştırmak amacıyla kullanılır.

ARIMA yönteminin model belirleme, parametre ve hata terimin kontrolü ve öngörü hesabı olmak üzere 4 aşamadan oluştuğunu söyleyebiliriz.

- Model belirleme

Box-Jenkins yöntemleri ile zaman serisi analizinde ilk aşama modelin belirlenmesidir. ARIMA kullanılacaksa  $p, d$  ve  $q$  değerlerinin ne olacağı, mevsimsel dalgalanma varsa (SARIMA) bu değerlere ek olarak  $s, P, D$  ve  $Q$  değerlerinin ne olacağı belirlenmelidir. Bu değerleri belirlemede kesin bir yol bulunmamakla birlikte seriye ait otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) grafiklerinden

faaydalanılabılır. Bu da deneyim ve uzman bilgisi gerektirmektedir. Bu aşamada önemli olan diđer bir unsur ise mümkün olan en basit model ile bir sonraki aşamaya geçmektir. Modele ait derecelerin artması parametre sayısını artırmakta, işlem süresi uzatmakta ve aşırı uyum (overfitting) sorununu da beraberinde getirmektedir.

- Parametre (katsayı) tahmini ve anlamlılığı

Aday model belirlendikten sonra model katsayıları en çok olabirlik fonksiyonu yardımıyla veya hataların kareleri toplamının minimize edilmesi ile belirlenebilmektedir. Bunlar dışında parametre tahmini için literatürde farklı yöntemler de mevcut olmasına rağmen bu yöntemler karmaşık çözümler gerektirdiğinden yaygın kullanım alanı bulamamıştır. Model katsayıları belirlendikten sonra bu katsayıların anlamlılığı t-testi ile yapılmaktadır.

- Hata terimi (Akgürültü)

Parametre tahminleri yapıldıktan sonra bu parametreler yardımıyla tahmin serisi oluşturulur ve orijinal seri ile farkları alınarak hata serisi elde edilir. Yukarıda bahsi geçen modellerde hata terimlerinin sıfır ortalamalı, sabit varyanslı, birbirleriyle ilişkisiz ve normal dağılımlı akgürültü serisi ( $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ ) olduğu varsayılmaktadır. Hata serisinin akgürültü olup olmadığını anlamak için artıkların ACF ve PACF grafiğı yol göstereceğidir. Ayrıca Box- Ljung ve Portmanteau testleri de hata serisinin akgürültü olup olmadığını tespit etmek amacıyla kullanılmaktadır (Kadılar, 2020)

Box- Jenkins yöntemlerinde birden fazla model seri için uygun bulunabilir. Yani oluşturulan modellerdeki tüm katsayılar anlamlı ve hatalar akgürültü serisi oluşturabilir. Bu durumda en uygun modele karar vermek için Akaike Bilgi Kriteri (Akaike Information Criteria-AIC) ve Bayesci Bilgi Kriteri (Bayesian Information Criteria-BIC)'nde yararlanılabilir. Bu kriterler hata kareler toplamı ve modeldeki parametre sayılarına bağılı olarak sırasıyla eşitlik 2.5 ve eşitlik 2.6 ile hesaplanmaktadır.

$$AIC = n \ln(\sigma_\varepsilon^2) + 2m \quad (2.5)$$

$$BIC = n \ln(\sigma_\varepsilon^2) + m \ln(n) \quad (2.6)$$

$n$ : Gözlem sayısı,  $m$ : Toplam parametre sayısı

AIC ve BIC için en uygun değer mümkün olan en küçük değerlerdir. Bu kriterler uygun model seçiminde kullanılabilir (Kutlar, 2007).

- Öngörü

Son aşamada uygun model kullanılarak öngörü değerleri hesaplanır. Öngörü değerleri ile gerçek değerlerin grafiği çizilerek uyumlu olup olmadıkları kontrol edilir. Modelin test kümesindeki performansının yeterli olup olmadığına bu aşamada karar verilebilir.

Çalışmada uygun modelin belirlenmesi için çok sayıda alternatif denenmiştir. En uygun modele karar verebilmek için en yaygın kullanılan iki bilgi kriteri AIC ve BIC'den yararlanılmıştır. Bu kriterlerin göstermiş olduğu modeller ile öngörüler yapılmış ve performansı en yüksek model nihai model olarak seçilmiştir.

### 2.1.2. Üstel Düzleştirme Yöntemleri

Verideki değişim ve sıçramalar ile birlikte trend ve mevsimselliği de dikkate alarak tahmin yapan üstel düzleştirme yöntemlerinin yaygın olarak kullanıldığı üç varyasyonu vardır. Bunlar Basit Üstel Düzleştirme yöntemi (Brown, 1959), Holt üstel düzleştirme yöntemi (Holt, 1957) ve Holt-Winters üstel düzleştirme yöntemi (Winters, 1960) olarak adlandırılmıştır. Basit üstel düzleştirme yöntemi; veri seti sadece bir ortalama etrafında hareket sergiliyor ise yani trend ve mevsimsellik bileşenine sahip olmadığı durumlarda kullanılan bir yöntemdir. Holt üstel düzleştirme yöntemi; veri seti uzun süreli bir artış veya azalış sergiliyor ise yani trend bileşenine sahip fakat mevsimsel bileşenin olmadığı durumlarda kullanılan bir yöntemdir. Holt Winters üstel düzleştirme yöntemi ise veri seti trende ve mevsimselliğe sahip, bazen de sadece mevsimsel bileşene sahip olduğu durumlarda kullanılır.

Basit üstel düzleştirme yönteminde öngörüler eşitlik 2.7 kullanılarak elde edilir.

$$S_t = \alpha y_t + (1 - \alpha)S_{t-1} \quad (2.7)$$

Burada  $\alpha$ : (0,1) aralığında ortalama düzleştirme parametresi,  $y_t$ : t. gözlem değeri,  $S_t$ : t. dönem öngörü değerini göstermektedir.  $S_0$  başlangıç değeri için genellikle serinin ilk değeri alınmaktadır.  $\alpha$  düzleştirme parametresi ise tahmin hatasını minimum yapan sabit bir değerdir.

Zaman serisi trendde sahipse basit üstel düzleştirme yöntemi için kullanılan denklem tek başına yetersiz kalmaktadır. Trend etkisini de dikkate alan, Holt üstel düzleştirme yöntemi ile öngörü hesaplayabilmek için eşitlik 2.8 ve eşitlik 2.9 da gösterilen formüllerden faydalanılır.  $a$  dönem ilerisi için öngörü değeri ise eşitlik 2.10 kullanılarak hesaplanır.

$$S_t = \alpha y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.8)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.9)$$

$$F_{t+m} = S_t + ab_t \quad (2.10)$$

Burada  $\alpha$ : (0,1) aralığında ortalama düzleştirme parametresini  $\gamma$ : (0,1) aralığında trend düzleştirme parametresini ve  $y_t$ :  $t$ . gözlem değerini ifade etmektedir. Başlangıç değerleri olan  $S_0$  ve  $b_0$  için genellikle basit regresyon analizi ile elde edilen modelin katsayıları kullanılmaktadır. Şöyle ki model de bulunan sabit terim  $S_0$ 'ı, regresyon katsayısı ise  $b_0$ 'ı göstermektedir.

Zaman serisi hem trend hem de mevsimsel hareketler sergiliyorsa bu durumda Holt üstel düzleştirme yöntemi de yetersiz kalmaktadır. Mevsimsel etkiyi de dikkate alan Holt Winters üstel düzleştirme yönteminin toplamsal ve çarpımsal olmak üzere iki farklı şekilde öngörü modeli vardır (Makridakis vd., 1998). Toplamsal model de mevsimsel dalgalanmalar bir trendde sahip olduğunda kullanılabilirken çarpımsal model ise seride mevsimsel etkinin trendde göre azalış ya da artış gösterdiği durumlarda kullanılabilir. Fakat bazı durumlarda hangi modelin kullanılacağına görsel olarak karar vermek zor olabilmektedir. Bu durumda iki model ile öngörüler elde edildikten sonra performans karşılaştırması yapılması daha doğru olacaktır.

Toplamsal model ile öngörü hesaplayabilmek için eşitlik 2.11, eşitlik 2.12 ve eşitlik 2.13 formüllerinde faydalanılır.  $a$  dönem ilerisi için öngörü değeri ise eşitlik 2.14 kullanılarak hesaplanır.

$$S_t = \alpha(y_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.11)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.12)$$

$$I_t = \beta(y_t - S_t) + (1 - \beta)I_{t-s} \quad (2.13)$$

$$F_{t+m} = (S_t + ab_t) + I_{t-s+(m-1)mod(s)+1} \quad (2.14)$$

Çarpımsal model ile öngörü hesaplayabilmek için eşitlik 2.15, eşitlik 2.16 ve eşitlik 2.17 formüllerinde faydalanılır.  $m$  dönem ilerisi için öngörü değeri ise eşitlik 2.18 kullanılarak hesaplanır.

$$S_t = \alpha \frac{y_t}{I_t - s} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.15)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.16)$$

$$I_t = \beta \frac{y_t}{S_t} + (1 - \beta)I_{t-s} \quad (2.17)$$

$$F_{t+m} = (S_t + mb_t) I_{t-s+(m-1)mod(s)+1} \quad (2.18)$$

Burada  $\alpha$ : (0,1) aralığında ortalama düzleştirme parametresini  $\gamma$ : (0,1) aralığında trend düzleştirme parametresini  $\beta$ : (0,1) aralığında mevsimsel düzleştirme parametresini,  $I_t$ : mevsimsel düzleştirme faktörünü,  $s$ : mevsimsel uzunluğu (periyodu) ve  $y_t$ :  $t$ . gözlem değerini ifade etmektedir. Başlangıç değerleri olan  $S_0$  ve  $b_0$  için Holt üstel düzleştirme yönteminde olduğu gibi basit regresyon analizi ile elde edilen modelin katsayıları kullanılmaktadır. Mevsimsel düzleştirme faktörüne ait başlangıç değerleri olan  $I_1, I_2, \dots, I_s$  ise ilgili dönemdeki gözlem değerleri göz önünde bulundurularak eşitlik 2.19 ve eşitlik 2.20'de verilen formül ile hesaplanmaktadır. Burada dikkat edilmesi gereken önemli bir nokta ilk periyod kadar gözlemin öngörü hesabının mümkün olmamasıdır.

$$C_m = \frac{\sum_{t=(m-1)s+1}^{ms} y_t}{s}, \quad m = 1, 2, \dots, n/s \quad (2.19)$$

$$I_k = \sum_{i=1}^m \frac{y_{(i-1)s+k}}{n/s}, \quad k = 1, 2, \dots, s \quad (2.20)$$

Burada  $n$ : gözlem sayısını,  $s$ : periyodu ve  $C$ : periyod kadar gözlem değerine sahip her bir dönemin gözlem değerleri ortalamasını ifade etmektedir.

### 2.1.2.1. Diferansiyel Gelişim Algoritması

Günümüzde pek çok yapay zeka tekniği optimizasyon problemlerini çözmede önemli başarılar sağlamaktadır. Bunlardan biriside diferansiyel gelişim algoritmasıdır.

Ken Price ve Rainer Storn diferansiyel gelişim algoritmasını (DGA) bir dizi makale ile tanıtmıştır (Storn ve Price, 1995, 1996, 1997a, 1997b; Storn, 1996; Chakraborty, 2008). DGA özellikle sürekli optimizasyon problemlerinin çözümünde kullanılan basit fakat güçlü, popülasyon tabanlı sezgisel bir algoritmadır (Karaboğa, 2007). İşleyiş ve operatörleri ile genetik algoritmaya benzeyen DGA, genetik algoritmadan farklı olarak operatörler popülasyonun tamamına değil kromozomlara tek tek uygulanmaktadır (Keskintürk, 2006). DGA'da araştırmacı tarafından belirlenmesi gereken 4 kontrol parametresi bulunmaktadır. Bunlar, kromozom sayısı ( $ks$ ), ölçekleme faktörü ( $F$ ), çaprazlama oranı ( $Co$ ) ve iterasyon sayısıdır. Ölçekleme faktörü genellikle 0-2 aralığında seçilmektedir. DGA'nın adımları aşağıda açıklanmaktadır.

**Adım 1.** Başlangıç popülasyonunun oluşturulması ve uygunluk değerinin hesaplanması: İlk olarak başlangıç popülasyonu oluşturulur ve popülasyonda bulunan bütün kromozomların uygunluk değerleri amaç fonksiyonu yardımı ile hesaplanır. Böylelikle her kromozom bir uygunluk değeri ile temsil edilmiş olur.

**Adım 2.** Mutasyon işlemi: Bu işlem için popülasyonda en az 4 kromozom bulunması gerekir. Bunlardan birincisi hedef kromozom olarak isimlendirilen mutasyona tabi tutulacak kromozom, diğer 3 kromozom ise popülasyondan rasgele seçilen ve hedef kromozoma alternatif bir aday kromozom elde etmek için kullanılacak kromozomlardır. Seçilen üç kromozomdan ilk ikisinin farkı alınarak ölçekleme faktörü ( $F$ ) ile çarpılır ve üçüncü kromozom ile toplanır. Bu işlem ile çaprazlama işlemine tabi tutulacak farklı bir kromozom elde edilmiş olur.

**Adım 3.** Çaprazlama işlemi: Mutasyon işlemi sonucunda oluşan kromozomun her bir geni hedef kromozoma karşılık gelen gen ile çaprazlama işlemine tabi tutulur. Çaprazlama sonunda oluşan gen aday kromozom olarak isimlendirilir. Çaprazlama işlemi 0 ile 1 aralığından rasgele türetilen sayının çaprazlama oranı ( $co$ ) ile karşılaştırılmasına dayanır. Türetilen sayı çaprazlama oranından küçükse mutasyonlu

kromozomda bulunan gen, büyükse hedef kromozomda bulunan gen aday kromozomda yer alır.

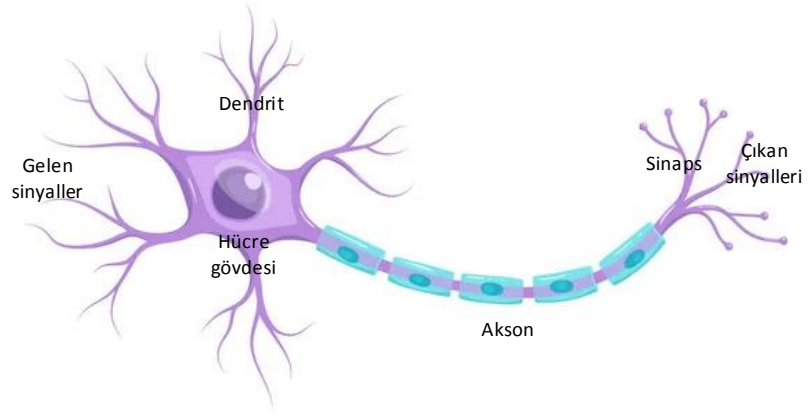
**Adım 4.** Seçim işlemi: Bir sonraki nesilde (popülasyonda) hedef kromozomun bulunmaya devam mı edeceğine yoksa yerine çaprazlama sonrası oluşan aday kromozomun mu seçileceğine bu adımda karar verilir. Seçme işlemi uygunluk değerleri karşılaştırılmasına dayanır. Aday kromozomdan hesaplanan uygunluk değeri hedef kromozomun uygunluk değeri ile karşılaştırılır. Hangisinin uygunluk değeri yüksek ise bir sonraki nesilde o kromozom yer alır.

**Adım 5.** Algoritmanın durdurulması: Popülasyonda bulunan bütün kromozomlara Adım 2-4 arası uygulanır ve yeni popülasyon oluşturulur. İterasyon sayısı arttıkça oluşturulan her yeni popülasyondaki kromozomların uygunluk değerleri artacaktır. Bu işlemler araştırmacının belirlemiş olduğu durdurma kriteri sağlanana kadar devam etmektedir.

## **2.2. Öğrenmeye Dayalı Yöntemler**

### **2.2.1. Yapay Sinir Ağları-YSA**

Yapay sinir ağları (YSA) insan beyninin en önemli özelliği olan öğrenme ile, sınıflama, genelleme ve analiz etme gibi kabiliyetlerinden esinlenerek ortaya çıkan bilgisayar yazılımlarıdır. Herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bu yazılımlar yeni bilgiler üretmek için beyindeki sinir ağlarını ve nöronları taklit etmiştir. Yapay bir sinir hücresi modeli ilk olarak 1943 yılında McCulloch ve Pitts tarafından oluşturulmuştur. Yapay bir nöron; girdilere bağlı ağırlıklar (Sinaps), birleştirme fonksiyonu (Dendrit), aktivasyon fonksiyonu (Hücre gövdesi) ve çıktı (Akson)'dan oluşmaktadır. Şekil 2.1'de biyolojik sinir hücresinin yapısı gösterilmektedir.



Şekil 2.1. Biyolojik sinir hücresinin yapısı

1958 yılında Rosenblatt tarafından tek katmanlı-basit algılayıcı (perceptron) modelinin önerilmesi ve 1960 da Widrow ve Hoff tarafından ADALINE (Adaptive Linear Neuron) öğrenme kuralının geliştirilmesiyle birlikte yapay sinir ağları ile ilgili çalışmalar hız kazanmıştır. Basit algılayıcılar günümüzde en çok kullanılan çok katmanlı algılayıcıların temelini oluşturmaktadır (Eğrioğlu vd., 2020). 1969 yılında Minsky ve Papert basit algılayıcı modelinin XOR probleminin çözümünde yetersiz olduğunu ispatlamıştır. Bu durum yapay sinir ağlarının popülerliğini düşürmüş ve alanda yapılan çalışmaları durma noktasına getirmiştir. 1980'li yıllarda denetimsiz öğrenme mantığının (Kohonen, 1982) geliştirilmesi ve geri yayılım algoritmasının çok katmanlı algılayıcılarda kullanılması (Rumelhart vd., 1986) ile yapay sinir ağlarındaki çalışmalar tekrardan hız kazanmıştır (Yılmaz, 2020).

YSA'nın doğrusal olmayan yapıları modellemesi, öğrenme tabanlı olması, genelleme yeteneği ve uyarlanabilir olması, hata toleransına sahip olması sebebiyle sağlık, mühendislik, işletme vb. bir çok alanda kullanılmaktadır. Tablo 2.1'de YSA'nın önemli özellikleri ve açıklamaları gösterilmektedir.


Tablo 2.1. YSA'nın önemli özellikleri (Hamzaçebi, 2021)

Özellik	Açıklama
Doğrusal olmama	Bir çok problem doğrusal olmayan yapıya sahiptir. YSA aktivasyon fonksiyonu sayesinde doğrusal modellerin yanı sıra doğrusal olmayan yapıları da modelleme özelliğine sahiptir.
Öğrenme	YSA öğrenme özelliği sayesinde değişkenler arasındaki saklı ilişkiyi modelleyebilir. Nöronlar arasında bulunan bağlantı ağırlıklarının belirlenmesi öğrenme olarak isimlendirilir.
Genelleme	Genelleme özelliği ile hiç görmediği girdiler için anlamlı çıktılar üretebilir. YSA'nın bu özelliği sayesinde tahmin ve örüntü tanıma gibi birçok alanda minimum hata ile başarılı sonuçlar elde edilmektedir.
Uyarlanabilirlik	Belirli bir problemi çözmek için eğitilen YSA, farklı bir problem için uyarlanabilir ve tekrardan eğitilebilir.
Hata toleransı	Gürültülü verilerin etkisi, hatanın geriye yayılımı sayesinde ağırlıklara dağıtılarak sonuç üzerindeki etkisi azaltılır. Bu yüzden diğer yöntemlere göre YSA'nın hata toleransı yüksektir.

Ara katmanın bulunmadığı ve tek nöronun olduğu yapay sinir ağı mimarisi tek katmanlı algılayıcı, en az bir ara katmana sahip çok nöronlu ağ mimarisi ise çok katmanlı algılayıcı olarak isimlendirilmektedir.

### 2.2.1.1. Tek Katmanlı Algılayıcılar

Tek katmanlı ağ mimarisi girdi katmanı ve çıktı katmanı olmak üzere iki katmandan ve bir nörondan oluşmaktadır. Şekil 2.2'de tek katmanlı yapay bir sinir hücresinin yapısı gösterilmektedir.




Şekil 2.2. Tek katmanlı yapay sinir hücresinin yapısı

Tek katmanlı bir yapay sinir hücresi girdi, birleştirme (toplama) fonksiyonu, aktivasyon fonksiyonu ve çıktıdan oluşmaktadır. Girdiler ağırlıklar ile çarpılıp birleştirme fonksiyonu olan toplama fonksiyonu aracılığıyla toplanarak net girdi elde edilir. Net girdi aktivasyon fonksiyonu işlemine tabi tutularak çıktı elde edilir. Tek katmanlı algılayıcılar kullanılarak sadece doğrusal problemlerin çözümü mümkündür. Burada birleştirme fonksiyonu toplamsal ve aktivasyon fonksiyonu olarak eşik ve doğrusal fonksiyon kullanılmaktadır. Aktivasyon fonksiyonu olarak eşik fonksiyonun kullanıldığı model basit algılayıcı, doğrusal fonksiyonun kullanıldığı model ADALİNE modeli olarak bilinir.

### 2.2.1.2. Çok Katmanlı Algılayıcılar

Çok katmanlı algılayıcıların bulunması yapay sinir ağlarının tarihsel gelişiminde çok önemli bir adım olmuştur. Tek katmanlı algılayıcılarla çözülemeyen XOR problemi yapay sinir ağlarında duraklamaya yol açmıştı. Çok katmanlı algılayıcıların bu problemi ortadan kaldırmasıyla YSA'na olan ilgi tekrardan alevlenmiştir. YSA'nın çözemediği iddia edilen bir çok tezler çok katmanlı algılayıcıların geliştirilmesiyle çürütülmüştür. (Öztemel, 2022)

Çok katmanlı algılayıcılarda ağ mimarisi girdi katmanı, ara katman (gizli katman) ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Ara katman sayısı ve katmanlardaki nöron sayısı veri setine göre değişkenlik göstermektedir. Zaman serilerinde genellikle en fazla iki ara katmanla tahmin yapılması önerilir. Derin öğrenmede bu sayının arttığı gözlenmektedir. Şekil 2.3'de 4 nöronlu 1 ara katman ile 3 girdi ve 1 çıktıya sahip çok katmanlı ağ mimarisi gösterilmektedir.



Şekil 2.3. Çok katmanlı Ağ Mimarisi

Çok katmanlı ağların bileşenleri aşağıda verilmiştir (Hamzaçebi, 2011).

- Girdi katmanı, ara katman ve çıkış katmanı

Her katmandaki nöronun bir sonraki katmandaki tüm nöronlar ile bağlantısı vardır. Girdi katmanından alınan girdi değişkenler, girdi katmanı ile ara katman arasında bulunan bağlantı ağırlıkları ile çarpılarak, birleştirme ve aktivasyon fonksiyonu yardımıyla ara katmana giren ve çıkan değerler hesaplanır. Aynı şekilde ara katman ile çıktı katmanı arasındaki bağlantı ağırlıkları kullanılarak çıktı katmanına giren ve çıkan değerler hesaplanarak çıktı elde edilir.

- Birleştirme fonksiyonu

Yapay sinir hücresine gelen tüm girdilerin ağırlıklar ile çarpıldıktan sonra birleştirme fonksiyonun türüne göre *net* girdinin hesaplanmasıdır. En çok kullanılan birleştirme fonksiyonu toplama fonksiyonudur. Tablo 2.2’de birleştirme fonksiyonları gösterilmiştir.

Tablo 2.2. YSA'da kullanılan birleştirme fonksiyonları

Birleştirme Fonksiyonu	Hesaplama Formülü	Açıklama
Toplama Fonksiyonu	$net = \sum_{i=1}^n x_i w_i$	Ağırlık değerleri girdiler ile çarpıldıktan sonra toplanarak net girdi hesaplanır.
Çarpım Fonksiyonu	$net = \prod_{i=1}^n x_i w_i$	Ağırlık değerleri girdiler ile çarpıldıktan sonra birbirleriyle çarpılarak net girdi hesaplanır.
Maksimum Fonksiyonu	$net = \text{enb}(x_i w_i)$	Ağırlık değerleri girdiler ile çarpıldıktan sonra en büyük değer net girdi olarak alınır.
Minimum Fonksiyonu	$net = \text{enk}(x_i w_i)$	Ağırlık değerleri girdiler ile çarpıldıktan sonra en küçük değer net girdi olarak alınır.
Çoğunluk Fonksiyonu	$net = \sum_{i=1}^n \text{sgn}(x_i w_i)$	Ağırlık değerleri girdiler ile çarpıldıktan sonra işaretlerine (+, -) göre sınıflandırılır. Büyük olan sayı net girdi olarak alınır.
Kümülatif Fonksiyonu	$net = \text{net}(\text{eski}) + \sum_{i=1}^n x_i w_i$	Ağırlık değerleri girdiler ile çarpıldıktan sonra daha önce hücreye gelen net değerlere eklenerek net girdi hesaplanır.

- Aktivasyon fonksiyonu

Aktivasyon fonksiyonu bir sinir hücresinde biriken sinyallerin aktarım şeklini ifade etmektedir. Birleştirme fonksiyonundan gelen  $net$  değerler aktivasyon fonksiyonu aracılığıyla çıktıya dönüştürülür. Tablo 2.3'de en çok kullanılan aktivasyon fonksiyonları gösterilmektedir.

Tablo 2.3. YSA'da en çok kullanılan aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Fonksiyon Grafiği	Açıklama
<p>Doğrusal Fonksiyon</p> $f(net) = net$	<p>Doğrusal Fonksiyon</p>	<p>Gelen net girdi doğrudan çıktı olarak iletilir.</p>
<p>Basamak Fonksiyonu</p> $f(net) = \begin{cases} 1 & net \geq E \\ 0 & net < E \end{cases}$	<p>Basamak Fonksiyonu</p>	<p>Gelen net girdi belirlenen bir eşik değeri (E)'ne göre 1 veya 0 değerini alır.</p>
<p>Lojistik Sigmoid Fonksiyonu</p> $f(net) = \frac{1}{1 + e^{-net}}$	<p>Lojistik Sigmoid Fonksiyonu</p>	<p>Gelen net girdi 0 ile 1 aralığında çıktıya dönüştürülür.</p>
<p>Hiperbolik Tanjant Fonksiyonu</p> $f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}}$	<p>Hiperbolik Tanjant Fonksiyonu</p>	<p>Gelen net girdi -1 ile 1 aralığında çıktıya dönüştürülür.</p>

- Hata fonksiyonu

Yapay sinir ağlarında öğrenmenin gerçekleşebilmesi için gözlem değerleri ile tahmin edilen değerler arasındaki farkın minimum olması istenmektedir. Bunun için literatürde en çok hata kareler toplamı, hata kareler ortalaması veya hata kareler ortalamasının karekökü kullanılmaktadır.

- Öğrenme

Denetimsiz (öğretmensiz) ve denetimli (öğretmenli) öğrenme olarak 2 şekilde sınıflandırılabilir. Denetimsiz öğrenmede ağın girdileri sisteme gösterilir. Değişkenler arasındaki ilişkilerin sistem tarafından öğrenmesi beklenir. Genellikle sınıflandırma problemlerinde kullanılır. Denetimli öğrenmede hem girdiler hemde girdilere karşılık gelen çıktılar ağa gösterilerek sistemin öğrenmesi sağlanır. Genellikle zaman serilerinde öngörü işlemi için kullanılır. Çok katmanlı algılayıcılar denetimli öğrenme stratejisine göre çalışırlar (Öztemel, 2020).

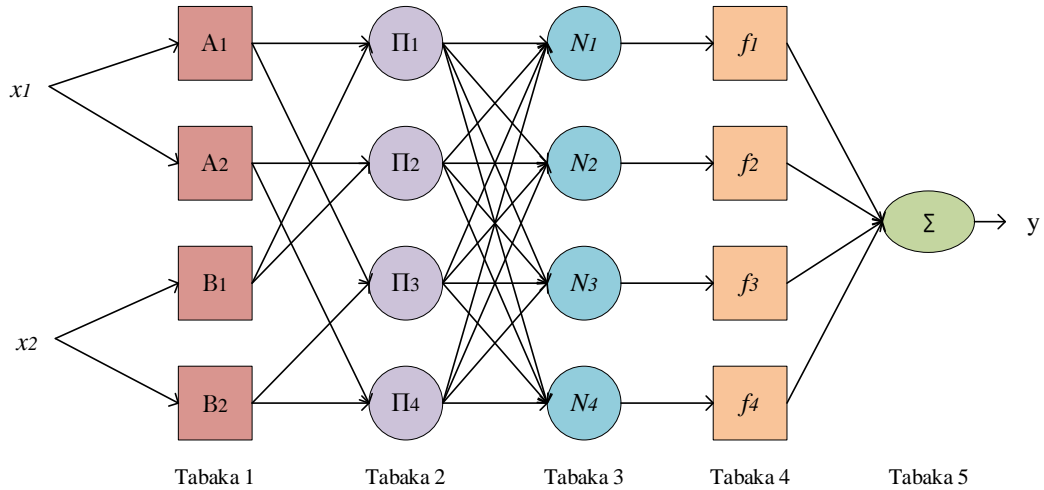
Çok katmanlı algılayıcılar öğrenmede ileri beslemeli geri yayılım algoritması kullanırlar. İleri beslemeli geri yayılım algoritması genelleştirilmiş delta öğrenme kuralına göre çalışırlar. İleri doğru hesaplama yapılarak ağın çıktısı hesaplanır ve üretilen çıktı hedef çıktı ile karşılaştırılarak hata hesaplanır. Elde edilen hata ağırlık değerlerine dağıtılarak her bir iterasyonda hatanın azaltılması sağlanır. Geri yayılım algoritmasının en büyük dezavantajı çok sayıda iterasyon gerektirmesi ve yavaş yakınsamasıdır (Eğrioğlu, 2020).

Çok katmanlı algılayıcı eğitiminde genellikle Levenberg- Marquardt (1963) algoritması kullanılır. Bu algoritmanın geriye yayılım algoritmasından farkı her bir çıktı için ayrı ayrı ağırlık güncellemesi yapmamakta bunun yerine toplam hata bulunduktan sonra bu hata geriye doğru yayılarak ağırlıklar güncellenmektedir. Bu sebeple Levenberg-Marquardt algoritması oldukça hızlı bir öğrenme algoritmasıdır. Birçok durumda diğer algoritmalara göre daha az HKO elde edilmesini sağlamaktadır. Ancak ağ yapısı büyüdükçe algoritmanın başarısı azalmaktadır (Hamzaçebi, 2011).

### **2.2.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi-ANFİS**

Jang (1993) tarafından önerilen Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi-Adaptive Network-Based Fuzzy İnference System (ANFİS), yapay sinir ağlarının eğitim yoluyla öğrenme becerisi ile eş zamanlı hesaplayabilme kabiliyetlerini

bulanık mantığın çıkarım özelliği ile birleştiren melez bir yapay zekâ yöntemidir. ANFİS'in uyarılana bilirliliği, bulanık sistem modeline sunulan veriler yardımıyla iletilen bilgileri kullanarak problemi öğrenmesi ve kendisini güncelleyebilmesinden gelmektedir. Sistem öğrenme yeteneği ile kendini probleme adapte ederek çözümü zor ve doğrusal olmayan problemlerde iyi sonuçlar verebilmektedir (Yılmaz, 2020). ANFİS yönteminde geri yayılım öğrenme algoritması ya da onun en küçük kareler yöntemi ile birlikte kullanıldığı hibrit öğrenme algoritmasıyla eğitim gerçekleşmekte ve parametreler tahmin edilmektedir. Bunların dışında yapay zekâ optimizasyon algoritmaları ile de ANFİS parametrelerinin optimize edilmesi mümkündür (Eğrioğlu ve Baş, 2021). Şekil 2.4'de yapısında 2 girdi ve 1 çıktı bulunan, girdiler için sırasıyla  $A_1, A_2, B_1, B_2$  bulanık kümeleri ve 4 kuralın tanımlandığı örnek bir ANFİS mimari yapı gösterilmektedir. Kare şekilleri içerisinde parametre bulunan fonksiyonlardır.



Şekil 2.4. ANFİS için örnek bir mimari

Şekil 2.4'de görüldüğü gibi ANFİS, girdi ve çıktı tabakası dışında 5 tabakadan oluşmaktadır ve bu tabakalar aşağıda tanımlanmaktadır.

**Tabaka 1:** Girdi değişkenlerinin bulanıklaştırıldığı tabakadır. Bulanıklaştırma işlemi bulanık kümelere ait üyelik fonksiyonları ile gerçekleştirilir. Tablo 2.4'de girdi üyelik fonksiyonları ve grafikleri gösterilmiştir.

Tablo 2.4. Girdi üyelik fonksiyonları ve grafikleri

Üyelik Fonksiyonu Tipi	Fonksiyon	Grafik
<p>Gauss</p> <hr/> <p>Parametreler</p> <p><math>c, \sigma</math></p>	$\mu = e^{-\frac{1}{2}(\frac{x-c}{\sigma})^2}$	
<p>Üçgen</p> <hr/> <p>Parametreler</p> <p><math>a, b, c</math></p>	$\mu = \begin{cases} (x-a)/(b-a), & a \leq x \leq b \\ (c-x)/(c-b), & b \leq x \leq c \\ 0, & d.d \end{cases}$	
<p>Yamuk</p> <hr/> <p>Parametreler</p> <p><math>a, b, c, d</math></p>	$\mu = \begin{cases} (x-a)/(b-a), & a \leq x \leq b \\ 1, & b \leq x \leq c \\ (d-x)/(d-c), & c \leq x \leq d \\ 0, & d.d \end{cases}$	
<p>İki sigmoid fonksiyon farkı</p> <hr/> <p>Parametreler</p> <p><math>a_1, c_1, a_2, c_2</math></p>	$\mu = \frac{1}{1 + e^{-a_1(x-c_1)}} - \frac{1}{1 + e^{-a_2(x-c_2)}}$	
<p>Genelleştirilmiş çan biçimli</p> <hr/> <p>Parametreler</p> <p><math>a, b, c</math></p>	$\mu = \frac{1}{1 + \left \frac{x-c}{a}\right ^{2b}}$	

Tablo 2.4. (devam)

Pi tipi	$\mu = \begin{cases} 1 - 2(x - a/b - a)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2(x - b/b - a)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - 2(x - c/d - c)^2, & c \leq x \leq \frac{c+d}{2} \\ 2(x - d/d - c)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & d.d \end{cases}$	
Parametreler		
$a, b, c, d$		
İki sigmoid fonksiyon çarpımı	$\mu = \frac{1}{1 + e^{-a_1(x-c_1)}} \cdot \frac{1}{1 + e^{-a_2(x-c_2)}}$	
Parametreler		
$a_1, c_1, a_2, c_2$		
Gauss kombinasyon	$\mu = \begin{cases} e^{-\frac{1}{2}(\frac{x-c_1}{\sigma_1})^2}, & x \leq c_1 \\ 1 - e^{-\frac{1}{2}(\frac{x-c_2}{\sigma_2})^2}, & x \leq c_2 \end{cases}$	
Parametreler		
$\sigma_1, c_1, \sigma_2, c_2$		

Birinci tabakadaki düğüm sayısı toplam üyelik fonksiyonu sayısına eşittir. Tabakanın çıktısı üyelik fonksiyonundan elde edilen üyelik dereceleridir. Şekil 2.3'te verilen mimari yapıda  $\mu_{A_1}(x_1), \mu_{A_2}(x_1), \mu_{B_1}(x_2)$  ve  $\mu_{B_2}(x_2)$  olmak üzere 4 üyelik derecesi vardır.

**Tabaka 2:** Kuralların oluşturulduğu tabakadır. Tabakada bulunan düğüm sayısı kural sayısına eşittir. Tabakanın çıktısı düğümlerden gelen üyelik derecelerinin çarpılmasıyla hesaplanır. İkinci tabakanın girdisi üyelik dereceleri çıktısı ise ilgili kuralın gücü diğer bir ifade ile ateşleme seviyesini göstermektedir. i. kural gücü  $\mu_i$  olmak üzere eşitlik 2.21 ile hesaplanır.

$$\mu_1 = \mu_{A_1}(x_1) \cdot \mu_{B_1}(x_2)$$

$$\mu_2 = \mu_{A_2}(x_1) \cdot \mu_{B_2}(x_2) \quad (2.21)$$

$$\mu_3 = \mu_{A_1}(x_1) \cdot \mu_{B_2}(x_2)$$

$$\mu_4 = \mu_{A_2}(x_1) \cdot \mu_{B_2}(x_2)$$

**Tabaka 3:** Kural güçlerinin normalize edildiği tabakadır. Üçüncü tabakanın girdisi kural gücü çıktısı ise normalize edilmiş kural gücü olmaktadır.  $i$ . normalize edilmiş kural gücü eşitlik 2.22 ile hesaplanmaktadır.

$$\bar{\mu}_i = \frac{\mu_i}{\sum_{i=1}^4 \mu_i} \quad (2.22)$$

**Tabaka 4:** Bulanıklaşan değerlerin arındırıldığı tabaka diğer bir ifade ile berraklaştırma tabakasıdır. Bu tabakada doğrusal fonksiyon katsayıları (soncul parametreler) kullanılarak fonksiyon değerleri hesaplanmaktadır.  $p_i, q_i$  ve  $r_i$   $i$ . kurala ilişkin soncul parametreler olmak üzere eşitlik 2.23 ile hesaplanır.

$$f_i = p_i x_1 + q_i x_2 + r_i \quad (2.23)$$

**Tabaka 5:** ANFİS çıktısının hesaplandığı tabakadır. Tabaka 3'te hesaplanan normalize edilmiş kural gücü ile tabaka 4'te hesaplanan fonksiyon değerlerin çarpılıp toplanması sonucu ANFİS'in çıktısı hesaplanmaktadır.  $t$ . çıktının öngörü değeri  $\hat{y}_t$  olmak üzere eşitlik 2.24 ile hesaplanmaktadır.

$$\hat{y}_t = \sum_{i=1}^4 \bar{\mu}_i f_i \quad (2.24)$$

### 3. DENEYSEL MOD AYRIŞTIRMA YÖNTEMİ

Deneyisel mod ayrışımı (DMA) ilk olarak 1998’de Huang ve arkadaşları tarafından doğrusal ve durağan olmayan sinyal analizleri için önerilmiştir. Yöntem bir sinyalin, farklı sinyallerin birleşiminden meydana geldiği varsayımından hareketle, içerisinde salınım yapan tüm frekansları, sinyalde doğrusallık ya da durağanlık kriteri aramaksızın ortaya çıkartan bir sinyal ayrıştırma yöntemidir (Barbosh vd., 2020; Huang vd., 1998; Yang vd., 2004). Ayrıştırılan sinyallerin her biri bir içsel mod fonksiyonu (İMF) ile temsil edilir. İMF’ler basit bileşenli fonksiyonlar olarak kabul edilir (Huang vd., 1998).

DMA ile ayrıştırılan fonksiyonun İMF bileşeni olması için iki koşulu sağlaması gerekmektedir (Huang vd, 1998).

1. Veri setinde bulunan yerel minimum ve yerel maksimum noktalarının toplam sayısı ile sıfır geçiş noktalarının sayısı ya birbirine eşit ya da aralarındaki fark en fazla bir olmalı,
2. Veri setindeki herhangi bir noktada yerel minimum ve yerel maksimum tarafından tanımlanan zarfların ortalaması sıfır olmalıdır.

Birinci koşul bileşenin verilerin dar bir bant arasında kalmasını sağlarken, ikincisi istenmeyen anlık dalgalanmaların önüne geçecektir. Bu iki özellik sayesinde daha düzenli ve durağan bileşenler elde edilir (Büyükşahin ve Ertekin, 2019).

Deneyisel mod ayrıştırma yöntemi ile en karmaşık sinyal bile sonlu ve sınırlı sayıda İMF bileşenine ayrıştırılabilir. Ayrıştırılma işlemi “eleme süreci (sifting process)” olarak adlandırılır. Bu bileşenler, daha basit frekans bileşenlerine ve kuvvetli korelasyonlara sahip olduğundan dolayı doğrusal ve durağan olmayan zaman serilerinde daha kolay ve daha doğru tahminler yapılmasını sağlamaktadır (Chen vd., 2012).

İMF bileşenlerinin elde edilmesi için uygulanacak adımlar aşağıda sıralanmıştır (Chen vd., 2015).

- 1-  $x(t)$ ’nin ekstremum noktaları tanımlanır ve yerel maksimum ve yerel minimum olmak üzere iki kısma ayrılır.

2- Kübik eğri interpolasyon yöntemi ile yerel maksimum ve yerel minimum noktalar birleştirilerek sırasıyla üst zarf ( $e_{üst(t)}$ ) ve alt zarf ( $e_{alt(t)}$ ) zarf oluşturulur.

3- Üst zarf ve alt zarfların ortalama değeri hesaplanarak  $m_1(t)$  eğrisi elde edilir.

$$m_1(t) = \frac{(e_{üst(t)} + e_{alt(t)})}{2}$$

4- Orijinal sinyalden  $m_1(t)$  çıkarılarak İMF adayı olan  $h_1(t)$  bulunur.

$$h_1(t) = x(t) - m_1(t)$$

5-  $h_1(t)$  İMF olma koşulunu sağlıyorsa ilk bileşen elde edilmiş olur.

$$\dot{IMF}_1(t) = h_1(t)$$

6- Eğer  $h_1(t)$  İMF olma koşulunu sağlamıyorsa  $h_1(t)$  yeni sinyal alınarak adım 1-5 arası işlemler tekrar edilir ve  $h_2(t)$  bulunur. Bu işlemler eleme süreci olarak isimlendirilir. Eleme işleminin durdurulması için iki ardışık eleme süreci arasındaki standart sapmaya (SS) bakılır. SS yeterinde küçük olduğunda eleme işlemi sonlandırılır.

$$SS(i) = \sum_{t=0}^N \left[ \frac{|h_{i-1}(t) - h_i(t)|^2}{h_{i-1}^2(t)} \right]$$

Durdurma kriteri olan SS, genellikle, 0.2 veya 0.3 arasında belirlenir (Huang vd., 1998:920). Eğer  $h_2(t)$  bu koşulu sağlıyor ise birinci bileşen  $\dot{IMF}_1(t) = h_2(t)$  olur. Aksi halde  $h_2(t)$  yeni sinyal alınarak adım 1-6 işlemler tekrar edilir.  $h_i(t)$  İMF olma koşulunu sağlar ya da durdurma kriteri gerçekleşirse birinci bileşen  $\dot{IMF}_1(t) = h_i(t)$  olur.

7- Daha sonra  $\dot{IMF}_1(t)$  orijinal sinyalden çıkarılarak artık sinyal  $r_1(t)$  elde edilir.

$$r_1(t) = x(t) - \dot{IMF}_1(t)$$

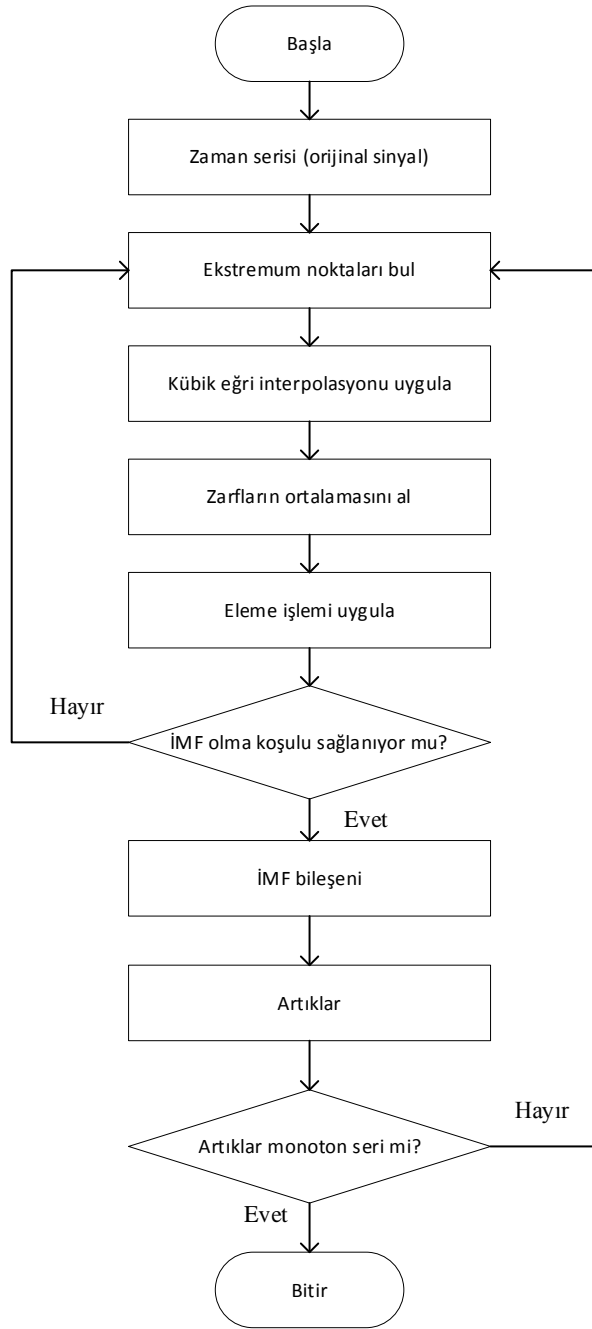
Artık sinyal orijinal sinyal olarak yerine geçerek adım 1-6 tekrar edilir. İşlemler artık sinyal monoton bir seri olana kadar tekrar edilerek İMF bileşenleri elde edilir.

$$r_n(t) = r_{n-1}(t) - \dot{IMF}_n(t)$$

Nihayetinde orijinal sinyal n tane bileşene ve bir artığa ayrıştırılmış olur.

$$x(t) = \sum_{i=1}^n \dot{IMF}_i(t) + r_n(t)$$

Şekil 3.1’de DMA yönteminin akış şeması gösterilmektedir.



Şekil 3.1. DMA akış şeması

Son yıllarda DMA yöntemi, farklı disiplinlerde kullanılan zaman serisi analizinde oldukça fazla uygulama alanı bulmuştur.

Liu vd. (2012) Rüzgar hızı tahmini için DMA-YSA yöntemini önermişlerdir. Çalışmada önerilen yöntemi karşılaştırmak amacı ile ARIMA ve YSA yöntemlerinden sonuçlar elde edilmiştir. Önerilen DMA-YSA yönteminin diğer yöntemlerden daha iyi sonuçlar verdiğini göstermişlerdir.

Okolobah ve İsmail (2013), elektrik yük tahmini için DMA-ANFİS modelini önermişlerdir.

Wang vd. (2014) kısa vadeli trafik akış hızını tahmin etmek için DMA-ARIMA modelini önermiştir. Georgia eyaletinin başkenti Atlanta'da bir otoyolda 5 gün boyunca ölçümler yapılmış ve ilk 4 gün eğitim son gün test verisi olarak kullanılmıştır. Önerilen DMA-ARIMA yönteminin başarılı sonuçlar verdiği gözlenmiştir.

Abadan ve Shabri (2014), Malezya vatandaşları için önemli bir tüketim kaynağı olan MYR tipi pirincin, 2003-2011 yılları arasında aylık satış fiyatları üzerinden sonraki 2 yılın pirinç fiyatları tahmininde DMA-ARIMA modelini kullanmışlardır.

Liu vd. (2015), Çin-Tibet bölgesinde kısa vadeli rüzgar hızı tahmini için DMA-ARIMA yöntemini kullanmışlardır.

Jothimani vd. (2016), Hindistan Ulusal Menkul Kıymetler Borsasında bulunan bir hisse senedinin 2007-2015 yılların arasında haftalık kapanış fiyatlarını modellemek amacıyla DMA-YSA yöntemini kullanmışlardır.

Awajan vd. (2017), 10 ülkeye ait borsa endekslerini tahmin etmek amacıyla DMA-HW bagging yöntemini önermiştir. DMA-HW bagging yönteminin uygulamada kullanılan diğer yöntemlere göre daha iyi sonuçlar verdiğini göstermişlerdir.

Nai vd. (2018), Çin hava yolu kargo (iç hat-dış hat) ve yolcu (iç hat-dış hat) talep tahmini üzerine yaptıkları çalışmada SARIMA, Holt-Winters ve DMA-SARIMA yöntemlerini kullanmıştır. DMA-SARIMA modelinin diğer yöntemlerden daha iyi sonuçlar verdiğini gözlemlemişlerdir.

Büyükşahin ve Ertekin (2019), Zhang (2013)'ın önermiş olduğu hibrit yöntem olan ARIMA-YSA modelini DMA yöntemi ile ayrıştırılan bileşenler için uygulamıştır. DMA sonrası her bir bileşene hibrit yöntem uygulandığında tek başlarına olduklarında daha iyi sonuçlar aldıklarını göstermişlerdir.

Ghide vd. (2022), Eritre'nin başkenti Asmara kentinin 1991-2017 yılları arasındaki günlük sıcaklık verileri ile sonraki 3 yılın sıcaklık tahmininde DMA-SARIMA yöntemini kullanmışlardır.

#### 4. ÇALIŞMADA KULLANILAN YAKLAŞIM

Başta ekonomi, sağlık ve mühendislik olmak üzere bir çok alanda zaman serisi verisi üretilmektedir. Bu serilerin bazıları sadece trend bileşeni ya da mevsimsel bileşeni, bazıları ise hem trend hem de mevsimsel bileşenleri birlikte içermektedir.

Zaman serisi mevsimsel hareketler sergilediği durumda geleceğe yönelik tahminde bulunmak amacıyla üstel düzleştirme yöntemlerinden olan Holt Winters yöntemi sıklıkla kullanılmaktadır. Yöntem içerisinde yer alan düzleştirme parametreleri ve başlangıç değerlerinin doğru belirlenmesi öngörü başarısı üzerinde önemli bir etkiye sahiptir. Bu çalışmada HW yöntemi düzleştirme parametreleri ve başlangıç değerleri yapay zeka tekniklerinden birisi olan DGA yöntemi ile elde edilmiştir. 2016 yılında sözlü sunumunu yaptığımız bu yöntem geliştirilerek uygulanmış ve klasik HW yöntemleri ile karşılaştırılmıştır (Kılıç Topal vd., 2016).

Literatürde zaman serisi analizinde kullanılan hem doğrusal hem de doğrusal olmayan birçok yöntem vardır. Ayrıca bu iki yöntemin birlikte kullanıldığı aşamalı ve hibrit yöntemlerde önerilmiştir (Zhang, 2003; Yolcu vd., 2013). Aşamalı yöntemlerde birinci aşamada zaman serisinin doğrusal bileşeni modellenmekte ve artıklar elde edilmekte, ikinci aşamada bu artıklar üzerinden doğrusal olmayan yapı modellenmektedir. Hibrit yöntemlerde ise doğrusal ve doğrusal olmayan yapı aynı anda modellenmektedir. Fakat hem aşamalı hem de hibrit yöntemlerde zaman serisi doğrusal ve doğrusal olmayan şekilde iki bileşenden oluştuğu varsayılmaktadır (Eğrioğlu vd.,2020) .

Büyüksahin ve Ertekin (2019) yaptıkları çalışmada Deneysel Mod Ayırıştırma (DMA) yöntemi kullanarak bir zaman serisini iki bileşen yerine iç içe geçmiş birden fazla bileşenin toplamı olarak ifade etmişlerdir. Sonrasında her bir bileşeni ayrı ayrı Zhang (2003)'ın önermiş olduğu aşamalı yöntem ile modellemişlerdir.

Bu tez çalışmasında mevsimsel bileşene sahip veri seti üzerinden HW yönteminin diferansiyel gelişim algoritması ile hibrit edildiği HW-DGA yöntemi ve deneysel mod ayırıştırma yöntemine dayalı DMA-YSA ve DMA-ANFİS aşamalı yöntemleri önerilmiştir. Yöntemlerin performans karşılaştırılmasında Hata Kareler Ortalamasının Karekökü (HKOK), Ortalama Mutlak Yüzdalık Hata (OMYH) ve Normalleştirilmiş Hata Kareler Ortalamasının Karekökü (NHKOK) ölçütleri kullanılmıştır. Bu değerlerin elde edilmesinde kullanılan formüller sırasıyla eşitlik

4.1, eşitlik 4.2 ,eşitlik 4.3 ve eşitlik 4.4'te gösterilmektedir. HKOK, OMYH ve NHKOK değerlerinin düşük, *doğruluk* değerinin yüksek olması yöntemden elde edilen öngörülerin gerçek değerler ile uyumlu olduğunu göstermektedir.

$$HKOK = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (4.1)$$

$$OMYH = \frac{100}{n} \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \quad (4.2)$$


$$NHKOK = \frac{HKOK}{y_{enb} - y_{enk}} \quad (4.3)$$

$$Doğruluk(\%) = 100 * (1 - NHKOK) \quad (4.4)$$

Burada  $n$ : ilgili kümenin gözlem sayısını,  $y_i$ :  $i$ . gözlem değerini,  $\hat{y}_i$ :  $i$ . gözlemin öngörü değerini,  $y_{enb}$ : ilgili kümenin en büyük gözlem değerini,  $y_{enk}$ : ilgili kümenin en küçük değerini ifade etmektedir.

## 5. UYGULAMA

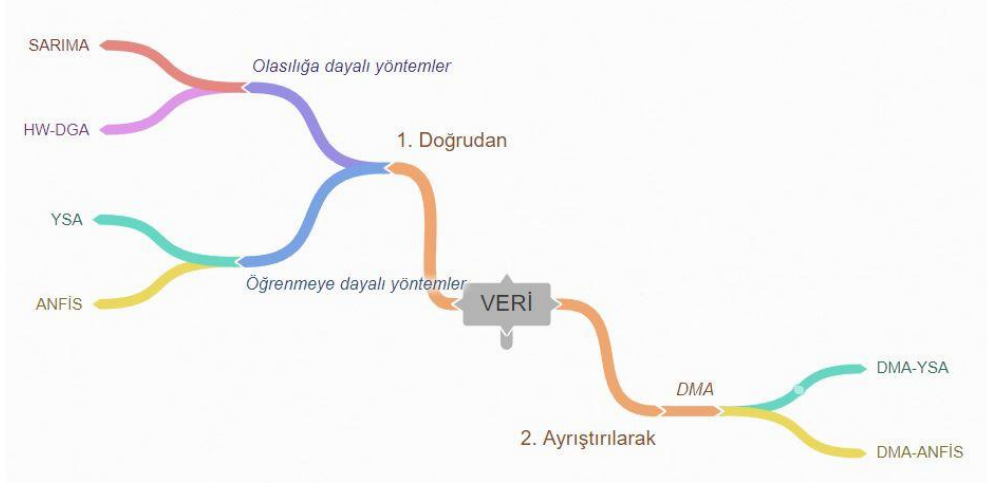
Bu çalışmada kullanılan EMA veri seti, Kurnaz vd. (2018) çalışmasının 26. konumundaki baz istasyonunu doğrudan gören sabit bir noktadan PMM-8053 EMA ölçüm cihazı ile 8 gün boyunca 24 saat ölçüm yapılarak elde edilmiştir. Her 6 dakikalık EMA ölçümlerinin ortalaması alınarak toplamda 1920 veri kullanılmıştır. Bu verilerin ilk 7 günü (1680) eğitim için kullanılırken 8. gün (240) test verisi olarak kullanılmıştır. EMA ölçümlerine ait zaman serisi grafiği şekil 5.1’ de verilmiştir.



Şekil 5.1. EMA ölçümlerinin zaman serisi grafiği

Zaman serisi grafiğine göre EMA ölçümleri periyodu (s)240 olan mevsimsel hareket sergilediği gözlenmektedir. Bu sebepten dolayı öngörü elde etmek için mevsimselliği göz önünde bulunduran yöntemler uygulamada tercih edilmiştir.

Uygulama iki farklı yol ile gerçekleştirilmiştir. İlkinde öngörüler doğrudan zaman serisi üzerinden elde edilirken, diğesinde ise DMA yöntemi ile ayrıştırılan bileşenler üzerinden öngörüler elde edilmektedir. Şekil 5.2’de uygulama şeması gösterilmektedir. Uygulama sonunda tüm sonuçların karşılaştırılması tek tabloda sunulmuştur. Sonuçlar MATLAB R2021a programı kullanılarak elde edilmiştir.



Şekil 5.2. Uygulama Şeması

### 1- Doğrudan uygulama

Öngörüler mevsimsel ARIMA (SARIMA), HW-DGA, YSA ve ANFİS yöntemleri ile edilmiştir.

#### SARIMA:

SARIMA yönteminden uygun modelin belirlenmesi için çok sayıda alternatif denenmiştir.  $SARIMA(p, 0, q)(P, D, Q)_{240}$ ,

- AR modelinin derecesi p:0,1,2,3 alınarak,
- MA modelinin derecesi q:0,1,2,3 alınarak,
- SAR modelinin derecesi P:0,1,2,3 alınarak,
- SMA modelinin derecesi Q:0,1,2,3 alınarak,

En uygun modele karar verebilmek için en yaygın kullanılan iki bilgi kriteri Akaike Bilgi Kriteri (AIC) ve Bayes Bilgi Kriteri (BIC) kullanılmıştır. Mevsimsel fark alma sayısı (D) 0 ve 1 alınarak tüm alternatif modeller için AIC ve BIC değerleri elde edilmiştir. En küçük değerlerden başlanarak model parametrelerinin anlamlılığı ve hata serisinin akgürültü olup olmadığı kontrol edilmiş ve kriterlere uygun en iyi modeller ve sonuçları tablo 5.1-5.4'te verilmiştir. Tüm alternatif sonuçlara ait AIC ve BIC değerleri Ek 1'de gösterilmektedir.

Tablo 5.1. D=0 olduğu durumda AIC bilgi kriterine göre en iyi modellere ait sonuçlar

Model	Bilgi Kriteri		HKOK	
	AIC	Eğitim	Test	
SARIMA(3,0,3)(1,0,0) <sub>240</sub>	4760.12	0.9924	1.5655	
SARIMA(3,0,3)(2,0,0) <sub>240</sub>	4741.67	0.9864	1.3505	
SARIMA(3,0,3)(3,0,0) <sub>240</sub>	4515.72	0.9217	1.5296	
SARIMA(3,0,3)(0,0,1) <sub>240</sub>	4761.21	0.9928	1.5936	
SARIMA(3,0,3)(1,0,1) <sub>240</sub>	4615.02	0.9499	1.4810	
SARIMA(3,0,3)(2,0,1) <sub>240</sub>	4607.31	0.9472	1.3932	
SARIMA(2,0,3)(3,0,1) <sub>240</sub>	4516.92	0.9220	1.5319	
SARIMA(3,0,3)(0,0,2) <sub>240</sub>	4761.45	0.9922	1.5619	
SARIMA(2,0,3)(1,0,2) <sub>240</sub>	4615.18	0.9500	1.4466	
SARIMA(2,0,3)(2,0,2) <sub>240</sub>	4390.53	0.8880	1.4004	
SARIMA(2,0,3)(3,0,2) <sub>240</sub>	4374.05	0.8831	1.3122	
SARIMA(3,0,3)(0,0,3) <sub>240</sub>	4758.78	0.9909	1.4835	
SARIMA(2,0,3)(1,0,3) <sub>240</sub>	4616.29	0.9497	1.4022	
SARIMA(3,0,2)(2,0,3) <sub>240</sub>	4389.57	0.8872	1.3470	

Tablo 5.2. D=0 olduğu durumda BIC bilgi kriterine göre en iyi modellere ait sonuçlar

Model	Bilgi Kriteri		HKOK	
	BIC	Eğitim	Test	
SARIMA(2,0,1)(1,0,0) <sub>240</sub>	4793.17	0.9946	1.5745	
SARIMA(2,0,1)(2,0,0) <sub>240</sub>	4779.59	0.9889	1.3561	
SARIMA(2,0,1)(3,0,0) <sub>240</sub>	4561.19	0.9252	1.5251	
SARIMA(2,0,1)(0,0,1) <sub>240</sub>	4795.08	0.9949	1.6019	
SARIMA(1,0,2)(1,0,1) <sub>240</sub>	4658.96	0.9536	1.4791	
SARIMA(2,0,1)(2,0,1) <sub>240</sub>	4649.05	0.9492	1.3966	
SARIMA(2,0,1)(3,0,1) <sub>240</sub>	4567.98	0.9251	1.5245	
SARIMA(2,0,1)(0,0,2) <sub>240</sub>	4800.78	0.9944	1.5699	
SARIMA(2,0,1)(1,0,2) <sub>240</sub>	4658.45	0.9514	1.4537	
SARIMA(2,0,1)(2,0,2) <sub>240</sub>	4442.41	0.8907	1.4178	
SARIMA(2,0,3)(3,0,2) <sub>240</sub>	4432.45	0.8831	1.3122	
SARIMA(2,0,1)(0,0,3) <sub>240</sub>	4803.99	0.9932	1.4929	
SARIMA(1,0,3)(1,0,3) <sub>240</sub>	4672.02	0.9511	1.4161	
SARIMA(2,0,1)(2,0,3) <sub>240</sub>	4446.54	0.8899	1.3705	

Tablo 5.3. D=1 olduğu durumda AIC bilgi kriterine göre en iyi modellere ait sonuçlar

Model	Bilgi Kriteri		HKOK	
	AIC	Eğitim	Test	
SARIMA(3,0,3)(1,1,0) <sub>240</sub>	4988.19	1.0621	1.2830	
SARIMA(3,0,3)(2,1,0) <sub>240</sub>	4570.29	0.9374	1.5946	
SARIMA(3,0,2)(3,1,0) <sub>240</sub>	4401.09	0.8913	1.2561	
SARIMA(2,0,3)(0,1,1) <sub>240</sub>	5011.92	1.0703	1.0958	
SARIMA(3,0,3)(1,1,1) <sub>240</sub>	4875.51	1.0265	1.1390	
SARIMA(2,0,3)(2,1,1) <sub>240</sub>	4570.54	0.9374	1.5952	
SARIMA(3,0,2)(3,1,1) <sub>240</sub>	4403.07	0.8913	1.2563	
SARIMA(2,0,3)(0,1,2) <sub>240</sub>	5009.54	1.0689	1.0975	
SARIMA(3,0,2)(1,1,2) <sub>240</sub>	4660.17	0.9628	1.1738	
SARIMA(2,0,3)(2,1,2) <sub>240</sub>	4564.30	0.9351	1.6253	
SARIMA(3,0,2)(3,1,2) <sub>240</sub>	4384.16	0.8858	1.2653	
SARIMA(2,0,3)(0,1,3) <sub>240</sub>	5009.36	1.0682	1.1050	
SARIMA(3,0,2)(1,1,3) <sub>240</sub>	4636.84	0.9561	1.2244	
SARIMA(3,0,2)(2,1,3) <sub>240</sub>	<b>4247.40</b>	0.8505	1.2011	

Tablo 5.4. D=1 olduğu durumda BIC bilgi kriterine göre en iyi modellere ait sonuçlar

Model	Bilgi Kriteri		HKOK	
	BIC	Eğitim	Test	
SARIMA(2,0,1)(1,1,0) <sub>240</sub>	5022.52	1.0652	1.2804	
SARIMA(2,0,1)(2,1,0) <sub>240</sub>	4612.90	0.9414	1.5924	
SARIMA(3,0,2)(3,1,0) <sub>240</sub>	4446.88	0.8913	1.2561	
SARIMA(2,0,3)(0,1,1) <sub>240</sub>	5054.10	1.0703	1.0958	
SARIMA(2,0,1)(1,1,1) <sub>240</sub>	4913.22	1.0290	1.1338	
SARIMA(2,0,3)(2,1,1) <sub>240</sub>	4619.21	0.9374	1.5952	
SARIMA(3,0,2)(3,1,1) <sub>240</sub>	4453.45	0.8913	1.2563	
SARIMA(2,0,1)(0,1,2) <sub>240</sub>	5051.17	1.0717	1.0932	
SARIMA(2,0,1)(1,1,2) <sub>240</sub>	4708.94	0.9662	1.1655	
SARIMA(2,0,3)(2,1,2) <sub>240</sub>	4617.84	0.9351	1.6253	
SARIMA(3,0,2)(3,1,2) <sub>240</sub>	4439.11	0.8858	1.2653	
SARIMA(2,0,1)(0,1,2) <sub>240</sub>	5056.15	1.0710	1.1011	
SARIMA(2,0,1)(1,1,3) <sub>240</sub>	4685.31	0.9595	1.2207	
SARIMA(2,0,1)(2,1,3) <sub>240</sub>	<b>4304.54</b>	0.8536	1.2030	

Model seçme kriteri olarak AIC kullanıldığında en iyi model  $SARIMA(3,0,2)(2,1,3)_{240}$  modeli olmaktadır. Bu model ile yapılan öngörüler ile hesaplanan HKOK değerleri eğitim ve test kümesi için sırasıyla 0.8505 ve 1.2011'dir.


Model seçme kriteri olarak BIC kullanıldığında ise en iyi model  $SARIMA(2,0,1)(2,1,3)_{240}$  modeli olmaktadır. Bu model kullanılarak yapılan öngörüler ile hesaplanan HKOK değerleri eğitim ve test kümesi için sırasıyla 0.8536 ve 1.2030'dur. AIC değerleri dikkate alınarak oluşturulan modelin performansının daha yüksek olduğu görülmektedir. Tablo 5.5'te en iyi modellere ilişkin sonuçlar gösterilmiştir.

Tablo 5.5. Öngörü performansı en iyi olan SARIMA modeline ait sonuçlar

MODEL	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
$SARIMA(3,0,2)(2,1,3)_{240}$	0.8505	1.2011	0.0818	0.1415	0.0850	0.1625	%91.50	<b>%83.75</b>
$SARIMA(2,0,1)(2,1,3)_{240}$	0.8536	1.2030	0.0821	0.1418	0.0853	0.1627	%91.47	%83.73


Buna göre en başarılı öngörü en düşük HKOK, OMYH ve NHKOK değerlerine sahip olan  $SARIMA(3,0,2)(2,1,3)_{240}$  modeline aittir. Modelin eğitim kümesinde %91.50, test kümesinde %83.75 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.3'te eğitim kümesi için ölçülen EMA değerleri ve  $SARIMA(3,0,2)(2,1,3)_{240}$  modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.3. SARIMA ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği

Şekil 5.4'te test kümesi için ölçülen EMA değerleri ve  $SARIMA(3,0,2)(2,1,3)_{240}$  modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.




Şekil 5.4. SARIMA ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği

#### HW-DGA:

Holt Winters üstel düzleştirme yönteminde kullanılan düzleştirme parametreleri  $\alpha$ ,  $\gamma$ ,  $\beta$  ve ortalama, trend ve mevsimsel bileşenlere ait başlangıç değerleri olan  $S_0$ ,  $b_0$ ,  $I_{-(s-1)}$ ,  $I_{-(s-2)}$ , ...,  $I_0$ 'ın optimal değerlerini belirlemek için diferansiyel gelişim algoritması kullanılmıştır.

Başlangıç popülasyonunda her bir kromozomda bulunan genler  $\alpha$ ,  $\gamma$ ,  $\beta$ ,  $I_{-239}$ ,  $I_{-238}$ , ...,  $I_0$ ,  $S_0$ ,  $b_0$  değerlerini temsil etmektedir (Şekil 5.5). Buna bağlı olarak bir kromozomdaki gen sayısı (kromozom uzunluğu) 245 olmaktadır.  $\alpha$ ,  $\gamma$  ve  $\beta$  parametrelerinin bulunduğu genler (0,1) aralığında düzgün (uniform) dağılımdan,  $S_0$  ve  $b_0$  başlangıç değerlerinin bulunduğu genler, regresyon analizi ile elde edilen sırasıyla sabit terim ve regresyon katsayısı tahminlerinin oluşturduğu %95'lik güven aralıklarından,  $I_{-239}$ ,  $I_{-238}$ , ...,  $I_0$  mevsimsel düzleştirmede kullanılan başlangıç değerlerinin bulunduğu genler ise eşitlik 5.1 ile ifade edilen hesaplamalar sonucu her bir  $k$ . başlangıç değeri için en küçük ve en büyük değer aralığından rasgele seçilerek türetilmiştir. Sonrasında bölüm 2.1.2.1 açıklanan DGA adımları (mutasyon, çaprazlama ve seçim) uygulanmıştır. Burada seçme işleminde amaç fonksiyonu olarak HKOK değeri kullanılmıştır.



Şekil 5.5. Bir kromozom örneği

$$C_m = \frac{\sum_{t=(m-1)s+1}^{ms} y_t}{s}, \quad m = 1, 2, \dots, \frac{n}{s} \quad k = 1, 2, \dots, s$$

$$\min \left( \frac{y_{k+(1-1)s}}{C_1}, \frac{y_{k+(2-1)s}}{C_2}, \frac{y_{k+(3-1)s}}{C_2}, \dots, \frac{y_{k+(m-1)s}}{C_m} \right) < I_{-(s-k)} \quad (5.1)$$

$$I_{-(s-k)} < \max \left( \frac{y_{k+(1-1)s}}{C_1}, \frac{y_{k+(2-1)s}}{C_2}, \frac{y_{k+(3-1)s}}{C_2}, \dots, \frac{y_{k+(m-1)s}}{C_m} \right)$$

DGA'da kullanılan kontrol parametreleri,

- Kromozom sayısı 30,
- Çaprazlama oranı 0.5 ve 0.8 olmak üzere 2 farklı şekilde,
- F ölçek faktörü 0.8 ve 1.2 alınarak 2 farklı şekilde,
- İterasyon sayısı 1000 alınarak,

sonuçlar elde edilmiştir. Deneme sonuçlarından elde edilen HKOK değerleri tablo 5.6'da verilmiştir.

Tablo 5.6. HW-DGA Sonuçları

Ölçek Faktörü (F)	Çaprazlama oranı (Co)	HKOK	
		Eğitim	Test
0.8	0.5	1.0250	1.0548
	0.8	1.0211	<b>1.0119</b>
1.2	0.5	1.0511	1.0191
	0.8	1.0259	1.0122


Tablo 5.6 görüldüğü gibi kontrol parametreleri F=0.8 ve Co=0.8 seçildiğinde en iyi sonuçlar elde edilmiştir. Bu parametreler kullanıldığında HW-DGA yönteminden elde edilen öngörülere ait HKOK, OMYH, NHKOK ve doğruluk değerleri tablo 5.7'de gösterilmiştir.

Tablo 5.7. HW-DGA yönteminden elde edilen öngörülerin performans sonuçlar

MODEL	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
HW-DGA	1.0211	1.0119	0.1044	0.1164	0.1023	0.1369	%89.77	%86.31


Buna göre HW-DGA yöntemi ile elde edilen öngörülerin HKOK değerleri eğitim ve test kümesi için sırasıyla 1.0211, 1.0119, OMYH değerleri ise eğitim ve test kümesi için sırasıyla 0.1044 ve 0.1164'tür. HW-DGA yönteminin eğitim kümesinde %89.77, test kümesinde %86.31 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.6'da eğitim kümesi için ölçülen EMA değerleri ve HW-DGA yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.6. HW-DGA yöntemi ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği

Şekil 5.7'de test kümesi için ölçülen EMA değerleri ve HW-DGA yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.7. HW-DGA yöntemi ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği

### YSA:

Her bir YSA modeli için girdi değişken sayısı (gecikmeli değişken sayısı) mevsimsel periyod göz önünde bulundurularak farklı sayılarda alınmıştır. Buna bağlı olarak aşağıda belirtilen model parametreleri ile bir çok alternatif model denenmiştir.

- Girdi katmanı birim sayısı: [1:239, 240] olmak üzere 239 farklı şekilde,
- Gizli katman sayısı: 1 sabit
- Gizli katmanı birim sayısı: 1 ile 10 arasında artırılarak denenmiştir.
- Gizli katman aktivasyon fonksiyonu: Logaritmik sigmoid fonksiyonu(logsig) ve Hiperbolik tanjant sigmoid fonksiyonu (tansig)
- Çıktı katman aktivasyon fonksiyonu: Doğrusal (purelin)

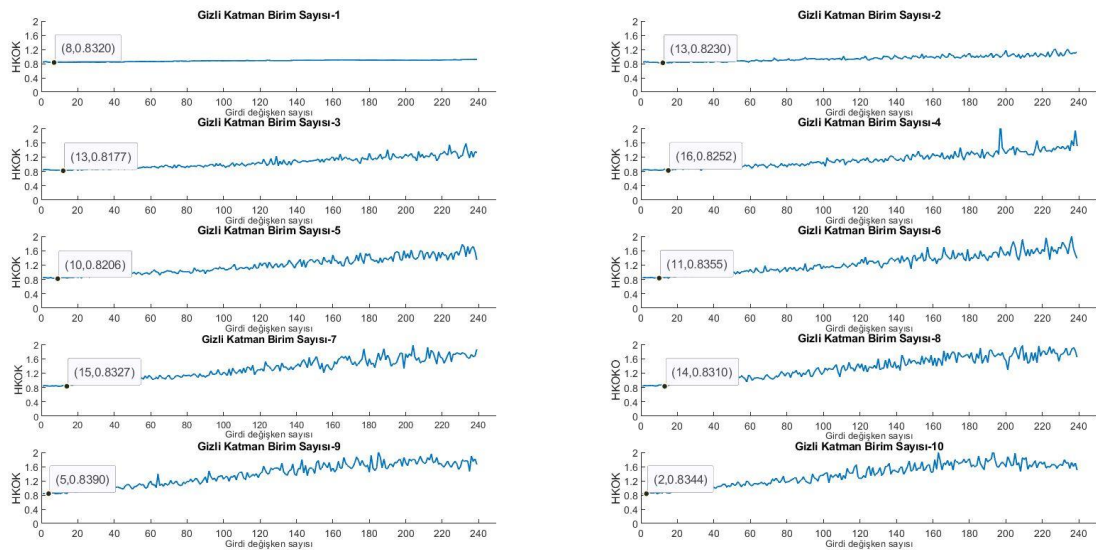
Deneme sonuçlarından elde edilen HKOK değerleri tablo 5.8' de özetlenmiştir.

Tablo 5.8. YSA ile kurulan farklı modellere ait HKOK değerleri

Gizli katman birim sayısı	logsig				tansig	
	Girdi değişken sayısı	HKOK		Girdi değişken sayısı	HKOK	
		Eğitim	Test		Eğitim	Test
1	8	0.9971	0.8320	8	0.9960	0.8307
2	13	0.9822	0.8230	16	0.9796	0.8208
3	13	0.9753	<b>0.8177</b>	18	0.9704	0.8222
4	16	0.9629	0.8252	11	0.9667	0.8326
5	10	0.9602	0.8206	8	0.9718	0.8320
6	11	0.9496	0.8355	11	0.9514	0.8357
7	15	0.9280	0.8327	11	0.9291	0.8327
8	14	0.9304	0.8310	12	0.9297	0.8251
9	5	0.9696	0.8390	2	1.0327	0.8389
10	2	1.0297	0.8344	4	0.9865	0.8355

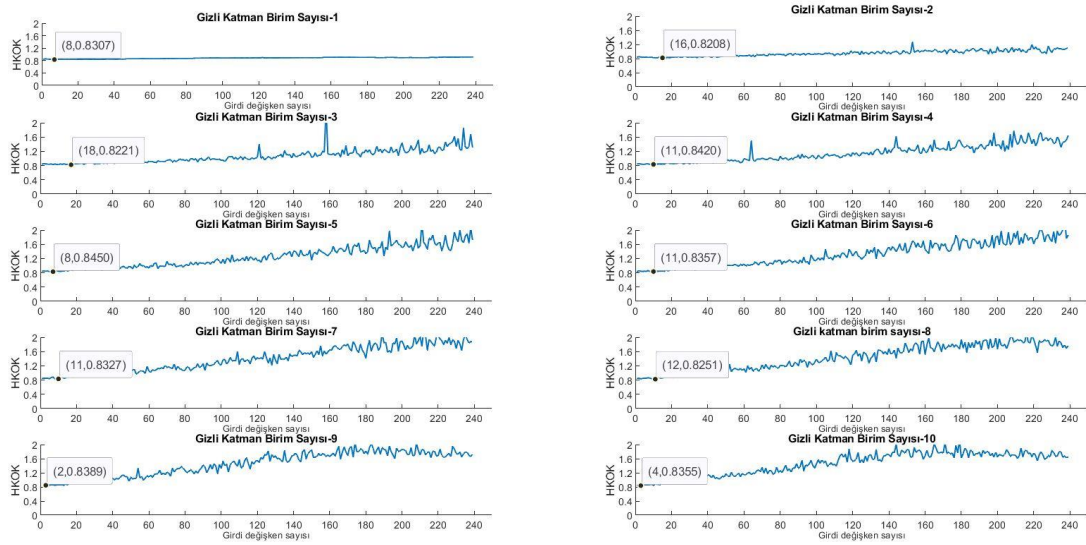
Model adlandırma işlemi [girdi değişken sayısı-gizli katman birim sayısı-çıkıktı sayısı]<sub>Aktivasyon Fonk.</sub> olarak yapılmıştır.

Tablo 5.8’de gösterildiği gibi aktivasyon fonksiyonu logaritmik sigmoid (logsig) seçildiğinde en iyi YSA modeli, HKOK değerlerinin eğitim ve test kümesi için sırasıyla 0.9753 ve 0.8177 olduğu [13-3-1]<sub>logsig</sub> modelidir. Aktivasyon fonksiyonu hiperbolik tanjant sigmoid (tansig) seçildiğinde ise en iyi YSA modeli, HKOK değerlerinin eğitim ve test kümesi için sırasıyla 0.9796 ve 0.8208 olduğu [16-2-1]<sub>tansig</sub> modelidir. Logaritmik sigmoid aktivasyon fonksiyonu kullanılarak oluşturulan tüm modellerden elde edilen HKOK değerlerine ait grafikler şekil 5.8’de gösterilmiştir.



Şekil 5.8. Girdi değişken sayısına göre HKOK’daki değişimler (logsig)

Hiperbolik tanjant aktivasyon fonksiyonu kullanılarak oluşturulan tüm modellerden elde edilen HKOK değerlerine ait grafikler şekil 5.9’da gösterilmiştir.



Şekil 5.9. Girdi değişken sayısına göre HKOK’daki değişimler (tansig)

İki aktivasyon fonksiyonu içinde girdi değişken sayısı arttıkça HKOK değerlerinde buna bağlı olarak artışı görülmektedir.


En iyi iki model diğer değerlendirme kriterleri olan OMYH ve NHKOK değerleri ile tablo 5.9’da özetlenmiştir.

Tablo 5.9. YSA ile kurulan en iyi modellere ait performans sonuçları

MODEL	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
[13-3-1] <sub>logs</sub>	0.9753	0.8177	0.1006	0.0892	0.1043	0.1106	%89.57	<b>%88.94</b>
[16-2-1] <sub>tans</sub>	0.9796	0.8208	0.1012	0.0896	0.1048	0.1110	%89.52	%88.90


Buna göre en başarılı öngörü en düşük HKOK, OMYH ve NHKOK değerlerine sahip olan [13-3-1]<sub>logs</sub> modeline aittir. Modelin eğitim kümesinde %89.57, test kümesinde %88.94 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.10’da eğitim kümesi için ölçülen EMA değerleri ve [13-3-1]<sub>logs</sub> modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.10. YSA ile eğitim kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği (logsig)

Şekil 5.11'de test kümesi için ölçülen EMA değerleri ve  $[13-3-1]_{\log s}$  modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.11. YSA ile test kümesi için ölçülen ve öngörülen değerlerin birlikte grafiği (logsig)

Zaman serisinde bölünmüş çapraz doğrulama yöntemi (Assaad and Fayek, 2021) ile 4. 5. 6. ve 7. günler ayrı ayrı test kümesi seçilerek  $[13-3-1]_{\log s}$  modelinin başarısı değerlendirilmiştir. Tablo 5.10'da seçilen test kümeleri için performans kriterleri olan HKOK ve doğruluk değerleri ve bu değerlerin ortalaması gösterilmiştir. Buna göre en iyi model olan  $[13-3-1]_{\log s}$  modeli %86.83 başarı ile öngörü yapmaktadır.

Tablo 5.10. YSA modeli çapraz doğrulama

								Eğitim	Test	HKOK	Doğruluk
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün	7.Gün	8.gün	⇒		0.8177	%88.94
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün	7.Gün		⇒		1.1037	%85.07
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün			⇒		1.0335	%86.02
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün				⇒		1.0027	%86.44
1.Gün	2.Gün	3.Gün	4.Gün					⇒		0.9102	%87.69
Çapraz Doğrulama									0.9736	%86.83	

### ANFİS:

ANFİS ile modelleme yapılırken girdi ve çıktılar belirli sayıda üyelik fonksiyonlarına ayrılır. Üyelik fonksiyonu sayısı ve tipi modellemenin başarısını etkilemektedir. Fakat hangi durumda hangi üyelik fonksiyonunun kullanılacağı belirsizdir. Bu belirsizlik deneme yanılma yöntemi ile ortadan kaldırılmaktadır.

Çalışmada girdi değişkenleri için 8 farklı üyelik fonksiyonu gecikmeli değişken sayısı değiştirilerek denenmiştir. Modelin en fazla kaç girdi ile oluşturulacağı yani gecikmeli değişken sayısı, ANFİS’de kullanılan doğrusal ve doğrusal olmayan parametre sayısı dikkate alınarak toplam parametre sayısına göre belirlenmiştir.

$p$ : girdi değişken sayısı,  $a_i$ :  $i$ . girdi değişkeni için üyelik fonksiyonu sayısı,  $\ell$ : üyelik fonksiyonu parametre sayısı olmak üzere kural sayısı ( $ks$ ) eşitlik 5.2 ile, toplam üyelik fonksiyonu sayısı ( $m$ ) eşitlik 5.3 ile, doğrusal parametre sayısı ( $L$ ) sabit ve doğrusal için sırasıyla eşitlik 5.4 ve eşitlik 5.5 ile ve doğrusal olmayan parametre sayısı ( $NL$ ) eşitlik 5.6 ile hesaplanmaktadır.

$$ks = a_1 x a_2 x \dots x a_p \quad (5.2)$$

$$m = a_1 + a_2 + \dots + a_p \quad (5.3)$$

Çıktı üyelik fonksiyonu sabit ise;

$$L = ks \quad (5.4)$$

Çıktı üyelik fonksiyonu doğrusal ise;

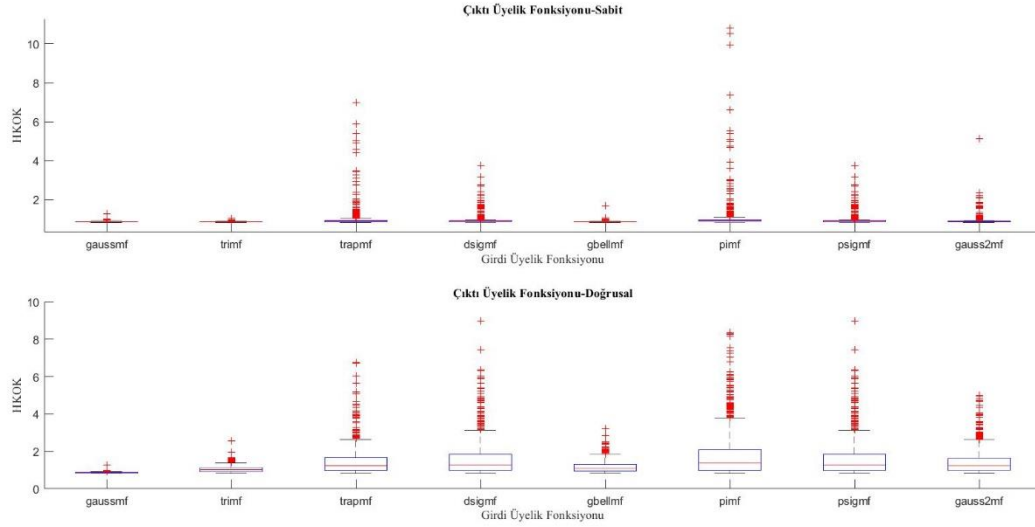
$$L = ksx(p + 1) \quad (5.5)$$

$$NL = \ell xm \quad (5.6)$$

ANFİS yönteminde toplam parametre sayısı ( $L + NL$ )'nın girdi sayısından fazla olması aşırı uyum problemine sebep olmasından dolayı istenmeyen bir durumdur. Eğitim kümesinde 1440 ölçüm değeri mevcuttur. Üyelik fonksiyonu girdi değişkeni için minimum 2 olarak alındığında 7 girdi için toplam parametre sayısı  $2^7 \times 8 + 2 \times 14 = 1052$  olmaktadır. 8 girdi için toplam parametre sayısı ise  $2^8 \times 9 + 2 \times 16 = 2336$  olmaktadır. Bu değer eğitim kümesindeki ölçüm değeri olan 1440'ın çok üzerinde olmasından dolayı en fazla 7 girdi değişken ile çalışma gerçekleştirilmiştir. Girdi değişken sayısı mevsimsellik dikkate alınarak [1 240] tanımını 1. gecikme ile 240. gecikme için yapacak olursak [1:6 240] ile farklı gecikmeler ve her bir girdi değişkeni için üyelik fonksiyonu sayısı en fazla 6 alınarak denenmiştir. Çalışma kapsamında

- Girdi üyelik fonksiyonu tipi: Gauss, Üçgen, Yamuk, İki sigmoid fonksiyon farkı, Genelleştirilmiş çan biçimli, Pi tipi, İki sigmoid fonksiyon çarpımı, Gauss kombinasyon olmak üzere 8 farklı tip üyelik fonksiyonu,
- Girdi üyelik fonksiyonu sayısı: 2-6 arasında değiştirilerek
- Girdi değişkeni sayı: 2-7 arasında,
- Çıktı üyelik fonksiyonu: Sabit ve doğrusal olmak üzere 2 tip,
- Öğrenme algoritması: Hibrit (geri yayılım ve en küçük kareler yöntemi)
- Performans ölçütü: Hata kareler ortalamasının karekökü ve ortalama mutlak yüzde hata olarak belirlenmiştir.

8 tip girdi üyelik fonksiyonu ve 2 tip çıktı üyelik fonksiyonu yukarıdaki parametreler değiştirilerek modeller oluşturulmuş ve test kümesi için HKOK ile performansları değerlendirilmiştir. Şekil 5.12'de girdi üyelik fonksiyonları ile deneme sonuçlarından elde edilen HKOK değerlerine ait kutu grafikleri görülmektedir. Tüm girdi ve çıktı üyelik fonksiyonları için oluşturulan modellerden elde edilen HKOK değerleri ek 3'de tablo olarak sunulmuştur.



Şekil 5.12. Girdi ve çıktı üyelik fonksiyonlarından elde edilen HKOK kutu grafikleri

Şekil 5.12’ye göre çıktı üyelik fonksiyonu hem sabit hem de doğrusal olduğunda en tutarlı sonuçlar girdi üyelik fonksiyonununun gauss (gausmf), üçgen (trimf) ve genelleştirilmiş çan eğrisi (gbellmf) olduğu durumda elde edilmiştir. Bu sebepten dolayı çalışmada girdi üyelik fonksiyonu olarak gauss, üçgen ve genelleştirilmiş çan eğrisi seçilerek EMA öngörülürü 6 ANFİS modeli için elde edilmiştir. Bu modellere ait HKOK ve OMYH değerleri Tablo 5.11’de sunulmuştur.

Tablo 5.11. ANFİS ile kurulan modellerin performansları

MODEL	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
[3 5 3 2] <sub>gausmf,s</sub>	0.9711	0.8270	0.0997	0.0895	0.1039	0.1119	%89.61	<b>%88.81</b>
[3 3] <sub>gausmf,d</sub>	1.0329	0.8291	0.1049	0.0915	0.1105	0.1121	%88.95	%88.79
[3 5 2 2] <sub>trimf,s</sub>	0.9849	0.8311	0.1013	0.0904	0.1053	0.1124	%89.47	%88.76
[2 3 2 2 2] <sub>trimf,d</sub>	0.9237	0.8285	0.0952	0.0922	0.0988	0.1124	%90.12	%88.79
[5 6] <sub>gbellmf,s</sub>	1.0374	0.8315	0.1056	0.092	0.1110	0.1125	%88.90	%88.75
[3 3] <sub>gbellmf,d</sub>	1.0319	0.8287	0.1047	0.0914	0.1104	0.1121	%88.96	%88.79

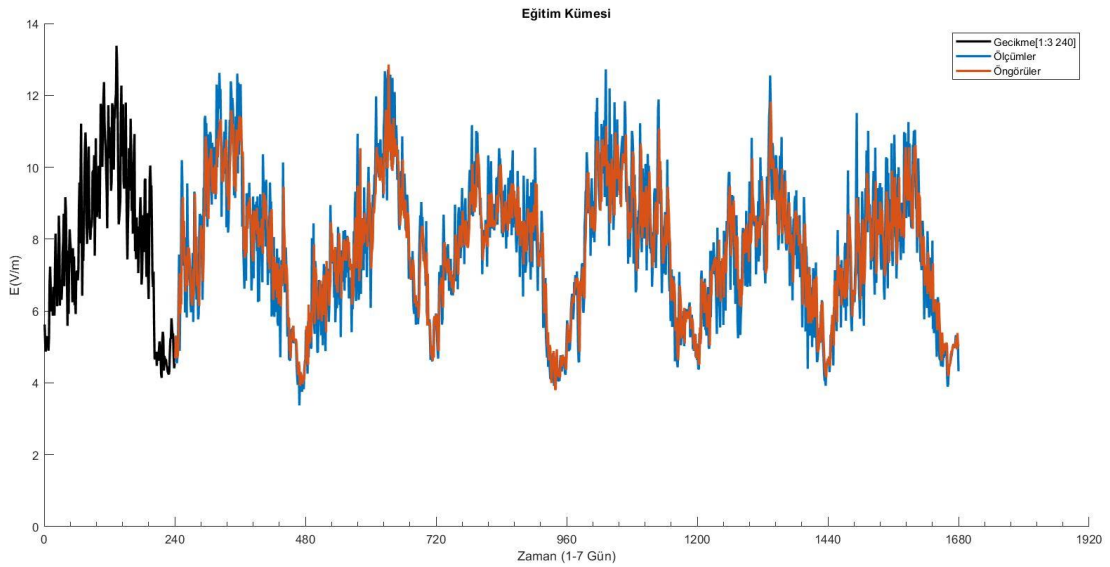
[3 5 3 2] modeli 4 girdi değişkenin olduğu ve her bir girdi değişkenin kaç üyelik fonksiyonuna sahip olduğunu temsil etmektedir. Ör: 1. girdi değişkeni için 3, 2. girdi değişkeni için 5, 3. girdi değişkeni için 3, 4. girdi değişkeni için 2 üyelik fonksiyonu bulunmaktadır.

Çıktı üyelik fonksiyonu sabit, girdi üyelik fonksiyonu gauss, üçgen ve çan eğrisi kullanılarak oluşturulan modellerde eğitim kümesi için HKOK değerleri sırasıyla 0.9711, 0.9849 ve 1.0374 OMYH değerleri sırasıyla 0.0997, 0.1013 ve 0.1056, test kümesi için HKOK değerleri sırasıyla 0.8270, 0.8311 ve 0.8315 OMYH değerleri sırasıyla 0.0895, 0.0904 ve 0.0920 olarak elde edilmiştir. Çıktı üyelik fonksiyonu

doğrusal, girdi üyelik fonksiyonu gauss, üçgen ve çan eğrisi kullanılarak oluşturulan modellerde eğitim kümesi için HKOK değerleri sırasıyla 1.0329, 0.9237 ve 1.0319 OMYH değerleri sırasıyla 0.1049, 0.0952 ve 0.1047, test kümesi için HKOK değerleri sırasıyla 0.8291, 0.8285 ve 0.8287 OMYH değerleri sırasıyla 0.0915, 0.0922 ve 0.0914 olarak elde edilmiştir.


Buna göre en başarılı öngörü en düşük HKOK, OMYH ve NHHKOK değerlerine sahip olan  $[3\ 5\ 3\ 2]_{\text{gaussmf,s}}$  modeline aittir. Modelin eğitim kümesinde %89.61, test kümesinde %88.81 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.13'te eğitim kümesi için ölçülen EMA değerleri ve  $[3\ 5\ 3\ 2]_{\text{gaussmf,s}}$  modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.13. ANFİS ile eğitim kümesi için ölçüm değerleri ile öngörülen değerlerin birlikte grafiği

Şekil 5.14'te test kümesi için ölçülen EMA değerleri ve  $[3\ 5\ 3\ 2]_{\text{gaussmf,s}}$  modeli ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.14. ANFİS ile test kümesi için ölçüm değerleri ile öngörülen değerlerin birlikte grafiği

Zaman serisinde bölünmüş çapraz doğrulama yöntemi ile 4. 5. 6. ve 7. günler ayrı ayrı test kümesi seçilerek  $[3\ 5\ 3\ 2]_{\text{gaussmf,s}}$  modelinin başarısı değerlendirilmiştir. Tablo 5.12’de seçilen test kümeleri için performans kriterleri olan HKOK ve doğruluk değerleri ve bu değerlerin ortalaması gösterilmiştir. Buna göre en iyi model olan  $[3\ 5\ 3\ 2]_{\text{gaussmf,s}}$  modeli %86.17 başarı ile öngörü yapmaktadır.

Tablo 5.12. ANFİS modeli çapraz doğrulama

							Eğitim	Test	HKOK	Doğruluk
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün	7.Gün	8.gün	⇒	0.8270	%88.81
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün	7.Gün		⇒	1.2167	%83.54
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün	6.Gün			⇒	1.0608	%85.66
1.Gün	2.Gün	3.Gün	4.Gün	5.Gün				⇒	1.1008	%85.11
1.Gün	2.Gün	3.Gün	4.Gün					⇒	0.9033	%87.75
Çapraz Doğrulama									1.0217	%86.17

SARIMA, HW-DGA, YSA ve ANFİS yöntemlerinin performans karşılaştırması tablo 5.13’te özetlenmiştir. Yöntemler karşılaştırılırken eğitim kümesine göre performans kıyaslaması yanıltıcı olabilmektedir. Şöyle ki eğitim kümesinde başarılı sonuçlar elde edilmesine rağmen benzer başarı test kümesinde sağlanmaz ise bu durum

akıllara aşırı uyum (overfittig) sorunu getirmektedir. Bu durumdan kaçınmak için performans kıyaslamasının test kümesi üzerinden yapılması daha doğru olacaktır.

Tablo 5.13. Doğrudan uygulama ile elde edilen sonuçlar

YÖNTEM	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
SARIMA	0.8505	1.2011	0.0818	0.1415	0.0850	0.1625	%91.50	%83.75
HW- DGA	1.0211	1.0119	0.1044	0.1164	0.1023	0.1369	%89.77	%86.31
YSA	0.9753	0.8177	0.1006	0.0892	0.1043	0.1106	%89.57	<b>%88.94</b>
ANFİS	0.9711	0.8270	0.0997	0.0895	0.1039	0.1119	%89.61	%88.81

Olasılığa dayalı yöntemler kendi içinde karşılaştırıldığında HW-DGA (%86.31) yönteminin, SARIMA (%83.75) yöntemine göre daha başarılı öngörülere sahip olduğu görülmektedir. Öğrenmeye dayalı yöntemlerde ise, YSA yöntemi kullanılarak kurulan modelin %88.94, ANFİS yöntemi ile kurulan modelin %88.81 doğrulukta öngörüler elde ettiği görülmektedir. Her iki yöntemle kurulan modelin öngörü başarılarının birbirine yakın ve yüksek olduğunu söylemek mümkündür.

## 2- Ayrıştırılarak uygulama

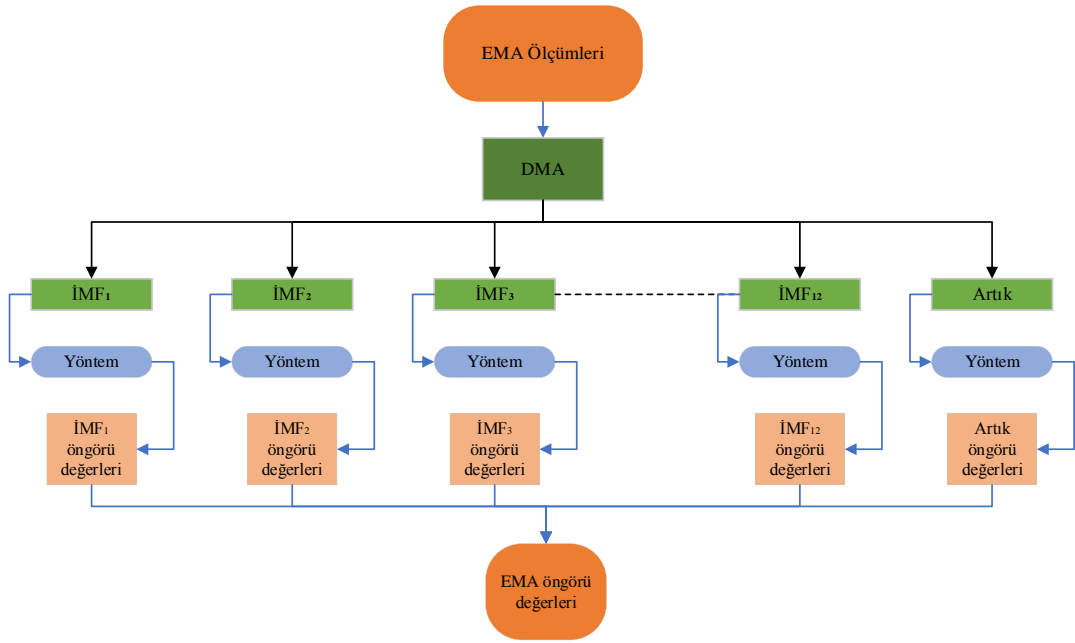
Bu aşamada orijinal zaman serisi yani ölçülen EMA değerleri öncelikle deneysel mod ayrıştırma yöntemi ile İMF bileşenlerine ayrılmaktadır. Daha sonra ayrıştırma işlemi ile elde edilen İMF bileşenlerinin her biri eğitim ve test kümesine ayrılmış ve hem YSA hem de ANFİS ile bileşenlerin öngörülere elde edilmiştir. Sonrasında öngörülere elde edilen bileşenler toplanarak EMA ölçüm değerlerinin öngörülere elde edilmiştir.

EMA ölçüm değerleri deneysel mod ayrıştırma yöntemi ile 12 İMF bileşeni ve artık şeklinde ayrılmaktadır. Ayrıştırma işlemi sonunda veri seti aşağıdaki eşitlik 5.7 ile ifade edilebilir.

$$EMA = \sum_{i=1}^{12} İMF_i + Artık \quad (5.7)$$

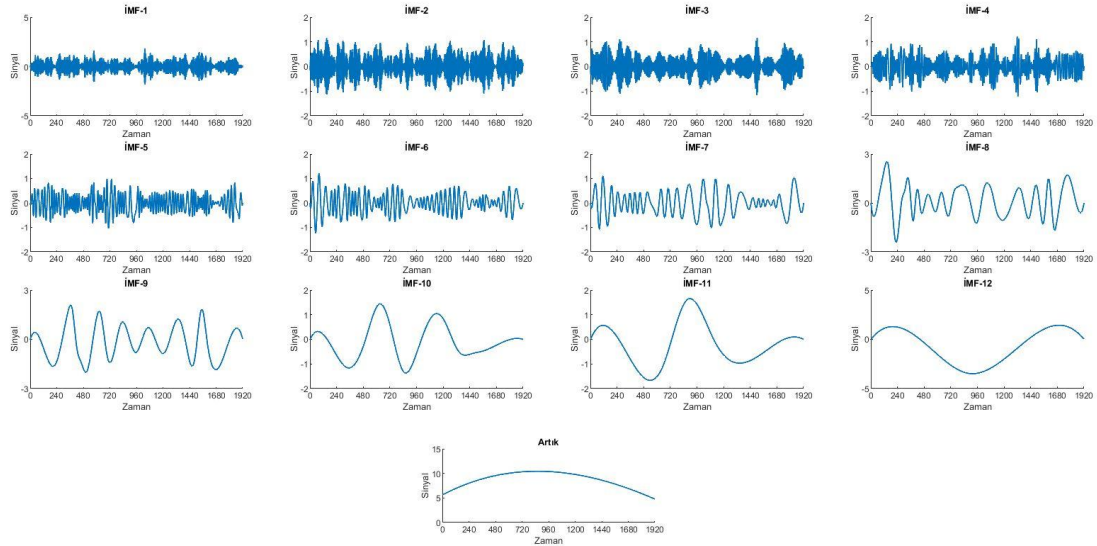
Burada 12 İMF bileşeni ile artık değerler toplandığında orijinal zaman serisi olan EMA ölçüm değerlerinin elde edildiği görülmektedir. Bu mantık ile her bir İMF bileşeni ve artık, veri setinin bir parçasını temsil etmektedir. EMA değerlerinin öngörülerini doğrudan elde etmek yerine bileşenler ve artık değerlerin öngörülere yapıldıktan sonra bu öngörü değerleri toplanarak da orijinal serinin öngörüsünü elde etmek mümkündür.

Bu çalışmada bileşenlerin öngöruları YSA ve ANFİS yöntemi ile elde edilmektedir. Şekil 5.15'te DMA yöntemi ile öngörü şeması yer almaktadır.



Şekil 5.15. DMA yöntemi ile öngörü şeması

Şekil 5.16'da DMA yöntemi ile elde edilen İMF bileşenlerinin ve artıkların zaman serisi grafikleri gösterilmektedir.



Şekil 5.16. DMA yöntemi ile elde edilen İMF bileşenleri ve artıkların zaman serisi grafiği

Ayrıştırma işlemi yapıldıktan sonra her bir bileşen artık da dahil eğitim ve test kümesine ayrılmıştır. İlk 7 günlük veri eğitim kümesini 8. gün ise test kümesini oluşturmaktadır.

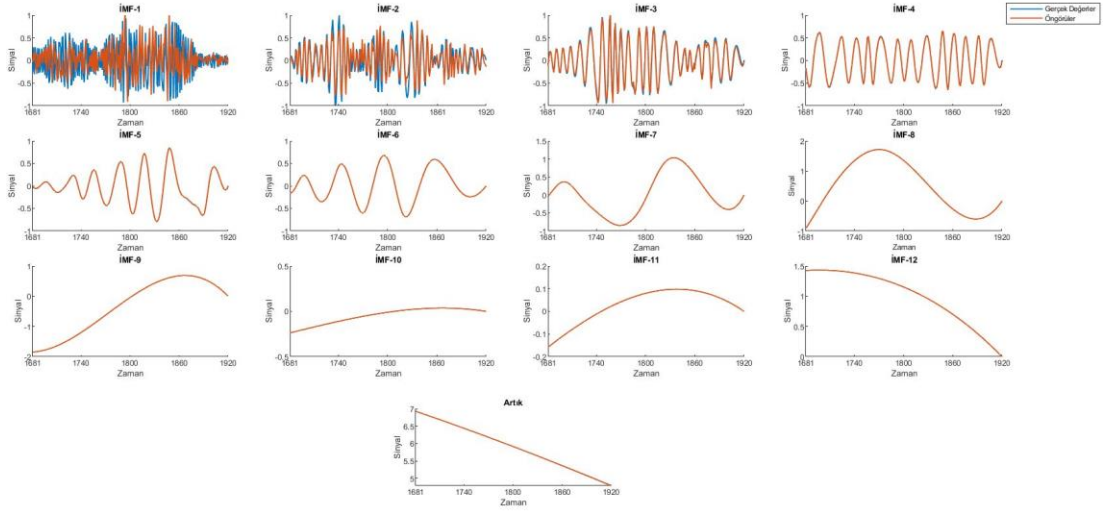
## DMA-YSA

DMA-YSA yönteminde kullanılan YSA modeli doğrudan uygulama sonucunda öngörü başarısı en yüksek olan [13-3-1]<sub>logs</sub> modelidir. Bu model ile her bir İMF bileşeni ve artık için ağ eğitilmiş ve test kümesi performansları değerlendirilmiştir. Tablo 5.14'te eğitim ve test kümesi için HKOK değerleri gösterilmiştir.

Tablo 5.14. İMF bileşenleri ve artığın öngörülerine ait HKOK değerleri

İçsel Mod Fonksiyonu	HKOK	
	Eğitim kümesi	Test kümesi
$\dot{IMF}_1$	0.4366	0.3467
$\dot{IMF}_2$	0.1926	0.1717
$\dot{IMF}_3$	0.0525	0.0585
$\dot{IMF}_4$	0.0143	0.0087
$\dot{IMF}_5$	0.0029	0.0016
$\dot{IMF}_6$	0.0005	0.0002
$\dot{IMF}_7$	0.0001	4.34E-05
$\dot{IMF}_8$	0.0000	0.0001
$\dot{IMF}_9$	3.27E-06	1.03E-06
$\dot{IMF}_{10}$	9.97E-06	8.88E-06
$\dot{IMF}_{11}$	1.30E-06	1.27E-06
$\dot{IMF}_{12}$	2.86E-06	0.0002
<i>Artık</i>	2.00E-06	0.0008

HKOK değerinin sıfıra yakınlığı öngörü başarısının çok yüksek olduğunu göstermektedir. Şekil 5.17'de test kümesi için, bileşenlerin gerçek değerleri ile öngörülerinin birlikte grafiği verilmiştir. Bu grafiklere göre öngörülerin gerçek değerler ile oldukça uyumlu olduğunu söyleyebiliriz.



Şekil 5.17. Test kümesi için İMF bileşenleri ve öngörülerinin birlikte grafiği

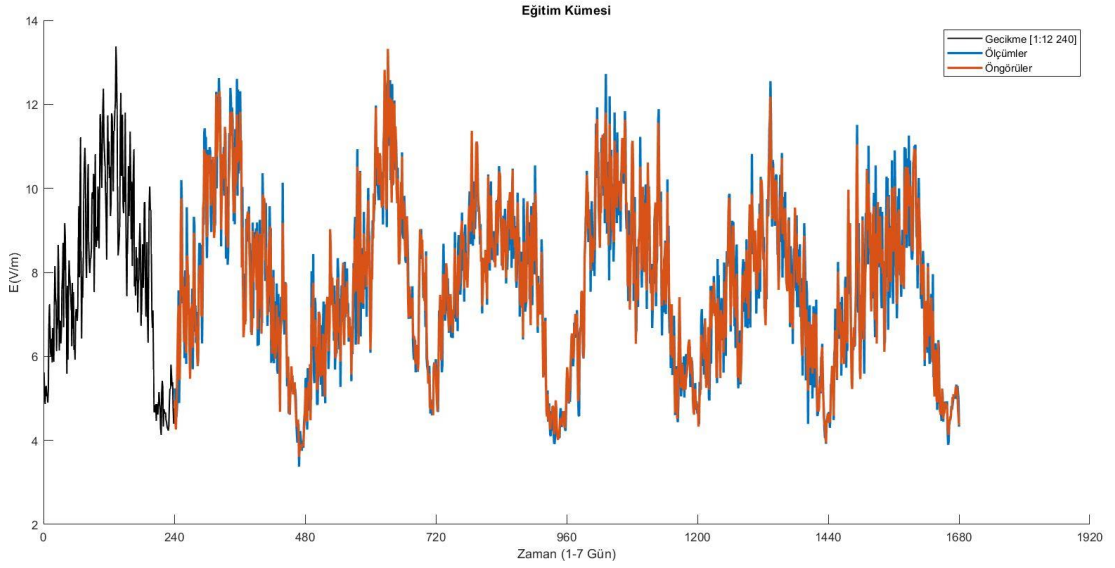
İMF bileşenleri ve artığın öngörülleri  $[13-3-1]_{\log s}$  YSA modeli ile elde edilmiştir. Bu öngörülerin toplamı orijinal zaman serisi verisi olan EMA ölçüm değerlerinin öngörüsünü oluşturmaktadır. Tablo 5.15'te EMA ölçüm değerlerinin DMA-YSA yöntemi ile öngörü performans sonuçları yer almaktadır.

Tablo 5.15. DMA-YSA modelinin öngörü performans sonuçları

DMA-YSA Modeli	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
$[13-3-1]_{\log s}$	0.4734	0.3943	0.0473	0.0409	0.0506	0.0533	%94.94	%94.67


DMA-YSA yöntemi ile elde edilen öngörülerin HKOK ve OMYH değerleri eğitim kümesi için sırasıyla 0.4734 ve 0.0473, test kümesi için sırasıyla 0.3943 ve 0.0439'dir. Modelin eğitim kümesinde %94.94, test kümesinde %94.67 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.18'de eğitim kümesi için ölçülen EMA değerleri ve DMA-YSA yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.18. Eğitim kümesi için ölçüm değerleri ile DMA-YSA yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği

Şekil 5.19'da test kümesi için ölçülen EMA değerleri ve DMA-YSA yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.19. Test kümesi için ölçüm değerleri ile DMA-YSA yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği

Şekil 5.18 ve şekil 5.19' da yer alan grafikler incelendiğinde ölçüm değerleri ile öngörü değerlerinin oldukça uyumlu olduğu görülmektedir.

### DMA-ANFİS

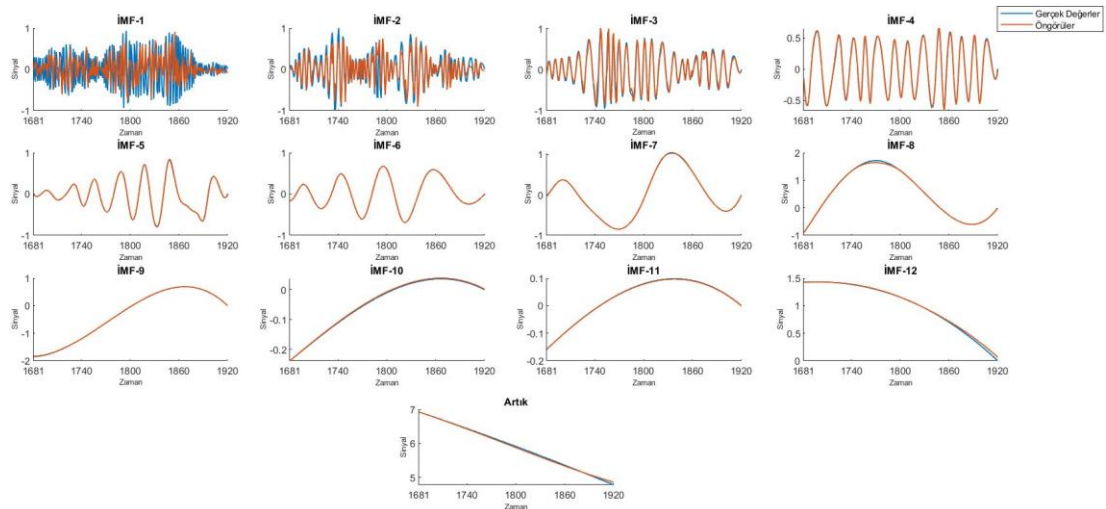
DMA-ANFİS uygularken öngörülerde kullanılan ANFİS modeli, ANFİS yaklaşımının veriye doğrudan uygulandığında öngörü başarısı en yüksek olan [3 5 3

2] $gaussmf_s$  modelidir. Bu model ile her bir İMF bileşeni ve artık için ağ eğitilmiş ve test kümesi performansları değerlendirilmiştir. Tablo 5.16’da eğitim ve test kümesi için HKOK değerleri gösterilmiştir.

Tablo 5.16. İMF bileşenleri ve artığın öngörülerine ait HKOK değerleri

İçsel Mod Fonksiyonu	HKOK	
	Eğitim kümesi	Test kümesi
$IMF_1$	0.2310	0.3507
$IMF_2$	0.1815	0.1959
$IMF_3$	0.0538	0.0796
$IMF_4$	0.0171	0.0157
$IMF_5$	0.0054	0.0053
$IMF_6$	0.0032	0.0016
$IMF_7$	0.0012	3.60E-03
$IMF_8$	0.0008	0.0231
$IMF_9$	8.20E-04	2.62E-03
$IMF_{10}$	4.90E-04	2.11E-03
$IMF_{11}$	3.77E-04	9.08E-04
$IMF_{12}$	3.81E-04	0.0219
Artık	1.94E-04	0.0272

HKOK değerinin sıfıra yakınlığı öngörü başarısının çok yüksek olduğunu göstermektedir. Şekil 5.20’de test kümesi için bileşenlerin gerçek değerleri ile öngörülerinin birlikte grafiği verilmiştir. Bu grafiklere göre öngörülerin gerçek değerler ile oldukça uyumlu olduğunu söyleyebiliriz.



Şekil 5.20. Test kümesi için İMF bileşenleri ve öngörülerinin birlikte grafiği


İMF bileşenleri ve artışın öngörüsü  $[3\ 5\ 3\ 2]_{\text{gaussmf},s}$  ANFİS modeli ile elde edilmiştir. Bu öngörülerin toplamı orijinal zaman serisi verisi olan EMA ölçüm değerlerinin öngörüsünü oluşturmaktadır. Tablo 5.17’de EMA ölçüm değerlerinin DMA-ANFİS yöntemi ile öngörü performans sonuçları yer almaktadır.

Tablo 5.17. DMA-ANFİS modelinin öngörü performans sonuçları

DMA-ANFİS Modeli	HKOK		OMYH		NHKOK		Doğruluk	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
$[3\ 5\ 3\ 2]_{\text{gaussmf},s}$	0.4563	0.3956	0.0460	0.0421	0.0488	0.0535	%95.12	%94.65


DMA-ANFİS yöntemi ile elde edilen öngörülerin HKOK ve OMYH değerleri eğitim kümesi için sırasıyla 0.4563 ve 0.0460, test kümesi için sırasıyla 0.3956 ve 0.0421’dir. Modelin eğitim kümesinde %95.12, test kümesinde %94.65 başarı ile öngörü yaptığı söylenebilir.

Şekil 5.21’de eğitim kümesi için ölçülen EMA değerleri ve DMA-ANFİS yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.21. Eğitim kümesi için ölçüm değerleri ile DMA-ANFİS yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği

Şekil 5.22’de test kümesi için ölçülen EMA değerleri ve DMA-ANFİS yöntemi ile öngörülen EMA değerlerinin birlikte grafiği gösterilmektedir.



Şekil 5.22. Test kümesi için ölçüm değerleri ile DMA-ANFİS yöntemi kullanılarak elde edilen öngörü değerlerinin birlikte grafiği





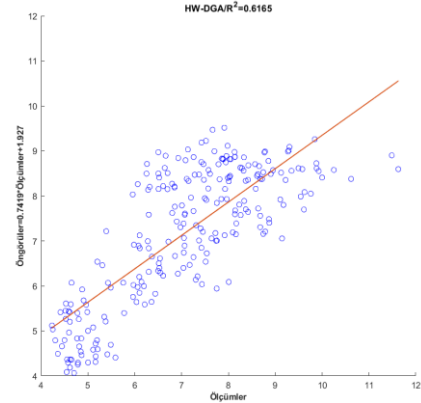



Şekil 5.21 ve şekil 5.22’ de yer alan grafikler incelendiğinde ölçüm değerleri ile öngörü değerlerinin oldukça uyumlu olduğu görülmektedir.

Uygulamada kullanılan yöntemlerin performans karşılaştırması tablo 5.18’ de özetlenmiştir. Ayrıca birinci aşamada önerilen HW-DGA yöntemi ile karşılaştırmak amacıyla literatürde kullanılan diğer Toplamsal (THW) ve Çarpımsal Holt Winters (ÇHW) yöntemine ait sonuçlar tabloya eklenmiştir.

Tablo 5.18. Yöntemlerin performans karşılaştırılması

Uygulama	YÖNTEM	HKOK		OMYH		NHKOK		Doğruluk	
		Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
Doğrudan	SARIMA	0.8505	1.2011	0.0818	0.1415	0.0850	0.1625	%91.50	%83.75
	THW	0.9351	1.1363	0.0956	0.1317	0.0934	0.1537	%90.66	%84.63
	ÇHW	1.0164	1.2804	0.1034	0.1485	0.1016	0.1732	%89.84	%82.68
	HW- DGA	1.0211	1.0119	0.1044	0.1164	0.1023	0.1369	%89.77	%86.31
	YSA	0.9753	0.8177	0.1006	0.0892	0.1043	0.1106	%89.57	%88.94
	ANFİS	0.9711	0.8270	0.0997	0.0895	0.1039	0.1119	%89.61	%88.81
Ayrıştırılarak	DMA-YSA	0.4734	0.3943	0.0473	0.0409	0.0506	0.0533	%94.94	<b>%94.67</b>
	DMA-ANFİS	0.4563	0.3956	0.0460	0.0421	0.0488	0.0535	%95.12	%94.65

Şekil 5.23’te test kümesi için ölçülen EMA değerleri ve yöntemlerden elde edilen öngörülerin regresyon grafikleri gösterilmektedir.



Şekil 5.23. Test kümesi için yöntemlerden elde edilen öngörülerin gerçek EMA değerleri ile regresyonu

Şekil 5.23'te yer alan grafikler incelendiğinde ölçüm değerleri ile DMA-YSA ( $R^2 = 0.9392$ ) ve DMA-ANFİS ( $R^2 = 0.9359$ ) yöntemlerinden elde edilen öngörülerin diğer yöntemlere göre oldukça iyi performans sergilediği gözlenmektedir.

SARIMA yöntemi eğitim kümesinde THW, ÇHW, HW-DGA, YSA ve ANFİS yöntemlerine göre daha başarılı öngörü değerlerine sahip olmasına rağmen bu performansı test kümesinde gösteremediği görülmektedir.

Holt Winters yönteminde, literatürde diğer klasik yöntemler ile parametre ve başlangıç değerleri hesaplandığında öngörülerin THW yönteminde %84.63, ÇHW yönteminde %82.68 doğrulukta başarı sağladığı görülmektedir. Holt Winters yönteminde kullanılan parametreler ve başlangıç değerlerinin DGA ile elde edilmesi durumunda ise öngörülerin %86.31 doğrulukta başarı sağladığı görülmektedir.

YSA yöntemi kullanıldığında %88.94, ANFİS yöntemi kullanıldığında %88.81 başarı ile öngörü elde edildiği görülmektedir. Her iki öğrenmeye dayalı yönteminde öngörü başarısı birbirlerine yakın ve diğer yöntemlerden de yüksek çıkmıştır.

DMA yöntemi ile bileşenlere ayrıştırma işleminden sonra, YSA yöntemi ile öngörülerin elde edilmesi durumunda %94.67, ANFİS yöntemi ile öngörülerin elde edilmesi durumunda %94.65 doğrulukta başarı sağlandığı görülmektedir.

## 6. SONUÇ VE ÖNERİLER

Baz istasyonları sayısının artmasıyla birlikte canlılar gün geçtikçe daha fazla elektromanyetik radyasyona (EMR) maruz kalmaktadırlar. EMR, elektromanyetik kirliliğin sağlık üzerine olumsuz etkisinin en fazla olduğu elektromanyetik alanlar (EMA)'da oluşmaktadır. Başta sağlık ve mühendislik olmak üzere EMA'nın kısa ve uzun vadede etkilerini araştıran birçok çalışma yapılmaktadır. Özellikle gelişen teknolojinin bizlere sunduğu kablolu ve kablosuz sistemler maruz kalınan EMR'yi her geçen gün artırmaktadır. Bununla beraber bu sistemlerin hayatımızı kolaylaştırdığı yadsınamaz bir gerçektir. Her ne kadar bu sistemler canlılar üzerinde olumsuz etkiye sahip olsa da hayatımızdan tamamı ile çıkarmak günümüzde ve gelecekte mümkün görünmemektedir. Fakat bu cihazların olası zararlarını kontrol altına alarak elektromanyetik kirliliği en aza indirmenin yollarını aramak gereklidir. Bu bağlamda bir ortamda bulunan EMA miktarının gözlenmesi, modellenmesi ve öngörüle bulunulması önem arz etmektedir. Bu amaçla, Samsun ilinde bir baz istasyonunu doğrudan gören ve sabit bir konuma yerleştirilen ölçüm cihazı ile 8 gün boyunca elektrik alan şiddeti (EMA-(V/m)) ölçümleri kaydedilmiş ve zaman serisi analiz yöntemleri ile modellenmiştir.

EMA ölçümlerinin zaman serisi grafiği incelenmiş ve periyodu (s)240 olan mevsimsel hareket sergilediği gözlenmiştir. Bu sebeple öngörü elde etmek için mevsimselliği göz önünde bulunduran yöntemler uygulamada tercih edilmiştir.

Veriye yöntemlerin uygulama şekli iki türlü yapılmıştır. Öncelikle öngörüler doğrudan zaman serisi üzerine uygulanan yöntemler ile elde edilirken, sonrasında DMA yöntemi ile ayrıştırılan bileşenleri ayrı ayrı modelleyen yöntemler ile elde edilmiştir.

İlk uygulamada düzleştirme parametreleri ve başlangıç değerlerinin DGA ile optimize edildiği hibrit bir yöntem olan HW-DGA yöntemi ile öngörüler elde edilmiştir. Bu sonuçlar SARIMA ve klasik HW yöntemleri ile karşılaştırılmış ve HW-DGA yönteminin daha başarılı sonuçlar verdiği görülmüştür. Ancak bu ilk uygulamada kullanılan YSA ve ANFİS yöntemleri bu yöntemden de daha iyi sonuçlar vermiştir. Bu iki yaklaşımın sunduğu sonuçlar birbirlerine yakın olmasına rağmen YSA ile elde edilen sonuç daha iyidir. Bu değerlendirmelerin tamamı test kümesi dikkate alınarak yapılmıştır.

Deneyisel mod ayrıştırması yapılarak seri bileşenlere ayrıldıktan sonra DMA-YSA ve DMA-ANFİS yöntemleri kullanılmıştır. Buradan elde edilen öngörü performansları veri ayrıştırılmadan önce uygulanan YSA ve ANFİS yöntemlerinden elde edilen öngörü performansları ile karşılaştırılmıştır. Bu karşılaştırma sonrasında DMA-YSA ve DMA-ANFİS yöntemlerinden elde edilen sonuçların daha başarılı olduğu gözlenmiştir.

Elektrik alan şiddeti üzerine yapılan en yakın tarihli çalışma Kurnaz ve Korunur Engiz (2018) tarafından yapılmıştır. Bu makalede veriye tek değişkenli zaman serisi analizi kapsamında yer alan Box-Jenkins (1970) metodolojisi uygulanarak en uygun ARIMA modeli bulunmuştur.

Bu tez çalışmasında ise yine farklı bir ortamda ölçülen elektrik alan şiddeti için zaman serisi ele alınmıştır. Bu veri seti mevsimsellik dikkate alınarak daha önce hiç uygulanmamış güncel zaman serisi analizlerinin dahil edildiği kapsamlı bir çalışma gerçekleştirilmiştir. 8 farklı güncel yaklaşım veriye uygulanarak test kümesi öngörü performansları karşılaştırılmış, en uygun model seçimi yapılmıştır.

Önerilen hibrit ve aşamalı yöntemler, farklı yapay zeka teknikleri ile birleştirilerek öngörü performansının artırılıp artırılamayacağı yeni çalışmalara konu olacak şekilde araştırılabilir.

## KAYNAKÇA

- Abadan, S. and Shabri, A. (2014). *Hybrid empirical mode decomposition-ARIMA for forecasting price of rice*. Applied Mathematical Sciences, 8(63), 3133-3143.
- Assaad, R. H. and Fayek, S. (2021). Predicting the price of crude oil and its fluctuations using computational econometrics: deep learning, LSTM, and convolutional neural networks. *Econometric Research in Finance*, 6(2), 119-137.
- Awajan, A. M., Ismail, M. T., and Wadi, S. A. (2017). *Forecasting time series using emd-hw bagging*. International Journal of Statistics and Economics, 18(3), 9-21.
- Barbosh, M., Singh, P., and Sadhu, A. (2020). *Empirical mode decomposition and its variants: A review with applications in structural health monitoring*. Smart Materials and Structures, 29(9), 093001.
- Box, G. E. P and Jenkins, G. M (1970). *Time Series Analysis, Forecasting and Control*, Holden Day.
- Brown, R. G., 1959. *Statistical forecasting for inventory control*. New York McGrawHill.
- Chakraborty, U. K. (Ed.). (2008). *Advances in differential evolution* (Vol. 143). Springer.
- Chen, C. F., Lai, M. C., and Yeh, C. C. (2012). *Forecasting tourism demand based on empirical mode decomposition and neural network*. Knowledge-Based Systems, 26, 281-287.
- Chen, F., Li, S., Li, C., Liu, M., Li, Z., Xue, H., ... and Wang, J. (2015). *A novel method for speech acquisition and enhancement by 94 GHz millimeter-wave sensor*. Sensors, 16(1), 50.
- Eğrioğlu, E., Yolcu, U. ve Baş, E. (2019). *Yapay sinir ağları: öngörü ve tahmin uygulamaları* (1. Basım). Nobel Akademik Yayıncılık, Ankara
- Ghide, L., Wei, S., and Ding, Y. (2022). *Comparative Study of Wavelet-SARIMA and EMD-SARIMA for Forecasting Daily Temperature Series*. International Journal of Analysis and Applications, 20, 17-17.
- Hamzaçebi, C., (2021). *Matlab uygulamalı Yapay Sinir Ağları*. Seçkin Yayıncılık San. ve Tic. A. Ş., Ankara.
- Hamzaçebi, Ç. (2011). *Yapay sinir ağları: tahmin amaçlı kullanımı MATLAB ve Neurosolutions uygulamalı*. Ekin Basım Yayın Dağıtım.
- Holt, C. C. (1957). *Forecasting seasonals and trends by exponentially weighted averages*. O.N.R. Memorandum 52/1957, Carnegie Institute of Technology. Reprinted with discussion in 2004. International Journal of Forecasting, 20, 5 – 13.
- Huang, N. E., Shen, Z. ve Long, S. R. (1999). *A New View of Nonlinear Water Waves The Hilbert Spectrum*. Ann. Rev. Fluid Mech. 31(-): 417-457.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C. ve Liu, H. H. (1998). *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*. Proc. Roy. Soc. Lond. 454(A): 903-993
- Huang, N. E., Wu, M. L., Long, S. R., Shen, S. S., Qu, W., Gloersen, D. P. ve Fan, K. L. (2003b). *A confidence limit for the Empirical Mode Decomposition and Hilbert Spectral Analysis*. Proc. Roy. Soc. London. 459A(-): 2317-2345.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.

- Jothimani, D., Shankar, R., and Yadav, S. S. (2015). *A hybrid EMD-ANN model for stock price prediction*. In International conference on swarm, evolutionary, and memetic computing (pp. 60-70). Springer, Cham.
- Kadılar, C., Çekim, H. Ö. (2020). *SPSS ve R Uygulamalı Zaman Serileri Analizine Giriş*. Seçkin Yayıncılık San. ve Tic. A. Ş., Ankara.
- Karaboğa, D. (2007). *Yapay Zeka Optimizasyon Algoritmaları*. Nobel Akademik Yayıncılık, 245.
- Keskintürk, T. (2006). *Diferansiyel gelişim algoritması*. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 5(9), 85-99.
- Kılıç Topal K., Uslu V. R., Demirci M. A. (2016). *Üçlü Üstel Düzleştirme Yönteminde Düzleştirme Parametrelerinin Diferansiyel Gelişim Algoritması ile Tahmini*. Xth International Statistics Days Conference (Özet Bildiri/Sözlü Sunum)(Yayın No:3406637).
- Kohonen, T. (1982). *Self-organized formation of topologically correct feature maps*. Biological cybernetics, 43(1), 59-69.
- Kurnaz, C., Yıldız, D. ve Karagol, S. (2018). Assessment of short/long term electric field strength measurements for a pilot district. Open Physics, 16(1), 69-74.
- Kurnaz, Ç. ve Korunur Engiz, B. (2018). Bir ortamdaki elektrik alan şiddetinin zaman serisi analizi ile belirlenmesi. International Journal of Engineering Research and Development, 10(2), 29-35.
- Kutlar, A. (2007). *Ekonometriye giriş*. Nobel Yayın Dağıtım.
- Levenberg, K. (1944). *A method for the solution of certain non-linear problems in least squares*. Quarterly of applied mathematics, 2(2), 164-168.
- Liu, H., Chen, C., Tian, H. Q., and Li, Y. F. (2012). *A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks*. Renewable energy, 48, 545-556.
- Liu, H., Tian, H. Q., and Li, Y. F. (2015). *An EMD-recursive ARIMA method to predict wind speed for railway strong wind warning system*. Journal of Wind Engineering and Industrial Aerodynamics, 141, 27-38.
- Makridakis, S., Wheelwright, S.C., Hyndman, R.J., (1998). *Forecasting: methods and applications*, Third ed. Wiley, New York.
- Marquardt, D. W. (1963). *An algorithm for least-squares estimation of nonlinear parameters*. Journal of the society for Industrial and Applied Mathematics, 11(2), 431-441.
- McCulloch, W. S., and Pitts, W. (1943). *A logical calculus of the ideas immanent in nervous activity*. The bulletin of mathematical biophysics, 5(4), 115-133.
- Minsky, M. and Papert, S. A. *Perceptrons: an Introduction to Computational Geometry* (The MIT Press, 1969).
- Nai, W., Liu, L., Wang, S., and Dong, D. (2017). *An EMD–SARIMA-based modeling approach for air traffic forecasting*. Algorithms, 10(4), 139.
- Okolobah, V. A., and Ismail, Z. (2013). *New approach to peak load forecasting based on EMD and ANFIS*. Indian Journal of Science and Technology, 6(12), 5600-6.
- Öztemel, E. (2020). *Yapay sinir ağları*. Papatya Yayıncılık, İstanbul.
- Rosenblatt, F. (1958). *The perceptron: a probabilistic model for information storage and organization in the brain*. Psychological review, 65(6), 386.

- Rumelhart, D. E., Hinton, G. E., and McClelland, J. L. (1986). *A general framework for parallel distributed processing*. *Parallel distributed processing: Explorations in the microstructure of cognition*, 1(45-76), 26.
- Storn, R., and Price, K. (1995). *DE—a simple and efficient adaptive scheme for global optimization over continuous space*. Technical report, 25(6), 95-102.
- Storn, R., and Price, K. (1996). *Minimizing the real functions of the ICEC'96 contest by differential evolution*. In *Proceedings of IEEE international conference on evolutionary computation* (pp. 842-844). IEEE.
- Storn, R. (1996). *On the usage of differential evolution for function optimization*. In *Proceedings of north american fuzzy information processing* (pp. 519-523). Ieee.
- Storn, R., and Price, K. (1997a). *Differential evolution a simple evolution strategy for fast optimization*. *Dr. Dobb's journal*, 22(4), 18-24.
- Storn, R., and Price, K. (1997b). *Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces*. *Journal of global optimization*, 11(4), 341-359.
- Widrow, B., and Hoff, M. E. (1960). *Adaptive switching circuits*. Stanford Univ Ca Stanford Electronics Labs.
- Wang, H., Liu, L., Qian, Z., Wei, H., and Dong, S. (2014). *Empirical mode decomposition—autoregressive integrated moving average: hybrid short-term traffic speed prediction model*. *Transportation Research Record*, 2460(1), 66-76.
- Winters, P. R. (1960). *Forecasting sales by exponentially weighted moving averages*. *Management Science*, 6, 324–342.
- Wu, Z. ve Huang, N. E. (2004). *A study of the characteristics of white noise using the empirical mode decomposition method*. *Proc. Roy. Soc. London*. 460A: 1597- 1611
- Yang, J. N., Lei, Y., Lin, S., and Huang, N. (2004). *Hilbert-Huang based approach for structural damage detection*. *Journal of engineering mechanics*, 130(1), 85-95.
- Yılmaz, A. (2020). *Yapay Zeka*. KODLAB Yayinevi, 373.

## EKLER

### EK 1: SARIMA modeli ile elde edilen tüm sonuçlar

<b>D=1: AIC ve BIC değerleri</b>							
(P,1,Q) (p,0,q)	Bilgi Kriteri	(1,1,0)	(2,1,0)	(3,1,0)	(1,1,1)	(2,1,1)	(3,1,1)
(0,0,1)	AIC	5467.01	4837.18	4837.18	5292.00	4839.11	4835.55
	BIC	5487.37	4861.51	4864.66	5317.45	4868.31	4867.60
(0,0,2)	AIC	5282.92	4718.95	4715.67	5120.07	4720.95	4713.53
	BIC	5308.37	4748.15	4747.73	5150.61	4755.01	4750.16
(0,0,3)	AIC	5217.71	4689.28	4683.46	5063.66	4691.24	4681.22
	BIC	5248.25	4723.35	4720.09	5099.29	4730.18	4722.44
(1,0,0)	AIC	5098.38	4643.29	4639.96	4971.64	4645.20	4639.98
	BIC	5118.74	4667.62	4667.43	4997.09	4674.40	4672.03
(2,0,0)	AIC	5073.30	4619.47	4461.36	4944.69	4621.32	4463.13
	BIC	5098.75	4648.67	4493.41	4975.23	4655.39	4499.77
(3,0,0)	AIC	5039.01	4607.09	4450.17	4922.96	4609.07	4452.15
	BIC	5069.55	4641.16	4486.80	4958.59	4648.01	4493.37
(1,0,1)	AIC	5051.24	4605.33	4431.28	4926.51	4606.95	4433.28
	BIC	5076.69	4634.53	4463.34	4957.05	4641.02	4469.91
(2,0,1)	AIC	4991.98	4578.83	4413.05	4877.59	4580.79	4415.02
	BIC	5022.52	4612.90	4449.68	4913.22	4619.73	4456.23
(3,0,1)	AIC	4993.02	4580.75	4406.90	4879.53	4582.69	4408.90
	BIC	5028.66	4619.68	4448.11	4920.25	4626.50	4454.69
(1,0,2)	AIC	4999.67	4585.47	4421.57	4888.83	4587.44	4423.53
	BIC	5030.21	4619.54	4458.21	4924.46	4626.37	4464.75
(2,0,2)	AIC	4992.82	4580.75	4408.06	4879.52	4582.69	4410.06
	BIC	5028.45	4619.68	4449.28	4920.24	4626.50	4455.86
(3,0,2)	AIC	4994.60	4572.30	4401.09	4876.80	4574.17	4403.07
	BIC	5035.33	4616.10	4446.88	4922.61	4622.84	4453.45
(1,0,3)	AIC	4994.13	4580.92	4408.91	4880.96	4582.86	4410.90
	BIC	5029.76	4619.86	4450.12	4921.68	4626.66	4456.70
(2,0,3)	AIC	4994.25	4582.72	4408.66	4881.45	4570.54	4410.56
	BIC	5034.97	4626.52	4454.45	4927.26	4619.21	4460.93
(3,0,3)	AIC	4988.19	4570.29	4401.91	4875.51	4572.28	4403.90
	BIC	5034.00	4618.96	4452.28	4926.41	4625.82	4458.85

<b>D=1: AIC ve BIC değerleri</b>						
$(P,1,Q)$ $(p,0,q)$	Bilgi Kriteri	(1,1,2)	(2,1,2)	(3,1,2)	(1,1,3)	(2,1,3)
(0,0,1)	AIC	5143.51	4829.71	4803.58	5070.97	4526.47
	BIC	5174.05	4863.78	4840.21	5101.51	4565.40
(0,0,2)	AIC	4943.45	4714.05	4679.49	4892.37	4404.37
	BIC	4979.08	4752.99	4720.70	4928.00	4448.18
(0,0,3)	AIC	4873.78	4686.58	4648.32	4831.18	4373.00
	BIC	4914.50	4730.39	4694.12	4871.90	4421.67
(1,0,0)	AIC	4783.39	4640.08	4516.61	4752.11	4329.09
	BIC	4813.93	4674.15	4553.24	4782.65	4368.02
(2,0,0)	AIC	4727.66	4617.62	4444.37	4702.23	4301.11
	BIC	4763.29	4656.55	4485.59	4737.87	4344.91
(3,0,0)	AIC	4710.90	4605.00	4431.95	4686.18	4290.60
	BIC	4751.62	4648.80	4477.75	4726.91	4339.27
(1,0,1)	AIC	4700.21	4603.26	4414.33	4676.69	4286.26
	BIC	4735.85	4642.20	4455.55	4712.32	4330.06
(2,0,1)	AIC	4668.22	4577.01	4393.67	4644.59	4255.87
	BIC	4708.94	4620.81	4439.46	4685.31	4304.54
(3,0,1)	AIC	4668.55	4579.00	4390.65	4645.44	4256.51
	BIC	4714.36	4627.67	4441.02	4691.25	4310.05
(1,0,2)	AIC	4679.07	4582.67	4401.99	4654.76	4267.71
	BIC	4719.79	4626.47	4447.78	4695.48	4316.38
(2,0,2)	AIC	4668.71	4579.01	4391.33	4645.61	4256.46
	BIC	4714.52	4627.67	4441.70	4691.42	4310.00
(3,0,2)	AIC	4660.17	4569.92	4384.16	4636.84	4247.40
	BIC	4711.07	4623.46	4439.11	4687.74	4305.81
(1,0,3)	AIC	4670.25	4578.62	4391.67	4646.53	4258.82
	BIC	4716.06	4627.29	4442.04	4692.34	4312.36
(2,0,3)	AIC	4663.70	4564.30	4389.62	4639.27	4249.76
	BIC	4714.60	4617.84	4444.57	4690.17	4308.16
(3,0,3)	AIC	4661.88	4566.26	4385.91	4638.22	4248.67
	BIC	4717.87	4624.66	4445.44	4694.21	4311.94

<b>D=0: AIC ve BIC deęerleri</b>							
$(P,0,Q)$ $(p,0,q)$	Bilgi Kriteri	(1,0,0)	(2,0,0)	(3,0,0)	(1,0,1)	(2,0,1)	(3,0,1)
(0,0,1)	AIC	5752.28	5369.80	4815.51	5256.85	5146.19	4817.49
	BIC	5773.37	5395.25	4844.71	5283.21	5176.73	4851.55
(0,0,2)	AIC	5453.88	5169.35	4694.56	5056.94	4967.27	4696.54
	BIC	5480.24	5199.89	4728.63	5088.58	5002.90	4735.48
(0,0,3)	AIC	5322.58	5091.65	4662.04	4980.60	4902.38	4663.96
	BIC	5354.21	5127.28	4700.97	5017.50	4943.10	4707.76
(1,0,0)	AIC	4980.41	4921.44	4923.37	4809.97	4778.71	4612.89
	BIC	5001.50	4946.89	4952.57	4836.33	4809.25	4646.96
(2,0,0)	AIC	4887.55	4866.21	4582.00	4752.03	4721.57	4583.82
	BIC	4913.91	4896.75	4616.07	4783.67	4757.20	4622.75
(3,0,0)	AIC	4836.32	4818.13	4773.70	4685.77	4679.22	4567.34
	BIC	4867.95	4853.76	4812.63	4722.68	4719.94	4611.14
(1,0,1)	AIC	4818.69	4811.17	4560.93	4667.93	4664.69	4562.39
	BIC	4845.05	4841.71	4595.00	4699.56	4700.32	4601.32
(2,0,1)	AIC	4761.53	4743.96	4522.25	4634.74	4608.33	4524.18
	BIC	4793.17	4779.59	4561.19	4671.65	4649.05	4567.98
(3,0,1)	AIC	4763.53	4745.75	4524.05	4617.63	4610.25	4526.01
	BIC	4800.44	4786.47	4567.85	4659.81	4656.06	4574.68
(1,0,2)	AIC	4770.01	4753.29	4531.53	4622.05	4615.44	4533.50
	BIC	4801.64	4788.92	4570.47	4658.96	4656.16	4577.30
(2,0,2)	AIC	4763.53	4745.69	4524.07	4617.60	4610.20	4526.03
	BIC	4800.44	4786.41	4567.88	4659.78	4656.01	4574.70
(3,0,2)	AIC	4760.32	4743.30	4516.20	4615.24	4607.83	4518.19
	BIC	4802.50	4789.11	4564.87	4662.69	4658.73	4571.73
(1,0,3)	AIC	4764.27	4746.68	4524.76	4617.67	4610.06	4526.73
	BIC	4801.18	4787.40	4568.56	4659.85	4655.87	4575.40
(2,0,3)	AIC	4760.14	4742.00	4526.06	4619.55	4612.00	4516.92
	BIC	4802.32	4787.81	4574.73	4667.00	4662.91	4570.45
(3,0,3)	AIC	4760.12	4741.67	4515.72	4615.02	4607.31	4517.58
	BIC	4807.57	4792.57	4569.26	4667.74	4663.30	4575.99

<b>D=0: AIC ve BIC deęerleri</b>						
$(P,0,Q)$ $(p,0,q)$	Bilgi Kriteri	(1,0,2)	(2,0,2)	(3,0,2)	(1,0,3)	(2,0,3)
(0,0,1)	AIC	5230.93	4985.66	4813.43	5225.13	4931.46
	BIC	5262.56	5021.29	4852.37	5262.03	4972.18
(0,0,2)	AIC	5039.68	4779.66	4694.11	5033.14	4745.05
	BIC	5076.59	4820.38	4737.91	5075.32	4790.86
(0,0,3)	AIC	4967.55	4705.07	4663.14	4962.31	4678.63
	BIC	5009.72	4750.88	4711.81	5009.76	4729.53
(1,0,0)	AIC	4806.83	4581.40	4604.23	4806.92	4573.04
	BIC	4838.47	4617.03	4643.16	4843.83	4613.76
(2,0,0)	AIC	4753.78	4504.51	4525.29	4732.76	4500.59
	BIC	4790.69	4545.23	4569.09	4774.94	4546.40
(3,0,0)	AIC	4707.16	4469.72	4472.97	4704.17	4468.08
	BIC	4749.34	4515.53	4521.64	4751.63	4518.98
(1,0,1)	AIC	4679.54	4444.35	4443.42	4677.73	4443.21
	BIC	4716.44	4485.07	4487.23	4719.91	4489.02
(2,0,1)	AIC	4616.27	4396.60	4386.94	4632.71	4395.64
	BIC	4658.45	4442.41	4435.61	4680.16	4446.54
(3,0,1)	AIC	4618.25	4398.53	4388.44	4634.11	4397.53
	BIC	4665.70	4449.44	4441.97	4686.84	4453.52
(1,0,2)	AIC	4645.04	4404.03	4530.84	4641.56	4422.18
	BIC	4687.22	4449.84	4579.51	4689.01	4473.08
(2,0,2)	AIC	4618.22	4398.59	4388.49	4634.19	4397.61
	BIC	4665.68	4449.49	4442.03	4686.92	4453.60
(3,0,2)	AIC	4634.04	4390.73	4381.05	4630.06	4389.57
	BIC	4686.76	4446.72	4439.45	4688.06	4450.65
(1,0,3)	AIC	4639.12	4397.11	4397.05	4619.30	4418.50
	BIC	4686.57	4448.01	4450.59	4672.02	4474.49
(2,0,3)	AIC	4615.18	4390.53	4374.05	4616.29	4389.70
	BIC	4667.90	4446.52	4432.45	4674.29	4450.78
(3,0,3)	AIC	4622.17	4390.77	4375.56	4640.22	4389.76
	BIC	4680.16	4451.85	4438.83	4703.49	4455.93

**EK 2. HW-DGA yöntemi ile en iyi sonucu veren kromozoma ait değerler**

Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer
$\alpha$	0.7346	$I_{-215}$	0.9388	$I_{-188}$	1.1307	$I_{-161}$	1.3099	$I_{-134}$	1.3699
$\gamma$	0.0029	$I_{-214}$	0.9029	$I_{-187}$	1.3511	$I_{-160}$	1.2263	$I_{-133}$	1.3943
$\beta$	0.3354	$I_{-213}$	0.9709	$I_{-186}$	1.3161	$I_{-159}$	1.2460	$I_{-132}$	1.3194
$I_{-239}$	0.6912	$I_{-212}$	0.9122	$I_{-185}$	1.3077	$I_{-158}$	1.3475	$I_{-131}$	1.3071
$I_{-238}$	0.6574	$I_{-211}$	0.8941	$I_{-184}$	1.4062	$I_{-157}$	1.2776	$I_{-130}$	1.3293
$I_{-237}$	0.6200	$I_{-210}$	0.8918	$I_{-183}$	1.2664	$I_{-156}$	1.2822	$I_{-129}$	1.2715
$I_{-236}$	0.6427	$I_{-209}$	0.9166	$I_{-182}$	1.2539	$I_{-155}$	1.1636	$I_{-128}$	1.2925
$I_{-235}$	0.7085	$I_{-208}$	0.9300	$I_{-181}$	1.1837	$I_{-154}$	1.0597	$I_{-127}$	1.2029
$I_{-234}$	0.7258	$I_{-207}$	0.9808	$I_{-180}$	1.1025	$I_{-153}$	1.2325	$I_{-126}$	1.2779
$I_{-233}$	0.7990	$I_{-206}$	1.0273	$I_{-179}$	1.0948	$I_{-152}$	1.2622	$I_{-125}$	1.3268
$I_{-232}$	0.8553	$I_{-205}$	1.0932	$I_{-178}$	1.2950	$I_{-151}$	1.2337	$I_{-124}$	1.2978
$I_{-231}$	0.8062	$I_{-204}$	1.1730	$I_{-177}$	1.2795	$I_{-150}$	1.2933	$I_{-123}$	1.3832
$I_{-230}$	0.7982	$I_{-203}$	1.1919	$I_{-176}$	1.2891	$I_{-149}$	1.3231	$I_{-122}$	1.3354
$I_{-229}$	0.8268	$I_{-202}$	1.1186	$I_{-175}$	1.3446	$I_{-148}$	1.2480	$I_{-121}$	1.3000
$I_{-228}$	0.9149	$I_{-201}$	1.1327	$I_{-174}$	1.2934	$I_{-147}$	1.2401	$I_{-120}$	1.3794
$I_{-227}$	1.0364	$I_{-200}$	1.0767	$I_{-173}$	1.2528	$I_{-146}$	1.1912	$I_{-119}$	1.3587
$I_{-226}$	1.0006	$I_{-199}$	1.0332	$I_{-172}$	1.2428	$I_{-145}$	1.2807	$I_{-118}$	1.4151
$I_{-225}$	0.9934	$I_{-198}$	1.0323	$I_{-171}$	1.3083	$I_{-144}$	1.3142	$I_{-117}$	1.2006
$I_{-224}$	0.8973	$I_{-197}$	1.0116	$I_{-170}$	1.1258	$I_{-143}$	1.1622	$I_{-116}$	1.1588
$I_{-223}$	0.8881	$I_{-196}$	0.9249	$I_{-169}$	1.3196	$I_{-142}$	1.1638	$I_{-115}$	1.2952
$I_{-222}$	1.0004	$I_{-195}$	1.0063	$I_{-168}$	1.3852	$I_{-141}$	1.1642	$I_{-114}$	1.2510
$I_{-221}$	0.8997	$I_{-194}$	1.1134	$I_{-167}$	1.2443	$I_{-140}$	1.3293	$I_{-113}$	1.2314
$I_{-220}$	0.9459	$I_{-193}$	1.1119	$I_{-166}$	1.3243	$I_{-139}$	1.3792	$I_{-112}$	1.2444
$I_{-219}$	0.9662	$I_{-192}$	1.0537	$I_{-165}$	1.3465	$I_{-138}$	1.2971	$I_{-111}$	1.3428
$I_{-218}$	0.8576	$I_{-191}$	1.0385	$I_{-164}$	1.4036	$I_{-137}$	1.3172	$I_{-110}$	1.3989
$I_{-217}$	0.9560	$I_{-190}$	1.0724	$I_{-163}$	1.4249	$I_{-136}$	1.3387	$I_{-109}$	1.3054
$I_{-216}$	0.9251	$I_{-189}$	1.0663	$I_{-162}$	1.1821	$I_{-135}$	1.3084	$I_{-108}$	1.3856

**EK 2. (devamı)**

Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer	Gen	Optimal değer
$I_{-107}$	1.4422	$I_{-80}$	1.4163	$I_{-53}$	1.0754	$I_{-26}$	0.9156	$S_0$	8.3776
$I_{-106}$	1.4793	$I_{-79}$	1.3259	$I_{-52}$	1.0492	$I_{-25}$	0.8032	$b_0$	-0.0004
$I_{-105}$	1.4659	$I_{-78}$	1.2900	$I_{-51}$	1.0096	$I_{-24}$	0.7823		
$I_{-104}$	1.3031	$I_{-77}$	1.2521	$I_{-50}$	0.9862	$I_{-23}$	0.8250		
$I_{-103}$	1.2344	$I_{-76}$	1.2174	$I_{-49}$	0.9462	$I_{-22}$	0.8574		
$I_{-102}$	1.3120	$I_{-75}$	1.2683	$I_{-48}$	0.9582	$I_{-21}$	0.7424		
$I_{-101}$	1.2579	$I_{-74}$	1.3390	$I_{-47}$	0.9087	$I_{-20}$	0.7401		
$I_{-100}$	1.3669	$I_{-73}$	1.3135	$I_{-46}$	1.0404	$I_{-19}$	0.7045		
$I_{-99}$	1.3779	$I_{-72}$	1.3684	$I_{-45}$	1.0891	$I_{-18}$	0.7990		
$I_{-98}$	1.3793	$I_{-71}$	1.2805	$I_{-44}$	1.0742	$I_{-17}$	0.6811		
$I_{-97}$	1.2607	$I_{-70}$	1.2325	$I_{-43}$	1.0824	$I_{-16}$	0.6732		
$I_{-96}$	1.3279	$I_{-69}$	1.2112	$I_{-42}$	0.9636	$I_{-15}$	0.7173		
$I_{-95}$	1.3916	$I_{-68}$	1.0895	$I_{-41}$	0.9983	$I_{-14}$	0.7071		
$I_{-94}$	1.4196	$I_{-67}$	1.1151	$I_{-40}$	0.9399	$I_{13}$	0.6761		
$I_{-93}$	1.2652	$I_{-66}$	1.0840	$I_{-39}$	0.9298	$I_{-12}$	0.6903		
$I_{-92}$	1.3416	$I_{-65}$	1.1616	$I_{-38}$	0.8091	$I_{-11}$	0.7197		
$I_{-91}$	1.2614	$I_{-64}$	1.1524	$I_{-37}$	0.8205	$I_{-10}$	0.7215		
$I_{-90}$	1.3428	$I_{-63}$	1.1162	$I_{-36}$	0.7818	$I_{-9}$	0.6565		
$I_{-89}$	1.4031	$I_{-62}$	1.2090	$I_{-35}$	0.8491	$I_{-8}$	0.6568		
$I_{-88}$	1.3601	$I_{-61}$	1.1580	$I_{-34}$	0.8298	$I_{-7}$	0.6365		
$I_{-87}$	1.2762	$I_{-60}$	1.1412	$I_{-33}$	0.7635	$I_{-6}$	0.6426		
$I_{-86}$	1.2857	$I_{-59}$	1.0593	$I_{-32}$	0.7494	$I_{-5}$	0.6844		
$I_{-85}$	1.2781	$I_{-58}$	1.2476	$I_{-31}$	0.8127	$I_{-4}$	0.7098		
$I_{-84}$	1.4043	$I_{-57}$	1.1391	$I_{-30}$	0.7967	$I_{-3}$	0.6585		
$I_{-83}$	1.2694	$I_{-56}$	1.1367	$I_{-29}$	0.8199	$I_{-2}$	0.6756		
$I_{-82}$	1.3468	$I_{-55}$	1.1611	$I_{-28}$	0.8244	$I_{-1}$	0.6617		
$I_{-81}$	1.3800	$I_{-54}$	1.0926	$I_{-27}$	0.9506	$I_0$	0.6518		

**EK 3: ANFİS: Girdi ve çıktı üyelik fonksiyonları için oluşturulan modellerden elde edilen HKOK değerleri**

**Girdi üyelik fonksiyonu: gaussmf**

Girdi sayısı	Girdi üyelik fonksiyonu Sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 6]	Sabit	1.0323	0.8315
	[3 3]	Doğrusal	1.0329	0.8291
3	[2 3 6]	Sabit	1.0075	0.8426
	[2 3 3]	Doğrusal	0.9928	0.8461
4	[3 5 3 2]	Sabit	0.9711	0.8270
	[2 2 2 2]	Doğrusal	0.9741	0.8348
5	[2 3 2 2 2]	Sabit	0.9850	0.8354
	[2 2 2 2 2]	Doğrusal	0.9162	0.8606
6	[2 2 2 3 2 2]	Sabit	0.9616	0.8410
	[2 2 2 2 2 2]	Doğrusal	0.8099	0.9429
7	[2 2 2 2 2 2 2]	Sabit	0.9419	0.8793
	[2 2 2 2 2 2 2]	Doğrusal	0.6338	1.1989

**Girdi üyelik fonksiyonu: trimf**

Girdi sayısı	Girdi üyelik fonksiyonu Sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 4]	Sabit	1.0341	0.8317
	[3 4]	Doğrusal	1.0252	0.8329
3	[5 3 2]	Sabit	1.0132	0.8391
	[3 2 2]	Doğrusal	1.0073	0.8444
4	[3 5 2 2]	Sabit	0.9849	0.8311
	[2 3 2 2]	Doğrusal	0.9694	0.8330
5	[3 2 2 2 2]	Sabit	0.9813	0.8347
	[2 3 2 2 2]	Doğrusal	0.9237	0.8285
6	[2 3 2 2 2 2]	Sabit	0.9631	0.8375
	[2 2 2 2 2 2]	Doğrusal	0.8858	0.8703
7	[2 2 2 2 2 2 2]	Sabit	0.9468	0.8554
	[2 2 2 2 2 2 2]	Doğrusal	0.7597	0.9866

<b>Girdi üyelik fonksiyonu: trapmf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 3]	Sabit	1.0718	0.8473
	[3 3]	Doğrusal	1.0305	0.8280
3	[2 3 6]	Sabit	1.0443	0.8441
	[4 2 4]	Doğrusal	0.9758	0.8432
4	[2 4 4 3]	Sabit	1.0001	0.8355
	[2 4 2 3]	Doğrusal	0.9236	0.8356
5	[2 4 3 3 2]	Sabit	0.9825	0.8321
	[2 2 2 2 3]	Doğrusal	0.8855	0.8867
6	[2 2 2 3 2 2]	Sabit	0.9881	0.8487
	[2 2 2 2 2 2]	Doğrusal	0.7813	1.2278
7	[2 2 2 2 2 2 2]	Sabit	0.9678	0.9237
	[2 2 2 2 2 2 2]	Doğrusal	0.6338	2.4211

<b>Girdi üyelik fonksiyonu: dsigmf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 6]	Sabit	1.0587	0.8431
	[3 3]	Doğrusal	1.0316	0.8279
3	[6 4 4]	Sabit	0.9970	0.8445
	[3 2 3]	Doğrusal	0.9919	0.8397
4	[6 4 3 2]	Sabit	0.9732	0.8401
	[2 2 2 3]	Doğrusal	0.9552	0.8466
5	[6 2 3 3 2]	Sabit	0.9382	0.8420
	[2 2 2 2 2]	Doğrusal	0.9152	0.9182
6	[2 2 2 3 2 2]	Sabit	0.9881	0.8487
	[2 2 2 2 2 2]	Doğrusal	0.7813	1.2278
7	[2 2 2 2 2 2 2]	Sabit	0.9817	0.8793
	[2 2 2 2 2 2 2]	Doğrusal	0.4151	4.6829

<b>Girdi üyelik fonksiyonu: gbellmf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 6]	Sabit	1.0374	0.8315
	[3 3]	Doğrusal	1.0319	0.8287
3	[2 3 6]	Sabit	1.0165	0.8416
	[3 2 3]	Doğrusal	0.9927	0.8416
4	[5 4 4 2]	Sabit	0.9566	0.8316
	[2 2 2 2]	Doğrusal	0.9734	0.8363
5	[2 2 2 3 2]	Sabit	0.9876	0.8331
	[2 2 2 2 2]	Doğrusal	0.9112	0.8826
6	[2 2 2 3 2 2]	Sabit	0.9658	0.8329
	[2 2 2 2 2 2]	Doğrusal	0.7098	1.0511
7	[2 2 2 2 2 2 2]	Sabit	0.9415	0.8983
	[2 2 2 2 2 2 2]	Doğrusal	0.5444	1.5078

<b>Girdi üyelik fonksiyonu: pimf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 3]	Sabit	1.0945	0.8584
	[3 3]	Doğrusal	1.0314	0.8292
3	[6 4 4]	Sabit	1.0219	0.8481
	[3 2 3]	Doğrusal	0.9924	0.8444
4	[6 4 3 2]	Sabit	0.9885	0.8436
	[2 2 2 3]	Doğrusal	0.9553	0.8446
5	[2 4 2 3 2]	Sabit	1.0101	0.8524
	[2 2 2 2 2]	Doğrusal	0.9126	0.9175
6	[2 2 2 3 2 2]	Sabit	1.0038	0.8608
	[2 2 2 2 2 2]	Doğrusal	0.7835	1.2530
7	[2 2 2 2 2 2 2]	Sabit	0.9917	0.9506
	[2 2 2 2 2 2 2]	Doğrusal	0.4106	4.3984

<b>Girdi üyelik fonksiyonu: psigmf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 6]	Sabit	1.0587	0.8431
	[3 3]	Doğrusal	1.0316	0.8279
3	[6 4 4]	Sabit	0.9970	0.8445
	[3 2 3]	Doğrusal	0.9919	0.8397
4	[6 4 3 2]	Sabit	0.9732	0.8401
	[2 2 2 3]	Doğrusal	0.9552	0.8466
5	[6 2 3 3 2]	Sabit	0.9382	0.8420
	[2 2 2 2 2]	Doğrusal	0.9152	0.9182
6	[2 2 2 3 2 2]	Sabit	0.9992	0.8521
	[2 2 2 2 2 2]	Doğrusal	0.7861	1.2167
7	[2 2 2 2 2 2 2]	Sabit	0.9817	0.9411
	[2 2 2 2 2 2 2]	Doğrusal	0.4151	4.6829

<b>Girdi üyelik fonksiyonu: gauss2mf</b>				
Girdi sayısı	Girdi üyelik fonksiyonu sayısı	Çıktı üyelik fonksiyonu	HKOK	
			Eğitim	Test
2	[5 6]	Sabit	1.0434	0.8331
	[3 3]	Doğrusal	1.0306	0.8314
3	[2 3 6]	Sabit	1.0281	0.8414
	[3 2 3]	Doğrusal	0.9908	0.8415
4	[2 4 2 4]	Sabit	0.9912	0.8350
	[2 2 2 2]	Doğrusal	0.9729	0.8438
5	[2 2 2 3 2]	Sabit	0.9967	0.8302
	[2 2 2 2 3]	Doğrusal	0.8867	0.8966
6	[2 2 2 3 2 2]	Sabit	0.9737	0.8306
	[2 2 2 2 2 2]	Doğrusal	0.7856	1.1637
7	[2 2 2 2 2 2 2]	Sabit	0.9473	0.9096
	[2 2 2 2 2 2 2]	Doğrusal	0.4067	3.6441

## ÖZ GEÇMİŞ

Mehmet Arif DEMİRCİ, Ondokuz Mayıs Üniversitesi Sinop Fen Edebiyat Fakültesi'nden 2010 yılında mezun oldu. 2014 yılında OMÜ LEE 'de Yüksek Lisans programını bitirdi. 2018/Mayıs ayından bu yana Muş Alparslan Üniversitesi Sağlık Bilimleri Fakültesinde öğretim görevlisi olarak görev yapan Mehmet Arif DEMİRCİ iyi derecede İngilizce bilmektedir.

### İletişim Bilgileri

ORCID ID: 0000-0003-2679-6281

### Yayınlar:

1. Demirci, M. A., ve Uslu V. R. (2022). *Forecasting Of Electric Field Intensity*. 4th International Conference On Culture, Civilization And Multidisciplinary Studies in Social Sciences. 932-938. (Full text paper, Sözlü sunum)
2. Demirci, M. A., ve Uslu V. R. (2022). *Forecasting Study For Electric Field Intensity With Adaptive Network-Based Fuzzy Inference System*. Cukurova 8th International Scientific Researches Conference. Vol.2., 312-319. (Full text paper, Sözlü sunum)