



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



KESTİRİMCİ BAKIM PLANLAMASI İÇİN
ZAMAN SERİSİ MODELLERİNE DAYALI
ARIZA ZAMANI TAHMİNİ

Gamze KAYNAK

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Ağustos-2022

KONYA

Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Gamze KAYNAK

Tarih: 02/08/2022

ÖZET

YÜKSEK LİSANS TEZİ

KESTİRİMCİ BAKIM PLANLAMASI İÇİN ZAMAN SERİSİ MODELLERİNE DAYALI ARIZA ZAMANI TAHMİNİ

Gamze KAYNAK

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Bilal ERVURAL

2022, 57 Sayfa

Jüri

**Dr. Öğr. Üyesi Bilal ERVURAL
Dr. Öğr. Üyesi Kemal ALAYKIRAN
Dr. Öğr. Üyesi Veysel ÇOBAN**

Arıza tahmini, arızaların tespit edilmesi ve bakım programı oluşturulması için işletmelerde önemli rol oynayan konulardan bir tanesidir. İşletmeler müşteri memnuniyetini sağlamak ve rakipleri ile rekabet edebilmek için sistemdeki plansız duruşları ve buna neden olan öngörülemeyen sebepleri ortadan kaldırması gerekmektedir. Bakım planlama sistemin sürekli olarak çalışır durumda olmasını sağlamak amacı ile yapılan faaliyetlerin planlanmasıdır. Bu çalışmada bir gıda firmasının kurutma hattındaki plansız duruşları ortadan kaldırmak ve kestirimci bakım planı oluşturmak için makine arıza tahmini çalışması yapılmıştır.

ARIMA modeli doğrusal modeller için Yapay Sinir Ağları doğrusal olmayan modeller için iyi sonuçlar vermektedirler. Fakat gerçek hayat verilerinde hem doğrusal hem de doğrusal olmayan veriler bulunabilmektedirler. Bu nedenle hibrit modeller daha iyi sonuçlar verebilmektedirler. Çalışmada ARIMA, Yapay Sinir Ağları (YSA) ve Hibrit ARIMA-YSA modelleri kullanılmıştır. Veri seti ARIMA, Yapay Sinir Ağları (YSA) ve Hibrit ARIMA-YSA modelleri ile ayrı ayrı modellenmiştir. 3 aylık makine arızası veri seti ile çalışılmıştır. Her bir model için 3 aylık makine arıza zamanı tahmin değerleri oluşturulmuştur. Oluşturulan tahmin değerleri Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE), Ortalama Mutlak Hata Yüzdesi (MAPE) ve Karekök Ortalama Mutlak Hata (RMSE) performans metrikleri ile istatistiksel olarak incelenmiştir. Hibrit modelin ARIMA ve YSA modellerine göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Anahtar Kelimeler: ARIMA, Hibrit ARIMA-YSA, Yapay Sinir Ağları (YSA), Zaman Serisi

ABSTRACT

MS THESIS

FAILURE TIME PREDICTION BASED ON TIME SERIES MODELS FOR PREDICTIVE MAINTENANCE PLANNING

Gamze KAYNAK

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF MASTER OF SCIENCE IN INDUSTRIAL ENGINEERING

Advisor: Asst. Prof. Dr. Bilal ERVURAL

2022, 57 Pages

Jury

**Asst. Prof. Dr. Bilal ERVURAL
Asst. Prof. Dr. Kemal ALAYKIRAN
Asst. Prof. Dr. Veysel ÇOBAN**

Failure estimation is one of the issues that play an important role in companies detecting failures and constructing a maintenance program. To ensure customer satisfaction and compete with their competitors, companies need to eliminate unplanned stops in the system and the unforeseen reasons that cause them. Maintenance planning is the planning of activities carried out to ensure that the system is in continuous operation. In this study, a machine failure estimation study was carried out to eliminate unplanned stops in the drying line of a food company and to construct a predictive maintenance plan.

ARIMA for linear models and Neural Networks for nonlinear models provide acceptable results. However, real-life problems can include both linear and non-linear data. Therefore, hybrid models can provide better results. The study used ARIMA, Artificial Neural Networks (ANN), and Hybrid ARIMA-ANN models. The data set was modeled separately with ARIMA, Artificial Neural Networks (ANN), and Hybrid ARIMA-ANN models. It has been studied with a 3-month machine failure data set. For each model, 3-month prediction values of machine failure time were computed. Estimated values were statistically analyzed using Mean Absolute Error (MAE), Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), and Root Mean Square Error (RMSE) performance metrics. The hybrid model has been demonstrated to give better results than the ARIMA and ANN models.

Keywords: ARIMA, Artificial Neural Network (ANN), Hybrid ARIMA-YSA, Time Series

ÖNSÖZ

Bu çalışmada gıda üretimi yapan bir firmanın kurutma hattındaki plansız duruşları ortadan kaldırmak ve kestirimci bakım planı oluşturmak için makine arıza süreleri üzerine tahmin çalışması yapılmıştır. Literatürdeki ARIMA, YSA modelleri ve hibrit yöntemler ile yapılan tahmin çalışmaları incelenmiştir. Uygulama kısmında ise ARIMA, YSA VE hibrit bir yöntem olan ARIMA-YSA modeli ile tahminleme çalışması yapılmıştır. 3 modelin tahmin sonuçları performans metrikleri ile istatistiksel olarak karşılaştırılmıştır. Hangi yöntemin gerçeğe daha yakın sonuçlar verdiği analiz edilmiştir.

Öncelikli olarak tez çalışmamda ve lisansüstü eğitimim sırasında benden bilgi ve tecrübelerini esirgemeyen her zaman destek olan kendisi ile çalışmaktan onur duyduğum saygıdeğer danışmanım Dr. Öğr. Üyesi Bilal ERVURAL'a teşekkür ederim.

Hem lisans hem de yüksek lisans eğitimim boyunca bilgi ve birikimlerinden her zaman yararlandığım Necmettin Erbakan Üniversitesi Endüstri Mühendisliği Bölümü hocalarıma teşekkür ederim.

Son olarak hayatımın her döneminde beni destekleyen canım aileme ve özellikle sevgisini her zaman kalbimde hissettiğim her adımda manevi destekçim olan kardeşim Veysel KAYNAK'a teşekkürü bir borç bilirim.

Gamze KAYNAK
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
KISALTMALAR	ix
ÇİZELGE LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
1. GİRİŞ.....	1
2. BAKIM PLANLAMASI.....	4
2.1. Plansız Bakım	5
2.2. Planlı Bakım	6
2.2.1. Önleyici Bakımlar.....	6
2.2.2. Düzeltici Bakım	7
2.3. Arıza Tahmini	7
3. LİTERATÜR TARAMASI.....	9
3.1. Makine Arıza Zamanı Çalışmaları.....	9
3.2. Zaman Serisi İle Tahminleme.....	10
3.3. Yapay Sinir Ağları İle Tahminleme.....	11
3.4. ARIMA-YSA Hibrit Modeller.....	12
4. ZAMAN SERİSİ ANALİZİ VE MAKİNE ÖĞRENMESİ.....	14
4.1. Zaman Serisi Analizi	14
4.1.1. Geleneksel Zaman Serisi Tahmin Yöntemleri.....	14
4.2. Makine Öğrenmesi.....	16
4.2.1. Naive Bayes Sınıflandırma Algoritması	17
4.2.2. K-Means Algoritması	17
4.2.3. Destek Vektör Makinesi	17
4.2.4. Yapay Sinir Ağları	17
4.2.5. Karar Ağaçları.....	18
4.2.6. Rassal Orman Algoritması.....	18
5. METODOLOJİ.....	19
5.1. Box-Jenkins Yöntemi (ARIMA/SARIMA).....	19

5.1.1. ARMA Modeli	21
5.1.2. ARIMA Modeli.....	22
5.1.3. SARIMA Modeli	22
5.2. Yapay Sinir Ağları	23
5.2.1. Tek Katmanlı Sinir Ağlar	25
5.2.2. Çok Katmanlı Sinir Ağları.....	26
5.3. ARIMA-YSA Hibrit Modeller.....	26
5.3.1. Zhang ARIMA-YSA Modeli	27
5.3.2. Khashei ve Bijari ARIMA-YSA Melez Modeli	27
5.3.3. Hareketli ortalama filtreli ARIMA-YSA modeli.....	28
5.4. Uygulanan ARIMA-YSA Hibrit Model	29
6. UYGULAMA	32
6.1. Veri Seti	32
6.2. Performans Ölçütleri.....	33
6.3. Tahmin Modelleri	34
6.3.1. ARIMA Tahmin Modeli	34
6.3.2. YSA Tahmin Modeli	38
6.3.3. ARIMA-YSA Hibrit Tahmin Modeli	39
6.4. Analiz Sonuçları ve Tartışma.....	42
7. SONUÇLAR.....	46
KAYNAKLAR	48
EKLER	53
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

KISALTMALAR

ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average)
YSA	: Yapay Sinir Ağları
MLP	: Çok Katmanlı Algılayıcılar (Multi Layer Perceptron)
ACF	: Otokorelasyon Fonksiyonu (Auto Correlation Function)
PACF	: Kısmi Otokorelasyon Fonksiyonu (Partial Auto Correlation Function)
AR	: Otoregresyon (Autoregression)
MA	: Hareketli Ortalamalar (Moving Average)
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hatası
MSE	: Ortalama Karesel Hata
RMSE	: Karekök Ortalama Karesel Hata

ÇİZELGE LİSTESİ

Çizelge 1. Biyolojik Sınır Sistemi elemanları ve ona karşılık gelen YSA elemanları (Çoban ve Demir, 2021)	23
Çizelge 2. Uygulamada kullanılan arıza verileri	34
Çizelge 3. Makine arızası veri seti ARIMA modeli	37
Çizelge 4. ARIMA(0,1,1) Modeli ile yapılan tahmini test verileri	37
Çizelge 5. ARIMA(0,1,1) modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları.....	38
Çizelge 6. YSA ile yapılan arıza tahmini test verileri	39
Çizelge 7. YSA modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları... 39	
Çizelge 8. Artık değer sonuçları	40
Çizelge 9. Artık değerlerin YSA tahmin sonuçları.....	40
Çizelge 10. ARIMA-YSA hibrit modeli arıza tahmini sonuçları.....	41
Çizelge 11. ARIMA-YSA hibrit modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları.....	41
Çizelge 12. Gerçekleşen arıza verileri ve ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan tahmin değerleri	42
Çizelge 13. ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan tahmin çalışmalarının test verilerinin istatistiksel sonuçları	42
Çizelge 14. ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan 3 aylık tahmin verilerinin istatistiksel sonuçları	43

ŞEKİL LİSTESİ

Şekil 1. Bakım planlama çeşitleri (Mansor, 2012)	5
Şekil 2. Arızalar arası sürenin ölçümü (Birolini, 2013)	8
Şekil 3. Yapay sinir hücresi matematiksel modeli	23
Şekil 4. Yapay sinir hücresi ağı yapısı (Çoban ve Demir, 2021)	24
Şekil 5. Tek katmanlı sinir ağı modeli (Arı ve Berberler, 2017).....	26
Şekil 6. Çok katmanlı YSA modeli (Ünlü, 2019).....	26
Şekil 7. ARIMA- YSA hibrit model akış şeması.....	31
Şekil 8. Makine arıza verileri zaman serisi grafiği	33
Şekil 9. ACF grafiği.....	35
Şekil 10. PACF grafiği	36
Şekil 11. Birinci dereceden fark alındıktan sonra oluşan serinin ACF grafiği.....	36
Şekil 12. Birinci dereceden fark alındıktan sonra oluşan serinin PACF grafiği.....	37
Şekil 13. ARIMA(0,1,1) modeli ile yapılan arıza tahmini ve gerçekleşen makine arızası verileri grafiği	38
Şekil 14. Uygulamada kullanılan YSA modeli	38
Şekil 15. YSA modeli ile yapılan arıza tahmini grafiği	39
Şekil 16. Hibrit modelin kümülatif veriler ile yapılan tahmin değerleri grafiği.....	41
Şekil 17. Makine arıza verileri ve hibrit modelin tahmin sonuçları grafiği	44
Şekil 18. Makine arıza verileri, ARIMA, YSA ve Hibrit model ile yapılan makine arıza tahmin grafiği.....	45

1. GİRİŞ

Arıza tahmini, sistem arızalarının oluşmasını önlemeyi ve ekipman, makine ve süreçlerin planlanmamış duruş sürelerini en aza indirmeyi amaçlayan endüstriyel bakım stratejilerinin önemli bir bileşenidir. Tahmine dayalı bakım, bakım faaliyetlerinin zamanında planlanmasını tasarlamak için gelecekteki arızaların doğru tahminlerine dayanır (Leukel vd. 2021). Gelişen değişen dünyada müşteri memnuniyetini sağlamak ve rakiplerle rekabet edebilmek için sistemin zamansız duruşlarını ve buna neden olan öngörülemeyen sebepleri ortadan kaldırması gerekmektedir.

İşletmeler genellikle arıza bakımını arıza oluştuğundan sonra plansız bir şekilde yapmaktadırlar. Zamansız çıkan arızalarda onarım esnasında zaman kaybı çok fazla olmaktadır. Birçok sektörde nihai ürün üretmek için birden fazla makinenin bir döngü içerisinde birlikte çalıştığı gözlenmektedir. Operasyonların birbirine bağlı olması sistemin aksamaması oldukça önemlidir. Plansız bakım nedeniyle farklı makineler veya farklı parçalarında zarar görebilmektedir. Operasyonun durması halinde sistemin dengesinin bozulmasına ara ürünlerin yığılmasına, yapılan işin gecikmesine ve elemanın boşa çıkmasına neden olabilmektedir. Bunların her biri birer israftır. Planlamanın iyi yapılmaması, ürünlerin zamanında teslim edilememesi firmanın hem prestijini zedelemekte hem de maddi açıdan kayıplar yaşamasına neden olmaktadır. Üretimin sorunsuz bir şekilde duraksamadan yapılması çok önemlidir.

Arıza tahmini yapılması ve ona uygun şekilde makinelerin bakımlarının yapılması tehlikeli durumların oluşmasını, kazaları, yaralanmaları, malzeme hasarını, zaman kaybını büyük ölçekte önlemektedir. Aynı zamanda ise sahip olunan makinelerin doğru, sorunsuz ve kontrollü bir şekilde çalışmasını sağlamaktadır.

Veri işleme, veriyi analiz etmek ve bu analizler sayesinde anlamlı bilgiler üretmek geleceğe yönelik tahminler yapmak gün geçtikçe daha fazla önem kazanmıştır. İlk zamanlar tahmin çalışmalarında matematiksel ve istatistiksel yöntemler kullanılmaktadır. Gün geçtikçe verilerin, değişkenlerin ve belirsizliklerin artması ile birlikte matematiksel ve istatistiksel yöntemler yetersiz kalmıştır. Bu gibi durumlarda tahmin çalışmalarında öğrenmeye dayalı kendini eğitebilen makine öğrenmesi algoritmaları kullanılmaya başlanmıştır. Makine öğrenmesi algoritmaları üretim sektöründe makine bakım ve onarım planlaması, üretim ve tedarik zincirinin planlanması, finansal hesaplamalar vb. birçok alanda uygulanabilmektedir.

Geleneksel yöntemlerle yapılan bakım planları işletmelerde hala kullanılmaktadırlar. Bakım çalışmalarının amacı arızanın meydana gelme zamanını hesaplayarak arıza oluşmadan hızlı bir şekilde önlemler alınmalı ve gereksiz yapılacak olan bakımların önüne geçmektir. Gereksiz yapılan bakımların sistem arıza vermeden daha uzun ömürlü gidebilecek parçaların değiştirilmesine, gereksiz bakım için üretimin durdurulmasına, gereksiz işgücü, yedek parça kullanımına neden olabilmektedir. Amacımız bakım çalışmalarının sürelerini optimize ederek, arıza oluşmadan bakım yapmak ve gereksiz bakımların önüne geçmektir.

Literatürde zaman serisi modelleri ve makine öğrenmesi algoritmaları ile yapılmış tahmin çalışmaları mevcuttur. Zaman serileri ile yapılan tahminler doğrusal modellerde iyi sonuçlar verirken, makine öğrenmesi ile yapılan tahminler doğrusal olmayan modeller için iyi sonuçlar vermektedir. ARIMA-YSA melez modeli ile yapılan arıza tahmin çalışması literatürde bulunmamaktadır. Gerçek hayat verilerinde doğrusal ve doğrusal olmayan veriler iç içe geçmiş durumdadır. Bunları ayrıştırıp modelleyerek tahmin yapmak çok zordur. Bu nedenle hibrit model ile yapılan tahmin çalışması sonuçlarının doğrusal ve doğrusal olmayan modellere göre daha iyi sonuçlar vereceği tahmin edilmektedir.

Bu çalışmanın temel amacı sistemin sağlıklı bir şekilde çalışması ve her an üretime hazır olmasıdır. Bunun gerçekleştirilebilmesi için plansız duruşların ortadan kaldırılması gerekmektedir. Bu çalışmada plansız duruşları ortadan kaldırmak ve kestirimci bakım planı oluşturmak için makine arıza zamanı tahmini yapmaktır. Çalışmada, doğrusal model olarak klasik zaman serisi yöntemlerinden Otoregresif Hareketli Ortalamalar Yöntemi (ARIMA) ve doğrusal olmayan model olarak ise makine öğrenmesi yöntemlerinden Yapay Sinir Ağı (YSA) 'larından yararlanılmıştır. Ayrıca bu iki yöntem birleştirilerek hibrit bir tahmin modeli de kullanılmıştır. Bu üç yöntem ile yapılan tahmin çalışmasının sonuçları Ortalama Mutlak Hata (MAE), Ortalama Karese Hata (MSE), Ortalama Mutlak Yüzde Hatası (MAPE) ve Karekök Ortalama Mutlak Hata (RMSE) performans metrikleri ile kıyaslanmıştır. Yapılan tahminlerin başarıları analiz edilmiştir.

Çalışmada gıda üretimi yapan bir firmanın üretimi en çok kesintiye uğratan kurutma makinesindeki (dryer) arızaları önlemeye yönelik bakım çalışması yapma hedeflenmiştir. İşletmeden alınan kümülatif arıza verileri ARIMA, YSA ve ARIMA-

YSA hibrit modeli ile modellenmiş ve elde edilen sonuçlar performans ölçütlerine göre analiz edilmiş ve karşılaştırılmıştır.

Çalışma yedi bölümden oluşmaktadır. İlk bölümde yapılan çalışma ile ilgili genel bir bilgi verilmiştir. İkinci bölümde bakım planlama hakkında genel bilgi verilmektedir. Üçüncü bölümde ise literatür araştırması sunulmaktadır. Dördüncü bölümde klasik zaman serisi yöntemlerini ve makine öğrenmesi yöntemlerini özetlemektedir. Beşinci bölümde uygulanan yöntemlerin metodolojileri anlatılmaktadır. Altıncı bölümde gerçekleştirilen uygulama ve analizler anlatılmaktadır. Yedinci bölüm olan son bölümde ise çalışmanın sonuçları analiz edilmektedir.

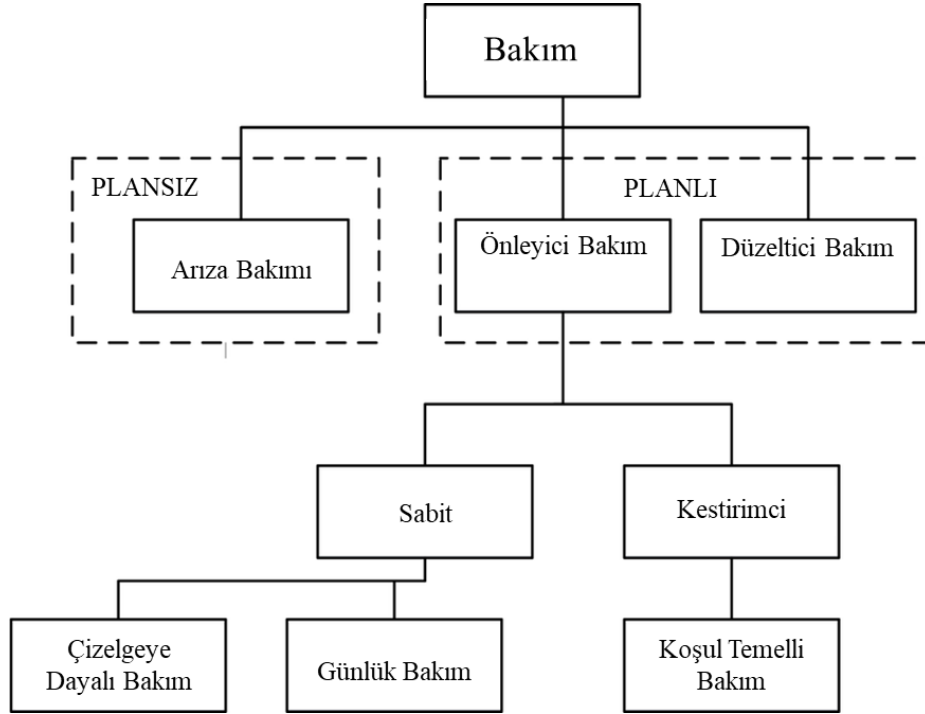
2. BAKIM PLANLAMASI

Üretim sektörü ve hizmet sektörü olarak bakıldığında günümüz rekabet koşullarında şirketlerin, kesintisiz üretim ve kesintisiz hizmet sağlayabilmeleri ekipmanların kalitesi ve sürekliliği ile direkt bağlantılı hale gelmiştir. Sağlıklı üretim yapılması ve üretim programlarının aralıksız gerçekleştirilebilmesi makine ve insan faktörlerinin uyumlu çalışmasına bağlıdır. İşletmelerde ekipman veriminden en yüksek düzeyde yararlanılması, planlı çalışma koşullarına bağlıdır. Makinelerin arıza yaparak beklemelere neden olması tüm çalışma sistematiğini bozmaktadır. İşletmelerin bugünkü rekabet şartlarında ayakta kalabilmesinin şartı üretimi etkileyecek tüm olumsuz faktörleri ortadan kaldırmasından geçmektedir. (Akteke, 2007).

Bakım planlama sistemin sürekli olarak çalışır durumda olmasını sağlamak amacı ile yapılan faaliyetlerin planlanmasıdır. Arıza; genel olarak bir sistemin, ekipmanın işlevini tam olarak veya hiç yerine getirememesi sonucu oluşan durum olarak tanımlanabilir. Arızalar kimi zaman ekipmanın genel tasarımından, kimi zaman yanlış belirlenmiş çalışma şartlarından, çoğu zaman da insan faktöründen meydana gelmektedir.

İşletmeler rakipleri ile rekabet edebilmek, üretimi ve ürün kalitesini artırmak, sistemin durmadan ve bozulmadan çalışması siparişlerin gününde ve eksiksiz üretilmesi için bakım planlama yapmak zorundadırlar. Herhangi bir arıza nedeniyle oluşabilecek plansız duruş ile tüm sistem durabilir. Bakım planlamanın amacı plansız duruşları en aza indirmek hatta ortadan kaldırarak sistemi sürekli çalışır hale getirmektir.

Bakım planlamanın başarılı bir şekilde işleyebilmesi için sürdürülebilirliğinin sağlanması gerekmektedir. Öncelikli olarak makinenin, sistemin veya ekipmanın kullanım şekline ve türüne uygun bakım planı tasarlanmalıdır. Bakım için gerekli olan ekipmanlar her zaman hazır olmalıdır. Düzenli bir şekilde prosedüre uygun sistemin bakımları yapılmalı ve yapılan bakımlar kayıt altına alınmalıdır.



Şekil 1. Bakım planlama çeşitleri (Mansor, 2012)

Bakım planlama 2' ye ayrılmaktadır. Bunlar plansız bakım ve planlı bakımdır.

2.1. Plansız Bakım

Arıza meydana geldiği zaman tamir etmek amacı ile yapılan bakım çeşididir. Arızalandığında aynı tür makine ve ekipmanların yedeklerinin bulunduğu bakım ve onarımının ucuz olduğu işletmelerde kullanılır. Bakım esnasında üretim durduğu için üretimde gecikme yaşanmaktadır.

Plansız bakımın dezavantajları:

- Bilinmeyen bir arıza oluşur, arızanın durumuna göre üretim gecikir.
- Arızanın nedeni bilinmiyorsa bunu anlamak uzun zaman alabilir ve yedek makine teçhizat ihtiyaçları oluşabilir.
- Planlı bakım yapılmadığı için oluşabilecek arızalardan kaynaklı sistemde farklı arızalarda meydana gelebilir.
- Çalışan güvenliği tehlikeye atılır.
- Çalışanların yaralanması durumunda tedavi masrafı, tazminat, sigorta vb. masraflar oluşur.

2.2. Planlı Bakım

Arıza meydana gelmeden arızayı engellemek adına yapılan bakımdır. Planlı bakım makine ve teçhizatların istenilen her an sorunsuz bir şekilde üretim yapılabilir olmasını sağlar. Planlı bakımın amaçları:

- Makine ve teçhizatın ömrünün uzaması,
- Ekipmanların performansını artırmak,
- Arıza sürelerini ve arıza maliyetlerini düşürmek,
- Makine ve teçhizatı her an üretime hazır hale getirmek,
- Oluşabilecek arıza durumlarında hasarı en aza indirmek,
- Bakım giderlerini ve onarım masraflarını düşürmek,
- Oluşabilecek arızadan kaynaklanan yedek makine ihtiyacının azaltılması,
- İşçiler için güvenli çalışma ortamı oluşturulmuş olması,
- Oluşabilecek kazalara karşı tazminat, sigorta vb. masrafları en aza indirmek.

Planlı bakımlar 2' ye ayrılır: Önleyici bakım ve Düzeltici bakım.

2.2.1. Önleyici Bakımlar

Önleyici işletmelerin son zamanlarda kullanmaya başladığı bir bakım çeşididir. Bu yöntem ile makina ve tesislerde oluşan arızalardan kaynaklanan arızaların ortaya çıkmasını önlemektir. İşletmelerde yapılacak değişiklikler ile oluşacak arızaların nedenleri ortadan kaldırılır. Bunun için firmaların ciddi bir ARGE çalışması yapması gerekmektedir.

Temizlik, yakıt ikmali, bozulmayı önlemek için kontrol, periyodik muayene ve bozulmayı ölçmek için ekipman teşhisi ve bozulmayı erken bir aşamada düzeltmek için bakım ve onarım gibi günlük rutin eylemleri (normalde günlük bakım olarak adlandırılır) gerçekleştirerek ekipmanın “sağlıklı” durumunu korumaktadır.

Sabit Bakım: Arıza oluşmadan önce periyodik bakım gerektirdiğinden, bakım masrafı maliyetlidir. İki tür sabit bakım vardır: çizelgeye dayalı bakım (TBM - Time Based Maintenance) ve inceleme ve onarım içeren günlük bakım.

Kestirimci bakım: Kontrol ve teşhis yoluyla önemli bir parçanın ömrünü öngörür; bu nedenle bakım maliyetleri ve arıza kayıpları bu yöntemle diğerlerine göre

daha azdır. Kestirime dayalı bakımın bir yöntemi, Koşul temelli bakımdır (CBM - Condition Based Maintenance). Bu tür bakım, ekipmanın durumundaki bozulmayı gözlemek ve ardından kullanım ömrünü öngörmek için Koşul tanılama teknolojisini (CDT) kullanır. Böylelikle bakım için uygun bir süre ve yöntem karar verilebilir. Örneğin, ekipmanın durumunu çevrimiçi olarak izlemek için bir sistem, Koşul temelli bakım, arıza tanılama teknolojisini ve insan gücünü TBM'den daha gerekli kılar (Mansor vd. 2012).

İşletmelerin termal kamera, sensörler, ölçüm cihazları vb. yardımıyla makine ve tesislerin belirli yerlerini belirli periyotlarla gözlemlerler. Yapılan gözlemler düzenli olarak kayıt altına alınır. Kaydedilen ölçümler sonucunda sistemin çalışmasında farklılık görülür görülmez bakımı yapılır ve oluşabilecek arızaların önüne geçilir. Yapılan bu bakım çeşidine de uyarıcı bakım denilmektedir. Yağ analizi, sıcaklık analizi (termal görüntüleme) vb. bu bakım türüne örnek olarak gösterilebilir.

Kestirimci bakımlar üç aşamadan oluşurlar. İlk aşama tespittir. Makinanın çalışma şartlarında meydana gelebilecek bir değişikliğin mümkün olan en kısa sürede tespit edilmesi. İkinci aşama analiz ve teşhistir. Meydana gelen değişikliğe neden olan hasarın teşhisi için, makinenin karakteristiğinin daha ayrıntılı bir şekilde incelenmesi. Üçüncü aşama ise düzeltmedir. Gerekli onarım, bakım ve değişimin yapılmasıdır.

2.2.2. Düzeltici Bakım


Ekipmanın güvenilirliğini, sürdürülebilirliğini ve güvenliğini iyileştirmeyi amaçlar. Bozulma ve bozulmayı azaltmak için ekipmanın bozuk parçalarını iyileştirmek, arızalar arasındaki ortalama süreyi (MTBF) artırmak ve ekipmanın onarım süresini (MTTR) azaltmak, düzeltici bakımda tipik eylemlerdir. Bu eylemler, kısa sabit bakım döngüsü, yüksek arıza bakımı sıklığı ve yüksek arıza gideri olan ekipman üzerinde gerçekleştirilir (Mansor vd. 2012).

2.3. Arıza Tahmini

Arıza tahmini, sistem arızalarının oluşmasını önlemeyi ve ekipman, makine ve süreçlerin plansız duruş sürelerini en aza indirmeyi amaçlayan endüstriyel bakım stratejilerinin önemli bir bileşenidir. Tahmine dayalı bakım, bakım faaliyetlerinin zamanında planlanmasını tasarlamak için gelecekteki arızaların doğru tahminlerine

dayanır. Arıza tahminine yönelik yaklaşımlar, sistem durumlarını, olayları ve işlemleri temsil eden mevcut ve geçmiş verileri analiz eder (Leukel vd. 2021).

Arıza zamanı tahmininde kullanılan önemli parametrelerden biri arızalar arası süre (time-between-failures - TBF)'dir. Şekil 2'de bu sürenin nasıl ölçüldüğü gösterilmiştir.



Şekil 2. Arızalar arası sürenin ölçümü (Biolini, 2013).

3. LİTERATÜR TARAMASI

Literatürde çeşitli konularda yapılmış tahmin çalışmaları problemin yapısına uygun olarak mevcuttur. Genel olarak doğrusal verilerin tahmin çalışmalarında zaman serisi analizi teknikleri, doğrusal olmayan verilerin tahmin çalışmalarında ise makine öğrenmesi algoritmaları kullanılmaktadır. Bu bölümde literatür taraması 3 bölümde incelendi. İlk olarak zaman serisi analizleri ile yapılan tahmin çalışmaları ikinci bölümde ise makine öğrenmesi algoritmalarından biri olan YSA ile yapılan tahmin çalışmaları ve son olarak ARIMA-YSA hibrit model çeşitleri incelenmiştir.

3.1. Makine Arıza Zamanı Çalışmaları

Zuo vd. (2021) etkin bir bakım planlaması oluşturmak amacıyla YSA tabanlı rulman arıza tespiti üzerine çalışma yapmıştır. Çalışma sonucunda uyguladığı veri setleri üzerinde tatmin edici sonuçlar elde etmiştir.

Çelikhıh (2020) uçak ekipmanlarının arıza sayısının tahminine yönelik YSA dahil olmak üzere makine öğrenmesi ve optimizasyon algoritmaları ile çalışma yapmıştır.

Sampaio vd. (2019) çalışmasında bir motoru modelleyerek elde eden titreşim sistemi verilerini kullanarak ekipmanların gelecekteki arıza durumunu tahmin etmek amacı ile YSA kullanarak tahmin çalışması yapmıştır.

Aktaş ve Aydın (2018) yaptıkları çalışmada talaşlı imalat sektöründe üretim performansını artırmak için zaman serisi analizi kullanarak üretim miktarını ve tesisin gelecekteki durumunu tahminleme çalışması yapmıştır.

Ben Ali vd. (2015) endüstriyel ve ev tipi makinelerde kullanılan rulmanın titreşim sinyalleri altında ne kadar ömrü olduğunu hesaplamak için YSA tabanı ile bir çalışma yapmıştır.

Kepekçi (2011) bir firmada kullanılan kamyonların duruş süreleri üzerine zaman serisi analizi ile ayrıntılı bir çalışma yapmıştır. Çalışma sonucunda mevsimsel olmayan ARIMA (p,d,q) modellerinin etkin sonuç verdiğini gözlemlemiştir.

Mahamad vd. (2010) makinelerin kalan ömrünü doğru bir şekilde tahmin etmek ve bakım planlamasını yapmak için rulman arızası tahmini üzerine YSA tabanlı rul ömrü tahmin çalışması yapmıştır.

Güngör (2007) talaşlı imalat yapan bir işletmede üretim hattındaki makinelerde arıza tahmini için YSA ile bir çalışma yapmıştır. Çalışma sonucunda veriler ile yapılacak önleyici bakım planı yapılması önerilmiştir.

3.2. Zaman Serisi İle Tahminleme

Fernandes vd. (2020) bir metalürji şirketinde kestirimci bakım uygulamalarına geçiş için arıza tespit mekanizması üzerine ARIMA yöntemi ile çalışma yapmıştır.

Baptista vd. (2018) kritik bir uçak parçası bakımı planı için veriye dayalı kestirimci bakım uygulaması üzerine ARIMA yöntemi ile çalışma yapmıştır.

Dindarloo vd. (2015) SARIMA yöntemi ile bir iş makinesi için arızalar arası süre tahmini ve güvenilirlik analizi çalışması yapmıştır.

Sarıyer (2018) tarafından yapılan çalışmada acil servisteki kalabalıklaşmayı önlemek ve kıt kaynak olan sürekliliği mecburi ekipmanların planlamasını yapmak amacıyla hasta sayısı tahminleme üzerine bir çalışma yapmıştır. Çalışma için İzmir'deki bir eğitim araştırma hastanesinin 90 günlük zaman serisi verisini kullanmıştır. ARIMA ve SARIMA modelleri ile modelleyip modellerin performansları karşılaştırılmıştır.

Maleki vd. (2020) son yıllarda tüm dünyayı etkisi altına alan Covid-19 hastalığı vaka sayısı verilerini kullanarak hastalığın yayılma hızını ve ölüm oranlarının tahminlemesi üzerine zaman serileri ile bir çalışma yapmıştır.

Can (2020), çalışmasında Doğu Akdeniz Bölgesindeki rüzgar tribünlerinden elde edilecek enerji miktarının tahmin çalışması zaman serisi analizi ile yapmıştır.

Alghamdi vd. (2019) trafik sıkışıklığını azaltmak amacıyla Kaliforniya da bir bölgede çalışma yapmıştır. Trafik sıklığını tahminlerken ARIMA modeli kullanılmış ve trafik durumunun yüksek performansla tahmin etmiştir.

Küçükoflaz vd. (2019) Türkiye'deki 2010-2018 yıllarına ait et ve süt üretici fiyatlarını zaman serisi analizi ile çözümleyerek Box-Jenkins modelleri ile 2019-2021 yılları arasının et ve süt üretici fiyatlarının tahmin çalışması yapılmıştır.

Tandon vd. (2020) Covid-19 hastalığının Hindistan'daki gelecek dönem verilerini tahmin ederek sağlık hizmetlerini hazırlamak, gelecek koşullara hazırlıklı olmak ve salgının eğilimini anlama için vaka sayısı üzerine tahmin çalışması yapmıştır. Çalışmada ARIMA modeli kullanılmıştır.

Fattah vd. (2018) çalışmasında bir gıda firmasındaki gelecek talepleri tahmin etmeyi ve tedarik zincirinin nasıl etkileneceğini anlamak amacıyla zaman serisi analizi ile talep tahmini yapılmıştır. Tahmin çalışmasında ARIMA modeli kullanılmıştır. Gerçeğe yakın sonuçlar elde edilmiştir.

Aksoy ve Salman (2020) son yıllarda dünyanın en önemli sorunlarından biri olan küresel ısınmayla ilgili önlem planı oluşturmak için Türkiye'deki iklim sıcaklığı tahmini üzerine bir çalışma yapmıştır. Çalışmada 2840 aya ait aylık ortalama sıcaklık verileri kullanılmıştır. Problemin yapısına uygun olarak ARIMA modeli ile modellenmiştir ve yüksek doğruluk oranı ile tahmin çalışması yapılmıştır.

3.3. Yapay Sinir Ağları İle Tahminleme

Datilo vd. (2019) Salgın hastalıkların oluşması durumunda salgın hastalığına karşı önlem almak ve salgının gelecekteki durumunu analiz etmek amacıyla YSA ile salgının tahmini, uygun model ve metodoloji üzerine bir çalışma yapılmıştır.

Fente ve Singh (2018) çalışmalarında tarım ve sanayi sektörlerinde kullanmak üzere ve oluşabilecek doğal afetlere karşı önlem alabilmek için hava durumu tahmini üzerine sinir ağları ile bir çalışma yapmışlardır.

Alanis ve Member (2018) yaptıkları çalışmada Yapay Sinir Ağlarını kullanarak gelecek dönemlerde elektrik fiyatı tahmini üzerine bir çalışma yapmışlardır.

Tamang vd. (2020) son yıllarda dünyayı etkisi altına alan Covid-19 salgınına Hindistan, ABD, Fransa, Birleşik Krallık gibi ülkelerdeki vaka sayılarını ve ölüm oranlarını analiz etmişlerdir. Çalışmada ileriye dönük tahminleme için YSA kullanılmıştır.

Pençe vd. (2019) sanayileşmenin en önemli ihtiyaçlarından biri olan elektrik enerjisi tahmini üzerine bir çalışma yapmışlardır. Türkiye'de sanayileşmenin artması ile oluşabilecek enerji ihtiyacını karşılayabilmek ve gelecek dönemlerde enerji sıkıntısı çekmemek için ileriye yönelik tahminleme yapmışlardır. Türkiye'deki 1970-2016 yılları

arasındaki sanayide kullanılan elektrik tüketim verilerini YSA ile modelleyerek 2017-2023 yılları arasındaki enerji tüketimini tahmin etmişlerdir.

Peiris vd. (2021) yaptıkları çalışmada yenilebilir enerji kaynağı olan rüzgar enerjisinin Sri Lanka' da enerji kaynağı olarak kullanabilmek için hem rüzgar enerjisi üretimini hem de rüzgar enerjisi potansiyeli tahmini üzerine YSA ile bir çalışma yapmıştır.

Runge ve Zmeureanu (2019) artan enerji miktarını karşılayabilmek enerji tüketimini tahmin etmek, planlamak ve optimizasyonu sağlamak amacıyla YSA ile enerji tüketimi tahmini üzerine bir çalışma yapmıştır.

Calp (2018) işletmelerde üretilen yemek miktarını veya personel talebini YSA kullanılarak tahminlemesi üzerine bir çalışma yapmıştır.

3.4. ARIMA-YSA Hibrit Modeller

Paithar ve Chatterje (2016), arıza tahmini için YSA ve genetik algoritma tabanlı bir hibrit zaman serisi modeli önermiştir. Çalışma sonucunda modelin iyi bir performans gösterdiği görülmektedir.

Erturan ve Merdivenci (2021), çalışmalarında ARIMA-YSA tabanlı yeni bir melez model önermişlerdir. Önerilen modelin tahmin performanslarını tespit etmek için literatürde sıklıkla kullanılan Wolf'un güneş lekesi, Kanada vaşak gibi veri setleri kullanılarak tahminleme yapılmıştır. Önerilen melez modelin kısa dönem tahminlemede yüksek performans gösterdiği gözlemlenmiştir.

Safari ve Davallou (2018), ham petrol fiyatlarını tahmin etmek için ESM (üstel yumuşatma modeli), ARIMA (otoregresif hareketli ortalama modeli) ve NAR (sinir ağı) modellerini hibritleyerek birleştirmiştir. Tahminleme sonucunda EWH (eşit ağırlıklı hibrit modeli), GWH (genetik algoritma ağırlıklı hibrit model ve ZHM (Zhang hibrit modeli) modelleri ile karşılaştırıldığında tahmin hatasında azalma olduğu görülmüştür.

Kaynar ve Taşhan (2009), yaptıkları çalışmada zaman serisi tahmini için ARIMA ve MLP modellerini birleştirerek hibrit bir model oluşturmuşlardır. Melez modelin MLP ve ARIMA modellerine göre daha etkin sonuçlar gösterdiği gözlemlenmiştir.

Júnior vd. (2019), bu çalışmada doğrusal ve doğrusal olmayan modellerin tahminlerini birleştirerek hibrit bir model önermiştir. Literatürde en çok kullanılan veri

setleri ile tahminleme yapılmıştır. Önerilen metodun literatürdeki modellere göre daha üstün performans gösterdiği görülmektedir.

Wang ve Jiang (2019), doğrusal ve doğrusal olmayan iki modeli birleştirerek tahmin doğruluğu daha yüksek 2 farklı hibrit model geliştirmişlerdir. (NMGM-ARIMA modeli ve ARIMA-ANN modeli) İki hibrit modelin tahminleri arasında farklılıklar olmasına rağmen iki modelde tutarlı sonuçlar vermiştir.

4. ZAMAN SERİSİ ANALİZİ VE MAKİNE ÖĞRENMESİ

4.1. Zaman Serisi Analizi

Eşit zaman aralıkları ile sıralı bir şekilde kaydedilen sıralı değerler dizisine zaman serisi denir (Deb vd., 2017). Bir veri setinin zaman serisi olabilmesi için verinin zamana bağlı olarak değişmesi gerekmektedir. Bu nedenle her seri zaman serisi değildir. Zaman serileri istatistik, ekonomi, astronomi, biyoloji, yıllık yağış miktarı, sinyal işleme, kontrol mühendisliği gibi birçok alanlarda kullanılmaktadır.

Zaman serisi analizinin 2 temel amacı vardır. Bunlar:

- Zaman serisi analizi: Gözlem değerleri arasındaki ilişkileri incelemek.
- Zaman serisi tahmini: Gelecekte olabilecek değerleri tahmin etmek.

Zaman serileri dört temel bileşenden oluşmaktadır (Brockwell ve Davis, 2002). Bunlar:

Trend: Seride yer alan değerlerin uzun dönemde gösterdiği artış veya azalışlardır.

Mevsimsel Hareketler: 1 yıl veya daha kısa süreli dönemlerde seride döngü gibi oluşturulan periyodik dalgalanmalardır.

Döngüsel (Konjonktürel) Hareketler: Belirli dönemlerde meydana gelen mevsimselliğe benzer dalgalanmalardır. Fakat bu dalgalanmalar sabit bir periyotta gerçekleşmezler.

Rassal (Düzensiz) Bileşen: Zaman serisinin kalan kısmıdır. Herhangi bir matematiksel model ile açıklanamayan kısımdır. Savaş, pandemi, doğal afetler gibi beklenmedik durumlarda oluşurlar. Önceden tahmin edilemezler.

Zaman serileri gözlemlenen verilerin hem yapısını ve modelini oluşturmak için hem de geleceğe yönelik tahmin yapmak için kullanılırlar.

4.1.1. Geleneksel Zaman Serisi Tahmin Yöntemleri

Zaman serisi gelecekteki değerini tahmin etmek için kullanılan yöntem; bu tahminin amacına zaman serisinin türüne ve öğelerine, geçmiş verilerin miktarına ve tahmin süresinin genişliğine göre değişiklik gösterebilir (Nebati vd., 2021). Zaman serisinde kullanılan yöntemler:

- 1) Box-Jenkins (ARIMA/SARIMA)
- 2) Trend Analizi
- 3) Hareketli Ortalamalar
- 4) Üstel Düzleştirme
- 5) Uyarlayıcı Arındırma

4.1.1.1. Box-Jenkins Yöntemi (ARIMA/SARIMA)

Box-Jenkins veya ARIMA yöntemi olarak da bilinen zaman serisi yöntemi, 1970 yılında ünlü istatistikçiler George E. P. Box (Wisconsin Üniversitesi) ve Gwilym M. Jenkins (Lancaster Üniversitesi) tarafından önerilmiştir. Bir zaman serisinin en iyi modelini bulmak için uygulanan bir yöntemdir. Box-Jenkins yöntemi uygulaması kolay ve iyi sonuçlar vermesi nedeniyle literatürde yaygın olarak kullanılan bir yöntemdir.

Box-Jenkins yöntemi diğer yöntemlerle kıyaslandığında seri yapısı ve serinin gelişim eğilimi için ön bilgiye gerek duymaz, geçmiş dönem verilerini açıklayıcı değişken gibi kullanır. Bu nedenle de karmaşık serilerde de uygulanması oldukça kolaydır.

SARIMA modeli genel olarak $SARIMA(p,d,q)(P,D,Q)m$ şeklinde gösterilir. Trend veya mevsimsellik içeren zaman serilerinde kullanılmaktadırlar. SARIMA modeli ARIMA ve mevsimselliğin birleşimi olduğu için Mevsimsel ARIMA da denilebilir.

4.1.1.2. Trend Analizi Yöntemi

Zaman serisi analizlerinde en çok kullanılan yöntemlerden biri de trend analizi yöntemidir. Seride yer alan değerlerin (8-10 yıl gibi uzun dönemlerde) göstermiş olduğu artış veya azalışlara trend denir. Bu analizin amacı trend eğrisinin denklemini bularak seriyi anlamak ve ileriye dönük tahmin yapmaktır.

4.1.1.3. Hareketli Ortalamalar Yöntemi

Mevsimselliğin olmadığı serilerde kullanılır. Kısa dönem tahminlerde kullanılır. Serinin grafiği çizildiğinde dalgalanmalar görünüyorsa ise bu dalgalanmaları

ortadan kaldırmak için hareketli ortalamalar yöntemi kullanılır. Serideki değerleri belirlenen büyüklükteki kümelere bölünür, her bir kümenin aritmetik ortalaması alınarak hesaplama yapılır (Kaya, 2019).

Bu yöntemi kullanabilmek için bir serinin şu özellikleri taşıması gerekmektedir:

- Trend doğrusal eğilimli olmalı,
- Dalgaların uzunluğu eşit olmalı,
- Dalgaların şiddeti eşit olmalı.

4.1.1.4. Üstel Düzeltme Yöntemi

Üstel düzeltme yöntemi trend ve mevsimsellik içermeyen zaman serilerinde uygulanan bir yöntemdir. Yöntem Hareketli Ortalamalar yöntemine benzemektedir. Hareketli ortalamalar yönteminden farkı ise tüm dönemlere eşit ağırlık vermek yerine son dönemlere ilk dönemlerden daha fazla ağırlık verilir. Bu sayede son döneme ait değerlerin ilk dönem verilerine göre tahminlerde daha etkin olması sağlanır.

4.1.1.5. Uyarlayıcı Arındırma Yöntemi

Hareketli ortalama ve üstel düzeltme yöntemleri gibi kısa dönem tahminlerinde kullanılan bir yöntemdir. Uyarlayıcı Arındırma Yönteminde gelecek bir dönemdeki tahmin değeri hareketli ortalamalar ve üstel düzeltme yönteminde olduğu gibi serideki geçmiş dönem verilerinin toplamları alınarak hesaplanır. Serideki gözlem değerlerinin birbirine çok fazla bağlı olması ve hesaplama yaparken çok fazla karmaşık olmasından dolayı çok tercih edilen bir yöntem değildir.

4.2. Makine Öğrenmesi

Makine öğrenmesi, bir problemi o probleme ait veriye göre modelleyen bilgisayar algoritmalarının genel adıdır. Mevcut veri seti ve kullanılan algoritma ile oluşturulan model, en yüksek performansı vermek üzere kurulmaktadır (Atalay ve Çelik, 2017).

Makine öğrenmesi terimi ilk kez 1959 yılında Amerikan bilgisayar bilimcisi Arthur Samuel tarafından “bilgisayarın açıkça programlamadan öğrenme yeteneği” olarak tanımlanmaktadır. Başka bir deyişle “bilgisayarın programlamadan, kendilerine insan

gözlemlerinin bilgi ve veri formunda verilmesiyle insanlar gibi davranıp öğrenmesi bilimi de diyebiliriz.

Makine öğrenmesinin otomotiv, fen bilimleri, tıp, pazarlama ve eğlence sektörü başta olmak üzere birçok kullanım alanı bulunmaktadır. Günümüz ise nesne tanıma, görüntü işleme, artırılmış gerçeklik, ses tanıma, robotlar ve hareketleri gibi pek çok farklı alanda kullanılmaktadır. Makine öğrenmesinin, ses tanıma, makine çevirisi, reklam ve tavsiye sistemleri, endüstriyel ürünlerin bakım kestirimleri, spor performanslarının değerlendirilmesi, haritalama, rota oluşturma, sürücüsüz araçlar, kanserli hücre tespiti, gök cisimlerinin kimyasal yapısının analiz edilmesi, tarlalardaki bitkilerin sağlık durumları, sahtekârlık tespiti ve nesne ve kişi tespit/takip sistemleri gibi çokça uygulama alanı bulunmaktadır.

Yaygın olarak kullanılan makine öğrenmesi algoritmaları aşağıda verilmektedir (Shinde ve Shah, 2018).

4.2.1. Naive Bayes Sınıflandırma Algoritması

Algoritma Bayes teoremine dayanır. Her değer değerinden bağımsız olarak sınıflandırılır. Olasılık kullanarak ve belirli bir dizi özelliğe dayanarak bir sınıf/kategori tahmin etmemizi sağlar.

4.2.2. K-Means Algoritması

Tanımlanmış kategorileri veya gruplar içermeyen verileri kategorilere ayırmak için kullanılan bir algoritmadır. Algoritma veri setini K değişkeni tarafından temsil edilen grup sayısına ayırtırmaya çalışır.

4.2.3. Destek Vektör Makinesi

Kategorize etmek ve tepki incelemesi için kullanılan bilgileri inceleyen denetimini sağlayan makine öğrenmesi algoritmasıdır.

4.2.4. Yapay Sinir Ağları

Her biri her iki taraftaki katmanlara bağlanan bir dizi katmanda düzenlenmiş ünitelerden oluşur. YSA'lar beyin gibi biyolojik sistemlerden ve bilgilerin nasıl işlendiğinden ilham alırlar. YSA temelde belirli sorunları çözmek için birlikte çalışan çok sayıda birbirine bağlı işlem ögesidir. YSA'lar örnek ve deneyim yoluyla öğrenirler.

Doğrusal olmayan yüksek verilerde modellenmek için girdi değişimleri arasında anlaşılması zor olduğu durumlarda çok faydalıdır.

4.2.5. Karar Ağaçları

Kararın her olası sonucunu göstermek için dallanma yönetimini kullanan akış şeması benzeri bir ağaç yapısıdır. Ağacın içindeki her düğüm belirli bir değişken üzerinde bir testi temsil eder ve her dal bu testin sonucudur.

4.2.6. Rassal Orman Algoritması

Rassal orman, sınıflandırma, regresyon ve diğer görevler için daha iyi sonuçlar üretmek üzere birden fazla algoritmayı birleştiren bir toplu öğrenme yöntemidir. Her bir sınıflandırıcı zayıf fakat başkalarıyla birleştiğinde çok daha iyi sonuçlar üretebilirler. Algoritma bir rassal orman ile başlar (ağaç benzeri veya model) ve en üste bir girdi girilir. Daha sonra ağaç aşağı doğru hareket eder, veriler belirli değişkenlere bağlı olarak daha küçük kümelere bölünür.

5. METODOLOJİ

Bu çalışmada zaman seri analizlerinden en çok tercih edilen ARIMA, YSA ve Hibrit bir ARIMA-YSA metotları kullanılmıştır. Bu bölümde de kullanılan yöntemlerin detaylı açıklamalarına yer verilmektedir.

5.1. Box-Jenkins Yöntemi (ARIMA/SARIMA)

Literatürde sıklıkla kullanılan zaman serisi yöntemlerinden bir tanesidir. Box-Jenkins tarafından önerilen bir metot olduğu için Box-Jenkins Modeli veya ARIMA modeli olarak da bilinmektedir (Brockwell ve Davis, 2002).

Box-Jenkins modelleri 4 aşamadan oluşmaktadır. Bu aşamalar:

- i. Seriyeye uygun modelin belirlenmesi
- ii. Modelin tahmini
- iii. Denetim
- iv. Öngörü

i. Modelin Belirlenmesi:

- Box-Jenkins modeli uygulanmadan önce modelin durağanlığı test edilir. Eğer seri durağan değil ise durağan hale dönüştürülür.
- Otokorelasyon Fonksiyonu (ACF - Auto Correlation Function) ve Kısmi Otokorelasyon Fonksiyonu (PACF - Partial Auto Correlation Function) grafikleri çizilir. Grafiklere göre seriyeye en uygun model seçilir.
 - ACF grafiğindeki ilişki miktarı yavaş, PACF grafiğinde ise hızlı bir şekilde azalma oluyorsa model Otokorelasyon (AR) modelidir.
 - ACF grafiğindeki ilişki miktarı hızlı, PACF grafiğinde ise yavaş bir şekilde azalma oluyorsa model Hareketli Ortalama (MA) modelidir.
 - Hem ACF grafiğinde hem de PACF grafiğinde ilişki miktarında yavaş bir şekilde azalma oluyorsa model Otokorelasyon Hareketli Ortalama modelidir.

ACF - Otokorelasyon Fonksiyonu Grafiği: Serinin durağanlığını ve p değerinin hesaplanması için kullanılır. ACF serinin otokorelasyon sayısı ile gecikme

değeri arasındaki ilişkiyi açıklar. Eğer grafikte sınır değerlerin üzerinde değerler var ise seri durağan değildir. Seri fark alarak durağanlaştırılarak işleme devam edilir.

PACF – Kısmi Otokorelasyon Fonksiyonu Grafiği: Kısmi otokorelasyon fonksiyonu ACF'nin bir alt kümesidir. İki noktada yapılan gözlemler arasındaki otokorelasyonu aradaki tüm değerlerin etkisini kaldırarak hesaplanmasıdır. Buradaki amaç tüm değerlerin üzerindeki etkiyi kaldırarak arada gerçekten ilişkili olup olmadığını incelemektir.

ii. Modelin Tahmini:

Grafiklerdeki azalışların hızlı veya yavaş olduğuna karar vermek oldukça zordur. Bu nedenle verilen kararların doğruluğunu anlamak için modeldeki katsayıların önemlilik testi yapılır. Modeldeki katsayıların önemlilik testi t-testi ile yapılmaktadır. Yani modeldeki katsayılardan biri istatistiksel olarak önemsiz ise model seriye uygun değildir demektir. Grafiklerin yanlış yorumlandığı ve modelin seri için uygun olmadığı anlamına gelmektedir.

iii. Denetim:

Seriye uygun model seçildikten sonra tahmin serisi oluşturulur. Tahmin serisinin değerlerinin gerçek değerlere yakınlığını ölçmek için hem tahmin serisinin hem de gerçek serinin grafiği çizilir. İki serinin birbirine olan uyumuna bakılır.

Hataların gürültü olup olmadığını anlamak için hata değerlerinin ACF ve PACF grafikleri çizilir ve Box-Ljung, Portmanteau gibi testlerin sonuçlarına bakılır.

iv. Öngörü:

Seriye seçilen ve uygulanan en uygun model üzerinden öngörü hesaplamaları yapılır.

Otoregresyon (AR): Otoregresif bir model kendi önceki (veya gecikmeli) değerine dayalı olarak değişen bir değişken arasındaki regresyon ilişkisini türetir (Karcıoğlu vd., 2021).

Trend ve mevsimsellik içermeyen tek değişkenli zaman serileri için uygulanan bir yöntemdir. “p” terimi modelin derecesini temsil eder. Örneğin p değeri 1 ise bir önceki zaman adımı ile model kurulmuş demektir.

$$\text{AR (1) Model:} \quad (1 - \phi_1 B)Z_t = \varepsilon_t \quad (1)$$

$$\text{AR (2) Model:} \quad (1 - \phi_1 B - \phi_2 B^2)Z_t = \varepsilon_t \quad (2)$$

$$\text{AR (p) Model:} \quad (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = \varepsilon_t \quad (3)$$

Hareketli Ortalama (MA): Bir gözlem ile önceki (veya gecikmeli) gözlemlere uygulanan hareketli ortalama modelinden kalan hata kombinasyonları ile tahmin yapılmaktadır. Trend ve mevsimsellik içermeyen tek değişkenli zaman serileri için uygulanan bir yöntemdir.

$$\text{MA (1) Model:} \quad Z_t = (1 - \theta_1 B)\varepsilon_t \quad (4)$$

$$\text{MA (q) Model:} \quad Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)\varepsilon_t \quad (5)$$

Entegrasyon (I): Entegrasyon, ham gözlemler arasındaki farkları modellemeyi ifade eder, böylece zaman serileri durağan kabul edilebilir. Bir başka deyişle, ham değerler, ham değerler ile önceki değerler arasındaki farklarla değiştirilir (Karcıoğlu vd., 2021).

5.1.1. ARMA Modeli

ARMA doğrusal bir regresyon modelidir. Bu model de AR ve MA modellerinde olduğu gibi trend ve mevsimselliğin olmadığı tek değişkenli zaman serilerinde uygulanabilmektedir.

ARMA modeli iki farklı model olan AR (otoregresyon) ve MA (hareketli ortalama)'nın birleşimi ile oluşmaktadır.

$$\text{ARMA}(p,q) = \text{AR}(p) + \text{MA}(q)$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)\varepsilon_t \quad (6)$$

5.1.2. ARIMA Modeli

Geçmiş gerçek değerler ve geçmiş hataların doğrusal kombinasyonunun bir fark alma işlemi ile gerçekleşmesi işlemine ARIMA denir. ARIMA (Oto regresif Hareketli Ortalama) modeli genel olarak ARIMA (p,d,q) şeklinde gösterilir. ARIMA modeli mevsimselliğin olmadığı ve durağan serilerde kullanılır. Fakat durağan serilere günlük hayatta oldukça az rastlanır. Seriyi durağan hale dönüştürmek için fark alma yöntemi uygulanır. Durağanlaştırılan zaman seriler ile ileriye dönük tahmin yapılır.

ARIMA modeli 3 parametreye sahiptir. Bunlar;

p : AR modelin derecesini,

d : serinin durağanlaştırılabilmesi için kaçınıcı dereceden farkının alındığını,

q : MA modelinin derecesini temsil etmektedir.

ARIMA modelinin genel formülü şu şekildedir:

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (7)$$

∇ = Fark alma operatörü

d = Fark alma derecesi

w_t = Farkı alınmış seri

$\nabla z_t = w_t = z_t - z_{t-1}$

$\nabla z_t = w_t = z_t - z_{t-1}$

5.1.3. SARIMA Modeli

Trend veya mevsimsellik içeren zaman serilerinde mevsimsel ARIMA metodu olan SARIMA modeli kullanılmaktadır. SARIMA(p,d,q),(P,D,Q,m) şeklinde gösterilir. SARIMA modelin parametreleri:

P: Mevsimsel AR (SAR) modelin derecesi,

D: Mevsimsel fark alma işlemi derecesi,

Q: Mevsimsel MA modelin derecesini,

m: periyodu temsil etmektedir.

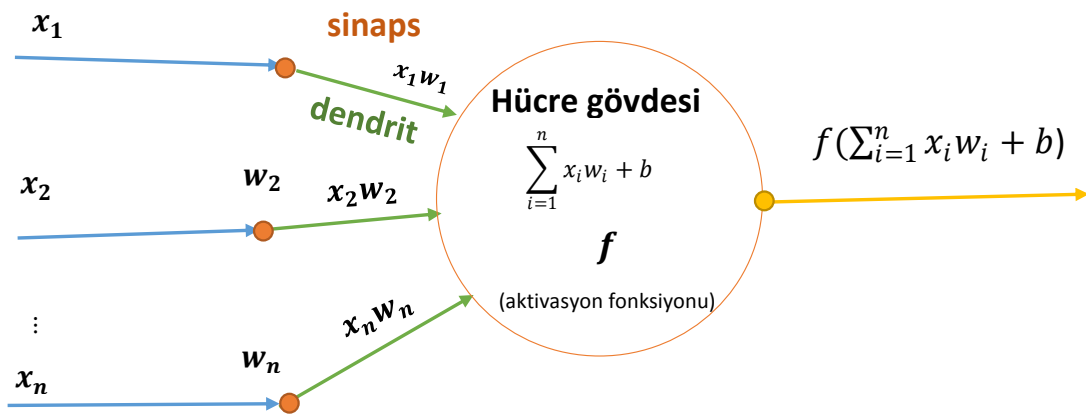
5.2. Yapay Sinir Ağları

Yapay sinir ağlarına ilk adım 1943 yılında Warren McCulloch ve Walter Pitts'in elektrik devrelerini kullanarak insan beyninden esinlenilmiş bir yapay sinir hücresi kurması ile atılmıştır. Yapılan bu ilk çalışmadan sonra YSA çeşitli gelişmeler ile günümüzdeki halini almıştır (Keskenler ve Keskenler, 2017).

Yapay sinir ağları; insan beynindeki sinir hücresi olan nöronların çalışma prensibinden esinlenerek modellenen, kendi kendini eğitime özelliğine sahip bir makine öğrenmesi algoritmasıdır. Tanımlanması ve modellenmesi zor olan problemlerde kullanımı oldukça yaygın bir modeldir. Teşhis, tahmin, sınıflandırma, sinyal işleme, veri filtreleme, robotik, planlama vb. gibi birçok alanda yaygın olarak kullanılan bir yöntemdir.

Çizelge 1. Biyolojik Sinir Sistemi elemanları ve ona karşılık gelen YSA elemanları (Çoban ve Demir, 2021).

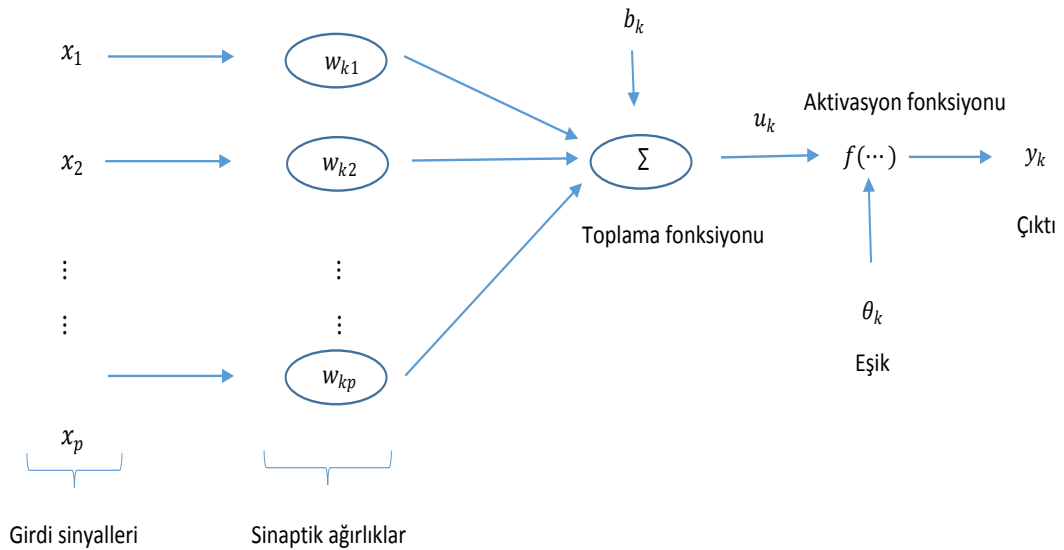
Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci elemanı
Sinaps	Ağırlıklar
Dendrit	Toplama fonksiyonu
Hücre Gövdesi	Aktivasyon fonksiyonu
Akson	Çıkış



Şekil 3. Yapay sinir hücresi matematiksel modeli

Biyolojik sistemlerde nöronlar birbirlerine sinaplardan sinaptik ağlar ile bağlıdır. Veriler hücreye dışarıdan veya bir önceki sinir hücresinden sinaplara gelmektedir.

Dentrit dediğimiz yollarda ağırlıklar mevcuttur. Bir önceki sinir hücresinden gelen veriler dentritlerde çarpılarak hücre gövdesine geçer. Hücre gövdesine dentritlerden gelen verilere ağırlıklı toplama işlemi yapılmaktadır. Daha sonra bias ile toplanır. Çıkan sonuçlar aktivasyon fonksiyonuna aktarılırlar. Aktivasyon fonksiyonundan çıkan sonuçlar çıkışa aktarılır. Bu sonuçlar nihai sonuç da olabilirler bir sonraki giriş hücresinin giriş verileri de olabilirler.



Şekil 4. Yapay sinir hücresi ağı yapısı (Çoban ve Demir, 2021).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (8)$$

$$y_k = f(u_k + b_k) \quad (9)$$

x_1, x_2, \dots, x_p : Giriş sinyali. Nöronlara gelen verilerdir.

$w_{k1}, w_{k2}, \dots, w_{kp}$: k. nöronun sinaptik ağırlığı

b_k (bias): sapma

u_k : giriş verilerine göre doğrusal birleştirici çıkışı

θ_k : eşik değeri

$f(\dots)$: aktivasyon fonksiyonu

y_k : nöronun çıkış sinyali

Girdiler: Nörondan gelen verilerdir. Dış dünyadan gelen nöronlara gönderilen bilgilerdir (verilerdir).

Toplama Fonksiyonu (Birleştirme fonksiyonu): Hücreye giren net girdiyi hesaplayan fonksiyondur. Hücreye giren girdiler ağırlıklar ile çarpılarak ve toplanarak net girdi hesaplanır.


Aktivasyon fonksiyonu: Girdi ve çıktı arasındaki bağlantıyı kuran fonksiyondur. YSA'nın modeline göre çeşitli fonksiyonlar kullanılabilir. Toplama fonksiyonundan gelen girdileri işleyip bir sonraki katman olan çıkış katmanına yollayan bir fonksiyondur.

YSA üç ana katmandan oluşmaktadır. İlk katman bilgilerin ağa geldiği giriş katmanı (input layer), ikinci katman bilgilerin işlendiği gizli katman (hidden layer) ve son katman işlenen bilgilerin çıktıya dönüştüğü ve çıkış katmanı (output layer). Model tek bir gizli katmandan oluşuyorsa tek katmanlı sinir ağı (single layer artificial neural network), birden fazla katmandan oluşuyor ise çok katmanlı sinir ağı (multi layer artificial neural network) olarak adlandırılır.

5.2.1. Tek Katmanlı Sinir Ağlar

Tek katmanlı ağlar 1958 yılında Cornell Üniversitesinde psikolog Frank Rosenbatt tarafından ortaya atılmıştır. 1969 yılından sonra yavaş yavaş rafa kaldırılmaya başlamıştır. Çünkü tek katmanlı sinir ağları basit problemlerin çözümlerinde oldukça etkili iken karmaşık problemlerde etkili çözüme ulaşamamaktadır. 1980'lere gelindiğinde çok katmanlı sinir ağları modeli geliştirilerek karmaşık problemler çözüme ulaştırılmıştır


Tek katmanlı yapay sinir ağları doğrusal problemlerin çözümünde kullanılıp sadece girdi ve çıktı katmanından oluşmaktadır. Katmanların bir veya daha fazla nöronu bulunabilmektedir. Şekil 5'te basit bir tek katmanlı algılayıcı (TKA) modeli gösterilmiştir (Arı ve Berberler, 2017).



Şekil 5. Tek katmanlı sinir ağı modeli (Arı ve Berberler, 2017).

5.2.2. Çok Katmanlı Sinir Ağları

YSA'ların günümüzde en çok yaygın olarak kullanılan modeli Çok Katmanlı Sinir Ağlarıdır. Girdi katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Karmaşık, doğrusal olmayan problemlerin çözümünde kullanılır. Gizli katman sayısı problemin türüne göre değişiklik gösterir.



Şekil 6. Çok katmanlı YSA modeli (Ünlü, 2019).

5.3. ARIMA-YSA Hibrit Modeller

Literatürde en çok kullanılan ARIMA-YSA melez modellerinden bazıları bu bölümde incelendi. ARIMA-YSA Melez modelleri:

1. Zhang Modeli
2. Khashei ve Bijari Modeli

3. Babu ve Reddy Modeli

5.3.1. Zhang ARIMA-YSA Modeli

Literatürdeki ilk ARIMA-YSA modeli 2003 yılında Zhang tarafından ortaya konulmuştur. Zhang zaman serisini doğrusal ve doğrusal olmayan iki serinin toplamı şeklinde ele almaktadır.

$$Y_t = L_t + N_t \quad (10)$$

Y_t gerçek seriyi, L_t modelin doğrusal bileşenini N_t ise doğrusal olmayan bileşenini doğrusal olmayan kısım olarak kabul edilir (Zhang, 2003).

$$ARIMA(Y_t) = y_{t,ARIMA} + e_{t,ARIMA} \quad (11)$$

$$l_t = y_{t,ARIMA} \quad (12)$$

$$e_{t,ARIMA} = Y_t - l_t \quad (13)$$

$$N_t = e_{t,ARIMA} \quad (14)$$

Doğrusal olmayan bileşen N_t YSA ile modellenmektedir. Doğrusal olmayan kestirim N_t ve hata değeri $e_{t,YSA}$ elde edilmektedir (Erturan ve Merdivenci, 2021).

$$YSA(N_t) = n_{t,YSA} + e_{t,YSA} \quad (15)$$

$$e_t = e_{t,YSA} \quad (16)$$

5.3.2. Khashei ve Bijari ARIMA-YSA Melez Modeli

Model de zaman serisi doğrusal veya doğrusal olmayan bileşenlere ayırlanamamaktadır. Zaman serisi gözlemlerin ve hataların doğrusal olmayan fonksiyonu olarak kabul edilir.

Zaman serileri ilk olarak ARIMA modeli ile modellenir. Modelleme sonucunda ARIMA tahmin değeri $y_{t,ARIMA}$ ve artık değer denilen hata değeri $e_{t,ARIMA}$ elde edilir.

$$Y_t = ARIMA(Y_t) = y_{t,ARIMA} + e_{t,ARIMA} \quad (17)$$

Artıklar ve orjinal veride var olan doğrusal olmayan değerler YSA ile modellenir.

t zamanlı n adet gecikmeli ARIMA hata değeri ve m adet gecikmeli gerçek değer kullanıldığı bir YSA modelinin girdi sayısı $(n+m+1)$ 'dir.

$$Y_t = YSA(e_{t-1,ARIMA} + e_{t-2,ARIMA} + \dots + e_{t-n,ARIMA} + Y_{t-1} + Y_{t-2} + \dots + Y_{t-m}) \quad (18)$$

$$Y_t = y_{t,YSA} + e_{t,YSA} \quad (19)$$

YSA modelinin sonucunda $y_{t,YSA}$ tahmin değeri ve $e_{t,YSA}$ hata değeri oluşmaktadır (Erturan ve Merdivenci, 2021, Khashei ve Bijari, 2010).

5.3.3. Hareketli ortalama filtreli ARIMA-YSA modeli

Zhang ve Khashei ve Bijari tarafından önerilen hibrit yöntemlerde verilerin doğrusal ve doğrusal olmaya bileşenlerin toplamı olduğu varsayılmıştır. Babu ve Reddy verilerin doğrusal ve doğrusal olmayan bileşenlere ayrıştırılamayacağını söyleyerek hareketli ortalama filtreli yeni bir melez model önermiştir.

Doğrusal bileşen hareketli ortalama filtresi ile oluşturulur. Zaman serisi Y_t , düşük uçtaki l_t ve yüksek uçtaki h_t 'nin toplamıdır.

$$Y_t = l_t + h_t \quad (20)$$

Hareketli ortalamalar filtresi ile zaman serisi verileri düşük uç ve yüksek uçlu veriler olma üzere 2 ye ayrılırlar.

$$Y_{tr} = \frac{1}{m} \sum_{i=t-m+1}^t Y_i \quad (21)$$

Y_{tr} hareketli ortalamalar filtresi ile elde edilen düşük uçtaki seridir. Y_{res} gerçek seriden filtrelenen serinin çıkarılması ile elde edilen yüksek uçtaki seridir.

$$Y_{res} = Y_t - Y_{tr} \quad (22)$$

$$l_t = Y_{tr} \quad (23)$$

$$h_t = Y_{res} \quad (24)$$

Düşük uçtaki bileşen l_t doğrusal bileşendir ve ARIMA ile modellenir, yüksek uçtaki bileşen h_t ise doğrusal olmayan bileşendir ve YSA ile modellenir (Erturan ve Merdivenci, 2021).

$$l_t = ARIMA(l_t) = l_t + e_t \quad (25)$$

$$h_t = YSA(h_t) = h_t + e_t \quad (26)$$

$$y_t = l_t + h_t \quad (27)$$

5.4. Uygulanan ARIMA-YSA Hibrit Model

Günlük hayat verilerinde doğrusal ve doğrusal olmayan veriler iç içe geçmiş durumdadır. ARIMA modelleri doğrusal zaman serilerini modellemede iyidir, ancak doğrusal olmayan yapıyı yakalamada çok iyi değildir. Gerçek hayat problemlerinde veri yapısının özelliklerini tam olarak bilmek kolay değildir. Bu nedenle hem doğrusal hem de doğrusal olmayan modelleme yeteneklerine sahip hibrit metodolojinin kullanılması, makine arıza zamanı tahmini için uygun görülmektedir.

Genel olarak hibrit modeller verileri iki aşamada incelemektedir. İlk aşama, regresyon veya zaman serisi modelleri gibi geleneksel yöntemlerle modellenmektedir. Daha sonra yapay sinir ağları gibi makine öğrenmesi yöntemleri kullanılarak hatalar modellenir. Bu çalışmada Zhang (2013) çalışması temel alınarak ARIMA-YSA hibrit modeli önerilmiştir. Önerilen ARIMA-YSA hibrit modeli Şekil 7'de gösterilmektedir.

Birinci bölümde başlangıç tahmin değeri elde etmek için zaman serisi ARIMA ile modellenir. ARIMA modeli ile tahminleme 7 adımda gerçekleşmektedir.

Adım 1: Zaman serisi verileri ile veri seti oluşturulur.

Adım 2: Mevsimsellik ve trend analizi yapılır.

Adım 3: Serinin durağanlığı kontrol edilir. Durağan değilse durağan hale dönüştürülür.

Adım 4: ACF ve PACF grafikleri çizilir.

Adım 5: Seriyeye en uygun ARIMA (p,d,q) modeli hesaplanır.

Adım 6: Gelecek dönem tahmini yapılır.

Adım 7: Modelin güvenilirliği ölçülür.

İkinci bölümde artık değerler $y(i)$ hesaplanır. Zaman serisi $x(i)$, ilk tahmin değeri \hat{x}_i ' dir. Tahminin değerinin gerçek verilerden farkı alınarak artık değer hesaplanır.

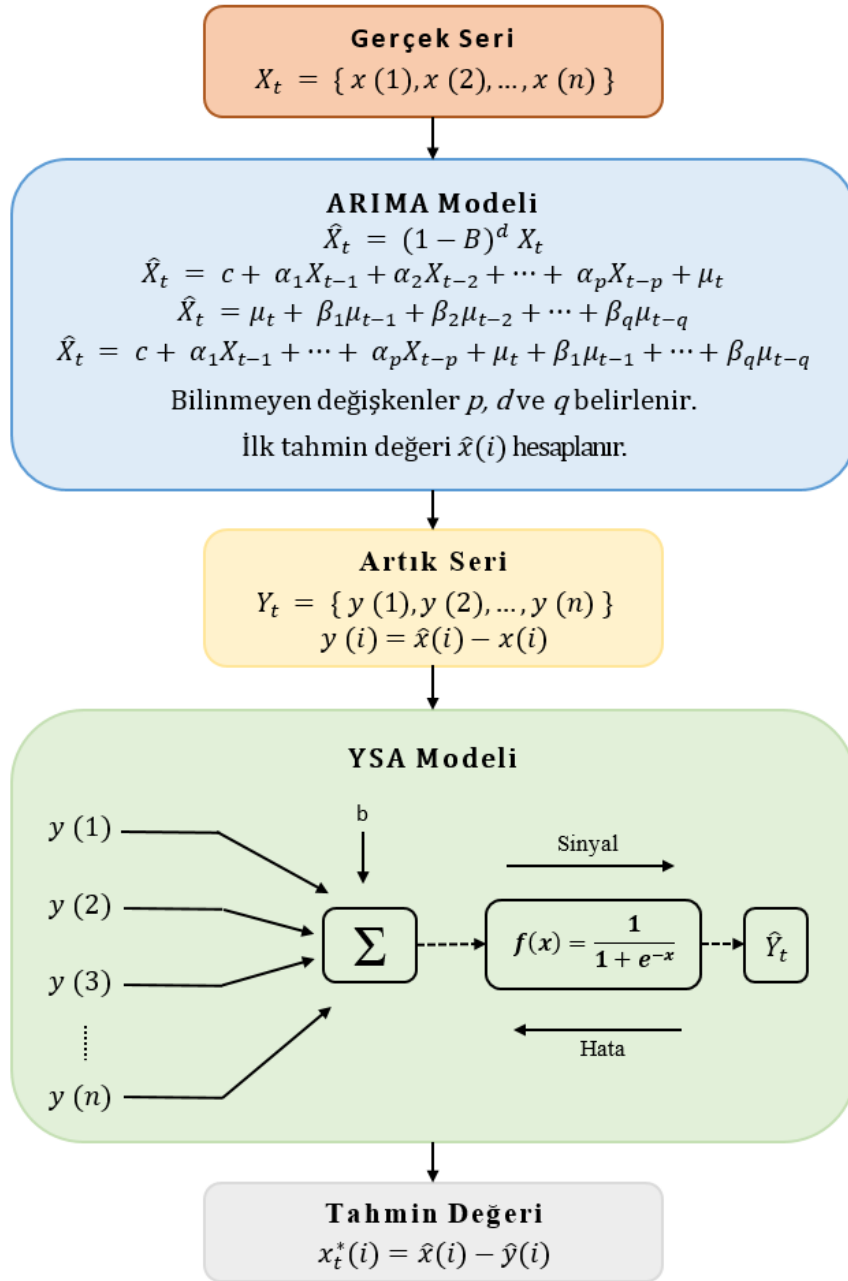
$$y_i = \hat{x}_i - x_i \quad (28)$$

Üçüncü bölümde artık değerler YSA ile modellenir. Ham veriler YSA'nın eğitim seti olarak kullanılır.

Dördüncü bölümde yeni artıklar $y(i)$ ilk tahmin değeri $\hat{x}(i)$ nihai tahmin değeri $x(i)$ kombinasyon modeli elde edilir.

ARIMA modeli ile yapılan tahmin değerinin YSA modeli ile yapılan tahmin değeri ile farklı alınarak hibrit modelin tahmin değerleri hesaplanmış olur.

$$x_t^*(i) = \hat{x}(i) - \hat{y}(i) \quad (29)$$



Şekil 7. ARIMA-YSA hibrit model akış şeması


6. UYGULAMA

Bu çalışmada, Bölüm 5'te açıklanan ARIMA, YSA yöntemleri ve bu iki yöntemi birlikte kullanan hibrit metodolojiden yararlanılarak makine arıza zamanı tahminleri elde edilmiştir. Modelin lineer kısmını tahmin etmek için ARIMA modeli kullanılmıştır. Doğrusal olmayan kısım için Doğrusal Olmayan Otoregresif (NAR) Sinir Ağı yöntemi kullanılmaktadır. Hibrit model bu iki modelin birleştirilmesiyle oluşturulmuştur. Ardından bu modeller tahmin performanslarına göre karşılaştırılmaktadır. Tahmin edilen değerlerin ve gerçek değerlerin zaman serisi grafikleri bu bölümde sunulmaktadır. Ayrıca tüm modeller için tahmin performansı tabloları Ekler kısmında verilmiştir. Doğrusal modelleme kısmı SPSS yazılımı ile doğrusal olmayan kısım ise MATLAB Sinir Ağları Zaman Serisi (Neural Network Time Series) aracı kullanılarak oluşturulmuştur.

6.1. Veri Seti

Önerilen yöntem için vaka çalışması makarna üretimi yapılan bir tesiste gerçekleştirilmiştir. Tesis günde üç vardiya çalışmaktadır. Firmadan üretim hattında meydana gelen arızaların gün ve saatini içeren veri temin edilmiş ve tahminlemede bu veriler kullanılmıştır. Veriler incelendiğinde üretimi en çok kesintiye uğratan ve günlük operasyonlarda önemli bir rol oynayan kurutma makinesinde (dryer) ortaya çıkan arızaların ele alınması kararlaştırılmıştır. Kurutma hattı çalışmazsa tüm üretim işlemi durmaktadır. Yönetim, makinenin arıza zamanını doğru ön görebilirse, arızaları önlemek için uygun bakım planlama faaliyeti gerçekleştirebilecektir.

Kurutma hattında meydana gelen toplam 50 arızaya ait arızalar arası süreler ve kümülatif arıza zamanları Çizelge 2'de ve kümülatif verilerin zaman serisi grafiği Şekil 8'de verilmiştir. Tahmin için kümülatif arıza zamanı verisi kullanılmış ve 50 kümülatif arıza verisinden son 7'si test verisi olarak kalan veriler ise eğitim için kullanılmıştır.



Şekil 8. Makine arıza verileri zaman serisi grafiği

6.2. Performans Ölçütleri

ARIMA, YSA ve hibrit ARIMA-YSA modelleri kullanılarak elde edilen deterministik tahminleri nicel olarak değerlendirmek için üç performans metriği kullanılmıştır: Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE), Ortalama Mutlak Yüzde Hatası (MAPE) ve Karekök Ortalama Karesel Hata (RMSE). Ayrıntılı matematiksel ifadeler aşağıda listelenmiştir.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (30)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (31)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (32)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (33)$$

Çizelge 2. Uygulamada kullanılan arıza verileri

Arıza Sıra No	Arızalar arası süre (saat)	Kümülatif arıza zamanı (saat)	Arıza Sıra No	Arızalar arası süre (saat)	Kümülatif arıza zamanı (saat)
1	39	39	26	386	1181
2	43	82	27	44	1225
3	50	132	28	111	1336
4	29	161	29	44	1380
5	19	180	30	48	1428
6	19	199	31	39	1467
7	21	220	32	76	1543
8	22	242	33	97	1640
9	25	267	34	19	1659
10	38	305	35	37	1696
11	27	332	36	15	1711
12	14	346	37	17	1728
13	23	369	38	91	1819
14	36	405	39	47	1866
15	20	425	40	8	1874
16	23	448	41	28	1902
17	16	464	42	50	1952
18	123	587	43	28	1980
19	25	612	44	63	2043
20	23	635	45	110	2153
21	59	694	46	93	2246
22	7	701	47	12	2258
23	43	744	48	77	2335
24	36	780	49	27	2362
25	15	795	50	123	2485

6.3. Tahmin Modelleri


6.3.1. ARIMA Tahmin Modeli

Tahmin işlemi için SPSS programı kullanılmıştır. Veri setindeki 3 aylık arıza verisinin ilk 42 verisi kullanılmıştır. Son 8 tanesi ise yapılan tahminlerin doğruluğunu test etmek için kullanılmıştır. 42 adet arıza verisi ile veri setine en uygun ARIMA

modeli hesaplanmıştır. Hesaplanan ARIMA modeline göre oluşacak 8 arıza verisi tahmin edilmiştir. Şekil 8 'de arıza verilerin zaman serisi grafiği gösterilmektedir.

Serinin durağanlığını, otokorelasyon değeri (p) ile arasında gecikme olup olmadığını analiz etmek için ACF ve PACF grafikleri çizilir. Veri setinin çizilen grafikler ile hangi Box-Jenkins modeline uygun olduğu analiz edilir.


Şekil 9' da ACF grafiği, Şekil 11' de ise PACF grafiği görülmektedir.




Şekil 9. ACF grafiği

Şekil 9'da görüldüğü gibi ACF grafiğindeki değerler sınır değerlerin üzerinde olduğu için seri durağan değildir. Fark alma işlemi uygulanarak seri durağanlaştırılmalıdır.


PACF grafiğinde görüldüğü gibi 1. gecikme en yüksek kısmi otokorelasyon değerine sahip olduğu için 1 dereceden fark alınarak daha anlamlı sonuçlar elde edilmelidir. (d=1) ACF grafiğinde de sadece ilk gecikme önemli olduğu için q=1 alınmalıdır.



Şekil 10. PACF grafiği



Şekil 11. Birinci dereceden fark alındıktan sonra oluşan serinin ACF grafiği



Şekil 12. Birinci dereceden fark alındıktan sonra oluşan serinin PACF grafiği

Zaman serisi modeline göre veri setinin yapısına en uygun ARIMA(p,d,q) modeli seçilir. Çizelge 3 'te görüldüğü gibi veri setine en uygun model ARIMA(0,1,1) modeli bulunmuştur.

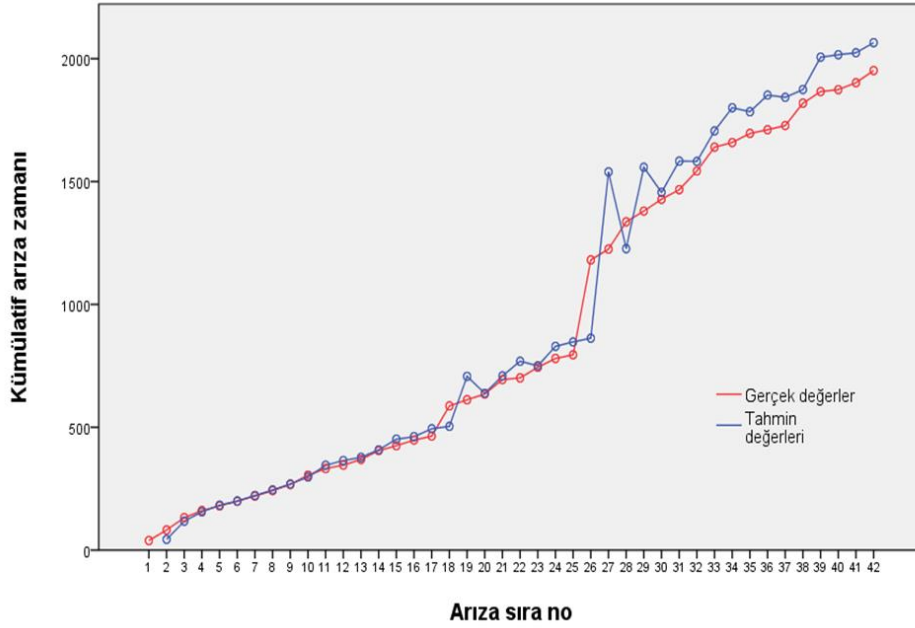
Çizelge 3. Makine arızası veri seti ARIMA modeli

Model Description			
			Model Type
Model ID	veri seti	Model_1	ARIMA(0,1,1)

ARIMA (0,1,1) modeli ile arıza tahmini yapılmıştır. Elde edilen tahmin değerlerinin tümü Ek-1'de sunulmaktadır. Test verisi için elde edilen tahmin değerleri Çizelge 4'te gösterilmiştir.

Çizelge 4. ARIMA(0,1,1) Modeli ile yapılan tahmini test verileri

Arıza numarası	ARIMA(0,1,1) tahmin değerleri
43	2126
44	2393
45	2693
46	3031
47	3412
48	3841
49	4323
50	4867



Şekil 13. ARIMA (0,1,1) modeli ile yapılan arıza tahmini ve gerçekleşen makine arızası verileri grafiği


Çizelge 5. ARIMA(0,1,1) modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları

	MAPE (%)	MAE	MSE	RMSE
ARIMA(0, 1, 1)	47,37	1102,95	1771323,34	1330,91

6.3.2. YSA Tahmin Modeli

Tahmin işlemi için MATLAB programı kullanılmıştır. YSA tahmin modelini oluşturmak için 42 arıza verisi kullanılmıştır. 8 veri ise test için ayrılmıştır.

Bu model için oluşturulan ağ Şekil 14'te gösterilmektedir. Bu ağda gecikme sayısı 1 ve gizli katman sayısı 10 olarak alınmıştır.



Şekil 14. Uygulamada kullanılan YSA modeli

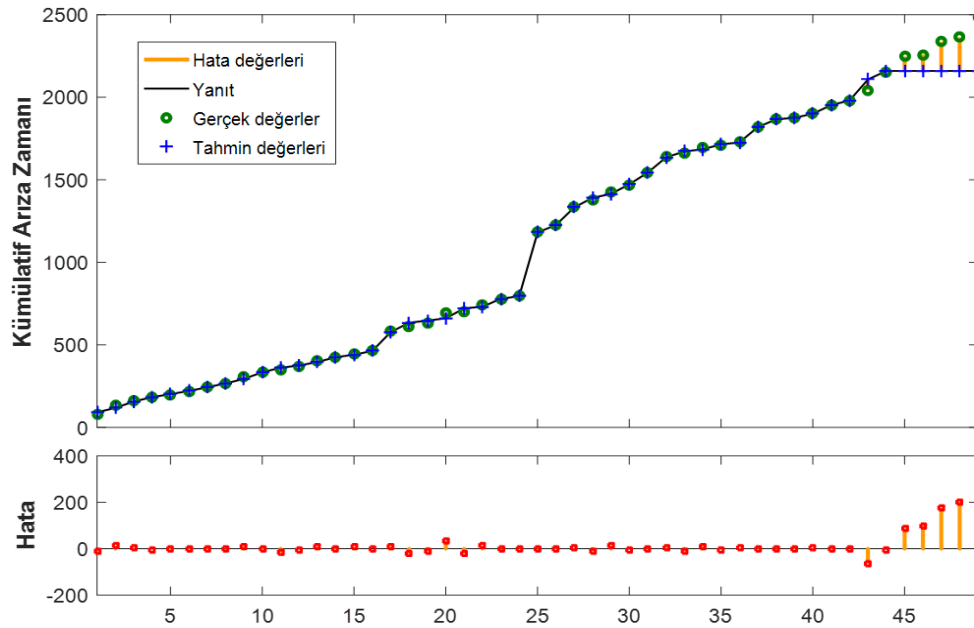
Bu parametreler farklı değerler denenerek ve performansları karşılaştırılarak karar verilmiştir. Yapay sinir ağları ile elde edilen tahmin değerleri Ek-2 ve Çizelge 6'da gösterilmektedir.

Çizelge 6. YSA ile yapılan arıza tahmini test verileri

Arıza verileri	YSA tahmin sonuçları
43	1989
44	2060
45	2133
46	2206
47	2276
48	2342
49	2402
50	2455

Çizelge 7. YSA modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları

	MAPE (%)	MAE	MSE	RMSE
YSA	5,18	120,17	25002,05	158,12



Şekil 15. YSA modeli ile yapılan arıza tahmini grafiği

6.3.3. ARIMA-YSA Hibrit Tahmin Modeli

Başlangıç tahmin değerlerini oluşturmak için ARIMA modeli ile tahmin yapılır. Veri setine en uygun model ARIMA(0,1,1) modeli bulunmuştur. ARIMA(0,1,1) ile yapılan tahmin sonuçları Çizelge 4 'te gösterilmiştir.

Veri seti ARIMA ile modellendikten sonra artık (hata) değerler oluşturulur. Artık değerler Denklem (28) uygulanarak hesaplanır.

Zaman serisi $x(i)$, ilk tahmin değeri $y(i)$ ' dir. Tahminin değerinin gerçek verilerden farkı alınarak artık değer hesaplanır. Çizelge 8.'de artık değerler görülmektedir.

Çizelge 8. Artık değer sonuçları

Arıza numarası	Artık değerler
43	146
44	350
45	540
46	785
47	1154
48	1506
49	1961
50	2382

Oluşturulan artık değerler YSA modeli ile tahminlenir. Artık değer Çizelge 8'de verilmiştir. YSA modelini oluşturmak için veri setindeki 42 adet arıza verisi kullanılmıştır. 8 veri ise test için ayrılmıştır. Bu aşda gecikme sayısı 1 ve gizli katman sayısı 10 olarak alınmıştır.

Veri setine göre uygun olarak oluşturulan YSA modeline göre 8 tane artık değerlerin tahmin değeri hesaplanmaktadır. Artık değerlerin YSA modeli ile elde edilen tahmin değerleri Çizelge 9' da verilmiştir.

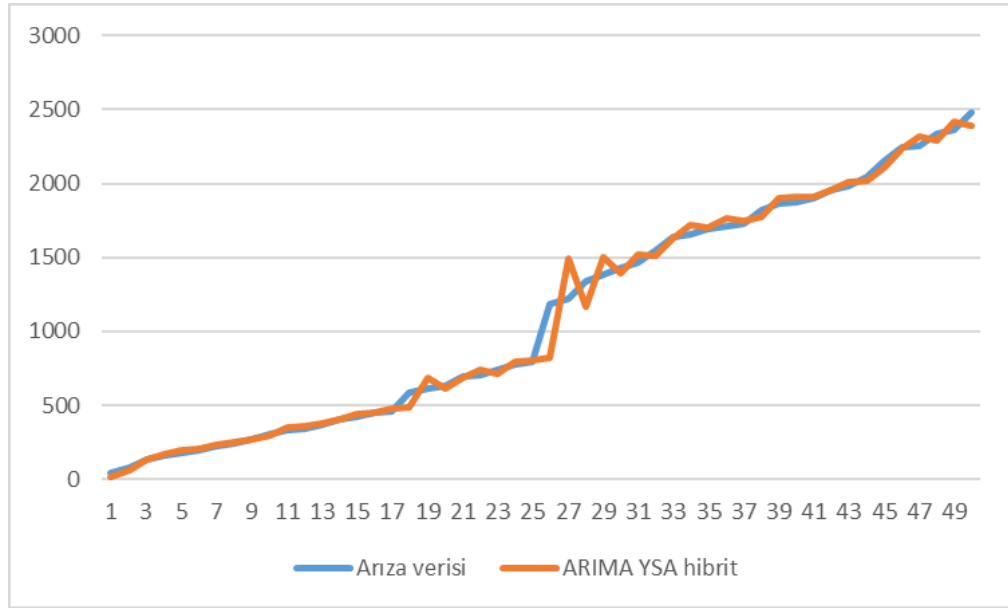
Çizelge 9. Artık değerlerin YSA tahmin sonuçları

Arıza numarası	YSA tahmin değerleri
43	186
44	324
45	521
46	792
47	1137
48	1539
49	1963
50	2364

Hibrit uygulamanın arıza tahmin sonuçlarını bulmak için Denklem (29) kullanılır. ARIMA-YSA hibrit modelinin arıza tahmin değerleri Çizelge 10 'da verilmiştir.

Çizelge 10. ARIMA-YSA hibrit modeli arıza tahmini sonuçları

Arıza numarası	Hibrit modelin tahmin sonuçları
43	1940
44	2069
45	2172
46	2239
47	2275
48	2302
49	2360
50	2503



Şekil 16. Hibrit modelin kümülatif veriler ile yapılan tahmin değerleri grafiği

Çizelge 11. ARIMA-YSA hibrit modeli ile yapılan tahminlerin test verilerinin istatistiksel sonuçları

	MAPE (%)	MAE	MSE	RMSE
ARIMA-YSA	0,83	18,33	375,33	19,37

6.4. Analiz Sonuçları ve Tartışma

Kestirimci bakım planı oluşturmak için 3 farklı model ile makine arıza tahmini çalışması yapıldı. Hangi modelin daha iyi tahmin sonucu verdiğini analiz etmek için de istatistiksel olarak modeller performans metrikleri ile analiz edildi. Çizelge 12’de gerçekleşen arıza verileri ve yapılan tahmin değerleri gösterilmektedir.

Çizelge 12. Gerçekleşen arıza verileri ve ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan tahmin değerleri

Arıza numarası	Gerçekleşen arıza verileri	ARIMA-YSA	ARIMA	YSA
44	2043	2069	2393	2060
45	2153	2172	2693	2133
46	2246	2239	3031	2206
47	2258	2275	3412	2276
48	2335	2302	3841	2342
49	2362	2360	4323	2402
50	2485	2503	4867	2455

Çizelge 13’te test verilerini istatistiksel verileri ve Çizelge 14’te 3 aylık arıza tahmini sonuçlarının istatistiksel verileri gösterilmiştir.

Çizelge 13. ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan tahmin çalışmalarının test verilerinin istatistiksel sonuçları

	MAPE (%)	MAE	MSE	RMSE
ARIMA	47,37	1102,95	1771323,34	1330,91
YSA	5,18	120,17	25002,05	158,12
ARIMA-YSA	0,83	18,33	375,33	19,37

Çizelge 13’te test verilerinin ARIMA, YSA ve hibrit model için istatistiksel sonuçları gösterilmiştir. Ortalama mutlak yüzde hata değerine göre (MAPE) ARIMA modeli 47,37, YSA modeli 5,18 ve hibrit model ise 0,83 değerini almıştır. MAPE değeri;

- %10’un altında olan modelleri “çok iyi”,
- % 10 ile % 20 arasında olan modelleri “iyi”,

- % 20 ile % 50 arasında olan modelleri “kabul edilebilir” ve
- % 50’ nin üzerinde olan modelleri ise “yanlış ve hatalı” olarak sınıflandırmıştır (Karahana, 2015).

Bu değerlendirmeye göre YSA ve Hibrit model çok iyi sonuçlar verirken ARIMA modeli ise kabul edilebilir sonuçlar vermiştir. YSA ve Hibrit modeli kendi aralarında değerlendirdiğimizde Hibrit modelin sonucu YSA modeline göre daha minimum değere sahip olduğu için Hibrit model daha iyi performans göstermektedir.

Ortalama mutlak hata (MAE) performans metriği için ARIMA 1102,95, YSA 120,17 ve hibrit model 18,33 değerlerini almıştır. En iyi performansı 0’ a en yakın değer olan hibrit yöntem daha sonra ise YSA modeli göstermiştir.

Ortalama karesel hata (MSE) performans metriğine göre ARIMA modeli 1771323,34, YSA modeli 25002,05 ve hibrit model ise 375,33 değerini almıştır. En iyi performansı aralarındaki minimum değere sahip olan hibrit model göstermiştir.

Karekök ortalama mutlak hata değerine göre (RMSE) ARIMA modeli 1330,9, YSA modeli 158,12 ve hibrit model ise 19,37 değerini almıştır. En iyi performansı aralarındaki minimum değere sahip olan hibrit model göstermiştir.

Çizelge 14. ARIMA, YSA ve ARIMA-YSA hibrit modeller ile yapılan 3 aylık tahmin verilerinin istatistiksel sonuçları

	MAPE (%)	MAE	MSE	RMSE
ARIMA	7,36	68,07	10383,68	101,90
YSA	1,59	6,62	96,19	9,81
ARIMA-YSA	0,38	1,67	4,69	2,17

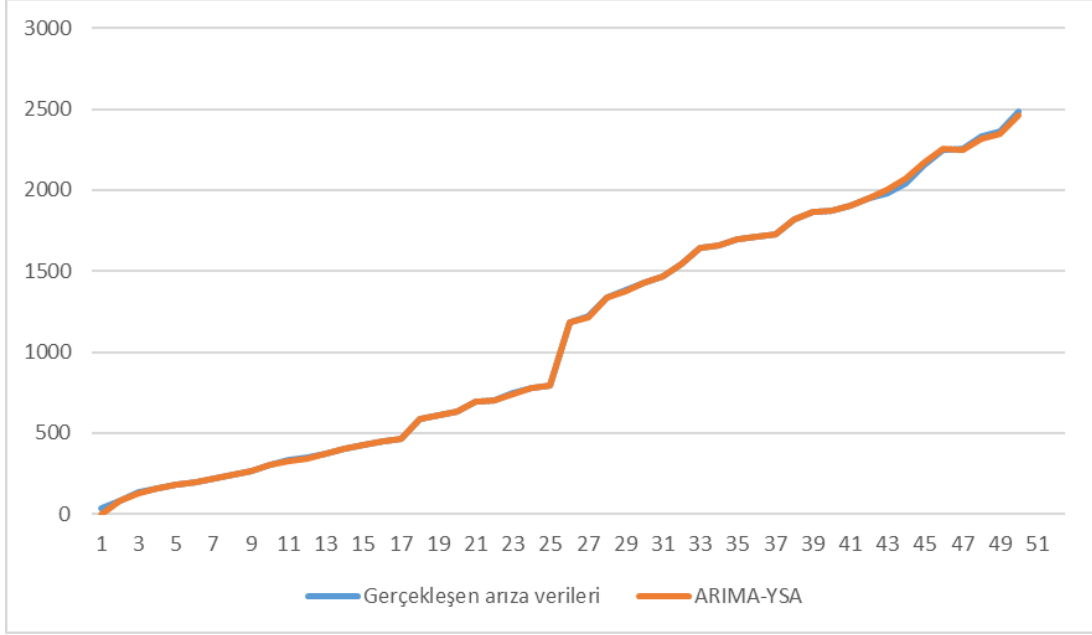
Çizelge 14’ te 3 aylık tahmin verilerinin ARIMA, YSA ve hibrit model için istatistiksel sonuçları gösterilmiştir.

Ortalama mutlak yüzde hata değerine göre (MAPE) ARIMA modeli 7,36 , YSA modeli 1,59 ve hibrit model ise 0,38 değerini almıştır. Hibrit model daha iyi performans göstermektedir.

Ortalama mutlak hata (MAE) performans metriği için ARIMA 68,07, YSA 6,62 ve hibrit model 1,67 değerlerini almıştır. En iyi performansı 0’ a en yakın değer olan hibrit yöntem daha sonra ise YSA modeli göstermiştir.


Ortalama karesel hata (MSE) performans metriğine göre ARIMA modeli 10383,68, YSA modeli 96,19 ve hibrit model ise 4,69 değerini almıştır. En iyi performansı aralarındaki minimum değere sahip olan hibrit model göstermiştir.

Karekök ortalama mutlak hata değerine göre (RMSE) ARIMA modeli 101,90, YSA modeli 9,81 ve hibrit model ise 2,17 değerini almıştır. En iyi performansı aralarındaki minimum değere sahip olan hibrit model göstermiştir.



Şekil 17. Makine arıza verileri ve hibrit modelin tahmin sonuçları grafiği

Şekil 17' de hibrit model ile gerçekleşen makine arızası verilerinin zaman serisi gösterilmektedir.



Şekil 18. Makine arıza verileri, ARIMA, YSA ve Hibrit model ile yapılan makine arıza tahmin grafiği

Şekil 18’ da gerçekleşen arıza verilerini ve 3 model ile yapılan tahmin değerlerinin zaman serisi grafiği verilmiştir.

Çizelge 13 ve Çizelge 14’te görüldüğü gibi hem test verilerinin hem de 3 aylık arıza tahmin değerinin MAPE, MAE, MSE ve RMSE performans metrikleri hibrit model için ARIMA ve YSA modellerine göre daha iyi sonuçlar vermektedir.

7. SONUÇLAR

Bu çalışma gıda üretimi yapan bir firmanın en çok arıza meydana gelen hattı ele alınarak sistem nasıl sürekli ve sorunsuz çalışabilir felsefesi ile yola çıkılarak yapılmıştır. Öyle ki kurutma hattı üretimin en önemli parçasıdır. Kurutma hattı çalışmadığı sürece hammadde çöp olmakta ve sistem işlememektedir. Plansız duruşların tahmin edilmesi, olabilecek arızalara karşı bakım planı oluşturması ve üretimin sorunsuz bir şekilde ilerlemesi için makine arıza tahmin çalışması yapılmıştır.

Bakım planlamada planlamanın zamanını oluşturmak oldukça önemlidir. Eğer tahmininizde doğru zaman dilimde bakım yapmaz iseniz sizin planınızdan önce arızalar meydana gelebilir veya çok sık periyotlarda bakım yapılması gereksiz üretimin durdurması, personelin gereksiz bir işle uğraşması, ömrü dolmamış parçaların erkenden değiştirilmesi vb. israflara neden olabilmektedir. Bu nedenle israfların ve arızaların önüne geçmek için bakım planlamayı doğru zaman dilimlerinde ve düzenli olarak kayıt tutarak yapmak önemlidir.

Sistemin sürekli ve sorunsuz bir şekilde çalışması için kestirimci bakım planı yapılması hedeflenmiştir. Literatürde de görüldüğü gibi ARIMA ve Yapay Sinir Ağları ile yapılan bakım planlama veya arıza tahmin çalışmaları mevcuttur. Fakat literatürde hibrit bir ARIMA-YSA tabanlı bakım planlaması veya arıza tahmin çalışması mevcut değildir. Bilindiği üzere ARIMA modeli doğrusal modellerin tahmin çalışmalarında Yapay Sinir ağları ise doğrusal olmayan modellerin tahmin çalışmalarında kullanılmaktadır. Günlük hayat verilerinde doğrusal ve doğrusal olmayan modelleri iç içe geçmiş durumdadır. Doğrusal ve doğrusal olmayan verileri ayırıştırıp modellemek oldukça zordur. Melez modeller ile yapılan tahmin çalışmaları klasik yöntem ile yapılan çalışmalara daha iyi sonuç verebilmektedir. Bu nedenle gerçek hayat verileri ile yapılan tahmin çalışmalarında hibrit modeller ile yapılan tahminlerin daha yüksek performans göstereceği düşünülmektedir. Hem klasik yöntemler ile hem de hibrit yöntemler ile tahmin çalışmaları yapılmıştır istatistiksel olarak analiz edilmiştir.

Üç aylık 50 makine arızası veri seti ile tahmin çalışması yapılmıştır. İlk 42 veri eğitim seti olarak ayrılırken son 8 veri test verisi olarak ayrılmıştır. ARIMA, YSA ve hibrit model bu 42 veri ile eğitilerek son 8 verinin tahmin çalışması yapılmıştır. 3 modelin sonuçları performans metrikleri ile istatistiksel olarak analiz edilmiştir.

Uygulama sonuçları incelendiğinde MAE, MAPE, MSE ve RMSE performans metriklerinin en iyi sonucunu Hibrit ARIMA-YSA yöntemi vermiştir. ARIMA ve YSA yöntemleri kendi aralarında kıyaslandığında YSA yöntemi ARIMA yöntemine oranla daha başarılı sonuçlar vermektedir.

Bu çalışmada makinelerin bakım planlarını oluşturmak ve arızalar oluşmadan önlem almak için hibrit bir zaman serisi ve makine öğrenmesi yöntemi olan ARIMA-YSA modeli ile gelecekteki oluşabilecek arıza verileri üzerine tahmin çalışması yapılmıştır.

Genel olarak önerilen hibrit modelin doğrusal ve doğrusal olmayan modellere göre daha iyi performans gösterdiği görülmektedir. Tez çalışmasında da doğrusal model olan ARIMA, doğrusal olmayan model olan YSA modellerine göre daha iyi performans gösterdiği görülmüştür. Elde edilen bulgular sonucunda ise yapılacak olan kurutma hattı kestirimci bakım planlaması için makine arıza tahmini çalışmasının Hibrit ARIMA-YSA modeli ile yapılmasına karar verilmiştir.

Gelecek çalışmalarda, destek vektör makineleri gibi farklı makine öğrenmesi algoritmaları ve Holt-Winter, SARIMA vb. zaman serisi yöntemleri kullanılarak performansları incelenebilir.

KAYNAKLAR

- Aksoy, B. ve Salman O. K. M. (2020). "ARIMA modeli kullanılarak Türkiye'deki iklim sıcaklıklarının geleceğe yönelik tahminlenmesi." *International Journal of Technological Sciences*, 12(2), 69-76.
- Aktaş, B. ve Aydın, C. (2018). "Talaşlı imalat sektöründe zaman serileri kullanarak üretim etkililiğinin tahmini". (2018). *Bilişim Teknolojileri Dergisi*, 11, 407-416. DOI: 10.17671/gazibtd.383339.
- Akteke, N. (2007). *Toplam verimli bakım planlaması ve bir uygulaması [Yüksek Lisans Tezi]*. Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü.
- Alanis, A. Y. ve Member, S. (2018). "Electricity prices forecasting using artificial neural networks." *IEEE Latin America Transactions*, 16, 1.
- Alghamdi, T., Bayoumi, M., Sharaf, T. ve Shah, S. (2019). "Forecasting Traffic Congestion Using ARIMA Modeling."
- Arı, A. ve Berberler M. E. (2017). "Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı." *ACTA INFOLOGICA*, 1(2), 55-73.
- Atalay, M. ve Çelik, E. (2017). "Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları." *Mehmet Akif Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9,155-172.
- Baptista, M., Sankararaman, S., Medeiros, I.P., Nascimento, C., Prendinger, H. Ve Henriques, E.M.P. (2018) "Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling." *Computers & Industrial Engineering*, 115, 41-53.
- Ben Ali, J., Fnaiech, N., Saidi, L., Chebel-Morello, B. ve Fnaiech, F. (2015). "Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals". *Applied Acoustics*, 89, 16-27.
- Birolini, A. (2013). *Reliability engineering: theory and practice*. Springer Science & Business Media.
- Brockwell, P. J., ve Davis, R. A. (2002). *Introduction to time series and forecasting*. New York, NY: Springer New York.
- Calp, M. H. (2019). "İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi." *Journal of Polytechnic*, 22(3): 675-686. DOI: 10.2339/politeknik.444380.
- Can, S. (2020). *Rüzgar tribünleri kullanılarak üretilen elektrin enerjisi miktarının zaman serileri ile analizi ve uygulaması [Yüksek Lisans Tezi]*. İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü.

- Çelikkırmı, K. (2020). Uçak bakım periyotları ve arıza sayılarının yapay zeka teknikleri kullanılarak tahmini [Doktora Tezi]. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü
- Çoban, F. ve Demir, L. (2020). “Yapay sinir ağları ve destek vektör regresyonu ile talep tahmini: gıda işletmesinde bir uygulama.” Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 23(67), 327-338.
- Datilo, P. M., Ismail, Z. ve Dare, J. (2019). “A review of epidemic forecasting using artificial neural networks.” International Journal of Epidemiologic Research, 6(3), 132-143. doi:10.15171/ijer.2019.24.
- Deb, C., Zhangb, F., Yanga, J., Leea, S. E. ve Shaha, K.W. (2017). “A review on time series forecasting techniques for building energy consumption.” *Renewable and Sustainable Energy Reviews*, 74, 902–924.
- Dindarloo, S. (2015). “Reliability forecasting of a load-haul-dump machine: a comparative study of arıma and neural networks.” *Quality and Reliability Engineering International*, 32, 1545-1552. DOI: 10.1002/qre.1844.
- Erturan M. B. ve Merdivenci, F. (2022). “Zaman serileri analizi için optimize ARIMA-YSA Modeli”. *Journal of the Faculty of Engineering and Architecture of Gazi University* 37:2, 1019-1032. DOI: 10.17341/gazimmfd.889513.
- Fattah, J., Ezzine, L. ve Aman, Z. (2018). “Forecasting of demand using ARIMA model.” *International Journal of Engineering Business Management*, 10, 1-9.
- Fente, D. N. ve Singh, D. K. (2018) “Weather forecasting using artificial neural network.” *Proceedings of the 2nd International Conference on Communication and Computational Technologies*, 978-1-5386-1974-2. doi.org/10.1007/978-3-030-23887-2_20.
- Fernandes, M., Canito, A. Corchado, J. M. ve Marreiros, (2020). “Fault detection mechanism of a predictive maintenance system based on autoregressive integrated moving average models.” *Distributed Computing and Artificial Intelligence*, 16th International Conference, 171–180.
- Güngör, E., (2007). [Yüksek Lisans Tezi]. “Yapay sinir ağları yardımı ile makine arızalarının önceden tahmin edilmesi. Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü.
- Júnior, D. S. S. O. S., Oliveira, J. F.L. ve Neto, P. S. G. M. (2019). “An intelligent hybridization of ARIMA with machine learning models for time series forecasting.” *Knowledge-Based Systems*, 175. 72-86.
- Karahan, M. (2015). “Yapay sinir ağları metodu ile ihracat miktarlarının tahmini: arıma ve ysa metodunun karşılaştırmalı analizi.” *Ege Akademik Bakış Dergisi*, 15 (2), 165-172.

- Karciođlu, A. A., Tanışman, S. ve Bulut, H. (2021). "Türkiye' de Covid-19 bulaşısının arıma modeli ve ltsm ađı kullanılarak zaman serisi tahmini". *European Journal of Science and Technology*, 32, 288-297. DOI: 10.31590/ejosat.1039394.
- Kaya, E. (2019). Zaman serileri analizinde box-jenkins yöntemi ile savunma sanayi verileri üzerine bir uygulama. [Yüksek Lisans Tezi]. Karamanođlu Mehmetbey Üniversitesi Sosyal Bilimler Enstitüsü.
- Kaynar, O. ve Tařhan, S. (2009). " Zaman serileri tahmininde ARIMA-MLP melez modeli." *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(3), 141-149.
- Kepekçi, E. (2011). "Açık İşletme Kamyonları Duruş Sürelerinin Analizi". (Yüksek Lisans Tezi). Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü.
- Keskenler, M. F. ve Keskenler, E. F. (2017). "Geçmişten günümüze yapay sinir ađları ve tarihçesi.", cilt 5 no:2 sayfa 8-18.
- Khashei M. ve Bijari, M. (2010). " An artificial neural network (p,d,q) model for timeseries forecasting." *Expert Systems with Applications*, 37, 479-489 .
- Küçükoflaz, M., Akçay, A., Çelik, E. ve Sarıözkan, S. (2019). " Türkiye' de kırmızı et ve süt fiyatlarını Box-Jenkins modelleri ile geleceđe yönelik kestirimleri." *Veteriner Hekimler Dergisi*, 90 (2): 122-131. DOI: 10.33188/vetheder.534469.
- Leukel, J., González, J. ve Riekert, M. (2021). "Adoption of machine learning technology for failure prediction in industrial maintenance: A systematic review, *Journal of Manufacturing Systems*." *Journal of Manufacturing Systems*, 61, 87-96.
- Mahamad, A., Saon, S. ve Hiyama, T. (2010). "Predicting remaining useful life of rotating machinery based artificial neural network". *Computers and Mathematics with Applications*, 60, 1078-1087.
- Maleki M., Mahmoudi, M. R., Wraith, D. ve Pho, K. (2020). "Time series modelling to forecast the confirmed and recovered cases of covid-19." *Travel Medicine and Infectious Disease*, 31(3), 353-372.
- Mansor, M.A., Ohsato, A. ve Sulaiman, S. (2012). "Knowledge management for maintenance activities in the manufacturing sector." *International Journal of Automotive and Mechanical Engineering* 5(1):612-621. DOI: 10.15282/ijame.5.2012.7.0048
- Nebati, E.E., Tař, M. ve Ertaş, G. (2021). "Türkiye' de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma". *European Journal of Science and Technology*, 31, 348-357. DOI: 10.31590/ejosat.998277.
- Paithankar, A. ve Chatterjee, S. (2016). "Forecasting time to failure of machine using hybrid neuro genetic algorithm a case study in mining machinery." *International Journal of Mining, Reclamation and Environment*, 32(3), 182-195.

- Peiris, A. T., Jayasinghe, J. ve Rathnayake, U. (2021). "forecasting wind power generation using artificial neural network:pawan danawi—a case study from sri lanka." *Hindawi Journal of Electrical and Computer Engineering*, 2021, 10. doi.org/10.1155/2021/5577547.
- Pençe, İ., Kalkan, A. ve Çeşmeli, M. Ş. (2019) "Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağları ile tahmini." *Journal of Applied Sciences of Mehmet Akif Ersoy University*, 3(2), 206-228.
- Runge, J ve Zmeureanu, R. (2019). "Forecasting energy use in buildings using artificial neural networks: A Review." *Energies*, 12, 3254, 1-27.
- Safari, A. ve Davallou, M., Oil price forecasting using a hybrid model, *Energy*, 148, 49-58, 2018.
- Sampaio, G. S., Aguiar Vallim Filho, A. R., Silva, L. S. ve Silva, L.A. (2019). "Prediction of motor failure time using an artificial neural network". *Sensors*, 19, 4342. doi:10.3390/s19194342.
- Sarıyer, G. (2018). "Acil servislerde talebin zaman serileri modelleri ile tahmin edilmesi." *International Journal of Engineering Research and Development*, cilt:10, sayı:1.
- Shinde ve S. Shah (2018). "A review of machine learning and deep learning applications," 2018 Fourth International Conference on Computing Communication Control and Automation (ICCCUBEA), 1-6.
- Tamang, S. K., Singh, P. D. ve Datta, B. (2020). "Forecasting of Covid-19 cases based on prediction using artificial neural network curve fitting technique." *Global Journal of Environmental Science and Management*, 6, 53-64.
- Tandon, H., Ranjan, P., Chakraborty, T. ve Suhag, V. (2020). "Coronavirus (COVID-19): ARIMA based time-series analysis to forecast near future."
- Taş, B. (2018). "Electricity price forecasting using hybrid time series models." [Yüksek Lisans Tezi]. Ortadoğu Üniversitesi Fen Bilimleri Enstitüsü.
- Ünlü, R. (2019). "A comparative study of machine learning and deep learning for time series forecasting: a case study of choosing the best prediction model for Turkey electricity production." *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(2), 635-64. DOI: 10.19113/sdufenbed.494396.
- Wang, Q. ve Jiang, F. (2019). "Integrating linear and nonlinear forecasting techniques based on grey theory and artificial intelligence to forecast shale gas monthly production in Pennsylvania and Texas of the United States Qiang." *Energy*, 178, 781-803.
- Zhang, G. P. (2003). "Time series forecasting using a hybrid ARIMA and neural network model". *Neurocomputing*, 50, 159-175.

Zuo, L., Zhang, L., Zhang, Z., Luo, X. ve Liu, Y. (2021). "A spiking neural network-based approach to bearing fault diagnosis". *Journal of Manufacturing Systems*, 61, 714-724.

EKLER

EK-1: ARIMA(0,1,1) modeli ile yapılan 3 aylık makine arızası tahmin sonuçları tablosu

Arıza numarası	ARIMA(0,1,1) tahmini	Arıza numarası	ARIMA(0,1,1) tahmini
1	0	26	862,59
2	43,56	27	1539,4
3	117,7	28	1227,01
4	155,82	29	1558,17
5	183,04	30	1455,97
6	199,82	31	1583,11
7	222,26	32	1582,14
8	244,98	33	1705,91
9	269,22	34	1800,56
10	297,6	35	1784,25
11	345,42	36	1851,84
12	364,47	37	1842,66
13	377,56	38	1874,44
14	408,38	39	2006,2
15	451,41	40	2016,09
16	461,9	41	2024,11
17	493,98	42	2065,21
18	503,72	43	2125,52
19	707,56	44	2392,54
20	638,32	45	2693,1
21	708,84	46	3031,42
22	768,73	47	3412,23
23	750,15	48	3840,89
24	829,29	49	4323,39
25	847,32	50	4866,52

EK-2: YSA modeli ile yapılan 3 aylık makine arızası tahmin sonuçları tablosu

Arıza numarası	YSA tahmini	Arıza numarası	YSA tahmini
1	0	26	1181
2	91,98	27	1225,88
3	118,69	28	1332,87
4	157,49	29	1391,06
5	183,65	30	1414,45
6	202,06	31	1472,71
7	221,31	32	1543,19
8	243,33	33	1635,43
9	266,95	34	1671,60
10	294	35	1684,71
11	334,39	36	1714,58
12	361,69	37	1726,30
13	375,19	38	1819,22
14	396,18	39	1865,98
15	425,75	40	1875,36
16	440,35	41	1900,05
17	464	42	1952,61
18	577,80	43	1980
19	634,62	44	2107,42
20	646,93	45	2158,96
21	661,14	46	2159
22	721,53	47	2159
23	731,26	48	2159
24	779,70	49	2159
25	795,02	50	2159

EK-3: Hibrit ARIMA-YSA modeli ile yapılan 3 aylık makine arızası tahmin sonuçları tablosu

Arıza numarası	ARIMA YSA hibrit	Arıza numarası	ARIMA YSA hibrit
1	0	26	1184,03
2	82,26	27	1217,69
3	130,33	28	1334,99
4	156,01	29	1378,63
5	178,60	30	1427,44
6	196,68	31	1467,72
7	217,74	32	1542,23
8	242,44	33	1639,34
9	265,69	34	1656,97
10	302,91	35	1694,97
11	330,26	36	1709,88
12	343,88	37	1727,61
13	371,25	38	1818,45
14	405,94	39	1864,01
15	423,41	40	1869,73
16	448,45	41	1901,05
17	467,15	42	1951,69
18	585,74	43	2005,39
19	610,74	44	2067,83
20	632,57	45	2171,14
21	691,29	46	2254
22	700,89	47	2248,96
23	742,13	48	2313,62
24	779,63	49	2344,70
25	796,53	50	2462,41

EK-4: Hibrit ARIMA-YSA modelin ile yapılan 3 aylık makine arızası tahmin sonuçlarının artık değer tablosu

Arıza numarası	e(artık)	Arıza numarası	e(artık)
1	0	26	-318,41
2	-38,44	27	314,40
3	-14,30	28	-108,99
4	-5,18	29	178,17
5	3,04	30	27,97
6	0,82	31	116,11
7	2,26	32	39,14
8	2,98	33	65,91
9	2,22	34	141,56
10	-7,40	35	88,25
11	13,42	36	140,84
12	18,47	37	114,66
13	8,56	38	55,44
14	3,38	39	140,20
15	26,41	40	142,09
16	13,90	41	122,11
17	29,98	42	113,21
18	-83,28	43	145,52
19	95,56	44	349,54
20	3,32	45	540,10
21	14,84	46	785,42
22	67,73	47	1154,23
23	6,15	48	1505,89
24	49,29	49	1961,39
25	52,32	50	2381,52

EK-5: Hibrit ARIMA-YSA modelin ile yapılan 3 aylık makine arızası tahmininin artık değer YSA tahmini tablosu

Arıza numarası	YSA tahmini	Arıza numarası	YSA tahmini
1	0	26	-321,44
2	-38,70	27	321,71
3	-12,63	28	-107,98
4	-0,19	29	179,54
5	4,44	30	28,53
6	3,14	31	115,39
7	4,52	32	39,91
8	2,54	33	66,57
9	3,53	34	143,59
10	-5,31	35	89,28
11	15,16	36	141,96
12	20,59	37	115,05
13	6,31	38	55,99
14	2,44	39	142,19
15	28	40	146,36
16	13,45	41	123,06
17	26,83	42	113,52
18	-82,02	43	120,13
19	96,82	44	324,71
20	5,75	45	521,96
21	17,55	46	777,42
22	67,84	47	1163,27
23	8,02	48	1527,27
24	49,66	49	1978,69
25	50,79	50	2404,11