

T.C.
TRAKYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ 4.0 ÇAĞINDA YAPAY ZEKA TEKNİKLERİ İLE TAKIM UCU
KONUM KESTİRİMİ: SANAYİDE BİR DİJİTAL DÖNÜŞÜM ÖRNEĞİ

Ezgi KÜÇÜKBAŞ

YÜKSEK LİSANS TEZİ

HESAPLAMALI BİLİMLER ANABİLİM DALI

Tez Danışmanı: Doç. Dr. Sezer ULUKAYA

EDİRNE-2025

Ezgi Küçükbaş'ın hazırladığı “**Endüstri 4.0 Çağında Yapay Zeka Teknikleri İle Takım Ucu Konum Kestirimi: Sanayide Bir Dijital Dönüşüm Örneği**” başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Hesaplamalı Bilimler** Anabilim Dalında bir **Yüksek lisans tezi** olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Doç. Dr. Sezer ULUKAYA

.....

Doç. Dr. Deniz TAŞKIN

.....

Dr. Öğr. Üyesi Murat Olcay ÖZCAN

.....

Tez Savunma Tarihi: 02/07/2025

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Doç. Dr. Sezer ULUKAYA

Tez Danışmanı

.....

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

.....

Doç. Dr. Filiz UMAROĞULLARI

Fen Bilimleri Enstitüsü Müdürü

TRAKYA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

HESAPLAMALI BİLİMLER ANABİLİM DALI YÜKSEK LİSANS PROGRAMI

DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

15/06/2025

Ezgi KÜÇÜKBAŞ

Yüksek Lisans Tezi

Endüstri 4.0 Çağında Yapay Zeka Teknikleri İle Takım Ucu Konum Kestirimi:

Sanayide Bir Dijital Dönüşüm Örneği

Trakya Üniversitesi, Fen Bilimleri Enstitüsü

Hesaplamalı Bilimler Anabilim Dalı

ÖZET

Dijital dönüşümle makinelerden toplanan sensör verilerinin işlenmesi sayesinde son yıllarda üretimin durmasına neden olabilecek takım tezgahlarının kırılmasını ve aşınmasını oluşmadan önce tahmin etmek için büyük çabalar sarf edilmiştir.

Yapay zeka algoritmaları kullanılarak üretimde kesici takımların verilerinden çıkarımlar yapılabilmektedir. Bu çalışmanın temel motivasyonu talaşlı imalatta kullanılan takımlardır. Takımların üretimi sırasında sensörler yardımıyla makineden veri alınmaktadır. Seçilen ayırıcı özelliklerden olan üç eksenle konum verilerinin gideceği yerlerin tahmini LSTM, RNN ve ARIMA algoritmaları kullanılarak yapılmıştır. Bu üç algoritma hata oranlarına göre karşılaştırılmıştır. LSTM algoritması en düşük ortalama mutlak hata ve kök ortalama karesel hata oranlarına sahiptir. Elde edilen sonuçlara göre, ayırıcı özellik seçimi ve derin öğrenmeye dayalı tahminin hibrit yaklaşımı ile ekipman ömrünü uzatmak ve ekipman verimliliğini artırmak mümkündür.

Yıl : 2025

Sayfa Sayısı : 70

Anahtar Kelimeler : RNN, Büyük Veri, Endüstri 4.0, LSTM, Zaman Serisi, ARIMA

Master's Thesis

Tool Tip Position Estimation with Artificial Intelligence Techniques in the Industry 4.0
Era: An Example of Digital Transformation in Industry

Trakya University, Institute of Natural and Applied Sciences

Department of Computational Sciences

ABSTRACT

Thanks to the advancement in the processing of sensor data collected from machines through digital transformation, great efforts have been made in recent years to predict machine tool breakage and wear that may cause production to stop before they occur.

Inferences can be made from the data of cutting tools in production using artificial intelligence algorithms. The main motivation for this study is the tools used for machining. During the production of the tools, data is received from the machine with the help of sensors. Estimation of the locations where the location data will go on the three axes, which are among the selected discriminative features, was made using LSTM, RNN and ARIMA algorithms. These three algorithms were compared using their error rates. The LSTM algorithm has the lowest mean absolute error and root mean square error rates. According to the results obtained, extending equipment life, increasing equipment efficiency and preventing production disruption by predicting tool tip wear is possible with the hybrid approach of discriminative feature selection and deep learning-based prediction.

Year : 2025

Number of Pages : 70

Keywords : RNN, Big Data, Industry 4.0, LSTM, Time-Series, ARIMA

TEŞEKKÜR

Bu yüksek lisans tezini meydana getirme aşamasında her türlü desteğini benden esirgemeyen değerli tez danışmanım Doç. Dr. Sezer ULUKAYA hocama çok teşekkür ederim.

Tez savunmamda yer alan değerli jüri üyeleri Doç. Dr. Deniz TAŞKIN ve Dr. Öğr. Üyesi Murat Olcay ÖZCAN' a ayırdıkları vakit ve kıymetli yorumları için teşekkür ederim.

Tez yazım sürecinde ve öznitelik seçimi konusunda karşılaştığım zorlu durumlarda verdiği destek için Öğr. Gör. Dr. İlke KURT' a teşekkür ederim.

Bu tezi oluştururken anonim olarak verileri benim ile paylaşan HEMA Endüstri A.Ş.' ye, HEMA Endüstri A.Ş. sayesinde birlikte çalışma imkanı bulduğum Nazım Emre ÖZDOĞAN' a ve bana kazandırdığı vizyon için M. Fatih AKKUŞ' a ve beni her zaman destekleyen ve yanımda olan aileme teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
1.1. Endüstri 4.0'ın Gelişimi	1
1.1.1. Endüstri 4.0'ın Ortaya Çıkışı	1
1.1.2. Endüstri 4.0 nedir?	2
1.1.3. Endüstri 4.0'ın Amacı	3
1.1.4. Endüstri 4.0'ın Olumlu ve Olumsuz yanları	3
1.1.5. Endüstri 4.0'ın Kullanım Alanları	3
1.1.6. Endüstri 4.0'ın Bu Tezde Kullanımı	3
1.2. Kestirimci Bakım	4
1.2.1. Önleyici Bakım	4
1.2.2. Düzeltilici Bakım	5
1.2.3. Kestirimci Bakım ve Tez Arasındaki Uyum Kriterleri	5

1.2.4.	Kestirimci Bakımın Bu Tezde Kullanılmasının Nedeni	5
1.3.	Tezin Konusu	7
1.3.1.	Tezin Amacı	7
1.3.2.	Tez ile Tespit Edilen Sorunlar.....	7
1.3.3.	Literatürde Zaman Serisi Analizi ile Kullanılan Modellemeler.....	8
BÖLÜM 2	10
GERÇEK ZAMANLI VERİ KÜMESİ ÜZERİNDE YAPILAN ANALİZ VE TAHMİNLEME MODELLERİNİN AŞAMALARI.....		10
2.1.	Verinin Anlamlandırılması	11
2.1.1.	Veri Kümesi Edinimi	11
2.1.2.	Meta Data Oluşumu Tanımlamalarının Anlamlandırılması.....	11
2.2.	Veri Kümesinde Öznitelik Seçimi	14
2.2.1.	Öznitelik Seçimi Yöntemleri.....	14
2.3.	Veri Manipülasyonu.....	16
2.3.1.	Veri Ön işleme	20
2.3.2.	Veri Tipi Dönüşümleri	21
2.4.	Veri Görselleştirilmesi	22
2.5.	Veri Tahminlemesi.....	34
2.5.1.	RNN Modeli.....	34
2.5.2.	LSTM Modeli	36
2.5.3.	ARIMA Modeli.....	39
BÖLÜM 3	45
SONUÇLAR VE TARTIŞMA	45
3.1.	Tahminleme Sonrası Çıkan Sonuçların Değerlendirilmesi.....	45
3.2.	Deney Sonuçları ve Tartışma	46

3.3. SONUÇ: Ulaşılmak İstlenen Hedefler ve Beklenen Çıktılar	49
KAYNAKLAR	52
TEZ ÖĞRENCİSİNE AİT BİLİMSEL ÇIKTILAR	56
ÖZGEÇMİŞ	57



SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

IOT	Nesnelerin İnterneti
RF	Rastgele Orman
RNN	Tekrarlayan Sinir Ağları
LSTM	Uzun Kısa Süreli Bellek
AR	Oto regresyon
MA	Hareketli Ortalama
ARIMA	Otoregresif Entegre Hareketli Ortalama
ACF	Oto Korelasyon Fonksiyonu
PACF	Kısmi Oto Korelasyon Fonksiyonu
SN	Saniye
MAE	Ortalama Mutlak Hata

Simgeler

α	Alfa
β	Beta
ε	Epsilon
X_t	Girdi
Y_t	Çıktı
P	AR İçin Gecikme Değeri
Q	MA İçin Gecikme Değeri

ŞEKİLLER DİZİNİ

Şekil 1.1. Endüstri 4.0'ın Zaman İçerisindeki Evreleri.....	2
Şekil 1.2. Kestirimci Bakım Türlerinin Ayrımı.....	4
Şekil 1.3. Önleyici Bakım Türleri.....	4
Şekil 1.4. Düzeltici Bakım Türleri.....	5
Şekil 2.1. Zaman Serisi Analizi Aşamaları.....	10
Şekil 2.2. Meta Data Aşaması.....	11
Şekil 2.3. Veri Özniteliklerinin Anonimleştirilmiş Görseli.....	14
Şekil 2.4. Veri Manipülasyonu Aşaması.....	16
Şekil 2.5. Veri Görselleştirme Aşaması.....	22
Şekil 2.6. Bir Gün İçerisinde Yapılan Üretim Serisi Grafiği.....	23
Şekil 2.7. Palet Değişimi Aşamaları.....	24
Şekil 2.8. Kesintisiz Üretilen 3 Ürün Serisi Grafiği.....	25
Şekil 2.9. Üretilen 3 Adet Motor Bloğunun Gecikmeli Üretim Süresi Grafiği.....	25
Şekil 2.10. Bir Ürün Üretilirken Ölçülen Hız Grafiği.....	26
Şekil 2.11. Bir Üretim Süresi Boyunca Kullanılan Takım Grafiği.....	26
Şekil 2.12. Takım Tutucuların Yapısı.....	28
Şekil 2.13. Üretim Esnasında Takım Ucunun 3 Boyutlu Ortamda Hareketi Grafiği.....	29
Şekil 2.14. Pearson Korelasyonu.....	31
Şekil 2.15. Spearman Korelasyonu.....	32
Şekil 2.16. X Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği.....	32

Şekil 2.17. Y Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği.....	33
Şekil 2.18. Z Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği.....	33
Şekil 2.19. Veri Tahminleme Aşaması.....	34
Şekil 2.20. RNN Yapısı.....	35
Şekil 2.21. LSTM Genel Yapısı.....	37
Şekil 2.22. LSTM Detaylı Yapısı.....	38
Şekil 2.23. AR Yapısı Kurgu Aşaması.....	41
Şekil 2.24. Korelasyon Fonksiyonları Ayrışımı Görseli.....	42
Şekil 3.1. Eğitim – Test Veri Kümesi Ayrımı	46
Şekil 3.2. En Başarılı Model ile Takım Ucunun X Koordinat Grafiği.....	48
Şekil 3.3. En Başarılı Model ile Takım Ucunun Y Koordinat Grafiği.....	48
Şekil 3.4. En Başarılı Model ile Takım Ucunun Z Koordinat Grafiği.....	49

ÇİZELGELER DİZİNİ

Çizelge 2.1. Öznitelik Seçim Teknikleri ve Seçilen Öznitelikler	15
Çizelge 2.2. Öznitelik Seçim Boruta Tekniği	16
Çizelge 2.3. Veri Kümesi Tablosu	18
Çizelge 2.4. Veri Kümesi Manipüle Edilmiş Tablo	20
Çizelge 2.5. Veri Kümesi Seçilen Öznitelikler	21
Çizelge 2.6. Palet Değişimi İşaretlenmiş Tablo Çizelgesi	23
Çizelge 2.7. Takım Ucu numaralarının Bazılarının Örnek Anlamı	27
Çizelge 2.8. Takım Ucu Numaralarının Ortalama Kullanılma Süresi	28
Çizelge 2.9. G-Code Yapısı Pozisyon Bilgisi	30
Çizelge 2.10. G-Code Yapısı Hız ve Eksen Bilgisi	30
Çizelge 2.11. Kullanılan Tahminleyici Algoritma Modelleri	34
Çizelge 2.12. LSTM Modeli Kapıları	38
Çizelge 3.1. X Eksen Hareketinde Hata Oranı Karşılaştırılması	46
Çizelge 3.2. Y Eksen Hareketinde Hata Oranı Karşılaştırılması	46
Çizelge 3.3. Z Eksen Hareketinde Hata Oranı Karşılaştırılması.....	46
Çizelge 3.4. RNN-LSTM-ARIMA Modellerinin MAE Karşılaştırması	47

BÖLÜM 1

GİRİŞ

Bu çalışmada, gerçek sanayi verileri üzerine yapay zeka yöntemleri kullanılarak karşılaştırma yapılmıştır. Bu bakış açısı ile yaklaşıldığında derin öğrenme modelleri son yıllarda veri miktarına bağlı olarak ön plana çıkmaktadır. Derin öğrenmenin ne olduğuna kısaca değinmek gerekirse, daha önceden gerçekleşen aksiyonları veriler doğrultusunda hafızada tutarak bir sonraki adımı tahmin etmek olarak açıklanabilir. Mevcutta, çok fazla derin öğrenme algoritmaları ve geliştirilmekte olan algoritma çeşitleri bulunmaktadır. İstatistiksel çıkarımlar ışığında modellerin tahmine dayalı sonuçlar vermesi de bu akışın bir parçasıdır. Büyük verilerin tahminlenmesi kısmında derin öğrenme algoritmaları, olmazsa olmaz bir yere sahiptir. Büyük veriler ile çalışma sırasında veriyi toplamak, toplanan veriyi anlayarak analiz etmek, yorumlamak ve bu yorumlar neticesinde çıkarılan sonuçlar veri biliminin sürecini anlatmaktadır.

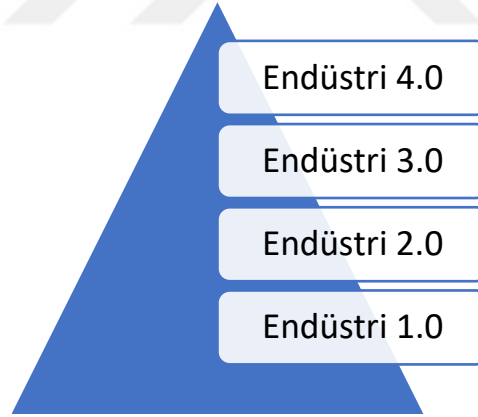
1.1. Endüstri 4.0'ın Gelişimi

1.1.1. Endüstri 4.0'ın Ortaya Çıkışı

Endüstri 4.0, karmaşık sistemleri kontrol altında tutabilmek ve verimliliğin maksimum seviyede tutulabilmesini sağlamak için yapılan 4. Sanayi devrimidir. Sanayi devrimi, günümüze gelene kadar 4 aşamadan geçmiştir. İlk olarak insan gücü kullanımı doğrultusunda çıkılan bu yolda Endüstri 1.0 ile başlanmıştır. Bu aşamada, yalnızca insanların gücü ve kısıtlı imkanlarla yapabilecekleri işler vardı. Bunlar, basit ve günlük hayatı sürdürebilmek adına yapılan eylemlerdi. Sonrasında, buharlı makinaların icadı ile endüstride yeni bir sanayi devrimi gerçekleştirildi. Endüstri 2.0'a geçildi. Endüstri 2.0 ile

seri bant düzeninde ve elektrik ile çalışan makinalar üretimde görülmeye başlanmıştı. Dünya bu aşamada değişen bu düzene uyum sağlamaya çalışıyordu. Sonrasında, üretimin bilgisayarların kontrolü ile yapılmaya başlamasıyla Endüstri 3.0'a geçilmiş oldu. Artık, endüstride üretim, robotlar tarafından yapılmaya başlanmış ve insan gücü daha da azalmaya başlamıştı.

Endüstri 3.0'a geçildiğinde insan faktörünün daha da azalmaya başladığı görüldü. Bununla birlikte performans optimizasyonunun yüksek seviyelere çıktığı görülürken üretim ortamında karmaşıklığın minimuma indiği net bir şekilde görülmeye başlandı. Sanayide, süreç daha da hızlı ilerlemeye devam etti. Endüstri 3.0 ile sanayilere getirilen robotlar, zaman ilerledikçe kendi kendini yönetebilir ve belirli rotalar ile üretim hatlarında çalışabilir hale geldi. Robotların çalışmaları esnasında Internet of Things (IOT) teknolojisi denilen 'Nesnelerin İnterneti' ile robotlardan belirli sensörler ve protokoller ile veriler alınmaya başlandı. Alınan veriler, ilk başta ham ve bir filtreden geçmeyen verilerdir. Bu verilerin bilgisayar programlarında analiz edilerek daha anlamlı hale getirilmesi amaçlanmaktadır. Bu aşamaya gelindiğinde ise, 4. Sanayi devrimi olan Endüstri 4.0 ortaya çıktı. Şekil 1.1.'de de bu geçiş en üst katmanda karşımıza çıkmaktadır.



Şekil 1.1. Endüstri 4.0 Zaman İçerisindeki Evreleri

1.1.2. Endüstri 4.0 nedir?

Endüstri 4.0, makinalardan sensörler aracılığı ile alınan verileri analiz ederek, derleyerek ve filtrelerden geçirerek anlamlı veriler ortaya çıkarır. Bununla birlikte ise yapay zeka algoritmaları ile verilerin tahminlemesi yapılır. Endüstri 4.0'ın amacı kaynakları optimize kullanarak ve süreci otomatik hale getirerek 'Karanlık Fabrikalar' oluşturmaya çalışılmasıdır (Akben, İ., & Avşar, İ. İ., 2018). Endüstride, 4. sanayi devrimi

ile Endüstri 4.0 insan gücünü ortadan kaldırarak sürekli çalışan karanlık fabrikalara geçmeyi amaçlamaktadır.

1.1.3. Endüstri 4.0'ın Amacı

Endüstride üretim yapılırken ortaya çıkan karmaşık yapı ve sistemlerin Endüstri 4.0 ile daha anlaşılabilir, karmaşadan uzak ve tek sistem ile yönetilebilmesi amaçlanmaktadır. Her üretilen ürünün kontrol altında tutulması sağlanır. Eş zamanlı olarak, her bir kontrolün bir araya getirilerek daha düzenli bir yapı oluşturulması sağlanır. Bu yapı ise sistem entegrasyonları ile fabrikalara uygulanarak 'Akıllı Fabrika' ların oluşturulmasını sağlar.

1.1.4. Endüstri 4.0'ın Olumlu ve Olumsuz yanları

Endüstri 4.0'ın çıkış amacı, fabrikalarda sıfır hata ile çalışmaktır. Sanayide sıfır hata ile çalışmak bilgisayarlı kontrol ve sistem entegrasyonları ile mümkündür. Bu sayede daha kontrollü ve verimli bir üretim sağlanır. Kendi kendini yönetebilmeleri büyük bir fırsattır. Eş zamanlı olarak etkileşim ve iletişim ile anlık olarak hata oranının sıfıra yakın olması ve insan faktörüne dayalı hataların ortadan kaldırılmasını amaçlamaktadır. Bu da tasarım yapan ve kodlanan robotlar nedeni ile iş sıkıntısına sebebiyet vermektedir.

1.1.5. Endüstri 4.0'ın Kullanım Alanları


Günümüzde Endüstri 4.0, üretimlerde verimlilik ve iyileştirilmeler ile birçok alanda kullanılmaktadır. Bu teknoloji genellikle, sağlık, eğitim, sanat, pazarlama stratejilerinde, sanayilerde seri üretimlerde ve ürün geliştirilmesi gibi pek çok yaygın alanda kullanılmaktadır.

1.1.6. Endüstri 4.0'ın Bu Tezde Kullanımı

Bu tezde ise Endüstri 4.0' da IOT teknolojisi ile makinalardan sensörler ve protokoller aracılığı ile veri alınması sağlandı. Alınan verilerin analizi yapıldı. Bu analize bağlı olarak ise yapay zeka algoritmaları kullanılarak tahminleme yapıldı. Bu sayede ise sanayide, robotlar ile çalışan seri üretim bantlarında üretilen parçaların davranış grafikleri elde edilmiştir (Rangwala ve Dornfeld, 1990).

1.2. Kestirimci Bakım

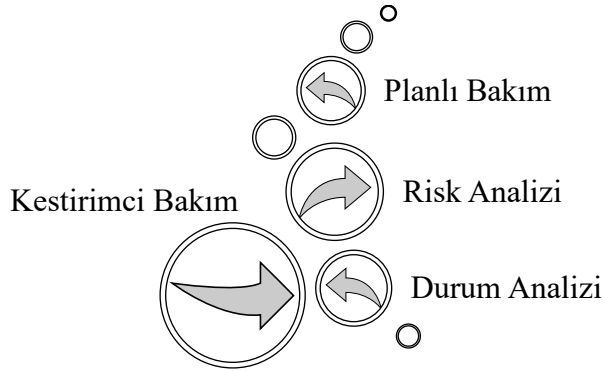
Bu tez çalışması kestirimci bakım için önemlidir. Kestirimci bakım aslında 2 bakım çeşidinden birinin alt kırılımında bulunan bir bakım türüdür. Üretimlerde, genellikle ya önleyici bakım ya da düzeltici bakım çeşidi kullanılır. Şekil 1.2.' de bu ayrım gösterilmiştir.



Şekil 1.2. Kestirimci Bakım Türlerinin Ayrımı

1.2.1. Önleyici Bakım

Önleyici bakım tipi olarak bilinen bakım, sanayide üretim yapan bir makinanın arıza yapmaması, sorun üretmemesi ya da olası problemlerin önüne geçmek adına yapılan bir bakım türüdür. Önleyici bakım türlerinin alt maddelerinde; planlı bakım, riskin analizi, durum analizi, kestirimci bakım ve planlı bakım gibi bakımlar bulunmaktadır. Şekil 1.3.' te bu ayrım gösterilmiştir. Bu bakımların ortak özelliği, üretim esnasında yaşanabilecek sorunların ve arızaların önüne geçmek için bir çeşit öngörü mekanizması oluşturmaktır.




Şekil 1.3. Önleyici Bakım Türleri

Oluşan problemlere müdahale edildiğinde veya arıza kaynaklı üretim duruşlarını önceden kestirip sorunun giderilmesi sağlandığında üretici firmaya çok büyük katkıları olur. Makinanın içerisindeki canlı veriler ya da geçmişten gelen sorunları öngörmek başka bir deyişle ön tahminini yapmak, ileride oluşabilme ihtimali olan sorunların önüne geçmiş olur. Bu yol ile makinelerin nasıl sorun çıkardığına dair de bir tespit yapılmış olur. Bu da bir çeşit öngören bir bakım türüdür.

1.2.2. Düzeltici Bakım

Diğer bir bakım türünün kırılımı olan ise düzeltici bakım türüdür. Burada ise olası sorunlar, duruşlar ya da arızalar gerçekleşmiştir. Üretim esnasında oluşan problemin giderilmesi için çözüm aranan bakım türleridir. Gecikmeli bakım, düzeltici bakım ya da acil durum bakımları bu konuda çözüm aşamasında türetilen bakım çeşitleridir. Şekil 1.4.'te bu ayırım gösterilmiştir.



Şekil 1.4. Düzeltici Bakım Türleri

1.2.3. Kestirimci Bakım ve Tez Arasındaki Uyum Kriterleri

Bu çalışma, kestirimci bakım üzerine yapılan kapsamda yer almaktadır. Makinadan, sensörler yardımı ile canlı veriler alınır. Alınan canlı veriler, sistemlere iletmeye başlar. Veriler, canlı olarak sensörler yardımı ile sistemlerde görüldüğü için anlık olarak takip edilebilmektedir. Takip edilen makine verileri, alındığı andan itibaren yorumlanmaya ve gelen verilerin anlamlandırılması aşamasına geçilir. Yapılan analizler ve incelemeler sonucunda daha önceden yaşanan duruşlar neticesinde kestirimci bakım ile buna bir çözüm getirilebileceği kanaatine varılmıştır.

1.2.4. Kestirimci Bakımın Bu Tezde Kullanılmasının Nedeni

Kestirimci bakım, arızayı daha önceden tespit edip öngörerek sorun giderilmesini sağlar. Bununla birlikte, zaman bazlı olarak hareket eder. Fabrikalarda, üretim

aşamasında olan bir ürünün, olası duruşu halinde bunun önüne geçebilmek için önceden tahminlenmesi için yapılan bir bakımdır.

Bu çalışmada, asıl sorun üretim esnasında bulunan bir makinanın çalışmanın başında, ortasında ya da üretimin bitiş zamanında duruş yaşamasıdır. Bu duruş kimi zaman kullanılan ekipmanların çeşitli nedenlerle aşınmasından kaynaklı kırılması ya da bozulması, kimi zaman makinanın arızalanmasından kaynaklıdır veya çeşitli sebeplerle süreçlerde aksaklık yaşanması nedeni ile gerçekleşir. Bu sebeplerin hepsi başlı başına firmada büyük kayıplara yol açmaktadır. Hepsi kendi içinde ayrı bir sorun teşkil etmektedir. Üretim sektöründe de otomotiv sektöründe de ya da havacılık sektörü gibi pek çok alanda bu problemler yaşanmaktadır.

Aslında, ana konu izlenebilirliktir. Eğer izlenebilir bir makine, robot ya da bir süreç var ise öngörülebilir yaklaşımlar konuyu daha ölçümlendirilebilir bir konuma taşıyabilir.

Sonuca etkileyen tüm parametreler kendi içerisinde önem teşkil etmektedir. Bu tezde ele alınan ana sorun üretim esnasında çalışan makinada, kullanılan ekipmanların zaman içerisinde aşınması sonucunda üretimin durması, kullanılan araçların kırılması ve yaşanan kayıp zamanın artmasıdır. Bu duruşlar da ciddi zaman kayıplarına yol açmaktadır. Zamanın daha efektif bir şekilde üretim ile değerlendirilmesi varken duruş yaşanması, firmada gelir düşüşlerine yol açmaktadır. Bu kayıplar belirli zaman aralıklarında nadiren görülmesi durumunda büyük perspektiften bakılınca aşırı kayıplara yol açmaz. Fakat bu durum çok sık gerçekleştiğinde ciddi maliyet sıkıntılarına yol açar. Bu durumda bir çözüm aranması gerekir. Bu çözümde ise kullanılmış olunan ekipmanları ve cihazları uzun ömürlü hale getirmek, proseslerin ve durma sürelerinin azaltılmasını sağlamak ve buna bağlı olarak kayıpları ortaya çıkarmak ilk hedef olmalıdır.

Bu çalışmada 'Kestirimci Bakım' sistematik çalışıyor ise beklenen etkiler;

- Durma sürelerinin azalması
- Üretilen ürün miktarında artış sağlanması
- Maliyetlerde düşüşün yaşanması
- Enerji tasarrufunun sağlanması
- İşçi maliyetlerinin azaltılması ve iş yükünün bu doğrultuda minimuma indirilmesi
- Karlılık sağlanması

- Üretim hızında artışın sağlanması

1.3. Tezin Konusu

1.3.1. Tezin Amacı

Bu tezde ana konu, araştırmanın ilgilendiği problem, üretimi durdurabilecek etkenlerin önüne geçmektir. Bu etken, motor blokları işleyen takımların üretim esnasında kırılmasıdır.

Bu tez çalışmasının amacı, bir işletmede Endüstri 4.0 kapsamında üretilen ve toplanan verilerin işleyişinin daha iyiye gitmesi adına derin öğrenme algoritmaları kullanılıp takım ucu konum kestirim tahmininde bulunulmasıdır. Bunun sonucunda, üretimde de büyük veri ile çalışılarak tahminleme yapıp üretimin daha az maliyetli ve sürekli akışta olunan bir sistem oluşturulması amaçlanmaktadır.

Yapay zeka tahminlemeleri ile üretimin durmasının önüne geçilebilmesi temel amaçtır. Ekipman ömrünü uzatmak ve ekipman verimliliğini arttırmak da amaçlanmaktadır. Bu amaca ise kestirimci bakım ile izlenebilirlik sağlayarak, derin öğrenme algoritmaları kullanarak ulaşılabilecek planlanmaktadır.

Özet ile ‘Üretim esnasında ekipmanların kırılması sonucunda oluşabilecek zararın önüne elde edilen veriler ve derin öğrenme modelleri kullanılarak geçilebilmesi mümkün müdür?’ sorusu eşliğinde çalışma yapılması amaçlanmaktadır.

1.3.2. Tez ile Tespit Edilen Sorunlar

Tez, bir işletmede Endüstri 4.0 kapsamında üretilen ve toplanan verilerin işleyişini iyileştirmek amacıyla derin öğrenme algoritmaları ile öngörülerde bulunmayı amaçlamaktadır.

Bu çalışmada temel motivasyon yapay zeka algoritmaları ile takım ucunun yıpranmasını tahmin ederek üretim aksamasını önlemektir. Daha detaylı anlatmak gerekirse motor bloğunun işlenmesi üretimde yapılır. Yani motor bloğu kalıp halinde gelir. Bu kalıplardan elde edilen kare bloklar araçlarda kullanılmak üzere makinelerde işlenmektedir. Blokların işlenme aşaması takım uçları ile gerçekleşir. Takım uçları veri tabanında toplanan verilerde sırasıyla takım 1, takım 2, takım 3, ... şeklindedir. Burada

takım ucu denilen kavram takım tutucunun ucuna takılan bir ekipmandır. Bu uçların ince olanları ya da dayanıksız olanları üretim sırasında kırılabilir.

Her numaralı takımın ayrı bir görevi vardır. Örneğin bir takımın kesme özelliği varsa diğer takımın yüzey parlatma özelliği bulunmaktadır. Bu tezde bahsedilen kesici takımlar üretim esnasında blok kısmının darbesinden dolayı kırılabilir (Nasir, V., & Sassani, F., 2021). Bu kırılma bazen üretimin hemen başında bazen üretimin ortasında bazen ise üretim tam tamamlanacak iken olmaktadır. Benzer şekilde kesinti de bazen üretimin en başında, bazen üretimin ortasında, bazen de üretim bitmek üzereyken meydana gelir.

Bu nedenle üretim beklenen sürede gerçekleşmemekte ve maliyet açısından büyük kayıplara neden olmaktadır. Bu nedenle takımların kırılmadan önceki aşınmaları tahmin edilmekte ve üretime alınacak bloğu işleyen parçanın yapay zeka algoritması ile tercih edilmesi amaçlanmaktadır (Li, X., Lim, B. S., Zhou, J. H., Huang, S., Phua, S. J., Shaw, K. C., & Er, M. J., 2009).

Sonuç olarak, büyük veri ile çalışarak üretimde öngörülerde bulunulması, üretimin daha az maliyetli ve sürekli akış halinde olduğu bir sistemin oluşturulması amaçlanmaktadır.

1.3.3. Literatürde Zaman Serisi Analizi ile Kullanılan Modellemeler

Genel çerçevede derin öğrenme, sinir ağlarından oluşur. Derin öğrenme büyük miktarda etiketli veri gerektirir. Bir kuruluş bu ihtiyacı karşıladığı takdirde yani yeterli büyüklükte veriyi hafızasında tuttuğu takdirde derin öğrenme algoritmaları birçok farklı alanlarda da kullanılabilirler. Derin öğrenme aynı zamanda yüz tanıma tespitinde, otonom arabaların yapımında ya da daha farklı bir alan olan sanayide dijital dönüşüm alanında kullanılan takım araçlarının iyiye gitmesi yönünde kullanılabilir. Bu tezde bahsi geçen sanayide dijital dönüşüm alanında üretime destek ve üretimi daha iyiye götürme amaçlı bir çalışma yapılması planlanmaktadır.

Zaman serisi veri tahmini, birçok uygulamada son derece önemli olan gelecekteki bilgileri tahmin etmek için önceki zaman dilimlerinden gelen bilgileri kullanır (Wen, X., & Li, W., 2023). Elektrik tüketimi, döviz fiyatı, yatırım stratejileri, hava kirliliği, rüzgar hızı ve COVID-19 vaka analizi gibi konularda tahmin amaçları için RNN (Sachin, M.,

Baby, M. P., & Ponraj, A. S., 2020), LSTM (Zeng, Z., & Khushi, M., 2020) veya ARIMA (Kashif, K., & Slepaczuk, R., 2025) yöntemleri literatürde tercih edilmiştir (ArunKumar, K., Kalaga, D. V., Kumar, C. M. S., Kawaji, M., & Brenza, T. M., 2021).

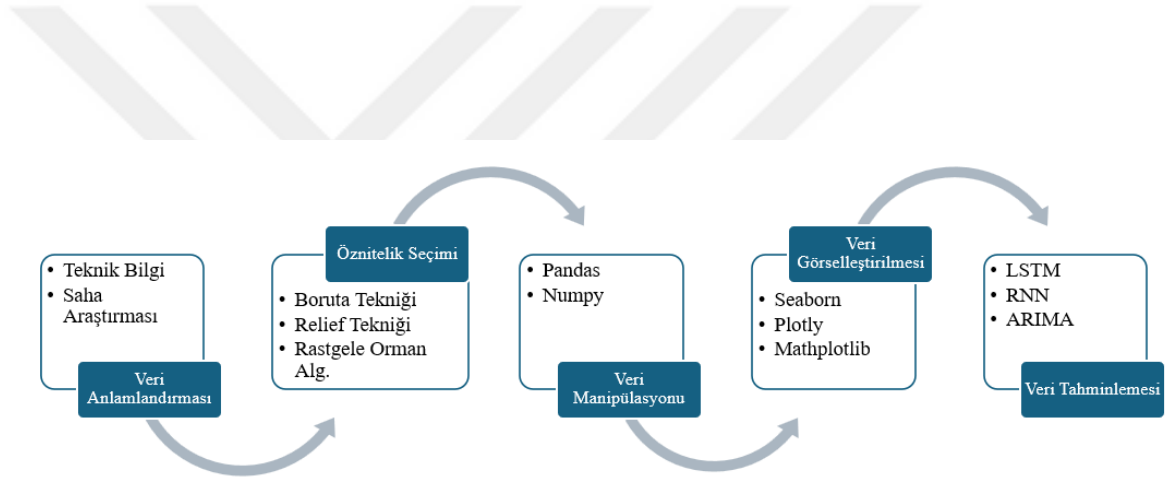
Yapay zeka tekniklerinin öngörücü analizde kullanımı dijital dönüşüm ve verimlilik için de önemlidir. Örneğin, darboğazları ve üretim kalitesindeki düşüşleri hızla tespit etmek ve çözmek, gerçek zamanlı olarak izlenen bir fabrikada üretimde sürdürülebilirliği sağlayacaktır (Wang, H., Zhang, W., Yang, D., & Xiang, Y., 2022). Yapay zeka ayrıca takım ömrünü artırmak için CNC işleme süreçlerinde tercih edilir (Soori, M., Arezoo, B., & Dastres, R., 2023). Takım aşınması izleme için çeşitli sensör sistemleri ve yapay zeka yöntemleri literatürde incelenmiştir. (Munaro, R., Attanasio, A., & Prete, A. D., 2023)' de, yapay zeka yöntemleri çevrimiçi ve çevrimdışı yöntemlerle takım aşınması analizi için araştırılmıştır.

Endüksiyon motorlarında hata analizi, Endüstri 4.0 teknolojisiyle öngörücü bakım alanında ilerleme göstermiştir (Drakaki, M., Karnavas, Y. L., Tzifettas, I. A., Linardos, V., & Tzionas, P., 2022). Öngörücü modellemenin (Stojov, V., Koteli, N., Lameski, P., & Zdravevski, E., 2018) bir sonucu olarak, müşteri memnuniyeti, arızaların ve duruşların önlenmesi, büyük mali kayıpların önlenmesi ve itibarın artması gibi şirket üzerinde olumlu etkiler olacaktır (Güven, Ö., & Şahin, H., 2022).

Takım uçlarının kırılmasından kaynaklı, bu kırılmanın önüne geçmek için birçok derin öğrenme algoritması kullanılabilir. Uzun-kısa süreli bellek (Elsaraiti, M., & Merabet, A., 2021) bu tezde kullanılan bir model çeşidi olarak örnek verilebilir. Daha önceden kırılan takımların tahminlemesi sağlanarak üretimdeki akışın yürütülmesi planlanmaktadır. Bir diğer modelleme RNN' dir. Son olarak, kullanılan algoritma ise ARIMA modelidir. Bu üç tahminleme yöntemi bu çalışmadaki veriler üzerinde kullanılacaktır.

BÖLÜM 2


GERÇEK ZAMANLI VERİ KÜMESİ ÜZERİNDE YAPILAN ANALİZ VE TAHMİNLEME MODELLERİNİN AŞAMALARI



Şekil 2.1. Zaman Serisi Analizi Aşamaları

Bu tezin yürütülmesinde kullanılan kodlama dili Python programlama dilidir. Şekil 2.1.'de uygulanan aşamalar gösterilmiştir. Python programlama dilinde veri manipülasyonu kısmında Pandas ve Numpy kütüphaneleri kullanılmıştır. Veri görselleştirilmesinde Matplotlib ve Plotly kütüphaneleri kullanılmıştır. Derin öğrenme kısmında ise LSTM derin öğrenme modeli uygulanmıştır. RNN modeli de geliştirilmiş ve denenmiştir. Ayrıca ARIMA modeli de uygulanmıştır. Veriler HEMA Endüstri A.Ş. şirketinden alınarak üzerinde temizleme ve etiketleme işlemleri yapılmıştır.

2.1. Verinin Anlamlandırılması



Şekil 2.2. Meta Data Aşaması

Veri anlamlandırılması, Şekil 2.2.'deki gibi ilk aşama olarak kullanılır.

2.1.1. Veri Kümesi Edinimi

Bu veri kümesi Endüstri 4.0 kapsamında üretilen bir veri kümesidir. Makinadan sensörler yardımı ile veriler alınır. Üretim sırasında motor blokları işlenir. Bazı durumlarda takım ucu ürünü işlerken kırılabilir. Bu sebep ile üretim aksamakta ve buna bağlı olarak üretim tamamen de durabilir. Bu durumlarda, işlenen parçanın üretimi tamamlanamadığı için zaman ve finansal açıdan firma zarara girebilmektedir. Bu durumu önlemek amacı ile robottan sensörler yardımı ile veriler alınmaya başlanmıştır.

Bu çalışmadaki veriler, robottan sensörler yardımı ile alınmıştır. Verilerin boyutu 14.375.168 satır ve 120 sütundan oluşuyor. Yaklaşık 14.8 GB lık bir bellek alanı kapsamaktadır. Yaklaşık 2 yılda toplanan verilerden oluşmaktadır. Veri kümesi, 'zaman serilerinde tahminleme' üzerine toplanmıştır.

Bu tezdeki ana amaç, üretim esnasında takım uçlarının kırılmasının önlenmesidir. Takım uçlarında meydana gelen kırılmanın önüne geçmek için robotlardan alınan canlı veriler bulunmaktadır. Bu veriler sensörler yardımı ile bir kesinti olmadığı sürece saniyede 4 satırlık veriler olarak alınır. Bu veriler veri tabanına 134 öznitelik ile aktarılır. Fakat hepsinin anlamlı ve analiz edilebilir olmadığına kanaat getirilerek 10 adet öznitelik otomatik olarak seçilerek indirgeme yapılmıştır.

2.1.2. Meta Data Oluşumu Tanımlamalarının Anlamlandırılması

Genel çerçevede, verilerin anlamlandırılması, analiz edilmesi, görselleştirilmesi ve veri tabanında toplanan verilerin derin öğrenme algoritmalarına tahminlenmek üzere aktarılması sağlanır. İlk olarak bahsedildiği gibi, verilerin anlamlandırılması ilk aşamadır.

Verilerin anlamlandırılması aşaması, tüm aşamalardan daha uzun süren bir süreçtir. Bu süreçte, üretilen malzemenin bilgisi, üretim ortamının bilgisi, makina özelliklerinin bilgisi ya da kullanılan ekipman özellikleri gibi pek çok bilginin öğrenilmesi gereklidir. Bu gereklilikler doğrultusunda üretim ortamını daha iyi analiz edebilmek için büyük kapsamda parametre bilgilerinin toplanması gerekir. Toplanan bilgiler, bazen makina operatörlerinden, bazen makinanın üretim esnasında gösterdiği hareketliliklerden bazen de üretimden çıkan motor blokların incelenmesinden sağlanır.

Veri kümesinde bulunan 40 adet sütunun isimlerinin nasıl ifade edildiğinin görülmesi ve fikir vermesi açısından anonim olarak paylaşıldı.

```
Index(['ID', 'ZAMAN', 'RO*_VE*', 'TE**', 'LO**',  
'AC***_AU**','AC***_CU*', 'AC***_TO***', 'EM*****_ST**', 'PAL***_ID',  
'WA****', 'AV****', 'R1**', 'DO*****', 'PA**_FE****', 'RO*_VE***_OV****',  
'EX****', 'LI**', 'CO****_MO****', 'PA**_CO****',  
'PA**_FE****_OV****_PR*****', 'PA**_FE****_OV****_RA***', 'PR*****',  
'PR**_CO*****', 'PR*****', 'TO**_NU**', 'TO**_GR**', 'UN**',  
'X_AX**_FE**_RA**', 'X_LO**', 'X_AB*_PO*', 'X_PO*', 'Y_AX**_FE**_RA**',  
'Y_LO**', 'Y_AB*_PO*', 'Y_PO*', 'Z_AX**_FE**_RA**', 'Z_LO**', 'Z_AB*_PO*',  
'Z_PO*'] dtype='object')
```

Edinilen bilgiler ışığında özniteliklerin ne anlama geldikleri aşağıdaki gibi tanımlanır ise;

ZAMAN: Canlıda anlık olarak akan verinin zaman damgası (timestamp) birimi ile tarihi temsil eder.

RO*_VE*: Takım ucunda takılı olan takım milinin ('Spindle'ın) dönme hızını ifade eder.

LO*: Takım ucuna binen yük miktarı değerini verir.

R1:** Takım ucunun zamana ve kullanıma bağlı aşınma değerini verir.

AC*_AU**:** Makinanın otomatik çalıştığı anlardaki sürenin toplamıdır.

AC*_CU*:** Makinanın, üretim esnasında motor bloğu kesici takım uçları ile kestiği zamanın toplamıdır.

AC*_TO*:** Makinanın, otomatik çalıştığı anlardaki süre ve kesme sürelerinin toplamıdır.

PA_ID:** Palet numarasıdır.

Bir robot, durmadan birinci, ikinci ve üçüncü vardiyalarda anbean aralıksız olarak çalışır. Çift paletli olarak üretime devam eder. Çift palet, birinci palet ve ikinci paletten oluşur. Bir blok, üretim ile motor bloğu haline getirilmesi için robotun içerisindeki birinci palete takılır. Motor bloğu, palet 1’de üretimini yaparken, palet 2’ye de arka tarafta diğer üretimin başlaması için başka bir blok yerleştirilir. Palet 1’deki üretim bittiği gibi, robot palet 2’ye geçerek üretime kesintisiz olarak devam eder.

TO_NU**:** Takım milinin ucuna takılan takım numarasını ifade eder.

X_PO*: X pozisyonunda bulunduğu koordinatı verir.

Y_PO*: Y pozisyonunda bulunduğu koordinatı verir.

Z_PO*: Z pozisyonunda bulunduğu koordinatı verir.

X_LO:** Takım ucuna, X ekseninde binen yük miktarıdır.

Y_LO:** Takım ucuna, Y ekseninde binen yük miktarıdır.

Z_LO:** Takım ucuna, Z ekseninde binen yük miktarıdır.

X_AX_FE**_RA**:** X ekseninde, takım milinin ilerleme hızını verir.

Y_AX_FE**_RA**:** Y ekseninde, takım milinin ilerleme hızını verir.

Z_AX_FE**_RA**:** Z ekseninde, takım milinin ilerleme hızını verir.

Bahsedilen sütunlar bu tezde analiz edilip görselleştirilerek aktarılacaktır. Birbirleri arasında korelasyonları ile ilişkileri ele alınacaktır. Korelasyon haritaları ile daha gerçekçi ve nesnel yaklaşımlar gerçekleştirilecektir.

2.2. Veri Kümesinde Öznitelik Seçimi



Şekil 2.3. Veri Özniteliklerinin Anonimleştirilmiş Görseli

Özellik seçimi, bir sistemin tespit doğruluğunu iyileştirmek için en az sayıda kesin parametreyi seçmek için bir optimizasyon yöntemidir. Bu tezde, Şekil 2.3.'te gösterildiği gibi kullanılan ikinci aşamadır. Yüksek kaliteli veya bilgilendirici niceleyiciler seçmek, tüm niceleyicileri kullanmak yerine modeli çok daha kolay anlamak ve yorumlamak için faydalıdır.

2.2.1. Öznitelik Seçimi Yöntemleri

Bu çalışmada, Çizelge 2.1.'de gösterildiği gibi 3 farklı özellik seçimi yaklaşımıyla (RF gömülü, RELIEF filtreleme, BORUTA sarıcı tipte) ilk 10 en ayırt edici özellik elde edildi.

RELIEF (Zhang, X., Zhao, B., & Lin, Y., 2021) algoritması, özelliklere ilişkilerine göre etkili bir şekilde ağırlık atar. Daha yakın mesafelerin aynı sınıfı paylaşma olasılığının daha yüksek olduğunu gösterdiği bir ilkeyi izler. RELIEF, ilgili özellikler ile komşuları arasındaki mesafe değerlerini birden çok kez hesaplayarak, özellik önemini doğru bir şekilde belirler ve sonuçta daha verimli bir veri kümesi oluşturmak için düşük ağırlıklı özelliklerin kaldırılmasına olanak tanır.

Rastgele orman (RF) (Iranzad, R., & Liu, X., 2024) algoritması, her döngüde farklı ağaç yapıları oluşturduğundan çeşitli özellik alt kümeleri üretir. Bu çalışmada, algoritma her yinelemede gözlemlenen sonuçları optimize etmek için 100 kez çalıştırılmıştır.

BORUTA özellik seçimi (Kursa, M. B., Jankowski, A., & Rudnicki, W. R., 2010) RF'ye benzerdir, ancak her özellik için z puanlarını hesaplar, oysa RF'deki bir özelliğin önemi tüm ağaçlardaki o özellik için yapılan ölçümlerin ortalamasıdır. BORUTA'da orijinal veri kümesinden tüm özelliklerin rastgele kopyaları üretilmiştir, bunlara gölge

özellikler denir ve sınıflandırıcıları eğitmek için bu genişletilmiş veri kümesi kullanıldı. Her özelliğin önemini değerlendirmek için o özellik gölge özelliklerle karşılaştırılmıştır. Yalnızca sentetik özelliklerden istatistiksel olarak daha büyük önem gösteren özellikler korunmuştur.

Çizelge 2.1.'de, üç farklı öznitelik seçme algoritması tarafından seçilen en ayırt edici 10 anonim özellik gösterilmektedir.

Çizelge 2.1. Öznitelik Seçim Teknikleri ve Seçilen Öznitelikler

Random Forest	Relief	Boruta
LI**	LI**	X_AB*_PO*
TO**_NU****	PA**_FE*****	X_PO*
ACC*****_C**	X_AX**_FE**_RA**	ACC*****_C**
ACC*****_TO***	R1**	Y_AB*_PO*
Y_AB*_PO*	TO**_NU****	ACC*****_AU***
ACC*****_AU***	X_LO**	LI**
LO**	Y_PO*	TO**_NU****
R1**	RO*_VE*	Z_LO**
Y_PO*	LO**	R1**
Z_AB*_PO*	TE***	X_LO**

İlk 10 anonimleştirilmiş özellik çıkartılmıştır. Çizelge 2.1.'de belirtilmiştir. Bu çıkartılan özelliklere göre LI**, TO**_NU**** ve R1**'in farklı sıralarda da olsa tüm yöntemler tarafından seçildiği görülmektedir. Ayrıca seçilen diğer özellikler en az iki yöntemin ortak kararıyla seçilmiştir. İlgili özellikler değerlendirildiğinde LI**, PA**_FE***** , TE*** ve ACC*****_TO*** ve ACC*****_C** özelliklerinin zaman damgasıyla ilgili olması sebebiyle makine veri aşınması hakkında bilgi verici olmadığı sonucuna varılmıştır. Bu özelliklerin algoritma tarafından seçilmesinin sebebinin, bazı durumlarda (elektrik kesintisi vb.) verilerde meydana gelen kesintiler nedeniyle anomali olarak seçilmiş olması olabileceği düşünülmektedir. Boruta metodu ise otomatik olarak 12 öznitelik belirlediği için Çizelge 2.2.'de ayrıca gösterilmektedir.

Çizelge 2.2. Öznitelik Seçim Boruta Tekniği

BORUTA
X_AB*_PO*
X_PO*
AC*****_C**
Y_AB*_PO*
AC*****_AU**
LI**
TO**_NU*****
Z_LO**
R1**
X_LO**
Z_PO*
AC*****_TO***

2.3. Veri Manipülasyonu



Şekil 2.4. Veri Manipülasyonu Aşaması

Bu tezde ele alınan çalışma, robottan gelen canlı veriler sayesinde gerçekleştirilmiştir. Canlı veriler gelirken, karmaşık, düzensiz ya da anlam ifade etmeyen veriler de iletilebilmektedir. Bunun nedeni ise bazen operatörün makinayı sensörlere bağlayan kablosunu çıkartması, bazen enerji kesintisi ve bazen de sistemsel aksaklıklardan kaynaklanmaktadır. Bunları göz önünde bulundurursak yüzde yüz anlam vadeden bir veri kümesinden bahsetmek ütöpik olacaktır.

Gelen veriler zaten sensörlerden bağlanarak direkt veri tabanına kayıt olmamaktadır. Bu aşamada da bir elemeden geçerek daha anlamlı hangi sütunlar var

şeklinde bir çalışma yapılmıştır. Sonrasında veri tabanında ortaya çıkan veri kümesinin incelenmesi yapılmak üzere analize alınır. Veri anlamlandırma aşaması uzun ve zaman alan bir aşamadır. Bu tezde, Şekil 2.4.'te gösterildiği gibi kullanılan üçüncü aşamadır. Bu aşamada, üretimi yapılmak üzere kare halinde düşünebileceğimiz bloklar paletler üzerinde taşınarak gelir. Gelen bloklar çift paletli ile çalışan makine için taşınmaktadır. Her blok palet numarası 1 ve 2 olarak belirtilen alanlara yerleştirilir. Üretim kesintisiz olması için 1,2,1,2,1,2,1,2,... şeklinde dönerek devam eder. Devam ederken bir yandan da operatör biten parçaları yani bloğun işlenmesi ile oluşan motor blok parçalarını bitmiş olarak alır. Sonrasında da motor bloklar hangi firma özelinde üretildi ise o firmadaki araca takılmak üzere gönderilir.

Olay örgüsünde anlatılan süreçlerin her biri bir veri kümesinde bir özelliği ifade etmektedir. Amaç, takım uçları ile ham gelen blokları işleyip müşteriye motor blok halinde yollamaktır. Delme, kesme gibi birçok işlemi gerçekleştiren takım uçları için alınan veri ile bir üretim süresini belirleyen palet numarası, takım ucu milinin gittiği X pozisyonu, Y pozisyonu, Z pozisyonu, eksenlerde ilerledikleri hız miktarı, hangi durumlarda aşınma yüzdelerinin verildiği ya da takım milinin dönme hızının ne kadar yüksek devirlerde çalıştığı, veri anlamlandırma aşamasında belirlenmiş oldu.

Verilerin hangi anlama ve neye karşılık geldiği anlaşıldıktan sonra karşımıza gelen veri kümesini daha anlaşılır ve sade analiz etmek için bir takım veri manipülasyonlarına ihtiyaç duyulmaktadır. Veri manipülasyonları bu tez çalışmasında, gelen verilerdeki sütunların ayrıştırılması, veri tiplerinin olması gerekene dönüştürülmesi ve birbirini takip eden tekrarlayan verilerin zaman ayrımının yapılması amacıyla kullanıldı.

İlk olarak 40 sütun ile özellik belirterek gelen verilerin her birinin aynı düzeyde bir önem teşkil edip etmediği araştırılmıştır. Bunun farkındalığı veri anlamlandırma seviyesinde oluşmaya başlamıştı. Daha temel ve daha ihtiyaca yönelik olan özellikler o aşamada belirlenip, veri manipülasyonu aşamasında aksiyon olarak alınmıştır. Belirlenen veri kümesi ile çalışmalara başlanmıştır.

İlk olarak sütunların topluca geldiği veri kümesi özellikleri aşağıdaki gibidir:

```
Index(['ID', 'ZAMAN', 'RO*_VE*', 'TE**', 'LO**', 'AC***_AU**','AC***_CU*',  
'AC***_TO***', 'EM*****_ST**', 'PAL***_ID', 'WA****', 'AV***', 'R1**',
```

```
'DO*****', 'PA**_FE*****', 'RO*_VE***_OV*****', 'EX***', 'LI**',
'CO*****_MO***', 'PA**_CO*****', 'PA**_FE*****_OV*****_PR*****',
'PA**_FE*****_OV*****_RA***', 'PR*****', 'PR**_CO*****', 'PR*****',
'TO**_NU**', 'TO**_GR**', 'UN**', 'X_AX**_FE**_RA**', 'X_LO**',
'X_AB*_PO*', 'X_PO*', 'Y_AX**_FE**_RA**', 'Y_LO**', 'Y_AB*_PO*', 'Y_PO*',
'Z_AX**_FE**_RA**', 'Z_LO**', 'Z_AB*_PO*', 'Z_PO*'] dtype='object')
```

Bu tezde kullanılan veri kümesindeki özelliklerin bazı durumlarda boş (null) olarak geldiği görülmektedir. İlk olarak veri tabanından alınan çalışma veri kümesi bir .csv dosyasına alınmıştır. Sonrasında, verilerin nasıl görüldüğü hangi değerler ile geldiği ya da NaN değerlerin olup olmadığının kontrolü için Python programlama dilinin Pandas kütüphanesinden yardım alınmıştır. CSV dosyası pandas kütüphanesi ile okunarak Jupiter Notebook üzerinde açılmıştır. Aşağıda da görüldüğü üzere okunan veri kümesinin bir kısmı verilmiştir. Veriler nümerik olarak – ve + değerlerin bulunduğu koordinatlar dahil takım milinin yüksek devirde hız ile dönmesinden mütevellit veri kümesine yansıyan tablosu Çizelge 2.3.’te görülmektedir.

Çizelge 2.3. Veri Kümesi Tablosu

ID	ZAMAN	RO*_VE*	TEM*	LO**	PA*****_ID	...	X_AB*_P O*	X_PO*	Y_PO*	Z_AB*_P O*	Z_PO*
25428 21	2021-03- 30 12:20:14.0 30	4***	28	0	1	...	-5.1**.1**	- 1.7**.4* *	- 3**.*3**	- 6.4**.*2**	0
25428 20	30.03.2021 12:20	4***	27	0	1	...	-4.9**.*7**	- 1.5**.*1* *	- 2.9**.*0 **	- 6.4**.*2**	0
25428 19	30.03.2021 12:20	4***	27	2	1	...	-4.8**.*6**	-1**	- 2.4**.*7 **	-6.4**.*2*	0

Veri kümesinde bulunan 40 sütunluk tabloda manipülasyonlar ile eleme yapılması gereklidir. Bu gereklilikler doğrultusunda ‘ZAMAN’ ve ‘ID’ parametresi değerlendirme için olmazsa olmaz alanlardır. Bu 2 özellik, veri kümesinde her bir satırın özelleşmiş olduğunu gösterir. ‘ID’ kolonu, bu çalışmada veri kümesinde indeksleme yaparken kullanılır. Bu işlemde indeks, çok önemli bir yer taşır. ‘ZAMAN’ bazında bir inceleme yapılacağı ölçüde hangi zamanda hangi indekste olduğunu bilmek diğer satırdaki verilere de ulaşılmasına katkı sağlamaktadır.

- ‘TO**_NU****’ alanı veri kümesinden alınmak üzere ayırılır. Çalışmanın asıl konusu, takım ucundaki milin aşınarak kırılmasının önüne geçilmek olduğu için ilk sırada bunun alınması gereklidir. Bu kolonda üretim yaparken diğer bir deyiş ile işlem sırasında, hangi takım numaralarının takıldığıнын bilgisi elde edilir. Bu takım numaraları üzerinden tahminlemeler yapılacaktır. Takım numaralarının karşılıkları ile pozisyon bilgileri alınarak aşınmaların neden kaynaklandığı bilgisi de makina operatörlerinden alındığı için incelemeler bu yönde yapılmak üzere veri kümesine katılır.

Pozisyon verilerine ulaşmak için ise ‘X_PO*’, ‘Y_PO*’, ‘Z_PO*’ alanlarından yararlanılmak üzere diğer kolonlardan ayrılarak incelenmek üzere analiz edilecek veri çerçevesi içerisine dahil edilir.

- ‘PA****_ID’, canlıda akan verinin oluşturduğu veri kümesinin bel kemiğini oluşturur. Çünkü bu kolon motor blok işlenmek üzere makine içerisine yerleştirilip motor blok olarak çıkana kadar geçen bir üretim süresini hesaplarken kullanılan alandır. Bu alan veri kümesinin yapı taşıdır. Bu sebep ile bu saha da dahil edilmek üzere koda eklenmiştir.
- ‘TEM**’ kolonu, ortam sıcaklığını temsil eder.
- ‘RO*_VE*’ değeri, takım ucu milinin dönme hızı olarak alınır. Takımın ucunun belirli hızlar ile X-Y-Z eksenlerinde ilerlemesi bu kolonda kayıt altına alınır. Bu veriler doğrultusunda olağan dışı hız verisi tespit edildiğinde takım ucunun aşınma oranları da buna bağlı olarak değişiklik göstermektedir. Ek olarak, ‘LO****’ ve ‘R1**’ kolonları da eğiteceğimiz veri kümesine eklenecektir. Takım ucuna binen yük ve aşınma yüzdesi bu kolonlardan alınır. Bu alanların dahil edilmesi de çalışmaya büyük bir hız ve güç kazandıracaktır.

Çizelge 2.4. Veri Kümesi Manipüle Edilmiş Tablo

ZAMAN	RO*_VE*	TE***	LO***	TO**_NU****	R1**	X_PO*	Y_PO*	Z_PO*	PA****_ID
2021-03-30 15:20	4*.5**.0**	2**.0**	0.0***	3**.0**	8.5**.0**	- 1.7**.4**	- 3**.3**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	0.0***	3**.0**	8.5**.0**	- 1.5**.1**	- 2**.6**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	2*.0**	3**.0**	8.5**.0**	- 1.4**.0**	- 2**.7**	0.0***	1

Bu tabloda da eleme sonrasında;

- Verilerde boşluk gelen NaN değerleri,
- Veri tabanındaki ilgili tabloya yazarken deneme satırları gibi anlamlandırılmayan kayıtlar,
- Veri kesintisinden kaynaklı eksik satırların varlığı tespit edilmiştir.

Böylece Çizelge 2.4.’te veri kümesinin manipüle edilmiş hali ortaya çıkmış olur.

2.3.1. Veri Ön işleme

Robottan sensörler yardımı ile alınan veride manipülasyonlar yapılmıştır. Veri kümesinde, alınan verilerin tiplerinin değişimi, üretim süreleri bazında zaman kısıtı yapılarak değerlendirilmesi, veri kesintisi veya ‘NaN’ gelen değerlerin doldurulması ya da çıkartılması kararı gibi ön işlemler yapılmıştır.

Tamamen boşluklu veya anlamsız gelen veriler veri kümesinden çıkartıldı. Bu tür veriler, veri kümesinin küçük bir kısmını oluşturduğu için çıkartıldı. Çok nadir de olsa, hafta sonu kesintilerinden kaynaklanan zaman dilimleri için ise ortalamaya yaklaşımları tespit edilerek kesintili veriler doldurulma yoluna gidilmiştir.

Anlık küçük kesintiler için ‘NaN’ gelen değerleri, Dropna komutu ile aralardan silinir. Veri kümesinde gelen boş (null) değerlerin silinmesi tasvip edilen bir işlem olmamakla birlikte anlık verilerin doğru gelmemesi, anlamsız gelmesi veya boş gelmesi gibi durumlar sebebi ile zaman serisi analizini yaparken ‘dropna’ ile ‘null’ gelen değerlerde silmeye gidildi. Diğer bir sebep olan eksik gelen satırlarda bulunan değerler

için ise satır ekleme ile bu şekilde kesintinin önüne geçmek için bir yaklaşım sağlanmış oldu.

2.3.2. Veri Tipi Dönüşümleri

Veri manipülasyonu neticesinde aşağıdaki tablodaki gibi veriler ile yola devam edilmiştir. Her biri diğeri ile bağlantılı olan bu parametrelerin, veri tabanına kaydolduğunda veri tiplerine bakıldı. Veri tiplerinde her birinin ‘object’ veri tipine sahip olduğu görüldü.

Çizelge 2.5. Veri Kümesi Seçilen Öznitelikler

Veri Kümesi Seçilen Kolonlar
ID
ZAMAN
RO*_VE*
TE***
LO***
TO**_NU****
X_PO*
Y_PO*
Z_PO*
PA****_ID

İlk olarak, Çizelge 2.5.’teki gibi seçilen verilerin, veri tiplerinin uyumuna bakıldı. Veri manipülasyonu sonrasında ilk bunun yapılmasının sebebi ise veri analiz edilir iken aynı standartta incelemeler yapılması içindir. ‘ID’ kolonu haricinde tüm verilerin tipi ‘object’ idi. ID kolonu da indeksi temsil ettiği için bu parametrenin nümerik olması bekleniyordu. Diğer nümerik olması gereken kolonların ‘object’ bir veri tipinden nümeriğe dönüştürülmesi için yine pandas kütüphanesi içerisinde ‘to_numeric’ komutu ile verinin tiplerinin ‘Float’ a çevrilmesi sağlandı. Tahminlemesini yapacağımız eksen verileri ‘xxx,xxx’ şeklinde değerler alacağı için bu veri tipine dönüştürülmüştür.

‘ZAMAN’ parametresi ise ‘to_datetime’ dönüşümü yapılarak ‘datetime’ olarak analiz edilmeye başlanmıştır. Bu veri tipinin dönüşümü de diğerleri kadar önem teşkil etmektedir. Veri analiz edilirken veri görselleştirilmesinden yararlanılmıştır. Veri görselleştirirken ‘ZAMAN’ parametresi kullanılır.

2.4. Veri Görselleştirilmesi



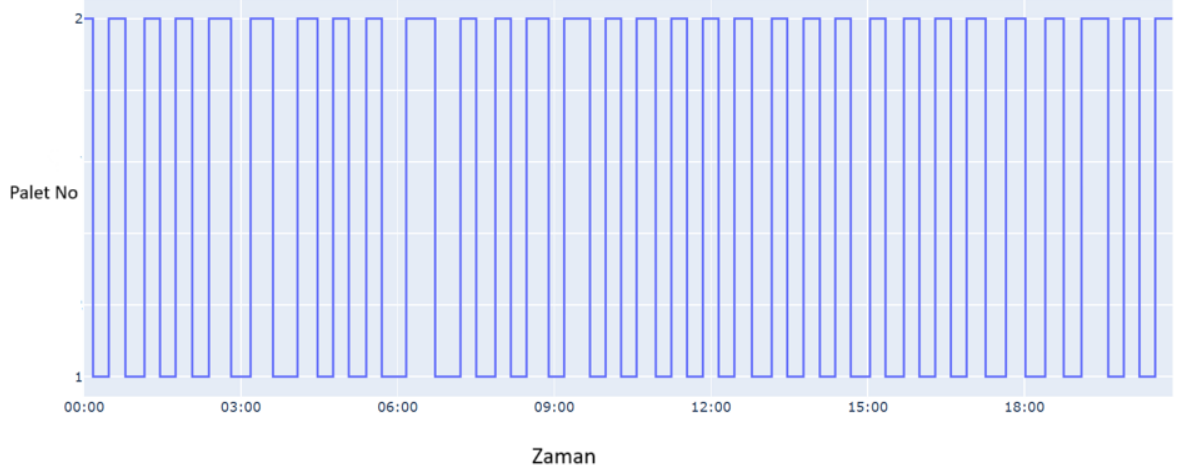
Şekil 2.5. Veri Görselleştirme Aşaması

Veri görselleştirme aşamasında veri kümesi içerisindeki tüm verilerin anlamları öğrenilmiş, iş birimi ile koordinasyon halinde, geçirilen süre yerini verilerin hareketlerini anlamaya bırakmış olur. Şekil 2.5.’te veri görselleştirme ile çalışmanın dördüncü aşamasına gelinmiş olur. Anlaşılmaya çalışılan verilerin arasından seçilen ve veri anlamlandırma aşamasında da bahsedilen öznitelikler burada tek tek görselleri çizdirilerek temsil edilmeye çalışılır.

Veri görselleştirilmede kullanılan kütüphaneler, ‘Matplotlib’, ‘Plotly’ ve ‘Seaborn’ kütüphaneleridir. Tezde daha çok kullanılan kütüphane ‘Plotly’ kütüphanesi olmuştur. Bunun sebebi ise çizgi grafiklerinin ya da herhangi bir çizimde grafiğin üzerine geldiğimizde tüm ayrıntısı ile bunu grafiğin üzerinde göstermektir. Bu yüzden, bu çalışmada veri görselleştirme aşamasında en çok kullanılan kütüphanedir. Bize daha net ve daha anlaşılır bir çerçeve sunmaktadır.

İlk olarak grafik çizimine, üretim sürelerindeki hareketleri görmek ile başlandı. Şekil 2.6.’yı çizdirmenin daha doğru olacağını düşünerek bir gün içerisindeki üretim çizdirilmiştir. Üretimde 1 ve 2 değerleri ile giden palet numarası aslında her bir üretimin yapıldığı düzlükleri ifade eder. Buradan da üretim adedi çıkarılmak istenirse palet numarası özneliği kullanılarak bu amaca ulaşılabilir. Bizim amacımız ilk başta, bir günde üretilen motor bloklarının hareketini gözlemlemektir. Çizdirilen grafik düzgün

tepeler yaparak gerçekleşiyor ise bu ideal çalışma süresinde gerçekleştirilen üretime tekabül eder. Her bir düzlük bir üretim süresidir.



Şekil 2.6. Bir Gün İçerisinde Yapılan Üretim Serisi Grafiği

Bir üretimin başlayıp bittiğini palet numarasındaki değişikliklerden anlamamız mümkündür. Alınan veriler kırmızı ile işaretlenen alanda tutulmaktadır. Bu durum Çizelge 2.6.'da işaretlenmiştir. Bu makina çift paletlidir. Bunun anlamı ise bir üretim bittikten sonra diğerinin de hemen ardından başlayarak sürekliliği sağlamak diğer bir deyiş ile bir sonraki üretime geçerken zaman kaybı yaşanmadan direkt paleti döndürerek blokları işlemeye başlamaktır. Bu da zaten, üretim sonucu olarak her bir palet dönüşünde motor blok üretildiği anlamına gelir.


Çizelge 2.6. Palet Değişimi İşaretlenmiş Tablo Çizelgesi

ZAMAN	RO*_VE*	TE****	LO****	TO**_NU*****	R17*	X_PO*	Y_PO*	Z_PO*	PA****_ID
2021-03-30 15:20	4*.5**.0**	2**.0**	0.0***	3**.0**	8.5**.0**	-1.7**.4**	-3**.3**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	0.0***	3**.0**	8.5**.0**	-1.5**.1**	-2**.6**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	2*.0**	3**.0**	8.5**.0**	-1.4**.0**	-2**.7**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	9*.0**	3**.0**	8.5**.0**	-1.4**.0**	-8*.5**	0.0***	1
30.03.2021 15:20	4*.5**.0**	2**.0**	1*.0**	3**.0**	8.5**.0**	-1.4**.0**	2**.8**	0.0***	1

Şekil 2.7.'de de gösterildiği gibi palet değişimlerindeki bir üretim 1 ve 2 değişimlerinden çıkartılır. Çizelge 2.6.'da veri içerisinde palet değerlerinin nasıl geldiği

gösterilir. Her bir değişimin ardından ve bir sonraki değişimden önceki satırlar bize üretim sürelerini vermektedir. Bu üretim hareketi bir döngü şeklinde devam eder. 1 bittikten sonra 2 başlar ve 2 bittikten sonra 1 başlar. Bu da kendisini tekrar eden bir döngünün içine girilerek üretimini gerçekleştirmiş olur. Burada bir üretimin süreleri hesaplanmış olur. Bu veri kümesi, gerçek zamanlı canlı verilerden oluştuğu için her bir palet hareketi belli bir zaman etiketine denk gelmektedir.

Üretim bazında zamanlara ayırmak bize bütünden parçalara giderek sorunun kök nedenine inmemize olanak sağlar. Bütünden gitmemizin sebebi ise Şekil 2.8.'de de görüldüğü gibi üretimin dengeli ve tutarlı bir davranış sergilediğini görmemiz içindir. Tabii ki bütüne bakarak dakikalık olan veri kesintilerini, duruşları ya da arızaları tespit etmek mümkün değildir. Fakat ciddi duruşların görüldüğü ya da bir motor bloğunun gereğinden fazla makinada durduğunun tespitini yani bir anomalinin varlığını bu grafik sayesinde fark etmiş oluruz.

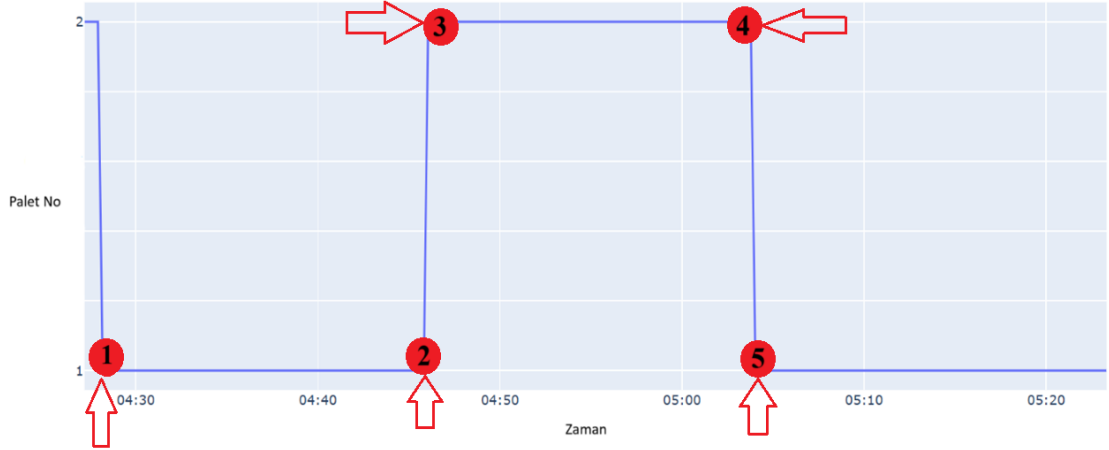


Şekil 2.7. Palet Değişimi Aşamaları

Şekil 2.8 ve Şekil 2.9' da bulunan 3 parçanın üretim grafiği plotly kütüphanesi ile çizdirilerek verilmiştir. Şekil 2.8' de zaman kaybetmeden üretimde sürekliliğin sağlandığı başlangıç ve bitiş çizgilerinin doğrusallığından anlaşılır.

Şekil 2.8' de, 1 numaralı noktada belirtildiği gibi üretim başlamış olur. 2 numaralı noktaya geldiğinde, üretimde işlenir ve hazır hale gelir. 1 ve 2 numaralı noktalar bir üretim süresini verir. Sonrasında seri üretimin devam etmesi için 2 numaraları nokta ile 3 numaralı noktanın ideal bir ortamda doğrusal olması gereklidir. Gerçek sanayi ortamında ütopyik olabileceği için bunun içerisine 10 ila 30 sn. aralığında bir açıklık güven

aralığı olarak konulabilir. Şekil 2.8.'de görüleceği gibi bir üretim biterken diğeri başlar. Bu grafikte, ikinci üretimin bitişini temsil eden 4 numaralı noktanın hemen altında 5 numaralı nokta başladığı için bu saatler aralığında seri ve sorunsuz üretimin devam ettiği grafiklerden de görülmektedir.



Şekil 2.8. Kesintisiz Üretilen 3 Ürün Serisi Grafiği

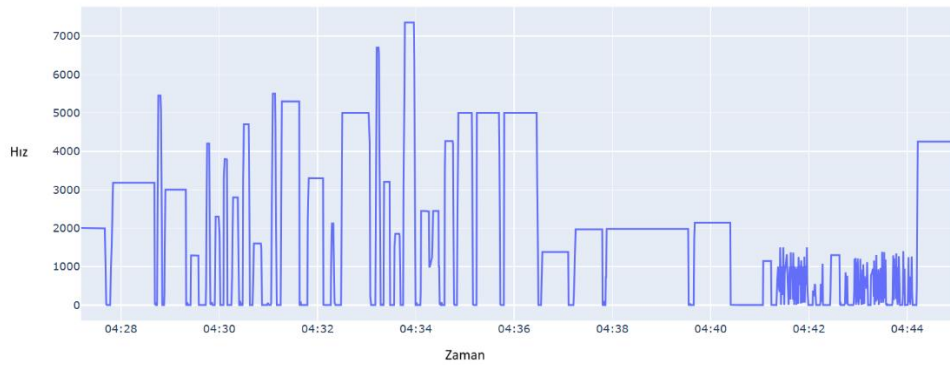
Veri kümesi her zaman Şekil 2.8.'deki gibi davranış sergileyemeyebilir. Bazen Şekil 2.9.'daki gibi zaman aralıklarının çok olduğu üretim aralarının düzgün gitmediği bölümler de olabilir. Şekil 2.9.'da çizdirilen üretim grafiğinde ise bir önceki üretimin bittiği yerin hemen altında bir sonraki üretimin başlangıcı yer alması gerekiyordu. Fakat görüldüğü üzere kırmızı çizgi ile kutu içerisine alınan alanda üretim esnasında oluşan bir sebep doğrultusunda zaman kaybı yaşanmıştır. Bu anomali hareketlerinin de veri kümesinde var olduğu aşağıdaki görselde gösterilmek istenmiştir.



Şekil 2.9. Üretilen 3 Adet Motor Bloğunun Gecikmeli Üretim Süresi Grafiği

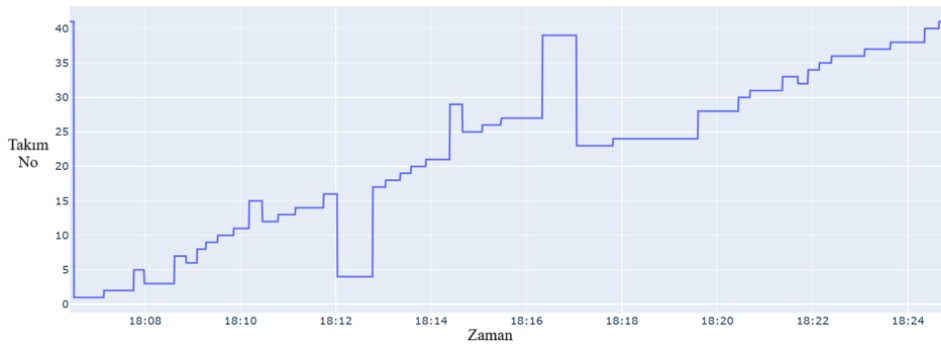
Makinadan sensörler yardımı ile alınan veriler doğrultusunda manipülasyonlar ve filtrelemeler yapılarak bir üretimin çıkarımı yapıldı. Bütünden parçaya gidilerek durum

ve hareketlilik analizi gereklidir. Tezin ilk başında değinilen ve bu çalışmanın da amacı olan takım tutuculara takılan takım uçlarının kırılacağı belirtilmişti. Takım uçları bazen de yüksek devirli hızlarda dönerek kırılabilirler. Dayanıklılığı arttırmak için bileme tezgâhlarında takım uçları bilemeye gönderilir. Fakat bunun atlandığı ya da üretim yakın zamanda başlayacağı için bilemeye gönderilmeden üretime sokulan takım uçları da olabilmektedir. Buna bağlı olarak da takım uçları kırılabilir. Şekil 2.10.'da ise bir motor bloğunun üretim süresi içerisindeki takım ucunun ne kadar devir hızda döndüğü gösterilmiştir. Bir çeşit davranış grafiği olan bu grafik de takım ucundaki aşınmanın önüne geçebilecek fikirler verebilecektir.



Şekil 2.10. Bir Ürün Üretilirken Ölçülen Hız Grafiği

Takım uçları üretim süresi boyunca birçok farklı numara ile işleme, delme, yüzey temizleme gibi işlemleri yapar. Şekil 2.11.'de ise üretim başlarken 'Hangi takım ucu ne kadar çalıştı?' sorusunun cevabı burada verilmiş olur. Bazı ince uçlu takımlar delme işlemini 40 saniyede gerçekleştirirken bazı kalın uçlu takımlar ise yüzey temizleyici olarak görev yapar yani yüzeyde kalan talaş parçalarını temizleyerek diğer bir takımın işlemesine hazır hale getirir.



Şekil 2.11. Bir Üretim Süresi Boyunca Kullanılan Takım Grafiği

Bu bağlamda, her takım eşit zamanda ve eşit devir hızında çalışmaz. Aksine, her bir takımın kendine ait özellikleri vardır. En önemlisi de bu takımların her birinin bir adı vardır. Bu adlar da zaten üretim esnasında takımların nasıl bir göreve sahip oldukları bilgisini verirler. Bu takım uçlarının her birinin anlamı sahada ustalarla yapılan toplantılarda iş biriminin bilgi aktarımı ile gerçekleştirilmiştir. Seçilen pilot tezgâhta bir ürün üretilirken çoğunlukla freze ve matkap uçları kullanılır. Bu takımlar da tek tip olmamakla birlikte inceliklerine kadar farklılık göstermektedir. Çizelge 2.7. tablosunda ise kullanılan takım uçlarının neye karşılık geldiği örnek olması açısından verilmiştir.

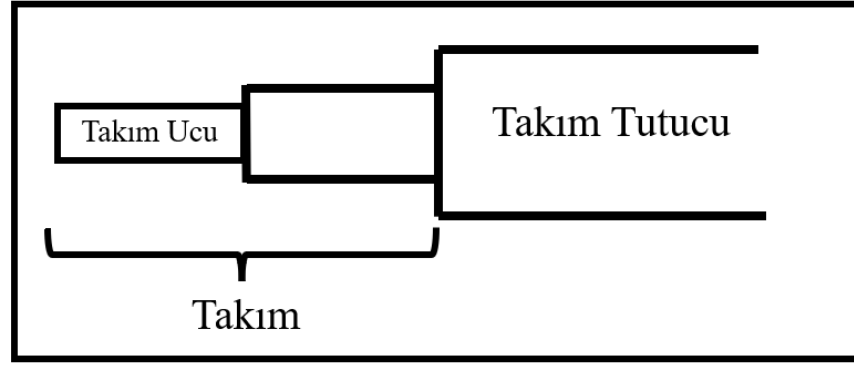
Çizelge 2.7. Takım Ucu Numaralarının Bazılarının Örnek Anlamı

Takım No	Karşılığı
1*	** FREZE
2*	****1 FREZE
3*	*** MATKAP
4*	*2 MATKAP
5*	*1 KABA
7*	**, * KABA
8*	*, * MATKAP
9*	*1 BORBAR
10*	*2 BORBAR
15*	*, * KABA
18*	*** Uçlar değişti.
23*	**, * MATKAP UZUN
25*	** Finiş
28*	** RAYBA (S***)

Çizelge 2.8. tablosunda ise takımların bir üretimde kaç saniye işlem yaptığı verilmiştir. Hangi takımların ne kadar süre üretim esnasında kullanıldığı ortalama değerler ile gözükmemektedir. Çizelge 2.8. bize kullanılan süreleri verirken, çok kullanılanların da daha sık bileme tezgâhına götürülmesi gerektiği bilgisi bu tablodan çıkarımda bulunulabilmektedir. Ortalama süresi diğer kesici takımlara göre daha az olanların pozisyon verilerine de bakılarak bir sonraki üretimde de kullanılabilceği çıkarımı yapılabilir.

Çizelge 2.8. Takım Ucu Numaralarının Ortalama Kullanılma Süresi

1	2	3	4	5	6	7	8	9	10	11	12	13	14
37.344	37.040	37.377	44.057	12.653	13.204	14.293	10.554	14.247	19.577	18.900	19.327	21.177	34.967
15	16	17	18	19	20	21	23	24	25	26	27	28	
16.103000	16.720	15.660	17.860	13.123	18.140	29.604	45.380	01:46.350	24.453	22.816	51.334	50.433	
29	30	31	32	33	34	35	36	37	38	39	40	41	
15.290	14.033	40.277	12.187	18.834	13.770	14.847	41.117	31.963	42.510	42.336	17.513	28.140	




Şekil 2.12. Takım Tutucuların Yapısı

Şekil 2.12.'de üretim esnasında motor blok işleyen robotun, takımları kullanabilmesi için takım tutucuların mevcut olması gerekliliği gösterilmiştir. Bu pilot tezgâhta, takım uçları tek başlarına makinede kullanılmazlar. Robotun bir takım tutucusu olması gerekir. Uç kısmına üretimde o esnada hangi takım ucu gelecek ise otomatik olarak onun takılması sağlanır (Mohanraj, T., Shankar, S., Rajasekar, R., Sakthivel, N. R., & Pramanik, A., 2020). Bu yapının da görsel olarak açıklaması Şekil 2.12.'de yapılmıştır.

Makinanın Takım Değiştirirken İzlediği X-Y-Z Pozisyon Grafiği

Şekil 2.13.'teki grafikte görüldüğü üzere daha önce belirtilen takım milinin (spindle'ın) gittiği X pozisyonu, Y pozisyonu ve Z pozisyonları 3 boyutlu olarak görünmektedir. Başka bir deyiş ile takım milinin ya da takım ucunun belli devirler ile dönerken motor blok üzerinde kesme, frezeleme, matkap ile delme gibi süreçleri gerçekleştirirken eksenler üzerinde yaptığı hareketler grafikte görülmektedir.

Üretim Esnasında Takım Ucunun 3 Boyutlu Ortamda Hareketi Grafiği



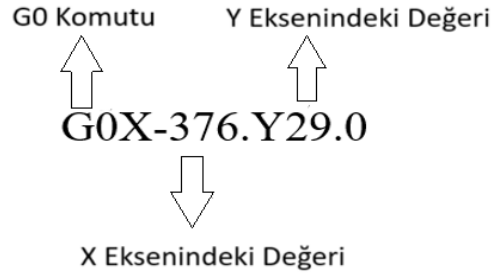
Şekil 2.13. Üretim Esnasında Takım Ucunun 3 Boyutlu Ortamda Hareketi Grafiği

G-Code;

Takım ucu denilen alan aslında, o anda G-Code hangi işleyişi yapmasını istiyor ise onu gerçekleştirmek ile mükelleftir. G-Code, endüstri sanayisinde makinaların rotasını, hızını ve birçok parametre ile üretim normlarını belirleyen bir koddur. Sonuç olarak G-Code, üretime giren bir bloğun, belirli işleyişlerden geçerek motor blok haline gelmesi için takım ucunun yönlendirmesini yapan koddur. Olması gereken ve daha öncesinde belirlenen kodlar ile G ve M kodları örnek olarak verilir ise eksenler arasında yol haritasını oluşturur. Bahsedilen yol haritasında takım mili ilerlerken hangi takımın takılacağını da belirler. Bununla birlikte, motor blok üretimi gerçekleştirilirken ne kadar devirde hız yapılacağı da bu kodlar ya da komutlar ile belirlenmiş olur.

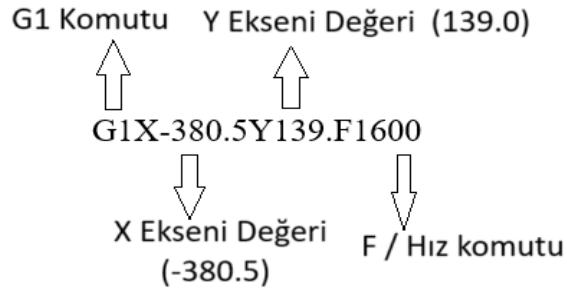
Çizelge 2.9.'da görülen G-Code örnek olarak ele alınabilir.

Çizelge 2.9. G-Code Yapısı Pozisyon Bilgisi



G0 komutu pozisyonlama olarak geçer. Üretimde olan motor blok üzerinde bir işlem gerçekleştirilmiyor. Kesme, delme ya da frezeleme gerçekleştirilmiyor. Malzemeye yaklaşmak için işlem gerçekleştirilmeden önce yaklaşılması gereken koordinatlar bu kod parçacığı sayesinde verilir. Bir çeşit takım ucu milinin boşta devam etmesi olarak tanımlayabiliriz.

Çizelge 2.10. G-Code Yapısı Hız ve Eksen Bilgisi




Çizelge 2.10.'da görülen G1 komutu ise doğrusal şekilde yani düz bir koordinat ile giderek malzemenin içerisinde talaş alma komutudur. Bunu düz giderek X ekseninde de yapabilir, Y ekseninde de, Z ekseninde de ya da 2 eksen koordinat kesişimini çarpıp giderek yapabilir.

Takım uçları değiştirilmek ya da takılmak üzere 'magazine' adı verilen takım değiştirme alanlarına gitmektedir. Bu alan, Şekil 2.13.'te görüldüğü gibi en sağ kısımda yer alır. En sağ kısımda, noktalar ya da koordinatlar belli alanlarda toplanmıştır. Burada toplanmasının sebebi takımın rutin olarak değiştirildiği yer olmasıdır. Bir üretim başladığında robot, takım ucu mili hangi takım numarası ile üretime girecek ise 'magazine' de onu takarak üretime başlar. Her bir takım numarası, görevini yaptıktan sonra bir sonraki takım numarası ile değiştirilmek üzere sağda koordinatları bulunan

magazine alanına gider ve deęişim gerekleşir. Robotun işleyişinin saęlıklı olarak gerekleştięini kontrol eden makine sorumluları tarafından yapılmaz, bu işlem otomatik olarak robot tarafından yapılır. Hangi takım numarası ne kadar süre ile kullanılacak ise gereken işleyiş gerekleşir. Bu noktada sensörler aracılıęı ile alınan canlı veriler sayesinde, X pozisyonu, Y pozisyonu ve Z pozisyonundan oluşan 3 boyutlu koordinat eksenleri hareketleri grafikler yardımı ile anlamlandırılmış olur.


Şekil 2.14. ve Şekil 2.15.'te özniteliklerin ilişkileri korelasyon haritası ile çıkarılarak incelenmiştir.

Pearson Korelasyonu




Şekil 2.14. Pearson Korelasyonu

Spearman Korelasyonu




Şekil 2.15. Spearman Korelasyonu

Şekil 2.16.'da X pozisyonunun ayrıntılı incelenmek üzere akan gerçek zamanlı verisi ve bu verideki 2 nokta arasındaki ortalama değerlerinin çizgi grafiği ve standart sapma verisi bir grafikte toplanarak çizdirilmiştir. X eksen verilerine bakıldığında ortalama ve standart sapmaları normal seviyede gözükmemektedir. Verilerin bulunduğu seviyede hareketlilik gösterildiği tespit edilmiştir.




Şekil 2.16. X Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği

Şekil 2.17.'de Y pozisyonunun koordinat grafiği, çizgi grafiği olarak tek bir alanda Şekil 2.16.'daki gibi verilmiştir. Yapılan görselleştirmede bir anomali tespit edilmemiştir.




Şekil 2.17. Y Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği

Şekil 2.18.'de ise diğer pozisyon grafikleri gibi Z pozisyonunun grafiği de verilmiştir. X eksen koordinatları ve Y eksen koordinatlarının bulunduğu grafiklerden farklı bir çıkarım elde edilmemiştir.



Şekil 2.18. Z Pozisyonu Verisi, Ortalama ve Standart Sapma Grafiği

2.5. Veri Tahminlemesi



Şekil 2.19. Veri Tahminlemesi Aşaması

Genel olarak zaman serisi analizlerinde, bir önceki veriden bir sonraki veriyi tahmin etmeye çalışmak temel amaçtır. Diğer bir deyişle geçmişteki verilerden gelecekteki verilerin tahminlemesi yapılır. Derin öğrenme ile yapılan zaman serisi tahmin modellerinde de benzer şekilde geçmiş verilerden gelecekteki veriler tahmin edilmeye çalışılır. Bu tez çalışmasında da zaman serisi verileri ile analiz yapılması sebebi ile zaman serileri zamana bağlı olarak değişen ve çeşitli incelemelerden ya da gözlemlerden oluşan verilere deniyor. Buradaki amacımız ise geçmişteki gözlemlenen, incelenen ve tespit edilen değerlerden bir sonraki zaman aralığındaki veriyi tahmin etmektir. Verilerin dağılımındaki durumu araştırmaktır. Şekil 2.19.'daki gibi son aşama veri tahminlemesi aşamasıdır.

Derin öğrenme ile zaman serisi tahmin modellerinde çeşitli yöntemler kullanılır. Bu tezde ise Çizelge 2.11.'deki gibi ARIMA, LSTM ve RNN yöntemleri kullanılmıştır.

Çizelge 2.11. Kullanılan Tahminleyici Algoritma Modelleri

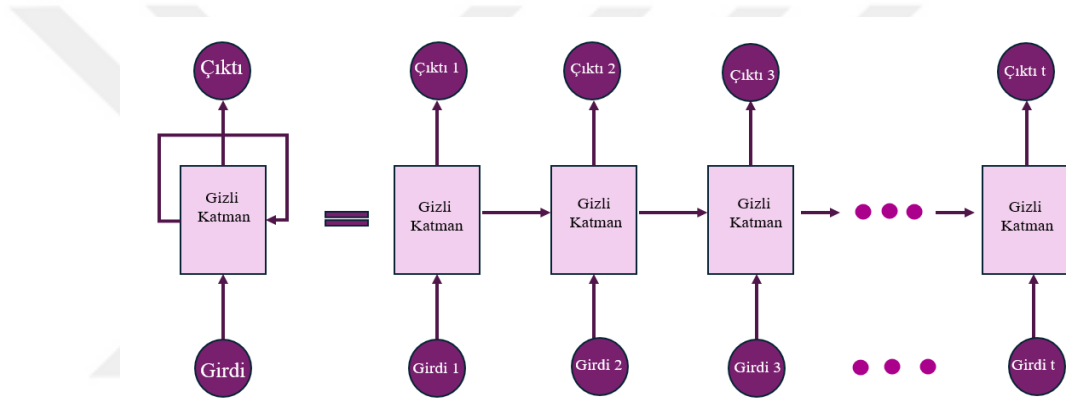
Kullanılan Tahminleyici Algoritma Modelleri		
LSTM (Long Short-Term Memory) (Uzun-Kısa Süreli Bellek)	RNN (Recurrent Neural Network) (Yinelemeli Sinir Ağları)	ARIMA (Autoregressive Integrated Moving Average) (Oto Korelasyonlu Entegre Hareketli Ortalama)

2.5.1. RNN Modeli

Yenilemeli sinir ağları (RNN), günümüzde kullanılan en ileri sinir ağlarından bir tanesidir. Standart sinir ağları belirli boyutta girdi alır. Buna bağlı olarak belli boyutta bir

çıkııı verir. Standart sinir ađlarıında hangi verinin hangi veriden önce veya sonra geldiđi dikkate alınmaz. Yani sinir ađı girdi alır sonrasında bir çıkııı üretir. Sonrasında tekrar bir girdi alıp çıkııı ürettiđinde bir önceki girdi ve çıkııının bir önemi kalmaz. Sonuç olarak, klasik bir sinir ađı bir girdi aldıđında önceki aldıđıı girdiyi unutup anlık olarak o anki girdi ile işlem yapar ve çıkııı üretir.

Bu tezde kullanılan zaman serisi verilerinin uzunluđundan dolayı verilerin sırası önemlidir. Veriler ardışık halde bulunur. Bundan dolayı, sinir ađına bir hafıza eklenmesi gereklidir. Eđer sinir ađına hafıza eklenebilir ise önceki aldıđıı girdiyi ve girdilerdeki bilgiyi bu hafızada ya da bellekte saklayabilir. Yinelenen sinir ađlarıı da tam olarak bu işlemi yapmaktadır.



Şekil 2.20. RNN Yapısı (Tunkiel, A., Sui, D., & Wiktorski, T., 2020)' den esinlenilmiştir.

Yinelenen sinir ađında, yapay sinir ađına bir hafıza ekleniyor ve Şekil 2.20.'deki gibi sinir ađı daha önceki aldıđıı girdileri göz önünde bulundurarak bir çıkııı üretiyor.

Bu çalışmada kullandıđımız veriler seçilen pilot tezgâhından sensörler yardımı ile alınmaktadır. Bu bağlamda gelen veriler, gerçek zamanlı verilerdir. Zaman serisi analizlerinde yinelemeli sinir ađlarının kullanılması daha uygun olduđu için bu modelin kullanılması tercih edildi. Kullanılan RNN yapısında belli parametrelerde denemeler yapılarak algoritma daha da düşük hata oranlı tahminlemeler yapması için optimize edilmiştir. Yinelemeli sinir ađlarından (RNN) maksimum verim alınan parametre değerleri şu şekildedir:

RNN derin öğrenmesinde, nöronlar, katmanlar, girdileri ve fonksiyon parametreleri üzerinden değerlendirmeler yapılmıştır. Nöron, 95 adettir. Fonksiyon


olarak 'Relu' fonksiyonu kullanılmıştır. Girdi verisi olarak ise 10 sütun ve yaklaşık 14 milyon satır veri kullanılmıştır. Dönem (epoch) sayısı, 100 olarak belirlenmiştir. Gizli birim sayısı, 64'tür.

2.5.2. LSTM Modeli

LSTM modeli, bir durum ya da olay devam ediyor ise orada tahmin yapılmasını sağlamaktadır. Daha net açıklanırsa devam eden işlemlerde ardı ardına gerçekleşen ve verilerin zaman içinde birbiriyle ilişkili olduğu durumlarda bu model kullanılır. Açıklanan sebepler ile bu tez çalışmasında zaman serisi analizi yaparken LSTM modelinin kullanılmasının da uygun olacağına karar verildi.

Bu çalışmada kullanılan LSTM modeli, geçmişte üretilen verilerin ışığında makinanın bir sonraki adımını tahmin etmekte kullanılır. Örnek olarak tezin amacı, takım ucunun pozisyon bilgisini daha önceki veriler ile besleyerek bir sonraki hareketini tahmin etmekte kullanılmaktadır (Zhang, Z., Lu, J., Zhou, G., & Liao, X., 2018).

Örnek olarak X_PO* verisi bir önceki veride '1. pozisyon' koordinatındadır. LSTM modelinde (Hanson, J., Yang, Y., Paliwal, K., & Zhou, Y., 2017) ise ağı besleyen ya da iletişim hattını eğiten veri kümeleri verilerek bir sonraki pozisyonun '2. pozisyon' değerinin tahmin edilmesi sağlanmaktadır. Burada, eksen bilgisini belirlenen koordinatlarda yüzde yüz tahminlemek pek mümkün olmasa bile istenen sonuca yakın bir sonuç vermesi beklenir. Çünkü bu algoritma ses dalgaları, finansal tahminler gibi zamana dayalı anlık değişen verilerin tahminlenmesinde sıklıkla kullanılmaktadır. Bizim ele aldığımız veri kümesi de takım ucunun anbean zaman içerisindeki hareketliliğini göstermektedir. Buna bağlı olarak Şekil 2.21.'deki gibi çıktıların bir sonraki sayıya çok yakın bir değer üretmesi beklenmektedir.



Şekil 2.21. LSTM Genel Yapısı (Belas ve Bidyuk, 2021)' den esinlenilmiştir.

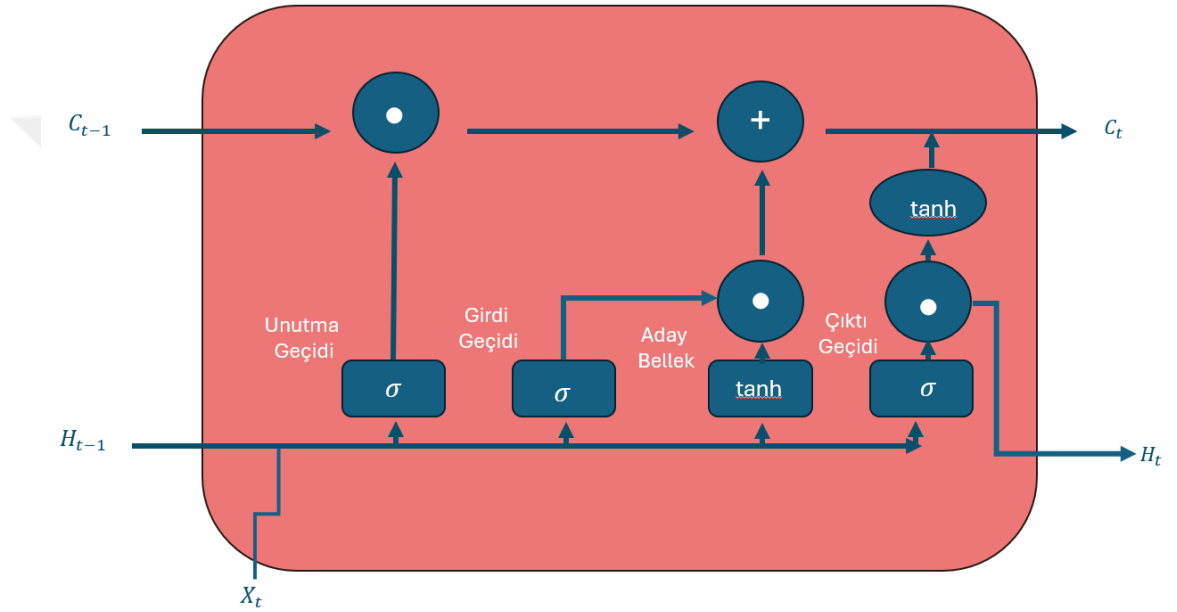
RNN' e kıyasla bilgileri daha iyi depoluyor ve kısa vadeli belleğini ortadan kaldırmış oluyor. LSTM' in bizim çalışmamızda iyi bir koordinat tahminlemesi sonucu verebilmesi için parametreler değiştirilerek defalarca denemeler yapılmıştır. Karar kılınan en iyi parametreler raporlanmıştır. Katman sayısı 100'dür. Dropout oranı 0.1' dir. Aktivasyon fonksiyonu olarak ise denemelerden sonra 'tanh' fonksiyonu seçilmiştir. Dönem (epoch) sayısı, 20 olarak belirlenmiştir. Optimizasyon fonksiyonu olarak Adam kullanılmıştır.

Zaman içerisinde anlık olarak sonuç üretilmesi gerekli olduğu için bu konuda ele alınan veri kümesi gerçek zamanlıdır. Her bir zaman diliminde tüm öznitelikler bazında farklı farklı değerler alabilir. Her an için değerler değişebilir. Çünkü sensörler aracılığı ile verileri elde eden robot, o anki üretimi gerçekleştirmek için canlı verileri sisteme aktarmaktadır.

Bu sebep ile LSTM modelinin (Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y., 2015) bu özelliği sayesinde birçok veri kümesinde avantajı oldukça büyük ölçüde artmaktadır (Graves, A., Schmidhuber, J., 2005). LSTM modeli, Çizelge 2.12.'de görüleceği üzere 'Unutma', 'Giriş' ve 'Çıkış' kapılarını barındırır.

Çizelge 2.12. LSTM Modeli Kapıları

LSTM Modeli Kapıları
Unutma Kapısı (Forget Gate)
Giriş Kapısı (Input Gate)
Çıkış Kapısı (Output Gate)



Şekil 2.22. LSTM Detaylı Yapısı (Jia, X., Zhou, W., Yang, H., Li, S., & Chen, X., 2023)' dan esinlenilmiştir.

Şekil 2.22.'de LSTM yapısının detaylandırılmış hali gösterilmektedir. Unutma kapısı, dün alınan eksen verisi ile bugün alınan eksen verisinin çarpımı bir değer ile elde edilir. Geçmişteki olayın ne kadar değiştiği ile alakalı bir değişim durumunu temsil etmektedir. Yani, geçmişten gelen bir bilginin ne kadarı unutulacak veya ne kadarı unutulmayacak, geleceğe ne kadar aktarılacak veya aktarılmayacağını kararı burada verilir (Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., & Zhang, H., 2019).

Tahminlerin uygun olmadığı durumlarda, geçmişteki bilginin bir önemi kalmaz. Bu yüzden LSTM modelinin kendi içerisinde yeniden planlama yapması gerekir ya da hiçbir şey olmadığı için daha hızlı unutulması gerekir. Bundan dolayı, Sigmoid fonksiyonu 0 ile 1 arasında bir değer alır. 0 değerinde daha hızlı unutulur. Bunun anlamı, alınan

geçmişteki eksen verisinin bir anlamı kalmaz ve unutarak yola devam edilebilir. Ek olarak, sigmoid fonksiyonu bu zincirde aslında “Ne kadar?” sorusuna cevap aramak için kullanılır.

2.5.3. ARIMA Modeli

AR Yapısı

Bir veri kümesinde değişkenler arasındaki bağlantıyı ya da ilişkiyi anlamak için korelasyon uygulanır. Korelasyon pozitif veya negatif yönde bir ilişkinin olduğunu bize verir. Buna örnek olarak, x_1 ve x_2 iki değişken olduğu var sayılsın. Bu iki değişken arasındaki ilişkiyi anlamak için korelasyon uygulanır. Korelasyon yapılarındaki sonuçlar incelenerek ilişkinin azlığı ve çokluğu hakkında yorum yapılabilir.

Diğer bir yandan da iki değişken arasındaki ilişkiyi anlamak için bağlanım (regresyon) da uygulanabilir. İlişki doğrusal yapıda açıklanmak istenir ise doğrusal regresyon yapısından faydalanılır. Regresyonda biri bağımlı biri bağımsız değişken kullanılır.

$$Y = \beta_0 + x \cdot \beta_1 + \varepsilon_t \quad (2.1)$$

(2.1) nolu denklem, doğrusal regresyonun çıktısını almak için kullanılır. (2.1) nolu denklemde x_1 ve x_2 vardır. Zaman serilerinde kullanacağımız bu model için $x_1, x_2, x_3, x_4, x_5, \dots$ bağımsız değişkenler de model içerisine dahil edilebilir (Shumway ve Stoffer, 2017). (2.1) nolu denklem Y bağımlı değişkeni, x bağımsız değişkenine bağlıdır. Bu denklem, standart bir regresyon modeli ile kurgulanan yapıdır (Namini, S. S., Tavakoli, N., & Namin, S., 2018).

Bu tez çalışmasında kullanılan veri kümesi zaman serisi verileridir. Yani, zamana dayalı değişkenlik gösteren verilerden oluşur. Dolayısı ile zaman serileri konuya dahil olduğu durumda bir ‘zaman gecikmesi’ terimi karşımıza çıkar. Zaman serisi analizi yapmak için kullandığımız veri kümesinde zaman gecikmesi dahil olduğunda verinin kendi gecikmeli değerleri kurgulanan yapının içine girmektedir. Bu durum ise özbağımlı (otoregresif) süreç içerisinde gerçekleştirilir. Bu da aslında AR model yapısını ortaya çıkartır.

$$Y_t = \beta_0 + Y_{t-1} \cdot \beta_1 + \varepsilon_t \quad (2.2)$$

(2.2) denklemini bir otoregresyon yapısıdır. Bu yapı ise AR model yapısıdır. Durağanlık analizinde kullanılır (Shumway ve Stoffer, 2017). Bu çalışmadaki zaman serileri, bir otoregresyon ile kısacası bir AR modeli ile açıklanmaya çalışılır ise bu durumda serinin gecikmeli değerleri de konuya dahil edilmiş olunur.

AR(1) süreci 1 dönem gecikme ile kurulmuş halidir.

$$AR(1) = Y_t = \beta_0 + Y_{t-1} \cdot \beta_1 + \varepsilon_t \quad (2.3)$$

AR(1) yapısını, elimizde bulunan zaman serisi ile kurgulayarak ileriye yönelik tahminler yapılabilir. 1 birim gecikme olacağı için (2.3) denklemin sağ tarafındaki Y değişkeninde 't-1' yapılarak gecikme burada belirtilerek bir sonraki Y değeri tahminlenerek hesaplanmaktadır (Shumway ve Stoffer, 2017).

Benzer şekilde AR(2) yapısı ise 2 birim ya da dönem gecikme ile kurgulanmış halidir.

$$AR(2) = Y_t = \beta_0 + Y_{t-1} \cdot \beta_1 + Y_{t-2} \cdot \beta_2 + \varepsilon_t \quad (2.4)$$

(2.4) denklem AR(2) model yapısını temsil etmektedir. 't' zamanındaki çıktının tahminini 2 birim gecikme ile kurgulamayı amaçlar (Shumway ve Stoffer, 2017).

Bu zincir devam ederse AR(1), AR(2), AR(3), AR(P) gecikme ile p. mertebeden AR model yapısı ile karşılaşılmaktadır.

1. mertebeden ve 2. mertebeden gecikmede kullanılan yapılarda olduğu gibi p. mertebeden kullanılan denklemlerde de hep bir ε_t terimi olacaktır. Bu hata terimidir.

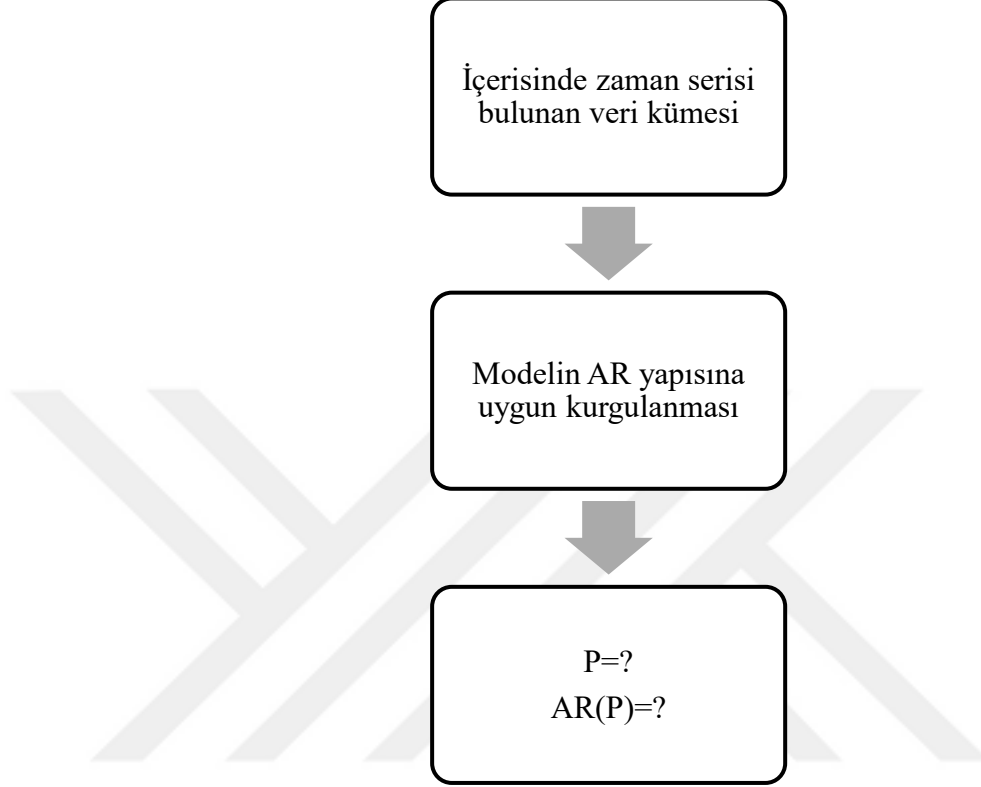
ε_t : Hata terimi

$$AR(P) = Y_t = \beta_0 + Y_{t-1} \cdot \beta_1 + Y_{t-2} \cdot \beta_2 + \dots + Y_{t-p} \cdot \beta_p + \varepsilon_t \quad (2.5)$$

(2.5) denklemini bir AR modelidir. AR modeli, serinin geçmiş değerlerinden etkilenir (Shumway ve Stoffer, 2017). Bununla birlikte bir de beyaz gürültü sürecinden etkilenen bir model yapısıdır. Beyaz gürültü sürecindeki hata ise denklemlerde ε_t olarak ifade edilmektedir. Sonuç olarak, serinin hem geçmiş değerlerinden etkilenmekte hem de beyaz gürültü yapısından etkilenmektedir. AR model yapısı olarak gösterilen bu kurgu, bir otoregresif süreç yapısıdır.

AR yapısında bahsedilen 'P' gecikme değerini hesaplamanın, evrensel olarak geçerliliği olan bir 'P' değeri yoktur. Tamamen doğru kabul edilen bir değeri yoktur

denilebilir. Bu tamamen çıkan sonuçlara göre ilerleyen sezgisel bir yönelimdir. Kendi kurgulayacağımız modelin gerçekten başarılı olup olmadığına çıkan sonuçlar ışığında denemeler sonucu karar verilecektir.



Şekil 2.23. AR Yapısı Kurgu Aşaması

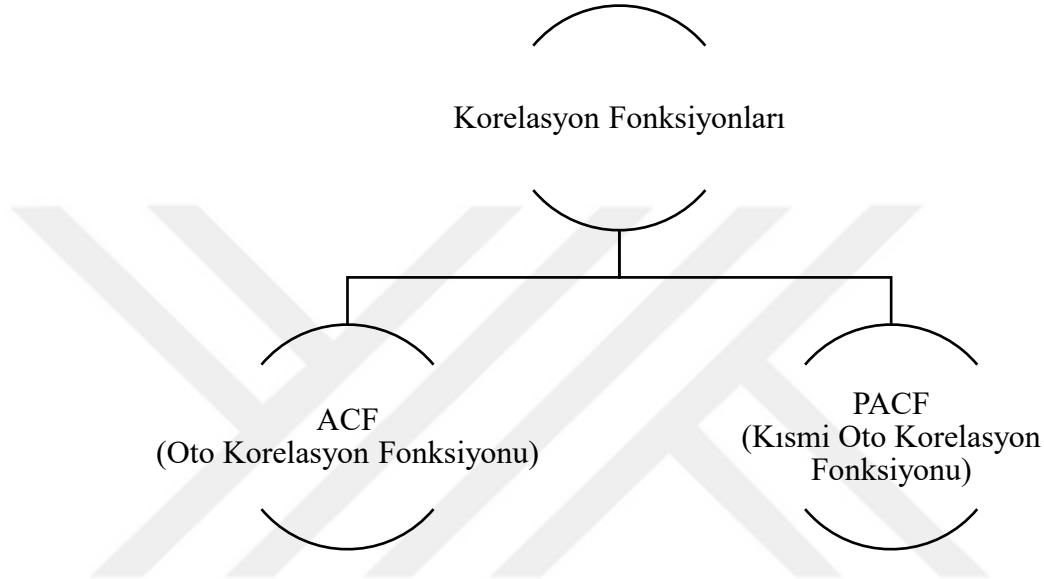
Şekil 2.23. nolu şekilde, aslında gecikme değerini ifade eden ‘P’ değerinin aşamaları verilmiştir. Şekil 2.23. nolu şeklin 3. Aşamasında, ‘P’ değeri kaç alınırsa doğru sonuca yaklaşan bir değer elde edilir?’ sorusu sorulmaktadır.

Otoregresif süreç denilen AR model yapısında elimizdeki verilerin bu model yapısına uygun olup olmama kararı verilerek bir sonraki aşamaya geçilir. Bu karar yapıları ise model kriterlerinin veri kümesi üzerinde uygulanarak sonuçlarının değerlendirildiği formlardır. Eldeki model yapısı ile uygun denklemler kurulur. Sonrasında ε_t ile ifade edilen hata parametresi oluşur. Bu hata parametresi kurgulanan düzende büyük bir önem taşımaktadır. Bu hata parametresinin hesaplanabilmesi için ise bir başlangıç noktasının olması gereklidir.

Bazı noktalar incelenerek doğru bir ‘P’ değeri ile başlanmalıdır. Bu değer, başlangıçta yüzde yüz doğru kabul edilen evrensel bir değer olmasa bile uygun bir ‘P’

değeri ile başlamak her zaman için daha iyi bir yol sunar. Uygun bir değerden kasıt ise aslında tutarlı ve öngörülebilir denemelerden sonra seçilen en iyi değer anlamına gelir.

Y_t değerinin hesaplanması için zaman serilerindeki korelasyon fonksiyonlarının değerlerinin bilinmesi gereklidir. Bu fonksiyonlar Şekil 2.24.'deki gibi ACF ve PACF olarak karşımıza çıkmaktadır. Bu fonksiyon sonuçlarının değerlerine dayanarak karar aşamaları şekillenmiş olacaktır.



Şekil 2.24. Korelasyon Fonksiyonları Ayrışımı Görseli

Oto Korelasyon Fonksiyonu (ACF)

ACF (Oto Korelasyon Fonksiyonu) yapısı içerisinde bağımsız değişkenlerin $x_1, x_2, x_3 \dots$ gibi x değişkenlerinin, gecikmeli değerler olarak bir modeli kurgulanabilir (Demir, V., Zontul, M., & Yelmen, I., 2020). Bahsedilen oto korelasyon fonksiyonunun sonucuna göre Y_t ' nin kendi gecikmeli değerleri ile ilgili olan ilişkileri bulunur. Bu ilişkiler yüksek değerlerde yakalanırsa fonksiyon sonucu pozitif ya da negatif yönde yüksek değer döner ise bu bize AR modeli kurgulayabiliriz kararının kapılarını aralar. ACF yapısında azalma sürecinde ise AR modelinin kullanılabilirliği üzerine sinyaller verir.

Kısmi Oto Korelasyon Fonksiyonu (PACF)

PACF (Kısmi Oto Korelasyon Fonksiyonu) yapısı ise aradaki değerleri dışlayarak sadece ikisi arasındaki oto korelasyonu bize veren bir yapıdır. Belirli bir 'P' gecikmeden sonra diğer noktalar arasındaki değer daha fazla olduğunda güven aralığının altında kalan

değerler alınmaz (Demir, V., Zontul, M., & Yelmen, I., 2020). Üstünde kalan değerler arasında bir ilişki kurulmaya çalışılır.

ACF'nin azalan yapısı var ise AR modeli uygulamaya yönelik sinyaller veriliyor denilebilir. Oto korelasyon yapısı bu şekiller gibi ise bu modelde karar kılınabilir. AR modelinde eğer karar verilir ise 'P' değeri yani gecikme değerinin belirlenmesi için inceleme yapılması gereklidir. Bu incelemelerde de ACF değeri gibi PACF değerinin de incelenmesi lazımdır. Bir anlamda kısmi oto korelasyon fonksiyonu, güven aralığının dışında kalan maksimum gecikme değeri olarak söylenebilir.

Özetleyecek olunursa, AR model yapısında yani otoregresif yapıda gerekli olan gecikme değeri 'P' idi. 'P' gecikme sayısının tespiti genellikle deneme-yanılma yapısındadır. Sezgisel yapı aslında, daha önceki çalışmalarda kullanılan işe yaradığı düşünülen yapılardır. Ancak, bu çalışmada da olduğu gibi önemli nokta modelin nihai çıktısıdır. Yani, bir modelin başarısı hata metrikleri ile ilişkilendirilir. Bu hata metrikleri modelin başarımına karar verme aşamasındaki önemli olan yapıdır. AR modeli tek başına aktif olarak kullanılacak bir yapı değildir. Fakat gerçekleşen modellerin ana temelini oluşturur.

MA (Moving-Average) Model Yapısı

MA süreci, bir zaman serisinin t zamandaki değerini rassal bir değişken olarak kabul eden hata teriminin, t yapısı ile ve bunun geçmiş dönemlerin ağırlıklı ortalamasını ifade eden bir yapıdır. Bu yüzden, hareketli ortalama modeli adı verilir. MA yapısı, hareketli ortalama olarak tanımlanır (Shumway ve Stoffer, 2017).

AR yapısında Y_t değişkeni vardı ve bu değişken otoregresyon sürecine aktarılmaktaydı. Bunun sonucunda yapı bize AR modelini veriyordu. MA yapısında ise serinin kendi gecikme değerleri değil hata yapısı denilen yapıyı barındırmaya odaklanılır. MA yapısındaki asıl odak olarak hata teriminin gecikmesi incelenir. AR modelinde 'P' ile temsil edilen bu değişken, MA yapısında 'Q' ile simgelenir.

MA yapısının 1. gecikme ile kurulan denklemi (2.6) nolu denklemde gösterilmektedir.

$$MA(1) = Y_t = \beta_0 + \beta_1 \cdot \varepsilon_{t-1} + \varepsilon_t \quad (2.6)$$

(2.6) denklemi:1 gecikmeli hata teriminin MA model yapısıdır, (Q=1), (Shumway ve Stoffer, 2017).

AR yapısında ‘p’, MA yapısında ise ‘q’ parametresi kullanılır.

q: hata teriminin gecikme sayısı

(2.7) denklemi: 1 gecikmeli hata teriminin MA model yapısıdır, (Q=1), (Shumway ve Stoffer, 2017).

$$MA(2) = Y_t = \beta_0 + \beta_1 \cdot \varepsilon_{t-1} + \beta_2 \cdot \varepsilon_{t-2} + \varepsilon_t \quad (2.7)$$

$$MA(q) = Y_t = \beta_0 + \beta_1 \cdot \varepsilon_{t-1} + \beta_2 \cdot \varepsilon_{t-2} + \dots + \beta_q \cdot \varepsilon_{t-q} + \varepsilon_t \quad (2.8)$$

(2.8) denklemi: q gecikmeli hata teriminin MA model yapısı/MA modelinin q gecikmelidir (Shumway ve Stoffer, 2017).

MA süreç yapısı, AR yapısının ACF ve PACF açısından tam tersi olarak düşünülebilir. Bir bakıma ACF ve PACF yapısı yer değiştiriyor olarak söylenebilir. Eğer süreç, MA model yapısını yani hareketli ortalama sürecinin kullanılmasının daha uygun olduğunu gösteriyor ise oto korelasyon fonksiyon yapısının bir anda kesildiğinin ortaya çıkması gereklidir. PACF oranı ise yavaş yavaş azalma sinyali vermelidir.

ARIMA Modeli

Hem otoregresif hem de hareketli ortalama sürecidir. Hem AR sürecinden ‘p’ yi hem de MA sürecinden ‘q’ değerlerini barındırır. AR ve MA modellerinin birleşimidir denilebilir (Demirel, Ö., Kakilli, A., & Tektaş, M., 2010).

İşlenecek olan ham data hareketli ve eğer seri gecikme ile durağanlaştırılabilir ise ARIMA kullanılır. Bu tezde kullanılan veri kümesi de zaman serisi verisi olduğu için bu veri değişken bir veridir. ARIMA yapısı, ‘p’, ‘d’, ‘q’ değişkenlerinden oluşur.

d: eldeki seri durağan olmadığı için fark işlemi ile durağanlık yakalamak gerekir. Bu durumda d parametresi, kaçınıcı farkta durağan hale geldiğini yani farkın derecesini belirleyen bir parametre yapısı olarak söylenebilir.

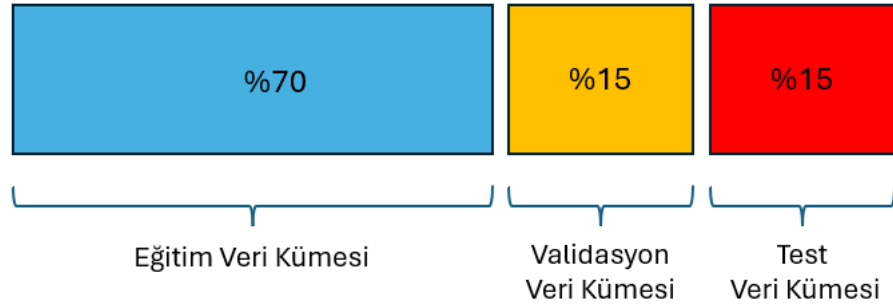
Sonuç olarak, ARIMA modelinde, P, D ve Q parametreleri kullanılmıştır. ‘P’ değeri, otoregresif süreci veren parametredir ve değeri 5’tir. ‘D’, fark alma derecesidir ve değeri 1’dir. ‘Q’, hareketli ortalama model derecesidir ve değeri 0’dır.

BÖLÜM 3

SONUÇLAR VE TARTIŞMA

3.1. Tahminleme Sonrası Çıkan Sonuçların Değerlendirilmesi

Bu tezde, zaman serisi analizinde kullanılan 3 farklı modelin karşılaştırılması yapılmıştır. Veri kümesinden %70'i eğitim veri kümesi ve %30'luk kısmı ise %15' i test ve %15'i validasyon veri kümesi olarak ayrılmıştır. Ayrılan veri kümeleri oranları literatürle uygun olacak şekilde belirlenmiştir (Abdel-Nasser, M., & Mahmoud, K., 2019), (Marquez-Zepeda, M. J., Santos-Ruiz, I., Pérez-Pérez, E. J., Navarro-Díaz, A., & Delgado-Aguñaga, J. A., 2025). Şekil 3.1.'de veri kümesinin ayrıştırılma gösterimi verilmiştir.



Şekil 3.1. Eğitim – Test Veri Kümesi Ayrımı

- X eksen hareketliliği Çizelge 3.1.'de hata oranları bazında verilmiştir.

Çizelge 3.1. X Eksen Hareketinde Hata Oranı Karşılaştırılması

	Eğitim Verisi Mutlak Hata	Eğitim Verisi Kök Ortalama Karesel Hata	Test Verisi Mutlak Hata	Test Verisi Kök Ortalama Karesel Hata
ARIMA	48.3601	71.8983	66.4197	74.7684
RNN	50.7160	74.2582	51.9083	76.0266
LSTM	44.2749	70.2373	43.1371	68.3188

- Y eksen hareketliliği Çizelge 3.2.'de hata oranları bazında verilmiştir.

Çizelge 3.2. Y Eksen Hareketinde Hata Oranı Karşılaştırılması

	Eğitim Verisi Mutlak Hata	Eğitim Verisi Kök Ortalama Karesel Hata	Test Verisi Mutlak Hata	Test Verisi Kök Ortalama Karesel Hata
ARIMA	61.3178	78.8339	80.4428	97.2952
RNN	48.9109	70.7659	50.8771	73.9210
LSTM	48.4316	62.1065	49.1683	54.4397

- Z eksen hareketliliği Çizelge 3.3.'de hata oranları bazında verilmiştir.

Çizelge 3.3. Z Eksen Hareketinde Hata Oranı Karşılaştırılması

	Eğitim Verisi Mutlak Hata	Eğitim Verisi Kök Ortalama Karesel Hata	Test Verisi Mutlak Hata	Test Verisi Kök Ortalama Karesel Hata
ARIMA	80.4744	123.9756	86.1105	133.0173
RNN	78.6507	102.9715	99.6994	108.6205
LSTM	76.5177	60.5844	52.6580	55.4584

3.2. Deney Sonuçları ve Tartışma

Bu bölüm, RNN, LSTM ve ARIMA modelleri kullanılarak üretimde kullanılan takım ucu verilerinin öngörülen tahminleyici eğilimlerini açıklamaktadır. Tahminlemeler, takımın pozisyon verilerini üç zaman serisi verisi için, zaman serisi verilerini optimize edilmiş LSTM, RNN ve ARIMA modellerine bağımsız olarak besleyerek yapılmıştır. Aşağıdaki tabloya göre LSTM daha az hatalı sonuçlar vermiştir.

Üç modelin ‘Eğitim Verisi Mutlak Hata’ değerlerini farklı parametreler ve aynı giriş özellikleri kullanılarak kıyaslamaktadır. Ortalama mutlak hata (MAE), ne kadar küçük ise model o kadar iyi tahminler yapmış olur. LSTM, bu aşamada diğer 2 modele göre Çizelge 3.4.’teki gibi her ekseninde daha küçük oranda hata sonucu vermiştir. Çizelge 3.1., Çizelge 3.2. ve Çizelge 3.3. incelendiğinde test verileri için ortalama mutlak hata ve kök ortalama karesel hata metrikleri bakımından da LSTM rakiplerine göre daha az hata yaparak en başarılı tahminlerde bulunmuştur.

Çizelge 3.4. RNN-LSTM-ARIMA Modellerinin MAE Karşılaştırması


	X Eksenini Ortalama Mutlak Hata	Y Eksenini Ortalama Mutlak Hata	Z Eksenini Ortalama Mutlak Hata
ARIMA	48.3601	61.3178	80.4744
RNN	50.7160	48.9109	78.6507
LSTM	44.2749	48.4316	76.5177

Bu çalışmada hassasiyet değişkenlik gösterebilir. Nedeni veride bazı durumlarda gerçekleşen kesintilerden kaynaklı olabilir, yine de bunun üstesinden gelebilmek için sanayi ortamında elde edilen büyük verinin varlığı modellerin eğitim sürecinde ihtiyaç duyduğu veri miktarını karşılayacak kadar yeterlidir.

Zaman serisi analizi üzerine kullanılan yöntemler, LSTM (Navares ve Aznarte, 2020), RNN (DiPietro ve Hager, 2020) ve ARIMA algoritmalarıdır. LSTM yapısı kullanılırken, 100 katman kullanılmıştır. Dropout oranı 0.1’dir. Aktivasyon fonksiyonu ‘tanh’ olarak seçilmiştir. RNN derin öğrenme modelinde, nöronlar, katmanlar, girdiler ve fonksiyon parametreleri üzerinden değerlendirmeler yapılmıştır.


Elde edilen sonuçlar, nöronlar, katmanlar, girdiler ve fonksiyon değişkenleri üzerinden hesaplanmıştır. 95 adet nöron kullanılmıştır. ‘Relu’ fonksiyonu kullanılmıştır. 10 sütun ve 14 milyon satırlı girdi verisi vardır. Üçüncü ve son olarak ARIMA modelinde, P, D ve Q parametreleri kullanılmıştır. ‘P’ değeri, otoregresif süreci veren parametredir ve değeri 5’tir. ‘D’, fark alma derecesidir ve değeri 1’dir. ‘Q’, hareketli ortalama model derecesidir ve değeri 0’dır.

Bu çalışmada LSTM, RNN ve ARIMA algoritmaları kullanılmıştır. LSTM en iyi sonucu verdiği için Şekil 3.2.'de X eksen tahmininin grafiği LSTM çıktısı olarak verilmiştir.




Şekil 3.2. En Başarılı Model ile Takım Ucunun X Koordinat Grafiği

Şekil 3.3.'de Y eksen tahmininin grafiği verilmiştir.



Şekil 3.3. En Başarılı Model ile Takım Ucunun Y Koordinat Grafiği

Şekil 3.4.'te Z eksen tahmininin grafiği verilmiştir. Şekil 3.2., Şekil 3.3. ve Şekil 3.4. incelendiğinde elde edilen tahminlerin gerçek koordinat verileri ile örtüştüğü ve LSTM modelinin başarımının görsel olarak da doğrulandığı sonucuna ulaşılmıştır.



Şekil 3.4. En Başarılı Model ile Takım Ucunun Z Koordinat Grafiği

3.3. SONUÇ: Ulaşılmak İstenen Hedefler ve Beklenen Çıktılar

Bu çalışmada anlatılan derin öğrenme modellerinin aşınmış bölge tespiti için kullanımının araştırılması üretim hattında gerçekleşmektedir. Üretimde bulunan kesici takımların verilerinden yapay zeka algoritmaları kullanılarak çıkarımlar yapılmaktadır. Derin öğrenme modellerinde kullanmayı amaçladığımız konunun ana motivasyon kaynağı makinede işlem için kullanılan takımlardır. Konunun genel hatları ile anlatılması gerekirse, sanayi bir ürün üretmek üzere tasarlanmış çalışma alanlarıdır. Bu ürün üretilirken kullanılan araç gereçlerden biri de makinelerdir. Makineler aslında ana hatlarıyla üretimde hem şirkete yüklü miktarda katkı sağlayan hem de aynı zamanda farklı durumlar neticesinde zarar getirme yetisine sahip olan bir gereçtir. Bu nedenle, üretimin gerçekleşmesi için makineler olmazsa olmaz bir öneme sahiptir. Makinadan gelen verilerin analizinin yapılması ana hedeftir.

Bu çalışmada amaçlanan ve ulaşılmaya odaklanılan ana konu sürdürülebilirliktir. Üretim kalitesindeki darboğazları ve düşüşleri hızlı bir şekilde tespit ederek çözmek için tüm tesisi gerçek zamanlı olarak izlemek amaçlanmaktadır. Ekipman ömrünü uzatmak ve ekipman verimliliğini arttırmak için bakım planlamalarının yapılması elzemdir. Derin öğrenme algoritmaları ile amaçladığımız ve gelecekte iyileştirilmek istenen birçok işlem vardır. Hangi takım türünün daha çok aşınma riski içerdiği, takımların geçmiş istatistiki verileri kullanılarak hangi bölgelerinin aşınmaya maruz kaldıkları, aşınmayı arttıran ısı, nem, sıcaklık, devir sayısı, sürtünme vb. gibi dış etkenlerin olup olmadığı, sensörlerden elde edilen veriler ve derin öğrenme modelleri ile kestirilmeye ve sonuç olarak fabrika

ortamında üretimin aksamaması gelecekte sağlanabilecektir. Halihazırda deneyimli çalışanların el yordamı ile dahil olduğu süreçlerde önerilen yapay zeka ve öznitelik seçme yöntemleri ile kırılma ve üretimde aksama olmadan çalışanlara da dolaylı olarak güvenli bir çalışma ortamı sağlayabilecek erken uyarı sistemi olarak düşünülebilecek bir model geliştirilebilecektir.

Bu çalışmada ana motivasyon kaynağımız, üretimin takım ucu kırılması kaynaklı durmasıdır. Endüstri 4.0 sanayi ortamında sensörler ile üretilen veriler ile makine öğrenimine dayalı LSTM, RNN ve ARIMA model kullanılması sağlanmıştır. Buna bağlı olarak, eksen hareketleri ile arızaların tahmini için sonuçlar üretilmiştir. Üç modelde de hata durumu tahminleri, ihmal edilebilir bir hata payıyla sonuçlanmıştır. Çalışmada, tahminci makine öğrenimi sonucunda tüm modeller arasında en başarılı sonuca sahip olan LSTM tahmincisi olmuştur. Zaman serisi analizi ile oluşturulan LSTM modeliyle, robotun eksenler üzerindeki hareketleri koordinatları ile birlikte tahmin edilebilir duruma gelmiştir. Böylece, üretim esnasında takım ucunun hareketlerini canlı olarak izlenebilirlik ile ölçecek ve her birinin işleme süresini hesaplayarak ekipmanın aşınmasını tahmin edici algoritmalar karşılaştırılmış oldu. Bu pilot çalışma, kullanılan üç modelin üretimdeki hareketini tahminleyerek gerçekçi bir şekilde kullanılabilirliğini göstermiştir. En ayırt edici özelliklerin otomatik olarak seçilmesi, seçilen özelliklerden tahmin edici bir modelin geliştirilmesi ve endüstriyel ortamda büyük verilere uygulanması bu çalışmanın inovasyonunun ana unsurlarıdır.

Bu çalışma ile iş ve işçi sağlığı ve güvenliği alanında da takım ucu kırılması kaynaklı istenmeyen kazalara dolaylı olarak erken uyarı sistemi geliştirilerek katkıda bulunulabilir. Sanayide farklı ürün üretim aşamalarında farklı takım ucu hasarları meydana gelebilmektedir. Birimde çalışan usta ve işçilerin el yordamı ile ayrımsayıcı sayısal verileri belirlemesi kişisel tecrübeye dayanmaktadır. Bu çalışma ile öznitelik seçimi ve derin öğrenme modeli hibrit bir şekilde birleştirilerek daha nesnel ve otomatik bir analiz sistemi geliştirilmiş olup sanayide dijital dönüşüme de katkı vermesi beklenmektedir.

Sonuç olarak, çalışmanın müşteri memnuniyeti, arızalar ve duruşların önlenmesi (Çakir, A., Ozkaya, E., Akkus, F., Kucukbas, E., & Yilmaz, O., 2022), büyük maddi kayıpların önüne geçilmesi ve itibarın artması (Güven ve Şahin, 2022) gibi firma bazında

olumlu etkileri olacaktır. Ek olarak, ilerleyen alıřmalarımızda derin ğrenme modellerinde daha fazla parametre deęiřiklięi yapılabilir. Veri sayısı arttırılabilir. Enerji kesintilerinden ve sensörün ıkarılmasından kaynaklanan veri kesintisi daha da minimuma indirilebilir.



KAYNAKLAR

- Abdel-Nasser, M., & Mahmoud, K. (2019). Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Computing and Applications*, 31(7), 2727-2740.
- Akben, İ., & Avşar, İ. İ. (2018). Endüstri 4.0 ve Karanlık Üretim: Genel Bir Bakış. *Türk Sosyal Bilimler Araştırmaları Dergisi*, 3(1), 26-37.
- ArunKumar, K. E., Kalaga, D. V., Kumar, C. M. S., Kawaji, M., & Brenza, T. M. (2021). Forecasting of COVID-19 using deep layer recurrent neural networks (RNNs) with gated recurrent units (GRUs) and long short-term memory (LSTM) cells. *Chaos, Solitons & Fractals*, 146, 110861.
- Belas, A., & Bidyuk, P. (2021). Convolutional neural networks for modeling and forecasting nonlinear nonstationary processes. *ScienceRise*, (3 (74)), 12-20.
- Cakir, A., Ozkaya, E., Akkus, F., Kucukbas, E., & Yilmaz, O. (2022). Real time big data analytics for tool wear protection with deep learning in manufacturing industry. In *International Conference on Intelligent and Fuzzy Systems* (pp. 148-155), Cham: Springer International Publishing.
- Demir, V., Zontul, M., & Yelmen, I. (2020, September). Drug sales prediction with ACF and PACF supported ARIMA method. In *2020 5th International Conference on Computer Science and Engineering (UBMK)* (pp. 243-247). IEEE.
- Demirel, Ö., Kakilli, A., & Tektaş, M. (2010). Anfis ve arma modelleri ile elektrik enerjisi yük tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25(3).
- DiPietro, R., & Hager, G. D. (2020). Deep learning: RNNs and LSTM. In *Handbook of Medical Image Computing and Computer Assisted Intervention* (pp. 503-519). Academic Press.

- Drakaki, M., Karnavas, Y. L., Tzifettas, I. A., Linardos, V., & Tzionas, P. (2022). Machine learning and deep learning based methods toward industry 4.0 predictive maintenance in induction motors: State of the art survey. *Journal of Industrial Engineering and Management (JIEM)*, 15(1), 31-57.
- Elsaraiti, M., & Merabet, A. (2021). A comparative analysis of the ARIMA and LSTM predictive models and their effectiveness for predicting wind speed. *Energies*, 14(20), 6782.
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5-6), 602-610.
- Güven, Ö., & Şahin, H. (2022). Predictive maintenance based on machine learning in public transportation vehicles. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 89-98.
- Hanson, J., Yang, Y., Paliwal, K., & Zhou, Y. (2017). Improving protein disorder prediction by deep bidirectional long short-term memory recurrent neural networks. *Bioinformatics*, 33(5), 685-692.
- Hua, Y., Zhao, Z., Li, R., Chen, X., Liu, Z., & Zhang, H. (2019). Deep learning with long short-term memory for time series prediction. *IEEE Communications Magazine*, 57(6), 114-119.
- Iranzad, R., & Liu, X. (2024). A review of random forest-based feature selection methods for data science education and applications. *International Journal of Data Science and Analytics*, 1-15.
- Jia, X., Zhou, W., Yang, H., Li, S., & Chen, X. (2023). Short-term traffic travel time forecasting using ensemble approach based on long short-term memory networks. *IET Intelligent Transport Systems*, 17(6), 1262-1273.
- Kashif, K., & Ślepaczuk, R. (2025). LSTM-ARIMA as a hybrid approach in algorithmic investment strategies. *Knowledge-Based Systems*, 113563.
- Kursa, M. B., Jankowski, A., & Rudnicki, W. R. (2010). Boruta—a system for feature selection. *Fundamenta Informaticae*, 101(4), 271-285.

- Li, X., Lim, B. S., Zhou, J. H., Huang, S., Phua, S. J., Shaw, K. C., & Er, M. J. (2009). Fuzzy neural network modelling for tool wear estimation in dry milling operation. In *Annual Conference of the PHM Society* (Vol. 1, No. 1).
- Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y. (2015). Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54, 187-197.
- Marquez-Zepeda, M. J., Santos-Ruiz, I., Pérez-Pérez, E. J., Navarro-Díaz, A., & Delgado-Aguíñaga, J. A. (2025). Internet-of-Things-Based CO2 Monitoring and Forecasting System for Indoor Air Quality Management. *Mathematical and Computational Applications*, 30(2), 36.
- Mohanraj, T., Shankar, S., Rajasekar, R., Sakthivel, N. R., & Pramanik, A. (2020). Tool condition monitoring techniques in milling process—A review. *Journal of Materials Research and Technology*, 9(1), 1032-1042.
- Munaro, R., Attanasio, A., & Del Prete, A. (2023). Tool wear monitoring with artificial intelligence methods: a review. *Journal of Manufacturing and Materials Processing*, 7(4), 129.
- Namini, S. S., Tavakoli, N., & Namin, A. S. (2018). A comparison of ARIMA and LSTM in forecasting time series. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1394-1401).
- Nasir, V., & Sassani, F. (2021). A review on deep learning in machining and tool monitoring: Methods, opportunities, and challenges. *The International Journal of Advanced Manufacturing Technology*, 115(9), 2683-2709.
- Navares, R., & Aznarte, J. L. (2020). Predicting air quality with deep learning LSTM: Towards comprehensive models. *Ecological Informatics*, 55, 101019.
- Rangwala, S., & Dornfeld, D. (1990). Sensor integration using neural networks for intelligent tool condition monitoring. *Journal of Engineering for Industry*, 11, 219-228.
- Sachin, M. M., Baby, M. P., & Ponraj, A. S. (2020). Analysis of energy consumption using RNN-LSTM and ARIMA Model. In *Journal of Physics: Conference Series* (Vol. 1716, No. 1, p. 012048), IOP Publishing.

- Shumway, R. H., Stoffer, D. S., Shumway, R. H., & Stoffer, D. S. (2017). ARIMA models. *Time series analysis and its applications: with R examples*, 75-163.
- Soori, M., Arezoo, B., & Dastres, R. (2023). Machine learning and artificial intelligence in CNC machine tools, a review. *Sustainable Manufacturing and Service Economics*, 2, 100009.
- Stojov, V., Koteli, N., Lameski, P., & Zdravevski, E. (2018). Application of machine learning and time-series analysis for air pollution prediction. *Proceedings of the CIIT*.
- Tunkiel, A. T., Sui, D., & Wiktorski, T. (2020). Training-while-drilling approach to inclination prediction in directional drilling utilizing recurrent neural networks. *Journal of Petroleum Science and Engineering*, 196, 108128.
- Wang, H., Zhang, W., Yang, D., & Xiang, Y. (2022). Deep-learning-enabled predictive maintenance in industrial internet of things: methods, applications, and challenges. *IEEE Systems Journal*, 17(2), 2602-2615.
- Wen, X., & Li, W. (2023). Time series prediction based on LSTM-attention-LSTM model. *IEEE Access*, 11, 48322-48331.
- Zeng, Z., & Khushi, M. (2020). Wavelet denoising and attention-based RNN-ARIMA model to predict forex price. In *2020 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-7). IEEE.
- Zhang, X., Zhao, B., & Lin, Y. (2021). Machine learning based bearing fault diagnosis using the Case Western Reserve University data: A review. *IEEE Access*, 9, 155598-155608.
- Zhang, Z., Lu, J., Zhou, G., & Liao, X. (2018). Research on tool wear prediction based on LSTM and ARIMA. In *Proceedings of the 2018 International Conference on Big Data Engineering and Technology* (pp. 73-77).

TEZ ÖĐRENCİSİNE AİT BİLİMSEL ÇIKTILAR

Konferans Bildirileri

1. Konferans Bildirisi: Ezgi Küçükbaş, İlke Kurt, Sezer Ulukaya, “Predictive modeling of machine tool data using artificial intelligence techniques in the Industry 4.0 era” (Gönderildi)

ÖZGEÇMİŞ

İş Bilgileri:

Kıdemli Alt Yapı Uygulama Geliştirme Lideri - HSBC BANK A.Ş. (Mart 2024 - Şuanda)

Veri Analisti - Şişecam Otomotiv Camları Fabrikası (Mart 2023 - Şubat 2024)

Veri Bilimci - Hema Endüstri A.Ş. (Aralık 2020 - Mart 2023)

Eğitim Bilgileri:

Trakya Üniversitesi (TÜ) : Hesaplamalı Bilimler (2022 - Şuanda)

Yıldız Teknik Üniversitesi (YTÜ) : Matematik Mühendisliği (2013 - 2019)