



**T.C.
EGE ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE TİTREŞİM ANALİZİ TABANLI
ARIZA TEŞHİS VE KESTİRİMCİ BAKIM SİSTEM
TASARIMI**

Doktora Tezi

MUSTAFA YURTSEVER

İşletme Anabilim Dalı

İZMİR

2020

T.C.
EGE ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE TİTREŞİM ANALİZİ TABANLI
ARIZA TEŞHİS VE KESTİRİMCİ BAKIM SİSTEM
TASARIMI**

Doktora Tezi

MUSTAFA YURTSEVER

Tez Danışmanı: Dr.Öğr. Üyesi URAL GÖKAY ÇİÇEKLİ

İşletme Anabilim Dalı
İşletme Doktora Programı

ETİK KURALLARA UYGUNLUK BEYANI

Ege Üniversitesi Sosyal Bilimler Enstitüsü Müdürlüğüne sunduğum “Makine Öğrenmesi ve Derin Öğrenme Yöntemleri İle Titreşim Analizi Tabanlı Arıza Teşhis Ve Kestirimci Bakım Sistem Tasarımı” adlı doktora tezinin tarafımdan bilimsel ahlak ve normlara uygun bir şekilde hazırlandığını, tezimde yararlandığım kaynakları bibliyografyada ve dipnotlarda gösterdiğimi onurumla doğrularım.



Mustafa YURTSEVER

ÖNSÖZ

Bakım faaliyetleri üretim maliyetlerini önemli şekilde etkilemektedir. Maliyetleri kontrol altında tutmak isteyen işletmelerin bu alan üzerine yoğunlaştıkları görülmektedir. Makine öğrenmesi ve derin öğrenme alanındaki hızlı gelişmeler; bakım yöntemlerinden birisi olan kestirimci bakım için de yeni fırsatlar ortaya çıkarmıştır. Nesnelerin interneti teknolojileri ile birlikte gelişen ve ucuzlayan sensörler vasıtasıyla üretimde kullanılan her makinenin verileri çok daha kolay ve ucuz yolla toplanabilmektedir.

Bu çalışmaya başlarken derin öğrenme yöntemlerinden oto kodlayıcının otomatik özellik çıkarma ve boyut azaltma yöntemlerinin etkinliği literatürdeki çalışmalarda görülmüştür.

Bu doğrultuda çalışmada makine öğrenmesi ve derin öğrenme yöntemleri ile titreşim analizi tabanlı arıza teşhis ve kestirimci bakım için bir sistem tasarımı amaçlanmıştır. Mems sensörlerinin kestirimci bakım sistemi için kullanılabilirliği de sorgulanmıştır. Literatürdeki çalışmalardan farklı olarak gerçek bir sistemden toplanan veriler ile bindirme hatasının teşhisi ve sınıflandırılması yapılmıştır.

İzmir, Ağustos 2020

Mustafa YURTSEVER

ÖZET

Günümüzde işletmeler; üretimin her aşamasından veri toplamak amacıyla daha fazla sensör ve bilgi iletişim teknolojisi kullanmaktadır. Nesnelerin interneti, makine öğrenmesi ve derin öğrenme gibi teknolojiler verilerin toplanmasını ve işlenmesini kolaylaştırmaktadır.

Gerçek zamanlı veriler kullanarak olası arızaların teşhis edilmesini sağlayan kestirimci bakım, arıza sürelerini ve bakım maliyetlerini en aza indirmeyi hedeflemektedir. Kestirimci bakımı etkin uygulamak için ekipman sağlığını değerlendirme ve toplanan verilerle mevcut veya gelecekteki arızalar hakkında ayrıntılı bilgi bulma yeteneğine sahip olunması gerekmektedir.

Makine öğrenmesi ve derin öğrenme yöntemleri kestirimci bakım uygulamalarına yeni bakış açıları kazandırmıştır. Bu tez kapsamında makine öğrenmesi ve derin öğrenme yöntemleri ile titreşim analizi tabanlı arıza teşhisi ve kestirimci bakım sistemi tasarımı amaçlanmıştır.

Geliştirilen sistem ile uzmanlık bilgisi gerektirmeden derin öğrenme yöntemlerinin özellik çıkarma yöntemleri kullanılarak, veri odaklı hata teşhisi modellerinin oluşturulması amaçlanmıştır. Derin öğrenmenin denetimsiz öğrenme için kullanılan oto kodlayıcı yapısının boyut azaltma özelliği kullanılarak yüksek boyutlu ham titreşim verilerinin boyutu azaltılarak önerdiğimiz modelde doğrudan kullanılmıştır.

Sistemde gerçek zamanlı durum izleme için, Mikro Elektro Mekanik Sistem (MEMS) sensörü ve Raspberry Pi donanımı kullanılarak sürekli veri kaydı yapısı tasarlanmıştır. Sistemde toplanan veriler ile veri odaklı hata teşhis modeli bu veriler üzerinde test edilmiştir. Ayrıca bu tez kapsamında, düşük bütçeli mini bilgisayar ve sensör teknolojileri ile işletme içinde kestirimci bakım uygulamalarının yapılabilirliği araştırılmıştır.

Bindirme hatası CNC makinelerinde yüksek onarım maliyetleri ve uzun arıza sürelerine yol açmaktadır. Bu çalışmada toplanan veriler ile bindirme hatasının teşhisi ve sınıflandırılması da yapılmıştır.

ABSTRACT

Today, businesses use more sensors and information communication technology to collect data from every stage of production. Technologies such as the internet of things, machine learning, and deep learning make it easy to collect and process data.

The purpose of predictive maintenance, based on the philosophy of maintenance when necessary, is to carry out the maintenance action after diagnosing possible faults. Minimizing downtime and maintenance costs by using real-time data is the main goal. The key to implementing predictive maintenance is evaluating equipment health and finding detailed information about current or future faults with the data collected.

Machine and deep learning methods have brought new perspectives to predictive maintenance practices. In this thesis, machine and deep learning methods, vibration analysis based fault diagnosis, and predictive maintenance system design are aimed.

The developed system aims to create data-oriented error diagnosis models by using feature extraction methods of deep learning methods without requiring expert knowledge. It was used directly in the model we proposed by reducing the size of the high dimensional raw vibration data using the size reduction feature of the autoencoder structure used for unsupervised learning of deep learning.

For real-time condition monitoring in the system, a continuous data recording structure is designed using Micro Electro Mechanical System (MEMS) sensor and Raspberry Pi hardware. The data collected in the system and the data-oriented error diagnosis model were tested on these data. Also, within this thesis's scope, the feasibility of low-cost microcomputer and sensor technologies and predictive maintenance applications in the enterprise were investigated.

Collision leads to high repair costs and long downtime in CNC machines. With the data collected in this study, the collision error diagnosis and classification were also made.

İÇİNDEKİLER

ÖNSÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
KISALTMALAR	viii
GİRİŞ	1

BİRİNCİ BÖLÜM BAKIM YAKLAŞIMLARI

1.1 Düzeltici Bakım.....	6
1.2 Önleyici Bakım.....	7
1.3 Kestirimci Bakım.....	9

İKİNCİ BÖLÜM MAKİNE ÖĞRENMESİ

2.1 Denetimli Öğrenme	14
2.1.1 Sınıflandırma.....	16
2.1.1.1 Naif Bayes	16
2.1.1.2 Karar Ağaçları	17
2.1.1.3 Destek Vektör Makineleri	19
2.1.1.4 K-En Yakın Komşu	21
2.1.2 Regresyon.....	22
2.2 Denetimsiz Öğrenme	23
2.2.1 Kümeleme	23
2.2.2 Boyut Azaltma	24
2.3 Derin Öğrenme	26
2.3.1 Çok Katmanlı Algılayıcılar	28
2.3.2 Oto Kodlayıcı	31

2.4	Özellik Mühendisliği	35
2.5	Model Performanslarının Değerlendirilmesi	40

ÜÇÜNCÜ BÖLÜM

ARIZA TEŞHİSİ

3.1	Arıza Teşhisinin Genel Çerçevesi	43
3.2	Titreşim Verisi ile Arıza Teşhisi	48
3.3	Arıza Teşhisinde Makine Öğrenmesi Temelli Yaklaşım	51
3.4	Arıza Teşhisinde Derin Öğrenme Temelli Yaklaşım	56

DÖRDÜNCÜ BÖLÜM

GELİŞTİRİLEN MODELİN RULMAN ARIZA TEŞHİS DENEY SETİ İLE TEST EDİLMESİ

4.1	Rulman Deney Verisi	61
4.2	Oluşturulan Modelin Uygulanması	65
4.3	Modelin Sonuçları	71

BEŞİNCİ BÖLÜM

CNC MAKİNESİ İÇİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE ARIZA TEŞHİS VE KESTİRİMCİ BAKIM UYGULAMASI

5.1	CNC Makinelerinin Genel Yapısı	76
5.2	Deney Seti ve Sensör Seçimi	79
5.3	Verilerin Elde Edilmesi	84
5.4	DeneySEL Sonuçlar	87
5.5	Modelin Sonuçları	90

SONUÇ	94
--------------------	----

KAYNAKÇA	98
-----------------------	----

TEŞEKKÜR	114
-----------------------	-----

ÖZGEÇMİŞ	115
-----------------------	-----

TABLÖLER LİSTESİ

Tablo 1: Genel İstatistikî Özellikler	39
Tablo 2: Karışıklık Matrisi Örneği.....	40
Tablo 3: 0 HP Motor Yüğü, 1797 dev/dak Altındaki Örnek Dağılımı	63
Tablo 4: 1 HP Motor Yüğü 1772 dev/dak Altındaki Örnek Dağılımı	63
Tablo 5: Yığılmış seyrek oto kodlayıcı modelinin parametreleri	66
Tablo 6: 0 HP Motor Yüğü, 1797 dev/dak için çıkarılan istatistiksel özelliklerin karşılaştırılması	67
Tablo 7: 1 HP Motor Yüğü 1772 dev/dak için çıkarılan istatistiksel özelliklerin karşılaştırılması	68
Tablo 8: 0 HP Motor Yüğü, 1797 dev/dak için değerlendirme sonuçları	72
Tablo 9: 0 HP 1797 dev/dak için karışıklık matrisi	73
Tablo 10: 1 HP 1772 dev/dak için değerlendirme sonuçları	74
Tablo 11: 1 HP 1772 dev/dak için karışıklık matrisi	75
Tablo 12: Arduinio ve Raspberry Pi özellikleri	85
Tablo 13: 1400 dev/dak Altındaki Örnek Dağılımı	88
Tablo 14: Yığılmış seyrek oto kodlayıcı model parametreleri.....	88
Tablo 15: 1400 dev/dak Altındaki Örnek Dağılımı için çıkarılan istatistiksel özelliklerin karşılaştırılması	89
Tablo 16: CNC Arıza Teşhis Modeli Doğruluk Oranları.....	91
Tablo 17: CNC Arıza Teşhis Modeli Karışıklık Matrisi.....	92
Tablo 18: CNC Arıza Teşhis Modeli AUC-ROC Eğrisi.....	93

ŞEKİLLER LİSTESİ

Şekil 1: Karar Ağacı Yapısı Örneği.....	18
Şekil 2: DVM Hiper Düzlem Yapısı (Lu ve Wang, 2014, s.138)	19
Şekil 3: K-en yakın komşu örneği	22
Şekil 4: Yapay Sinir Ağının Genel Yapısı.....	29
Şekil 5: İki Gizli Katmanlı Derin Sinir Ağı Yapısı	31
Şekil 6: Oto Kodlayıcının Yapısı.....	32
Şekil 7: Titreşim Tabanlı Arıza Teşhisinin Genel Yapısı.....	51
Şekil 8: Makine Öğrenmesi Tabanlı Arıza Teşhis Modelinin Genel Yapısı	53
Şekil 9: Arıza Teşhisi Yapısı (a)Makine Öğrenmesi (b) Derin Öğrenme	57
Şekil 10: Test Düzeneği (Case Western Reserve University, 2011).	62
Şekil 11: 0 HP Motor Yüğü, 1797 dev/dak için zaman etki alanı titreşim sinyalleri	64
Şekil 12: 1 HP Motor Yüğü 1772 dev/dak için zaman etki alanı titreşim sinyalleri	65
Şekil 13: Önerilen Arıza Teşhis Modeli	69
Şekil 14: YSOK modeli	70
Şekil 15: İstatistiksel özellikler kullanılarak oluşturulan DSA yapısı	71
Şekil 16: Arıza Teşhisi Yapılan CNC Makinesi.....	80
Şekil 17: Titreşim Sensörünün Sabitlendiği Yer	81
Şekil 18: ADXL 345 İvme Ölçer.....	83
Şekil 19: Mini Bilgisayar (Raspberry Pi)	85
Şekil 20: Hazırlanan sistemin genel yapısı.....	86
Şekil 21: 1400 dev/dak için zaman etki alanı titreşim sinyalleri	87

KISALTMALAR

AE: Akustik Emisyon
AMD: Ampirik Mod Ayrışması
AUC: Area Under the ROC Curve
BBA: Bağımsız Bileşen Analizi
BİT: Bilgi ve İletişim Teknolojileri
CNC: Computer Numerical Control
DBM: Derin Boltzmann Makineleri
DD: Dalgacık Dönüşümü
DDA: Doğrusal Diskriminant Analizi
DSA: Derin Sinir Ağları
DİA: Derin İnanç Ağı
DVM: Destek Vektör Makineleri
GA: Genetik Algoritma
HFD: Hızlı Fourier Dönüşümü
KSFD: Kısa Süreli Fourier Dönüşümü
MEMS: Mikro Elektronik Mekanik Sistem
NC: Numerical Control
OK: Oto Kodlayıcı
OYF: Olasılık Yoğunluk Fonksiyonu
RO: Rasgele Orman
ROC: Receiver Operating Characteristics
SB: Spektral Basıklık
SGİ: Stokastik Gradyan İnişi
TBA: Temel Bileşen Analizi
YSA: Yapay Sinir Ağları
YSOK: Yığılmış Seyrek Oto Kodlayıcı
YZ: Yapay Zeka

GİRİŞ

Bilgi ve iletişim teknolojileri (BİT) kullanımı imalat endüstrisinde hızlı bir gelişime neden olmuştur. Bu gelişim mühendislik sistemlerini giderek daha karmaşık ve entegre hale getirmiştir. Günümüz küresel pazardaki üreticiler rekabet güçlerini korumak için maliyetlerini azaltırken ürün kalitesini artırmaya çalışmaktadırlar. Bu sebeple, işletme giderlerinin önemli bir bölümünü oluşturan bakım maliyetlerinde iyileştirmeler yapılması gerekliliği ortaya çıkmıştır. Genel olarak karlılığının birincil planda olduğu işletmelerde, bakım etkinliğinin artırılması finansal tasarruf açısından gereklidir (Eti, Ogaji ve Probert, 2006, s.1236). Yıllık üretilen veri miktarının 1000 Exabaytı aştığı modern endüstride (Yin ve Kaynak, 2015, s.143), iş yapış tarzları yeniden şekillenmektedir.

Endüstride sensör ve nesnelerin interneti kullanımı giderek yaygınlaşmaktadır. Bu yaygınlaşma sonucunda ortaya çıkan yüksek hacim, yüksek hız ve yüksek çeşitlilik ile karakterize edilen büyük üretim verilerinin işlenmesi ihtiyacı ortaya çıkmıştır. Makine öğrenmesi ve derin öğrenme, büyük üretim verilerini işlemek ve analiz etmek için gelişmiş analiz araçları sağlamaktadır (Wang, Ma, Zhang, Gao ve Wu, 2018, s.144). Bu büyük üretim verilerinin bir bölümünü de üretimde kullanılan makinelerden elde edilen veriler oluşturmaktadır. Bu veriler bakım yaklaşımlarına yeni bir bakış açısı getirmiştir.

Etkili bir bakım yöntemi, üretimin kritik operasyonlarını yerine getirmek için karmaşık ve pahalı makinelerin kullanıldığı her işletme açısından önemlidir. Hataları tamamen ortadan kaldırma kabiliyetine sahip olmayan geleneksel bakım stratejileri artık modern endüstrinin gereksinimlerini karşılamamaktadır. Bir şirketin rekabetçi ve sürdürülebilir olması açısından sıfır başarısızlık üretimi kapsamında arıza süresinin ve bakım maliyetinin nasıl azaltılacağı kritik bir konudur. Bu sebeple kestirimci bakım faaliyetlerinin kullanımı yaygınlaşmaktadır.

Kestirimci bakım maliyetlerin azaltılmasına ve tesis kullanılabilirliğinin artmasına katkı sağlar (Carnero, 2005, s.539). Kestirimci bakımın temel amacı, toplanan veriler aracılığıyla ekipman sağlığını değerlendirme, mevcut veya gelecekteki arızalar için detaylı bilgi edinmektir. Bu veriler ile uygulanabilecek yaklaşımlardan birincisi olan arıza teşhisi, belirli bileşenlerin ve performansın mevcut bozulmalarını tespit etmeyi ve tanımlamayı sağlamaktadır. İkinci yaklaşım olan hata prognozu ise, ekipmanın yaklaşan

ve potansiyel çıkabilecek arızalarını tanımlamak ve tahmin etmek için kullanılmaktadır (Zhang, Yang ve Wang, 2019, s.2225).

Kestirimci bakım yönteminin uygulanabilmesi için üç temel gereksinim bulunmaktadır. İlk olarak uygulanacak ekipmanın çalışma koşullarını temsil edebilecek büyük veriye erişimin sağlanması gerekmektedir. İkinci olarak, elde edilen verilerin arıza teşhis ve prognoz için entegre edilerek kullanma becerisi gerekmektedir. Son olarak mevcut ve potansiyel arızaların doğru olarak tespit ve teşhisini yapabilecek veri odaklı modellerinin oluşturulması gerekmektedir.

Sensör ağlarının ve bilgi işlem sistemlerinin önemli gelişimi ile veri odaklı makine sağlığı izleme modellerine olan ilgi giderek artmaktadır. Veri odaklı makine sağlığı izleme modellerinde, büyük verilerden uygun kararlar almak için makine öğrenmesi tekniklerini güçlü bir çözüm olarak kabul edilmiştir. Makine öğrenmesinin yeni ve gelişen alanı derin öğrenme, büyük makine verilerini ve akıllı makine sağlığı izlemeyi birleştiren bir yapıdadır (Zhao ve diğ., 2019, s.214).

Titreşim analizi, makinelerin operasyonel durumlarını izlemek için kullanılan bir tekniktir (Renwick ve Babson, 1985, s.324; Peng ve Kessissoglou, 2003, s.1221). Dönen makinelerde titreşim izleme ve analizi makinelerde oluşan anormallikler hakkında önemli bilgiler sağlar. Bakım planlaması için bu bilgiler kaynak oluşturmaktadır (Orhan, Aktürk ve Celik, 2006, s.293; Safizadeh ve Latifi, 2014, s.1). Titreşimlerin oluşturduğu desenler arıza başlangıcında değişiklik gösterir. Titreşim analizi makinenin durumunu belirlemek açısından son yıllarda hızla gelişmiş farklı teknikleri barındıran bir alandır (Henriquez, Alonso, Ferrer ve Travieso, 2014, s.643).

Arıza teşhisi genel olarak; veri toplama, örneklerin ön işlenmesi, özelliklerin çıkarılması ve sınıflandırma olmak üzere dört adımdan oluşmaktadır. Makine öğrenmesi yöntemleri için özellik çıkarma aşamasında; zaman, frekans ve zaman-frekans alanından özellikler çıkarılır. Derin öğrenme yöntemleri için de özellik çıkarma aşamasında çoğu çalışmada ham veriler direkt olarak modelde kullanılmamıştır. Wang, Mo, Zhang ve Miao (2019) zaman-frekans görüntüsüne dayalı olarak arıza teşhisi için bir derin öğrenme yöntemi önermişlerdir. Junbo, Weining, Juneng ve Xueqian (2015), titreşim sinyallerini işlemek için dalgacık dönüşümü ve doğrusal olmayan yumuşak eşik yöntemini kullanarak önceden işlenmiş sinyal üzerinde otomatik kodlayıcıyı uygulamışlardır.

Oto kodlayıcıya dayalı derin sinir ağlarının katmanlar halinde ön eğitimi, makine verilerinin karakterize edilmesine katkı sağlamaktadır (Zhao ve diğ, 2019, s.221). Sınıflandırma için kullanılacak özellikler otomatik olarak öğrenilmektedir. İnsan bilgisine duyulan ihtiyacı ve ön bilgi gereksinimini azaltmaktadır (Lu, Wang, Qin ve Ma, 2017, s.378). Chen, Zeng, Li ve Liao (2016), ham verileri derin inanç ağı (DIA) tabanlı softmax sınıflandırıcı ile ham verileri doğrudan kullanarak arıza teşhisinde başarılı sonuçlar almışlardır. Endüstride kullanılan hepsi birbirinden farklı ve kompleks yapıda olan makineler hakkında uzmanlığa sahip olmadan sensörlerden toplanan veriler ile arıza teşhis sistemi oluşturulması mümkün kılınabilmektedir.

Arıza teşhis için başa çıkılması gereken sorunlardan bir diğeri de yüksek boyutlu ve doğrusal olmayan verinin nasıl kullanılacağıdır. Daha fazla veri, daha fazla bilgi çıkarmak açısından avantaj gibi görülsede, etkili bir şekilde kullanımı zordur. Bu problemin üstesinden gelmenin bir yöntemi boyut azaltmadır. Boyutsal küçültmede amaç yüksek boyutlu verilerin daha küçük bir temsilini elde etmektir. (Wang, Zheng, Zhao ve Wang, 2015, s.16226). Yüksek boyutlu verilerin sınıflandırılması ve depolanması daha kolay hale gelmektedir(Hinton ve Salakhutdinov, 2006, s.504). Oto kodlayıcı ile verinin daha iyi temsili elde edilebilirken boyut da küçültülebilmektedir (Khan ve Yairi, 2018, s.253).

Literatürdeki çalışmaların pek çoğunda arıza teşhis için laboratuvar ortamında oluşturulan yapay arızalar kullanılmıştır. Bu çalışmaların genelinde rulman arızaları ele alınmıştır. Bu çalışmada farklı olarak, bir işletmede üretim aşamasında kullanılan CNC makinesinden toplanan veriler ile bindirme hatasının teşhisi ve sınıflandırılması yapılmıştır.

Bu tez kapsamında, makine öğrenmesi ve derin öğrenme yöntemleri ile titreşim analizi tabanlı arıza teşhis ve kestirimci bakım sistemi tasarımı oluşturulması amaçlanmıştır. Geliştirilen sistem ile uzmanlık bilgisi gerektirmeden derin öğrenme yöntemlerinin özellik çıkarma yöntemleri kullanılarak, veri odaklı hata teşhisi modellerinin başarılı sonuçlar verebildiği gösterilmiştir. Derin öğrenmenin denetimsiz öğrenme için kullanılan oto kodlayıcının boyut azaltma özelliği kullanılarak yüksek boyutlu ham titreşim verilerinin boyutu azaltılarak önerdiğimiz modelde doğrudan kullanılmıştır.

Sistemde gerek zamanlı durum izleme iin, mikro elektromekanik sistem (MEMS) sensr ve mini bilgisayar kullanılarak srekli veri kaydı yapısı tasarlanmıřtır. Sistemde toplanan veriler ile veri odaklı hata teřhis modeli bu veriler ile test edilmiřtir. Ayrıca bu tez kapsamında, dřk bteli mini bilgisayar ve sensr teknolojileri ile iřletme iinde kestirimci bakım uygulamalarının yapılabilirliėi arařtırılmıřtır.

Bilgi iřleme ve yapay zeka alanının hızlı geliřimi, Endstri 4.0 yaklařımı ve derin ėrenme teknikleri ile birlikte kestirimci bakım iin de yeni bir dnem bařlamıřtır. Bu amala bařlangı noktası olarak kapsamlı bir inceleme yapıldıktan sonra arařtırmacılara veya uygulayıcılara Endstri 4.0 kapsamında kestirimci bakım iin uygulanan tm yaklařımlara dair daha geniř bakıř aısı saėlanması hedeflenmiřtir. Makine ėrenmesi ve derin ėrenme temelli arıza teřhisi zerine sistematik bir arařtırma yapılarak stnlkleri ve zayıflıkları ortaya konulmuřtur. Bu durum tez iin uygun yntemlerin seilmesi aısından rehberlik saėlamıřtır. Tezde seilen hazır veri seti zerinde derin ėrenme ve makine ėrenmesi odaklı arıza teřhisi uygulamaları sonularıyla birlikte sunulmuřtur.

Tez beř blmden oluřmaktadır. Birinci blmde  temel bakım tr detaylı olarak anlatılmıřtır. İkinci blmde tezde kullanılan metodolojileri ieren makine ėrenmesi ve derin ėrenme yaklařımları incelenmiřtir. nc blmde kestirimci bakım uygulamalarının makine ėrenmesi ve derin ėrenmeye dayalı alıřmaları literatr kapsamında ortaya konulmuřtur. Drdnc blmde ise deneysel veri seti zerinde seilen yntemler uygulanmıř ve sonuları aıklanmıřtır. Beřinci blmde belirlenen bir CNC makinesinin titreřim verilerini toplamak iin tasarlanan sistem tanıtıldıktan sonra, toplanan veriler zerinde, derin ėrenme ve makine ėrenmesi yntemlerinin uygulanabilirliėi tartıřılmıřtır. Son blmde tez sonuları ve arařtırma nerileri sunulmuřtur.

BİRİNCİ BÖLÜM

BAKIM YAKLAŞIMLARI

Bakım üretim yönetiminin önemli bir bileşenidir. Bakımları etkili yapılan makineler bakım maliyetlerini azaltırken üretim kapasitesinin artmasını sağlamaktadır. Bakım maliyetleri aşağıdaki şekilde gruplanabilir:

- Değiştirilen yedek parçadan kaynaklanan maliyet.
- Bakım işçilik maliyeti.
- Makinenin çalışmaması, makinenin boşa olması veya kullanılmamasından kaynaklanan maliyet.
- Arızalı makine tarafından üretilen kötü kalitede ürün.

Pintelon ve Gelders (1992)'e göre bakım, ekipmanı belirli bir çalışma durumuna geri getirmek veya çalışır halde tutmak için yapılması gereken tüm faaliyetleri kapsamaktadır.

Susto, Schirru, Pampuri, McLoone ve Beghi (2014) bakım yöntemlerini düzeltici bakım, önleyici bakım ve kestirimci bakım olmak üzere üç kategoriye ayırmışlardır. Wang, Chu ve Wu (2007) çalışmalarında dört bakım yönteminden (düzeltici, zaman bazlı önleyici bakım, duruma dayalı bakım ve kestirimci bakım) bahsetmişlerdir fakat literatürde duruma dayalı bakım ile kestirimci bakımın birbirinin yerine geçen iki terim olduğunu ifade etmişlerdir.

Bakımın amacı ekipmanın ömrünü uzatmak veya en azından onarımı maliyetli olabilecek bir sonraki arızaya kadar geçen ortalama süreyi uzatmaktır. Ayrıca etkili bakım politikalarının, hizmet kesintilerinin sıklığını ve bu kesintilerin istenmeyen sonuçlarını azaltması beklenmektedir (Endrenyi ve diğ., 2001, s.638).

Bakım; bakım için ayrılan çalışma saatlerini, doğrudan yedek parça, bakım araçları ve envanterde yedek parça tutma maliyetlerini içerir. İşletmeler kendileri için optimum bakım yönetimini planlamalıdır. Kestirimci bakım düzeltici bakımın beklenmeyen yüksek maliyetleri ile önleyici bakımın gereksiz bakım maliyetlerini ortadan kaldırabilecek bir alternatif sunmaktadır. Kestirimci bakım, sistemi önceden uyarmak ve düzeltici bakım gerekip gerekmediğini belirlemek için ekipmanın gerçek

durumunu izlemek üzere tasarlanmıştır. Arıza teşhis ve durum izleme bu yöntemin kritik bileşenleridir (Yu, Dillon, Mostafa, Rahayu ve Liu, 2019, s.183).

Farklı makinelerin farklı bakım stratejileri olabilmektedir. Her işletmenin farklı bakım hedefleri de olabilmektedir. Wang ve diğeleri (2007) bu hedefleri güvenlik, maliyet, katma değer ve uygulanabilirlik olarak dörde ayırmışlardır. Kaliteyi tüm süreçler için birincil amaç olarak gören işletmeler gelişmiş üretim teknolojileri, yüksek otomasyon, fazla sayıda bakım personeli kullanmaktadırlar. Bunlar için daha fazla bütçe ayırdıkları da görülmektedir. Bu işletmeler maliyet ve esneklik amaçlayan işletmelere oranla daha proaktif bakım politikalarına, iyi planlama ve kontrol sistemlerine sahiptirler (Pinjala, Pintelon ve Vereecke, 2006, s.214).

Karmaşık ve hızla genişleyen endüstrilerde makinelerin genel verimliliğinde bakımın önemli rolünün kabul edilmesiyle mevcut çabalar; bakımdaki maliyetleri ve teslim sürelerini azaltmaya, hizmet kalitesini iyileştirmeye, sistemlerin güvenilirliğini artırmaya yönelmektedir.

Endüstri 4.0 ile daha önceki yıllara oranla daha büyük ölçekte ekipman verisi sağlayan sensör ve kablosuz iletişim teknolojilerindeki gelişmeler bakıma olan bakışı değiştirmiştir. Toplanan veriler doğru bir şekilde analiz edildiğinde ekipman arızalarının hassas bir şekilde tahmin edilebilmesi sağlanmaktadır. Toplam duruş sürelerinin azalması ile genel verimliliğin artması işletmelerin karlarının artırılmasını sağlayabilmektedir.

1.1 Düzeltici Bakım

İnsanlığın en basit makineleri kullanmaya başlamasıyla birlikte arızalanan bir parçanın onarılması veya değiştirilmesi gerçekleştirilen bir eylemdir. Basit makinelere arızalandığı veya işlevini yitirdiği zaman müdahale edilirdi.

En eski bakım tekniği temel olarak sadece arızalardan sonra yapılan bakımdır. Bu bakım türüne planlanmamış bakım veya arıza bakım da denilmektedir (Jardine, Lin ve Banjevic, 2006, s.1484).

Makinenin arızalanana kadar çalışması mantığına dayanan bu yaklaşımda bakım süreci arıza oluştuktan sonra başlamaktadır. Gerekli bakım veya parça değişikliği yapıldıktan sonra bir sonraki arızaya kadar bakım yapılmaması prensibine dayanmaktadır. Düzeltici bakımın amacı, makinenin en kısa süre içerisinde işlevini yerine

getirebilecek hale döndürülmesidir. İlkel bir bakım yöntemi olarak kabul edilen düzeltici bakım beklenmeyen arızaların neden olduğu kayıpları dikkate almamaktadır.

Bu bakım metodu genellikle ilgili tesislerde, personelde ve çevrede ciddi hasara neden olabilmektedir. Artan küresel rekabet ve küçük kar marjları bakım yöneticilerini daha etkili ve güvenilir bakım stratejileri uygulamaya zorlamaktadır (Wang ve diğ., 2007, s.153).

Düzeltilici bakım, ucuz ve kritik öneme sahip olmayan makineler için doğru yaklaşım olabilmektedir. Arızaların sonuçları ağır değilse, güvenlik riski yoksa ve onarım hızlı bir şekilde gerçekleştirilebiliyorsa bu bakım yöntemi kullanılabilir. Modern endüstriyel imalat alanlarında bu koşulları sağlayan basit makinelerin yerini teknoloji yoğun makineler almıştır. Bu bakım yönteminde arızanın büyüklüğü ve zamanı bilinmediği için belirsizlik çok fazladır. Bakım maliyetleri genellikle daha yüksektir ve kesinti olayları aşağıdaki nedenlerden dolayı genellikle daha sık ve uzun süreli gerçekleşmektedir.

- Kriz durumunda ekipmanın çalışır duruma getirilmesinin yüksek maliyeti,
- Arıza nedeniyle ikincil hasar ve güvenlik / sağlık tehlikeleri
- Kayıp üretim ile ilgili maliyet (Niu, 2017, s.4).

1.2 Önleyici Bakım

Belirli bir takvim veya makinenin çalışma zamanına göre bakım periyodunun belirlendiği, yaygın olarak kullanılan bir bakım stratejisidir. Makine parçalarının düzenli olarak değiştirilmesi temeline dayanır. Ancak ek işletim maliyetleri ile kullanım ömrü dolmadan parça değişimine sebep olabilmektedir.

Birçok sistemin bileşeni zamanla bozulma eğilimine girer ve sonunda sistem arızasına neden olur. Önleyici bakım, bozulma sürecini yavaşlatmak ve sistem ömrünü uzatmak için kullanılmaktadır (Canfield, 1986, s.78). Mal üretiminde ve hizmet sunumunda kullanılan sistemler, endüstrinin sermayesinin büyük çoğunluğunu oluşturmaktadır. Bu sistemler kullanım ve yaşla birlikte bozulmaya başlar. Sistemin bozulması genellikle yüksek üretim maliyetlerine ve daha düşük ürün kalitesine neden olur. İyi kaliteyi korurken üretim maliyetlerini düşük tutmak için sistemlerde önleyici bakım uygulanmaktadır (Valdez-Flores, Feldman, 1989, s.419).

Bu bakım türü, planlanmamış düzeltici bakım ihtiyacını ortadan kaldırarak arızaları azaltmayı amaçlamaktadır. Ekipmanın güvenilirliğini ve kullanılabilirliğini artırmayı hedeflemektedir. Önleyici bakımın amacı sorunların, arızaların önlenmesi ve hataların ortaya çıkmadan önce düzeltilmesidir (De Faria, Costa ve Olivas, 2015, s.203).

Önleyici bakımda, arızalardan kaçınılabilmesi ve arızalardan kaynaklanabilecek herhangi bir sorunun azaltılması için bakım, arızalardan önce gerçekleştirilir. Ayarlamalar, değiştirmeler, yenilemeler ve denetimler iyi hesaplanmış planlama ve programa göre düzenlenir. Makine periyodik olarak kontrol edilir ve uygun parçalar sabit bir zaman çizelgesine göre değiştirilir.

Ekipmanın artan bir arıza oranı sergilediği ve arıza oluşmasının maliyetinin yüksek olduğu durumlarda arızadan önce bakım yapılması avantajlı olabilmektedir. Uygun bir değişim planı yapmak önemlidir (McCall, 1965, s.496). Bu yöntemle yöneticiler, makineleri bozulmalara karşı korumaya almış olurlar. Önceden belirlenmiş aralıklarla ve kriterlere göre yapılan önleyici bakım, bir bileşenin arıza veya bozulma olasılığını azaltmayı amaçlamaktadır. Bu bakım türü, arıza sayısını en aza indirerek planlanmamış düzeltici bakım gerekliliğinden kaçınır.

Önleyici bakımla arızalardan kaçınılabilme avantajı kazanırken ekipman parçalarının erken değiştirilmesi olumsuzluğu da yaşanabilir. Bununla birlikte rastgele gerçekleşebilecek büyük bir arızanın ortaya çıkma olasılığını tamamen ortadan kaldırmamaktadır. Ek olarak bakım maliyetleri artarken gereksiz bakım performansı gerçekleştirilir.

Önleyici bakımın fazla yapılması, yüksek bakım maliyetlerine yol açabilir ve çok sık planlanan bakım aralıkları kapasite eksikliğine neden olabilir. Önleyici bakım yapılmaması ise planlanmayan arıza süreleri nedeniyle bakımla ilgili yüksek maliyetlere yol açabilir (Pintelon ve Gelders, 1992, 308).

Bu yöntemin avantajı, çoğu bakımın önceden iyi planlanabilmesi ve yıkıcı başarısızlığın büyük ölçüde azaltılmasıdır. Bu bakım stratejisinin dezavantajı, varlıkların fiili durumuna bakılmaksızın bakım işlemlerinin gerçekleştirilmesidir. Parçaların kullanım ömürleri sona ermeden önce değiştirilmesi veya onarılması bakım maliyetlerini arttırmaktadır. Modern sanayi sistemlerinin karmaşıklığı, güvenilirlik ve ürün kalitesi beklentisi bu maliyetleri daha da artırmıştır.

Bu bakım ile az sayıda öngörülemeyen hatanın oluşabilmesine ek olarak çok fazla bakım yapılması ve aşırı sayıda yedek bileşenin tüketilmesidir (Randall,2011,s.2). Bu bakım faaliyetleri yapılırken üretim için ayrılan zaman kullanılmış olur. Buna karşın arıza göz ardı edilerek üretim için bakımın geciktirilmesi makine arızasının olasılığını artırabilir (Cassady, Kutanoglu, 2005, s.304).

Toplam maliyeti en aza indirerek, kullanılabilirliği en üst düzeye çıkararak ve diğer hedefleri optimize ederek önleyici bakım politikaları belirlenmelidir (Sim ve Endrenyi, 1988, s.92). Günümüzde, çoğu imalat sanayisinde önleyici bakım uygulanmaktadır. Ekipman performansını kaybettikten sonra bakım müdahaleleri yerine ekipmanın ortalama veya beklenen yaşam istatistiklerine bağlı olarak bakım yapılmaktadır. Programlı bakım yaklaşımı arızaları önleyebilse de kaynakların verimsiz kullanılmasına neden olan gereksiz düzeltici eylemler gerçekleştirebilmektedir (Yu ve diğ., 2019, s.183).

1.3 Kestirimci Bakım

Modern üretim teknolojilerinin gelişmesiyle birlikte yeni mühendislik sistemleri gittikçe daha karmaşık ve entegre hale gelmiştir. Çeşitli bileşenler ve alt sistemlerin birlikte çalışabildiği ortamlarda bir arıza meydana geldiğinde, sonuçların ve nedenlerin olabildiğince hızlı bir şekilde tanımlanması ve buna uygun bakım önlemlerinin alınması kritik önem taşımaktadır. Beklenmedik arızalar işletmeler açısından yıkıcı bir kazaya ve mali kayıplara neden olabilmektedir.

Kestirimci bakım yöntemlerinin ilk uygulamalarından olan görsel inceleme; sinir ağları, bulanık mantık ve makine öğrenmesi gibi desen tanımaya dayalı yöntemlere dönüşmüştür. Bu sebeple, sensörler kestirimci bakım için önemli hale gelmiştir (Hashemian, 2010, s.226).

Ekipman arızalanmaya başladığında arıza öncüllerini algılamak için keskin gözler, kulaklar ve burunlar işaretleri fark edebilmektedir. Ekipman bozulmalarının ve arızalarının başlangıcını belirlemek için günümüzde keskin gözlerin, kulakların ve burunların yerini sensörler almıştır. Nesnelerin interneti konusunda farkındalık arttıkça fiziksel nesneleri birbirleriyle bağlamak için daha fazla seçenek ortaya çıkmakta, sensör verileri ve raporlar gibi nesne ile ilgili bilgilere erişim mümkün olmaktadır. Ortaya çıkan

veri, birçok şekilde olasılıkları ortaya koymaktadır. Veriler kullanılarak gelecekteki arızalar ortaya çıkmadan önce teşhis edilir, böylece bakım işlemlerinin planmasını sağlanmaktadır.

Arızaların oluşarak ciddi problemlere yol açmaması bakımından erken tahmin ve teşhis yeteneği endüstriler için belirleyici ve zorunlu hale gelmiştir (Henriquez ve diğ., 2014, s.642). Kestirimci bakım stratejisi herhangi bir endüstriyel sisteme veya ekipmana uygulanabilmektedir. Kestirimci bakımın amacı, makinelerin sağlık durumunu izlerken yeni başlayan arızaların teşhis edilmesini sağlamaktır (Garcia, Sanz-Bobi, Del Pico, 2006, s.553).

Kestirimci bakım sadece arıza önlemenin yanında verimli çalışma, gelişmiş güvenlik, ürün kalitesi, güvenilirlik, kullanılabilirlik ve enerji maliyetinde azalmayı amaçlamaktadır. Bu nedenle aşırı bakım ve yetersiz bakımdan kaçınmayı amaçlar (Selçuk, 2017, s.2).

Kestirimci bakım uygulaması iki şekilde formüle edilebilir. Birincisi, ekipman bozulmadan önce makineye ait geçmiş sağlık verilerinin kullanılarak kestirimci bakımı sınıflandırma problemi olarak formüle edilmesidir. İkincisi, bir sonraki başarısızlığın meydana geleceği zamanın tahmin edilmesini sağlayan regresyon probleminin formüle edilmesidir.

Arıza teşhisinin kestirimci bakıma katkısı, sorunların ortaya çıktıktan sonra çözülmesi yerine arıza ortaya çıkmadan çözülüp maliyete önemli ölçüde katkı vermesidir (Liu, Logan, Cartes ve Srivastava, 2007, s.1613). İyi bir kestirimci bakım stratejisi, düzeltici bakımın uygun şekilde planlanmasını sağlar ve beklenmedik ekipman arızalarını önler. Hangi ekipmanın bakıma ihtiyacı olduğu bilinerek bakım işleri daha iyi planlanabilir (yedek parçalar, insanlar vb.). Plansız duruş sürelerini azaltmaya ve daha kısa arıza sürelerine ulaşmaya yardımcı olur, böylece ekipman kullanılabilirliğini artırır. Kestirimci bakım; uzun ekipman ömrü, yüksek tesis güvenliği, az kaza ve optimize edilmiş yedek parça kullanımı avantajlarını da sağlar (Butte, Prashanth ve Patil, 2018, s.1).

Kestirimci bakım, kilit bileşenlerin sağlık durumlarının değerlendirilmesi noktasında öngörülebilirliği erişir kılmaktadır. Ekipmanın durumu sağlıklı bir şekilde izlendiğinde bakım zamanları daha net tahmin edilebilir. Kestirimci bakımla düzeltici ve önleyici bakıma göre maliyet tasarrufu avantajı sunulur.

Kestirimci bakımın işletme içerisinde uygulanması noktasında aşağıdaki hususlara dikkat edilmesi gerekmektedir (Selçuk, 2017, s.6):

- İzlenecek bileşenin belirlenmesi
- Bozulmayı gösteren parametrelerin belirlenmesi
- Uygun kestirimci bakım yönteminin belirlenmesi (titreşim, sıcaklık, akustik ses, görsel vb.)
- Sensör yerinin belirlenmesi
- Her değişken için kritik eşiklerin belirlenmesi
- Kontrol aralığının belirlenmesi (Sürekli, koşul temelli aralıklarla uzman görüşleri veya geçmiş verilere dayanarak)
- Uygun bilgisayarlı bakım yönetim sisteminin belirlenmesi

Diğer bakım stratejileri ile karşılaştırıldığında, kestirimci bakımın üstünlükleri bulunmaktadır. Bu avantajlar ekipmanın kullanım ve işletim süresini en üst düzeye çıkarmak, bakım faaliyetlerini geciktirmek / azaltmak, malzeme ve işçilik maliyetlerini azaltmak olarak sıralanabilir (Carvalho ve diğ., 2019, s.2). Bu bakış açısıyla ekipman yaklaşan arızalardan veya arıza başlangıcından önce kapatılır. Ekipmanın bakımı için harcanan toplam süre bu sayede azaltılır. Yıkıcı hasarı önleyerek bakım maliyetleri azaltılır. Makinelerin kullanılabilirliğini ve güvenilirliği artırılır. Ekipman ve süreçlerin ömrünün uzatılması sağlanır.

Bununla birlikte kestirimci bakım aşağıdaki gibi çeşitli zorluklarla karşı karşıyadır:

- Veri elde etme ve veri kalitesi: Verileri elde etmek için kullanılan sensör ve benzeri cihazların güvenilirliği veri kalitesi ile doğrudan ilişkilidir. Bu veri kaynakları genellikle heterojen bir ortamda çalıştığı için sistemler arasındaki entegrasyon problemli olabilmektedir.
- Endüstriyel büyük veri ile başa çıkma: Farklı kaynaklardan gelen farklı veri türlerini işletmenin amaçları doğrultusunda kullanabilme becerisi gerekmektedir. Büyük veri kümelerini depolayacak altyapıya ve depolandıktan sonra kullanabilme esnekliğine sahip olunması gerekir.

- Kestirimci bakımın doğruluğu: Doğru tahmin edilemeyen arıza sonucunda oluşan gereksiz bakım veya beklenmedik makine arızası, üretim kesintilerine yol açılabilir.

Bilgisayar, sensör ve sinyal işleme teknolojilerinin hızlı gelişimi ve yapay zeka (YZ) teknikleriyle arıza teşhisi ve prognozu etkili bir şekilde uygulanabilmektedir. Makine öğrenmesi ile birlikte modellenen kestirimci bakım uygulanırken ele alınması gereken parametreler bulunmaktadır. Sensörlerin dış etkenlerden etkilenmesi ölçüm hatalarına neden olabilmektedir. Büyük veri ile birlikte gelen fırsatların yanında zorluklar da vardır. Sensör izleme cihazlarından toplanan verinin hacmi, bilgi çıkarımı konusunda avantaj sağlarken depolama ve işleme konusunda zorluklar çıkarabilmektedir.

Kestirimci bakımda özellik çıkarma veya sinyal analizi için literatürde birçok etkili yöntem bulunmaktadır. Bu yöntemler temel olarak zaman alanı, frekans alanı ve zaman-frekans alanı olmak üzere üç çeşittir. Zaman alanı yönteminin özü, bir dalga formunun analizidir. Frekans alanı analizinde, sinyal belirli bir dönüşüm sonucunda frekansa göre analiz edilir. Sinyaller işlendikten ve özellikler çıkarıldıktan sonraki problem, mevcut arızaların nasıl tespit edileceği ve potansiyel hataların nasıl tahmin edileceğidir. Derin öğrenmenin bu alanda kullanılması, otomatik özellik çıkarma ve yüksek boyutlu verilerde boyut azaltma avantajını da getirmiştir.

İKİNCİ BÖLÜM

MAKİNE ÖĞRENMESİ

Makine öğrenmesi yapay zekanın bir alt dalı olarak tanımlanmaktadır. Yeni öğrenme algoritmalarının geliştirilmesi, çevrimiçi verilerdeki ve işlem gücündeki artış makine öğrenmesi alanının gelişmesini hızlandırmıştır (Jordan ve Mitchell, 2015, s.255).

Makine öğrenmesi, bir girdi vektörü ile bir sonuç arasındaki ilişkiyi belirlemeye çalışır. Makine öğrenmesi, probleme ait verilerden yola çıkarak modelleme işlemi yapmaktadır. Makine öğrenmesi, veriler içindeki kalıpları çıkararak sınıflandırma, kümeleme ve tahmin gibi farklı işlemleri gerçekleştirebilir (Witten, Frank ve Hall, 2005, s.8).

Geleneksel makine öğrenmesi, özellik çıkarma ve model seçimi süreçlerini ayrı şekilde gerçekleştirmektedir. Her süreç adım adım oluşturulmaktadır. Modeli oluşturan bireylerin seçimine göre özelliklerin belirlenmesi uzman alan bilgisi gerektirir. Özellikler ham verilerin farklı bir alana (istatistiksel, frekans ve zaman-frekans alanı vb.) dönüştürülmesiyle elde edilir. Özellikler makine öğrenmesi modeline girmeden önce özelliklerden ilgisiz olanların çıkarılması işlemi yapılır.

Oluşturulan modelin performansı sadece kabul edilen algoritmaların optimizasyonuna bağlı değildir. Aynı zamanda seçilen özelliklerden de büyük ölçüde etkilenir. Genellikle, özellik çıkarma ve seçme zaman alıcı olup büyük ölçüde alan bilgisine bağlıdır (Wang ve diğ., 2018, s.146).

Teknolojinin gelişmesiyle birlikte veriler çok daha rahat toplanabilir ve saklanabilir duruma gelmiştir. Toplanan verilerin büyüklüğü, verileri klasik yöntemlerle analiz etmek noktasında yetersiz kalabilmektedir. Bilgisayarların işlem güçlerinin artmasıyla toplanan bu verilerin işlenmesi kolaylaşmıştır. Bu gelişmeler ışığında makine öğrenmesi çok daha önemli hale gelmeye başlamıştır.

Veriler makine öğrenmesi uygulamalarının en önemli bileşenidir. Verilerden anlamlı bilgi çıkarılmadığı sürece veriler fayda sağlamamaktadır (Ghahramani, 2015, s.452). Büyük boyutta elde edilen veriler ile makine öğrenmesi uygulamaları güvenlik, sağlık, ulaşım ve üretim gibi birçok alanda uygulanmaktadır.

Makine öğrenmesi temel olarak denetimli öğrenme ve denetimsiz öğrenme olarak ikiye ayrılmaktadır.

2.1 Denetimli Öğrenme

Denetimli öğrenmenin temelinde, etiketlenmiş verilerin kullanılarak yeni veriler için tahmin ya da sınıflandırma yapılması bulunmaktadır. Kullanılan verilerde her örnek için giriş ve çıkış nesnesi gerekmektedir. Oluşturulan model bu nesneleri kullanarak girdi ve çıktı arasındaki ilişkiyi öğrenmektedir. Denetimli öğrenme sistemleri genellikle tahminlerini her bir giriş x için y çıktısı üreten öğrenilmiş bir haritalama $f(x)$ modeliyle oluşturur. (Jordan ve Mitchell, 2015, s.257).

Başta derin öğrenme olmak üzere çoğu makine öğrenmesi algoritmalarının çözmeye çalıştığı hedeflerden biri bir çıktıyı tanımlayabilen bir fonksiyonu öğrenmektir. Fonksiyon ile sınıflayıcı özelliklerinin değerlerinin bilindiği ancak sınıf etiketinin değerinin bilinmediği test örneklerine sınıf etiketlerinin doğru bir şekilde atanması amaçlanır (Kotsiantis, Zaharakis ve Pintelas, 2006, s.159).

Denetimli makine öğrenmesi, dışarıdan temin edilen örneklerden genel hipotezler üreterek daha sonra gelecek örnekler hakkında tahminler yapmayı amaçlamaktadır (Kotsiantis, 2007, s.249). Denetimli öğrenme problemleri, sınıflandırma ve regresyon olmak üzere ikiye ayrılmaktadır. İki problem arasındaki fark, bağımlı özelliğin yani çıktı değerinin regresyon için sayısal, sınıflandırma için ise kategorik olmasıdır.

Denetimli öğrenmede geçmişteki her tür veri kullanılır. Eğitimin her verisi sonucu bilinen kayda göre etiketlenir. Ortaya çıkan veri seti, eğitim verileri olarak adlandırılır. Oluşan veri seti bir makine öğrenmesi yöntemi ile işlenir. Bu yöntem, bir veri kaydı ile etiketli çıktı arasındaki ilişkiyi inceler ve sonra veriye dayalı bir model oluşturur. Yeni veriler için öğrenilen verilerle ilişki kurularak en iyi sonuçlar bulunur.

Normal şartlarda bir örneği tam olarak ifade eden öznitelikleriyle sınıf etiketinin de bilindiği varsayılır. Bununla birlikte pratik görevlerde mevcut özellikler örneği açıklayan tüm bilgileri içermeyebilir. Eğitim seti aynı öznitelik değerlerine sahip ancak farklı sınıflardaki örnekleri içerebilir. Ayrıca örnekler hatalı sınıf değerleriyle, hatalı öznitelik değerleriyle veya her ikisiyle birlikte görülebilir. Bu hatalar, bir bilgisayara örnek yazarken ölçüm cihazlarının sınırlamaları ve insan hatası da dahil olmak üzere

çeşitli kaynaklardan ortaya çıkabilir. Tüm bu fenomenlere toplu olarak gürültü denir. Bu durum bir sınıflandırma probleminde ulaşılabilir doğruluğu sınırlandırmaktadır (Pham ve Afify, 2005, s.396).

Farklı algoritmalar farklı veri setlerinin işlenmesi ile ilgili belirli güç ve zayıflıklara sahiptirler. Bir algoritma seçildikten sonra eğitim veri seti kullanılarak eğitilmektedir. Oluşturulan model test verisi ile değerlendirilmektedir.

Test veri seti ile eğitilmiş algoritmanın performansına bağlı olarak parametreler optimize edilir. Temel kural, veri setinin % 70'inin bir eğitim veri seti olarak % 20'sinin, değerlendirme veri seti olarak, (parametreleri ayarlamak için), % 10'unun test verisi olarak kullanılmasıdır (Wuest, Weimer, Irgens ve Thoben, 2016, s.35).

Denetimli öğrenmede kullanılan veri eğitim kümesi, test kümesi ve doğrulama kümesi olmak üzere üç kümeye ayrılmaktadır. Eğitim kümesi seçilen modelin eğitilmesinde kullanılan verilerdir. Test kümesi, modelin performansını belirlemek için ayrılan verilerdir. Doğrulama kümesi ise modelin son halinin performansını değerlendirmek için kullanılan veri parçasıdır. Denetimli öğrenme, eğitim verilerindeki girdiler ve çıktılar arasında net bir harita oluşturur.

Bir bağımlı ve birden fazla bağımsız değişkenden oluşan veri seti üzerinde çalışan sınıflandırma problemi bir öğrenme algoritmasına dayanır. Sınıf etiketi olarak adlandırılan bağımlı değişken bağımsız değişkenlere bağımlıdır. Makine öğrenmesi alanı, bilgisayar programlarının deneyim yoluyla bazı görevlerdeki performanslarını otomatik olarak iyileştirmesini sağlamakla ilgilidir. Makine öğrenmesi üzerine yapılan çok sayıda araştırma, aynı popülasyondan yeni örnekleri doğru bir şekilde kategorize edebilen, önceden etiketlenmiş bir dizi örnekten model geliştirme görevi olan sınıflamaya odaklanmıştır (Pham. Afify, 2005, s.395).

Sınıflandırma günlük yaşamda sıklıkla karşılaşılan karar verme problemlerinden bir tanesidir. Bir sınıflandırma problemi hatalı veya hatasız parçalar, normal veya anormal gibi etiketlerin kategorik olduğu durumdur. Sınıflandırma problemleri işletme, bilim, endüstri ve tıp gibi birçok alanda ele alınmaktadır. Örnekler arasında iflas tahmini, kredi puanlama, tıbbi teşhis, kalite kontrol, el yazısı karakter tanıma ve konuşma tanıma vb. sayılabilir. Bir regresyon problemi ise çıktı değişkeninin gerçek veya sürekli bir değer olduğu durumdur.

2.1.1 Sınıflandırma

Bu bölüm sınıflandırma problemi için en sık kullanılan makine öğrenmesi algoritmalarına genel bakış sağlamaktadır. Her bir algoritma için avantajlar ve dezavantajlar ortaya konulmuştur.

2.1.1.1 Naif Bayes

Naif Bayes, Bayes teoremine dayanan istatistiksel bir sınıflandırma tekniğidir. En basit denetimli öğrenme algoritmalarından birisidir. Naif Bayes en basit öğrenme algoritmalarından biri olmakla beraber bazı durumlarda karmaşık öğrenme algoritmalarından daha iyi sonuçlar verebilmektedir. Bayes teoremine dayanan yöntemde istatistiksel kestirim ile bir sınıfın üyelik olasılığı tahminlemeye çalışılır. En temel özelliği bir sınıftaki belirli bir özelliğin etkisinin diğer özelliklerden bağımsız olduğunu varsaymasıdır. Bu varsayım hesaplamayı basitleştirir. Olasılığı en yüksek olan durum hedef sınıf olarak belirlenir. Amaç $P(C_i|X)$ 'nin maksimum olmasıdır. $X=(x_1, x_2, x_3, \dots)$ veri setindeki örnekler iken $C=(C_1, C_2, C_3, \dots, C_n)$ olmak üzere n adet sınıf bulunduğu varsayılmaktadır. $P(C_i|X)$, X örneğinin i sınıfından olma durumunu ifade eder.

$$P(C_i|X) = \frac{P(X|C_i) P(C_i)}{P(X)}$$

$P(C_i|X)$: X olayı gerçekleştiğinde C_i olayının meydana gelme olasılığı

$P(X|C_i)$: C_i olayı gerçekleştiğinde X olayının meydana gelme olasılığı

$P(C_i)$ ve $P(X)$: Veriden bağımsız olarak C_i ve X olaylarının olasılıklarıdır.

Naif Bayes, verileri hızlı bir şekilde eğitip sınıflandırabilir. Bir sınıfın olasılığı her bir özelliğinin olasılıklarının sonucudur. Bu nedenle ilgisiz özelliklere karşı dirençli olması avantajıdır. Naif Bayes algoritması, sınıflandırma problemleri için yaygın bir yöntemdir. Yüksek verimlilikle kolaylıkla uygulanabilmektedir (Liu, Yang, Zio ve Chen, 2018, s.35).

Bu sınıflandırma algoritmasında her bir değişkenin birbirinden bağımsız ve eşit olduğu varsayılır. Normal koşullarda değişkenlerin tamamen bağımsız olması mümkün olmadığı için bu durum dezavantaj olarak görülmektedir.

Naif Bayes algoritmasının en büyük avantajı eğitim için hesaplama süresinin kısa olmasıdır. Ek olarak model bir ürün biçimine sahip olduğu için önemli hesaplama avantajları doğru sonuçlara dönüştürülebilmektedir (Kotsiantis ve diğ., 2006, s.174).

2.1.1.2 Karar Ağaçları

İlk kez Breiman ve arkadaşları tarafından tanıtılan karar ağaçları popüler bir parametrik olmayan istatistiksel öğrenme yöntemi haline gelmiştir (Breiman, Friedman, Olshen ve Stone,1984). Karar ağaçları algoritmaları kural çıkarma üzerine kurulu güvenilir yöntemlerden birisidir. Yapısı gereği anlaşılması kolay, yapılandırması basit bir yöntemdir. Bir sınıflandırma ya da regresyon problemi için eldeki eğitim setinde bir tane bağımlı nitelik olup diğerleri belirleyici yapıdadır. Bu öznitelikler kategorik ya da sayısal olabilmektedir.


Karar ağaçları, bir dizi basit testi mantıksal olarak birleştiren sıralı modellerdir. Her test, sayısal bir özniteliği bir eşik değeriyle veya nominal bir özniteliği bir dizi olası değerle karşılaştırır (Kotsiantis,2013, s.261). Karar ağaçları yapısı gereği hiyerarşik bir düzen içerir. Hiyerarşideki her bir adım karar düğümü olarak isimlendirilir.

Karar ağacının yapısı düğüm, dal ve yaprak olmak üzere üç terimden oluşur. Ağaçta yaprağın en üst kısmı kök olarak isimlendirilir. Kök ve yapraklar arasındaki kısımlar dal olarak ifade edilir.

Karar ağaçları, örnekleri özellik değerlerine göre sıralayarak sınıflandıran ağaçlardır. Bir karar ağacındaki her düğüm, sınıflandırılacak bir örnekte bir özelliği temsil eder. Her dal, düğümün üstlenebileceği bir değeri temsil eder. Örnekler kök düğümünden başlayarak sınıflandırılır ve özellik değerlerine göre sıralanır (Kotsiantis, 2007, s.251).

Yapılarına bakıldığı zaman tepeden aşağıya doğru inen bir strateji sunmaktadırlar. Bir algoritma açısından iç içe geçmiş “eğer-ise” olarak yorumlanabilecek kuralların bütünü olarak tanımlanabilir. Diğer sınıflandırma algoritmaları ile kıyaslandığında

anlaşılması ve uygulaması kolay bir yöntemdir. Şekil 1’de karar ağacına ait örnek bir yapı verilmiştir.



Şekil 1: Karar Ağacı Yapısı Örneği

Karar ağaçları oluşturulurken kökten itibaren dallamanın hangi kritere göre yapılacağı en önemli problemdir. Karar ağacının karmaşıklığı ağacın doğruluğunun ölçülmesinde etki olmaktadır. Ağaç karmaşıklığı, kullanılan durma kriterleri ve uygulanan budama yöntemi ile dolaylı olarak kontrol edilmektedir. Ağaç karmaşıklığının ölçülmesi için toplam düğüm sayısı, toplam dal sayısı, ağaç derinliği ve kullanılan özniteliklerin sayısı gibi parametreler kullanılır (Breiman ve diğ., 1984).


Yıllar boyunca çok sayıda karar ağacı algoritması (C4.5, CART, SPRINT, SLIQ) geliştirilmiştir (Quinlan, 1993; Breiman ve diğ., 1984; Shafer, Agrawal ve Mehta,1996; Mehta, Agrawal ve Rissanen, 1996).

Karar ağaçları oluşturulurken kullanılan algoritmaya göre ağacın yapısı değişkenlik gösterebilir. İlk düğüm olan kök düğümün farklı olması en uçtaki yaprağa ulaşırken izlenecek yolu farklılaştırarak sınıflandırma sonucunu etkiler.

2.1.1.3 Destek Vektör Makineleri

Vapnik (1995) tarafından geliştirilen, istatistiksel öğrenme teorisine dayanan destek vektör makineleri(DVM) makine öğrenmesi tekniklerinden bir tanesidir. DVM’de amaç, sınıfları birbirinden ayıracak optimal ayırma hiper düzleminin elde edilmesidir. Bu hiper düzlem farklı sınıflara ait destek vektörleri arasındaki mesafeyi maksimize etmeyi amaçlamaktadır (Ayhan ve Erdoğan, 2014, s.179). DVM'nin temel fikri, verileri iki farklı sınıftan ayırmak için en iyi hiper düzlemi bulabilmesidir, böylece iki sınıf arasındaki mesafe, yani kenar boşluğu en üst düzeye çıkar. Bu basit yöntem yalnızca iki doğrusal olarak ayrılabilir sınıf için çalışır. Bunun yanında destek vektör makinelerini doğrusal olmayan durumlarda çalışacak şekilde genişletmek için teknikler vardır.

Verilerin özelliklerine bağlı olarak DVM, farklı çekirdek işlevlerini kullanarak doğrusal veya doğrusal olmayan sınıflamalar yapabilir. Yanlış sınıflandırma hatasını en aza indirmeyi amaçlayan geleneksel eğitim yöntemlerinden farklıdır. Doğrusal hiper düzlem aşağıdaki fonksiyon kullanılarak tasarlanabilir. Burada $x = [x_1, x_2, x_3, \dots, x_k]$ girdi vektörüdür. Şekil 2’de hiper düzlem yapısı gösterilmektedir.



Şekil 2: DVM Hiper Düzlem Yapısı (Lu ve Wang, 2014, s.138)

Destek vektörleri, hiper düzleme en yakın olan veri noktalarıdır. Bu noktalar, kenar boşluklarını hesaplayarak ayırma çizgisinin daha iyi tanımlanmasını sağlar. Hiper düzlem farklı sınıf üyeliklerine sahip bir dizi nesne arasında ayrım yapan karar düzlemidir. Kenar boşluğu en yakın sınıf noktalarında bulunan iki çizgi arasındaki boşluktur. En yakın noktaları desteklemek için çizgiden dikey mesafe olarak hesaplanır. Bu yöntemin amacı, eldeki veri kümesindeki destek vektörleri arasında mümkün olan maksimum kenar boşluğuna sahip hiper düzlem oluşturmaktır.

DVM verileri doğrusal olarak sınıflandıramadığı durumlarda çekirdek hilesine başvurur. Doğrusal olarak ayrılamayan daha genel veri durumuyla başa çıkmak için orijinal veriler, verilerin doğrusal olarak ayrılabilmesinin mümkün olduğu yeni ve daha yüksek boyutlu bir özellik alanına eşlenir. DVM, düşük boyutlu girdi alanını yüksek boyutlu bir alana dönüştürerek ayırma problemi için çözüm üretebilir. DVM iki sınıflı ve çok sınıflı sınıflandırma probleminin çözümü için geliştirilmiş makine öğrenmesi algoritmasıdır.

Eğitim veri setindeki hatayı minimize etmek üzerine kurulu olan klasik öğrenme yaklaşımları deneysel risk minimizasyonu olarak ifade edilir. Sinir ağları bu yaklaşıma bir örnektir. DVM ise istatistiksel öğrenme teorisini benimseyen yapısal risk azaltma ilkesine dayanmaktadır.

DVM doğrusal sınıflandırmayı başarılı bir şekilde yapabilirken doğrusal olmayan sınıflandırma yapma kabiliyetine de sahiptir. Bazı veri setleri, bir hiper düzlemle düzgün bir şekilde iki gruba ayrılmamaktadır. Bu durumda, veriler sınıfların düzgün bir şekilde ayrılabilmediği daha yüksek boyutlu bir özellik alanına taşınır. Doğrusal olmayan durumlar için sigmoid, radyal ve polinom tabanlı çekirdek fonksiyonları uygulanır.

DVM'nin eğitim optimizasyonu sinir ağları gibi diğer arama algoritmalarında meydana gelebilecek yerel bir minimumla bitirmekten kaçınarak, problemi mutlaka küresel bir minimum seviyeye ulaştırmaktadır. Ancak DVM yöntemleri ikiliktir, bu nedenle çok sınıflı bir sorun olması durumunda sorunu bir dizi ikili sınıflandırma problemine indirgenmesi gerekmektedir. Ayrık veriler başka bir sorun oluşturabilmektedir. Uygun yeniden ölçekleme ile iyi sonuçlar elde edilebilmektedir (Kotsiantis ve diğ., 2006, s.177).

2.1.1.4 K-En Yakın Komşu


Sınıflandırma algoritmalarından biri olan K-en yakın komşu yöntemi mesafeye dayalı olarak sınıflandırma yapmaktadır. Bugün halen geçerliliğini koruyan bu yöntem parametrik olmayan sınıflandırıcıların en basiti olarak bilinmektedir. Parametrik olmayan, altta yatan veri dağıtımı için herhangi bir varsayım olmadığı anlamına gelmektedir. Başka bir deyişle model yapısı veri kümesinden belirlenmiştir. Bu, gerçek dünya veri kümelerinin çoğunun matematiksel teorik varsayımları takip etmediği uygulamalarda çok yardımcı olmaktadır. Tembel algoritma olarak isimlendirilen model üretimi için herhangi bir eğitim veri noktasına ihtiyaç duymamaktadır.

Tüm eğitim verileri test aşamasında kullanılmaktadır. Eğitim aşaması hızlı bir şekilde tamamlanırken test aşaması yavaş ve maliyetlidir. Yöntemin tüm veri noktalarını taraması zaman alır ve daha fazla bellek gerektirir. Bu yöntemde ilk gereksinim, sınıf etiketi bilinen verilerin mevcut olmasıdır. Bu veri seti kaynak alınarak yeni örneğin diğer tüm noktalara göre uzaklığı hesaplanır.

K-en yakın komşu sınıflandırmasının en yakın komşuların belirlenmesi ve bu komşuların kullanıldığı sınıfın belirlenmesi olmak üzere iki aşaması vardır (Cunningham ve Delany, 2007, s.1).

Önceden girilen örneklerden oluşan belirli bir girdi vektörünün sınıfını belirlemek için Eukledian mesafesi, Hamming mesafesi veya Manhattan uzaklığı gibi mesafe metrikleri kullanır. K-en yakın komşuda k, en yakın komşu sayısıdır. Bu yöntemde komşu sayısı temel karar faktörüdür. İlk adım olarak örnek nokta olan N_1 'in, sınıf etiketinin tahmin edilmesi gereken nokta olduğu varsayılır. İlk önce N_1 'e en yakın nokta bulunur, daha sonra puanları k komşularının çoğunluk oyuna göre sınıflandırılır. Her nesne kendi sınıfına oy verir ve en çok oy alan sınıf, tahmin edilen sınıftır. Şekil 3 iki sınıftan oluşan bir problemin yapısını göstermektedir. K-en yakın komşu aşağıdaki temel adımları takip etmektedir.

- 1.adım: Mesafeyi hesapla.
- 2.adım: En yakın komşuları bul.
- 3.adım: Sınıf etiketlerine oy ver.



Şekil 3: K-en yakın komşu örneği

K komşu sayısı, model oluşturma sırasında seçilmesi gereken bir hiper parametredir. Uygun komşu sayısı veri kümesinin yapısına göre değişmektedir. Genellikle sınıf sayısı çiftse tek sayı seçilir. Farklı komşu sayıları ile performanslar karşılaştırılabilir. K-en yakın komşu az sayıda özellikle daha iyi performans gösterir.

2.1.2 Regresyon

Regresyon, iki veya daha fazla değişken arasındaki ilişkiye dayanarak çıktı değerlerinin hesaplanması işlemi olarak tanımlanmaktadır. Basit doğrusal regresyon, bağımlı değişken y ile bağımsız değişken x arasındaki ilişkinin tahmin edildiği bir modelleme yaklaşımıdır. Birden fazla bağımsız değişken kullanıldığında model, çoklu doğrusal regresyon modeline dönüşür. Regresyon bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi açıklamaktadır. Bağımlı değişken sayısal olmak zorundadır. Doğrusal regresyon verilen $(x_{i1}, x_{i2}, \dots, x_{ip}, y_i)_{i=1}^n$ bir veri setinde bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi tahminlemeyi amaçlamaktadır. Regresyonun formül olarak gösterimi aşağıda verilmiştir:

$$y = a + bx \text{ veya } y = B_1 + B_2X_2$$

Hipotez sınamalarında ya da ilişkinin istatistiksel olarak anlamlı düzeyde olup olmadığına karar vermek için p (olasılık) değeri kullanılmaktadır. Model sonucu bulunan p değeri < 0.05 ise iki değişken arasındaki ilişki istatistiksel olarak anlamlıdır. P değeri bir karşılaştırmada “istatistiksel olarak anlamlı fark vardır” kararı verilmesini sağlamaktadır. Formüldeki a değeri doğrunun y eksenini kestiği noktayı, b değeri ise eğimin ölçüsünü ifade etmektedir. Regresyon sonucunda bağımsız değişkenlerin bağımlı değişkene etkisini açıklayan en iyi denklem belirlenmektedir. X ekseninde gösterilen bağımsız değişken, Y ekseninde ise tahmin edilen bağımlı değişken gösterilir.

2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, veri etiketlerinin bilinmediği sınıflandırma problemlerinde kullanılmaktadır. Denetimsiz öğrenme, denetimli öğrenmedeki hedef çıktılarına ihtiyaç duymamaktadır. Bu öğrenme yönteminde sadece $(x_1, x_2, \dots, x_n)$ girdileri bulunmaktadır (Ghahramani, 2003, s.73).

Denetimsiz öğrenme, yalnızca girdi verilerinin erişilebilir olduğu, insan rehberliği olmayan bir makine öğrenmesi sürecidir. Denetimsiz öğrenme herhangi bir etiket içermeyen girdilerde öngörülebilirliklerin bulunmasını amaçlamaktadır. Kümeleme problemi bu duruma örnek olarak verilebilir. Kümeleme analizi, ilişkilendirme ölçütlerini kullanarak örnekleri otomatik olarak birkaç grup halinde kümelemek için kullanılır. Verilerin daha iyi anlaşılmasını sağlayan, gizli ilişkilerin ortaya çıkarılmasını amaçlayan öğrenmedir. Geçmiş veriler dahilinde benzer örnek grupları bulunabilir.

2.2.1 Kümeleme

Kümeleme, temel verilerdeki önemli grupları tanımlamayı ve çıkarmayı amaçlamaktadır. Belirli bir kümeleme ölçütüne dayanarak bir kümedeki veri noktalarının farklı kümelerdeki noktalara göre kendi içinde daha benzer olması için gruplandırır (Halkidi, Batistakis, Vazirgiannis, 2001, s.142).

Kümeleme, verilerin gruplara bölünme işlemidir. Kümeleme işleminde sınıflar önceden bilinmemektedir. Verilerin birbirlerine göre uzaklığına bağlı olarak veriler gruplara ayrılmaktadırlar. Kümeleme algoritmaları bölümsel ve hiyerarşik olarak ikiye ayrılmaktadır (Ahmad, Dey, 2007, s.504). Kümelenme problemi, belirli bir veri

kümesindeki homojen veri noktalarının gruplandırılması problemi olarak tanımlanmaktadır. Bu grupların her birine küme denir ve nesnelerin yoğunluğunun diğer bölgelere göre yerel olarak daha yüksek olduğu bir bölge olarak tanımlanmaktadır. Kümeleme belirli bir veri kümesini ayrık alt kümelere bölmeyi amaçlamaktadır (Likas, Vlassis ve Verbeek, 2003, s.451). Veriler arası uzaklıkları ölçmek için Euclidyen, Manhattan, Minkowski ve Cosine gibi uzaklık ölçümleri kullanılabilir. K-means en basit bölümsel algoritmadır.

Bir dizi sayısal nesne X ve bir tam sayı k ($k \leq n$) verildiğinde, K-means algoritması, X 'in k kümeye bölünmesi için kare hatalarının toplamını en aza indirmeyi amaçlamaktadır (Huang, 1998, s.287). K-means algoritması, her bir gözlemin en yakın ortalamaya sahip kümeye ait olduğu n tane gözlemi k kümeye ayırmayı amaçlayan bir küme analizi yöntemidir. K kümelerinin maksimum iç küme benzerliğine sahip olması istenir.

Veri noktaları birbirine ne kadar yakınsa aynı kümeye dahil olma ihtimali o kadar yüksektir. Diğer kümeler içindeki elemanlar ile de minimum benzerliğe sahip olması beklenir. Kümeleme yöntemleri, farklı hata modlarıyla ilgili verilerdeki benzer kalıpları veya kümeleri tanımlayabilir.

K-means algoritması birçok kümeleme uygulamasında kullanılan hızlı bir yinelemeli algoritmadır. Yöntemin ana dezavantajı, küme merkezlerinin başlangıç konumlarına olan duyarlılığında yatmaktadır (Likas ve diğ., 2003, s.452).

Hiyerarşik kümeleme yönteminde küme sayısı baştan belirlenmemektedir. Yöntemin başlangıcında her veri bir küme iken süreç sonunda her veri belirli kümeler altında toplanır. Bu yöntemin sonuçları dendrogramlar ile sunulmaktadır. Dendrogram aracılığıyla değişkenlerin birbirine yakınlıkları görsel şekilde ifade edilmektedir.

2.2.2 Boyut Azaltma

Boyut azaltma, bir veri kümesindeki girdi değişkenlerinin sayısını azaltan teknikleri ifade eder. Sınıflandırma problemlerinde modele dahil edilmesi gereken çok fazla değişken olabilmektedir. Bu değişkenler modelde kullanılacak özellikler olarak tanımlanır. Özellik sayısı arttıkça model üzerinde çalışmak zorlaşabilir. Özelliklerin birbirleriyle yüksek korelasyona sahip olması onların kullanılmasını gereksiz kılabilir.

Boyut azaltma, rastgele deęişkenlerin sayısının azaltılarak temel özelliklerin elde edilmesidir. Bu yüksek boyutlu bir alandaki verileri daha düşük bir boyut aralığına indirir.

Özelliklerin sayısı arttıkça model daha karmaşık hale gelir. Özellik sayısı arttıkça model eğitildięi verilere daha bağımlı hale gelir ve test verileri üzerinde düşük performans sergileyebilir. Eğitim verisinde özellik sayısı azaldıkça model daha basit hale gelir.

Daha az özellik model doğruluğunun performansını artırır. Daha az boyut işlem gücü açısından avantaj sağlar ve modelin eğitim süresi azalır. Daha az veri, daha az depolama alanı ihtiyacı doğurur. Sonuç olarak gereksiz özellikleri ve gürültüyü ortadan kaldırır.

Boyut azaltma genellikle orijinal boyutlu özellik alanının doğrusal bir kombinasyonu olan yeni düşük boyutlu özellik alanı elde etmek için kullanılır. Makine arıza teşhisinde kullanılan en yaygın teknikler arasında temel bileşen analizi (TBA), doğrusal diskriminant analizi (DDA) ve bağımsız bileşen analizi (BBA) yer almaktadır.

TBA, denetimsiz öğrenme yöntemi olarak orijinal özelliklerin doğrusal kombinasyonunu oluşturur. TBA, düşük boyutlu bir özellik vektörü oluşturmak için kullanılır (Wold, Esbensen ve Geladi, 1987, s.37).

Temel bileşen analizi (TBA), yüksek boyutlu veri alanından önemli özelliklerin çıkarılması için en klasik ve iyi bilinen istatistiksel yöntemdir (Zhong ve Enke, 2017, s.127). TBA'nın hedefi, birbiriyle ilişkili çeşitli deęişkenlere sahip olan bir veri kümesinin boyutsallığını azaltmak ve aynı zamanda içerisindeki deęişimi mümkün olduğunca düşürmektir (Jing ve Hou, 2015, s.638). TBA aracılığıyla verilerin boyutsallığı azaltılırken önemsiz bileşenler göz ardı edilir. TBA, verileri artan varyans yönü boyunca döndürür ve yansıtır. Maksimum varyansa sahip özellikler kullanılır.

TBA, veri kümesinin en yüksek varyansını açıklarken kalan kısım daha az bilgilendiricidir. TBA, birçok basit ve doğrusal endüstriyel süreçte kayda deęer bir başarıya ulaşmıştır. Bununla birlikte birçok modern endüstriyel sürecin veri özellikleri aslında daha karmaşıktır (Zhang, Jiang, Li ve Yang, 2018, s.49). TBA, proses izleme, kalite kontrol, sensör ve proses hatası teşhisi gibi çeşitli alanlarda kullanılmıştır (Misra, Yue, Qin ve Ling, 2002, s.1282). Yaygın olarak kullanılan bir boyut küçültme algoritması olarak TBA, bir dizi ilişkisiz deęişken çıkarır ve bunları daha küçük boyutlarda saklar.

Yüksek boyutlara sahip veri kümeleriyle başa çıkmadaki etkinliği ve sadeliği nedeniyle TBA, özellikle veri sıkıştırma için çeşitli alanlarda yaygın olarak uygulanmıştır (Gao ve Hou, 2016, s.907).

2.3 Derin Öğrenme

Derin öğrenme, hiyerarşik mimarilerde birden fazla katmanın desen sınıflandırması ve temsil öğrenimi için kullanıldığı makine öğrenmesi teknikleri sınıfını ifade etmektedir. Günümüzde derin öğrenmenin popüleritesinin üç önemli nedeni; çip işleme yeteneklerinin (ör. GPU birimleri) büyük ölçüde artması, bilgi işlem donanımının önemli ölçüde azaltılmış maliyeti ve makine öğrenmesi, sinyal / bilgi işleme araştırmalarındaki son gelişmelerdir (Deng, 2014, s.2).

Makine öğrenmesinin bir dalı olan derin öğrenme, insan beyninin işleyişinden ilham alan yapısıyla son yıllarda araştırmacıların daha fazla üzerinde durduğu bir alan haline gelmiştir. Bu mimari, algoritmanın birden fazla soyutlama seviyesindeki özelliklerini otomatik olarak öğrenmesini sağlamaktadır. Ham verilerin girdi olarak doğrudan kullanılabildiği yöntemde özelliklerin çıkarılması için insan uzmanlığına ihtiyaç duyulmamaktadır.

Yapay zekâda bir atılım olarak derin öğrenme; konuşma tanıma, görüntü yenileme, doğal dil işleme (örneğin çeviri, anlama, test soruları ve cevapları), çok modlu görüntü metni ve oyunların (örn. Alphago) çeşitli uygulamalarında olağanüstü performans göstermektedir. Otomatik özellik öğrenme ve yüksek hacimli modelleme yetenekleri ile derin öğrenme büyük veri çağında akıllı üretim için gelişmiş bir analiz aracı sağlamaktadır (Wang ve diğ., 2018, s.145).

Yapay sinir ağları birden fazla katman geliştirdiğinde derin öğrenme başlar. Birkaç nöron katmanında çalışmak, derin öğrenme ve veri madenciliğine doğru atılan ilk adımdır. Perseptron, çok katmanlı ağlarda 1986'da Rumelhart, Hinton ve Williams tarafından Gradient iniş adı verilen bir geri yayılım tekniği ile geliştirildiğinde yararlı olmaya başlamıştır. Geriye yayılım; sinir ağının öğrenmesinde daha düşük hataya sahip olduğu, doğru ağırlıkları tahsis etmeyi amaçlayan algoritmalar topluluğudur. Geri yayılım içinde en fazla kullanılan yöntemlerinden biri olan Stokastik Gradyan İnişi(SGD), kısmi türevler için hesap kavramlarını zincir kuralları olarak kullanarak hesaplama hata oranını

en aza indirmeyi amaçlayan bir algoritmadır (Rumelhart, Hinton ve Williams, 1986, s.533).

Yapay zekânın bir dalı olarak derin öğrenme, akıllı hata teşhisi alanında bir terim haline gelmiştir. Sığ öğrenme yöntemleriyle karşılaştırıldığında, derin ağ karmaşık işlevleri öğrenebilir, daha soyut özellikleri etkili ve kompakt bir şekilde temsil edebilir (Chen ve Li, 2017, s.1694). Hinton'un 2006 yılında yeni bir derin yapılandırılmış öğrenme mimarisi olarak geliştirdiği derin inanç ağı, derin öğrenmedeki önemli gelişmelerden birisidir(Hinton, Osindero ve Teh,2006).

Derin öğrenme, çoklu işleme katmanlarından oluşan hesaplama modellerinin, birden fazla soyutlama seviyesine sahip verilerin temsillerini öğrenmesini sağlar. Bu yöntemler; konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ile genom gibi diğer birçok alandaki son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, her katmandaki temsili hesaplamak için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder (Lecun, Bengio ve Hinton, 2015, s.436).

Beynin mimari derinliği gibi, belirli bir girdi algısı algoritmada çoklu soyutlama seviyelerinde temsil edilir ve her seviye korteksin farklı bir alanına karşılık gelir(Bengio 2009, s.8). Veri miktarı ve uygulama aralığı artmaya devam ettikçe güçlü özellikleri otomatik olarak öğrenme yeteneği giderek daha önemli hale gelecektir.

Derin öğrenme yöntemleri çok katmanlı yapıları nedeniyle büyük verileri işleme ve gizli bilgileri çıkarma yeteneğine sahiptir. Buna bağlı olarak yüksek oranda doğrusal olmayan işlemler gerçekleştirebilir. Büyük verinin ortaya çıkmasıyla derin öğrenme, büyük miktarlarda denetimsiz verilerin yer aldığı senaryolar için kullanılmıştır. Büyük veri analizi için etkili bir araç olan derin öğrenme tekniği, büyük miktarlarda etiketlenmemiş eğitim verileri ile başarılı sonuçlar vermiştir(Liu ve diğ., 2017, s.22).


Derin öğrenmenin doğuşu, yalnızca geleneksel makine öğrenmesi tekniklerinin zengin birikiminden değil aynı zamanda istatistiksel öğrenmenin ilhamından da yararlanır. Geleneksel makine öğrenmesi algoritmalarından derin öğrenmeye geçiş sürecinde farklı nedenler etkili olmuştur. Derin ağların eğitimi için gereken işlem gücü yüksek performanslı grafik işlemci birimi kullanımı ile hızlanmıştır. Kullanılan yöntemlerde daha iyi yakınsama ve genelleme elde etmek için daha fazla teknik ile

çerçeve geliştirilmiştir. Yakınsaklık hızını artıran Relu gibi algoritmalar, dropout ve pooling gibi aşırı öğrenmeyi engelleyen teknikler derin ağların başarısını artırmaktadır.

Geleneksel makine öğrenmesi yöntemleri ham verileri işleme konusunda yetenekli değildirler. Bir makine öğrenmesi modeli oluşturulurken ham verileri girdi setine dönüştürürken alan ve özellik mühendisliği bilgisi gerekmektedir. Derin öğrenme bir modelin ham verilerle beslenmesine ve algılama veya sınıflandırma için gerekli gösterimleri otomatik olarak keşfetmesine izin vermektedir(Lecun ve diğ., 2015, s.436).

2.3.1 Çok Katmanlı Algılayıcılar

Yapay sinir ağları (YSA) kavramı, beynin biyolojik sinir ağlarından ilham almaktadır. İnsan beyninin düşünme ve problem çözme süreçleri araştırmacılar için her zaman cazip bir konu olmuştur. YSA'lar insan beyninde bilgi işlemeyi ve bilgi edinimini taklit ederek öğrenmelerini sağlayacak matematiksel algoritmalar geliştirmeyi amaçlar (Basheer ve Hajmeer, 2000, s.4). Beyin, karmaşık problemleri çözmek için birbirine bağlı nöronları kullanır. YSA yapay nöronlar kullanarak giriş sinyalleri ile bir çıkış sinyali arasındaki ilişkiyi modellemek için aralarında bağlantı kurar. Birbirine bağlı nöronlar, problemi çözmenin temelini oluşturan yapı taşlarıdır. Şekil 4’de temel bir YSA modeli gösterilmektedir.



Şekil 4: Yapay Sinir Ağının Genel Yapısı

Makine öğrenmesi alanında, yapay sinir ağı biyolojik sinir ağının bilgisine adapte olmaya çalışır. Yapay sinir ağı, nöronlar arasındaki bağlantılar üzerinde, ağırlıkları belirleme yöntemi ve aktivasyon fonksiyonu ile karakterize edilir (Fausett, 1994, s.3). Giriş vektörünün boyutuna eşit olan bir girdi katmanı ile bir çıktı katmanı olan yapı en basit halidir. Nöronlar arasındaki bağlantıların farklı ağırlıkları vardır. Farklı ağırlıktaki girişler toplamının matematiksel formülasyonu aşağıda gösterilmiştir.

$$y = \sum_{i=1}^k w_i x_i + b$$

Burada k, giriş sayısını; w, ağırlığını; x, giriş değerini ve b, bias terimini ifade etmektedir. Daha sonra net toplam bir çıkış değeri sağlayan doğrusal olmayan bir aktivasyon fonksiyonu ile işlenir.

$$f(y) = f\left(\sum_{i=1}^k w_i x_i + b\right)$$

Doğrusal olmayan aktivasyon fonksiyonu (f), ağırlık girişlerinin toplamını düğümün çıkışına dönüştürür. Sigmoid veya lojistik fonksiyon düğüm çıkışını 0 ile 1 arasında kısıtlayan transfer fonksiyonudur.


Standart bir sinir ağı, her biri gerçek değerli aktivasyonlar dizisi üreten nöron adı verilen birçok basit bağlı işlemciden oluşur. Giriş nöronları çevreyi algılayan sensörler aracılığıyla aktif hale gelirken diğer nöronlar daha önce aktif olan nöronların ağırlıklı bağlantıları ile aktif hale gelir (Schmidhuber, 2015, s.86).

Genel bir yapay sinir ağının eğitimi, geri yayılım algoritması kullanılarak gerçekleştirilir (Rumelhart ve diğ., 1986, s.533). Geri yayılım algoritması bilinen en yaygın yöntemdir. Denetimli öğrenmede ağı bir dizi girdi dahil edildikten sonra çıktı ile gerçek değer karşılaştırılır. Ağırlıkların değerini ayarlamak için normalize edilmiş ortalama kare hatası (OKH) kullanılarak ağ üzerinde geriye doğru yayılır. Bu işlem kabul edilebilir bir OKH değerine ulaşmaya kadar tekrarlanır. YSA başarılı bir şekilde eğitildikten sonra test verileri için kullanılma hazır hale gelmiş olur (Paya, Esat ve Badi, 1997, s.754).

$$OKH = \frac{1}{n} \sum_{i=1}^n (y^*_i - y_i)^2$$

Bağlantı mimarisine göre YSA'lar ileri beslemeli ağlar ve geri beslemeli ağlar olarak ikiye ayrılır. Çok katmanlı algılayıcı denilen en yaygın ileri beslemeli ağ ailesinde nöronlar, aralarında tek yönlü bağlantıları olan katmanlar halinde düzenlenir (Jain, Mao ve Mohiuddin, 1996, s.34).

Derin sinir ağlarının yapısı, daha karmaşık ve doğrusal olmayan ilişkileri modellemek için giriş ve çıkış katmanları arasındaki gizli katmanlar ekleyerek geleneksel sinir ağlarının genişletilmesi prensibine dayanmaktadır. Giriş katmanından çıkış katmanına akan tipik bir ileri besleme ağı, iki ve ikiden fazla gizli katmanın bulunduğu yapılardır. Gizli katmanlardaki nöron sayısını seçmek için herhangi bir kriter yoktur. Bu parametreler farklı ayarlandığında sınıflandırma doğruluğunun performansını etkileyecektir. Derin sinir ağı (DSA), birçok alanda başarılı sınıflandırma veya regresyon için yaygın olarak kullanılan bir mimaridir. Şekil 5, DSA'lar için tipik mimariyi göstermektedir.




Şekil 5: İki Gizli Katmanlı Derin Sinir Ağı Yapısı

2.3.2 Oto Kodlayıcı

Oto kodlayıcı (OK), temelde bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşan denetimsiz öğrenme yöntemlerini kullanan bir sinir ağıdır.

Denetimsiz öğrenme mantığı ile çalışan oto kodlayıcı bir derin öğrenme çeşididir. İnsan uzmanlığına dayanan özellik çıkarma ihtiyacını ortadan kaldırır. Bir diğer avantajı da büyük veri eğitimi problemlerinde aşırı uyumu engelleyebilmesidir (Xueyi, Jialin, Yongzhi ve David, 2019, s.2). Oto kodlayıcı, girdisini çıktısına kopyalamaya çalışmak üzere eğitilmiş ve genellikle denetimsiz özellik çıkarımı için kullanılan bir sinir ağıdır (Khan ve Yairi, 2018, s.251).

Giriş ve çıkış katmanının boyut olarak eşit olduğu, bir kodlayıcı ve çözücüye sahip olan OK girdi katmanını çıktı katmanında yeniden oluşturan eğitilmiş ileri beslemeli bir ağıdır. Şekil 6’da basit bir oto kodlayıcı yapısı bulunmaktadır.



Şekil 6: Oto Kodlayıcının Yapısı

Oto kodlayıcılar, giriş vektörü x ile çıkış vektörü x' te oluşturulması sırasında yapılandırma hatasını en aza indiren ağ ağırlıkları ve sapmaları ile eğitilir. Bitişik katmanlar arasındaki bağlantı $W^t x$ ve Wy ağırlık matrisleri ile tamamlanır. Kodlama işleminin açıklaması aşağıdaki gibidir:

$$y = s(W^t x + b)$$

Burada b kodlayıcının bias vektörüdür; s tipik olarak sigmoid, hiperbolik tanjant veya kimlik fonksiyonu olan kodlayıcıda kullanılan aktivasyon fonksiyonudur. Benzer şekilde, kod çözücünün tanımı aşağıda gösterilmiştir.

$$x' = s(Wy + b')$$

Burada b' çözücünün bias vektörüdür, s ise aktivasyon fonksiyonudur.

$$\min\{\|x - x'\|^2\}$$

Son katmanın özellikleri bir sonraki katmanın girdisidir. Farklı gizli katmanlar aracılığıyla farklı boyutlardaki özellikleri ayıklayabilir. Sinir ağları, otomatik kodlayıcıların eğitimi için uygun olan geri yayılma algoritması ile eğitilir. W ağırlığı ve b sapması, s maliyet fonksiyonunu (W, b) en aza indirmek için gradyan iniş yöntemiyle güncellenir.

OK, denetimsiz öğrenme yöntemleri kullanarak özellikleri elde etmek için kullanılabilen bir sinir ağı modelidir. OK, kodlama işleminde yüksek boyutlu alandan düşük boyutlu alana indirgenir ve daha sonra kodlanmış düşük boyutlu özellik vektörü, kod çözme işleminde açılır. Oto kodlayıcı ham verinin iyi bir temsilini oluşturabileceği gibi, etkin bir şekilde verilerin özelliklerini kaybetmeden boyutunu da azaltabilir.

Yüksek boyutlu veriler, yüksek boyutlu girdi vektörlerini yeniden yapılandırmak için küçük bir merkezi katmanla çok katmanlı bir sinir ağı eğitilerek düşük boyutlu kodlara dönüştürülebilmektedir. Boyutsal küçültme, yüksek boyutlu verilerin sınıflandırılmasını, görselleştirilmesini, iletişimini ve depolanmasını kolaylaştırır (Hinton ve Salakhutdinov, 2006, s.504). Gizli katman düğümlerinin sayısını orijinal giriş düğümlerinin sayısından düşük tutulduğunda, girişin sıkıştırılmış bir temsili alınarak istenen boyutsallık azaltma etkisini elde edilebilmektedir (Wang, Yao ve Zhao, 2016, s.233).

OK'un önemli bir avantajı, bu modelin yayılma sırasında sürekli olarak yararlı özellikler elde edebilmesi ve yararsız bilgileri filtreleyebilmesidir. Ayrıca girdi vektörü kodlama işleminde daha düşük boyutlu bir temsile dönüştürüldüğünden öğrenme sürecinin verimliliği arttırılabilmektedir (Liu ve diğ., 2017, s.15).

Oto kodlayıcılar, ham girdi verilerinden ilgili gizli bilgilerin çıkarılması, daha sonra bunların farklı seviyelere bölünmesi, boyut azalması ve girdi boyutsallığı büyük olduğunda veriler hakkında ayrımcı bilgiler bulunması gibi farklı şekillerde model içerisinde kullanılabilir.

Çeşitli oto kodlayıcılar mevcuttur, en yaygın olanlardan birisi gürültü temizleyen oto kodlayıcıdır. Bu yöntem denoising olarak adlandırılır. Girişlerin temiz bir şekilde çoğaltılmasını sağlamak için giriş veri kümesinden gürültü temizlenir. Bu işlem sonucu giriş katmanında bulunan gürültü çıkış katmanında bulunmamaktadır. Genellikle ses tanımlama işlemlerinde sıklıkla kullanılmaktadır.

Gizli birimlerin sayısı büyük olduğunda, verileri daha verimli bir şekilde temsil eden bir dizi aşırı tamamlanmış temel vektör, kısıtlamalar getirilerek elde edilir. Bu özellik çıkarma daha iyi bir performans sağlar. Özellikle, gizli birimlerin etkinleştirilmesini küçük bir değere getiren kısıtlamalar, genel maliyet fonksiyonuna bir azlık kısıtlama ceza faktörü koymak suretiyle elde edilir. Bu yapı yığılmış seyrek oto

kodlayıcı(YSOK) olarak adlandırılır (Wang, Liu, Bao ve Zhang, 2019, s.6721). Genel maliyet fonksiyonu, kısıtlama ceza faktörü ile birlikte aşağıdaki şekilde formüle edilir:

$$J_{seyrek}(W, b) = J(W, b) + \beta \sum_{j=1}^s KL(\rho || p'j)$$

$$KL(\rho || \rho^{\wedge}_j) = \rho \log \frac{\rho}{\rho^{\wedge}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \rho^{\wedge}_j}$$

Burada $\sum_{j=1}^s KL(\rho || \rho^{\wedge}_j)$ kısıtlılık cezası terimidir. β kısıtlılık cezası süresinin ağırlığıdır. Seyrek ceza terimi oto kodlayıcının amaç fonksiyonuna eklenir. Böylece öğrenilen özelliklerin girdiyi tekrarlaması kısıtlanır. Seyrek ceza terimi aktif nöron sayısını kontrol etmek için gizli katman üzerinde çalışır. Seyrek oto kodlayıcının çıktısı, bir veri kümesi için boyutsallık azaltmayı öğrenmek için kullanılan veri girişinin kendisidir. Seyrek oto kodlayıcılar boyutsal azaltma için birçok araştırmada başarılı bir şekilde uygulanmıştır (Shin, Orton, Collins, Doran ve Leach, 2012; Zabalza ve diğ., 2016).

OK kullanılırken ilk aşamada denetimsiz öğrenme kullanılarak özellikler çıkarılır, ikinci aşamada ise denetimli öğrenme kullanılarak sınıflandırma problemine dönüştürülür. Son katmanda softmax algoritması kullanılarak çıktı değerleri tahmin edilebilmektedir.

Çok sınıflı bir sınıflandırma problemi genellikle çoklu çıkış nöronlarına sahiptir. Softmax regresyon, çok sınıflı verilerin sınıflandırılmasında kullanılan başarılı bir sınıflandırma yöntemidir. Softmax katmanı, iki sınıfı ayırabilen genişletilmiş bir mantıksal regresyon sürümüdür. Softmax işlevi her sınıfın olanaklarını sunar ve net değerde en yüksek sonuçları seçer. Softmax katmanı, YSOK yapısına kolay entegrasyonu ve basitliği sayesinde derin öğrenme yapılarında kullanılır. Softmax regresyonunun uygulanması kolaydır ve çok sınıflı sınıflandırma için sıklıkla son katmana uygulanır (Lei, Jia, Lin, Xing ve Ding, 2016, s.3139).

Sınıf etiketinin ikiden fazla olduğu durumlarda softmax sınıflandırıcısı, lojistik regresyonu genelleştirerek çözüme ulaşır (Wang ve diğ., 2019, s.6721). Softmax, bir veya daha fazla OK ile işlenen verileri sınıflandırırken daha iyi sonuçlar elde ederek sınıflandırmanın doğruluğunu artırır. Sınıf etiketlerinin yalnızca iki olası değer

alabileceği lojistik regresyon ile karşılaştırıldığında, softmax regresyon sınıf etiketleri için daha fazla seçenek sunar. Bu birçok çok sınıflı sınıflandırma problemini çözmek için yararlıdır.

Genel anlamda oto kodlayıcıların, kolay uygulanabilir olması, daha zengin temsiller için modifiye edilebilmesi, boyut azaltılabilmesi, geri yayılım ile kayıp maliyeti en aza indirebilmesi güçlü yönleri olarak gösterilebilir. Eğitim için çok fazla veri gerekmesi, işlem süresinin uzun olması, parametre ayarlarını gerektirmesi, olabildiğince fazla bilgi çıkarması ve hangi bilgilerin ilgili olduğunu belirleyememesi eksik yönleri olarak belirtilebilir (Khan, Yairi, 2018, s.253).

2.4 Özellik Mühendisliği

Veri toplama işleminden sonra, toplanan tüm veriler teşhis ve prognoz için veri tabanında veya bulut ortamında saklanmaktadır. Bununla birlikte bilgi keşfi sürecinde gürültülü veya güvenilir olmayan verilerin düzenlenmesi gerekmektedir. Bu nedenle, bir sonraki adımdan önce verilerin işlenmesi gerekmektedir. Veri ön işleme, ham verileri etkin bir şekilde temizleyebilir, verilerin boyutunu azaltabilir ve bilgi keşfi için depoya geri depolayabilir (Li, Wang ve Wang, 2017, s.381).

Arıza teşhis ve kestirimci bakım uygulamasında veri toplama sisteminden elde edilen değerler makine öğrenmesi algoritmasının daha iyi performans gösterebilmesi için yeni bir değişken alanına dönüştürülmeden önce işlenmektedir. Arıza teşhisinde elde edilen titreşim sinyallerinde arızanın karakteristiği ile ilgili özelliklerin çıkarılması önemli aşamalardan birisidir.

Özellik mühendisliği genellikle arıza teşhis sisteminin en önemli parçası olarak kabul edilir. Özellik mühendisliğinden sonraki işlevler (sağlık değerlendirmesi, arıza teşhisi, kalan faydalı ömür tahmini), özelliklerin kalitesinden doğrudan etkilenir. Uygun maliyetli bir bakım sistemine sahip olmak için yalnızca arıza teşhisi için gerekli olan sinyaller toplanmalıdır.

Makinelerden elde edilen verilerden, teşhis ve prognostik için bilgi sağlayan özellikler elde edilebilir. Uygulamaya bağlı olarak ayıklanacak birçok önemli özellik olabilir.

Veri ön işlemede yer alan başlıca adımlar arasında veri temizleme, veri birleştirme, veri azaltma, veri dönüştürme ve özellik çıkarma yer almaktadır.

Veri temizleme, eksik değerleri doldurarak, gürültülü verileri yumuşatarak, aykırı değerleri belirleyerek veya kaldırarak, tutarsızlıkları gidererek yanlış kayıtları algılama ve düzeltme işlemidir.

Veri birleştirme, birden çok veri kaynağındaki verilerin entegre edilmesidir. Dikkatli entegrasyon, ortaya çıkan veri kümesindeki fazlalıkları ve tutarsızlıkları azaltmaya ve önlemeye yardımcı olabilir.

Veri dönüşümünde, veriler bilgi keşfi için uygun biçimlere dönüştürülür veya birleştirilir, böylece makine öğrenmesi süreci daha verimli olabilir ve bulunan örüntülerin anlaşılması kolaylaşır.

Veri azaltma, hacim olarak çok daha küçük olan ve yaklaşık olarak aynı analitik sonuçları üretebilen veri kümesinin temsil edecek şekilde azaltılmasıdır. Birçok boyutsal azaltma yöntemi vardır. Bunlar arasında, basit bir yaklaşım, veri setine özellik çıkarma yöntemlerini uygulamaktır. Genellikle, özellikler zaman alanı, frekans alanı ve zaman-frekans alanı olmak üzere üçe ayrılır.

Büyük veriler teşhis ve prognoz modelleri için girdi değişkenleri olarak özelliklere veya istatistiksel değerlere dönüştürülebilir. Bu nedenle uygun veri ön işleme işlemleri sinyal karakteristiklerini arttırabilir. Arıza teşhisinde ve prognozda yararlı bilgilerin verimli bir şekilde çıkarılmasını kolaylaştırabilir.

Arıza teşhis ve kestirimci bakım için özellik mühendisliğinin en önemli süreçleri aşağıda verilmektedir:

- Sinyal İşleme: İşlenmemiş ham verilerin yorumlanmasına, üretilmesine ve dönüştürülmesine sinyal işleme denir. Sinyal işleme, analog veya dijital sinyallerin üretilmesi, dönüştürülmesi, iletilmesi ve öğrenilmesi için matematiksel, istatistiksel, hesaplamalı, sezgisel modelleme teknikleri ve algoritmalar kullanır. Sinyal analizi için birçok farklı teknik mevcuttur.

- Özellik Çıkarma ve Seçimi: Özellik çıkarma verilerinden ayırıcı özellikler çıkarma sürecidir. Bir titreşim sinyali ivmeölçerler tarafından ölçüldükten sonra, hataya duyarlı özellikleri ayıklamak için farklı sinyal işleme teknikleri kullanılır. Bu teknikler tamamen bağımsız değildir ve birçok durumda birbirini tamamlar. Dalga formu ve çok

boyutlu veriler için veri işleme, sinyal işleme olarak da adlandırılır. Daha fazla tanı ve prognostik amaç için yararlı bilgileri elde etmek üzere dalga formu ve çok boyutlu verileri analiz etmek ve yorumlamak için çeşitli sinyal işleme teknikleri geliştirilmiştir. Ham sinyallerden faydalı bilgilerin çıkarılması prosedürü, özellik çıkarmadır (Jardine ve diğ., 2006, s.1486). Etkili tanı ve prognoz, anlamlı ve en duyarlı özellikler çıkarılarak gerçekleştirilebilir. Hatalı ve uygun olmayan özellikler, arıza teşhis ve prognoz tekniklerinin genel güvenilirliğini azaltır ve gerçek rulman durumunu tahmin doğruluğu azalır (Sharma, Amarnath ve Kankar, 2016,s.179).

Veri toplama ve sinyal işleme sonrasında tüm özelliklerin sayısı kullanılmak için fazla olabilir. Oluşturulan makine öğrenmesi modelinin doğruluğunu artırmak ve işlem süresini optimum düzeye indirmek için özellik sayısını azaltmak ve özelliklerin bilgi içeriğini artırmak gerekebilir.

Özellik seçimi temsili özelliklerin bir alt kümesini oluştururken, özellik çıkarma orijinal özellik uzayını dönüştürerek yeni bilgiler ortaya çıkarır. Özellik çıkarmanın bir avantajı özellik alanının çok daha fazla azaltılabilesidir. Özelliklerin seçimi genellikle arıza teşhis doğruluğunu doğrudan etkiler. Bununla birlikte, farklı hassas özelliklerle, sınırlı ön bilgi ile doğru ayırt etme işlemi yapmak çok zordur (Shao, Jiang, Zhang ve Niu, 2015, s.1)

Zaman alanı analizi doğrudan zaman dalga formunun kendisine dayanır ve geleneksel zaman alanı analizi, zaman alanı özellikleri olarak adlandırılan özellikleri hesaplar. Zaman alanı teknikleri, zaman dalga formu sinyallerinin istatistiksel olarak ayırt edici davranışlarına dayanır. Zaman alanı analizi, basitliği nedeniyle, arıza teşhisi için her zaman çekici bir yaklaşım olmuştur. Titreşim sinyalleri toplanırken başlangıçta zaman alanıdır. Sinyalin zaman içinde genliğinin değişmesi zaman alanına atıfta bulunur. Sistemden elde edilen titreşim verilerinin zaman düzleminde özelliklerinin çıkarılması, arıza teşhisinde kullanılabilecek önemli bilgileri ortaya çıkarmaktadır. Sağlıklı ve arızalı durumlarda titreşim sinyalleri zaman alanı özelliklerinde farklılıklarını göstermektedir.

İstatistiksel göstergeler ve zaman-senkronlu ortalama gibi zaman alanı sinyal işleme yöntemleri, hem frekans-etki alanı hem de zaman-frekans-etki alanı yöntemlerine kıyasla nispeten kolay olmakta ve doğrudan kullanılabilmektedir (Lei, Lin, Zuo ve He, 2014, s.298).

Geleneksel istatistik özellikleri, arıza meydana geldiğinde makine titreşim sinyallerinin değişimini karakterize eden güçlü bir araçtır. İstatistiksel özellikleri çıkarmanın basitliği ve düşük hesaplama süresi bu yöntemin avantajıdır (Ali, Fnaiech, Saidi, Chebel-Morello ve Fnaiech, 2015, s.19).

İstatistiksel yöntemler, zaman-alan verilerinin fiziksel özelliklerini sağlayabilir. Titreşim sinyallerinin istatistiksel analizi farklı tanımlayıcı istatistiksel parametreler verir (Sakthivel, Sugumaran ve Babudevasenapati, 2010, s.4044). İstatistiksel yöntemlerden etkin değer, ortalama değer, standart sapma, maksimum değer, minimum değer çarpıklık, basıklık, tepe faktörü, etki faktörü gibi özellikler sıklıkla kullanılan özelliklerdir.

Durağan olmayan sinyale, çarpıklık ve basıklık gibi daha gelişmiş istatistiksel tabanlı özellikler uygulanabilir. Bu özellikler sinyalin olasılık yoğunluk fonksiyonunu (OYF) inceler. Çarpıklık, sinyalin negatif veya pozitif çarpık olup olmadığını ölçmek için kullanılırken, basıklık OYF'nin tepe değerini ölçer (Caesarendra ve Tjahjowidodo, 2017, s.4). Genel istatistiki özelliklerin isimleri ve tanımları şu şekildedir:

- Etkin değer: Etkin değer, bir sinyalin etkin miktarıdır. Titreşim sinyalindeki güç içeriğini gösterir.
- Ortalama değer: Ortalama değer, sinyal genliğinin genel ortalamasını verir.
- Standart sapma: Standart sapma, titreşim sinyalindeki enerji içeriğinin ölçüsüdür.
- Maksimum değer: Arıza sinyal genliğinin maksimum değerini verir.
- Minimum değer: Arıza sinyal genliğinin minimum değerini verir.
- Çarpıklık: Üçüncü normalleştirilmiş merkezi istatistiksel moment olarak da adlandırılan çarpıklık, olasılık yoğunluğu fonksiyonu yoluyla titreşim sinyalinin asimetri davranışının bir ölçüsüdür. Titreşim sinyalinin, titreşim sinyalinin normal durumunun dağılımının soluna veya sağına eğik olup olmadığını ölçer.
- Basıklık: Dördüncü normalleştirilmiş merkezi istatistiksel moment olarak da adlandırılan basıklık, olasılık yoğunluk fonksiyonu yoluyla titreşim sinyalinin tepe değerinin bir ölçüsüdür, yani pikin karşılık gelen dağılımın tepe noktasından daha yüksek veya daha düşük olup olmadığını ölçer. Hasar durumuna göre titreşim verisinin basıklık değeri de yükselir.
- Tepe faktörü: Tepe faktörü maksimum değer in etkin değere bölünmesiyle elde edilir. Genellikle bir hata durumunun erken aşamalarını tespit etmede yararlıdır.

- Etki faktörü: Tepe değerinin titreşim sinyalinin mutlak değerinin ortalamasına oranı olarak tanımlanır. Etki faktörü, titreşim sinyalinde üretilen bir hatanın etkisinin ölçülmesinde faydalıdır.

Tablo 1’de genel istatistiki özelliklerin formülleri verilmiştir.

No	İstatistiksel Özellik	Denklem
1	Ortalama Değer	$x_m = \frac{1}{K} * \sum_{k=1}^K x(k)$
2	Standart Sapma	$x_{std} = \sqrt{\frac{\sum_{k=1}^K (x(k) - x_m)^2}{(K - 1)}}$
3	Basıklık	$x_{kurt} = \frac{\sum_{k=1}^K (x(k) - x_m)^4}{(K - 1)x_{std}^4}$
4	Çarpıklık	$x_{skew} = \frac{\sum_{k=1}^K (x(k) - x_m)^3}{(K - 1)x_{std}^3}$
5	Etkin Değer	$x_{rms} = \sqrt{\sum_{k=1}^K (x(k))^2 / K}$
6	Maksimum Değer	$x_{max} = \max(x(k))$
7	Minimum Değer	$x_{min} = \min(x(k))$
8	Tepe Faktörü	$CF = \frac{x_{max}}{x_{rms}}$
9	Etki Faktörü	$IF = \frac{x_{max}}{(1/K \sum_{k=1}^K x(k))}$

Tablo 1: Genel İstatistiki Özellikler

2.5 Model Performanslarının Değerlendirilmesi

Doğruluk bir sınıflandırıcıyı değerlendirmek için kullanılan en yaygın ve en basit ölçüdür. Sadece bir modelin doğru tahminlerinin derecesini veya tersine yanlış sınıflandırma hatalarının yüzdesi olarak tanımlanır (Ferri, Hernández-Orallo ve Modroi, 2009, s.29). Model performansının genel değerlendirmesini sunmaktadır. Doğru sınıflandırma sayısı ile toplam sınıflandırma arasındaki oranı ifade etmektedir. Bu doğruluk herhangi bir yüzde olarak ifade edilebilmektedir. Değeri yüzde 0 ile yüzde 100 arasındadır. Yüksek doğruluk yöntemin daha tutarlı bir şekilde tahmin edildiğini göstermektedir.

Dengesiz sınıflandırma problemlerinde doğruluk ölçüsü yeterli ve uygun değildir. Aşırı dengesiz veriler olması durumunda doğruluk yapay olarak oldukça yüksek olabilir fakat azınlık sınıfların performanslarını tam olarak gösterememektedir (Koço ve Capponi, 2013, s.277).

$$\text{Doğruluk} = \frac{\text{Doğru sınıflandırma sayısı}}{\text{Toplam sınıflandırma sayısı}}$$

Karışıklık matrisi, farklı başarı türlerini ve sınıflandırıcı tarafından yapılan hataları ayırt etmeyi sağlar. Doğruluk oranından farklı olarak karışıklık matrisi n x n boyutundadır. N sınıf sayısı olarak kullanıldığı matriste her sınıfa ait ayırt edici sınıflandırma oranı görülebilir. Karışıklık matrisi, sınıf dengesizliği sorununun üstesinden gelmek için kullanılabilecek bir dengeleyici araçtır. Aşağıdaki tabloda ikili sınıflandırma için karışıklık matrisi örneği verilmiştir.

TAHMİN EDİLEN DEĞER			
Pozitif	Negatif		
Gerçek Pozitif	Yanlış Negatif	Pozitif	GERÇEK DEĞER
Yanlış Pozitif	Gerçek Negatif	Negatif	

Tablo 2: Karışıklık Matrisi Örneği

Bir sınıflandırmanın doğruluğu, gerçek pozitifler, gerçek negatifler, yanlış pozitifler, yanlış negatifler olarak tanımlanan değerler hesaplanarak ölçülebilir (Sokolova ve Lapalme, 2009, s.429).

Karışıklık matris hücrelerinin anlamı şöyledir:

Gerçek Pozitifler: Sınıflandırıcı tarafından da sınıflandırılan gerçek pozitif sınıfların sayısı.

Gerçek Negatifler: Sınıflandırıcı tarafından da sınıflandırılan gerçek negatif sınıfların sayısı.

Yanlış Pozitifler: Sınıflandırıcı tarafından pozitif olarak yanlış sınıflandırılan negatif sınıfların sayısı.

Yanlış Negatifler: Sınıflandırıcı tarafından negatif olarak yanlış sınıflandırılan pozitif sınıfların sayısı.

Karışıklık matrisinden yararlanarak aşağıdaki kalite göstergelerinin hesaplanışı gösterilmektedir.

Kesinlik: Pozitif olarak tahmin edilen sonuçların gerçekte kaç tanesinin pozitif olduğunu ifade etmektedir. Doğru tahmin edilen pozitif örneklerin oranının, tahmin edilen toplam pozitif örnek sayısına bölünmesiyle hesaplanır. İki'den fazla sınıfla dengesiz bir sınıflandırma probleminde, kesinlik, tüm sınıflardaki gerçek pozitiflerin toplamı ile tüm sınıflardaki gerçek pozitiflerin ve yanlış pozitiflerin toplamına bölünmesiyle hesaplanır.

$$Kesinlik = \frac{Gerçek\ Pozitifler}{Gerçek\ pozitifler + Yanlış\ Pozitifler}$$

Duyarlılık: Doğru tahmin edilen pozitif örneklerin oranının, doğru tahmin edilen pozitif örneklerinin ve yanlış tahmin edilen negatiflerin toplamına bölünmesiyle hesaplanır. Bu parametre yanlış tahmin edilen gerçek pozitiflerin bir göstergesidir. Çoklu sınıflandırma problemlerinde tüm sınıflardaki gerçek pozitiflerin toplamının, tüm sınıflardaki gerçek pozitiflerin ve yanlış negatiflerin toplamına bölünmesiyle hesaplanır.

$$\text{Hatırlama} = \frac{\text{Gerçek Pozitifler}}{\text{Gerçek Pozitifler} + \text{Yanlış Negatifler}}$$

F1 Skor: Eşit dağılmayan veri kümelerinde yanlış modeli seçmemek için doğruluk yerine F1 skoru kullanılabilir. F1 skor, kesinlik ve duyarlılığı beraber ele alıp tek bir ölçüde birleştirmenin bir yolunu sunar.

$$F1 \text{ Skor} = 2 * \frac{\text{Kesinlik} * \text{Hatırlama}}{\text{Kesinlik} + \text{Hatırlama}}$$

Makine öğrenmesi ve derin öğrenme modellerin performans sonuçlarının değerlendirilmesi önemli bir konudur. Model performansının ölçülmesinde yararlanılan bir yöntem de AUC (Area Under an ROC Curve)-ROC (Receiver Operating Characteristics) eğrisidir. Dengesiz veri setlerinde makine öğrenmesi ve derin öğrenme algoritmalarının performans değerlendirmelerinin daha sağlıklı yapılmasını sağlamaktadır (Fawcett, 2004, s.1). AUC, ROC eğrisi altında kalan alanı ifade etmektedir. Bu alan kullanılan modelin tahminin ne kadar iyi olduğunu da açıklamaktadır. Bu alanın büyüklüğü, modelin sınıfları etme becerisini gösterir. İdeal değeri 1 olan AUC model performansının göstergesidir. ROC eğrisinde x ekseninde yanlış pozitif oran, y ekseninde gerçek pozitif alan bulunmaktadır.

ÜÇÜNCÜ BÖLÜM

ARIZA TEŞHİSİ

3.1 Arıza Teşhisinin Genel Çerçevesi

Arıza terimi; sistemin istenmeyen veya dayanılmaz davranışlarına yol açan fonksiyonel birimlerdeki yanlışlıklar, hatalar veya bozukluklar ile eş anlamlı olarak kullanılır. Arıza teşhisinin amacı, ilgili hataların ve nedenlerinin yeterince erken tespit edilmesi, böylece genel sistemin arızalanmasının önlenmesidir (Frank, 1996, s.7).

Arıza teşhisi ile bir arızanın büyüklüğünün, yerinin ve zamanının belirlenmesi sağlanır. Bu teşhis, arızanın tespiti ve tanımlanmasını içerir (Isermann ve Balle, 1997, s.710). Arıza teşhisi esasen bir çeşit örüntü tanıma veya sınıflandırmadır (Yuan ve Chu, 2006, s.950). Makine arıza teşhisi, ölçümle elde edilen bilgilerin veya frekans/zaman alanı özelliklerinin makine arızalarına eşlenmesi prosedürüdür. Bu eşleme işlemine örüntü tanıma da denir (Jardine ve diğ., 2006, s.1492).

Arıza teşhisi, kestirimci bakımın temel yaklaşımlarından birisidir. Cihaz çalışma ve durum izleme bilgisine dayalı hata teşhisi; çeşitli karakteristik parametreleri kullanarak veri analizi, işleme ve veriye dayalı modelleme ile cihaz durumunu tanımlar. Arıza teşhisi, beklenen değerlerinden dikkat çeken sapmalara sahip proses değişkenlerini belirli arızalarla ilişkilendirerek yapılabilir (MacGregor, Cinar, 2012, s.113). Teşhis, bir durumun veya sorunun nedenini, doğasını araştırmak, analiz etmek için yapılır. Bir sistem veya alt sistem içindeki bir hata modunu algılama ve tanımlama yapabilmemize olanak sağlar (Lee ve diğ., 2014, s.315).

Hem teşhis hem de prognoz tıp alanından aktarılan kavramlardır. Makine bakım teknolojisi geliştikçe teşhis ve prognoz yavaş yavaş makine mühendisliğinin tüm alanlarında kullanılmaya başlanmıştır. Günümüzde, arıza teşhisi yapmak için sensörler, sayaçlar, kontrolörler ve hesaplama cihazları gibi birçok profesyonel cihazlar bulunmaktadır. Bu cihazlar bir makine veya işlemde sinyal almak ve bunu analiz etmek için kullanılabilir. Makine arızasının temel nedenlerini belirlemek için giderek daha karmaşık teşhis yöntemleri kullanılmaya başlanmıştır (Lee ve diğ., 2014, s.314).

Arıza teşhisi ile arızadan önce yedek parçaların sipariş edilmesi ve değiştirilmesi sağlanırken sorunun tekrarlanmasını önlemek için hatanın kök nedeninin bulunmasının ilk adımı atılmış olur.

Endüstriyel sistemlerin artan karmaşıklığı ve ilgili performans gereksinimleri, onları denetlemek için yeni yaklaşımlar geliştirme ihtiyacını doğurmuştur. Denetim, her seferinde sistemin çalışma durumunu belirlemeyi amaçlayan izleme görevlerini içerir. Bu sorun iki ayrı adıma ayrılabilir: Sistemde meydana gelen bir hatanın varlığını tespit etmeyi amaçlayan adım ve tespit edilen hatanın temel nedenlerini belirlemeyi amaçlayan teşhistir. Teşhis ile arızanın türü, boyutu ve profili karakterize edilir (Tidiri, Chatti, Verron ve Tiplica, 2016, s.63).

Sensörler, bilgisayarlar, bulut altyapısı ve analitik araçlardaki teknolojik ilerlemelerle veriler, daha kolay ulaşılabilir hale gelmiştir. Bu durum, birçok sektöre katma değer sağlamaktadır. Makine verilerinin artan kullanılabilirliğinden önemli ölçüde faydalanan bir alan da kestirimci bakımdır.

Kestirimci bakım, makinelerin performansı ve durumu hakkında bilgi sağlamaya odaklanır. Varlık yönetimi, bakım ve operasyonları mümkün kılan bir alandır. Kestirimci bakım uygulamasının bir ayağını oluşturan arıza teşhisi, bozulma tespit edildikten sonra gerçekleşen ve makinenin nasıl bozulduğu hakkında anlamlı bilgiler sağlayan bir yöntemdir.

Üretim tesislerinde, makinelerde, arabalarda vb. yerlerde kurulan artan sayıda gömülü algılama sistemlerinden gelen verileri izlemek ve kayıt altına almak için yeni teknolojiler geliştirilmektedir. Bu gelişmelerle veri kaybı yaşamadan büyük veri olarak adlandırılan yapı oluşturmaktadır. Büyük veri olarak adlandırılan bu yapı anormallikleri tespit etmeyi ve bakım planlarını etkileyen arızaları tahmin etmeyi daha kolay hale getirmede kaynaklık etmektedir.

Çalışan bir sistemde arızaların teşhisi için makinelerin sürekli ya da belirli aralıklarla izlenmesi gereklidir. Sistemlerin izlenmesinin gerekliliği, durum izleme ve arıza teşhis kavramlarının birbiriyle bağlantılı olduğunu gösterir. Arıza, bir sisteme ait bir bileşenin yapısına uygun olmayan şekilde davranmasıdır. Bakım ise bir sistemi anormal durumundan başlangıç durumuna döndürme sürecidir. Durum izleme ile sistemin karakteristik özellikleri takip edilir. Arıza öncesi durumu tespit ederek bakım ihtiyacının

olup olmadığına karar verilmesi sağlanır. Arıza teşhisi ile arızanın nereden kaynaklandığı ve şiddeti de belirlenebilir.

Arıza teşhis sistemleri model tabanlı ve veri odaklı yaklaşımlar olarak ikiye ayrılmaktadır (Venkatasubramanian, Rengaswamy, Yin ve Kavuri, 2003a; Venkatasubramanian, Rengaswamy, Yin ve Kavuri, 2003b; Venkatasubramanian, Rengaswamy, Yin ve Kavuri, 2003c).

Model tabanlı yaklaşımlar, sürecin önceden fiziksel ve matematiksel bilgisini gerektirir. Proses modelinin ilk prensiplere dayanarak inşa edilmesinden sonra başarıyla uygulanabilir (Yin, Ding, Xie ve Luo, 2014, s.6418). Model tabanlı yaklaşımlarda, endüstriyel proseslerin veya pratik sistemlerin sistem tanımlama teknikleri kullanılarak elde edilen modellerinin mevcut bulunması gerekir. Modele dayanarak pratik sistemlerin ölçülen çıktıları ile modelde öngörülen çıktılar arasındaki tutarlılığı izlemek için arıza teşhis algoritmaları geliştirilmiştir (Gao, Cecati ve Ding, 2015, s.3759).

Bu teknikte sistem ile ilgili bilginin varlığı önceliklidir. Model tabanlı arıza tespiti ve teşhis yaklaşımı, gözlem altında olan sistemin bir hatanın model parametrelerinde deterministik değişikliklere neden olacağı matematiksel bir yaklaşımdır. Bu yaklaşımlar, izlenen makinenin fiziksel doğasına dayalı bir matematiksel model geliştirir. Daha sonra ölçülen sinyaller, artıklar oluşturmak için matematiksel modelin öngörülen sinyal değerleri ile karşılaştırılır. Kalıntılar sonra işlenir ve arızaların teşhisi için değerlendirilir.

Model tabanlı yaklaşımlar önemli miktarda veriye erişim mümkün olmadığında, ancak doğru bir analitik model mevcut olduğunda iyi bir alternatiftir (Tidriri ve diğ., 2016, s.64). Bu yaklaşımlarda olağan diferansiyel denklemler ve gerçek sonuçlarla ilgili modelin farklı unsurları kullanılır. Giriş ve çıkış sinyallerini kullanarak parametre tahminleri, durum tahminlerini üretir. Olası arıza koşullarını belirlenir ve yararlı bilgiler çıkarılır.

Birçok gerçek dünya uygulaması, doğru bir model geliştirmek için çok karmaşıktır. Bu nedenle modele dayalı hata tespiti ve teşhis yaklaşımlarının uygulanması pratik değildir. Bu modeller alan uzmanları tarafından oluşturulur. Uzmanlar, belirli bir gerçek dünya sisteminin fiziksel süreci ve bu sistemleri modelleme becerileri hakkında bilgi sahibi olmalıdır. Bir sistemi modelledikten sonra doğrulamak için büyük bir veri kümesine ihtiyaç duyulur.

Fiziksel bir model yaratmak, gerçek dünya sistemini çok iyi anlamayı gerektirir. Bu modellerin dezavantajları arasında yüksek maliyetleri ve bileşen uzmanlığı vardır. Bu da diğer bileşen türlerine uygulanamayacakları anlamına gelir. İyi bir doğrulukla fiziksel bir model oluşturmak çok zordur.

Otomasyon derecesinin önemli ölçüde büyümesiyle modern tesislere monte edilen önemli sensörler ve aktüatörler çok sayıda işlem verisi üretir. Sonuç olarak elde edilen sürecin veya fiziksel modelin ihtiyaç duyduğu ön bilgiyi gerektiren geleneksel model tabanlı yaklaşımlar, özellikle karmaşık büyük ölçekli sanayi için pratik değildir (Yin, Li, Gao ve Kaynak, 2014, s.657).

Karmaşık sistemler için doğru bir model elde etmek mümkün değildir. Bu nedenle model tabanlı tekniklerin performansları birçok gerçek uygulamada azalır. Model tabanlı tekniklerin bir diğer dezavantajı, farklı uygulamalar için farklı modellerin oluşturulması gereğidir. Bu nedenle model tabanlı teknikleri farklı endüstriyel bileşenlere uygulamak zordur.

Veri odaklı yaklaşımlar, izlenen makineyi modellemek için herhangi bir fiziksel denklem gerektirmemektedir. Bu yaklaşımlar, ampirik tabanlıdır ve örüntü tanıma algoritmaları kullanarak makinelerin davranışını doğrudan verilerden öğrenir. İlk aşama olarak veri odaklı modeli eğitmek için veri etiketleri gereklidir. Veri etiketleri, makinenin durumunu tanımlamak için kullanılır ve örüntü tanıma algoritmaları, verilerdeki makinenin farklı koşullarıyla ilişkili desenlerini tanıyabilir. Eğitildikten sonra veriye dayalı modeller, gerçek durumu bilmeden bir makine durumunu tahmin etmek için kullanılabilir.

Bu yöntem, doğası gereği eğitilen model dışındaki makine koşullarıyla karşılaştığında yararlı olmamaktadır. Diğer yandan, sistem bilinen sınırlar dâhilinde çalıştığı sürece teşhis tekniğinin sistemin hatalı koşullarını bulması beklenir. Eğitim seti, modelin performansının belirlenmesinde direkt rol oynar. Veriye dayalı karar süreçleri tarafından kullanılan çeşitli algoritmalar bulunmaktadır ve kapsamlı bir literatüre sahip olgunlaşmış bir alandır. Bu yaklaşım caziptir çünkü sistemin fiziksel modeli ile ilgilenmemektedir.

Veri odaklı bir modelin performansı genellikle fiziksel modellerden daha yüksektir. Fiziksel modeller birçok varsayım gerektirir ve karmaşık makineler için bu

varsayımları belirlemek zor bir süreçtir. Bu nedenlerle veri odaklı yaklaşım daha fazla popülerlik kazanmaktadır.

Veri odaklı yaklaşım, karmaşık gerçek dünya uygulamalarında kullanılabilir. Literatürde arıza tespiti ve teşhisi problemlerini çözmek için veri odaklı yaklaşım için çok sayıda teknik bulunmaktadır. Arıza teşhisi için kullanılan algoritmalar, makinenin durumunun temel gerçekliğinin bilindiği eğitim verilerini kullanarak, izlenen makinenin veri özellikleri ile arıza modları arasındaki ilişkileri öğrenebilir. Teşhis modeli eğitildikten sonra eğitim verilerinde görülen herhangi bir arıza modunu teşhis etmek için kullanılabilir.

Oluşturulan teşhis modelleri, arıza etiketinin bilindiği farklı hata durumlarına ait verilerle eğitilir. Modeller, farklı arıza modlarıyla ilgili verilerdeki kalıpları tanımlayabilir. Eğitimden sonra modeller etiketlenmemiş veriler için en olası arıza modunu teşhis etmek için kullanılabilir.

Örüntü tanıma şemasına dayanan genel bir teşhis yöntemi ilk olarak edinilen fiziksel ölçümden sayısal özellikleri hesaplanır. Gizli örüntüleri vurgulamak ve bilgileri sıkıştırmak için bir özellik azaltma prosedürü uygulanır. Farklı arıza sınıflarının tanımlandığı bir sınıflandırma aşaması ile sonuçlandırılır (Prieto, Cirrincione, Espinosa, Ortega ve Henao, 2012, s.3399).

Veriye dayalı arıza tespiti ve teşhisi, veriye dayalı ve çok değişkenli özellikler sayesinde endüstriyel uygulamada yaygın olarak kabul edilmektedir (Qin, 2012, s.221). Veriye dayalı yöntemler, sürecin normal çalışma sınırları içinde olmayan yeni örnekleri tespit etmek için geçmiş kontrol verilerini kullanılır. En dikkat edilmesi gereken nokta normal veri kümelerinin seçimidir.

Eğitim verilerinde daha önce görülen desenlerden çok farklı bir düzen oluşursa arıza modu doğru şekilde performans gösteremeyebilir. Bu durumda, oluşan arıza modu büyük olasılıkla yeni bir durumu ifade etmektedir ve eğitim verilerinde bulunmamaktadır. Yeni bir arıza deseni olup olmadığını belirlemek için denetimsiz öğrenme yöntemlerinden kümeleme tekniği uygulanabilir.

İşletmelerde üretimin kesintisiz devam etmesi istenilen bir durumdur. Arıza teşhisi ile amaç, sistem bileşenlerinin arızalarını erken aşamada tespit edip uygun bakımın yapılmasıdır. Her sistem için izlenmesi gereken bileşen farklılık göstermektedir. Durum

izleme ve arıza teşhisi ile bir sistemden gerekli verileri topladıktan sonra arıza ilgili model oluşturulmalıdır.

Arıza teşhis sistemleri, üretim sektörüne sağladıkları faydalarla çeşitli endüstriyel uygulamalar için fırsat oluşturmaktadır. Üretim tesislerinde, proses süreçlerinde oluşabilecek arızaların temel nedenini teşhis etmek için kullanılmaktadır. Temel neden bilgileri, uygun bakım işlemlerini önceden yapmak ve yüksek kalitede üretilmiş parçalar sağlamak için sorunun kaynağını tanımlamak için kullanılabilir olanağı sağlamaktadır.

Veri toplama teknolojisindeki hızlı büyüme ve ilerlemelerle makine sistemlerine monte edilen çeşitli sensörler kullanılarak uzun süreli, sürekli ölçümler elde edilebilir. Arızaları teşhis etmek ve arıza gelişmelerini tahmin etmek için kullanılan farklı sensörlerden çok sayıda durum izleme verisi elde edilebilmektedir. Analiz için çok boyutlu sinyalleri birleştirmek için birçok teknik geliştirilmiştir.

Bakımı iyileştirmenin bir yolu, bileşen sağlığı ve performansının kritik göstergelerini ölçen durum izlemeyi kullanarak daha öngörücü hale getirmektir.

Arıza teşhisinin temel amacı, performans bozulmasının erken aşamalarındaki arızalarını bulmak ve sistemin anormal koşullar altında çalışırken bakımı için planlamasını yapmaktır. Arızaların başlangıcında teşhis edilmesi çok önemlidir; planlanmamış makine duruş süreleri, ürünün son teslim tarihlerini geciktirebilir ve ağır mali kayıplara neden olabilir. Rulman, stator, indüksiyon makinelerindeki kırık rotor, uç halka hataları, eksantriğe bağlı arızalar en önemli ve dikkat edilmesi gereken hatalardır (Nandi, Toliyat ve Li, 2005, s.719).

3.2 Titreşim Verisi ile Arıza Teşhisi

Üretimde kullanılan makinelerde belli arızalar oluştuğunda makineler, bu arızalara yönelik olarak tepki oluşturmaya başlar. Bu tepkilerin en önemlilerinden biri de titreşim sinyalleridir. Titreşim sinyalleri, makinelerin mekanik aksamalarında meydana gelen olaylar hakkında bilgi içerir. Titreşim sinyallerinin analiziyle arızalar çok ciddi boyuta gelmeden önce tanımlanabilir.

Titreşim tekniği, makine durumunun izlenmesi için en sık kullanılan tekniktir. Çalışma koşulunu değiştirmeden makinedeki titreşim sinyalinin değişmesi, makinenin sağlık durumunun değişmesi anlamına gelebilir. Titreşim sinyalleri tipik olarak rulman,

dişli kutuları, pistonlu bileşenler ve yakınlarında meydana gelen kusurlar tarafından üretilir.

Titreşim sinyallerinin zaman, frekans veya modsal alanlardaki özelliklerinin analiziyle makinenin hasar veya bozulmayı gösterebilecek değişiklikleri tespit edilebilir. Tespit metodolojisi, geçmiş zaman verilerine veya spektrumlara uygulanan örüntü tanımaya dayanır (Carden ve Fanning, 2004, s.355). Titreşime dayalı durum izleme uygulamasının sanayi sektöründe artışı, veri işleme ve analiz tekniklerinin yanı sıra sensör teknolojilerinin de gelişimine yansımıştır.

Titreşim ve akustik emisyon (AE) sinyallerinin kullanımı, dönen makinelerin durum izlemesi alanında oldukça yaygındır. Normal ve hatalı koşullarda çalışan bir makinenin sinyalleri karşılaştırılarak kütle dengesizliği, rotor sürtünmesi, şaftın yanlış hizalanması, dişli hataları ve yatak hataları gibi arızaların tespiti mümkündür (Samanta, 2004, s.626)

Titreşim analizi ile çeşitli arıza türlerinin teşhisi yapılabilir. Rulmanlar ve dişliler gibi dönen bileşenler, birçok endüstriyel makinede en kritik bileşenler olarak görülmektedir. Heng ve Nor (1998) istatistiksel analiz yöntemi kullanılarak rulman yatağındaki arızaları tespit etmek için ses basıncı ve titreşim sinyallerinin analizi üzerine bir çalışma ortaya koymuşlardır. Orhan ve diğerleri (2006) çalışmalarında, gerçek çalışma koşullarında bulunan makinelerde zaman içinde oluşan arızaları spektral analiz ile belirlemişlerdir. Bunlardan yola çıkılarak titreşim analizinin fabrikalarda kestirimci bakım için avantaj sağladığı belirtilmiştir.

Titreşim analizi, dönen ekipman bakımı için bilinen en iyi yöntemdir. Titreşim tabanlı izleme teknikleri, hem zaman hem de frekans alanlarında rulman kusurlarının tespiti ve teşhisi için yaygın olarak kullanılmaktadır. (Saimurugan, Ramachandran, Sugumaran ve Sakthivel, 2011, s.3819). Titreşim temelli rulman durumu izleme, geniş çapta incelenmiş ve planlanan birçok bakım yönetiminin kabul görmüş bir tekniği haline gelmiştir (Randall ve Antoni, 2011, s.486).

Makineler farklı arıza durumları için farklı titreşim spektrum modelleri oluşturur. Titreşim analizi, makinenin iç parçalarını fiziksel olarak açmadan kontrol etmemizi sağlar. Ayrıca makinenin genel durumunu izlemek açısından titreşim sinyallerinden

çeşitli karakteristik özellikler gözlemlenebilir. Edinilen farklı yapıdaki sinyaller analiz edilerek bir sınıflandırma problemine dönüştürülebilir.

Kütle dengesizliği, rotor sürtünmesi, şaftın yanlış hizalanması, dişli hataları ve yatak hataları gibi makine arızalarının tespiti; hatalı koşullar ve sağlıklı çalışan bir makinenin titreşim sinyalleri karşılaştırılarak yapılır. Bu sinyaller ayrıca çevrimiçi izleme sistemi aracılığıyla makine bileşenlerinin yeni arızalarını tespit etmek için de kullanılabilir ve büyük hasarların oluşma olasılığını azaltır (Samanta, Al-Balushi, 2003, s.317).

Uygulanan sensör teknolojisi, frekans aralığı ve çalışma koşulları dikkate alınarak seçilebilir. Her bileşenin geometrisi ve makinenin dönme hızı, bileşenlerin frekansları üzerine etki eder. Titreşim sinyali analizi, makinenin teorik modellemesi veya ölçüm yoluyla elde edilen frekanslar ile beklenen hatalar arasındaki ilişkiyi kullanır. Böylece arıza nedeni ve ciddiyeti belirlenebilir.

İzleme için titreşim sinyallerini kullanmanın ardındaki prensip, mekanik sistemlerde çalışma sırasında titreşen bileşenleri içerir. Arızalar geliştiğinde, bazı sistem dinamikleri değişir, bu da titreşim modellerinde önemli sapmalara neden olur. Uygun veri analizi algoritmaları kullanılarak hatalı bileşenlerin neden olduğu titreşim imzalarındaki değişiklikleri tespit etmek ve makinelerin durumu hakkında karar vermek mümkün olabilmektedir (Yen, Lin, 2000, s.650).


Dönen makinelerin arıza teşhisinde, makinenin performansını izlemek için titreşim sinyalleri fazlaca tercih edilmekte, makinede arıza veya bozulma olup olmadığına böylece karar verilebilmektedir. Sinyal analizi için birçok yararlı teknik bulunmaktadır. Bunlar zaman alanı, frekans alanı ve zaman-frekans alanı olarak sınıflandırılabilir (Henriquez ve diğ., 2014, s.643) Frekans alanı analizinde en sık kullanılan teknik, Hızlı Fourier Dönüşümü (HFD) kullanılarak yapılan spektrum analizidir (Liu ve diğ., 2010; Wang ve diğ., 2016).

Zarf analizi gibi diğer teknikler de yaygın olarak kullanılmaktadır (Yu, Cheng ve Yang, 2005; Kang, Kim, Wills ve Kim, 2015). Kısa Süreli Fourier Dönüşümü (KSFD) ve Wigner-Ville dağılımı arıza teşhisi için uygulanan en popüler zaman-frekans dağılımlarıdır (Al-Badour, Sunar, Cheded, 2011; Tang, Liu ve Song, 2010; Li, Zheng ve Tang, 2006).

Sinyal işleme yöntemlerinde hata paterni, dalgacık dönüşümü (DD), ampirik mod ayrışması (AMD) ve spektral basıklık (SB) gibi gelişmiş sinyal işleme yöntemleri kullanılarak titreşim dalga formlarının özelliği veya arıza karakteristik frekansı tespit edilerek uygulanabilir (Antoni ve Randall, 2006; Liu ve Riemenschneider, 2006; Lei, Lin, He ve Zuo, 2013; Lou ve Loparo, 2004; Han, Jiang ve Wang, 2016; Wang, Xiang, Markert ve Liang, 2016; Yan, Gao ve Chen, 2014). Bu yöntemler operatörün çok fazla uzmanlık sahibi olmasını gerektirir.

Tüm bu yöntemler, zaman veya frekans alanında ham titreşim verilerinden kalıpları çıkarmak için yaygın olarak uygulanmaktadır.

Örüntü tanıma yöntemleri ile otomatik ve akıllı teşhisi gerçekleştirebilen veri odaklı teknikler, son yıllarda büyük ilgi görmekte ve gelişmektedir. Genel bir arıza teşhisi modeli Şekil 7’de gösterilmiştir. Veri toplama adımı olan birinci adımda, ilgili makineye bir sensör monte edilmektedir. Sensör aracılığıyla işlenecek ham veriler toplanmaktadır. İkinci adım; toplanan titreşim verisinin üzerinde filtreleme, özellik seçimi ve çıkarımı gibi ön hazırlık işlemlerini içermektedir. Son olarak bir hatanın algılanmasını ve tanımlanmasını içeren arıza teşhisi, veri sinyallerinden çıkarılan özellikleri kullanarak farklı sınıflara ayırmak için bir sınıflandırıcı algoritması kullanılmaktadır (Worden, Staszewski ve Hensman, 2011, s.11).



Şekil 7: Titreşim Tabanlı Arıza Teşhisinin Genel Yapısı


3.3 Arıza Teşhisinde Makine Öğrenmesi Temelli Yaklaşım

Yüksek derecede gelişmiş ekipman ve otomasyon sayesinde modern endüstriyel tesislerde proses izleme için veriye dayalı yöntemlerin kullanılması arttırılmıştır. Modern büyük ölçekli sanayi tesisleri, çeşitli makine ve cihazlara sahip karmaşık sistemlerdir.

İşletmelerde farklı makine ve cihazların durumunun izlenmesi, arızaların erken ve doğru teşhisi arıza süresini en aza indirdiğinden tesis operasyonlarının güvenliğini artırır. Optimum kontrol ve bakım stratejileri için karar verme desteklenir. İşlem verimliliğini artırarak bakım ve işletme maliyetleri azaltılır. Hatalı ve verimsiz ekipmanın çalışmasını önler. Kapatma ve yeniden başlatma işlemi sırasında tüketilen enerjinin bir sonucu olarak planlanmamış duruşlarla ilişkili maliyetin de azalmasını sağlar. Bunlar, arıza tespit ve teşhisinin bakım maliyetlerinin düşürülmesine, tesis güvenliği ile kullanılabilirliğinin iyileştirilmesine nasıl katkıda bulunabileceğinin açık örnekleridir.

Üretim süreçlerinden çıkarılan veri miktarı, algılama teknolojilerinin çoğalması sayesinde katlanarak artmıştır. İşlendiğinde ve analiz edildiğinde veriler üretim süreci, üretim sistemi ve ekipmanlar için değerli bilgi sağlar. Endüstrilerde, ekipman bakımı kesintisiz üretim için anahtar rol oynayarak ekipmanın çalışma süresini ve verimliliğini etkiler. Ekipman arızalarının belirlenmesi ve çözülmesi üretim süreçlerinde kapanmayı önlemektedir. Makine öğrenmesi yöntemleri, fabrika katındaki üretim hatlarını oluşturan ekipmanlardaki arızaları önlemek için kestirimci bakım uygulamalarında umut verici bir araç olarak ortaya çıkmıştır (Carvalho ve diğ., 2019, s.1).

Teşhis doğruluğunu en üst düzeye çıkarmak için uygun yöntemi seçmek önemlidir. Literatürde farklı bozulma tipleri için farklı yöntemler ile uygulanmış çalışmalar bulunmaktadır. Makine öğrenmesi modelleri ile arıza teşhisinin genel yapısı Şekil 8’de verilmiştir.



Şekil 8: Makine Öğrenmesi Tabanlı Arıza Teşhis Modelinin Genel Yapısı

Günümüzün karmaşık üretim sistemlerinin ortaya çıkardığı kompleks zorlukların üstesinden gelmek için makine öğrenmesi yöntemleri iyi bir tercihtir. Bu yöntemler, farklı tür ve kaynaklardaki verilerde oldukça karmaşık ve doğrusal olmayan kalıpları bulabilmektedir. Ham veriler daha sonra tahmin, algılama, sınıflandırma, regresyon veya öngörü için kullanılabilir (Wuest ve diğ., 2016, s.25).

Widodo ve Yang (2007) çalışmalarında makine durumunun izlenmesi ve teşhisinde DVM'nin etkisini araştırmışlardır. DVM'nin genelleme konusundaki yüksek performansının, makine durumu izleme ve tanılamada için de geçerli olabileceğini ifade etmişlerdir.

Destek vektör makineleri (DVM), seçilen özellik alanı kullanılarak makine sağlığı durumunu sınıflandırmak için iyi bir algoritmadır. Rulman arıza teşhisi yöntemi, bulanık entropi ve destek vektör makineleri kullanılarak uygulanmıştır (Zheng, Pan ve Cheng, 2017, s.746). Hata örnekleri az da olsa genellemeyi iyi gösteren yapısal risk minimizasyonuna dayanan DVM algoritmasının, turbo pompa rotor test yatağındaki çok sınıflı arızaları doğru ve etkili bir şekilde teşhis edebildiği görülmüştür (Yuan ve Chu, 2006, s.950). Otomotiv şanzımanındaki arızaları tespit etmek için DVM tabanlı bir model ortaya konulan çalışmada, dört vites kutusundan iki farklı hızda ve yük koşullarında elde edilen titreşim verileri DVM modelini eğitmek için kullanılmıştır. Elde edilen sınıflandırma başarısı %90 civarında yüksek bir orandadır (Praveenkumar, Saimurugan, Krishnakumar ve Ramachandran, 2014, s.2092).

Titreşim sinyallerinden çıkarılan zaman, frekans ve zaman frekansı alanlarındaki özellikler ortamda genetik algoritmalar, rastgele ormana dayalı bir sınıflandırma problemine dönüştürülmüştür. Yapılan çalışmada, özellik seçiminin arıza teşhis modellerinin iyi performans göstermesi için önemli olduğu vurgulanmıştır (Cerrada ve diğ., 2016, s.87).

Shen, Wang, Kong ve Peter (2013) çalışmalarında, toplanan sinyalleri farklı ayırışma derinliklerinde dalgacık paket dönüşümü ile işlemişlerdir. İstatistiksel özellikler çıkarıldıktan sonra özellik alanının boyutunu düşürmek için mesafe değerlendirme tekniği kullanılmıştır. DVM tabanlı model hem rulmanların hem de dişlilerin hata düzeylerini ayırt etmede yüksek doğruluk sağlamıştır.

DVM ve YSA'nın karşılaştırıldığı çalışmada, rulman arızasının tespiti için iki yöntem kullanılmıştır. Özellikler, istatistiksel teknikler kullanılarak zaman alanı titreşim sinyallerinden çıkarılmıştır. Prosedür, küme üyelik değerlerini üretmek için yoğunluk tabanlı bir küme kullanan filtreleme algoritması ile en uygun özellik seçimini içermektedir. Yüklü veya yüksüz çeşitli hızlarda elde edilen farklı titreşim sinyallerinin rollerini araştıran çalışmada DVM'nin YSA'dan daha iyi sonuç verdiği belirtilmiştir (Kankar, Sharma ve Harsha, 2011, s.1885).

YSA'nın uygulandığı çalışmada zaman alanındaki titreşim sinyali segmentlerinden basit işlemlerle doğrudan çıkarılan özellikler kullanılarak rulman arıza teşhisi için sunulmuştur. Sonuçlar, arıza teşhisinde YSA'nın etkinliğini göstermektedir

(Samanta, Al-Balushi, 2003, s.317). Karar ağaçlarının YSA ile karşılaştırıldığı çalışmada altı farklı koşul için arıza teşhis modeli uygulanmıştır. Sonuçlar, karar ağaçlarının modelin eğitimi için daha az sürede daha yüksek doğruluk ile arızaları teşhis ettiğini ortaya koymaktadır (Sun, Chen ve Li, 2007, s.1300).

Tek ağaç sınıflandırıcısını geliştirmek için çok sayıda karar ağacı oluşturan yeni bir topluluk sınıflandırıcı olan rastgele ormana (RO) dayanan çalışmada, genetik algoritma ile birleştirilmiş hibrit bir yöntem sunulmuştur. RO tabanlı yöntemin hızlı işlem gücü, ağaç sınıflandırıcının özelliği ve makine arıza teşhisinde yüksek performansı gösterdiği belirtilmiştir (Yang, Di ve Han, 2008, s. 1724).

Palacios, da Silva, Goedel ve Godoy (2015) zaman alanındaki akım sinyallerinin genliklerini kullanarak Naif Bayes, K-en yakın komşu, DVM ve YSA yöntemlerini motor arıza teşhisi için kullanıp karşılaştırmışlardır. Flett ve Bone (2016) dizel içten yanmalı motor valf dizisi için bir arıza tespit ve teşhis sistemini geliştirdikleri çalışmada Naif Bayes, Yapay Sinir Ağları, Karar Ağaçları, K-en yakın komşu ve Lineer Diskriminant analizi dâhil beş sınıflandırma yönteminin sonuçlarını karşılaştırmışlardır.

Zhang, Wu, Yang ve Guan (2018)'ın çalışmalarında Naif Bayes algoritması rulman arıza teşhisi yöntemi olarak kullanılmıştır. Naif Bayes'in bağımsız varsayımlara dayanan yapısına karşın rulman verileri tamamen bağımsız değildir. Ancak bu durumun uygulanan hibrid yöntemlerle başarılı performans gösterdiği görülmektedir.

Yapay sinir ağlarının örüntü tanıma problemlerinde başarısı göz önüne alınarak yapılan çalışmada, çok katmanlı algılayıcı ağların eğitim modellerini güvenilir bir şekilde sınıflandırabildiği görülmüştür (Sorsa ve Koivo, 1993, s.848). Samanta (2004) zaman alanlı titreşim sinyallerinden genetik algoritma (GA) tabanlı özellik seçimine sahip YSA'lar ve DVM'ler olmak üzere iki sınıflandırıcı kullanılarak dişli durumunun tespiti için bir prosedür sunmuştur. Giriş özelliklerinin seçimi ve uygun sınıflandırıcı parametreleri GA tabanlı bir yaklaşım kullanılarak optimize edilmiştir. Normal ve hafif yükler altında düşük ile yüksek örnekleme hızlarında elde edilen farklı titreşim sinyallerinin etkisi araştırılmıştır. GA olmadan DVM'lerin sınıflandırma doğruluğunun YSA'lardan daha iyi olduğu tespit edilmiştir.

Belirli bir girdi ile beklenen çıktı arasındaki ilişkiyi öğrenen çok çeşitli makine öğrenmesi yöntemleri vardır. Bununla birlikte bu yöntemlerin iki eksikliği vardır.

Performansları, insan uzmanlığı ile çıkarılan özelliklerinin seçimine bağlıdır. Bu özellikleri önceden tasarlamak zordur ve genel bir varsayım altında iyi çalışırlar. Eğitim ve test verileri aynı dağıtımdan alınmıştır ancak bu varsayım birçok mühendislik uygulamasında başarısız olabilmektedir (Wen, Gao ve Li, 2017, s.136).

3.4 Arıza Teşhisinde Derin Öğrenme Temelli Yaklaşım

Modern endüstrilerin gelişim ile birlikte teknoloji yoğun üretim işletmelerinin sayısı giderek artmaktadır. Endüstriyel makinelerde ve üretim sistemlerindeki karmaşıklığın artması arıza koşullarını geleneksel yöntemlerle zamanında tanımlamayı ve tahminlemeyi zorlaştırmaktadır. Geleneksel makine öğrenmesi teknikleri verilerin ham hallerini doğrudan kullanma yetenekleri bakımından sınırlıdır (Lecun ve diğ., 2015, s.436).

2006 yılından bu yana, derin öğrenme hızla artan bir araştırma yönü haline gelmiştir. Nesne tanıma, görüntü segmentasyonu, konuşma tanıma ve makine çevirisi gibi çok çeşitli alanlarda son teknoloji performansları kullanmaktadır. Modern üretim sistemlerinde, düşük maliyetli sensörlerin yaygın kullanımı ve internete bağlanması sayesinde veri odaklı makine sağlığı izlemesi popülerlik kazanmıştır (Zhao ve diğ., 2019, s.213).

Derin öğrenme, veriler içindeki önemli ilişkileri otomatik olarak öğrenme yeteneğine sahiptir. Derin inanç ağının (DİA) (Hinton ve diğ., 2006) kullanılmasından bu yana, DİA'lar ve diğer derin öğrenme yöntemleri büyük veri işleme ve analizi için popüler bir yaklaşım haline gelmiştir.

Derin öğrenme, farklı çekirdekler seçerek veya parametreleri uçtan uca optimizasyon yoluyla ayarlayarak özellik öğrenme ve model ayarlamasını tek bir modelde birleştirir. Birçok gizli katmana sahip sinir ağlarının derin mimarisi aslında çok seviyeli doğrusal işlemlerdir. Karmaşık doğal yapıları bulmak için her katmanın gösterimini (veya özelliklerini) orijinal girdiden daha yüksek katmanlarda soyutlanmış gösterime aktarır. Genel olarak derin öğrenme, minimum insan çıkarımına sahiptir. Uçtan uca bir öğrenme yapısıdır ve parametreleri birlikte eğitilir (Wang ve diğ., 2018, s.146).

Makine öğrenmesi ve sinyal işleme tekniklerinin çoğu sığ yapıli mimarilerden faydalanmaktadır. Bu mimariler tipik olarak tek bir doğrusal olmayan özellik

dönüşümleri katmanı içerir ve bunlar uyarlanabilir doğrusal olmayan özelliklerin çoklu katmanlarından yoksundur.

Geliştirilen başarılı derin öğrenme teknikleri iki yeni özelliği paylaşmaktadır. Modelin genellikle ayrımcı görevleri yerine getirmek için ek bir üst katman ile üretken doğası vardır. Diğer özelliği ise girdi yapılarının ve düzenliliklerin çıkarılması için büyük miktarlarda etiketlenmemiş eğitim verilerinin denetimsiz bir ön eğitim adımı olarak kullanılabilmesidir (Deng, 2014, s.3). Makine öğrenmesi ve derin öğrenme ile arıza teşhisinin genel yapısı aşağıdaki şekilde gösterilmektedir. Şekilde görüldüğü üzere derin öğrenmede özellik çıkarımı işlemi otomatik olarak bütünsel bir yapı içinde gerçekleşmektedir. Makine öğrenmesi yönteminde ise insan müdahalesi ile özellik çıkarımı ve seçimi yapılmaktadır.



Şekil 9: Arıza Teşhisi Yapısı (a) Makine Öğrenmesi (b) Derin Öğrenme

Derin öğrenme, tahmine dayalı gücü geliştirmek için verilerden yararlı ve önemli özellikler sağlama yeteneğine sahiptir (Bengio, Courville ve Vincent, 2013, s.1798). Çok katmanlı yapısı sayesinde büyük verileri işleme ve gizli bilgileri çıkarma yeteneğine sahiptir. Doğrusal olmayan işlemler gerçekleştirebilir.

AlphaGo tarafından yakın zamanda elde edilen başarı, büyük veri işleme ve özellik öğrenimi için derin öğrenmenin gücünü göstermiştir (Silver ve diğ. 2016, s.484). AlphaGo, dünyadaki en iyi insan Go oyuncusunu yenmiştir. Büyük hacimli veri işleme ve özellik öğrenimi kabiliyeti ile derin öğrenmenin avantajı ortaya konulmuştur.

Son zamanlarda makine öğrenmesinin bir alt alanı olan derin öğrenme örüntü tanımada yeni bir yöntem olarak ortaya çıkmıştır(Gan, Wang ve Zhu, 2016, s.92). Derin öğrenme ham titreşim sinyalleri ile (Chen ve diğ., 2016, s.1) makine arızası teşhisi için kullanılmıştır. Derin öğrenme büyük sınıflandırma sorunlarına odaklanmış olsa da derin öğrenmenin tahmin problemlerini çözmede de başarılı olduğu kanıtlanmıştır. Derin öğrenme, arıza teşhisinde mekanik büyük verileri işlemek için cazip bir seçeneği temsil eder çünkü derin öğrenme beceri, zaman ve deneyim gerektiren özellikleri otomatik olarak çıkarma yeteneğine sahiptir.

Derin öğrenme, verilerdeki hiyerarşik özelliklerin veya temsillerin hedef verilerden nasıl hesaplanacağı ile ilgilenir. Derin öğrenme algoritmaları denetimli ve denetimsiz olmak üzere çoklu katmanları ve çeşitli sinir ağları türlerini kapsamaktadır.

Literatürde makine arıza teşhisi amacıyla oto kodlayıcılar kullanılarak çeşitli çalışmalar yapılmıştır. Bununla birlikte odak noktaları özelliklerin daha iyi temsiliyi ortaya çıkarmaktır. Örneğin, Tao, Zhang, Yang, Wang ve Lu (2015), yığılmış oto kodlayıcı ve softmax regresyonuna dayanan hata teşhisi için derin bir sinir ağı algoritması önermişlerdir. Jia, Lei, Lin, Zhou ve Lu (2016), büyük arıza verilerini işlemek ve dönen makineler için otomatik olarak doğru teşhis sonuçları sağlamak için derin sinir ağına dayalı akıllı bir yöntem önermiştir. Önerilen yöntem farklı koşullarda ölçülen ve kaydedilen rulman yatak verileri ile planet dişli kutu verileri üzerinde kullanılmıştır. Arıza teşhis sonuçları geleneksel yöntemlere göre yüksek doğruluk sonuçları vermiştir.

Asenkron motor arıza teşhisi için seyrek oto kodlayıcı(SOK) tabanlı yaklaşım ile asenkron motorların farklı çalışma koşulları üzerinde ayırt edebilen ham verilerden doğrudan özellikler öğrenebilir. Gürültü gidericinin SOK ile entegre edildikten sonra öğrenilen özellikler sinir ağı ile eğitilerek hatalar tanımlanmıştır (Sun ve diğ., 2016, s.177).

Shao, Jiang, Lin ve Li (2018), makaralı rulmanların akıllı arıza teşhisi için topluluk derin oto kodlayıcıları adıyla yeni bir yöntem önermişlerdir. Çalışmalarında farklı özelliklere sahip karşılık gelen oto kodlayıcıları tasarlarken 15 farklı aktivasyon fonksiyonu kullanmışlardır. Derin öğrenme ile topluluk öğrenme yöntemlerinin birleştirilmesi açısından ilgi çekici bir çalışmadır. Xueyi ve diğerleri (2019) çalışmalarında artırılmış derin seyrek oto kodlayıcı adlı yeni bir yöntem önermişlerdir.

Çalışmada dişli arızası teşhisi, önerilen yöntemle ham verilerden otomatik olarak çıkarılan özellikler yardımıyla gerçekleştirilmiştir. Wang ve diğerleri (2019), güç sistemlerinde arıza teşhisinin doğruluğunu geliştirmek için destek vektör makinesi ve temel bileşen analizi ile YSOK tabanlı bir ağ önermişlerdir. YSOK'un katman yapısı ve özellik çıkarım yapısının etkili bir yaklaşım olduğu ifade edilmektedir.

Derin boltzmann makineleri, derin inanç ağları ve yığılmış oto kodlayıcıların uygulandığı çalışmada, sınıflandırma doğrulukları %99 seviyelerindedir. İki farklı yöntemle yapılan sınıflandırmada ham veriye dayalı olanının girdisinin yeterli olmadığı ve derin sinir ağları için de özellik çıkarılmasının gerekli bir adım olduğu ifade edilmektedir (Chen ve diğ., 2017, s.333). Geleneksel tanı algoritmalarına kıyasla temel avantajı, arıza özelliklerinin elle tasarlanmış veya sinyal işleme teknikleri hakkında önceden bilgi sahibi olmak yerine genel amaçlı bir öğrenme prosedürü ile öğrenilmesidir (Lu ve diğ., 2017, s.387).

Ham zaman verilerine dayalı bir çalışmada, özellik seçimi ve sinyal işleme olmadan ham zaman serisi sensör verilerini doğrudan tanıyabilmektedir. Ayrıca verinin zamansal tutarlılığından da yararlanır. İlk olarak sensörler tarafından toplanan ham zaman serisi eğitim verileri, DSA'nın maliyet fonksiyonu minimum değeri elde edinceye kadar DSA'yı eğitmek için kullanılır. İkinci olarak test verileri, yerel zaman serisi verilerinde DSA'nın sınıflandırma doğruluğunu test edebilir. Deneysel sonuçlar, rulman hatalarının sınıflandırma hassasiyetinin% 100 olabileceğini göstermektedir. (Zhang, Peng, Wu, Yao ve Guan, 2017, s.15).

Sensörler tarafından toplanan ham zaman serilerinin doğrudan kullanılabileceği görülmektedir. Geleneksek makine öğrenmesi yöntemleri ham titreşim verilerinin genellikle zaman alanı ve frekans alanı özelliklerini çıkarmaya yönelmektedir. Bu yöntemler uzman bilgisi gerektirmektedir.

Derin öğrenmenin performansının doğrudan ham veriler ile test edilmesi, geleneksel yöntemlerden farklı bir seçenek sunmaktadır. Birden fazla oto kodlayıcıların üst üste yığılması ve son bir sınıflandırma katmanı ile derin bir sinir ağı oluşturulabilmektedir. Birden fazla oto kodlayıcının kullanılması ham verilerin temsiline daha iyi sağlanarak ayırt edici bilgilerin çıkarılmasını ve daha düşük boyutta çalışılmasını

sağlamaktadır. Daha düşük boyutlu çalışma özellikle girdi setininin büyük olduğu endüstriyel uygulamalarda performansı arttırabilmektedir.



DÖRDÜNCÜ BÖLÜM

GELİŞTİRİLEN MODELİN RULMAN ARIZA TEŞHİS DENEY SETİ İLE TEST EDİLMESİ

4.1 Rulman Deney Verisi

Günümüzde, dönen makineler endüstriyel sistemlerde önemli bir rol oynamaktadır. Dönen makineler petrokimya tesisleri, havacılık, kimya ve ev aletleri endüstrileri gibi birçok alanda en kritik ekipmanlar arasında yer almaktadır. Dönen makineler; stator, rotor, şaft ve rulmanlar gibi çeşitli elemanlardan oluşmaktadır (Boudiaf, Moussaoui, Dahane ve Atoui, 2016, s.271). Rulman, dönen makine arızalarının birincil kaynağıdır.

Rulmanlar, dönen ekipmanlarda en yaygın olarak kullanılan mekanik parçalardır ve makinelerdeki arızaların birincil nedenidir. Bu tür arızalar maliyetli kapanmalara, üretimde düşüşlere ve verimsizliklere yol açabilmektedir.


Makaralı rulman arızası, makine dönüşünün bozulmasına neden olan önemli bir faktördür. Zamanında tespit edilmezse tüm sistemin çökmesine ve büyük ekonomik kayıplara yol açabilmektedir (Lu, Wang, Yang ve Zhang, 2015, s.2427). Bu nedenle rulman hata teşhisi konulu araştırmalar son yıllarda yoğun ilgi görmektedir. Mekanik titreşim sinyali, rulman hataları ile ilgili olayları anlamak için en etkili ve zengin bilgi kaynaklarından birisidir (Boudiaf ve diğ., 2016, s.271).

Makine duruş sürelerini en aza indirmek amacıyla arızaları erken aşamalarında tespit etmek ve olası arızalara ilişkin uyarılar sağlamak için hassas ve sağlam bir izleme sistemine ihtiyaç vardır. Böyle bir izleme sistemi bakım maliyetlerini düşürebilir, yıkıcı arızaları önleyebilir ve makinenin kullanılabilirliğini artırabilir. Etkili bir teşhis ve prognostik sistem geliştirmek için rulman hareketlerinin kapsamlı bir şekilde anlaşılması gerekmektedir.

Dönen makinelerin önemli bir parçası olan makaralı rulmanlar sadece makineyi desteklemekle kalmaz, aynı zamanda tekerleklerin de dönmesini sağlar. Makaralı rulmanlarda hata oluştuğunda makinenin güvenilirliğini düşürebilir veya makineyi çalışamaz hale getirebilir. Bu durum çeşitli kazalara neden olabilecek titreşim ve gürültüye neden olabilmektedir (Zheng ve diğ., 2017, s.746).

Makine öğrenmesi tabanlı rulman arıza teşhisi son yıllarda yaygın olarak uygulanmaktadır. Bu yaklaşım kullanılırken çıkarılması gereken özellikler için insan uzmanlığı ve sinyal işleme teknikleri gerekmektedir(Hoang ve Kang, 2019, s.328). Derin öğrenme ile birlikte insan uzmanlığı gerektirmeyen algoritmalar da sıklıkla kullanılmaya başlanmıştır.

Çalışma kapsamında kullanılan rulman titreşim verileri Case Western Reserve Üniversitesi rulman veri merkezinden alınmıştır (Case Western Reserve University, 2011). Bu veriler rulman arıza teşhis alanında yaygın olarak kullanılmaktadır. Bu titreşim verilerini elde etmek için kullanılan test donanımı Şekil 10'da görülmektedir.



Şekil 10: Test Düzeneği (Case Western Reserve University, 2011).

Veriler, farklı çalışma yükleri ve yatak koşulları altında dönen rulmanlardan elde edilmiştir. Şekil 10'da gösterildiği gibi test standı 2 hp motordan (solda), bir tork transdüseri / kodlayıcıdan (ortada), bir dinamometreden (sağda) oluşmaktadır. Titreşim verileri ivmeölçerler kullanılarak toplanmıştır. Titreşim sinyalleri, kanal başına 12 K / s örnekleme oranına sahip 16 kanallı bir DAT kaydedici ile toplanmıştır. Arıza boyutları sırasıyla 0.007 inç, 0.014 inç ve 0.021 inç'tir. Titreşim verileri, 0, 1, 2 ve 3 hp'lik bir motor yükü için farklı motor hızlarında farklı rulman hatalarıyla kaydedilmiştir.

Sürücü uç yatağında 0 hp yük, 1797 dev / dak ve 1 hp 1772 dev/dak olmak üzere 2 farklı veri seti kullanılmıştır. Arıza boyutu olarak 0.007 inç seçilmiştir. Dört farklı arıza tipi (normal, bilya arızası, iç bilezik arızası ve saat 6 konumundaki dış bilezik arızası) içeren 12K örnekleme frekansında toplanana veri seti kullanılmıştır. Her veri türü için en az 121.000 örnek noktası bulunmaktadır. Motorun saniyedeki devir hızı ortalama 30 dev / sn'dir. Buradan yola çıkarak örnekleme periyodu, devir başına 410 örnek noktası olarak

belirlenmiştir. Zaman alanı özellikleri her 410 örnek için hesaplanmıştır. 7 milimetrelilik bir hata çapından 0 HP yük ve 1 HP yük ile toplanan ham sürekli titreşim sinyalinden toplam 1200 adet zaman serisi titreşim veri seti çıkarılmıştır. Daha sonra 1200 titreşim verisi seti, bir kısmı makine öğrenmesi modelinin eğitim aşaması olan giriş çıkış arasındaki ilişkiyi kurmak için kullanılmıştır. Geriye kalan kısım modelin testi için kullanılmıştır. Çalışmada her hata tipi için 300 örnek bulunmaktadır. Tablo 3 ve Tablo 4'te verilerin hata tiplerine göre dağılımı gösterilmektedir. Örneklerin %70'i makine öğrenmesi modelini sentezlemek için eğitim verisi olarak rastgele seçilirken %30'u eğitilmiş makine öğrenmesi modelini doğrulamak için kullanılmıştır.

Veri Tipi	Motor Yüğü	Arıza Çapı(inç)	Örnek Sayısı	Etiket
Normal (N)	0	0	300	NO
Bilya (B)	0	0.007	300	BO
İç Bilezik (IY)	0	0.007	300	IY0
Dış Bilezik 6 Yönünde (DY6)	0	0.007	300	DY0


Tablo 3: 0 HP Motor Yüğü, 1797 dev/dak Altındaki Örnek Dağılımı

Veri Tipi	Motor Yüğü	Arıza Çapı(inç)	Örnek Sayısı	Etiket
Normal (N)	1	0	300	N1
Bilya (B)	1	0.007	300	B1
İç Bilezik (IY)	1	0.007	300	IY1
Dış Bilezik 6 Yönünde (DY6)	1	0.007	300	DY1


Tablo 4: 1 HP Motor Yüğü 1772 dev/dak Altındaki Örnek Dağılımı

Farklı çalışma koşullarında bir saniyede içinde toplanan 410 adet zaman serisi verisinin yapısı şekil 11'de gösterilmiştir.


NO




BO



IB0



DB0



Şekil 11: 0 HP Motor Yüğü, 1797 dev/dak için zaman etki alanı titreşim sinyalleri



Şekil 12: 1 HP Motor Yüğü 1772 dev/dak için zaman etki alanı titreşim sinyalleri

4.2 Oluşturulan Modelin Uygulanması

Özellik çıkarma, desen sınıflandırma yapılandırmasında ve sınıfların tanımlanmasıyla ilişkili özelliklerin belirlenmesinde önemli bir parçadır. Özellik çıkarma, karmaşık verilerin boyutunu basit bir yapıya indirebilmektedir.


Özellik çıkarma yöntemleri, d boyutsallığının orijinal özellik uzayında m boyutsallığında ($m < d$) doğrusal veya doğrusal olmayan bir şekilde uygun bir alan uzayını belirlemektedir (Jain, Duin ve Mao, 2000, s.12). Anlamlı özellik çıkarımı ve seçimiyle etkili arıza teşhis ve prognoz performansı elde edilmektedir. Hatalı özellikler, arıza teşhis ve prognoz için uygulanan tekniklerin genel güvenilirliğini azaltarak gerçek hata durumunun tahmin sonucunu düşürebilmektedir

Yığılmış seyrek oto kodlayıcı, hata sınıflandırması için kullanılabilen ham sinyal verilerinden anlamlı özelliklerin çıkarılmasını sağlar. Çalışmamızda, iki gizli katmana sahip bir otomatik kodlayıcı yapısı kullanılmıştır. Gizli katmanlardaki nöron sayısı sırasıyla 256 ve 128'dir. Kodlayıcı etkinleştirme işlevi sigmoid, kod çözücü etkinleştirme işlevi relu olarak belirlenmiştir. Çalışmada kullanılan parametreler; her gizli birimin sayısı, seyreklik parametresi ve seyreklik ceza süresinin ağırlığı Tablo 5'te gösterilmiştir.


Parametreler	Değer
Girdi Sayısı	400
Çıktı Sayısı	4
Gizli Katman Sayısı	2
Her Gizli Katmandaki Nöron Sayısı	256,128
Seyreklik Parametresi	0.1
Seyreklik Parametresinin Ağırlığı	3
İş Boyutu	30

Tablo 5: Yığılmış seyrek oto kodlayıcı modelinin parametreleri

Makine öğrenmesi algoritmaları ve derin sinir ağı modelinde kullanılmak üzere titreşim sinyallerinden istatistiksel özellikler çıkarılmıştır. Elde edilen özellikler; ortalama, standart sapma, basıklık, çarpıklık, kök ortalama kare, maksimum genlik, minimum genlik, tepe faktörü ve etki faktörüdür. Çıkarılan özelliklerin hata tiplerine göre farklılıkları Tablo 6 ve Tablo 7’de gösterilmektedir.




Tablo 6: 0 HP Motor Yüğü, 1797 dev/dak için çıkarılan istatistiksel özelliklerin karşılaştırılması



Tablo 7: 1 HP Motor Yüğü 1772 dev/dak için çıkarılan istatistiksel özelliklerin karşılaştırılması


Şekil 13'te çalışmada uygulanan yöntemler bir akış şeması içinde gösterilmiştir.



Şekil 13: Önerilen Arıza Teşhis Modeli

Önerilen modelde iki farklı yöntem uygulanmıştır. Birinci yöntemde ham veriler doğrudan modelde kullanılırken ikinci yöntemde ham verilerden çıkarılan istatistiki özellikler kullanılmıştır.


İlk modelin yapısı Şekil 14'te gösterilmektedir. YSOK modeli için $h_1(x)$ birincil özellikleri ham girdiler kullanılarak ve $W(1)$ ağırlığının ayarlanmasıyla öğrenilir. Bu özellikler $h_1(x)$ ikinci seyrek otomatik kodlayıcı için giriş olarak kullanılır. Bu özellikler ve $W(2)$ ağırlık kullanılarak $h_2(x)$ ikincil özellikleri elde edilir. Bu ikincil özellikler, bir softmax sınıflandırıcısına ham girdi olarak veriler. Sonuç olarak model iki gizli katman ve bir son sınıflandırma katmanı (softmax) kullanılarak oluşturulmuştur.



Şekil 14: YSOK modeli

İkinci modelde uygulanan derin sinir ağında giriş katmanı, iki adet gizli katman ve çıkış katmanı bulunmaktadır. Şekil 15'te gösterilen yapıda girdi katmanı, ölçülen titreşim sinyallerinden çıkarılan istatistiksel özellikler ile temsil edilmiştir. İlk gizli katmanda yüz, ikinci gizli katmanda ise elli adet nöron bulunmaktadır. Sonraki her katman bir önceki katmandan gelen ağırlığa sahiptir. Ağırlık uyarlamaları hiperbolik tanjant fonksiyonu ile yapılmıştır. Tüm katmanların bias değerleri vardır. Çıkış katmanında dört adet nöron bulunmaktadır. Her biri farklı bir hata tipini ifade etmektedir. Girdiler 0.0 ile 1.0 aralığında normalleştirilmiştir. Softmax algoritması ile geri yayılım kullanılarak eğitilen model Python dilinde Jupyter Notebook ortamı üzerinde yazılmıştır. Ağın başlangıç ağırlık ve bias değerleri program tarafından otomatik olarak oluşturulmuştur. Model eğitilirken hedef, ortalama kare hatasının minimuma gelmesidir.

Metrik olarak doğruluk metriği kullanılmıştır. Bunun için maksimum olarak 500 iterasyon yineleme sayısı kullanılmıştır.



Şekil 15: İstatistiksel özellikler kullanılarak oluşturulan DSA yapısı

Önerilen modellerin performansını değerlendirmek için diğer makine öğrenmesi sınıflandırma algoritmaları (DVM, Naif Bayes, K-en Yakın Komşu ve Karar Ağaçları) sonuçları karşılaştırılmıştır.

4.3 Modelin Sonuçları


Python scikit-learn kütüphanesi ile çeşitli denetimli makine öğrenmesi yöntemleri, keras kütüphanesi ile derin sinir ağları ve yığılmış seyrek oto kodlayıcı+softmax modelinin karşılaştırılması yapılmıştır. Tablo 8, 0 HP yükü altında, YSOK, DSA ve makine öğrenmesi algoritmalarının sınıflandırma doğruluklarını göstermektedir. Ham veriler ile uygulanan modelin % 99'luk bir sınıflandırma doğruluğu ile en etkili yöntemlerden biri olduğu görülmektedir. Diğer makine öğrenmesi yöntemlerinden DVM'min %100 başarı ile sınıflandırma yaptığı görülmektedir. K-en Yakın Komşu algoritması da %99 ile yüksek bir doğruluk ile sınıflandırma ortaya koymuştur. İstatistiksel özellikler çıkarıldıktan sonra uygulanan DSA modeli %96'lık doğruluk başarısı göstermiştir. Karar ağaçları ise %95 oranı yakalamıştır. En düşük sınıflandırma performansını %92 ile Naif Bayes yöntemi sergilemiştir.

Bu çalışmada değerlendirme metriği olarak doğruluk, hassasiyet, duyarlılık ve F1-skoru kullanılmıştır. Tablo 8’de tüm yöntemlerin sonuçları bir arada gösterilmiştir.

Metodlar	Doğruluk Oranı	Hassasiyet	Duyarlılık	F1-skor
Yığılmış Seyrek Otomatik Kodlayıcı ile Softmax Sınıflandırması (Ham Veri)	0.99	0.99	0.99	0.99
Destek Vektör Makineleri	1	1	1	1
Karar Ağaçları	0.95	0.95	0.95	0.95
K-en Yakın Komşu	0.99	0.99	0.99	0.99
Derin Sinir Ağları ile Softmax Sınıflandırması (Özellik Çıkarımından Sonra)	0.96	0.96	0.96	0.96
Naif Bayes	0.92	0.92	0.92	0.92

Tablo 8: 0 HP Motor Yüğü, 1797 dev/dak için değerlendirme sonuçları

Karışıklık matrisinde, titreşim sinyali sınıflamasının isabet ve hataları açıklanır. Karışıklık matrisi, performansın değerlendirilmesine ve sınıflandırıcının etkinliğini doğrulamaya yardımcı olur. 0 HP motor yükü altındaki N0, B0, IB0, DB0 veri kümelerine ait karışıklık matrisi, Tablo 9’da verilmiştir. Tablo 9’a baktığımızda YSOK modelinde bir adet sağlıklı veri ile bir adet bilya hatasının yanlış sınıflandırıldığı görülmektedir. Derin Sinir Ağları yönteminde bilya hatası dışında diğer hataların %100 doğruluk ile sınıflandırıldığı görülmektedir. Tüm model sonuçlarına baktığımızda bilya hatasının en zor sınıflandırılan hata olduğu görülmektedir. DVM makine öğrenmesi algoritmaları arasında en yüksek sınıflandırma doğruluğunu vermiştir. DVM’lerin çekirdek numarası karmaşık veri dönüşümünlerini gerçekleştirerek, çıktılara bağlı sınıflandırmaları kolaylıkla yapabilmektedir.



0-Sağlıklı Veri, 1- Bilya Hatası,

2- İç Bilezik Hatası, 3- Saat 6 yönünde Dış Bilezik Hatası

Tablo 9: 0 HP 1797 dev/dak için karışıklık matrisi


Tablo 10, 1 HP yükü altında YSOK, DSA ve makine öğrenmesi algoritmalarının sınıflandırma doğruluklarını göstermektedir. Ham veriler ile uygulanan modelin % 97'lik bir sınıflandırma doğruluğu ile en etkili yöntemlerden biri olduğu görülmektedir. Derin sinir ağları yönteminin %98 başarı ile sınıflandırma yaptığı görülmektedir. Diğer makine öğrenmesi yöntemlerinden K-en yakın komşu algoritması da %96 ile yüksek bir

doğruluk sınıflandırma başarısı göstermiştir. En düşük sınıflandırma performansını %63 ile Naif Bayes yöntemi sergilemiştir.

Metodlar	Doğruluk Oranı	Hassasiyet	Duyarlılık	F1-skor
Yığılmış Seyrek Otomatik Kodlayıcı ile Softmax Sınıflandırması (Ham Veri)	0.97	0.97	0.97	0.97
Destek Vektör Makineleri	0.95	0.95	0.95	0.95
Karar Ağaçları	0.91	0.91	0.91	0.91
K-en Yakın Komşu	0.96	0.96	0.96	0.96
Derin Sinir Ağları ile Softmax Sınıflandırması (Özellik Çıkarımından Sonra)	0.98	0.98	0.98	0.98
Naif Bayes	0.63	0.51	0.63	0.55

Tablo 10: 1 HP 1772 dev/dak için değerlendirme sonuçları

N1, B1, IB1, DB1 veri kümelerine ait karışıklık matrisi, 1 HP motor yükü altındaki dört sınıflandırma için Tablo 11’de verilmiştir. Tabloya baktığımızda ham verileri kullanarak uyguladığımız yöntemde dış bilezik hatasının %100 doğruluk ile sınıflandırıldığı görülmektedir. Karar ağaçlarının dış bilezik hatasını sınıflandırmada başarısız olduğu görülmektedir. K-en yakın komşu algoritması da dış bilezik hatasını sınıflandırmada diğer hatalara oranla görece düşük kalmıştır. Dış bilezik hatalarının iç bilezik hatası olarak yanlış sınıflandırıldığı görülmektedir. Naif Bayes yöntemi ise 1 HP yük altında elde edilen hata tiplerini sınıflandırmada oldukça başarısız bir performans sergilemiştir.



0-Sağlıklı Veri, 1- Bilya Hatası,

2- İç Bilezik Hatası, 3- Saat 6 yönünde Dış Bilezik Hatası

Tablo 11: 1 HP 1772 dev/dak için karışıklık matrisi

BEŞİNCİ BÖLÜM

CNC MAKİNESİ İÇİN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE ARIZA TEŞHİS VE KESTİRİMCİ BAKIM UYGULAMASI

5.1 CNC Makinelerinin Genel Yapısı

CNC (Computer Numerical Control) takım tezgahları, modern dijital imalatta önemli bir rol oynamaktadır. Metal veya diğer sert malzemelerin şekillendirilmesi ya da işlenmesi için genellikle kesme, delme, taşlama ve diğer deformasyon formları ile kullanılmaktadırlar (Luo, Wang, Liu, Li ve Peng, 2018, s.509). CNC'nin kullanıldığı başlıca alanlar; talaşlı imalat, kaynakçılık, pres, muayene, kontrol, montaj vb. olarak sıralanabilir. İnsan iş gücü gereksinimini azaltan CNC, seri imalat için avantaj sağlamaktadır. CNC tezgâhları aşağıdaki amaçlar doğrultusunda geliştirilmiştir:

- Üretimin hızlandırılması ve birim maliyetinin azaltılması,
- İşlenmesi zor olan parçaların üretiminin kolaylaştırılması,
- Üretilen her parçanın kalitesinin ve süresinin aynı olması,
- Geleneksel yöntemlerle işlenmesi mümkün olmayan parçaların üretilmesi.

CNC takım tezgahlarının sağladığı en önemli fayda otomasyona imkan tanımasıdır. CNC teknolojisinin diğer önemli faydası ise iş parçalarının hassas ve devamlı aynı ölçüde çıkmasıdır. Modern CNC taşlama makinelerinin artan karmaşıklığı bu makinelerin güvenli ve verimli çalışmaları gerekliliğini ortaya çıkarmıştır. Bu doğrultuda çevrimiçi makinelerin sağlığının izlenmesi ve arıza teşhis yöntemlerinin kullanımı yaygınlaşmıştır.

CNC makinesi, yüksek derecede otomasyon ve karmaşık yapıya sahip gelişmiş bir işleme ekipmanıdır. CNC takım tezgahı bilgisayar teknolojisinin, otomasyon teknolojisinin, servo sürücünün, hassas ölçümlü makinelerin ve diğer teknolojilerin entegresini sağlamaktadır. Karmaşıklığı yüksek bu gelişmiş cihazların verimli kullanım oranını artırmak için belirli arıza teşhis ve kestirimci bakım yöntemlerini kavramak çok önemlidir.

Oluşan arızalar daha yüksek işletme maliyetleri, daha düşük verimlilik, daha fazla parça israfı ve beklenmedik arıza sürelerine neden olabilir. Modern akıllı imalat, bir CNC takım tezgahının arıza süresinin en önemli kısmını mekanik arızalar

oluşturmaktadır. Akıllı üretimi uygulayabilmek için bir fabrikanın makine koşullarının izlenmesi, yeni başlayan kusurlarının tespit edilmesi, arızaların temel nedeninin teşhis edilmesi, daha sonra elde edilen bilgilerin imalat üretimi ve kontrolüne dahil edilmesi çok önemlidir. Bu sebeple veriye dayalı arıza teşhisi kullanılması gerekmektedir. Veriye dayalı arıza teşhisi, karmaşık sistemler için geçmiş verileri kullanarak hata modlarını oluşturabilmektedir.

Bu çalışmada önerilen kestirimci bakım sistemi için veri toplama ve veri odaklı arıza teşhis olarak iki bölüme ayrılmıştır. Veri toplama kısmında CNC platformunun sağlığı hakkında veri toplanması amaçlanmıştır. Toplanan veriler etkin bir şekilde kullanılarak arıza teşhis modeli oluşturulması amaçlanmıştır. Gerçek zamanlı sensör verileri kullanılarak oluşturulan arıza teşhis sistemi bakım yönetimi için bilgi sağlamayı amaçlamaktadır.

İşleme proseslerinin çalışma koşulları; farklı kesme aletleri, farklı iş parçaları, farklı kesme parametreleri gibi birçok faktörden etkilenmektedir. CNC makinelerinde arıza meydana geldiğinde iş milindeki titreşim gibi yaygın sinyaller dikkate alınmaktadır.

İşleme alanı altında, bir iş milinin aşırı yüklenmesini önlemek için optimum işleme parametrelerini belirlemek gerekmektedir. Aşırı kesme kuvveti, tırlama titreşimi, takım aşınması ve diğer kısıtlamaların takım tezgahlarının performansı üzerinde etkisi bulunmaktadır. Bu özellikleri anlamak kesin ampirik modeller ile takım tezgahlarının sistematik kontrolü arasında bir denge kurulması gerekmektedir (Ridwan ve Xu, 2013, s.12).

Üretim makinelerinin üretkenliklerine ve kalitelerine ilişkin gereksinimler sürekli artmaktadır. Bu talepleri yerine getirmek için giderek daha fazla makine bileşeninin durumlarının izlenmesi için çeşitli sensör sistemleri ile donatılmıştır. Güvenilir işlem, yüksek işleme hızları ve hassasiyet; takım tezgahlarının vazgeçilmez bir özelliğidir.

Çok eksenli CNC takım tezgahı işlemleri sırasında meydana gelebilecek en tehlikeli olaylardan biri, takımlar, iş parçası ve makine elemanları arasında istenmeyen temas olarak görülen bindirmedir (Racz, Breaz ve Cioca, 2020, s.2).

Bu bindirmeler genellikle yüksek onarım maliyetleri ve uzun arıza sürelerine yol açmaktadır. Bindirme şiddeti, makine bileşenlerinin arızalanmasına ya da ömrünün kısılmasına neden olabilmektedir.

Tüm proses bozuklukları arasında, bindirmeler en yüksek onarım maliyetlerine ve en uzun arıza sürelerine neden olmaktadır. Bazı durumlarda bindirme sayısal kontrol ünitesi tarafından öngörülemeyebilir. Ortaya çıkan hasarı önlemek için aletin yük limitleri aşıldığında takım tezgahı mümkün olduğunca hızlı durdurulmalıdır.

Üretim sürecinde işleme alanında bindirmelerin çeşitli sebepleri bulunmaktadır. Bu bindirmeler genellikle parçaya, ana iş mili ünitesine ve makine eksenlerine zarar vermektedir (Abele ve Korff, 2011, s.425).

NC (Numeric Control) parça işleme için kullanılan program hataları iş parçası ile kesici arasında bindirmelere neden olabilir (Zhang, Xu ve Liu, 2011, s.594). Modern takım tezgahlarındaki yüksek ilerlemeler ve iş parçalarının artan karmaşıklığı, makine operatörünü kritik durumlarda seçeneksiz bırakabilir.

Yüksek hızlı uygulamalarda bindirmeler takım kırıkları, aşırı yük ve işleme merkezlerinde ciddi hasara neden olabilmektedir (Abele, Altintas ve Brecher, 2010, s.795). Bindirmeler sıklıkla operatörün makine takımını kurması ve çalıştırması sırasında neden olduğu hatalardan kaynaklanmaktadır. Yanlış iş parçası konumlandırma, yanlış takım seçimi ve sayısal kontrolün hatalı programlanması başlıca örneklerdir (Abele ve Korff, 2011, s.425). Beş eksenli NC işlemede çarpışma sorunları yerel ve küresel olarak iki tipte sınıflandırılabilir: Yerel çarpışma kesici temas noktalarının yakınındaki kesici kenar ile iş parçası arasındaki parazit anlamına gelir. Küresel çarpışma; aletin yüzeyi ile iş parçası arasındaki, iş parçası ile makine bileşenleri arasındaki veya hareketli makine bileşenleri arasındaki kazara temaslara karşılık gelir (Tang, Bohez ve Koomsap, 2007, s.1012).

Döner eksenlerin konumuna bağlı olarak CNC makineleri üç ana tipte sınıflandırılabilir. Birinci tip dönme eksenleri makine masasına uygulanır, ikinci tipte dönme eksenleri takım miline uygulanır. Üçüncü tipte dönme eksenleri hem tezgah tablasına hem de takım miline uygulanır (Bohez, 2002, s.506). İşleme sırasında meydana gelebilecek bindirmeler makine tipine bağlıdır.

Bir bindirme durumunda maksimum hasar gören mil bileşenleri yuvarlanma elemanı yataklarıdır. Yuvarlanma elemanları ile iç ve dış bilezikler arasındaki temas alanları küçük olduğundan birim temas alanı başına bir bindirme sırasındaki reaksiyon

kuvvetleri, izin verilen arayüz basıncını aşabilir. Bu durum çatlakların başlamasına ve yayılmasına yol açabilir (Abele ve Korff, 2011, s.426).

Süreçlerin izlenmesi ile kontrolü için sensör verileri kaydedilerek takım tezgahı karakteristiklerinin anlaşılabilmesi ve gerçek zamanlı bir müdahale için geri beslenebilmesi amaçlanır.

Yapay zekanın gelişimi ile birlikte veri odaklı yöntemlere dayanan kestirimci bakım çalışmaları artmıştır. Kestirimci bakım, makine sağlığının izlenmesi ve akıllı üretimde endüstriyel büyük verileri ele almak için etkili bir çözüm haline gelmiştir. Ayrıca mevcut araştırmalar genellikle birkaç açık veri kümesi kullanılarak yürütülmektedir. Özel kombinasyonlar nadir görülmektedir (Zhang ve diğ., 2019, s.2213).

Literatürde kestirimci bakım ve CNC makinelerini konu alan birçok farklı çalışma bulunmaktadır. Tornalama işlemi için otomatik, düşük maliyetli veri toplama ve durum izleme sağlayan kestirimci bakım odaklı bir yaklaşımın sunulduğu çalışmada, işleme prosesi içinde sıcaklık, titreşim ve pürüzlülük ortalaması arasındaki korelasyonlarına bakılarak işlenmiş parçaların kalite kontrolü yapılmıştır (Sezer, Romero, Guedea, Macchi ve Emmanouilidis, 2018, s.7).

5.2 Deney Seti ve Sensör Seçimi

CNC takım tezgahlarından veri toplama konusunda birçok araştırma bulunmaktadır. Geleneksel CNC sistemi ile karşılaştırıldığında yeni CNC sistemleri daha açıktır ve çeşitli yöntemlerle sistemden daha kolay veri toplanabilmektedir. İletişim arayüzü olmayan bazı eski takım tezgahlarına bakıldığında birçok araştırmada veri toplamak için dahili veya harici yardımcı donanım yöntemleri benimsenmiştir (Liu, Kong, Niu, Jiang ve Zhou, 2020, s.2). Bu donanım yöntemlerini üretim sistemlerine entegre edip makine sağlığı verilerini alarak bunları arıza teşhisi için kullanan farklı çalışmalar literatürde bulunmaktadır.


Düşük maliyetli sensörler, endüstriyel nesnelerin interneti ve makine öğrenmesi ile üretim makinelerinin kestirimci bakım için nasıl etkinleştirilebileceğini gösteren çalışmada, BMW Groupta ağır kaldırma elektrikli monoray sistemi üzerinde bir çalışma yapılmıştır. Makine öğrenmesi yöntemlerini uygulamak için siber fiziksel bir sistem

oluşturulmuştur. Düşük maliyetli donanım ve yazılımın nasıl kullanılabileceğini açıklayan çalışmada ADXL345 titreşim sensörü kullanılmıştır (Strauß, Schmitz, Wöstmann ve Deuse, 2018, s.1475).

Chuang, Sahoo, Lin ve Chang (2019), sensör verilerinin analizi ile kestirimci bakım çalışması için Raspberry Pi tabanlı bir model önermişlerdir. İletişim için TCP/IP yapısı kullanılmış olup veriler zaman dizisi olarak saklanmıştır. I2C iletişim protokolü sensör ile Raspberry Pi arasındaki haberleşmeyi sağlamıştır. Bir diğer çalışmada, Raspberry Pi mini bilgisayar ve 3 eksenli dijital MEMS ADXL345 ivmeölçer kullanarak titreşim ivmelerinin spektrum analizörü olarak geliştirilmiştir (Iwaniec ve diğ., 2017, s.25).


Modern üretim sistemlerinde, düşük maliyetli sensörlerin yaygın kullanımı ve internete bağlanması nedeniyle veri odaklı makine sağlığı izlemesi yaygınlaşmıştır. Derin öğrenme yüksek hacimli makine verilerinin işlenmesi ve analizi için faydalı araçlar sağlamaktadır (Zhao ve diğ., 2019, s.213).

Arıza teşhisi için durum izlemesi yapılacak olan CNC makinesi Şekil 16'da gösterilmektedir. CNC, açısal taşlama makinesi olarak görev yapmaktadır.



Şekil 16: Arıza Teşhisi Yapılan CNC Makinesi

Titreřim verilerinin alınması iin yerleřtirilen ivmelerin konumu řekil 17’de grldė gibi monte edilmiřtir. Sensr konumu, verilerin lm ve analizinde ok nemli bir rol oynamaktadır. Sensrn grltsz lm saėlaması iin lm eksenine sıkıca sabitlenmelidir. Sensr konumu belirlenirken iřletmenin bakım uzmanlarından destek alınmıřtır. Titreřim sinyalleri, normal kořullar altında 1400 rpm sabit dnř hızında alıřan CNC makinesi zerinde llmřtr. Bir yıllık periyotta titreřim sinyalleri kayıt altına alınmıřtır. Bu sre zarfında cihazın arıza vermesi beklenerek arıza verdiėi zaman ile kayıt altına alınan verilerin eřleřtirilmesi planlanmıřtır.



řekil 17: Titreřim Sensrnn Sabitlendiėi Yer

CNC iin rnekleme frekansı 800 Hz’dir. rnekleme uzunluėu bazı hususlar dikkate alınarak isteėe baėlı olarak seilmiřtir. İstatistiksel lmler, rnek sayısı daha fazla olduėunda daha anlamlıdır. te yandan, veri sayısı arttıķa hesaplama sresi de artmaktadır. Bu dengeyi saėlamak iin yaklařık 350 rnek uzunluėu seilmiřtir. CNC

makinesinin saniyedeki devir hızı ortalama 23 dev / sn'dir. Devir başına 35 örnek noktası bulunmaktadır. Her bir koşul için 10 saniyelik örnekler alınmıştır.

Titreşimi ölçmek, normal koşullardan sapmayı tespit etmek ve teşhis etmek için çok önemlidir. Mikro elektromekanik sistemler (MEMS) sensörleri gibi gömülü sistem teknolojilerindeki son gelişmeler, çok daha ucuz bir alternatif olan titreşim tabanlı durum izlemenin geleceği için büyük bir umut vaat etmektedir (Albarbar, Badri, Sinha ve Starr, 2009, s.790). MEMS'ler, mekanik ve elektrik bileşenleri tek bir silikon çip içinde çok küçük ölçeklerde birleştirebilmektedir (Ratcliffe ve diğ., 2008, s.62).

Titreşim sensörü, ölçüm doğruluğunu artıran ve donanım maliyetini düşüren, hızla gelişen teknoloji ile desteklenen nesnelerin interneti'nin önemli bir parçası haline gelmektedir. Titreşim sensörleri, kontrol ve üretim sistemlerindeki motorlar ve üretimde kullanılan CNC'lerin temel bileşenlerine fiziksel olarak bağlanarak bu cihazların çalışma durumu hakkında temel bilgiler sağlayabilmektedir (Jung, Zhang ve Winslett, 2017, s.1271).

Sensörler son yıllardaki gelişmelere bağlı olarak daha küçük, daha akıllı, mevcut sistemlerde uygulanması kolay, ucuz ve güvenli hale gelmiştir. Sensör seçimi, istikrarlı performans, iyi frekans tepkisi ve geçerli sonuçlar elde etmek için önemlidir.

Sensör teknolojisindeki hızlı ilerleme, gerçek zamanlı veri akışını her zamankinden daha kolay hale getirmiştir. Mikro, ultrasonik, titreşim ve akustik emisyon sensörleri gibi çeşitli sensörler çeşitli veri türlerini toplamak ve zengin endüstriyel veri kaynakları üretmek için kullanılabilir.

Yarı iletken teknolojilerindeki ve yeteneklerindeki ilerlemeler endüstriyel uygulamalardaki verileri özellikle de duruma dayalı izleme çözümlerini algılama, ölçme, yorumlama ve analiz etme konusunda yeni fırsatlar sunmaktadır. MEMS teknolojisine dayalı yeni nesil sensörler, teşhis ve prognostik uygulamalar için gelişmiş algoritmalarla birlikte çeşitli makinelerin etkin bir şekilde izlenmesi, çalışma sürelerinin iyileştirilmesi ve süreç kalitelerinin artırılmasını sağlamaktadır.


Üç MEMS sensörünün incelendiği bir çalışmada sensörlerin performansı iyi kalibre edilmiş ticari bir ivmeölçerle karşılaştırılmıştır. Testler gerçek bir CNC makinesi üzerinde yapılmıştır. Sonuçlara göre MEMS sensörlerinin iyi bir alternatif olduğu fakat

seim yapılırken spesifikasyonlara dikkat edilmesi gerektięi vurgulanmıřtır (Albarbar, Mekid, Starr ve Pietruszkiewicz, 2008, s.798).

Maruthi ve Hedge'in (2015), alıřmalarının deneysel sonuları, MEMS ivmeölerlerinin üç fazlı asenkron motorlarda basit ve karmařık rulman hatalarının tespit edilebilmesi için güvenilir bir řekilde kullanılabileceęini göstermektedir.

Bu yeni yeteneklerden faydalanmak ve makine saęlığını izlemenin avantajlarını yakalamak için sensör seiminin doęru ve güvenilir olması gerekmektedir. Bu sayede gerek zamanlı izleme ile anlaşılır ve eyleme geçirilebilir bilgiler toplanabilmektedir. Alınan veriler potansiyel makine arızalarının teşhis edilmesi için kullanılabilmektedir.

Arıza teşhisinin temel bileřenlerinden biri olan titreřim, ok eřitli endüstriyel uygulamalarda en kritik bileřenleri izlemek için güvenilir bir řekilde kullanılmaktadır. Piyasada bulunan MEMS sensörlerinden ADXL345, oluřturulan arıza teşhis sistemi için seilmiřtir. řekil 18'de sensörün yapısı görölmektedir.



řekil 18: ADXL 345 İvme Öler

ADXL345, küçük ve ince 3mm x 5mm x 1mm'lik bir büyüklüktedir. $\pm 2g$, $\pm 4g$, $\pm 8g$ ve $\pm 16g$ arasında seçilebilir bir ölçüm aralığına sahiptir. ADXL345 hareketten kaynaklanan dinamik ivmeyi ölçmek için uygundur. Bu uygulama için $\pm 1 g$ kullanılmıştır. Dijital iletişim protokolleri I2C ve SPI mevcuttur. Hemen okunamayan bilgileri saklamak için gömülü 32 düzey ilk giren ilk çıkar tamponu kullanmaktadır.

Bu tip tamponlama, eşzamansız olarak gelen verilerin depolanmasında faydalı bir yoldur ve mikrodenetleyici ile sensör arasında daha az etkileşime izin vererek önemli ölçüde güç tasarrufu sağlamaktadır. ADXL345, bant genişliği 0.05 -1600 Hz olan kapasitif ivmeölçerdir. ADXL345 için maksimum örnek frekansı 3200 Hz'dir (Analog Devices, 2015, s.1).

Sensörlerin seçimi, hem teknik özellikleri hem de maliyet etkinliğini göz önünde bulundurulduğunda toplanan verilerle makine sağlığının temsilini belirlemektedir. Uygun sensörlerin ve veri kaynaklarının seçimi durum izlemenin etkinliği açısından önemlidir. Eksiksiz bir veri toplama sistemi, teşhis ve prognozun etkinliğini doğrudan artırabilir. Seçilen sensör düşük maliyet, çıkış hızının yüksek olması ve dijital bağlantı sağlaması nedeniyle tercih edilmiştir.

5.3 Verilerin Elde Edilmesi

Uygun veri kaynaklarının seçimi, bakım etkinliğinin anahtarıdır. Eksiksiz bir veri toplama sistemi arıza teşhis ve prognoz etkinliğini artırmaktadır. Mikro-sensörler, ultrasonik sensörler, titreşim sensörleri ve akustik emisyon sensörleri gibi çeşitli sensörler farklı verileri toplamak için kullanılabilir. Sensörlerin seçimi, hem teknik özellikleri hem de maliyet etkinliğini göz önünde bulundurarak, toplanan verilerle makine sağlığının temsilini belirlemektedir.

Kestirimci bakım ve arıza teşhis uygulamalarının ilk adımı veri toplamaktır. Bu uygulamalar için en önemli veri kaynağı sensörlerden toplanan verilerdir. Sinyali işlemek için küçük uygun maliyetli bir mini bilgisayar kullanılmıştır. Yaygın olarak kullanılan cihazlar mikro denetleyici Arduino ve mini bilgisayar Raspberry Pi'dir. Arduino, harici sensörler kullanılan uygulamalar için uygun olan analog-dijital dönüştürücü içeren bir mikro denetleyicidir. Raspberry Pi işlevsel olarak kullanılabilen, üzerine takılan sd karta yüklenen bir işletim sistemi sayesinde çalışan bir mini bilgisayardır. Raspberry Pi'nin

kullanışlı bir özelliği de genel amaçlı giriş-çıkış (GPIO) arayüzüdür. Sinyal girişi veya çıkışı I / O pinleri aracılığıyla gerçekleştirilebilmektedir. Çalışmada kullanılan Raspberry Pi Şekil 19’da görülmektedir.



Şekil 19: Mini Bilgisayar (Raspberry Pi)

Bu iki platformun karşılaştırılması Tablo 12’de verilmiştir.


Özellik	Ardunio Uno	Raspberry Pi 3 Model B+
Mimari	ATmega328P	ARM
İşlemci	16 Mhz	1.4 Ghz
RAM	2 KB	1 GB
İşletim Sistemi	-	Linux
Programlama Dili	C, C++	C++, Python, Java
I2C	+	+
SPI	+	+
Ethernet	-	+

Tablo 12:Ardunio ve Raspberry Pi özellikleri

Arduino, Raspberry Pi ile karşılaştırıldığında daha az ek yüke sahiptir. Arduino bir işletim sistemi olmadan yorumladığı yazılı kodu yürütür. Raspberry Pi’de bulunan işletim sistemi ise Linux tabanlıdır. Raspberry Pi’nin avantajı işlem gücünün yüksek olması, üzerinde bulunan ethernet bağlantısı sayesinde verilerin anlık olarak sunucu ortamına aktarabilmesidir.

Raspberry Pi, tek kart bir bilgisayar olarak da tanımlanabilir. Aynı bilgisayar gibi birçok görevi aynı anda yapabilir. Ağ oluşturma, veri aktarımı, veritabanları ve web sunucularının tümü Raspberry Pi tabanlı uygulamalarda yer alabilir.

CNC makinesi üzerinden titreşim sinyallerini toplamak için oluşturulan prototip donanımsal olarak hazırlandıktan sonra sensörden verilerin okunup kaydedilmesi için gerekli yazılımlar kurulmuştur. Raspberry Pi üzerine Raspbian Stretch Lite işletim sistemi kurulmuştur. Python ortamında geliştirilen yazılım ile sensör verileri alınarak Sqlite veritabanına kaydedilmiştir. Kaydedilen veriler belirlenen sunucuya anlık olarak aktarılmıştır. Sunucu üzerinde verilerin kaydı için Mysql veri tabanı yönetim sistemi kurulmuştur. Veriler zamana bağlı olarak kaydedilmiştir. Şekil 20’de sistemin işleyişi görülmektedir.



Şekil 20: Hazırlanan sistemin genel yapısı


Veriler, olası tüm sistem durumlarını gösteren yeterli gözlemleri elde edebilmek için yeterince uzun bir süre toplanmalıdır. Yeterli veri toplandıktan sonra, veriler ile makine durumu eşleştirmektedir.

Bu veri kayıtları daha sonra, makine koşulları ile sistemin durumu arasındaki ilişkileri bulmak amacıyla seçilen yöntem aracılığıyla işlenir. Bu adım çalışmanın model geliştirme aşamasıdır.


Modelin genelleştirilebilirliğini test etmek için giriş değişkenleri ve durum arasındaki ilişki veri kümesi iki alt kümeye bölünmektedir. İlk alt küme olan eğitim veri seti modeli eğitmek için kullanılır. Diğer altküme olan test veri seti model tahmininin doğruluğunu ölçmek için kullanılır. Test veri seti eğitim aşamasında dahil edilmemektedir. Modelin performansını değerlendirmek için test kümeleri üzerinde model uygulanarak doğruluk performansı ölçülmektedir. Karışıklık matrisi ile de her sınıfın ayrıntılı sınıflandırma doğruluğu ölçülmektedir.

5.4 Deneysel Sonuçlar

Titreşim sensörünün takıldığı CNC makinesinden bir yıllık zaman periyodunda titreşim sinyalleri toplanmıştır. Bu gözlem sonucunda elde edilen sağlıklı çalışma koşuluna ve bindirme sırasındaki çalışma koşuluna ait 10 saniyelik titreşim sinyallerinin zaman düzlemi üzerinde gösterimi aşağıdaki şekillerde sunulmaktadır.



Sağlıklı Koşul



Bindirme Hatası

Şekil 21: 1400 dev/dak için zaman etki alanı titreşim sinyalleri

Ölçülen ham veriler için zaman alanı özellikleri her 350 örnek için hesaplanmıştır. Toplam 600 adet zaman serisi veri seti olarak kullanılmıştır. Bunlardan 300 tanesi normal koşulu kalan 300'ü bindirme koşulunu temsil etmektedir. Sonrasında 600 titreşim verisi seti, bir kısmı makine öğrenmesi modelinin eğitim aşamasında giriş çıkış arasındaki ilişkiyi kurmak için kalanı ise eğitilmiş olan modelin testi için kullanılmıştır. Tablo 13'de verilerin hata tiplerine göre dağılımı gösterilmektedir. Örneklerin %70'i makine

öğrenmesi modelini sentezlemek için eğitim verisi olarak rastgele seçilirken, örneklerin geri kalan %30'u eğitilmiş makine öğrenmesi modelini doğrulamak için kullanılmıştır.

Veri Tipi	Örnek Sayısı	Etiket
Normal	300	N
Bindirme	300	B

Tablo 13: 1400 dev/dak Altındaki Örnek Dağılımı


YSOK, hata sınıflandırması için kullanılabilen ham sinyal verilerinden anlamlı özelliklerin çıkarılmasını sağlamaktadır. Bu çalışmada, iki gizli katmana sahip bir otomatik kodlayıcı yapısı kullanılmıştır. Gizli katmanlardaki nöron sayısı sırasıyla 256 ve 128'dir. Kodlayıcı etkinleştirme işlevi sigmoid, kod çözücü etkinleştirme işlevi relu olarak belirlenmiştir. Çalışmada kullanılan parametreler, her gizli birimin sayısı, seyreklik parametresi ve seyreklik ceza süresinin ağırlığı Tablo 14'de gösterilmiştir.

Parametreler	Değer
Girdi Sayısı	350
Çıktı Sayısı	2
Gizli Katman Sayısı	2
Her Gizli Katmandaki Nöron Sayısı	256,128
Seyreklik Parametresi	0.1
Seyreklik Parametresinin Ağırlığı	3
İş Boyutu	30

Tablo 14:Yığılmış seyrek oto kodlayıcı model parametreleri

Makine öğrenmesi algoritmalarında kullanılmak üzere titreşim sinyallerinden istatistiksel özellikler hesaplanmıştır. Elde edilen özellikler; ortalama, standart sapma,

basıklık, çarpıklık, kök ortalama kare, maksimum genlik, minimum genlik, tepe faktörü ve etki faktörüdür. Çıkarılan özelliklere ait grafikler Tablo 15’de gösterilmektedir.



Tablo 15: 1400 dev/dak Altındaki Örnek Dağılımı için çıkarılan istatistiksel özelliklerin karşılaştırılması

YSOK modeli için, $h(1)$ x birincil özellikleri ham girdiler kullanılarak ve $W(1)$ ağırlığının ayarlanmasıyla öğrenilir. Bu özellikler $h1(x)$ ikinci seyrek otomatik kodlayıcı için giriş olarak kullanılır. Bu özellikler ve $W(2)$ ağırlık kullanılarak $h2(x)$ ikincil özellikleri elde edilir. Bu ikincil özellikler, bir softmax sınıflandırıcısında ham girdi olarak kullanılır. Model, iki gizli katman ve bir son sınıflandırma katmanını (softmax) kullanılarak oluşturulmuştur.

İstatistiksel özelliklerin girdi olarak kullanıldığı derin sinir ağırları modelinde giriş katmanını, iki adet gizli katman ve çıkış katmanını bulunmaktadır. İlk gizli katmanda yüz,

ikinci gizli katmanda ise elli adet nöron bulunmaktadır. Sonraki her katman bir önceki katmandan gelen ağırlığa sahiptir. Ağırlık uyarlamaları hiperbolik tanjant sigmoid fonksiyonu ile yapılmıştır. Tüm katmanların bias değerleri vardır. Çıkış katmanında, bir tanesi normal diğeri bindirme hatasını temsil eden iki adet nöron bulunmaktadır. Bir tanesi normal diğeri bindirme hatasını temsil etmektedir. Girdiler 0.0 ile 1.0 aralığında normalleştirilmiştir. Model, YSA softmax algoritması ile geri yayılım kullanılarak Python dilinde Jupyter Notebook ortamı üzerinde eğitilmiş ve uygulanmıştır. Ağırlık başlangıç ağırlık ve bias değerleri program tarafından otomatik olarak oluşturulmuştur. Eğitim seti eğitilirken hedef, ortalama kare hatasının(OKH) minimuma gelmesidir. Metrik olarak doğruluk kullanılmıştır. Eğitim için 100 iterasyon yineleme sayısı kullanılmıştır.

5.5 Modelin Sonuçları

Python scikit-learn kütüphanesi ile çeşitli denetimli makine öğrenmesi algoritmaları, derin sinir ağları ve yığılmış seyrek oto kodlayıcı+softmax modelinin karşılaştırılması yapılmıştır. Ham veriler ile önerilen modelin %52 'luk bir sınıflandırma doğruluğu ile ortalama bir performans sergilemiştir. Diğer makine öğrenmesi yöntemlerinden DVM'min %68 başarı ile makine öğrenmesi algoritmaları arasında en yüksek doğruluk oranını sergilemiştir. K-en yakın komşu ve karar ağaçları algoritması %60 doğruluk sonucu göstermiştir. İstatistiksel özellikler çıkarıldıktan sonra uygulanan derin sinir ağları modeli %80'lik doğruluk başarısı ile en iyi sonucu göstermiştir. En düşük sınıflandırma performansını %49 ile Naif Bayes yöntemi sergilemiştir. Tablo 16'da tüm yöntemlerin performans sonuçları bir arada gösterilmektedir.

Karışıklık matrisinde, titreşim sinyali sınıflamasının isabet ve hataları açıklanır. Bu çalışmada kullanılan değerlendirme metrikleri olarak doğruluk, hassasiyet, duyarlılık ve F1-skoru uygulanmıştır. Karışıklık matrisi, performansın değerlendirilmesine ve sınıflandırıcının etkinliğini doğrulamaya yardımcı olur.

Metodlar	Doğruluk Oranı	Hassasiyet	Duyarlılık	F1-skor
Yığılmış Seyrek Otomatik Kodlayıcı ile Softmax Sınıflandırması (Ham Veri)	0.52	0.53	0.53	0.53
Destek Vektör Makineleri	0.68	0.69	0.69	0.69
Karar Ağaçları	0.60	0.62	0.61	0.60
K-en Yakın Komşu	0.60	0.65	0.62	0.60
Derin Sinir Ağları ile Softmax Sınıflandırması (Özellik Çıkarımından Sonra)	0.80	0.81	0.80	0.80
Naif Bayes	0.49	0.47	0.47	0.46


Tablo 16: CNC Arıza Teşhis Modeli Doğruluk Oranları

Normal ve bindirme hatası veri kümelerine ait karışıklık matrisi ikili sınıflandırma için Tablo 17’de verilmiştir. İstatistiksel özellikler çıkarıldıktan sonra uygulanan DSA modelinin, bindirme hatasında %88 oranında başarılı olduğu görülmektedir. İstatistiksel özelliklerin normal ve bindirme hatasını yüksek düzeyde temsil ettiği görülmektedir.

Karar Ağaçları	DVM	Naif Bayes																											
<table border="1"> <tr> <td>0</td><td>58</td><td>24</td></tr> <tr> <td>1</td><td>47</td><td>51</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	58	24	1	47	51		0	1	<table border="1"> <tr> <td>0</td><td>60</td><td>22</td></tr> <tr> <td>1</td><td>34</td><td>64</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	60	22	1	34	64		0	1	<table border="1"> <tr> <td>0</td><td>21</td><td>61</td></tr> <tr> <td>1</td><td>30</td><td>68</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	21	61	1	30	68		0	1
0	58	24																											
1	47	51																											
	0	1																											
0	60	22																											
1	34	64																											
	0	1																											
0	21	61																											
1	30	68																											
	0	1																											
K-en Yakın Komşu	Derin Sinir Ağları ile Softmax Sınıflandırması (Özellik Çıkarımından Sonra)	Yığılmış Seyrek Otomatik Kodlayıcı ile Softmax Sınıflandırması (Ham Veri İle)																											
<table border="1"> <tr> <td>0</td><td>69</td><td>13</td></tr> <tr> <td>1</td><td>58</td><td>40</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	69	13	1	58	40		0	1	<table border="1"> <tr> <td>0</td><td>64</td><td>26</td></tr> <tr> <td>1</td><td>10</td><td>80</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	64	26	1	10	80		0	1	<table border="1"> <tr> <td>0</td><td>33</td><td>52</td></tr> <tr> <td>1</td><td>41</td><td>54</td></tr> <tr> <td></td><td>0</td><td>1</td></tr> </table>	0	33	52	1	41	54		0	1
0	69	13																											
1	58	40																											
	0	1																											
0	64	26																											
1	10	80																											
	0	1																											
0	33	52																											
1	41	54																											
	0	1																											
0-Sağlıklı Veri, 1- Bindirme Hatası																													

Tablo 17: CNC Arıza Teşhis Modeli Karışıklık Matrisi

AUC-ROC eğrileri incelendiğinde sol üst köşeye en yakın olan derin sinir ağlarının en başarılı sınıflandırma modeli olduğu görülmektedir. AUC büyüdükçe doğru pozitifler ve doğru negatiflerin keşismesi azalmaktadır. ROC eğrisi sol üst köşeye yaklaştıkça sınıflandırmanın genel doğruluğu artmaktadır. ROC eğrisi (0,0) ile (1,1) noktaları arasında yer alan bir eğridir. Bu eğri altında kalan alan ise 0 ile 1 arasında değişmektedir.



Tablo 18: CNC Arıza Teşhis Modeli AUC-ROC Eğrisi

SONUÇ

Dijital ve ileri teknoloji odaklı üretimin en önemli bileşenlerinden biri olan otomasyonda hızlı gelişmeler yaşanmaktadır. Bu gelişmeler endüstrilerde makineleşme düzeylerinde artışa sebep olmuştur. Bu ortamda ürünün satışını artırmak, ürünün kalitesini korumak ve verimli bir üretim sağlayabilmek için makinelerin izlenmesi oldukça önemli hale gelmiştir. Bunun yanında, endüstriyel sistemlerin karmaşıklığının ve maliyetlerinin sürekli artışı, her türlü potansiyel anormallik ve arızayı mümkün olduğunca erken tespit edip tanımlamayı ve zamanında bakım yapmayı işletmeler açısından temel değer haline getirmiştir.

İşletmelerin dijitalleşme eğilimi, bakım hizmetleri için yeni yaklaşımlar sunmaktadır. Sensörler, bulut teknolojisi, makine öğrenmesi ve derin öğrenme bakım çalışmaları için gerçek bir katma değer sağlamak açısından eşsiz bir fırsat sunmaktadır. Kestirimci bakım, işletmelerin dijitalleşmesi ile ilişkili olarak Endüstri 4.0 konseptinin temel unsurlarından biridir. Üretimi çeşitlenerek piyasaya sunulan yeni sensörler bakım yöntemlerinin gelişmesine katkı sağlamaktadır. Bakım sisteminin verimli olabilmesi sadece sensörlerden toplanan veriler ile değil, bu verilerden doğru sonuçlar çıkarmayı sağlayacak modellerin de doğru seçilmesine bağlıdır. Gelişmiş sensör ve bilişim teknolojileri gerçek zamanlı makine verilerinin toplanmasını, saklanmasını ve işlenmesini kolaylaştırmıştır.

Modern imalat sistemlerinin karmaşıklığının artmasıyla elde edilen verilerin katlanarak arttığı görülmüştür. Elde edilen bu büyük verilerin verimli kullanılması, imalat makinelerinin sağlık koşullarının çıkarılmasında kullanılan gelişmiş arıza tespiti, teşhis, prognoz, sağlık yönetimi ve bakım planlaması için kaynak sağlamaktadır. Makine öğrenmesinin bir dalı olan derin öğrenme, makine durumunu belirleme ve performans düşüşü tahmini konularında büyük bir potansiyel göstermektedir.

İmalat şirketleri günümüzde sürekli artan üretkenlik baskılarıyla karşı karşıya kalmaktadır. Bu üretkenlik baskısı nedeniyle yüksek makine kullanılabilirliği ihtiyacı doğmaktadır.

Endüstri 4.0 ile sunulan akıllı üretimin bir sonucu olarak daha fazla üretim ekipmanı akıllı sensörler ile donatılmış ve nesnelerin interneti ile birleştirilmiştir. Akıllı üretimde başrol oynayan büyük veri, sensör ve nesnelerin interneti kavramları makinelere

ait üretim zekasının oluşturulmasına odaklanmıştır. Bu aşamada tanımlayıcı, teşhis edici, tahminleyici ve kural koyucu olmak üzere farklı düzeylerde veri modelleri ortaya konulmaktadır. Derin öğrenme, bu alanlardaki büyük ve yüksek çeşitliliğe sahip verilerin üstesinden gelebilme kabiliyetine sahiptir.

Arıza teşhisi, daha güvenli, daha etkili ve daha uygun maliyetli süreçler geliştirme bağlamında önemli olan kestirimci bakım için önemli bir bileşenidir. Arıza teşhisi kullanıcıya hangi bileşenin ayrıştığı ve bileşenin arızalanma şekli hakkında bilgi verdiğinden akıllı bakım kararlarının etkinleştirilmesi için gereklidir. Bu bilgiler, yedek bileşenlerin hatadan önce sipariş edilmesine ve değiştirilmesine izin vermektedir. Ayrıca sorunun tekrarlanmasını önlemek için de sorunun temel nedenini belirlemeye yardımcı olmaktadır.

Makine öğrenmesi algoritmalarının, imalat uygulamalarına belirgin bir şekilde değer sağladığı görülmektedir. Makine öğrenmesi algoritmalarının uygulanması alan uzmanlığı ve özellik mühendisliği gerektirmektedir. MÖ algoritmalarını uygulamak için en iyi özellikler dikkatle seçilmelidir.

Derin öğrenme, denetimsiz öğrenme yoluyla soyutlayıcı bir temsil elde edebilen üretken bir modeldir. Deneysel sonuçlar oto kodlayıcıların makine arıza teşhisini uzman bilgisi olmadan doğrudan ham titreşim verilerinin kullanılması ve bunların eğitilmesi yoluyla kullanılabileceğini göstermiştir. Ham girdi verilerinden arızalarla ilgili gizli bilgilerin çıkarılması, daha sonra bunların farklı seviyelere bölünmesi, boyutunun azaltılması ve girdi boyutsallığı büyük olduğunda arızalar hakkında ayrımcı bilgiler bulunması açısından seyrek oto kodlayıcılar avantaj sağlamaktadır.

Geleneksel makine öğrenmesi algoritmalarına kıyasla önerilen yöntemin temel avantajı arıza özelliklerinin insan uzmanlığı yerine genel amaçlı bir öğrenme prosedürü ile öğrenilmesidir.

Hesaplama gücünün büyük ölçüde iyileştirilmesi ve veri hacminin hızlı büyümesi ile YZ algoritmaları ve bunların değişken modelleri giderek daha üstün bir performans avantajı göstermektedir. Algoritmaların sürekli gelişimi ile araştırmacılar kestirimci bakım için uygulamalarda veriye dayalı yöntemlere odaklanmaya devam edeceklerdir.

Bu tez çalışması kapsamında YSOK tabanlı bir model geliştirilmiştir. Bu yaklaşım ile farklı çalışma koşullarına ait ham titreşim verilerinden doğrudan özellikler

çıkarılmıştır. Derin öğrenmenin özellik çıkarma için uzmanlık bilgisi gerektirmemesi en büyük avantajı olarak belirtilebilir. Model, güvenilirliği bilinen ve literatürde birçok çalışmada kullanılan deney veri seti üzerinde arıza teşhisi için etkinliğini göstermiştir. MEMS titreşim sensörü ile topladığımız veri seti üzerinde model ortalama bir performans sergilemiştir.

Uygulama aşamasında, Türkiye'nin en büyük elektrik motoru üreticilerinden biri olan bir işletme seçilmiştir. Çalışma, üretimin başlama aşamasında kullanılan bir CNC makinesi üzerinde gerçekleştirilmiştir. CNC makinesinin belirlenen noktasına yerleştirilen ivmeölçer ile titreşim sinyalleri toplanmıştır. Toplanan veriler ekipmanın verdiği arıza ile eşleştirilerek etiketlenmiştir.

Geliştirilen model deney veri seti üzerinde başarılı sonuçlar vermiştir. YSOK modelinde deney veri seti için 2 gizli katman kullanılmıştır. Birinci katman 256, ikinci katman 128 adet nörondan oluşmaktadır. Seyreklik parametresinin 0.1 olarak kullanıldığı modelde oto kodlayıcı boyut azaltma için kullanılmıştır. Azaltılan boyut girdilerin temsilini oluşturmuştur. Son katmanda softmax katmanı ile hataların sınıflandırılması yapılmıştır. Ham veriler ile uygulanan model %99 ve %97'lik sınıflandırma oranları ile yüksek bir performans göstermiştir. Ham verilerden çıkarılan istatistiksel özelliklerin girdi olarak kullanıldığı DSA modeli ise %96 ve %98'lik sınıflandırma oranı yakalamışlardır. Ham verilerden çıkarılan istatistiksel özelliklerin farklı arıza tiplerine ait titreşim sinyallerinin karakteristiğini yüksek oranda yansıttığı görülmektedir.

Başarılı sonuçlar alınan model, uygulama aşamasında CNC makinesinden toplanan veriler için de kullanılmıştır. Aynı parametrelerin kullanıldığı model sonucunda %52'lik ortalama bir sonuç elde edilmiştir. Çalışma süresince yakalanan hata sayısından dolayı veri setinin boyutu sınırlı kalmıştır. Modelin eğitilmesi için gereken eğitim setinin daha yüksek boyutta olması sınıflandırma başarısını arttırmaktadır. MEMS sensörlerinin frekans aralığı ve kullanılan mini bilgisayarın işlem gücü de göz önüne alındığında, endüstriyel titreşim sensörlerin hassas ve güvenilir ölçümleri ile daha yüksek doğruluk oranları elde edilebilir. Ham verilerden çıkarılan istatistiksel özelliklerin girdi olarak kullanıldığı DSA modeli ise %81 oranında bir sonuç yakalamıştır. Bu oran deney veri setinde de görüldüğü üzere istatistiksel özelliklerin titreşim sinyallerinin temsilini iyi sağladığını göstermektedir. Uygulama sonuçlarına bakıldığında zaman modelin farklı sensör

ve farklı makinelerden toplanan veriler için başarılı sonuçlar vereceği mümkün görünmektedir.

Kullanılan makine öğrenmesi algoritmalarından naif bayes iki veri seti üzerinde de en düşük doğruluk başarısı gösteren algoritma olmuştur. Deney setindeki ve uygulama setindeki veriler tamamen bağımsız değildir. Naif bayes algoritması verilerin bağımsız olmadığı durumlarda daha düşük performans göstermektedir. DVM ise en başarılı makine öğrenmesi algoritması olarak görülmektedir. Genelleme performansının yüksek olması, yüksek boyutlu verilerdeki başarısı bu modelin avantajıdır.

Modelde kullanılan; gizli katman sayısı, gizli katmanlardaki nöron sayısı, seyreklik parametresi, seyreklik parametresinin ağırlığı ve iş boyutu gibi parametrik veriler değiştirilerek model üzerinde iyileştirmeler yapılabilir. Parametrik verilerin modelin performansına etkisi bu şekilde ölçülebilir.

Sonuç olarak, makine verimliliğini artırırken bakım maliyetlerinin düşüren kestirimci bakım uygulamaları bakım yönetiminin performansını doğrudan etkilemektedir. Etkin bir kestirimci bakım uygulayan işletmeler önemli rekabet üstünlükleri kazanmaktadırlar. Bu doğrultuda doğru zamanda doğru bakım yapılmasını sağlayan kestirimci bakım, işletmelerin maliyet avantajı sağlamaları açısından oldukça önemli hale gelmiştir.

İşletmeler her gün karar almalarını gerektirecek süreçler yaşamaktadırlar. Bu kararlar uygulama süreleri açısından; kısa, orta ve uzun vadeli olabilmektedir. Hiyerarşik düzeylere göre bu kararların önemi artmaktadır. Kararlar sorun ile ilgili bilgiye sahip olma açısından; belirlilik, belirsizlik ve risk durumları altında alınmaktadır. Veri-odaklı kestirimci bakım yöntemleri karar alıcılar açısından belirsizlik durumunu azaltmaktadır. Doğru karar sonucu yapılan işlemler; işletmelerin makine, yedek parça ve personel verimliliğine katkıda bulunmaktadır.

KAYNAKÇA

- Abele, E., Altintas, Y., & Brecher, C. (2010). Machine tool spindle units. *CIRP annals*, 59(2), 781-802.
- Abele, E., & Korff, D. (2011). Avoidance of collision-caused spindle damages—challenges, methods and solutions for high dynamic machine tools. *CIRP annals*, 60(1), 425-428.
- Ahmad, A., & Dey, L. (2007). A k-mean clustering algorithm for mixed numeric and categorical data. *Data & Knowledge Engineering*, 63(2), 503-527.
- Albarbar, A., Badri, A., Sinha, J. K., & Starr, A. (2009). Performance evaluation of MEMS accelerometers. *Measurement*, 42(5), 790-795.
- Albarbar, A., Mekid, S., Starr, A., & Pietruszkiewicz, R. (2008). Suitability of MEMS accelerometers for condition monitoring: An experimental study. *Sensors*, 8(2), 784-799.
- Al-Badour, F., Sunar, M., & Cheded, L. (2011). Vibration analysis of rotating machinery using time–frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, 25(6), 2083-2101.
- Ali, J. B., Fnaiech, N., Saidi, L., Chebel-Morello, B., & Fnaiech, F. (2015). Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*, 89, 16-27.
- Analog Devices, <http://www.analog.com/media/en/technical-documentation/data-sheets/ADXL345.pdf>. Eriřim Tarihi: 04.03.2020
- Antoni, J., & Randall, R. B. (2006). The spectral kurtosis: application to the vibratory surveillance and diagnostics of rotating machines. *Mechanical systems and signal processing*, 20(2), 308-331.
- Ayhan, S., & Erdoğmuş, ř. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskiřehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.

- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
- Bohez, E. L. (2002). Five-axis milling machine tool kinematic chain design and analysis. *International Journal of Machine Tools and Manufacture*, 42(4), 505-520.
- Boudiaf, A., Moussaoui, A., Dahane, A., & Atoui, I. (2016). A comparative study of various methods of bearing faults diagnosis using the case Western Reserve University data. *Journal of Failure Analysis and Prevention*, 16(2), 271-284.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). Classification and regression trees. *Wadsworth Int. Group*, 37(15), 237-251.
- Butte, S., Prashanth, A. R., & Patil, S. (2018, April). Machine Learning Based Predictive Maintenance Strategy: A Super Learning Approach with Deep Neural Networks. In *2018 IEEE Workshop on Microelectronics and Electron Devices (WMED)* (pp. 1-5). IEEE.
- Caesarendra, W., & Tjahjowidodo, T. (2017). A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing. *Machines*, 5(4), 21.
- Canfield, R. V. (1986). Cost optimization of periodic preventive maintenance. *IEEE Transactions on Reliability*, 35(1), 78-81.
- Carden, E. P., & Fanning, P. (2004). Vibration based condition monitoring: a review. *Structural health monitoring*, 3(4), 355-377.
- Carnero, M. C. (2005). Selection of diagnostic techniques and instrumentation in a predictive maintenance program. A case study. *Decision support systems*, 38(4), 539-555.
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- Case Western Reserve University (2011). Bearing Data Center.Seeded Fault Test Data. Available online: <http://csegroups.case.edu/bearingdatacenter/home> adresinden elde edildi. Erişim Tarihi: 10.04.2019

- Cassady, C. R., & Kutanoglu, E. (2005). Integrating preventive maintenance planning and production scheduling for a single machine. *IEEE Transactions on reliability*, 54(2), 304-309.
- Cerrada, M., Zurita, G., Cabrera, D., Sánchez, R. V., Artés, M., & Li, C. (2016). Fault diagnosis in spur gears based on genetic algorithm and random forest. *Mechanical Systems and Signal Processing*, 70, 87-103.
- Chen, Z., Zeng, X., Li, W., & Liao, G. (2016, May). Machine fault classification using deep belief network. In *2016 IEEE international instrumentation and measurement technology conference proceedings* (pp. 1-6). IEEE.
- Chen, Z., & Li, W. (2017). Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network. *IEEE Transactions on Instrumentation and Measurement*, 66(7), 1693-1702.
- Chen, Z., Deng, S., Chen, X., Li, C., Sanchez, R. V., & Qin, H. (2017). Deep neural networks-based rolling bearing fault diagnosis. *Microelectronics Reliability*, 75, 327-333.
- Chuang, S. Y., Sahoo, N., Lin, H. W., & Chang, Y. H. (2019). Predictive Maintenance with Sensor Data Analytics on a Raspberry Pi-Based Experimental Platform. *Sensors*, 19(18), 3884.
- Cunningham, P., & Delany, S. J. (2007). k-Nearest neighbour classifiers. *Multiple Classifier Systems*, 34(8), 1-17.
- De Faria Jr, H., Costa, J. G. S., & Olivas, J. L. M. (2015). A review of monitoring methods for predictive maintenance of electric power transformers based on dissolved gas analysis. *Renewable and sustainable energy reviews*, 46, 201-209.
- Deng, L. (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Transactions on Signal and Information Processing*, 3.
- Endrenyi, J., Aboresheid, S., Allan, R. N., Anders, G. J., Asgarpoor, S., Billinton, R., ... & Grigg, C. (2001). The present status of maintenance strategies and the impact of maintenance on reliability. *IEEE Transactions on power systems*, 16(4), 638-646.
- Eti, M. C., Ogaji, S. O. T., & Probert, S. D. (2006). Reducing the cost of preventive maintenance (PM) through adopting a proactive reliability-focused culture. *Applied energy*, 83(11), 1235-1248.

- Fausett, L. (1994). *Fundamentals of neural networks: architectures, algorithms, and applications*. Prentice-Hall, Inc.
- Fawcett, T. (2004). ROC graphs: Notes and practical considerations for researchers. *Machine learning*, 31(1), 1-38.
- Ferri, C, Hernández-Orallo, J., & Modroiu, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*, 30(1), 27-38.
- Flett, J. & Bone, G. M. (2016). Fault detection and diagnosis of diesel engine valve trains. *Mechanical Systems and Signal Processing*, 72, 316-327.
- Frank, P. M. (1996). Analytical and qualitative model-based fault diagnosis—a survey and some new results. *European Journal of control*, 2(1), 6-28.
- Gan, M., Wang, C., & Zhu, C. (2016). Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings. *Mechanical Systems and Signal Processing*, 72, 92-104.
- Gao, Z., Cecati, C., & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 62(6), 3757-3767.
- Gao, X., & Hou, J. (2016). An improved SVM integrated GS-PCA fault diagnosis approach of Tennessee Eastman process. *Neurocomputing*, 174, 906-911.
- Garcia, M. C., Sanz-Bobi, M. A., & Del Pico, J. (2006). SIMAP: Intelligent System for Predictive Maintenance: Application to the health condition monitoring of a windturbine gearbox. *Computers in Industry*, 57(6), 552-568.
- Ghahramani, Z. (2003, February). Unsupervised learning. In *Summer School on Machine Learning* (pp. 72-112). Springer, Berlin, Heidelberg.
- Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553), 452.
- Halkidi, M., Batistakis, Y., & Vazirgiannis, M. (2001). On clustering validation techniques. *Journal of intelligent information systems*, 17(2-3), 107-145.
- Han T, Jiang D and Wang N (2016) The fault feature extraction of rolling bearing based on EMD and difference spectrum of singular value. *Shock and Vibration*: 1–14
- Hashemian, H. M. (2010). State-of-the-art predictive maintenance techniques. *IEEE Transactions on Instrumentation and measurement*, 60(1), 226-236.

Heng, R. B. W., & Nor, M. J. M. (1998). Statistical analysis of sound and vibration signals for monitoring rolling element bearing condition. *Applied Acoustics*, 53(1-3), 211-226.

Henriquez, P., Alonso, J. B., Ferrer, M. A., and Travieso, C. M. (2014). Review of automatic fault diagnosis systems using audio and vibration signals. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44(5), 642-652.

Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.

Hoang, D. T., & Kang, H. J. (2019). A survey on Deep Learning based bearing fault diagnosis. *Neurocomputing*, 335, 327-335.

Huang, Z. (1998). Extensions to the k-means algorithm for clustering large data sets with categorical values. *Data mining and knowledge discovery*, 2(3), 283-304.

Isermann, R., & Balle, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control engineering practice*, 5(5), 709-719.

Iwaniec, M., Holovatyy, A., Teslyuk, V., Lobur, M., Kolesnyk, K., & Mashevskaya, M. (2017, April). Development of vibration spectrum analyzer using the Raspberry Pi microcomputer and 3-axis digital MEMS accelerometer ADXL345. In *2017 XIIIth International Conference on Perspective Technologies and Methods in MEMS Design (MEMSTECH)* (pp. 25-29). IEEE.

Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.

Jain, A. K., Duin, R. P. W., & Mao, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1), 4-37.

Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7), 1483-1510.

Jia, F., Lei, Y., Lin, J., Zhou, X., & Lu, N. (2016). Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, 72, 303-315.

- Jing, C., & Hou, J. (2015). SVM and PCA based fault classification approaches for complicated industrial process. *Neurocomputing*, 167, 636-642.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Junbo, T., Weining, L., Juneng, A., & Xueqian, W. (2015, May). Fault diagnosis method study in roller bearing based on wavelet transform and stacked auto-encoder. In *The 27th Chinese Control and Decision Conference (2015 CCDC)* (pp. 4608-4613). IEEE.
- Jung, D., Zhang, Z., & Winslett, M. (2017, April). Vibration analysis for iot enabled predictive maintenance. In *2017 IEEE 33rd International Conference on Data Engineering (ICDE)* (pp. 1271-1282). IEEE.
- Kang, M., Kim, J., Wills, L. M., & Kim, J. M. (2015). Time-varying and multiresolution envelope analysis and discriminative feature analysis for bearing fault diagnosis. *IEEE Transactions on Industrial Electronics*, 62(12), 7749-7761.
- Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with applications*, 38(3), 1876-1886.
- Khan, S., & Yairi, T. (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241-265.
- Koço, S., & Capponi, C. (2013, October). On multi-class classification through the minimization of the confusion matrix norm. In *Asian Conference on Machine Learning* (pp. 277-292).
- Kotsiantis, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. *Informatica*, 31, 249-268.
- Kotsiantis, S. B. (2013). Decision trees: a recent overview. *Artificial Intelligence Review*, 39(4), 261-283.
- Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, 26(3), 159-190.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436.
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., & Siegel, D. (2014). Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. *Mechanical systems and signal processing*, 42(1-2), 314-334.

- Lei, Y., Lin, J., He, Z., & Zuo, M. J. (2013). A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical systems and signal processing*, 35(1-2), 108-126.
- Lei Y, Jia F, Lin J, Xing S and Ding SX (2016) An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on Industrial Electronics* 63(5): 3137-3147.
- Lei, Y., Lin, J., Zuo, M. J., & He, Z. (2014). Condition monitoring and fault diagnosis of planetary gearboxes: A review. *Measurement*, 48, 292-305.
- Li, Z., Wang, Y., & Wang, K. S. (2017). Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. *Advances in Manufacturing*, 5(4), 377-387.
- Li, H., Zheng, H., & Tang, L. (2006, September). Wigner-Ville distribution based on EMD for faults diagnosis of bearing. In *International Conference on Fuzzy Systems and Knowledge Discovery* (pp. 803-812). Springer, Berlin, Heidelberg.
- Likas, A., Vlassis, N., & Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2), 451-461.
- Liu, Y., Guo, L., Wang, Q., An, G., Guo, M., & Lian, H. (2010). Application to induction motor faults diagnosis of the amplitude recovery method combined with FFT. *Mechanical Systems and Signal Processing*, 24(8), 2961-2971.
- Liu, L., Logan, K. P., Cartes, D. A., & Srivastava, S. K. (2007). Fault detection, diagnostics, and prognostics: software agent solutions. *IEEE Transactions on Vehicular Technology*, 56(4), 1613-1622.
- Liu, B., Riemenschneider, S., & Xu, Y. (2006). Gearbox fault diagnosis using empirical mode decomposition and Hilbert spectrum. *Mechanical Systems and Signal Processing*, 20(3), 718-734.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26.
- Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108, 33-47.

- Liu, W., Kong, C., Niu, Q., Jiang, J., & Zhou, X. (2020). A method of NC machine tools intelligent monitoring system in smart factories. *Robotics and Computer-Integrated Manufacturing*, 61, 101842.
- Lu, W. Z., & Wang, D. (2014). Learning machines: Rationale and application in ground-level ozone prediction. *Applied Soft Computing*, 24, 135-141.
- Lu, C., Wang, Z. Y., Qin, W. L., & Ma, J. (2017). Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification. *Signal Processing*, 130, 377-388.
- Lu, W., Wang, X., Yang, C., & Zhang, T. (2015, May). A novel feature extraction method using deep neural network for rolling bearing fault diagnosis. In *The 27th Chinese Control and Decision Conference (2015 CCDC)* (pp. 2427-2431). IEEE.
- Luo, B., Wang, H., Liu, H., Li, B., & Peng, F. (2018). Early fault detection of machine tools based on deep learning and dynamic identification. *IEEE Transactions on Industrial Electronics*, 66(1), 509-518.
- Lou, X., & Loparo, K. A. (2004). Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical systems and signal processing*, 18(5), 1077-1095.
- MacGregor, J., & Cinar, A. (2012). Monitoring, fault diagnosis, fault-tolerant control and optimization: Data driven methods. *Computers & Chemical Engineering*, 47, 111-120.
- Maruthi, G. S., & Hegde, V. (2015). Application of MEMS accelerometer for detection and diagnosis of multiple faults in the roller element bearings of three phase induction motor. *IEEE Sensors journal*, 16(1), 145-152.
- McCall, J. J. (1965). Maintenance policies for stochastically failing equipment: a survey. *Management science*, 11(5), 493-524.
- Mehta, M., Agrawal, R., & Rissanen, J. (1996, March). SLIQ: A fast scalable classifier for data mining. In *International conference on extending database technology* (pp. 18-32). Springer, Berlin, Heidelberg.
- Misra, M., Yue, H. H., Qin, S. J., & Ling, C. (2002). Multivariate process monitoring and fault diagnosis by multi-scale PCA. *Computers & Chemical Engineering*, 26(9), 1281-1293.
- Nandi, S., Toliyat, H. A., & Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors—A review. *IEEE transactions on energy conversion*, 20(4), 719-729.

- Niu, G. (2017). *Data-driven technology for engineering systems health management*. Beijing, China: Springer.
- Orhan, S., Aktürk, N., & Celik, V. (2006). Vibration monitoring for defect diagnosis of rolling element bearings as a predictive maintenance tool: Comprehensive case studies. *Ndt & E International*, 39(4), 293-298.
- Pham, D. T., & Afify, A. A. (2005). Machine-learning techniques and their applications in manufacturing. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219(5), 395-412.
- Palácios, R. H. C., da Silva, I. N., Goedtel, A., & Godoy, W. F. (2015). A comprehensive evaluation of intelligent classifiers for fault identification in three-phase induction motors. *Electric Power Systems Research*, 127, 249-258.
- Paya, B. A., Esat, I. I., & Badi, M. N. M. (1997). Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical systems and signal processing*, 11(5), 751-765.
- Peng, Z., & Kessissoglou, N. (2003). An integrated approach to fault diagnosis of machinery using wear debris and vibration analysis. *Wear*, 255(7-12), 1221-1232.
- Pinjala, S. K., Pintelon, L., & Vereecke, A. (2006). An empirical investigation on the relationship between business and maintenance strategies. *International journal of production economics*, 104(1), 214-229.
- Pintelon, L. M., & Gelders, L. F. (1992). Maintenance management decision making. *European journal of operational research*, 58(3), 301-317.
- Praveenkumar, T., Saimurugan, M., Krishnakumar, P., & Ramachandran, K. I. (2014). Fault diagnosis of automobile gearbox based on machine learning techniques. *Procedia Engineering*, 97, 2092-2098.
- Prieto, M. D., Cirrincione, G., Espinosa, A. G., Ortega, J. A., & Henao, H. (2012). Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks. *IEEE Transactions on Industrial Electronics*, 60(8), 3398-3407.
- Qin, S. J. (2012). Survey on data-driven industrial process monitoring and diagnosis. *Annual reviews in control*, 36(2), 220-234.
- Quinlan, J. R. (1993). C4. 5: Programs for machine learning. Morgan Kaufmann, San Francisco. *C4. 5: Programs for machine learning. Morgan Kaufmann, San Francisco.*

- Racz, S. G., Breaz, R. E., & Cioca, L. I. (2020). Hazards That Can Affect CNC Machine Tools during Operation—An AHP Approach. *Safety*, 6(1), 10.
- Randall, R. B. (2011). *Vibration-based condition monitoring: industrial, aerospace and automotive applications*. John Wiley & Sons.
- Ratcliffe, C., Heider, D., Crane, R., Krauthauser, C., Yoon, M. K., & Gillespie Jr, J. W. (2008). Investigation into the use of low cost MEMS accelerometers for vibration based damage detection. *Composite Structures*, 82(1), 61-70.
- Ridwan, F., & Xu, X. (2013). Advanced CNC system with in-process feed-rate optimisation. *Robotics and Computer-Integrated Manufacturing*, 29(3), 12-20.
- Randall, R. B., & Antoni, J. (2011). Rolling element bearing diagnostics—A tutorial. *Mechanical systems and signal processing*, 25(2), 485-520.
- Renwick, J. T., & Babson, P. E. (1985). Vibration Analysis---A Proven Technique as a Predictive Maintenance Tool. *IEEE Transactions on Industry Applications*, (2), 324-332.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Safizadeh, M. S., & Latifi, S. K. (2014). Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Information Fusion*, 18, 1-8.
- Saimurugan, M., Ramachandran, K. I., Sugumaran, V., & Sakthivel, N. R. (2011). Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*, 38(4), 3819-3826.
- Sakthivel, N. R., Sugumaran, V., & Babudevasenapati, S. (2010). Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. *Expert Systems with Applications*, 37(6), 4040-4049.
- Samanta, B., & Al-Balushi, K. R. (2003). Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical systems and signal processing*, 17(2), 317-328.
- Samanta, B. (2004). Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical systems and signal processing*, 18(3), 625-644.

- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Selçuk, S. (2017). Predictive maintenance, its implementation and latest trends. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 231(9), 1670-1679.
- Sezer, E., Romero, D., Guedea, F., Macchi, M., & Emmanouilidis, C. (2018, June). An industry 4.0-enabled low cost predictive maintenance approach for smes. In *2018 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)* (pp. 1-8). IEEE.
- Shafer, J., Agrawal, R., & Mehta, M. (1996, September). SPRINT: A scalable parallel classifier for data mining. In *VLDB* (Vol. 96, pp. 544-555).
- Shao, H., Jiang, H., Zhang, X., & Niu, M. (2015). Rolling bearing fault diagnosis using an optimization deep belief network. *Measurement Science and Technology*, 26(11), 115002.
- Shao, H., Jiang, H., Lin, Y., & Li, X. (2018). A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders. *Mechanical Systems and Signal Processing*, 102, 278-297.
- Sharma, A., Amarnath, M., & Kankar, P. K. (2016). Feature extraction and fault severity classification in ball bearings. *Journal of Vibration and Control*, 22(1), 176-192.
- Shen, C., Wang, D., Kong, F., & Peter, W. T. (2013). Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier. *Measurement*, 46(4), 1551-1564.
- Shin, H. C., Orton, M. R., Collins, D. J., Doran, S. J., & Leach, M. O. (2012). Stacked autoencoders for unsupervised feature learning and multiple organ detection in a pilot study using 4D patient data. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1930-1943.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... & Dieleman, S. (2016). Mastering the game of Go with deep neural networks and tree search. *nature*, 529(7587), 484.
- Sim, S. H., & Endrenyi, J. (1988). Optimal preventive maintenance with repair. *IEEE Transactions on Reliability*, 37(1), 92-96.

- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Sorsa, T., & Koivo, H. N. (1993). Application of artificial neural networks in process fault diagnosis. *Automatica*, 29(4), 843-849.
- Strauß, P., Schmitz, M., Wöstmann, R., & Deuse, J. (2018, December). Enabling of Predictive Maintenance in the Brownfield through Low-Cost Sensors, an IIoT-Architecture and Machine Learning. In *2018 IEEE International Conference on Big Data (Big Data)* (pp. 1474-1483). IEEE.
- Sun, W., Chen, J., & Li, J. (2007). Decision tree and PCA-based fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 21(3), 1300-1317.
- Sun, W., Shao, S., Zhao, R., Yan, R., Zhang, X., & Chen, X. (2016). A sparse auto-encoder-based deep neural network approach for induction motor faults classification. *Measurement*, 89, 171-178.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A. (2014). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812-820.
- Tang, T. D., Bohez, E. L., & Koomsap, P. (2007). The sweep plane algorithm for global collision detection with workpiece geometry update for five-axis NC machining. *Computer-Aided Design*, 39(11), 1012-1024.
- Tang, B., Liu, W., & Song, T. (2010). Wind turbine fault diagnosis based on Morlet wavelet transformation and Wigner-Ville distribution. *Renewable Energy*, 35(12), 2862-2866.
- Tao, S., Zhang, T., Yang, J., Wang, X., & Lu, W. (2015). Bearing fault diagnosis method based on stacked autoencoder and softmax regression. In *2015 34th Chinese Control Conference (CCC)* (pp. 6331-6335). IEEE.
- Tidriri, K., Chatti, N., Verron, S., & Tiplica, T. (2016). Bridging data-driven and model-based approaches for process fault diagnosis and health monitoring: A review of researches and future challenges. *Annual Reviews in Control*, 42, 63-81.
- Valdez-Flores, C., & Feldman, R. M. (1989). A survey of preventive maintenance models for stochastically deteriorating single-unit systems. *Naval Research Logistics (NRL)*, 36(4), 419-446.

- Vapnik, V. N. (1995). The nature of statistical learning. *Theory*.
- Venkatasubramanian, V., Rengaswamy, R., Yin, K., & Kavuri, S. N. (2003). A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. *Computers & chemical engineering*, 27(3), 293-311.
- Venkatasubramanian, V., Rengaswamy, R., & Kavuri, S. N. (2003). A review of process fault detection and diagnosis: Part II: Qualitative models and search strategies. *Computers & chemical engineering*, 27(3), 313-326.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., & Yin, K. (2003). A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers & chemical engineering*, 27(3), 327-346.
- Wang, L., Chu, J., & Wu, J. (2007). Selection of optimum maintenance strategies based on a fuzzy analytic hierarchy process. *International journal of production economics*, 107(1), 151-163.
- Wang, Y., Liu, M., Bao, Z., & Zhang, S. (2019). Stacked sparse autoencoder with PCA and SVM for data-based line trip fault diagnosis in power systems. *Neural Computing and Applications*, 31(10), 6719-6731.
- Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144-156.
- Wang, J., Mo, Z., Zhang, H., & Miao, Q. (2019). A deep learning method for bearing fault diagnosis based on time-frequency image. *IEEE Access*, 7, 42373-42383.
- Wang, T., Qi, J., Xu, H., Wang, Y., Liu, L., & Gao, D. (2016). Fault diagnosis method based on FFT-RPCA-SVM for cascaded-multilevel inverter. *ISA transactions*, 60, 156-163.
- Wang, Y., Xiang, J., Markert, R., & Liang, M. (2016). Spectral kurtosis for fault detection, diagnosis and prognostics of rotating machines: A review with applications. *Mechanical Systems and Signal Processing*, 66, 679-698.
- Wang, Y., Yao, H., & Zhao, S. (2016). Auto-encoder based dimensionality reduction. *Neurocomputing*, 184, 232-242.

- Wang, X., Zheng, Y., Zhao, Z., & Wang, J. (2015). Bearing fault diagnosis based on statistical locally linear embedding. *Sensors*, 15(7), 16225-16247.
- Wen, L., Gao, L., & Li, X. (2017). A new deep transfer learning based on sparse auto-encoder for fault diagnosis. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(1), 136-144.
- Widodo, A., & Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574.
- Witten, I. H., Frank, E., & Hall, M. A. (2005). Practical machine learning tools and techniques. *Morgan Kaufmann*, 578.
- Wold, S., Esbensen, K., & Geladi, P. (1987). Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3), 37-52.
- Worden, K., Staszewski, W. J., & Hensman, J. J. (2011). Natural computing for mechanical systems research: A tutorial overview. *Mechanical Systems and Signal Processing*, 25(1), 4-111.
- Wuest, T., Weimer, D., Irgens, C., & Thoben, K. D. (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4(1), 23-45.
- Xueyi, L. I., Jialin, L. I., Yongzhi, Q. U., & David, H. E. (2019). Semi-supervised gear fault diagnosis using raw vibration signal based on deep learning. *Chinese Journal of Aeronautics*.
- Yan, R., Gao, R. X., & Chen, X. (2014). Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal processing*, 96, 1-15.
- Yang, B. S., Di, X., & Han, T. (2008). Random forests classifier for machine fault diagnosis. *Journal of mechanical science and technology*, 22(9), 1716-1725.
- Yen, G. G., & Lin, K. C. (2000). Wavelet packet feature extraction for vibration monitoring. *IEEE transactions on industrial electronics*, 47(3), 650-667.
- Yin, S., Ding, S. X., Xie, X., & Luo, H. (2014). A review on basic data-driven approaches for industrial process monitoring. *IEEE Transactions on Industrial Electronics*, 61(11), 6418-6428.

- Yin, S., & Kaynak, O. (2015). Big data for modern industry: challenges and trends [point of view]. *Proceedings of the IEEE*, 103(2), 143-146.
- Yin, S., Li, X., Gao, H., & Kaynak, O. (2014). Data-based techniques focused on modern industry: An overview. *IEEE Transactions on Industrial Electronics*, 62(1), 657-667.
- Yu, D., Cheng, J., & Yang, Y. (2005). Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings. *Mechanical systems and signal processing*, 19(2), 259-270.
- Yu, W., Dillon, T. S., Mostafa, F., Rahayu, W., & Liu, Y. (2019). A Global Manufacturing Big Data Ecosystem for Fault Detection in Predictive Maintenance. *IEEE Transactions on Industrial Informatics*, 16(1), 183-192.
- Yuan, S. F., & Chu, F. L. (2006). Support vector machines-based fault diagnosis for turbo-pump rotor. *Mechanical Systems and Signal Processing*, 20(4), 939-952.
- Zabalza, J., Ren, J., Zheng, J., Zhao, H., Qing, C., Yang, Z., ... & Marshall, S. (2016). Novel segmented stacked autoencoder for effective dimensionality reduction and feature extraction in hyperspectral imaging. *Neurocomputing*, 185, 1-10.
- Zhang, Z., Jiang, T., Li, S., & Yang, Y. (2018). Automated feature learning for nonlinear process monitoring—An approach using stacked denoising autoencoder and k-nearest neighbor rule. *Journal of Process Control*, 64, 49-61.)
- Zhang, R., Peng, Z., Wu, L., Yao, B., & Guan, Y. (2017). Fault diagnosis from raw sensor data using deep neural networks considering temporal coherence. *Sensors*, 17(3), 549.
- Zhang, N., Wu, L., Yang, J., & Guan, Y. (2018). Naive bayes bearing fault diagnosis based on enhanced independence of data. *Sensors*, 18(2), 463.
- Zhang, Y., Xu, X., & Liu, Y. (2011). Numerical control machining simulation: a comprehensive survey. *International Journal of Computer Integrated Manufacturing*, 24(7), 593-609.
- Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, 13(3), 2213-2227.
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.

Zheng, J., Pan, H., & Cheng, J. (2017). Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines. *Mechanical Systems and Signal Processing*, 85, 746-759.

Zhong, X., & Enke, D. (2017). Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, 67, 126-139.



TEŞEKKÜR

Uzun ve yorucu bir çalışma sonucu ortaya çıkan tezimin bilime katkı sağlamasını umuyorum. Tez çalışmam sırasında hem manevi olarak yanımda olan hem de tezimin redaktesini yaparak bana destek olan eşim Güzin Gül YURTSEVER'e, bu süreçte bilgisayar başına her geçtiğimde çalışmamı teşvik eden oğlum Çağan YURTSEVER'e teşekkürlerimi sunarım. Tezimin uygulama kısmında çalışmamıza ortam sağlayan Volt Elektrik Motorları fabrikasına, fabrikada her türlü desteği gösteren üretim ve teknoloji grup müdürü Gökhan YAKAN'a ve üretim yöneticisi Atanur İZ'e teşekkürlerimi borç bilirim. Doktora eğitimim boyunca katkılarını hiç esirgemeyen Hocalarım Prof. Dr. Sayın Haluk SOYUER'e, Prof. Dr. Sayın Vahap TECİM'e ve tabi ki her zaman bana güvenen, akademik anlamda bana çok şey kazandıran tez danışmanım Dr. Öğr. Üyesi Sayın Ural Gökay ÇİÇEKLİ'ye teşekkürlerimi ve saygılarımı sunarım.

ÖZGEÇMİŞ

Mustafa YURTSEVER

Görevi: Öğretim Görevlisi

Kişisel Bilgiler

Doğum Tarihi: 17.09.1984

Medeni Hali: Evli

Askerlik Durumu: Aralık 2007- Mayıs 2008(Kısa Dönem)

İletişim

İş Adresi: Dokuz Eylül Üniversitesi Tınaztepe Yerleşkesi, Akıllı Kart Birimi

35160 Buca, İzmir

Telefon: 0232 3018996

Cep Tel: 05072964275

E-posta: mustafa.yurtsever@deu.edu.tr

Deneyimler

2012 – Devam ediyor

Dokuz Eylül Üniversitesi Bilgi İşlem Dairesi Başkanlığı

Öğretim Görevlisi

2008 - 2010

Dokuz Eylül Üniversitesi Eğitim Fakültesi BÖTE

2547 Sayılı Kanunun 31. Madde ile Öğretim Görevliliği (4 Dönem)

2006 - 2012

Milli Eğitim Bakanlığı

Bilişim Teknolojileri Öğretmeni

Dereceler

YDS (2019):	81.25
Yüksek Lisans:	3.81 / 4.00
Lisans(BÖTE):	83.92 / 100

Eğitimler

2016 - 2020	Ege Üniversitesi – Sosyal Bilimler Enstitüsü İşletme - Doktora(PhD) Tez Konusu: Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile Titreşim Analizi Tabanlı Arıza Teşhis ve Kestirimci Bakım Sistemi Tasarımı
2012-2015	Dokuz Eylül Üniversitesi – Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri - Yüksek Lisans (MSc)
2001-2006	Ege Üniversitesi – Eğitim Fakültesi Bilgisayar ve Öğretim Teknolojileri Öğretmenliği

Akademik Yayınlar

Yüksek Lisans(Tez)	Mini Bilgisayarların Akıllı Kart Sistemleri için Tasarlanması ve Uygulanması: Üniversite Örneği. (2015)
Makale	Yurtsever, M, Tecim, V. (2016) Mini Bilgisayarların Akıllı Kart Sistemleri için Tasarlanması ve Uygulanması: Üniversite Örneği. Yönetim Bilişim Sistemleri Dergisi, 2 (1), 13-28.

Bildiriler

Yurtsever, M. & Tecim, V. Mini Bilgisayarların Akıllı Kart Sistemleri için Tasarlanması ve Uygulanması: Üniversite Örneği. II. Ulusal Yönetim Bilişim Sistemleri Kongresi, Erzurum, 2015.

Yurtsever, M. & Tecim, V. Forecasting Meal Requirements Using Time Series Methods in Organization. The Economies of the Balkan and the Eastern European Countries in the changing World, Warsaw, 2018

Yurtsever, M. & Çiçekli, G. Kestirimci Bakım için Nesnelerin İnterneti Tabanlı Bir Sistem Tasarımı. İzmir Uluslararası İktisadi İdari Bilimler Kongresi, İzmir, 2018

İş Zekasının Yönetici Kararlarına Etkisi: Üniversite Örneği, 6. Uluslararası Yönetim Bilişim Sistemleri Kongresi, İstanbul, 2019

Kitap İçi Bölüm

Kestirimci Bakım için Nesnelerin İnterneti Tabanlı Bir Sistem Tasarımı, İZCEAS 2018 NEW TRENDS IN ECONOMICS AND ADMINISTRATIVE SCIENCES, 2018

Bilişim Etiği ve Telif Hakları, BİLİŞİM TEKNOLOJİLERİ, Nobel Yayıncılık, 2019

Dosya Yönetimi, BİLİŞİM TEKNOLOJİLERİ, Nobel Yayıncılık, 2019

Yabancı Diller**İngilizce**

Writing and Reading Intermediate,
Speaking Intermediate

Projeler

- Dokuz Eylül Üniversitesi Hızlı Geçiş Sistemi(HGS) Uygulaması
- Dokuz Eylül Üniversitesi Akıllı Kart Sistemi İçerisinde Çalışan Endüstriyel PC Yazılım Geliştirme (Raspberry Pi - Python ile)
- DEPARK Personel Devam Kontrol Sistemi

- Dokuz Eylül Üniversitesi Kantin ve Kafeteryalar için Yükleme ve Harcama Kiosk Yazılımı
- Dokuz Eylül Üniversitesi Akıllı Kart Sistemi Oracle Database Tasarımı
- Dokuz Eylül Üniversitesi Güvenlik Geçiş İzleme Ekranı
- Dokuz Eylül Üniversitesi Hemşirelik Öğrenci Devam Kontrol Sistemi
- Dokuz Eylül Üniversitesi Rektörlük Personel Devam Kontrol Sistemi
- Dokuz Eylül Üniversitesi Akıllı Kart Birimi Arıza Takip Sistemi
- Sağlık Bakanlığı 112 Acil Servis Kantin, Güvenlik ve Yemekhane Geçiş Yazılımları
- Selçuk Belediyesi Personel Devam Kontrol Sistemi

Çalışma Alanları

Yönetim Bilişim Sistemleri, Makine Öğrenme, Derin Öğrenme, Kestirimci Bakım, İş Zekası