

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİYEL KUTULAMA ROBOTLARINDA MAKİNE
ÖĞRENMESİ TEMELLİ ARIZA TAHMİNİ İLE KESTİRİMCİ BAKIM
UYGULAMASI

Onur KOCA

YÜKSEK LİSANS TEZİ

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı

Kontrol ve Otomasyon Mühendisliği Programı

Danışman

Doç.Dr. Özgür Turay KAYMAKÇI

Şubat, 2021

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENDÜSTRİYEL KUTULAMA ROBOTLARINDA MAKİNE ÖĞRENMESİ
TEMELLİ ARIZA TAHMİNİ İLE KESTİRİMCİ BAKIM UYGULAMASI**

Onur KOCA tarafından hazırlanan tez çalışması 01.02.2021 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Mühendisliği Anabilim Dalı, Kontrol ve Otomasyon Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Özgür Turay KAYMAKÇI
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Özgür Turay KAYMAKÇI, Danışman
Yıldız Teknik Üniversitesi

Dr. Öğr. Üye. Muharrem MERCİMEK, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Gökhan GELEN, Üye
Bursa Teknik Üniversitesi

Danışmanım Doç.Dr. Özgür Turay KAYMAKÇI sorumluluğunda tarafımca hazırlanan Endüstriyel Kutulama Robotlarında Makine Öğrenmesi Temelli Arıza Tahmini İle Kestirimci Bakım Uygulaması başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Onur KOCA

İmza

Aileme

ve

biricik eşime

TEŞEKKÜR

Bu çalışmada fabrikamızdaki, üretim süreçlerinin daha verimli kılmak, plansız duruşların önüne geçebilmek, bakım faaliyetlerini daha sistematik bir şekilde tasarlanması amaçlanmıştır. Tasarlanan kurgu, mevcut veriler üzerinden yapay zekâ algoritmaları ve ekipmanların güvenilirlik analizi hesapları ile ötüştürölerek incelenmek istenmiştir.

Disiplini ve özverili bir çalışmanın ardından yüksek lisans tezimi bitirmeyi başardım. Çalışmamda konunun belirlenmesi, araştırılması, planlanması ve yürütölmesinde, tüm desteğı, bilgisi ve liderliğı ile her zaman yanımda olan saygideğer danışman hocam Doç.Dr. Özgür Turay KAYMAKÇI'ya ve saygideğer hocam Dr.Öğr.Üye. Muharrem MERCİMEK'e teşekkürü bir borç bilirim.

Yüksek lisans eğitimim boyunca yardımcı, bilgisi ve tecrübesi ile sürekli destek olan, çalışma ortamında işlerin yoğunlaştığı dönemde dahi bana karşı anlayışını kaybetmeyen yöneticim Abdullah ÇİLDAN'a sonsuz teşekkür ve saygılarımı sunarım.

Son olarak bu süreçte yılmadan sıkılmadan yanımda olan, her koşulda destekleyip güç veren, çocuklarımin annesi canım eşim Hatice KOCA'ya, beni yetiştirip büyüten, hayatın tüm zorluklarına hazırlayan, haklarını hiçbir zaman ödeyemeceğim canım annem Güler KOCA, canım babam İbrahim KOCA ve canım kardeşim Ramazan KOCA'ya verdikleri destek için sonsuz teşekkürlerimi sunarım.

Onur KOCA

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xv
1 GİRİŞ	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	3
1.3 Hipotez.....	3
2 HATADA GÜVENLİ SİSTEMLER	4
2.1 Güvenilirlik Nedir	4
2.2 Güvenilirlik ve Hata Fonksiyonları.....	4
2.3 Güvenilirlik Durum Değişkenleri ve Fonksiyonları.....	5
2.3.1 Hata Zamanı.....	5
2.3.2 Güvenilirlik ve Hata Fonksiyonları.....	6
2.3.3 MTTF, MTTR ve MTBF	8
2.3.4 Poisson Bağıntısı.....	9
2.4 Güvenilirlik Blok Diagramı (Reliability Block Diagram)	11
2.5 Hata Ağacı Analizi (Fault Tree Analysis)	12
3 MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI	13
3.1 Makine Öğrenmesi Nedir	13
3.1.1 Makine Öğrenmesi Uygulama Alanları.....	13
3.1.2 Makine Öğrenmesi ve Yapay Sinir Ağları Karşılaştırması.....	14
3.2 Makine Öğrenmesine Giriş.....	15
3.2.1 Sinir Ağları ve Kapasitesi.....	16

3.2.2 Sinir Modeli.....	17
3.2.3 Ağ Mimarileri.....	19
3.2.4 Öğrenme İşlemleri.....	21
3.3 Algılayıcılar, Çok Katmanlı, Algılayıcılar, Geri Yayılım.....	24
3.3.1 Rosenblatt Algılayıcısı.....	24
3.3.2 Algılayıcı Öğrenmesi.....	26
3.3.3 Çok Katmanlı Algılayıcı Öğrenmesi (Multilayer Perceptron)	27
4 TEORİNİN ROBOT MİMARİSİNE UYGULANMASI	30
4.1 Veri Toplama, Optimizasyon ve Analiz.....	30
4.1.1 Yapay Zeka Ağı Yaklaşımı ve MLP Yapısı Kurulması.....	33
4.1.2 Robot Komponentleri Üzerinden Robot MTTF Değer Hesabı.....	34
4.1.3 Makine Arıza Bölgelerinin Gruplanması ve Güvenilirlik Analizi	39
4.1.4 Poisson Dağılımı İle Yedek Parça Analizi.....	41
4.2 Hesaplanan ve Gerçek MTTF Değer Karşılaştırılması.....	42
4.3 MLP Modeli ile Verilerin Test İşlemi.....	45
5 SONUÇ VE ÖNERİLER	47
KAYNAKÇA	48
A SİMÜLASYON SONUÇLARI	50
A.1 100 İterasyon İle Simülsayon Sonuçları.....	50
A.2 500 İterasyon İle Simülsayon Sonuçları.....	52
A.3 1.000 İterasyon İle Simülsayon Sonuçları.....	54
A.4 2.000 İterasyon İle Simülsayon Sonuçları.....	56
A.5 5.000 İterasyon İle Simülsayon Sonuçları.....	58
A.6 10.000 İterasyon İle Simülsayon Sonuçları.....	60
TEZDEN ÜRETİLMİŞ YAYINLAR	62

SİMGE LİSTESİ

y_k	Aktivasyon işlemi
$o(\Delta t)$	Belirli zaman aralığındaki hata olasılığı
E, e	Euler katsayısı
Fs	FTA sistem hata bağıntısı
t_d	Gerçek output değeri
$R(t)$	Güvenilirlik fonksiyonu
$F(t)$	Hata dağılım fonksiyonu
$X(t)$	Hata fonksiyonu
T	Hata oluşma zamanı
$\lambda(t)$	Hata oran fonksiyonu
o_d	Hesaplanan output değeri
u_k	Lineer kombinasyon outputu
k	Nöron
$f(t)$	Olasık yoğunluk fonksiyonu
μ	Onarım oranı
η	Öğrenme parametresi
x_n	Percentron giriş sinyalleri
P	Poisson dağılımı için olasılık fonksiyonu
Rs	RBD sistem güvenilirlik bağıntısı
$sgn(t)$	Signum fonksiyonu
wk_n	Sinaptik ağırlık
w^T	Sinaptik ağırlık transpozu
A	Sistemdeki ekipman adeti
Δw_i	Stokastik sinaptik ağırlık
M	Sistemin çalışma süresi
N	Tüm sistemin alt sistemi adeti
w_{old}	Update edilmemiş son sinaptik ağırlık
w_{new}	Update edilmiş sinaptik ağırlık

KISALTIMA LİSTESİ

AI	Yapay Zekâ (Artificial Intelligence)
ANN	Yapay Sinir Ağı (Artificial Neural Network)
CENELEC	Avrupa Elektrik Standardizasyon Kuruluşu (European Committee for Electrotechnical Standardization)
CRM	Müşteri İlişkileri Yönetimi (Customer Relationship Management)
DCS	Dağıtılmış Kontrol Sistemi (Distributed Control System)
EN 50128	Demir Yolları Güvenlik Standartları
ERP	Kurumsal Kaynak Planlama (Enterprise Resource Planning)
FB100	Fonksiyon Blok 100
FTA	Hata Ağacı Analizi (Fault Tree Analysis)
IEC 61511	Fonksiyonel Güvenlik Standartları
IEC 61513	Nükleer Güç Uygulamalarında Güvenlik Standartları
IEC 62061	Özel Makine Güvenlik Standartları
IEC EN 61508	Kontrol Sistemlerinin Fonksiyonel Emniyeti
IEC	Uluslararası Elektrik Sandardizasyonu (International Electrotechnical Commission)
IIOT	Endüstriyel IoT (Industrial IoT)
IOT	Nesnelerin İnterneti (Internet of Things)
ISO 26262	Otomotiv Fonksiyonel Güvenlik Standartları
MLP	Çok Katmanlı Algılayıcı (Multilevel Preceptron)
MTBF	Ortalama Hata Oluşma Süresi (Mean Time Between Failures)
MTTF	Ortalama Arıza Süresi (Mean Time To Failure)
MTTR	Ortalama Tamir Süresi (Mean Time To Restore)
RBD	Güvenlilik Blok Diagramı (Reliability Block Daigrams)
VLSI	Paralel Veri İşleme (Very Lage Scale Integration)

ŞEKİL LİSTESİ

Şekil 2.1	Güvenilirlik blok diyagramında sistemin başarılı olması.....	6
Şekil 2.2	Güvenilirlik fonksiyonunun $R(t)$ zamana göre değişimi.....	7
Şekil 2.3	Güvenilirlik blok diyagramında sistemin başarılı olması.....	11
Şekil 2.4	Hata ağacı analizinde and ve or kapıları ile oluşturulmuş diagram	12
Şekil 3.1	Görüntü tanıma işlem basamakları.....	14
Şekil 3.2	Sürücüsüz araçlarda nesne tanımlama	14
Şekil 3.3	Yapay sinir ağları ile insan göz modellemesi.....	16
Şekil 3.4	Yapay sinir ağı, nöron sinaps bağlantıları ve aktivasyon işlemi	17
Şekil 3.5	Treshold fonksiyonu $(-2,2)$ aralığında gösterimi.....	18
Şekil 3.6	Sigmoid fonksiyonu a 'ya bağlı $(-10,10)$ aralığında gösterimi.....	18
Şekil 3.7	Signum fonksiyonu $(-\infty,\infty)$ aralığında gösterimi.....	19
Şekil 3.8	Hiperbolik tanjant fonksiyonu $(-\infty,\infty)$ aralığında gösterimi.....	19
Şekil 3.9	Tek katmanlı ileri beslemeli ağ model gösterimi.....	20
Şekil 3.10	Çok katmanlı ileri beslemeli ağ model gösterimi.....	20
Şekil 3.11	Tekrarlayan (feedback) ağ model gösterimi.....	21
Şekil 3.12	Supervised learning ile MR görüntülerinden hastalık tespiti	23
Şekil 3.13	Reinforcement learning ile santraç oyunu hamle tahmini.....	24
Şekil 3.14	Rosenblatt perceptron ile vektörel ayrılmış sınıflar elde etme	25
Şekil 3.15	Doğrusal perceptron input-output modeli.....	25
Şekil 3.16	Perceptron sinaptik vektör ile verilerin sınıflandırılması.....	27
Şekil 3.17	MLP doğrusal olmayan vektörler ile verilerin sınıflandırılması.....	27
Şekil 3.18	MLP doğrusal olmayan vektörler ile input-output modeli.....	28
Şekil 3.19	MLP modelinin sigmoid fonksiyonu ile aktivasyon modeli.....	28
Şekil 4.1	MLP algoritmasında input, hidden ve output layer mimarisi.....	33
Şekil 4.2	ADL MTBF calculator programı.....	35
Şekil 4.3	Robot servo motor MTBF değerinin hesaplanması.....	35
Şekil 4.4	Servo motor NPRD-95 mekanik standardına göre MTBF değeri.....	36
Şekil 4.5	Robot transport sistemine ait FTA diagramı.....	38
Şekil 4.6	Robot grup 0 için hesaplanan güvenilirlik ve hata analizi.....	42

Şekil 4.7 Robot grup 1 için hesaplanan güvenilirlik ve hata analizi.....	43
Şekil 4.8 Robot grup 2 için hesaplanan güvenilirlik ve hata analizi.....	43
Şekil 4.9 Robot hesaplanan güvenilirlik ve hata analizi.....	44
Şekil 4.10 Robot MTTF değeri ile reel MTTF değer karşılaştırması.....	44
Şekil 4.11 Test verisi 13,38 gün standart sapma ile doğruluğu %73	45
Şekil 4.12 MLP algoritması 500 iterasyon sonucu train ve test data sonuçları....	46
Şekil A.1 100 iterasyon ve 12,95gün standart sapma ile doğruluğu %64	50
Şekil A.2 Makine öğrenmesi 100 iterasyon ile gerçek ve tahmin verileri.....	51
Şekil A.3 500 iterasyon ve 13,38gün standart sapma ile doğruluğu %82	52
Şekil A.4 Makine öğrenmesi 500 iterasyon ile gerçek ve tahmin verileri.....	53
Şekil A.5 1.000 iterasyon ve 13,83gün standart sapma ile doğruluğu %73	54
Şekil A.6 Makine öğrenmesi 1.000 iterasyon ile gerçek ve tahmin verileri.....	55
Şekil A.7 2.000 iterasyon ve 7,30gün standart sapma ile doğruluğu %73	56
Şekil A.8 Makine öğrenmesi 2.000 iterasyon ile gerçek ve tahmin verileri.....	57
Şekil A.9 5.000 iterasyon ve 10,92gün standart sapma ile doğruluğu %64	58
Şekil A.10 Makine öğrenmesi 5.000 iterasyon ile gerçek ve tahmin verileri.....	59
Şekil A.11 10.000 iterasyon ve 22,2gün standart sapma ile doğruluğu %82	60
Şekil A.12 Makine öğrenmesi 10.000 iterasyon ile gerçek ve tahmin verileri.....	61

TABLO LİSTESİ

Tablo 2.1	Güvenilirlik analizi bağıntı dönüşümleri.....	7
Tablo 3.1	Makine öğrenmesi train işlem adımları.....	22
Tablo 4.1	Train verisinin sigmoid fonksiyon ile aralığında optimizasyonu	31
Tablo 4.2	Makine öğrenmesi algoritmasında train arıza bildirim verisi.....	32
Tablo 4.3	MLP mimarisinde kullanılan input ve outputlar	33
Tablo 4.4	Robot 13 adet arıza bölgesi ve arıza grupları.....	34
Tablo 4.5	Robota ait tüm ekipmanların MTBF değerleri.....	37
Tablo 4.6	Robot bölgesel hata oranları ve MTTF değerleri.....	39
Tablo 4.7	Robot hata oranlarının bölge, grup ve genel hesabı	40
Tablo 4.8	Robot poisson bağıntısı yedek parça analizi	42
Tablo 4.9	MLP ağında test edilmek üzere optimize edilmiş veriler	45
Tablo A.1	MLP train verisi 100 iterasyon ile sinaptik ağırlık hesaplama süresi ..	40
Tablo A.2	MLP test verisi gerçek, tahmin ve hata verisi	50
Tablo A.3	Gerçek ve tahmin değer farklarının ortalama ve standart sapması	50
Tablo A.4	Hata değerinin ortalamadan sapma başarısı	50
Tablo A.5	500 iterasyon ile sinaptik ağırlık hesaplama süresi	52
Tablo A.6	MLP test verisi gerçek, tahmin ve hata verisi	52
Tablo A.7	Gerçek ve tahmin değer farklarının ortalama ve standart sapması	52
Tablo A.8	Hata değerinin ortalamadan sapma başarısı	52
Tablo A.9	1.000 iterasyon ile sinaptik ağırlık hesaplama süresi	54
Tablo A.10	MLP test verisi gerçek, tahmin ve hata verisi	54
Tablo A.11	Gerçek ve tahmin değer farklarının ortalama ve standart sapması ...	54
Tablo A.12	Hata değerinin ortalamadan sapma başarısı	54
Tablo A.13	2.000 iterasyon ile sinaptik ağırlık hesaplama süresi	56
Tablo A.14	MLP test verisi gerçek, tahmin ve hata verisi	56
Tablo A.15	Gerçek ve tahmin değer farklarının ortalama ve standart sapması ...	56
Tablo A.16	Hata değerinin ortalamadan sapma başarısı	56
Tablo A.17	5.000 iterasyon ile sinaptik ağırlık hesaplama süresi	58
Tablo A.18	MLP test verisi gerçek, tahmin ve hata verisi	58

Tablo A.19	Gerçek ve tahmin değer farklarının ortalama ve standart sapması...	58
Tablo A.20	Hata değerinin ortalamadan sapma başarısı.....	58
Tablo A.21	10.000 iterasyon ile sinaptik ağırlık hesaplama süresi.....	60
Tablo A.22	MLP test verisi gerçek, tahmin ve hata verisi.....	60
Tablo A.23	Gerçek ve tahmin değer farklarının ortalama ve standart sapması...	60
Tablo A.24	Hata değerinin ortalamadan sapma başarısı.....	60

Endüstriyel Kutulama Robotlarında Makine Öğrenmesi Temelli Arıza Tahmini ile Kestirimci Bakım Uygulaması

Onur KOCA

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Özgür Turay KAYMAKÇI

Üretim sistemlerinde, operasyon sırasında tekrarlayan arızalar ve planlı bakım duruşları, üretim verimliliği açısından büyük bir öneme sahiptir. Plansız üretim duruşları ve planlı bakım sırasında uygulanan, veriye bağlı olmadan yapılan geçici müdahaleler, işletmelerde büyük zaman ve para kayıplarına neden olmaktadır.

Son zamanlarda büyük gelişmelerin yaşandığı Endüstri 4.0 teknolojileri, makinelerden toplanan gerçek zamanlı verileri (BigData) kapsamlı bir şekilde depolanarak potansiyel sorunların kalıcı olarak çözümü için yol göstermektedir. BigData ile birlikte oluşturulan yapay zekâ algoritmaları ile arızaların, kronik problemlerin analiz edilmesinde ve aksiyonlar alınmasında büyük öneme sahiptir. Yapay zekâ üzerinden tespit edilen aksiyon planları ile işletmelerde üretim verimliliğinin sağlanmakta ve yüksek bakım giderleri minimum seviyelere indirilmektedir.

Bu çalışmamızda, üretim hattı kutulama robotlarına ait ortalama arıza süresi (MTTF) değerleri ve geçmiş arıza verileri kullanılarak sistem arıza tahmini için yapay sinir ağı (ANN) modeli oluşturulmuştur. Nesnelerin interneti (IoT) teknolojisi kullanılmadan kurgulanan makine öğrenmesi modeli üzerinden birçok iterasyon denemesi yapılmış ve başarı yüzdesi en yüksek olan iterasyon belirlenmiştir. İlave olarak sistemin MTTF karakteristiği tespit edilerek arızaların tahmin başarısı

artırılmıştır. Yaşanan duruşların minimum sürelerde çözülebilmesi için yedek parça analizi yapılmış ve robot üzerindeki ekipmanların teknik depo adetleri belirlenmiştir. Bu sayede geçmiş arıza verileri ile robot üzerinde başarılı bir kestirimci bakım uygulaması yapılması yanında duruşların minimum sürelerde çözülmesi için çalışmalar yapılmıştır.

Anahtar Kelimeler: Endüstri 4.0, kestirimci bakım, MTTF, makine öğrenmesi, arıza tahmini

**Predictive Maintenance Application with Machine Learning Based
Failure Estimation in Industrial Packaging Robots**

Onur KOCA

Department of Control and Automation Engineering
Master of Science Thesis

Advisor: Assoc. Prof. Dr. Ozgur Turay KAYMAKCI

In the production systems during operation, repetitive downtimes and planned maintenace stops are great importance in terms of production efficiency. Temporary interventions applied during the unplanned production stops and planned maintenance, without depending on data, cause great time and money losses in facilities.

Industry 4.0 technologies, which have experienced great developments in recent times, provide guidance for solving potential problems permanently by storing real-time data (Big Data) collected from the machines comprehensively. It is great importance in analyzing downtimes, and chronic problems and taking actions with artificial intelligence algorithm created by BigData. Production efficiency is ensured and decreases high maintenance costs to minimum levels in facilities by the action plans which determined through artificial intelligence.

In this study, an artificial neural network (ANN) model has been created for system failure prediction by using mean time to failure (MTTF) values and past failure data of production line packaging robots. Many iteration attempts have been made over the machine learning model, which is designed without using the internet of things (IoT) technology, and the iteration with the highest percentage of success was determined.

In addition, the MTTF characteristic of the system was determined and the prediction success of the failures was increased. Spare parts analysis was performed and the equipments were determined on the technical warehouse, in order to solve the downtimes in the minimum periods. In this way, studies were carried out to solve the downtimes in minimum time, as well as the successful predictive maintenance application on the robot with past fault notification data.

Keywords: Industry 4.0, predictive maintenance, MTTF, machine learning, failure prediction

1

GİRİŞ

Son yıllarda teknoloji alanında tüm dünyada büyük gelişmeler yaşanmaya başladı. Bu gelişmelerin hızla artması hem gündelik yaşantımızda hem de çalışma hayatımızda bize birçok avantajı beraberlerinde getirmektedir. Kullandığımız birçok cihaz, veri toplama ve toplanan veriler üzerinden analizler yapılarak sağlık, verimlilik ve üretkenlik gibi konularda bizleri yönlendirmekte, hayat kalitemizi artırmaktadır.

Endüstriyel alandaki teknolojik gelişmeler ise firmaların üretim kapasitelerini artırılmasında, yaşanan duruşların minimize edilmesinde ve yaşanan mali kayıpların önlenmesinde büyük bir etkisi olmaktadır. Bu kapsamda dünya üzerinde artan ihtiyaçların karşılanması için Endüstri 4.0 ve Nesnelerin İnterneti (IoT) gibi birçok yeni teknolojik gelişmeler hayatımıza girmiştir. Bu gelişmelerde amaçlanan makineler üzerinden verilerin anlık toplanması, toplanan veriler ile Big Data'nın oluşturulması ve verilerin analiz edilmesidir. Analiz edilen verilerden çıkan anlamlı sonuçlar ile sistemin verimli ve minimum maliyet ile işlevselliğinin sağlanması için tedbir, önlem ve iyileştirmelerin yapılmaktadır. Örneğin, bir üretim tesisindeki robotta yaşanan bir arıza tüm üretim hattının planlanan üretimden daha azını gerçekleştirmesine, siparişlerin zamanında yetiştirmemesine, müşteri kayıplarına ve duruş sırasında yapılan müdahalelerde işçilik ve maliyet kayıplarına neden olmaktadır. İşletmelerin talebi bu kayıpların en aza indirilerek maksimum verimlilik ile üretim tesislerinin planlanan seviyelerde çalışmasını sağlamaktadır.

Günümüzde, Big Data'nın yapay zekâ (AI) algoritmaları üzerinden analiz edilmesi, sistemin öğretilmesi ve maksimum verimlilik ile makinelerin çalışması üzerine ileri seviye çalışmalar da yapılmaktadır.

1.1 Literatür Özeti

Literatürde birçok kestirimci bakım önerileri bulunmaktadır. Bu çalışmalarda genellikle sensör verileri, IoT mimarisi ile elde edilmekte ve toplanan veriler makine

öğrenmesi ve derin öğrenme modelleri ile değerlendirilmektedir [1], [2]. Titreşim, sıcaklık ve nem gibi sensörler tarafından toplanan veriler ile sistemin genel bir modeli oluşturulur. Model, toplanan Big Data verilerindeki anormallikleri tespit ederek, sistemin uyarı vermesine ve daha önemlisi üretim duruşu oluşmadan sistemin ilk bakım duruşunda ilgili anormallik için müdahale edilme imkânı sağlamaktadır. Böylelikle yapılan planlı bakım müdahaleleri ile plansız üretim duruşları, işçilik ve bakım maliyetlerinin önüne geçilmiş olunmakta ve üretim verimliliği artırılabilir.

Başka bir çalışmada ise düşük maliyetli sensörler ile oluşturulan IoT mimarisiyle veriler elde edilip veriler makine öğrenmesi modeli ile değerlendirilmiştir [3]. Bir sinir ağı yapısı, ileri beslemeli bir katman mantığı ile oluşturulur ve güvenilirlik analizi kullanılan entegre devreleri ile gerçekleştirilmektedir [4]. IoT teknolojisi yardımıyla veri toplama çalışması, verilerin bulut yapısında saklanacak bir Azure IoT oluşturulmasını ve işletmelerin kullandıkları ERP sistemleri ile haberleşmektedir [5], [6]. Değerlendirmeler sırasında kullanılan yapay zekâ uygulamaları, sistem üzerindeki tahminlerin daha hızlı ve doğru yapılmasına olanak vermektedir. Sistemin MTTF karakteristiği hesaplanmakta ve entegre devreler ile arıza tahminlerinin genel yapısı öğrenilmektedir [7]. Farklı bir uygulamada, Dağıtılmış Kontrol Sistemi (DCS) ve Endüstriyel IoT (IIoT) ile Big Data oluşturulmuştur [8], [9]. Bu sistemler makine verilerinden bir yapı oluşturulmasını ve makine öğrenmesi FB100 fonksiyon bloğu kullanılarak hata tahmini sağlanmıştır [10]. Bu şekilde hata oluşmadan önce rahatlıkla bakım ve ekipman değişim işlemlerinin gerçekleştirilmesi sağlanmıştır [11].

Endüstriyel başka bir uygulamada, IoT teknolojisi kullanılarak makine üzerinden Big Data verileri toplanmakta, ardından arıza bildirimleri ve arızalara yönelik müdahale bilgileri toplanmaktadır [12], [13]. Bu tür veriler, veri madenciliği, makine öğrenimi ve bulut teknolojilerinden oluşan Bakım 4.0 olarak isimlendirilen gelişmiş bir veri analiz aracı kullanılarak analiz edilmiştir [14]. Analiz sonucunda sistem dinamik değişkenler izlenebilmekte ve bakım teknisyeninin iş programına kestirimci bakım uygulaması olarak otomatik olarak alınabilmektedir [15].

1.2 Tezin Amacı

Bu tezin diğ er literat r  alıřmalarından farkı, oluřturulan Big Data verisi, bir IoT sens r teknolojisi ve ekstra bir ekipman kullanılmadan, sadece iřletme ERP sistemi tarafından  retilen ge miř arıza bildirimlerinden yararlanılarak oluřturulmasıdır. B ylelikle ekstra bir yatırım maliyeti oluřturmadan oluřturulan kategorize edilmiř makine Big Datası, makine  ğrenme algoritması ile sistemin modellenmesi yapılmıřtır. Yapılan model ile makine  zerinden arıza oluřmadan arızanın daha  nceden tahmin edilmesi ama lanmıřtır.

1.3 Hipotez

Yapılan bu  alıřmada,  retim hattındaki kutulama robotu  zerinden    yıllık arıza verisi toplanarak, verilerin makine  ğrenmesi algoritmasında kullanılabilecek řekilde optimize edilmiřtir ve sistemin Multilayer Perceptron (MLP) modeli oluřturulmuřtur. Ardından robot  zerindeki ekipmanların MTTF değ erleri  zerinden sistemin g venlilirlik analizi hesaplanmıřtır. Son olarak sistemin MTTF değ eri  zerinden hata oluřma sıklıėı, toplanan arıza verileri ile karřılařtırılması yapılmıřtır ve arıza test verilerinin yapay zek  algoritması  zerinden sim lasyonları yapılarak modelin hata tahmin bařarı tespit edilmiřtir.

2.1 Güvenilirlik Nedir

Son zamanlarda teknolojinin gelişmesi ile günlük yaşantımıza birçok yeni tanımlı beraberinde getirmiştir. Gelişen teknoloji ile bu teknolojiyi kullanan bireylerin sistemlere karşı güven duyma ve bu sistemleri hatasız olarak kullanabilme istekleri doğmuştur. Makine üreticileri ise hem tüketicilerin taleplerini yerine getirmek hem de maliyeti en aza düşürmek için çalışmalara başlamışlardır. Bu kapsamda ortaya çıkan güvenilirlik kavramı, belirli bir periyot boyunca bir ekipmanın istenilen bir işlevi belirli koşullar altında bozulmadan çalışma olasılığı olarak tanımlanmaktadır.

Güvenilirlik ölçüsü olarak, bir ürün satın alındığında ne kadar süre bozulmadan çalışmaya devam edecek, garanti süresi dolmadan üretilen ürünlerin kaçında bozulma olacak ve bir ürün için garanti süresi ne kadar olmalı gibi sorulara sistem cevap verebiliyor olmalıdır.

Güvenilirlik fonksiyonunda, hata oranı ve çalışma saati olmak üzere iki kriter önemlidir. Hata oranı, bir ekipmanın olasılık yoğunluğunun güvenilirlik fonksiyonuna oranı ile elde edilir. Bu oran ile bir ekipmanın hata yapmadan ne kadar süre boyunca çalıştığı bilgisine ulaşılabilir [24].

2.2 Güvenilirlik Standartları

Endüstriyel faaliyetlerden kaynaklanan büyük kazaların önlenmesi, kazalara karşı hazırlıklı olma ve kazanın gerçekleşmesi durumlarında müdahale ile ilgili önlemleri kapsayan Avrupa Birliği Konsey Direktifi ile birçok standart geliştirilmiştir. Ülkemizde de bu gibi emniyet kriterlerini kapsayan Uluslararası Standartlarda CENELEC, IEC vb. standartları TSE tarafından kabul edilmiştir. İşlevsel güvenliğin temel standardı olarak kabul edilen IEC EN 61508, elektrik, elektronik veya programlanabilir kontrol sistemleri yardımıyla oluşturulan koruma amaçlı fonksiyonları içeren tüm uygulamaları kapsar. IEC 61508 standardının kapsadığı fonksiyonlar;

- Konsept,
- Şartname,
- Tasarım ve uygulama,
- Kurulum ve devreye alma,
- Operasyon,
- Bakım,
- Devreye alındıktan sonra yapılan değişiklikler

IEC61508 standardı baz alınarak, proses endüstrisine özgü olarak IEC 61511 standardı geliştirilmiştir. Bununla beraber, ISO 26262 otomotiv elektrik/elektronik sistemler, EN 50128 demir yolları uygulamaları, IEC 61513 nükleer güç uygulamalarında kontrol ve ekipmanların gereklilikleri ve önerilerini, IEC 62061 ise özel makine uygulamaları için geliştirilmiş standartlardır.

2.3 Güvenilirlik Durum Değişkenleri ve Fonksiyonları


Bu kısımda bir sistem üzerindeki ekipmanların hata oluşmadan sağlıklı bir şekilde çalışır pozisyonunu korumak ve bu kapsamda uygun standartlarda tasarım yapabilmek için gerekli olan fonksiyonlara değinilecektir.

2.3.1 Hata Zamanı

Bir sistem tasarımı öncesi kurulacak olan proses ekipmanlarının oluşturduğu bütünün, ilk çalışmasından ilk bozulmasına kadar geçen süreye “Hata Zamanı” denir.

Başlama noktası $t = 0$ olarak alınır, T süre sonra ise hata oluştuğu belli bir olasılığa göre düşünülür. " t " zamanı sistemin $t = 0$ ile T arasındaki bir süreyi ifade etmektedir ve $X(t)$ olarak ifade edilir.

$$X(t) = \begin{cases} 1, & \text{sistem } t \text{ anında aktif} \\ 0, & \text{sistem } t \text{ anında pasif} \end{cases} \quad (2.1)$$



Şekil 2.1 Güvenilirlik blok diyagramında sistemin başarılı olması

Hata zamanı " T " her zaman için süre olarak ölçülemeyebilir. Bu durumda ise sisteme dolaylı zaman kavramaları girmektedir. Bunlar;

- Sivcin kaç kez aktif edildiği,
- Aracın kaç kilometre sürüldüğü,
- Rulmanın kaç tur attığı,
- Makinenin kaç kez açılıp kapatıldığı vb.

2.3.2 Güvenilirlik ve Hata Fonksiyonları

Bir sistem veya ekipmanın hata zamanından yola çıkarak sistemin olasılık yoğunluk fonksiyonu $f(t)$ ve hata dağılım fonksiyonu $F(t)$ ve değişkenleri elde edilerek sistemin Güvenilirlik fonksiyonu $R(t)$ bulunabilmektedir. Bu kapsamda verilen $f(t)$ veya $F(t)$ kendi içerisinde aşağıdaki uygun olasılık dönüşüm formülleri uygulanır.


$$F(t) = P(T \leq t) = \int_0^t f(u) du \quad t > 0 \text{ için} \quad (2.2)$$

$$f(t) = \frac{d}{dt}F(t) = \lim_{\Delta t \rightarrow 0} \frac{F(t + \Delta t) - F(t)}{\Delta t} = \lim_{\Delta t \rightarrow 0} \frac{P(t < T \leq t + \Delta t)}{\Delta t} \quad (2.3)$$

Verilen $f(t)$ olasılık yoğunluk fonksiyonundan yukarıdaki bağıntı ile $F(t)$ bulunur. Ardından sistemin güvenilirliği ve hata katsayısı elde edilir.

$$R(t) = 1 - F(t) = \Pr(T > t) \quad t > 0 \text{ için} \quad (2.4)$$

$$R(t) = 1 - \int_0^t f(u) du = \int_t^\infty f(u) du \quad (2.5)$$



Şekil 2.2 Güvenilirlik fonksiyonunun $R(t)$ zamana göre değişimi

$$\lambda(t) = \lim_{\Delta t \rightarrow 0} \frac{F(t + \Delta t) - F(t)}{\Delta t} \frac{1}{R(t)} = \frac{f(t)}{R(t)} \quad (2.6)$$

$$\lambda(t) = \frac{f(t)}{R(t)} = -\frac{R'(t)}{R(t)} = -\frac{d}{dt} \ln R(t) \quad R(0) = 1 \text{ için}, \quad (2.7)$$

$$\int_0^t \lambda(t) dt = -\ln R(t) \quad (2.8)$$

$$R(t) = e^{\left(\int_0^t \lambda(u) du\right)}, f(t) = \lambda(t) e^{\left(\int_0^t \lambda(u) du\right)} \quad t > 0 \text{ için} \quad (2.9)$$

Aşağıdaki Tablo 2.1'de bulunan güvenilirlik analizi bağıntıları ile birbiri arasında geçişleri de mümkündür.

Tablo 2.1 Güvenilirlik analizi bağıntı dönüşümleri

Expressed by	$F(t)$	$f(t)$	$R(t)$	$\lambda(t)$
$F(t) =$	-	$\int_0^t f(u) du$	$1 - R(t)$	$1 - \exp\left(-\int_0^t \lambda(u) du\right)$
$f(t) =$	$\frac{d}{dt} F(t)$	-	$-\frac{d}{dt} R(t)$	$\lambda(t) \cdot \exp\left(-\int_0^t \lambda(u) du\right)$
$R(t) =$	$1 - F(t)$	$\int_t^\infty f(u) du$	-	$\exp\left(-\int_0^t \lambda(u) du\right)$
$\lambda(t) =$	$\frac{dF(t)/dt}{1 - F(t)}$	$\frac{f(t)}{\int_t^\infty f(u) du}$	$-\frac{d}{dt} \ln R(t)$	-

2.3.3 MTTF, MTTR ve MTBF

Proses sistemleri birçok ekipmanın bir araya gelmesi ile oluşur. Sistemde hata oluşma olasılığı da ekipmanların her birinin sistem içerisindeki fonksiyonuna bağlı olarak hata oranlarına göre değişkenlik göstermektedir. Hata oranlarından yola çıkarak üretici firmalar ekipmanlar için belirli bir "T" anı için iki hata arası geçen süre hesaplanmaktadır. Bu süreye ise MTTF (Mean Time To Failure) olarak adlandırılmaktadır.

$$\lambda(t) = \lambda \text{ için,} \quad (2.10)$$

$$MTTF = E(\tau) = \int_0^{\infty} (1 - F(t)) dt = \int_0^{\infty} R(t) dt = \int_0^{\infty} e^{-\lambda t} dt \quad (2.11)$$

$$MTTF = -\frac{e^{-\lambda t}}{\lambda} \Big|_0^{\infty} = -\frac{e^{\lambda \infty}}{\lambda} - \left(-\frac{e^{\lambda 0}}{\lambda} \right) = 0 + \frac{1}{\lambda} \quad (2.12)$$

$$MTTF = \frac{1}{\lambda} \quad (2.13)$$

$$MTTF = \int_0^{\infty} R(t) dt \quad (2.14)$$

MTTR (Mean Time To Restore), bir ekipmanın veya sistemin arızalandığında tekrar işler hale gelmesi için geçen süre olarak ifade edilmektedir. MTTF ve MTTR değerleri ortalama değerler üzerinden verilmektedir. MTTR için bu değer, sistemin hata oluşma ile çalışır hale geçtiği toplam süre göz önüne alınmalıdır. Sistemin MTTR hesabında kullanılan süre esasları aşağıdaki gibidir;

- Hatayı bulma, tanımlama ve detaylandırma süresi,
- Yedek parça tedarik süresi,
- Tamir personeline ulaşma süresi,
- Tamir edilme süresi,
- Dokümantasyon için geçen tüm aktivite süreleri,

$$\text{restore rate: } \mu = \frac{1}{MTTR} \quad (2.15)$$

MTBF (Mean Time Between Failures), sistem veya ekipmanın hata oluşma ve tamir sürelerinin ortalama periyodik süresi olarak ifade edilebilir. Bu süre, hatanın oluşması, tüm gereken hata tespit ve tamir sürelerini kapsamaktadır.

$$MTBF = MTTF + MTTR \quad (2.16)$$

$$MTBF = \frac{1}{\lambda} + \frac{1}{\mu} \quad (2.17)$$

2.3.4 Poisson Bağıntısı

"A" , verilen bir zaman aralığında bir olayın meydana gelme durumu olsun. Homojen bir Poisson aşağıdaki varsayımları gerektirir.

- "A" zaman aralığında herhangi bir anda meydana gelebilir, t 'den bağımsız ve " λ " pozitif bir sabitken " $\lambda\Delta t + o(\Delta t)$ " ile gösterilebilir.
- $o(\Delta t)$, " $(t, t + \Delta t]$ " zaman aralığında "A" 'nın birden fazla sayıda meydana gelme olasılığıdır.

$$o(\Delta t) \rightarrow \lim_{\Delta t \rightarrow 0} \frac{o(\Delta t)}{\Delta t} = 0 \quad (2.18)$$

- " $(t_{11}, t_{12}]$, $(t_{21}, t_{22}]$, ..." , zaman periyodundaki farklı aralıklar olsun. "A" 'lar " $(t_{11}, t_{12}]$ " aralığında meydana gelir.

Sürecin " λ " yoğunluğuna sahip olduğu söylenir. Genel olarak $t = 0$ noktası sürecin başlangıç noktası alınır.

$N(t)$, $(0, t]$ aralığında "A" olayının meydana gelme sayısı,

$P(n, t) = P(N(t) = n)$ ise A olayının $(0, t]$ 'de n defa meydana gelme olasılığı,

$$p(0, t + \Delta t) = p(0, t)(1 - \lambda\Delta t - o(\Delta t)) \quad (2.19)$$

$$p(0, t + \Delta t) = p(0, t) - \lambda p(0, t)\Delta t - p(0, t)o(\Delta t) \quad (2.20)$$

$$\frac{p(0, t + \Delta t) - p(0, t)}{\Delta t} = -\lambda p(0, t) - \frac{p(0, t)o(\Delta t)}{\Delta t} \quad (2.21)$$

$$\frac{d}{dt}p(0, t) = -\lambda p(0, t) \quad (2.22)$$

Bu sebeple;

$$p(0,t) = Ce^{-\lambda t} \quad t > 0 \text{ için ve } C \text{ sabit} \quad (2.23)$$

$$p(0,0) = 1, C = 1 \quad (2.24)$$

$$p(0,t) = e^{-\lambda t} \quad t > 0 \text{ için} \quad (2.25)$$

T_1 , "A" olayının ilk defa meydana geldiği zaman olsun.

$$F_{T_1}(t) = P(T_1 \leq t) = 1 - P(T_1 > t)p(0,t) = e^{-\lambda t} \quad t > 0 \text{ için} \quad (2.26)$$

$$F_{T_1}(t) = 1 - p(0,t) \quad (2.27)$$

$$F_{T_1}(t) = 1 - e^{-\lambda t}, t < 0 \quad (2.28)$$

$$F_{T_1}(t) = 0, t > 0 \quad (2.29)$$

Burada λ parametresiyle ilk "A" olayındaki "T" zamanının üstel dağıldığı söylenir. Olasılık yoğunluğu ise;

$$f_T(t) = \begin{cases} \lambda e^{-\lambda t}, & t > 0 \quad \lambda > 0 \\ 0, & \text{diğer} \end{cases} \quad (2.29)$$

$$E(T_1) = \int_0^{\infty} t f_{T_1}(t) dt = \lambda \int_0^{\infty} t e^{-\lambda t} dt = \frac{1}{\lambda} \quad (2.29)$$

"A" olayı meydana geldiğinde süreç yeniden başlar, bu yüzden birbirini takip eden olaylar arasındaki bekleme zamanı T homojen Poisson bağıntısı ile üstel dağılır.

- λ büyük ise ortalama bekleme zamanı kısadır.
- λ küçük ise ortalama bekleme zamanı uzundur.

$$p(n,t) = \frac{(\lambda t)^n}{n!} e^{-\lambda t} \quad n = 0,1,2, \dots \quad (2.30)$$

$$E(N(t)) = \sum_{n=0}^{\infty} \frac{(\lambda t)^n}{n!} e^{-\lambda t} = \lambda t \quad (2.31)$$

$$P \leq \sum_{x=0}^n \frac{(\lambda t)^x}{x!} e^{-\lambda t} = e^{-\lambda t} [1 + \lambda t + \dots + \frac{(\lambda t)^n}{n!}] \quad (2.32)$$


$$\lambda t = \frac{1}{MTTF} t = \frac{AxNxMxT}{MTTF} \quad (2.33)$$

- "A", Bir sistemde kaç adet bulunuyor
- "N", Tüm sistemin kaç alt sisteminde bulunuyor
- "M", Belirli bir süre içerisinde ne kadar çalışıyor
- "T", Belirlenen periyodik süre
- "MTTF", Ekipmanın hata yapma süresi

2.4 Güvenilirlik Blok Diagramı (Reliability Block Diagram)

Güvenirlilik Blok Diyagramı (RBD) sistem üzerindeki ekipman arıza durumlarının kombinasyonunu grafiksel olarak gösterme metodudur. Digram, sistemin komponentlerinin kutular halinde çizilmesiyle oluşturulur. RBD, ikili durum güvenilirlik problemleri için oldukça etkilidir. İkili durum ise sistemin başarılı çalışma ve hatalı çalışma olarak iki çalışma durumunu ifade etmektedir.

RBD, çizim hattı üzerinde hat karşıya geçebiliyorsa sistem başarılıdır. Eğer bir üst katmana geçebilecek bir yol mümkün değilse sistem hatadadır. Sistemin RBD çiziminde, seri ve paralel olmak üzere iki yöntem kullanılmaktadır. Seri yollarda komponentlerden biri başarılı çalışmasını devam ettiremezse sistem hataya geçer. Paralel yollarda ise sistem yolunu diğer paralel yollar üzerinden de tamamlayabiliyorsa sistem başarılı olarak çalışmaya devam etmektedir.



Şekil 2.3 Güvenilirlik blok diyagramında sistemin başarılı olması


$$R_s = R_a \times R_b \times R_c \times \dots \quad \text{Seri sistem} \quad (2.34)$$

$$R_s = R_a + R_b - R_a \times R_b \quad \text{Paralel sistem} \quad (2.35)$$

2.5 Hata Ağacı Analizi (Fault Tree Analysis)

Hata ağacı analizi (FTA), sistem hatalarını ve sistem bileşenlerinin hatalardaki özgül problemleri olaylar arasındaki bağlantıyı gösteren mantıksal bir diyagramdır. Bu metod, tımdengelimli mantığa dayanan bir tekniktir.

FTA oluşturulması sırasında mantık kapıları kullanılmaktadır. Eğer sistemde mevcut kol üzerindeki durumlardan biri bile hata olmasına neden oluyorsa “OR”, mevcut brenç üzerindeki kollardan tamamının hataya düşmesi şartı var ise “AND” kapısı kullanılır.



Şekil 2.4 Hata ağacı analizi and ve or mantık kapıları ile oluşturulmuş diyagram

$$F_s = F_a \times F_b \times F_c \times \dots \quad \text{AND kapısı} \quad (2.36)$$

$$F_s = F_a + F_b - F_a \times F_b \quad \text{OR kapısı} \quad (2.37)$$

$$F_s = 1 - R_s \quad (2.38)$$

Not: F_s sistemin hata olasılığı, R_s sistemin güvenilirlik olasılığıdır.

MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI

3.1 Makine Öğrenmesi Nedir

Makineler veya sistemler çalıştıkları sürece veri üretmeye devam ederler. Bu verilerin kısıtlı bir zaman aralığında karşılaştırılması yapılarak makine ve sistem üzerindeki anomallikler, problemler veya proses hakkında fikir sahibi olmamızı sağlar. Resmin büyük kısmına baktığımızda haftalık, aylık veya yıllık veriler incelendiğinde, bu denli büyük miktardaki verilerin manuel işlenmesi ve analizinin yapılması mümkün değildir. Bir yanda da geçmiş verileri kullanarak sistem hakkında gelecek için tahminlerde bulunmak ve bu sayede oluşabilecek olumsuz durumlara karşı hazırlıklı olmak için de veri analizlerinin yapılması gerekmektedir. Verilerden analiz yapma ve gelecek tahminleri problemini çözmek amacıyla makine öğrenmesi (machine learning) yöntemleri geliştirilmiştir. Makine öğrenmesi yöntemleri, geçmişteki veriyi kullanarak yeni veri için en uygun modeli bulmaya çalışır. Uygulama alanı ne olursa olsun, çok miktardaki verinin analiz edilerek gelecek ile ilgili tahminlerde bulunması ve sonuçlar hakkında karar vermemize yardımcı olması ile makine öğrenmesi yöntemlerinin her geçen gün önemi artmaktadır. Makineler, insanlığın iş gücüne sağladıkları yararı, makine öğrenmesi yöntemleri ile birleştirdiklerinde beyin gücünü de sağlamayı başarmışlardır [25].


3.1.1 Makine Öğrenmesi Uygulama Alanları

Verinin kapsam ve önemi arttıkça makine öğrenmesi yöntemleri gelişmeye devam etmektedir. Bu yöntemlerin gelişmesi ile oluşan uygulama alanları;


- Perekende sektörü: Pazar analizi, müşteri ilişkileri yönetimi (CRM)
- Finans sektörü: Kredi puanlama, dolandırıcılık tespiti
- Üretim sektörünü: Üretim verimliliği optimizasyonu, sorun giderme
- Tıp sektörü: Hasta tıbbi teşhis
- Telekomünikasyon sektörü: Hizmet kalitesi artırma optimizasyonu

- Web madenciliği sektörü: Talebe yönelik arama motorları

Gündelik hayatta yaygın olarak kullanılan makine öğrenmesi örnekleri, el yazısı karakter tanımlama, sistem fonksiyon yaklaşım tespiti, sürücüsüz arabalar, bilgisayar santraç oyunları, yüz tanıma (gözlük, sakal, makyaj vb.), konuşma tanıma, semptomalara göre hastalık tahmini gibi daha birçok örnek sayabiliriz.



Şekil 3.1 Görüntü tanıma işlem basamakları



Şekil 3.2 Sürücüsüz araçlarda nesne tanımlama

3.1.2 Makine Öğrenmesi ve Yapay Sinir Ağları Kaşılaştırması

Makine öğrenmesi, örnek veriyi ve geçmiş deneyimleri kullanarak sistemin performans kriterini optimize etmek için kullanılan bir bilgisayar algoritmasıdır. Sistem olarak yapay zekânın öğrenme ve test etme işlem adımlarını kullanmaktadır. Makine öğrenmesi algoritmaları, algoritmanın istenen outputlara veya eğitimi

sırasında mevcut input türlerine bağılı olarak farklı öğrenme grupları ile organize edilebilmektedir. Bu gruplar;

- Denetimli öğrenme (Supervised learning)
- Denetimsiz öğrenme (Unsupervised learning)
- Yarı denetimli öğrenme (Semi-supervised learning)
- Pekiştirmeli öğrenme (Transductive inference)
- Gelişimsel öğrenme (Developmental learning) vb.

Yukarıdaki öğrenme grupları öğrenme işlemini birçok farklı yapı üzerinde gerçekleştirebilmektedir, yapay sinir ağı (artificial neural network-ANN) ise bu yapıların biyolojik sinir ağlarının işlevsel yönlerini kullanarak sonuçlar üretmektedir. ANN kullanarak, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi makine öğrenmesi algoritmalarında birçok işlevi sağlamak mümkündür. Bu durumda makine öğrenmesi, ANN'nin bir alt kümesi olduğunu göstermektedir.

3.2 Makine Öğrenmesine Giriş

İnsan beyni, bir veriyi işlerken herhangi bir dijital bilgisayardan tamamen farklı bir şekilde hesaplayarak sonuçlar elde eder. Beynin genel özellikleri;


- Oldukça karmaşıktır
- Doğrusal değildir
- Birbiri ile paralel çalışan birçok işlevsel fonksiyonları vardır
- Beyin, istenilen hesaplamaları gerçekleştirmek için nöronları tekrardan düzenleyebilir.
- Dünya üzerindeki en hızlı bilgisayardan çok daha hızlıdır. Örneğin, beyin bir yüz tanıma işlemini 100-200ns sürede tamamlarken, bu işlem en hızlı bilgisayar tarafından bu sürelerde gerçekleştirmesi mümkün değildir.
- Yarasa, hedefin hızını, boyutunu, yüksekliğini ve daha birçok özelliğini tanımlamak için sonar yeteneğini kullanmaktadır. Yarasanın, sonar

yeteneğinin özelliklerine, en son tasarlanan bir sonar veya radar dahi ulaşamamaktadır.

3.2.1 Sinir Ağları ve Kapasitesi

Sinir ağları non-linearity özelliği göstermektedir, bu da sistemin doğrusal olmayan ağlar boyunca yayılabildiğini göstermektedir. Sinir ağlarında input ve outputlar ile haritalandırma işlemi vardır. Popüler bir öğrenme yönetimi olan denetimli öğrenme algoritması ile beyin giriş uyarıcılar ile yapılması gereken görevi sinir ağlarının sinaptik ağırlıklarını değiştirerek öğrenmeyi sağlamakta ve sonuçlar oluşturmaktadır. Sinir ağları bu sinaptik ağırlıkları ortam değişkenlerine göre uyarlayabilme (adaptivity) yeteneğine sahiptir. Özellikle belirli bir ortamda çalışmak üzere eğitilmiş bir sinir ağı, çalışma ortamındaki küçük değişikliklerle başa çıkmak için kolayca yenide eğitilebilirler. Ayrıca ortamın dinamik olduğu, değişkenlerin sürekli değiştiği ortamlarda sinaptik ağırlıklar gerçek zamanlı olarak değişebilmektedir.

Sinir ağlarının bu kapasite fonksiyonlarına ilave olarak, kanıta dayalı yanıt (evidential response), bağlamsal bilgi (contextual information), hata toleransı (fault tolerance), VLSI paralel veri işleme (VLSI Implementability), tekil analiz ve dizyan, nöro-biyolojik analogi özellikleri de bulunmaktadır.




Şekil 3.3 Yapay sinir ağları ile insan göz modellenmesi

3.2.2 Sinir Modeli

Nöron, sinir ağlarının temel işlemi olan bilgi işleme fonksiyonunun birimidir. Nöron modelinin 3 temel ögesi bulunmaktadır;

1. Sinaps bağlantıları, herbiri karakterize edilmiş ve ağırlığı olan diğer sinapslar ile birbirine bağlıdır. x_n sinyali, k nöronuna bağlandığında w_{kn} ile çarpılacaktır. k olarak ifade edilen, k 'nıncı nöronu, n ile ifade edilen ise n 'nınci sinyali ifade etmektedir. Beyindeki bir sinapsın ağırlığı nöron modeline bağlı olarak pozitif ve negatif olabilir.
2. Sinaps ağırlığı ile çarpılan sinyallerinin toplanması bir doğrusal birleştirici kullanılır.
3. Nöronun genliğinin 0-1 veya (-1)-(+1) arasında normalleştirilmesi için bir aktivasyon sınırlama işlemi uygulanmaktadır.




Şekil 3.4 Yapay sinir ağı, nöron sinaps bağlantıları ve aktivasyon işlemi

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (3.1)$$

$$y_k = \phi(u_k + b_k) \quad (3.2)$$

u_k lineer kombinasyonun outputu iken, y_k ise aktivasyon işlemine girmiş outputumuzdur. Aktivasyon işlem adımları kendi içersinde treshold, sigmoid, signum ve hiperbolik tanjant fonksiyonu olmak üzere dört bölüme ayrılmaktadır.


Treshold fonksiyonu;



Şekil 3.5 Treshold fonksiyonu $(-2,2)$ aralığında gösterimi

$$\phi(u) = \begin{cases} 1 & \text{if } u \geq 0 \\ 0 & \text{if } u < 0 \end{cases} \quad (3.3)$$


Sigmoid fonksiyonu;



Şekil 3.6 Sigmoid fonksiyonu a 'ya bağlı $(-10,10)$ aralığında gösterimi

$$\phi(u) = \frac{1}{1 + e^{-au}} \quad (3.4)$$


Signum fonksiyonu;



Şekil 3.7 Signum fonksiyonu $(-\infty, \infty)$ aralığında gösterimi

$$\phi(u) = \begin{cases} 1 & \text{if } u > 0 \\ 0 & \text{if } u = 0 \\ -1 & \text{if } u < 0 \end{cases} \quad (3.5)$$

Hiperbolik tanjant fonksiyonu;




Şekil 3.8 Hiperbolik tanjant fonksiyonu $(-\infty, \infty)$ aralığında gösterimi

$$\phi(u) = \tanh(u) \quad (3.6)$$

3.2.3 Ağ Mimarileri


Ağ Mimarisi, öğrenme algoritmaları ile yakından ilişkilidir. Probleme ve sonuca yönelik doğru bir yapay zekâ ağ mimarisi ile daha kararlı ve doğru sonuçlar elde etmek mümkündür. Genel olarak ağ mimarileri üç sınıf altında tanımlanabilir.

Tek katmanlı ileri beslemeli ağ, katmanlı sinir ağlarında, nöronlar katmanlar şeklinde organize edilmektedir. Sensörler aracılığıyla gelen inputarın oluşturduğu katman, output katmanına nöron bağlantıları ile direk bağlanır. Ancak output katmanı aynı şekilde input katmanına tekrar bağlanmaz. Nöronlar bu mimaride tek yönlü bağlandığı ve input katmanı hesaplamaya katılmadığı için tek katmanlı ileri beslemeli olarak adlandırılmaktadır.




Şekil 3.9 Tek katmanlı ileri beslemeli ağ model gösterimi

Çok katmanlı ileri beslemeli ağlar, tek katmanlardan farklı olarak input ve output katmanları birbirlerine bağlanırken bir veya daha fazla gizli katman ile nöronlar birbirlerine bağlanırlar. Gizli terimi, nöron ağının bu kısmında doğrudan input ve output tarafından görülemediğini ifade etmektedir. Bu şekilde bir veya daha fazla gizli katman eklenerek oluşturulmuş nöron ağları daha yüksek düzeyli istatistikleri hesaplamak için kullanılırlar. İleri beslemeli olduğu için output katmanında geriye dönük input katmanını ile bir bağlantı yoktur.



Şekil 3.10 Çok katmanlı ileri beslemeli ağ model gösterimi

Tekrarlayan ağlar, en az bir geri bildirim döngüsüne sahip olması nedeniyle ileri beslemeli ağ mimarilerinden ayrılmaktadır. Tekrarlayan bir nöron ağı, output katmanını sinyalini input katmanına geri beslemektedir. Bu ağ mimarisi hem tek katmanlı hem de çok katmanlı olarak tasarlanabilir. Feedback döngüleri, ağın öğrenme kapasitesi üzerinde önemli bir etkiye sahiptir. Diğer ağ mimarilerine göre tasarlanması daha zor ağlardır.




Şekil 3.11 Tekrarlayan (feedback) ağ model gösterimi


3.2.4 Öğrenme İşlemleri

Nöron ağları, eğitim veya öğrenim methodları ile denklemlerin modellerini öğrenir. Örneğin, harfleri sınıflandırma için, sinaptik ağırlıklar ve biaslar ile ilk aşamada atanan temel değerlere göre değerlerin güncellenmesi sağlanır, bu sayede eğitim veya öğrenim tamamlandıktan sonra net ve istenen yanıtları sistem verebilmektedir. Nöron ağ mimarisi tasarlandıktan sonra, sinaptik ağırlıkların ve biasların uygun şekilde güncellenmesi için öğrenme sisteminin doğru bir şekilde ayarlanması gerekmektedir. Temel olarak öğrenme kategorileri ikiye ayrılmaktadır.

Tablo 3.1 Makine öğrenmesi train işlem adımları



Öğretici ile öğrenmede, öğretici çevresel input ve output örneklerine ait bilgilere sahiptir. Çalışma başında değişkenler, sinir ağı tarafından bilinmektedir. Öğreticinin görevi sinir ağına girdi olarak sağlanacak input ve output sinyallerini sağlar. Sinaps ağırlıkları, bias değerleri ve hata sinyali kullanılarak ağ mimarisi oluşturulur. Hata sinyali, bulunan output değerleri ile gerçek output değerleri arasındaki fark olup hatanın karesi veya hataların ortalamaları alınmış şekilde ifade edilebilir. Her işlem adımı yenilemeli olarak devam eder. Öğreticinin verisi eğitim algoritması yoluyla sinir ağına aktarılır. Eğitim tamamlandıktan sonra sinaps ağırlıkları uzun süreli hafıza biriminde depolanır. Örneğin, sağlıklı ve hasta bireylerden alınan kan değerlerine göre hastalıkları öğrenen sistem üzerinden hastalığı bilinmeyen bir bireye ait kan değerleri ile hastalık tespiti yapılabilir.



Şekil 3.12 Supervised learning ile MR görüntülerinden hastalık tespiti

Öğretici olmadan öğrenme işlemlerinin ilki, denetimsiz yani kendi kendine organize eden öğrenmedir (unsupervised learning). Bu öğrenme yönteminde işlemi denetleyen harici bir öğretici yoktur. Input verilerinin istatistiksel düzeni, oluşturulan sinir ağı tarafından kabullenilir. Oluşturulan sinir ağı, inputların özelliklerini tespit edip otomatik olarak sınıflar ve etiketler oluşturulmaktadır. Bu durumda en yüksek toplam inputa sahip olan nöron açılır ve sonuçlar buna göre değerlendirilir. Örneğin bu öğrenme şeklinde örnek bir resim verildiğinde bunun hangi sınıf içerisinde olduğunu bularak benzer resimleri getirebilmektedir.

Diğer öğrenme işlemi takviyeli öğrenmedir (reinforcement learning). Bu öğrenmede öğretici kendi deneyimlerinden öğrenmektedir. Performans endeksini en aza indirebilmek için sürekli olarak veri akışı olmalıdır. Sisteme hangi eylemleri gerçekleştireceği söylenmesinden ziyade, hangi eylemlerin en çok kazanım yapıldığının keşfedilmesi gerekir. Bu durumda ortamın özellikleri oluşan sonuçları büyük oranda etkilemektedir. Örneğin santanç oyunu, sistem kazanma eylemini çevre durumlarını gözlemleyerek en doğru hamleyi yapma üzerine bir öğrenme sistemi uygulanmaktadır.




Şekil 3.13 Reinforcement learning ile satranç oyunu hamle tahmini

3.3 Algılayıcılar, Çok Katmanlı Algılayıcılar, Geri Yayılım

3.3.1 Rosenblatt Algılayıcısı


Sinir ağı fikrinin ortaya atılması 1943-1958 yıllarında birkaç öncü araştırmacı katkılarıyla sağlanmıştır. McCulloch ve Pitts (1943), sinir ağı fikirlerini bilgi işlem makinelerini fikrini tanıtmak için kullanmıştır. Hebb (1949), ilk kendi kendine öğrenmenin kurallarını ortaya koymuştur. Rosenblatt (1958) ise bir öğretici ile öğrenmenin yani supervised learning'in ilk modelini önermiştir.

Perceptron (algılayıcı), doğrusal olarak verilerin ayrılabilceği ve sınıflandırılabilceğini söyleyen en basit sinir ağı şeklidir. Temel olarak ayarlanabilir sinaptik ağırlıklara ve bias değerlerine sahip tek bir nörondan oluşur. Rosenblatt, perceptronu eğitmek için kullanılan vektörler doğrusal olarak ayrılarak iki karakterize sınıfın bir düzlemde birleştiğini ve konumlandırıldığını kanıtlamıştır.



Şekil 3.14 Rosenblatt perceptron ile vektörel ayrılmış sınıflar elde etme

Resenblatt algılayıcısı, doğrusal olmayan bir nöron etrafında inşa edilmiştir. Nöral modelinde toplama nodu, uygulanan input sinallarının doğrusal kombinasyonları ve harici bir bias kaynağı ile hesaplar. Son olarak ortaya çıkan toplam, sınırlayıcı bir aktivasyon fonksiyonundan geçirilerek oluşan sonuç pozitif ise 1'e, negatif ise -1'e eşit bir output üretir.



Şekil 3.15 Doğrusal perceptron input-output modeli

$$y(x_0 = Bias = 1, x_1, x_2, x_3, \dots, x_m) = \begin{cases} 1 & \text{if } w^T x > 0 \\ -1 & \text{otherwise} \end{cases} \quad (3.7)$$

$$y(x) = \text{sgn}(w^T x) \quad (3.8)$$

y , perceptron tarafından hesaplanan output değeri.

Temel perceptron'ların sinaptik ağırlık vektörünün tespiti için; d öğrenme setinin bir üyesi kabul edildiğinde, x değeri belirli iterasyonlara göre ağırlık vektörleri

yardımıyla doğru olarak sınılandırılır ve belirlenen kurala göre perceptronun ağırlık vektöründe herhangi bir düzeltme yapılmaz.

$$w \leftarrow w \text{ or } (w_{new} \leftarrow w_{old}) \quad \text{if } w^T x_d > 0 \quad (3.9)$$

$$w \leftarrow w \text{ or } (w_{new} \leftarrow w_{old}) \quad \text{if } w^T x_d \leq 0 \quad (3.10)$$

Diğer durumda ise, perceptronun ağırlık vektörü belirlenen kurala göre uygun olacak şekilde update edilir.

$$w \leftarrow w + \eta x_d \quad \text{if } w^T x_d \leq 0 \quad (3.11)$$

$$w \leftarrow w - \eta x_d \quad \text{if } w^T x_d > 0 \quad (3.12)$$

η , öğrenme parametresidir. Eğer iterasyondaki sabir değer olan $\eta > 0$ ise, perceptron için sabit bir adaptasyon kuralımız olmalıdır. Bu değer pozitif olduğu sürece çok önemli değildir.

3.3.2 Algılayıcı Öğrenmesi

Sinir ağıımız, ister basit perceptron olsun isterse karmaşık çok katmanlı bir ağ olsun, uygun sinaptik ağırlıkları belirlemek için sistematik bir prosedür geliştirilmesi gerekmektedir. Öncelikle, perceptronların verilen eğitim örneklerinin her biri için doğru output değeri üretmesini sağlayacak bir ağırlık vektörü belirlenmelidir. Ağırlık vektörünün bulunabilmesi için ilk aşamada belirlenen rasgele sinaptik ağırlıklar ile başlanması gerekir, ardından perceptron her eğitim örneğine göre ağırlık değerleri değişmektedir. Bu süreç, perceptronun tüm eğitim örneklerini doğru bir şekilde sınıflandıran kadar örnekler üzerinden gerektiği kadar iterasyon yapılarak tekrarlanır. Perceptron ağırlıkları her adımda bir önceki değerlere göre pozitif veya negatif olarak değişir. Bu iterasyon işlemi standart ortalama veya stokastik ortalama yöntemleri ile yapılır. Standart ortalama işlemi ile başta rasgele w_i seçilir. Δw_i sıfır olarak atanır. Belirlenen iterasyon sayısı boyunca Δw_i hesaplanır ve son olarak w_i ile Δw_i toplanarak ağırlıklar bulunur.


$$\Delta w_i \leftarrow \Delta w_i + \eta(t_d - o_d)x_{id} \quad (3.13)$$

$$w_i = w_i + \Delta w_i \quad (3.14)$$

Stokastik ortalama yönteminde ise standart ortalamadan farklı olarak Δw_i hesaplanmaksızın her iterasyonda tüm ağırlıklar w_i tekrar bulunur. İterasyon tamamlandığında elde edilen w_i 'ler istenilen ağırlıklar olacaktır.

$$w_i \leftarrow w_i + \eta(t_d - o_d)x_{id} \quad (3.15)$$


t_d , gerçek output değerleri, o_d ise hesaplanan output değerleridir.



Şekil 3.16 Perceptron sinaptik vektör ile verilerin sınıflandırılması


3.3.3 Çok Katmanlı Algılayıcı Öğrenmesi (Multilayer Perceptron)

Tek katmanlı algılayıcılar sadece doğrusal karar vektörlerini ifade edebilir. Ancak karşılaşılan bazı problemlerde öğrenme sırasında gerçek output değerlerini doğrusal olarak tanımlamaya yetmemektedir. Bu problemlerin çözümünde ise çok katmanlı algılayıcılar (Multilayer Perceptron) kullanılarak doğrusal olmayan karar vektörlerinin oluşturulması sağlanır.




Şekil 3.17 MLP doğrusal olmayan vektörler ile verilerin sınıflandırılması

Çok katmanlı perceptronlar bir veya daha fazla gizli katman ve output katmanı kullanılarak oluşturulur. Ağ içerisinde tüm nöronlar bir önceki katmandaki tüm nöron nodlarına bağlı ve ağdaki sinyal akışı soldan sağa ve katman katman olarak ileri yönde ilerlemektedir.



Şekil 3.18 MLP doğrusal olmayan vektörler ile input-output modeli

Bu mimaride outputları hesaplamak için gradient descent learning kuralı geliştirilmiştir. Çözüm için yapılan işlem sigmoid fonksiyonudur.



Şekil 3.19 MLP modelinin sigmoid fonksiyonu ile aktivasyon modeli

Sigmoid fonksiyonu;

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.16)$$

$$\sigma'(x) = \sigma'(x) - \sigma^2(x) \quad (3.17)$$

Backpropagation kuralı, her ağırlık w_{ji} hesaplanırken Δw_{ji} eklenerek update edilir.

$$\Delta w_{ji} = \eta \frac{dJ_d}{dw_{ji}} \quad (3.18)$$

$$J(w) = \frac{1}{2} \sum_{d \in D} \sum_{k \in \text{outputs}} (t_{kd} - o_{kd})^2 \quad (3.19)$$

outputs, ağdaki output birimlerinin set değerleri, t_{kd} d örneğinin öğrenmesi için k biriminin ulaşması gereken değer, o_{kd} d örneğinin öğrenmesi için verilen k biriminin output değeridir.

$$net_j = \sum_i w_{ji} x_{ji} \quad (3.20)$$

$$\frac{dJ_d}{dnet_j} = -(t_j - o_j) o_j (1 - o_j) \quad (3.21)$$

$$\Delta w_{ji} = -\eta \frac{dJ_d}{dnet_j} x_{ji} = \eta (t_j - o_j) o_j (1 - o_j) x_{ji} \quad (3.22)$$

Bulunan Δw_{ji} ile delta kuralına göre, lineer aktivasyon fonksiyonu;

$$w_i \leftarrow w_i + \eta (t_d - o_d) x_{id} \quad (3.23)$$

veya sigmoid fonksiyonu kullanılır.

$$w_i \leftarrow w_i + \eta (t_d - o_d) o_d (1 - o_d) x_{id} \quad (3.24)$$

İterasyon sayısı boyunca işlem tekrarlanarak ağırlıklar w_i tespit edilir ve öğrenme işlemi tamamlanır. Eldeki test verileri bu ağırlıklar w_i kullanılarak ulaşılmak istenen output t_d değerleri tespit edilebilir.

TEORİNİN ROBOT MİMARİSİNE UYGULANMASI

4.1 Veri Toplama, Optimizasyon ve Analiz

Bu çalışmada, üretim hattında meydana gelecek olan duruşların tahmin edilebilmesi için, hat üzerindeki son üç yıl içerisinde meydana gelen duruş kayıtları incelenmiştir. Plansız üretim duruşları temel olarak çevresel ve donanımsal problem kaynaklı oluşmaktadır. Uzun incelemeler sonrasında, endüstriyel paketleme robotlarında yaşanan duruşların, makineye bağlı çalışma sürelerine, mevsimsel faktörlere, duruş sürelerine ve dönüşüm adetlerine vb. bağlı benzerlikler olduğu tespit edilmiştir. Tespit edilen çevresel ve donanımsal duruş benzerlikleri uzman teknik bilgisi göz önünde bulundurularak, fabrika ERP sisteminden makine çalışma süreleri, oluşan duruş süresi ve makine ürün dönüşüm verileri, bir yapay zekâ algoritmasının çalışabileceği bir train yapısı oluşturulmuştur.

Eğitim yapısında teknik bilgi ve hata verileri değerlendirilerek bu veriler yapay sinir ağı üzerinden aktarılır. Sinir ağında kullanılacak veriler için bir gruplama stratejisi kullanıldı. Train örnekleri kullanılarak geliştirilen sinaptik ağırlık iterasyon işlemleri sayesinde oluşturulan yapay zekâ algoritması, arızalar olmadan önce tahmin ederek makine üzerinde kestirimci bakım yapabilmemize imkân sağlamaktadır.

Bu çalışmada ilave olarak makine üzerindeki donanım bileşenleri üzerinde güvenilirlik analizi yapılmıştır. Mevcut sistem duruş süreleri dikkate alınarak her donanım bileşeni için MTTF değerleri hesaplanmıştır. Yapılan teorik ve pratik testler, mevcut makine duruş bildirimleri ile hazırlanan yapay zekâ algoritmaları ve güvenilirlik analizi ile gerçekleştirilmiştir.

İncelemelerimiz sonrasında, fabrika geneli arızaların analizi yapılarak en yüksek iki üretim hattı tespit edilmiştir. Bu hatlarda ortak olarak kullanılan buffer, ambalaj makineleri ve kutulama robotları gibi bölgesel istasyonlar bulunmaktadır. Yapılan arıza analizlerinde makine arıza bölgelerinin tanımlanma kolaylığı, üç yıllık gelen arıza bildirimlerinin yeterlilikleri dolayısıyla kutulama robotlarına odaklanılmıştır.

Big Data'mız, 2017-2019 yılları arasında seçtiğimiz üretim tesisine ait kutulama robotlarında gelen 157 adet arıza bildiriminden oluşmaktadır. Bu arıza bildirimlerine ilave olarak, makine de arıza bölgeleri tanımlandı ve her bölgede oluşan iki arıza arasındaki makine çalışma saati, makine ürün dönüşüm adeti ve arıza durumundaki tesisteki üretilen ürün verileri fabrika ERP sisteminden alınmıştır. Bu alınan ilave veriler, yapay zekâ algoritmasının başarı oranının yükselmesi sağlanmıştır. Hazırlanan Big Data, makine öğrenmesi algoritmasında kullanılabilmesi için bazı düzenlemeler yapılmıştır. Aşağıdaki tabloda, yapay sinir ağına sunulan analog verilerin log-sigmoid transfer fonksiyonu kullanılarak $[0,1]$ aralığında normalleştirilmiştir.

Tablo 4.1 Train verisinin sigmoid fonksiyonu ile optimizasyonu

SEASON (t-1)/3	WORKSHOP (Code)/2	MACHINE (Code)	FAILURE AREA (Code)/2	OPERATION TIME (min/518400*3)	DOWNTIME (min/540)	PRODUCTION AT FAILURE (Code)/4	CONVERSION (pieces)/40
0.0000	0.00	1	0.50	0.0075	0.0370	0.25	0.0500
0.0000	0.50	1	1.00	0.0064	0.0556	0.25	0.0250
0.3333	0.50	1	0.50	0.0000	0.0741	0.25	0.0000
0.3333	0.00	0	0.50	0.0066	0.0556	0.75	0.0000
0.3333	1.00	1	1.00	0.2315	0.1111	0.75	0.9250
0.6667	1.00	1	1.00	0.0382	0.0741	0.25	0.1000
0.6667	1.00	1	1.00	0.0785	0.1667	0.75	0.3000
1.0000	1.00	0	1.00	0.0000	0.0556	0.25	0.0000
1.0000	0.50	1	1.00	0.0068	0.2222	0.25	0.0000
0.0000	0.00	0	0.00	0.1009	0.1111	0.75	0.3000
0.0000	0.50	1	0.00	0.0000	0.0370	0.75	0.0000

Tablo 4.2 Makine öğrenmesi algoritmasında kullanılan train arıza bildirim verisi

No	Date	Workshop	Arrival Time	Line	Machine	Notification	Technical Action	Technician	Failure Area	Operation Time (min)	Downtime (min)	Production At Failure	Conversion (pieces)
1	02/01/2017	EB	07:20	WINKLER-1	2.ROBOT	2.ROBOT KOLA HAZNE ARIZAYA GEÇMESİ	HIZLI ISITLAMA RESETLENDİ	S.ACUN	Kola Sistemi(5)	1,294	20	Dido(1)	2
2	03/01/2017	AB	09:00	WINKLER-1	2.ROBOT	2.ROBOT TARAK ÜST SAÇ PİSTON YAVAŞ ÇALIŞMASI	PİSTON HAVA AYARI YAPILDI	Y.KONAK	Tarak Sistemi(8)	1,110	30	Dido(1)	1
3	09/01/2017	EB	16:00	WINKLER-1	1.ROBOT	1.ROBOT KOLA ATIŞI YAPMAMASI	KONTROL EDİLDİ	Ü.SARI	Kola Sistemi(5)	7,342	15	Dido(1)	8
4	10/01/2017	AB	15:00	WINKLER-1	1.ROBOT	1.ROBOT 2.KOLA ATIŞ YAPMAMASI	VENTİL DEĞİŞTİRİLDİ	U.ALTUNTAŞ	Kola Sistemi(5)	882	20	Dido(1)	2
5	11/01/2017	EB	10:20	WINKLER-1	1.ROBOT	1.ROBOT KOLA HAZNESİ ARIZAYA GEÇMESİ	ISITICILAR KONTROL EDİLDİ	M.ÇİÇEK	Kola Sistemi(5)	1,167	20	Laviva(3)	0
6	12/01/2017	AB	13:00	WINKLER-1	2.ROBOT	2.ROBOT MAMÜL TARAKLARA TAKILMASI	VANTUZ DEĞİŞTİRİLDİ	Z.AKTEL	Tarak Sistemi(8)	9,503	20	Laviva(3)	10
7	13/01/2017	AB	14:20	WINKLER-1	1.ROBOT	ROBOT 1 KOLA ARIZAYA GEÇMESİ	KOLA ISITMA DERECEİ YÜKSELTİLDİ	Z.AKTEL	Kola Sistemi(5)	2,135	15	Laviva(3)	0
8	19/01/2017	AB	08:30	WINKLER-1	1.ROBOT	1.ROBOT KOLA ATIŞ YERİNİN AYARLANMASI	VALF DEĞİŞTİRİLDİ AYAR YAPILDI	U.ALTUNTAŞ	Kola Sistemi(5)	6,913	90	Dido(1)	2
9	24/01/2017	EB	07:30	WINKLER-1	2.ROBOT	2.ROBOT VAKUM SOKET KABLO DEFORME OLMASI	SOKET DEĞİŞTİRİLDİ	T.ACAR	Vakum Sistemi(12)	5,891	45	Dido(1)	3
10	30/01/2017	AB	10:00	WINKLER-1	1.ROBOT	1.ROBOT VANTUZ KOPMASI	VANTUZ DEĞİŞTİRİLDİ	İ.AKYÜZ	Transfer Sistemi(10)	912	30	Laviva(3)	0
11	06/02/2017	AB	08:15	WINKLER-1	1.ROBOT	1.ROBOT TARAK ÜST KILAVUZ YAVAŞ ÇALIŞMASI	PİSTON KISICI VE GERİ DÖNÜŞ VALF DEĞİŞTİRİLDİ	A.BERBER	Tarak Sistemi(8)	27,761	45	Dido(1)	19
12	06/02/2017	AB	16:50	WINKLER-1	2.ROBOT	2.ROBOT TARAK ÜST SAÇ ÇALIŞMAMASI	PİSTON DEĞİŞTİRİLDİ	Y.KONAK	Tarak Sistemi(8)	0	30	Dido(1)	0
13	09/02/2017	AB	07:45	WINKLER-1	1.ROBOT	1.ROBOT TARAKTAN MAMÜL ALIRKEN SES GELMESİ	ROBOT SERVO MOTOR KABLIN DEĞİŞTİRİLDİ	A.BERBER	Transfer Sistemi(10)	11,410	120	Dido(1)	4
14	14/02/2017	AB	10:45	WINKLER-1	2.ROBOT	2.ROBOT GİRİŞ TARAK YAN APARAT VİDA KIRILMASI	KIRILAN PARÇANIN YENİSİ YAPIDI	Ş.GENÇ	Tarak Sistemi(8)	9,398	45	Dido(1)	5
15	15/02/2017	AB	14:20	WINKLER-1	2.ROBOT	2.ROBOT TARAK İÇERİNDE TERS DÖNMESİ	ÜST SAC MESAFE AYARI YAPILDI	Ş.GENÇ	Tarak Sistemi(8)	835	60	Dido(1)	2
16	16/02/2017	AB	16:40	WINKLER-1	1.ROBOT	1.ROBOT GİRİŞ SİLİKONLU BANDIN AŞIRI ISINMASI	2.ADET BAND VE RULMANLARI DEĞİŞTİRİLDİ	A.GÜMÜŞ	Giriş Bant Sistemi(4)	1,178	30	Laviva(3)	1
17	22/02/2017	AB	08:00	WINKLER-1	2.ROBOT	2.ROBOT GİRİŞ BAND MOTOR VİDASININ DÜŞMESİ	REDÜKTÖR VE TAMBUR DEĞİŞTİRİLDİ	S.ARSLAN	Giriş Bant Sistemi(4)	6,183	60	Smat Mini(4)	5
18	01/03/2017	AB	15:30	WINKLER-1	2.ROBOT	2.ROBOT TARAK ÜST SAÇ AĞIR HAREKET ETMESİ	PİSTON HAVA GİRİŞ REKOR DEĞİŞTİRİLDİ	Y.KONAK	Tarak Sistemi(8)	6,942	30	Dido(1)	10
19	02/03/2017	AB	08:45	WINKLER-1	2.ROBOT	2.ROBOT KUTU ALMA MAGAZİN TIRNAK KIRILMASI	TIRNAK DEĞİŞTİRİLDİ	Y.KONAK	Magazin Sistemi(6)	22,273	40	Dido(1)	25
20	06/03/2017	AB	16:20	WINKLER-1	1.ROBOT	1.ROBOT TARKLARINDA MAMÜLLER TERS DÖNMESİ	TARAK ÜST SAÇ AYARI YAPILDI	Z.AKTEL	Tarak Sistemi(8)	5,877	45	Dido(1)	4
21	06/03/2017	EB	17:30	WINKLER-1	2.ROBOT	2.ROBOT JET-3 MÜREKKEP AKITMASI	PARAMETRE AYARLARI YAPILDI	M.ÇİÇEK	Tarih Kodlama Sistemi(9)	44,456	30	Dido(1)	40
22	07/03/2017	AB	07:40	WINKLER-1	1.ROBOT	1.ROBOT TARAKLARDAN MAMÜL TERS DÖNMESİ	TARAK ÜST SAÇI DEĞİŞTİRİLDİ	Ş.GENÇ	Tarak Sistemi(8)	717	45	Laviva(3)	2


4.1.1 Yapay Zekâ Ağı Yaklaşımı ve MLP Yapısı Kurulması

Bu çalışmamızda yapay zekâ öğrenme algoritması olarak sistem karmaşıklığı ve input outputlar arası ilişkinin analiz edilebilmesi için Çok Katmanlı Algılayıcı Öğrenmesi (Multilevel Perceptron-MLP) yapısı kullanılmıştır. Bu öğrenme yapısında, yapay nöronlar arasındaki her bağlantı işlenecek olan bilgiyi ve sinyali, nöronlar vasıtasıyla birbirine aktarabilmektedir. Geri yayılım (Backpropagation) algoritması ile de çok katmanlı ağ için sinaptik ağırlıkları öğrenilmektedir. Bir önceki verilen tablodaki değerler MLP yapısında input ve output olarak Tablo 4.3’de verilmiştir. Input verisi, mevcut arıza durumundaki veriyi tutmaktadır. Output verisi ise bir sonraki arızaya ait tahmini ifade etmektedir.

Tablo 4.3 MLP mimarisinde kullanılan input ve outputlar

INPUTs	OUTPUTs
SEASON	WORKSHOP
WORKSHOP	MACHINE
MACHINE	FAILURE AREA
FAILURE AREA	OPERATION TIME
OPERATION TIME	
DOWNTIME	
PRODUCTION AT FAILURE	
CONVERSION	

Şekil 4.1, oluşturulan MLP yapısındaki parametre ve sinaptik ağırlıkların ilişkisini göstermektedir. Bu yapıda 8 adet input nodu, 20 adet hidden nodu ve 4 adet output nodu kullanılmıştır.



Şekil 4.1 MLP algoritmasında input, hidden ve output layer mimarisi

MLP yapısı ve backpropagation öğrenme algoritmaları tasarlandıktan sonra 157 makine arıza bildiriminden 146'sı algoritma eğitim işleminde ve 11'i daha sonra test işleminde kullanılmak üzere organize edilmiştir.

Oluşturulan makine öğrenme algoritması, output değerleri ile hedef değerler arasındaki hatayı en aza indirme modelini kullanarak öğrenme iterasyon işlemlerini gerçekleştirmektedir. Eğitim aşamasında 100 ve 10.000 arasında 6 farklı iterasyon modelinde kullanılmış ve öğrenme hatasının minimuma indirilmesi sağlanmıştır. Minimum hata ile en yakın tahmin 500 iterasyonda sağlanmıştır.

4.1.2 Robot Komponentleri Üzerinden Robot MTTF Değer Hesabı

Bu kapsamda kutulama robotu üzerinde kullanılan tüm elektriksel ekipmanların belirlenmesi sağlanarak çalışma başlatılmıştır. Tablo 4.4'de robot üzerindeki 13 arıza bölgesi görülmektedir. Bu 13 robot arıza bölgesi benzer özellikleri gösteren 3 ana grupta toplanmıştır.

Tablo 4.4 Robot 13 adet arıza bölgesi ve arıza grupları

<i>FAILURE AREA</i>		
<i>0-GROUP SYSTEM</i>	<i>1-GROUP SYSTEM</i>	<i>2-GROUP SYSTEM</i>
CLOSER SYSTEM	SAFETY SYSTEM	ENTER BAND SYSTEM
ERECTOR SYSTEM	HOT MELT SYSTEM	CELL SYSTEM
FILLER SYSTEM	DATE CODING SYSTEM	TRANSPORTER SYSTEM
MAGAZINE SYSTEM	VACUUM SYSTEM	
MODULE SYSTEM		
TRANSFER SYSTEM		

Robot üzerinde tespit edilen tüm elektriksel ekipmanlar ve alt sistemler için arıza oluşma sıklığı (MTTF) belirleme çalışması yapılmıştır. Tespit edilen ekipman MTTF değerleri, NPRD-95 mekanik standartları ve 25 °C'de ground-bening temel koşullar alınarak ADL MTBF Calculator kullanılmıştır [26].

1. Select Component Family and Type Family: ELECTRONIC MECHANICAL Item Code: IC-Memory IC-Analog IC-Digital Bubble Memory Resistor Potentiometer Capacitor Switch Relay Connector LF Diode LF Transistor HF Diode HF Transistor	2. Select Reliability Prediction Method MIL-217E-1 Part stress MIL-217F-1 Part count MIL-217F-1 Part stress MIL-217F-2 Part count MIL-217F-2 Part stress ANSI/MIL-STD-883C ALCATEL BELLCORE Issue 5 BELLCORE Issue 6 BRITISH TELECOM HRD4 BRITISH TELECOM HRD5	4. Enter Component Parameters Calculate
3. Select Environment and Temperature Environment: GB Ground, Benign Temperature: 25 degrees Centigrade		5. Get MTBF and FR MTBF: 0.0 hours Failure Rate: 0.0 failures per million hours Failure Rate: 0.0 FIT

Şekil 4.2 ADL MTBF calculator programı

Ref. des.: QTY: 1 ENV: GB Temp: 25 °C		OK									
Part name:		Cancel									
Mil. num.:		Help									
Cat. num.:											
Generic name:											
Automatic search in library: Part Description: Summary ENV: GB Quality: --- Failure Rate: --- Manual library record selection: Part Description: Sustainer Servo <table border="1"> <tr> <td>---</td> <td>---</td> <td>12.50</td> </tr> <tr> <td>---</td> <td>Unk</td> <td>12.50</td> </tr> <tr> <td>GB</td> <td>Unk</td> <td>12.50</td> </tr> </table>			---	---	12.50	---	Unk	12.50	GB	Unk	12.50
---	---	12.50									
---	Unk	12.50									
GB	Unk	12.50									
Search data for calculation by: Automatic search, then manual selection if not found											

Şekil 4.3 Robot servo motor MTBF değerinin hesaplanması

1. Select Component Family and Type Family: ELECTRONIC Item Code: MECHANICAL Accelerometer Accumulator Actuator Air Conditioner Alarm Antenna Axle Battery Bearing Bellows Belt Blower Bracket Brake	2. Select Reliability Prediction Method NPRD-95 NSWC-98/LE1 Mechanic	4. Enter Component Parameters  Calculate
3. Select Environment and Temperature Environment: GB Ground, Benign Temperature: 25 degrees Centigrade		5. Get MTBF and FR MTBF: 80000.00 hours Failure Rate: 12.5000 failures per million hours Failure Rate: 12500.0000 FIT

Şekil 4.4 Servo motor NPRD-95 mekanik standardına göre MTBF değeri

ADL MTBF Calculator, 20'den fazla güvenilirlik tahmin standardını destekleyen, güvenilirlik tahmini için bir yazılım aracıdır. Güvenilirlik tahmin yazılım aracının konsepti ise elektronik veya mekanik bileşen verilerini girildiğinde tahmini MTBF ve arıza oranını vermektedir.


MTBF hesaplayıcı, güvenilirlik tahminini gerçekleştirmek için bileşen parametrelerinin girilmesi gerekmektedir. Genel olarak bu parametreler üreticinin veri sayfalarından temin edilmelidir. Bununla beraber, ADL 40.000'den fazla öge içeren aktif elektronik bileşenler güvenilirliği içeren veri kitaplığı içermektedir.

Bu çalışmamızda robot bileşenleri belirlendikten son ADL MTBF Calculator üzerinden, üretici firma parametreleri ile verilere toplanarak Tablo 4.5'te gösterildiği gibi sistemin güvenilirlik analizi yapılmıştır.

Tablo 4.5 Robota ait tüm ekipmanların MTBF değerleri

WINKLER-1 ROBOT EQUIPMENT LIST (NPRD-95 Mechanical)								
Ekipman	Ko	Marka	Model	Adet	MTTF(y)	MTBF(h)	ADL MTBF	
Fren Boşaltma Butonu	B	Siemens	M22-K01	2	33.79	296,033.15	Contact/Electrical	
Stop Butonu	B	Siemens	M22-K01, M22-K10	8	33.79	296,033.15	Contact/Electrical	
Acil Stop	B	Siemens	M22-K10	2	33.79	296,033.15	Contact/Electrical	
Kola haznesi	G	Robatech	Concept A 8/8 KPC12	1	29.22	255,924.66	Gauge/Fuel,Storage Tank, Indicator	
Kutu Yapma Depozitörü	G	Robatech	HOLMELT TABANCASI 125W SX 2EL Kod :131247	4	11.30	99,006.96	Heater/Summary	
Kutu Kapama Depozitörü	G	Robatech	HOLMELT TABANCASI SX 2EL/296 Kod :131248	4	11.30	99,006.96	Heater/Summary	
Kola Hortumu 3 Metre Kutu Yapma	G	Robatech	Tip : 136457 230V 1,18A 272W	4	9.50	83,200.21	Cable/Multiconductor	
Kola Hortumu 5 Metre Kutu Kapama	G	Robatech	Tip : 136461 230V 2,18A 500W	4	9.50	83,200.21	Cable/Multiconductor	
Eksen Servo Sürücü Fren Modülü	K	Bosch	HAS05.1-006-NNN-NN R911318195	10	54.36	476,190.50	Brake/Assembly	
Output Modül AS-i Bus	K	Siemens	3RKT1400-0BE00-0AA2	6	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
Emniyet Rölesi	K	Siemens	3TK2821-1CB30	8	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
Input Modül AS-i Bus	K	IFN	AC 2254	8	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
Input Output modül	K	LUTZE	CAN 8E/8A 24V DC DIORAIL;DR-CO-CMDIO-8/8-2	3	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
Servo Modüllerin Filtresi	K	Bosch	HNS02.1A-Q200-R0023	4	15.53	136,054.42	Servo/Amplifier	
Kola Ventilleri Kontrol Kartı	K	Murr Elektronik	MAS120 D04/2A Part No: 556593	2	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
MODULE VMS	K	Schubert	SM MODÜL	5	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
VMS MODÜL	K	Schubert	VMS MODUL; RM	3	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
PCB Kontrol kartı	K	Schubert	VMS-WK02 IPS Sip No : 79716210	8	16.74	146,666.27	Miscellaneous/Arm,Center,Assembly	
Servo Modüllerin Güç Modülü	K	Bosch		3	15.53	136,054.42	Servo/Amplifier	
Tarih Kodlama	K	Leibinger	Jet-3	1	16.52	144,730.37	Printer/Plotter	
Robot kollarındaki Vakum motoru	M	Jardner Denve	G200 2BH1410-7HH46-Z 2,2KW 2800 Min 5,8A	2	10.27	90,000.09	Pump/Vacuum,Ring Seal Type	
Kapak Motorları	M	Bühler	IPS KOD:1.13.044..236	8	15.47	135,503.19	Actuator/Linear	
Magazin-1 Servo Motor	M	Bosch	MSK030C-0900-NN-M1-UG1-NNNN R911308684	2	9.13	80,000.00	Actuator/Susainer servo	
Tabla Servo Motor	M	Bosch	MSK050C-0300-NN-M1-UG0-NNNN	1	9.13	80,000.00	Actuator/Susainer servo	
Fooding Unit Servo Motor	M	Bosch	MSK-050C-0300-NN-M1-UG1-NNNN	2	9.13	80,000.00	Actuator/Susainer servo	
Tarak Servo Motoru	M	Bosch	MSK060C-0600-NN-M1-UG0-NNNN R911308684	2	9.13	80,000.00	Actuator/Susainer servo	
TRANSPORTER SERVO MOTOR	M	Bosch	MSK060C-C600-NN-M1-UG0-NNNN	3	9.13	80,000.00	Actuator/Susainer servo	
Eksen Motoru	M	Bosch	MSK071D-0300-NN-M1-UG1-NNNN	8	9.13	80,000.00	Actuator/Susainer servo	
Giriş Bant Motoru	M	Küenle	TYP : K71A2BTH 0,37KW 2800 Min	3	17.22	150,838.66	Motor/Induction	
Kutu Yapma Ve İletme İçin Vakum Mot	M	Becker	VT 4.25 1400 Min / 1700 Min	2	10.27	90,000.09	Pump/Vacuum,Ring Seal Type	
Operatör Panel	OP	Schubert	IPS PART NO: 19000197	1	7.12	62,350.36	Monitor/PH,Loss	
AS-i Bus Güç Kaynağı	PS	Siemens	3RX9 502-0BA00 , 5A	1	8.36	73,253.63	Power Supply/Summary	
AKIM ÇEVİRCİ	PS	PHOENIX	MCR-S-1/5-UI-SW DCI	1	13.83	121,135.76	Transducer/Summary	
Güç Kaynağı	PS	Plus	Qt20.241	6	8.36	73,253.63	Power Supply/Summary	

MTTF değerleri belirlenmiş olan ekipmanlar arıza bölgelerine göre listelenmesi ardından tüm bağımsız bölgeler için Hata Ağacı Analizi (Fault Tree Analysis-FTA) yapılmıştır. Şekil 4.5, kutulama robotunun Transport sistemine ait FTA çizimini göstermektedir.



Şekil 4.5 Robot transport sistemine ait FTA diyagramı

FTA şema çizimlerine bağlı kalınarak, makine arıza bölgelerine göre kategorize edilmiş ekipmanlar, 1001, 1002 veya 1004 olarak formülize edilmesi sağlanır. Oluşturulan yapı üzerinden, arıza bölgeleri, 1gün ile 5yıl arasında 16 farklı döneme excel tablo oluşturulmuştur. Güvenilirlik fonksiyonu $R(t)$, hata fonksiyonu $F(t)$ ve başarısızlık oran fonksiyonu $\lambda(t)$ aşağıdaki gibi hesaplanabilmektedir.

$$R(t) = e^{-\int_0^t \lambda(u) du} \quad (4.1)$$

$$F(t) = 1 - R(t) \quad (4.2)$$

$$\lambda(t) = -\frac{d}{dt} \ln R(t) \quad (4.3)$$

t , hata zamanını temsil etmektedir.

4.1.3 Arıza Bölgelerinin Gruplanması ve Güvenilirlik Analizi

Yukarıda arıza bölgeleri üzerine FTA diagramı kullanılarak yapılan bölgesel hesaplamalar sonrasında, bölgeler benzer ekipman ve işlevselliğe göre üç ana gruba ayrılmıştır. Akabinde tüm grupların güvenilirlik, hata ve başarısızlık oranları yukarıdaki fonksiyonlar kullanılarak hesaplanmıştır. Son olarak bu veriler kullanılarak kutulama robotunun 16 farklı zaman dilimi içerisinde güvenilirlik hesaplamaları yapılmıştır. Hesaplamalar sonrasında tüm bölgesel grup ve sistemlerinde başarısızlık oranı ve MTTF değerleri elde edilir. Bu değerler Tabloda 4.6 gösterilmiştir.

Tablo 4.6 Robot bölgesel hata oranları ve MTTF değerleri

	0.GROUP FAIL SAFE	1.GROUP FAIL SAFE	2.GROUP FAIL SAFE	ROBOT RELIABILITY	
F(1st.day)	0.023289	0.011182	0.003441	R(1st.day)	0.962466
F(2nd.day)	0.046036	0.022239	0.006870	R(2nd.day)	0.926341
F(4th.day)	0.089953	0.043984	0.013693	R(4th.day)	0.858107
F(1st.week)	0.162000	0.080880	0.025520	R(1st.week)	0.750567
F(2nd.week)	0.297760	0.155218	0.050388	R(2nd.week)	0.563347
F(1st.month)	0.506873	0.286344	0.098237	R(1st.month)	0.317351
F(2nd.month)	0.756853	0.490695	0.186824	R(2nd.month)	0.100700
F(3rd.month)	0.880125	0.636531	0.266708	R(3rd.month)	0.031950
F(4th.month)	0.940906	0.740608	0.338745	R(4th.month)	0.010136
F(6th.month)	0.985644	0.867891	0.462283	R(6th.month)	0.001020
F(9th.month)	0.998282	0.951982	0.605696	R(9th.month)	0.000033
F(1st.year)	0.999795	0.982547	0.710860	R(1st.year)	0.000001
F(2nd.year)	1.000000	0.999695	0.916398	R(2nd.year)	0.000000
F(3rd.year)	1.000000	0.999995	0.975827	R(3rd.year)	0.000000
F(4th.year)	1.000000	1.000000	0.993011	R(4th.year)	0.000000
F(5th.year)	1.000000	1.000000	0.997979	R(5th.year)	0.000000
				F. RATE(λ)	0.0383
				MTTF(DAY)	26.14

$$MTTF(t) = \frac{1}{\lambda(t)} \quad (4.4)$$

Bir yıl için yapılan hesaplama $t = 1 \text{ year}$;

$$\lambda(1\text{year}) = -\ln(1.03602E - 06) \quad (4.5)$$

$$\lambda(1 \text{ year}) = 13.78 \quad (4.6)$$

$$MTTF(\text{day}) = \frac{1}{\lambda(1\text{year})} * 360 \quad (4.7)$$

$$MTTF(\text{day}) = 26.12 \quad (4.8)$$

Tablo 4.7 Robot hata oranlarının bölge, grup ve genel hesabı

	1.day	2.day	1.month	3.year	5.year
Enstrüman	R(1.gün)	R(2.gün)	R(1.ay)	R(3.yıl)	R(5.yıl)
	F(1.gün)	F(2.gün)	F(1.ay)	F(3.yıl)	F(5.yıl)
0.CLOSER SYSTEM FAIL SAFE	0.00210109	0.004197799	0.061162887	0.898600836	0.978299566
1.SAFETY SYSTEM FAIL SAFE	0.004637476	0.009253445	0.13016163	0.993396287	0.999767559
2.ERECTOR SYSTEM FAIL SAFE	0.003108002	0.006206376	0.089170451	0.965918287	0.996474018
3.FILLER SYSTEM FAIL SAFE	0.00181992	0.003636558	0.053193329	0.862326458	0.96381709
4.ENTER BAND SYSTEM FAIL SAFE	0.000866081	0.001731411	0.025658749	0.607717234	0.789784187
5.HOT MELT SYSTEM FAIL SAFE	0.005223916	0.010420542	0.145405538	0.99650568	0.999919535
6.MAGAZINE SYSTEM FAIL SAFE	0.001551881	0.003101353	0.045523812	0.813128301	0.938919035
7.MODULE SYSTEM FAIL SAFE	0.012394084	0.024634554	0.312123474	0.999998586	1
8.CELL SYSTEM FAIL SAFE	0.001108918	0.002216607	0.032738123	0.698292185	0.86427987
9.DATA CODING SYSTEM FAIL SAFE	0.000277748	0.000555419	0.008298973	0.259188921	0.393479085
10.TRANSFER SYSTEM FAIL SAFE	0.002499029	0.004991842	0.072328607	0.933986424	0.989371431
11.TRANSPORTER SYSTEM FAIL SAFE	0.001469722	0.002937284	0.043164784	0.79576158	0.929168071
12.VACUUM SYSTEM FAIL SAFE	0.0010808951	0.0021606218	0.0319237171	0.6890110961	0.8572504254
0.GROUP FAILURE RATE	F(1.gün)	F(2.gün)	F(1.ay)	F(3.yıl)	F(5.yıl)
0.CLOSER SYSTEM FAIL SAFE, 2.ERECTOR SYSTEM FAIL SAFE, 3.FILLER SYSTEM FAIL SAFE, 6.MAGAZINE SYSTEM FAIL SAFE, 7.MODULE SYSTEM FAIL SAFE, 10.TRANSFER SYSTEM FAIL SAFE	0.0232890189	0.0460357795	0.5068734098	1.0000000000	1.0000000000
	R(1.gün)	R(2.gün)	R(1.ay)	R(3.yıl)	R(5.yıl)
	0.9767109811	0.9539642205	0.4931265902	0.0000000000	0.0000000000
1.GROUP FAILURE RATE	F(1.gün)	F(2.gün)	F(1.ay)	F(3.yıl)	F(5.yıl)
1.SAFETY SYSTEM FAIL SAFE, 5.HOT MELT SYSTEM FAIL SAFE, 9.DATA CODING SYSTEM FAIL SAFE, 12.VACUUM SYSTEM FAIL SAFE	0.0111821462	0.0222392521	0.2863439059	0.9999946838	0.9999999984
	R(1.gün)	R(2.gün)	R(1.ay)	R(3.yıl)	R(5.yıl)
	0.9888178538	0.9777607479	0.7136560941	0.0000053162	0.0000000016
2.GROUP FAILURE RATE	F(1.gün)	F(2.gün)	F(1.ay)	F(3.yıl)	F(5.yıl)
4.ENTER BAND SYSTEM FAIL SAFE, 8.CELL SYSTEM FAIL SAFE, 11.TRANSPORTER SYSTEM FAIL SAFE	0.0034408591	0.0068698786	0.0982372075	0.9758274075	0.9979791284
	R(1.gün)	R(2.gün)	R(1.ay)	R(3.yıl)	R(5.yıl)
	0.9965591409	0.9931301214	0.9017627925	0.0241725925	0.0020208716
ROBOT SYSTEM FAILURE RATE	F(1.gün)	F(2.gün)	F(1.ay)	F(3.yıl)	F(5.yıl)
	0.037533889	0.073659101	0.682649117	1	1
	R(1.gün)	R(2.gün)	R(1.ay)	R(3.yıl)	R(5.yıl)
	0.962466111	0.926340899	0.317350883	1.06632E-18	1.04746E-30

4.1.4 Poisson Dağılımı İle Yedek Parça Analizi

Çalışmalarımızda ele aldığımız kutulama robotlarında, komponent adeti ve MTTF değerlerine göre hataya geçme zamanı hesaplandıktan sonra sistemin minimum %85 verim ile çalışması talep edilmektedir. Bu verimliliğin sağlanması için arıza durumunda ilgili komponent ulaşılabilir olmalı ve hızlı bir şekilde değiştirilebilir olmalıdır. Bu yöntem ile makine duruş süresi minimuma indirilerek üretim verimliliğinin artırılması hedeflenmektedir.

Poisson dağılımı kullanılarak, arıza durumunda makine için elimizde bulunması gereken yedek komponent stokları belirlenmiştir.

$$\lambda t = \frac{AxNxMxT}{MTTF} \quad (4.9)$$

λt her zaman aralığı için ortalama olay sayısı, A arıza bölgesinde kullanılan ekipman sayısı, N alt sistem sayısı, M makine çalışma yılı, T zaman periyodunu temsil etmektedir.

$$P \leq \sum_{x=0}^n \frac{(\lambda t)^x}{x!} e^{-\lambda t} = e^{-\lambda t} [1 + \lambda t + \dots + \frac{(\lambda t)^n}{n!}] \quad (4.10)$$

P Poisson dağılımı için olayların olasılığı, x toplam sembolündeki sıralı değerler (0,1,2,...), $x!$ x 'in faktöriyel değerlerini, n ekipman yedek parça sayısını ve e matematiksel Euler sabit sayısını temsil etmektedir.

Kutulama robotsisteminin %85 sistem güvenilirliği ile çalışması için 2 adet PCB kart yedeği tutulduğu durum için hesaplanmıştır.

$$P \leq \sum_{x=0}^2 \frac{(\lambda t)^x}{x!} e^{-\lambda t} \quad (4.11)$$

$$P \leq e^{-0.96} [1 + 0.96 + \frac{(0.96)^2}{2!}] \quad (4.12)$$

$$P_{PCB \text{ Card for 2 spares}} \leq 92.7\% \quad (4.13)$$


Tablo 4.8 Robot posson bağıntısı yedek parça analizi


SPARE PART ANALYSIS									
	Servo Modüllerin Filtresi	Kola Ventilleri Kontrol Kartı	MODULE VMS	V → Module	PCB Control Card	Servo Module Power Card	Date Coding	Robot kollarındaki Vakum motoru	Kapak Motorları
MTTF	15.5	16.7	16.7	16.7	16.7	15.5	16.5	10.3	15.5
A (piece)	4	2	5	3	8	3	1	2	8
N (system)	2.00	2.00	2.00	2.00	2.00	2.00	2.00	2.00	2.00
M (time)	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
T (period)	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
λt	0.52	0.24	0.60	0.36	0.96	0.39	0.12	0.39	1.03
Spare 0	59.7	78.7	55.0	69.9	38.4	67.9	88.6	67.7	35.5
Spare 1	90.5	97.5	87.9	94.9	75.2	94.2	99.3	94.1	72.3
Spare 2	98.4	99.8	97.7	99.9	92.7	99.3	100.0	99.2	91.3
Spare 3	99.8	100.0	99.6	99.9	98.3	99.9	100.0	99.9	97.8

Poisson dağılımı kullanılarak hesaplanan yedek parça analizinde örnek olarak robot üzerindeki kritik komponentlerden olan PCB kontrol kartı için iki adet yedek parça bulundurulduğu durumda sistemin verimliliği komponent özelinde %92,7’de olarak hesaplanmıştır.


4.2 Hesaplanan ve Gerçek MTTF Değer Karşılaştırılması

Kutulama robotlarındaki sisteminin hesaplanan güvenilirliği ve hata analizi Şekil 4.6, Şekil 4.7 ve Şekil 4.8’de robot arıza gruplarının, Şekil 4.9’da ise sistemin genel güvenilirlik ve hata analizi gösterilmektedir. Grafikten robotun güvenilirliğinin son arıza müdahalesinden yaklaşık bir hafta sonra %75’e düştüğü görülmektedir.


**Şekil 4.6** Robot grup 0 için hesaplanan güvenilirlik ve hata analizi



Şekil 4.7 Robot grup 1 için hesaplanan güvenilirlik ve hata analizi




Şekil 4.8 Robot grup 2 için hesaplanan güvenilirlik ve hata analizi



Şekil 4.9 Robot hesaplanan güvenilirlik ve hata analizi

Robot sistemi arıza hata bölge gruplarındaki gelen üç yıllık arıza bildirimleri bakıldığında tüm gelen arıza bildirimlerinin reel ortalaması 6,79 gün/arıza ve hesaplanan güvenilirlik analizinde de sistemin güvenilirliği 6,79 gün sonunda %75'e düştüğü tezini doğrulamaktadır. Gerçek değer, hesapladığımız değer üzerinde olması da ayrıca sistemimizin duruşlarının olması gerekenden daha az oluştuğunu göstermektedir.

Güvenilirlik analizi hesabı sonrasında robotun arıza bölge grupları üzerinden MTTF değer 26,21 gün olarak hesaplanmıştır. Robotta üzerinde gelen reel arıza bildirimlerine de bakıldığında 18-23 gün arasında belirlenen bölgelerde arıza bildirimi geldiği görülmüştür. Bu durum Şekil 4.10'da görülmektedir.



Şekil 4.10 Robot MTTF değeri ile gruplar arası reel MTTF değer karşılaştırması


4.3 MLP Modeli ile Verilerin Test İşlemi

Yapay sinir ağları, deneyim sonucu elde edilen veriyi depolayabilir ve önceden kullanıma hazır hale getirebilir. Sinaptik ağırlıkların güncellenmesi ise, eğitim için kullanılan örnekleri ve nöron ağını kullanarak gerçekleştirilir. Bu çalışmamız için MLP ağına, öğrenme işlemi yapılmayan elimizdeki 11 adet test verisi çalışmanın başarısını test etmek için sunulmuştur.


Tablo 4.9 MLP ağında test edilmek üzere optimize edilmiş veriler

SEASON (t-1)/3	WORKSHOP (Code)/2	MACHINE (Code)	FAILURE AREA (Code)/2	OPERATION TIME (min/518400*3)	DOWNTIME (min/540)	PRODUCTION AT FAILURE (Code)/4	CONVERSION (pieces)/40
1.0000	0.00	1	0.0000	0.1247	0.1111	0.25	0.2750
1.0000	0.00	1	0.5000	0.1597	0.0556	0.75	0.5500
1.0000	0.50	1	0.0000	0.1540	0.0556	0.50	0.5750
1.0000	1.00	0	1.0000	0.1932	0.2222	0.50	0.6750
1.0000	1.00	1	0.5000	0.0341	0.1667	0.50	0.1000
1.0000	0.00	0	0.5000	0.0203	0.1111	0.25	0.1000
1.0000	0.50	1	0.5000	0.2865	0.1111	0.25	1.1750
1.0000	0.50	1	0.0000	0.1517	0.2222	0.25	0.6500
1.0000	0.50	1	0.5000	0.0683	0.0556	0.25	0.2000
1.0000	0.50	1	0.0000	0.0450	0.1667	0.25	0.1750
0.0000	0.50	0	0.0000	0.0122	0.0556	0.25	0.0250
0.0000	0.50	1	0.0000	0.0119	0.0556	0.25	0.1750

Elde edilen güncellenmiş sinaptik ağırlıklardan oluşan algoritmaya test verisi eklendikten sonra makine çalışma süresine ilişkin sonuçlar Şekil 4.11’de gösterilmektedir. Şekil 4.12’de gerçek arıza bildirimleri ile tahmin edilen test arıza verisi arasındaki 7,16 gün ortalama ve 7,30 gün standart sapma ile ($\mu / \sigma + \mu$ aralığında 8 tahmin, 11 veri) %73’lük bir arıza tahmin başarı oranı elde edilmiştir.



Şekil 4.11 Test verisi 7,30 gün standart sapma ile doğruluğu %73



Şekil 4.12 MLP algoritması 2000 iterasyon sonucu train ve test data sonuçları

Bu çalışmada IoT sensör teknolojisi kullanılmadan, geçmiş arıza kayıtlarının optimize edilerek makine öğrenmesi uygulaması ile sistemin en yakın modeli oluşturulması sağlanmıştır. Elde edilen model ile test edilen arızaların önceden tahmin edilmesi sağlanmıştır. Bu çalışma ile amacımız en az kurulum maliyeti ile nasıl bir predictive maintenance uygulaması yapılabileceğinin akademik çalışması ile yapay zekâ teknolojisi ile geçmiş arıza verileri ile başarılı sonuçlar elde etmektedir.

Big datanın büyüklüğü ise bize ileriki çalışmalarımızda daha yakın tahminler yapabilmemizi ve arıza daha olmadan birkaç gün içerisinde yapılan arıza tahmini ile predictive maintenance bakım uygulaması yapılabilmesine imkân sağlayacaktır. Bu sayede üretimde yaşanan plansız üretim duruşlarının yüksek ölçüde azalması ile üretim verimliliği artırılabilecektir.

Bununla beraber yaptığımız komponent bazlı hesaplanan güvenilirlik analizi ile sistemde yaşanabilecek arızaların hem teoriksel hem de pratiksel karşılaştırılması sağlanmıştır. Hesaplanan MTTF ile sistemde yaşanan gerçek arıza verilerinden çıkan MTTF verilerinin birbirleri ile örtüşmesi, yaptığımız predictive maintenance uygulamasındaki tahminlerimizin başarısını büyük ölçüde sağlaması yapılmıştır.

Poisson bağıntısı ile elde ettiğimiz yedek parça analizi ile de sistemin, %85 seviyesinde yüksek üretim verimliliklerinde çalışabilmesi amacı ile malzeme ihtiyaç listesi oluşturulması sağlanmıştır. Bu sayede predictive maintenance uygulaması sırasında malzeme eksikliği kaynaklı müdahale sürelerinin en aza indirilmesi sağlanmış olacaktır.

Big Data boyutunu büyütme gelecekte daha kesin tahminler yapmamızı sağlayacaktır. Şu anda, sistem çevrimdışı ve arıza verileri manuel olarak toplanmaktadır. İlerleyen süreçte arıza tahmin sistemi, fabrika ERP sistemi ile iletişim kuran bir çevrimiçi IoT Server arayüzü ile arıza tahminleri online olarak yapılabilecektir.

- [1] O.T.Kaymakci, "Functional safety and industrial applications, Failure Models," Course Notes, Yildiz Technical University, 2018, pp.3-13.
- [2] S.Haykin, "Neural Networks and Learning Machines," in McMaster University, vol.3, pp.122-367.
- [3] P.Strauß, M.Schmitz, W.Wöstmann, and J.Deuse, "Enabling of predictive maintenance in the Brownfield through low-cost sensors, and IIoT architecture and machine learning," IEEE, 2018, pp.1474-1483.
- [6] P.Strauß, R. Wöstmann, and J. Deuse, "Predictive Maintenance: Entwicklung eines cyber-physischen Predictive-MaintenanceSystems basierend auf einem Low-Cost-Sensorkit und Data Analytics," in Erfolg durch Lean Smart Maintenance: Bausteine und Wege des Wandels, 31. Instandhaltungs-Forum, H. Biedermann, Ed., Köln: TÜV Media GmbH TÜV Rheinland Group, 2017, pp. 121–142.
- [5] H. M. Hashemian and W. C. Bean, "State-of-the-Art Predictive Maintenance Techniques," IEEE Trans. Instrum. Meas., vol. 60, no. 10, pp. 3480–3492, 2011.
- [6] K. Lorentzen, "Herausforderungen in der Ausgestaltung von Industrie 4.0-Lösungen: Interface-Design zwischen Kunde und Provider," in Erfolg durch Lean Smart Maintenance: Bausteine und Wege des Wandels, 31. Instandhaltungs-Forum, H. Biedermann, Ed., Köln: TÜV Media GmbH TÜV Rheinland Group, 2017, pp. 65–82.
- [7] Y.Liu, T.Lu, J.Y.Kim, K.Wu, and J.Jin, "Fast and accurate current prediction in packages using neural networks," IEEE, 2019, pp.621-624.
- [8] D. Yang, Y. C. Chan, B. Wu, and M. Pecht, "Electromigration and thermomigration behavior of flip-chip solder joints in high current density packages," Journal of Materials Research, vol. 23, no. 9, pp. 2333–2339, 2008.
- [9] G. Klambauer, T. Unterthiner, A. Mayr, and S. Hochreiter, "Selfnormalizing neural networks," in Advances in Neural Information Processing Systems, 2017, pp. 971–980.
- [10] D.-A. Clevert, T. Unterthiner, and S. Hochreiter, "Fast and accurate deep network learning by exponential linear units (elus)," arXiv preprint arXiv:1511.07289, 2015.
- [11] K.Liulys, "Machine learning application in predictive maintenance," in Vilnius Gediminas Technical University, IEEE, 2019, pp.1-4
- [12] Search Data Management [online], 2019. Big data : [cited 2 February 2019]. Available from internet: <https://searchdatamanagement.techtarget.com/definition/big-data1>.

- [13] Reliable Plant [online], 2019. 3 Factors Driving Industry 4.0 : [cited 4 February 2019]. Available from internet: <https://www.reliableplant.com/Read/30933/factors-driving-industry>.
- [14] Thorsten Wuest, Daniel Weimer, Christopher Irgens & Klaus-Dieter Thoben, "Machine learning in manufacturing: advantages, challenges, and applications," Production & Manufacturing Research, vol. 4:1, 2016 pp. 23-45, [cited 4 February 2019].
- [15] S. Butte, Pwashanth A R, and S. Patil, "Machine learning-based predictive maintenance strategy: a super learning approach with deep neural networks," IEEE, 2018, pp. 1-5.
- [16] Thoben KD, Wiesner S, Wuest T. Industrie 4.0 and smart manufacturing—a review of research issues and application examples. Int. J. Autom. Technol. 2017;11(1).
- [17] Özgür K., (2018) "Functional Safety And Industrial Applications", Yıldız Teknik Üniversitesi.
- [18] Özlem Ö., (2012) "Proses Güvenliğinde Fonksiyonel Güvenlik (SIL) ve ATEX Direktifi İlişkisi", Önder Akademi Endüstriyel Danışmanlık Eğitim ve İleri Teknoloji Ürünleri Ticaret AŞ.
- [19] Enver V., (2007) "Sistem Güvenirliği Analizi ve Bir Uygulama", Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [20] R.E. Barlow, F. Proschan, (1975) "Statistical Theory of Reliability and Life Testing".
- [21] "Spare Parts Stock Level Calculation" <http://www.geocities.ws/riekonissi/spareparts>
- [22] Aydinli, G., (2007) "Reliability Modeling and Analysis of Low Power Portable Direct Methanol Fuel Cell", UMI.
- [23] Özgür K. (2015) "Bir Tramvay Hattının Güvenilirlik Analizi", Yıldız Teknik Üniversitesi.
- [24] Özgür K. (2018), Hatada Güvenli Sistemler Ders Notları, Yıldız teknik Üniversitesi, Kontrol Otomasyon Mühendisliği, Fen Bilimleri Enstitüsü
- [25] Muharrem M. (2019), Makine Öğrenmesi ve Yapay Sinir Ağları Ders Notları, Yıldız teknik Üniversitesi, Kontrol Otomasyon Mühendisliği, Fen Bilimleri Enstitüsü
- [26] "Free MTBF Calculator User Guide, Perform reliability prediction (MTBF calculation)" <https://aldservice.com/Free-MTBF-Calculator-User-Guide.html>

SİMÜLASYON SONUÇLARI

A.1 100 İterasyon İle Simülasyon Sonuçları

Tablo A.1 100 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi:	23.558330 seconds.
---------------	--------------------

Tablo A.2 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (100 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	4.1202	9.8873	7.3729	28.4179	12.6461	10.5614	14.5626	12.2689	5.2606	5.9131	5.6096
Fark	15.0438	8.5927	15.8111	-24.326	-10.21	23.8186	3.6414	-4.0729	0.1394	-4.4491	-4.1816

Tablo A.3 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	1.800672727
σ	12.95075961

Tablo A.4 Hata değerinin ortalamadan sapma başarısı

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-37.0516061	0
$-2\sigma+\mu$	-24.10084649	1
$-\sigma+\mu$	-11.15008688	0
μ	1.800672727	5
$\sigma+\mu$	14.75143234	2
$2\sigma+\mu$	27.70219194	3
$3\sigma+\mu$	40.65295155	0
$4\sigma+\mu$	53.60371116	0
BAŞARI		64%



Şekil A.1 100 iterasyon ve 13,38 gün standart sapma ile doğruluğu %64



Şekil A.2 Makine öğrenmesi 100 iterasyon ile gerçek ve tahmin verileri

A.2 500 İterasyon İle Simülasyon Sonuçları

Tablo A.5 500 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi	127.675857 seconds.
---------------------	---------------------

Tablo A.6 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (500 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	6.37544	14.80294159	10.09250245	12.2186	25.4287	5.61286	13.6279	11.0044	15.7041	9.62372	3.75818
Fark	12.7886	3.677058412	13.09149755	-8.1266	-22.993	28.7671	4.57608	-2.8084	-10.304	-8.1597	-2.3302

Tablo A.7 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	0.743522042
σ	13.38804962

Tablo A.8 Hata değerinin ortalamadan sapma başarı oran tespiti

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-39.42062682	0
$-2\sigma+\mu$	-26.0325772	0
$-\sigma+\mu$	-12.64452758	1
μ	0.743522042	5
$\sigma+\mu$	14.13157166	4
$2\sigma+\mu$	27.51962129	0
$3\sigma+\mu$	40.90767091	1
$4\sigma+\mu$	54.29572053	0
BAŞARI		82%



Şekil A.3 500 iterasyon ve 13,38 gün standart sapma ile doğruluğu %82



Şekil A.4 Makine öğrenmesi 500 iterasyon ile gerçek ve tahmin verileri

A.3 1.000 İterasyon İle Simülasyon Sonuçları

Tablo A.9 1.000 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi	254.986425 seconds.
--------------	---------------------

Tablo A.10 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (1.000 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	6.25581	27.00423453	23.51110472	0.42707	22.1253	1.57205	18.7251	17.6957	19.5735	12.1604	1.25511
Fark	12.9082	-8.524234525	-0.32710472	3.66493	-19.689	32.8079	-0.5211	-9.4997	-14.173	-10.696	0.17289

Tablo A.11 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	-1.261576988
σ	13.83405273

Tablo A.12 Hata değerinin ortalamadan sapma başarı oran tespiti

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-42.76373518	0
$-2\sigma+\mu$	-28.92968245	0
$-\sigma+\mu$	-15.09562972	1
μ	-1.261576988	4
$\sigma+\mu$	12.57247574	4
$2\sigma+\mu$	26.40652847	1
$3\sigma+\mu$	40.2405812	1
$4\sigma+\mu$	54.07463394	0
BAŞARI		73%



Şekil A.5 1.000 iterasyon ve 13,83 gün standart sapma ile doğruluğu %73



Şekil A.6 Makine öğrenmesi 1.000 iterasyon ile gerçek ve tahmin verileri

A.4 2.000 İterasyon İle Simülasyon Sonuçları

Tablo A.13 2.000 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi	515.651553 seconds.
---------------------	---------------------

Tablo A.14 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (2.000 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	0.23922	8.572817155	1.456205359	3.05123	2.73077	27.4196	11.5863	0.79113	1.04919	0.73647	0.0334
Fark	18.9248	9.907182845	21.72779464	1.04077	-0.2948	6.96035	6.61768	7.40487	4.35081	0.72753	1.3946

Tablo A.15 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	7.160144956
σ	7.308202705

Tablo A.16 Hata değerinin ortalamadan sapma başarı oran tespiti

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-14.76446316	0
$-2\sigma+\mu$	-7.456260455	0
$-\sigma+\mu$	-0.14805775	1
μ	7.160144956	6
$\sigma+\mu$	14.46834766	2
$2\sigma+\mu$	21.77655037	2
$3\sigma+\mu$	29.08475307	0
$4\sigma+\mu$	36.39295578	0
BAŞARI		73%



Şekil A.7 2.000 iterasyon ve 7,30 gün standart sapma ile doğruluğu %73



Şekil A.8 Makine öğrenmesi 2.000 iterasyon ile gerçek ve tahmin verileri

A.5 5.000 İterasyon İle Simülasyon Sonuçları

Tablo A.17 5.000 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi	1275.723028 seconds.
---------------------	----------------------

Tablo A.18 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (5.000 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	2.50888	13.21165043	10.94617616	12.6467	12.7568	10.032	10.3381	4.66125	12.0158	6.5999	7.79908
Fark	16.6551	5.268349567	12.23782384	-8.5547	-10.321	24.348	7.86592	3.53475	-6.6158	-5.1359	-6.3711

Tablo A.19 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	2.991977631
σ	10.92983607

Tablo A.20 Hata değerinin ortalamadan sapma başarı oran tespiti

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-29.79753058	0
$-2\sigma+\mu$	-18.86769451	0
$-\sigma+\mu$	-7.937858441	2
μ	2.991977631	3
$\sigma+\mu$	13.9218137	4
$2\sigma+\mu$	24.85164977	2
$3\sigma+\mu$	35.78148584	0
$4\sigma+\mu$	46.71132192	0
BAŞARI		64%



Şekil A.9 5.000 iterasyon ve 10,92 gün standart sapma ile doğruluğu %64



Şekil A.10 Makine öğrenmesi 5.000 iterasyon ile gerçek ve tahmin verileri

A.6 10.000 İterasyon İle Simülasyon Sonuçları

Tablo A.21 10.000 iterasyon ile sinaptik ağırlık hesaplama süresi

İşlem Süresi	2618.779665 seconds.
---------------------	----------------------

Tablo A.22 MLP test verisi gerçek, tahmin ve hata verisi


TEST VERİLERİ, GERÇEK VE TAHMİNİ DEĞER KARŞILAŞTIRMASI (10.000 İTERASYON)											
	1	2	3	4	5	6	7	8	9	10	11
Gerçek Değer	19.164	18.48	23.184	4.092	2.436	34.38	18.204	8.196	5.4	1.464	1.428
Tahmin Değer	0.13571	2.110083401	84.78964702	2.52978	5.22107	11.3536	0.20201	20.1196	3.28706	1.31065	0.76714
Fark	19.0283	16.3699166	-61.60564702	1.56222	-2.7851	23.0264	18.002	-11.924	2.11294	0.15335	0.66086

Tablo A.23 Gerçek ve tahmin değer farklarının ortalama ve standart sapması



Başarı Kriteri	
μ	0.418329821
σ	22.22808053

Tablo A.24 Hata değerinin ortalamadan sapma başarı oran tespiti

Kriter	Kriter Değeri	Değer Adt.
$-3\sigma+\mu$	-66.26591175	0
$-2\sigma+\mu$	-44.03783123	1
$-\sigma+\mu$	-21.8097507	0
μ	0.418329821	3
$\sigma+\mu$	22.64641035	6
$2\sigma+\mu$	44.87449087	1
$3\sigma+\mu$	67.1025714	0
$4\sigma+\mu$	89.33065192	0
BAŞARI		82%



Şekil A.11 10.000 iterasyon ve 22,22 gün standart sapma ile doğruluğu %82



Şekil A.12 Makine öğrenmesi 10.000 iterasyon ile gerçek ve tahmin verileri

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgisi: okocatr@gmail.com

Konferans Bildirileri

1. Kaymakci O., Mercimek M., Koca O., “Advanced Predictive Maintenance with Machine Learning Failure Estimation in Industrial Packaging Robots”, 15th International Conference on Development and Application Systems, Suceava, Romania, 2020, pp. 1-6, doi:10.1109/DAS49615.2020.9108913.