



**BULUT TEMELLİ BİR MÜHENDİSLİK
PORTALINDA ETKİN VERİ GİRİŞİ İÇİN
MAKİNE ÖĞRENMESİ
ALGORİTMALARI**

Yüksek Lisans Tezi

Burak DEMİREL

Eskişehir 2023

**BULUT TEMELLİ BİR MÜHENDİSLİK PORTALINDA ETKİN VERİ GİRİŞİ
İÇİN MAKİNE ÖĞRENMESİ ALGORİTMALARI**

Burak DEMİREL

Yüksek Lisans Tezi

İstatistik Anabilim Dalı

Uygulamalı İstatistik Bilim Dalı

Danışman: Prof. Dr. Gürkan ÖZTÜRK

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ocak 2023

JÜRİ VE ENSTİTÜ ONAYI

Burak DEMİREL'nin BULUT TEMELLİ BİR MÜHENDİSLİK PORTALINDA ETKİN VERİ GİRİŞİ İÇİN MAKİNE ÖĞRENMESİ ALGORİTMALARI başlıklı çalışması 20/01/2023 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, İstatistik Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof. Dr. Gürkan ÖZTÜRK

Üye

: Prof. Dr. Yeliz MERT KANTAR

Üye

: Dr. Öğr. Üyesi Erdener ÖZÇETİN

Prof. Dr. Murat TANIŞLI

Lisansüstü Eğitim Enstitüsü Müdürü

20/01/2023

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Yksek Lisans đrencisi Burak DEMİREL, BULUT TEMELLİ BİR MHENDİSLİK PORTALINDA ETKİN VERİ GİRİřİ İÇİN MAKİNE đRENMESİ ALGORİTMALARI bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımda incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. Grkan ZTRK

ÖZET

BULUT TEMELLİ BİR MÜHENDİSLİK PORTALINDA ETKİN VERİ GİRİŞİ İÇİN MAKİNE ÖĞRENMESİ ALGORİTMALARI

Burak DEMİREL

İstatistik Anabilim Dalı

Uygulamalı İstatistik Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ocak 2023

Danışman: Prof. Dr. Gürkan ÖZTÜRK

Teknolojinin gelişmesi ile hayatımızın ayrılmaz bir parçası haline gelen makine ve sistemlerde yer alan en önemli bileşen, yapay zekâ kavramı ile ortaya çıkan makine öğrenmesi algoritmalarıdır. Bu çalışmada, bulut hesaplama mimarisi kullanılarak tasarlanan bir mühendislik portalının, kullanıcı deneyimini artırmak üzere makine öğrenmesi temelli çalışmalar gerçekleştirilmiştir. Sistemdeki arayüzde yer alan parametreler için veri girişleri yapılırken, kullanıcının girdiği parametreleri değerlendirerek eksik kalan parametrelerin ne olacağını belirleyen bir tahmin yapmak için makine öğreniminden yararlanılmıştır. Bu amaçla, doğrusal, destek vektör, karar ağaçları, rassal orman ve k en yakın komşu olmak üzere beş farklı regresyon yaklaşımı kullanılarak modeller oluşturulmuş ve karşılaştırmalı analizler yapılmıştır. Bu analizler sonucunda seçilen rassal orman yaklaşımı ile elde edilen tahmin modeli sisteme entegre edilmiştir.

Anahtar Sözcükler: Makine öğrenmesi, Regresyon, Kullanıcı Deneyimi, Asansör parametre tahmini.

ABSTRACT

MACHINE LEARNING ALGORITHMS FOR EFFICIENT DATA ENTRY IN A CLOUD-BASED ENGINEERING PORTAL

Burak DEMİREL

Department of Statistics

Programme in Applied Statistics

Eskişehir Technical University, Institute of Graduate Programs, January 2023

Supervisor: Prof. Dr. Gürkan ÖZTÜRK

The most important component in machines and systems, which have become an integral part of our lives with the development of technology, is machine learning algorithms that emerged with the concept of Artificial Intelligence. In this study, machine learning-based studies were carried out to increase the user experience of an engineering portal designed using cloud computing architecture. While making data entries for the parameters in the interface in the system, machine learning was used to evaluate the parameters entered by the user and make a prediction about the missing parameters. For this purpose, models were created using five different regression approaches: linear, support vector, decision trees, random forest and k nearest neighbor, and comparative analyzes were made. The prediction model obtained with the random forest approach selected as a result of these analyzes has been integrated into the system.

Keywords: Machine learning, Regression, User experience, Prediction of elevator parameter.

TEŞEKKÜR

Hayatımın her anında manevi ve maddi destek sağlayan aileme; benden her zaman hiçbir şeyi esirgemedi destek sağlayan babam Mustafa DEMİREL'e, dualarıyla her an yanımda olan ve desteğini gönülden hissettiğim annem Keziban DEMİREL'e ve sevgili ablam Rabia DEMİREL'e gönülden teşekkür ederim.

Her açıdan kendime örnek aldığım ve ihtiyacım olduğu her anda bana destek veren ve değerli hocam Prof. Dr. Sayın Gürkan ÖZTÜRK'e şükranlarımı sunuyorum. Tez çalışması sürecinde görüş ve önerileriyle katkı sağlayan tez izleme kurulu üyeleri Prof. Dr. Sayın Yeliz MERT KANTAR'a ve Dr. Öğr. Üyesi Sayın Erdener ÖZÇETİN'e; bu zamanlara gelmemde emeği olan kıymetli hocam Prof. Dr. Sayın İlhan USTA'ya; eğitim hayatımın lisans sürecinde kodlamanın temellerini öğrettiği için değerli hocam Öğr. Gör. Sayın Ali ATALAY'a saygı ve sevgilerimi sunarak teşekkür ederim.

Çalışmalarına verdikleri değerli destekler nedeniyle Yazılım Uzmanı Sayın Latif DALLI'ya ve Elektrik Mühendisi Sayın Mehmet YÜCELAY'a; Gravit, Eleport ve İncir Ar-Ge şirketlerine teşekkür ederim.

Ailem için...

Burak DEMİREL

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Burak DEMİREL

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ	XI
ŞEKİLLER DİZİNİ.....	XII
GÖRSELLER DİZİNİ	XIII
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ.....	1
1.1. Tezin Amacı	2
1.2. Önceki Çalışmalar.....	3
2. KULLANICI DENEYİMİ	11
2.1. Bulut Bilişim	12
2.2. Kullanıcı Deneyimi ve Makine Öğrenmesi	13
3. ASANSÖR	16
3.1. Kullanım Amacına Göre Asansörler	17
3.2. Konstrüksiyon ve Tahrik Sistemlerine Göre Asansörler	18
3.3. Halat Sistemli Asansörlerin Güvenlik Hesapları	19
3.3.1. Motor hesabı	19
3.3.2. Halat hesabı.....	20
3.3.3. Ray hesabı	20
3.3.4. Kolon hattı kesit hesabı.....	21

3.3.5. Trafik hesabı.....	21
3.3.6. Binaya gelen kuvvetler hesabı.....	22
3.3.7. Toplam çekilen güç hesabı.....	22
3.3.8. Kabin süspansiyonu hesabı.....	22
3.3.9. Karşı ağırlık şase hesabı	22
3.3.10. Motor şase hesabı	22
3.3.11. Dübel hesabı.....	23
3.3.12. Regülatör hesabı.....	23
3.4. Halat Tahrikli Asansörlerin Mekanik Donanımı.....	23
4. MAKİNE ÖĞRENMESİ.....	26
4.1. Makine Öğrenmesi Yöntemleri.....	29
4.1.1. Doğrusal Regresyon (Linear Regression).....	31
4.1.2. Destek vektörleri (Support vectors).....	32
4.1.3. Karar ağaçları (Decision trees)	34
4.1.4. Rassal orman (Random forest)	35
4.1.5. K - en yakın komşu (K - nearest neighbor).....	36
4.2. Performans Metrikleri.....	37
5. UYGULAMA	39
5.1. Mühendislik Hesaplamaları için Bulut Bilişim Temelli Portal – ELEPORT.....	39
5.2. Hesaplamalarda Kullanılan Kullanıcı Arayüzleri	40
5.3. Tahmin Parametreleri	43
5.3.1. Kabin hızı	44
5.3.2. Halat çapı ve Halat sayısı.....	44
5.3.3. Tahrik kasnağı çapı.....	44
5.3.4. Motorun nominal gücü	45
5.3.5. Tahrik kasnağı kanal açısı.....	46
5.4. Sayısal Sonuçlar ve Model Seçimi	47
5.5. Parametre Seçimi	59
6. SONUÇ	65
KAYNAKÇA.....	67

ÖZGEÇMİŞ



TABLÖLAR DİZİNİ

Sayfa

Tablo 5.1. Çalışmada kullanılan bağımsız değişkenler ve açıklamaları	43
Tablo 5.2. Çalışmada kullanılan değişken tipleri	48
Tablo 5.3. Motor hesabı veri setine ait betimleyici istatistikler	48
Tablo 5.4. Halat hesabı veri setine ait betimleyici istatistikler	49
Tablo 5.5. Tahmin değişkenlere ait betimleyici istatistikler	49
Tablo 5.6. Tahmin parametrelerinin çarpıklık ve basıklık değerleri.....	50
Tablo 5.7. Tahmin Parametrelerinin Shapiro- Wilk Teti Sonuçları.....	50
Tablo 5.8. Motor gücü parametresi için kurulan modellerin performans metrikleri	57
Tablo 5.9. Halat sayısı parametresi için kurulan modellerin performans metrikleri	57
Tablo 5.10. Kabin hızı parametresi için kurulan modellerin performans metrikleri	57
Tablo 5.11. Halat çapı parametresi için kurulan modellerin performans metrikleri.....	58
Tablo 5.12. Kanal açısı parametresi için kurulan modellerin performans metrikleri	58
Tablo 5.13. Tahrik kasnağı çapı parametresi için kurulan modellerin performans metrikleri.....	59

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Asansörlerin sınıflandırılması (İmrak & Erdemligil, 2000).....	18
Şekil 4.1. Makine Öğrenmesi Yöntemleri	29
Şekil 4.2. Gelir ve gider arasındaki doğrusal regresyon grafiği	32
Şekil 4.3. SVR Grafiği (Chanklan, ve diğerleri, 2018)	33
Şekil 4.4. Doğrusal ve Doğrusal Olmayan SVR	33
Şekil 4.5. Karar Ağacı Yapısı.....	34
Şekil 4.6. Rassal Orman'ın Yapısı.....	35
Şekil 5.1. Tahmin Parametrelerine Ait Histogram Grafikleri	51
Şekil 5.2. Motor Parametrelerinin Korelasyonlarının Isı Haritası.....	52
Şekil 5.3. Halat Parametrelerinin Korelasyonlarının Isı Haritası	53
Şekil 5.4. Motor Gücünün Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	61
Şekil 5.5. Kabin Hızı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	62
Şekil 5.6. Halat Sayısı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	62
Şekil 5.7. Halat Çapı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	63
Şekil 5.8. Kanal Açısı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	63
Şekil 5.9. Tahrik Kasnağı Çapı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları	64

GÖRSELLER DİZİNİ

Sayfa

Görsel 1.1. Kullanıcıların kağıt üstünde oluşturdukları çizimlerin manuel ve “Paper2Wire” ile dijitale aktarılmış tasarımları.....	5
Görsel 1.2. “Coupon Buddy” Adlı Uygulamanın Üç Farklı Prototipi (Ahmed, 2018)	6
Görsel 1.3. “Coupon Buddy” Adlı Uygulamada Kullanılan Ekranlar (Ahmed, 2018).	6
Görsel 3.1. Elisha Otis’in Asansör Emniyet Frenini Tanıtma Anı (Sığırcı, 2021)	17
Görsel 3.2. Hidrolik Asansör Elemanları (DD, 2022)	19
Görsel 3.3. Asansörün mekanik donanımı (FEMA, 2019)	24
Görsel 4.1. AI, ML, Derin Öğrenme Kavramları Arasındaki İlişki (Intelligenza Artificiale: hanno vinto le Reti Neurali?, 2022)	26
Görsel 4.2. Makine Öğrenmesi Yöntemlerinin Çalışma Mantığı (Raschka & Mirjalili , 2015).....	27
Görsel 5.1. Eleport Sitesi Projeler Sekmesi	40
Görsel 5.2. Eleport Motor Hesabı Arayüzü	41
Görsel 5.3. Makine Öğrenmesi Tahmin Butonları	42
Görsel 5.4. Makine Öğrenmesi Tahmin Sonuç Ekranı	42
Görsel 5.5. Çelik Halatın Çapı ve Sarmal Yapısı.....	44
Görsel 5.6. Tahrik Kasnağı (Astim Toro, 2022)	45
Görsel 5.7. Makine Dairesi ve Tahrik Makinesi (Motor) (Yönel Asansör, 2022).....	46
Görsel 5.8. V Kanal Açısı	47
Görsel 5.9. Çalışmada kullanılan kütüphaneler	54
Görsel 5.10. Pandas kütüphanesi ile veri okuma	54
Görsel 5.11. Izgara Arama ile Doğrusal Regresyon Modeli Adımları	55
Görsel 5.12. Izgara Arama ile En İyi Doğrusal Regresyon Parametreleri	56
Görsel 5.13. Sklearn Kütüphanesi ile Hesaplanan Performans Metrikleri	56
Görsel 5.14. Parametre Seçiminde Kullanılan Kütüphaneler	60
Görsel 5.15. En İyi Parametrelerle Oluşturulan RF Modeli Kod Bloğu	60
Görsel 5.16. Özellik Önemi Fonksiyonu ve Değişkenlerin Önem Grafiği	61

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zekâ)
DT	: Decision Tree (Karar Ağaçları)
ELEPORT	: Elevator Portal
IML	: In Mould Labelling (Kalıp içi Etiketleme)
KNN	: K- Nearest Neighbors (K- En Yakın Komşu)
Lin- Reg	: Linear Regression (Doğrusal Regresyon)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percent Error (Ortalama Mutlak Yüzde Hata)
ML	: Machine Learning (Makine öğrenmesi)
MSE	: Mean Square Error (Hata Kareler Ortalaması)
RF	: Random Forest (Rassal Orman)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
UI	: User Interface (Kullanıcı Arayüzü)
UX	: User Experience (Kullanıcı Deneyimi)
UXR	: User Experience Research (Kullanıcı Deneyimi Araştırması)
X	: Girdi parametreleri
y	: Çıktı parametresi
R^2	: Belirlilik katsayısı
β_0	: Belirlilik katsayısı the coefficient of determination
β_1	: Doğrusal regresyon modelinde eğim katsayısı
ε	: Hatalar

1. GİRİŞ

Kullanıcı deneyimi için ilk gereksinim, müşterinin ihtiyaçlarını tam olarak, sorunsuz ve zahmetsizce karşılamaktır. Ardından ürünün, sadelik ve zarafet içinde kullanılabilmesi gelmektedir. Gerçek kullanıcı deneyimi, müşterilere istediklerini söylemenin veya kontrol listesi özelliklerini sağlamanın çok ötesine geçer. Bir şirketin yüksek kaliteli kullanıcı deneyimi elde edebilmesi için mühendislik, pazarlama, grafik, endüstriyel tasarım ve arayüz tasarımı dahil olmak üzere birden çok hizmeti sorunsuz bir şekilde birleştirmesi gerekir (User Experince, 2022).

Teknolojinin gelişmesi ile birlikte makineler hayatımızın vazgeçilmez bir parçası haline gelmiş ve yapay zekâ kavramı makinelerin önemli bir bileşeni olarak ortaya çıkmıştır. Yapay zekanın alt yapısını oluşturan makine öğrenmesi algoritmaları, geçmiş verilerdeki önemli tanımlar arasında ilişki kurarak olaylara genel bir bakış sağlar. Bu algoritmalar görüntü tanıma, konuşma algılama, tüketici önerileri, dolandırıcılık tespiti, yapay zekâ sohbet ve tasarım robotları gibi farklı uygulama alanlarında kullanılmaktadır. Bu amaçları gerçekleştirmek ve bunun yanı sıra büyük ve karmaşık veri kümelerindeki kalıpları tanımak için matematiksel modeller kullanır.

Makine öğrenmesi aslında yapay zekânın bir alt kümesi olsa da birçok yerde yapay zekâ kavramının karşılığı olarak da kullanılmaktadır. Makine öğrenmesi algoritmaları, tarayıcı tanımlama bilgileri veya kullanıcının web sitesindeki etkinliği gibi çeşitli yöntemlerle her bir kullanıcı hakkında bilgi toplayabilmektedir. Daha sonra makine öğrenmesi modelleri, toplanan bilgiler doğrultusunda kullanıcının ihtiyaçları ve davranışları hakkında tahminlerde bulunurlar. Tahmin sonuçlarını karşılaştırmak ve kalıpları keşfetmek için eğitim algoritmaları, araştırma yapan insanlardan çok daha hızlıdır. Şu anda birçok şirket, kullanıcılarına fayda sağlamak amacıyla bilgi mimarisini kişiselleştirmek için makine öğrenimini kullanmaktadır.

Örneğin Google kullanıcılara ücretsiz olarak sunduğu Gmail hizmetinde, e-postaları (sosyal, birincil veya promosyon) kullanıcıya göre farklı şekilde etiketlemek için yapay zekâyı kullanır. Makine öğrenmesi, geçmiş e-posta gönderme alışkanlıklarını analiz ederek, gelen e-postaları spam, reklam veya birincil olarak sınıflandırır. Bu durum geçmiş davranışlara bağlı olarak herkes için farklı sonuçlar verir (Robertson, 2022).

Bir e-ticaret sitesi, makine öğrenmesi ile ne tür ürünleri tercih ettiğinizi analiz ederek onlara benzer ürünler önerebilir. Bu durum, kullanıcıların deneyimlerini iyileştirerek o siteyi daha sık ziyaret etmelerini sağlayabilir ve farklı kişilere göre farklı

kullanıcı akışları oluşturulabilir. Makine öğrenmesi, birçok amaç için farklı alanlarda kullanılabilir (AI, 2022).

1.1. Tezin Amacı

Bu çalışmada, kullanıcı deneyimi üzerine yapılmış önceki çalışmalar incelenmiş, araştırmanın önemi vurgulanmıştır. Makine öğrenmesi ile kullanıcı deneyimi faydası en üst düzeye çıkartılarak kullanıcılar için tahminlerin doğruluğunun artırılmasının mümkün olduğu sonucuna varılmıştır. Makine öğrenimi için toplanan verilerin kullanıcı hesap ilişkisine uyarlanması hedeflenmiştir.

Temel uygulamalardan daha ayrıntılı olanlara geçtikçe, işlevsellik tam olarak temsil edilememektedir. Her kullanıcının yazılım üzerindeki deneyimi farklı olacağından, müşteri memnuniyetsizliği meydana gelmesi kaçınılmazdır. Genel anlamda kullanıcıların beğeni ve tercihlerine göre değişen arayüzler tasarlanabilmekte ve kullanıcıların yaşadığı hoşnutsuzluk dinamik arayüzlerin kullanımı ile giderilebilmektedir. Bu tür arayüzler, kullanıcıya en iyi şekilde hitap edebileceği şekilde önceden depolanan veya öğrenilen verilere bağlı olarak kendilerini ayarlayabilirler. Bu sayede, uygulamanın genel kullanılabilirliğini ve anlaşılabilirliğini azaltılabilecektir. Dinamik arayüzler, sadece kullanıcı memnuniyetsizliği sorununu çözmekle kalmaz, aynı zamanda bu metodoloji uygulama sahiplerine de (Uygulama Geliştiricisi, Ticari Kuruluşlar, vb.) olumlu fayda sağlayabilir. Bu tür arayüzlerde kullanıcı gereksinimleri ön planda tutulduğu için müşteri memnuniyeti üst seviyelere çıkacaktır. Genel olarak uygulamaların, kullanıcı tercihleri ve öncelikleri ile ilişkilendirilecek biçimde şekillendirilmesinin her iki tarafa da fayda sağlayacağı kesindir (Sankar, Amudha, Madhavan, & Lamba, 2020).

Eleport, asansör tasarımı için hazırlanmış, bulut üzerinde çalışan bir endüstriyel web uygulamasıdır. Bu web uygulamasının amacı, hesaplanması günler alabilen 12 adet hesabı ve asansörün teknik çizimlerini pratik bir şekilde kullanıcıya sunmaktır. Asansör sektöründeki mimarların ve çok sayıda KOBİ'nin hizmet alacağı yapay zekâ destekli bir uygulama olacaktır. Sistemde kullanıcıların yaptıkları hesaplamalar ve çizimler ile ilgili olarak oluşturulan veriler işlenerek, sistemin kullanıcı deneyiminin en üst düzeylere çıkarılması hedeflenerek çeşitli tahmin modelleri oluşturulmuştur. Bu bağlamda geliştirilen Endüstriyel Bulut Uygulaması; model tabanında, asansör hesabı için kullanılan birçok kritik hesaplama modelinin yanı sıra kullanıcı deneyimini arttırmaya yönelik makine öğrenmesi modellerini içeren bir karar destek sistemi niteliğindedir.

Çalışmada kullanıcı deneyimi elde etmek için makine öğreniminin arayüzlerle birlikte nasıl kullanılabileceği ve sektöre nasıl fayda sağlayacağı vurgulanmıştır.

Asansör inşaatı başlamadan önce, yapılması gereken Trafik, Binaya Gelen Kuvvetler, Motor, Toplam Çekilen Güç, Ray, Kolon Hattı Kesit, Halat, Kabin Süspansiyonu, Karşı Ağırlık Süspansiyonu, Motor Şase, Dübel ve Regülatör hesapları olmak üzere 12 farklı kontrol veya güvenlik hesabı bulunmaktadır. Bu kritik hesaplamalar yapıldıktan sonra hesap raporları ve asansörün farklı açılardan kesitlerinin teknik çizimleri, ilgili kuruluşlara sunularak asansör ruhsat belgesi temin edilmektedir. Hesapların yetkili kuruluşlar tarafından kontrol edilip onaylanması durumunda asansörün ruhsat belgesi çıkarılmaktadır. Asansörün ruhsatlandırılmasının ardından hesaplarda beyan edilmiş belirli ölçüdeki parçalar ile asansör inşa edilebilmektedir.

Asansör imalatında uyulması gereken ve hayati derecede önem taşıyan parametreler, farklı parametreler ile belirlenmektedir. Bu tez kapsamında asansör kontrol ve güvenlik hesaplarında kullanılan parametreler makine öğrenmesi algoritmaları ile tahmin edilmiştir.

Makine öğrenmesi ile dinamik kullanıcı arayüzlerinin oluşturulması, site kullanıcılarının deneyimlerini artıracak, böylece ilgili projelerin hızlı ve hatasız bir şekilde oluşturulması mümkün olabilecektir. Makine öğrenmesi algoritmaları halat tahrikli asansörler için uygulanmış ve hesaplanmış olup ileride diğer tip asansörler için de uygulanması planlanmaktadır.


1.2. Önceki Çalışmalar

Şapcı ve Pektaş 2021 yılında, mimari tasarım süreci ve kullanıcı deneyimi alanının kesişimleri üzerine bir makale yazmışlardır. Yazarlar kullanıcıların olaylar karşısındaki seçimlerini ve tercihlerini inceleyerek, kullanıcı deneyiminin kişiye özel farklı alternatifler sonuçlar sunulması üzerine yoğunlaşmakta olduğunu belirtmiştir.

Makine öğrenimi ise insanların geçmiş tercihlerine odaklanmakta ve bu davranışlardan yola çıkarak yeni bir veri kümesi ile yeni ürünlerin oluşturulmasını amaçlamaktadır. Makalede, bu iki alanın birbirinden neler öğrenebileceği ortaya konulmaktadır. Makine öğrenmesi ve kullanıcı deneyiminin birbirini destekleyen ve besleyen iki alan olduğu, mimari tasarımda daha işlevsel ürünler ortaya çıkabileceği ve yapılan hataların azalacağı sonucuna varılmıştır (Şapcı & Taşlı Pektaş, 2021).


Yang 2017’de yayınladığı makalede, makine öğrenmesi yeteneği ile doğru kullanıcı deneyimi problemini eşleştirmenin çok önemli ve zor olduğunu belirtmiştir. Sistem tasarım süreçlerinde kullanıcı deneyimi ve makine öğrenmesi uzmanlığı arasında bir diyalog eksikliğinin var olduğunu söylemiştir. Makine öğrenimi içeren sistemler tasarlanırken kullanıcı deneyimi sunan uygulamanın, iki temel rolü olan problem belirleme ve problem çözme konularını detaylandırmıştır. Yani, kullanıcı merkezli sorunu çözmek için makine öğrenimini kasıtlı olarak kullanmak ve kullanıcı arayüzü ile deneyimini makine öğrenmesi çıktıları için uygun şekilde üretecek ve iletecek şekilde tasarlamasının altını çizmiştir. Makine öğreniminin yeni kullanıcı deneyimi olduğu fikrini desteklemiştir. Makine öğreniminin kullanıcılar için algılanabilir bir şekilde olması için kullanıcı deneyimi tasarımına ihtiyacı olduğunu ve makine öğrenmesi ile kullanıcı deneyimi kavramlarının birbiriyle simbiyotik bir ilişki içinde bulunduğunu söylemiştir (Yang, 2017).

Buschek ve arkadaşları 2021 yılında yayınladıkları makalede, kâğıt üzerine çizilmiş olan eskizleri, grafiksel kullanıcı arayüz öğeleri olarak dijitalle aktarmak için “Paper2Wire” adında bir prototip geliştirmişlerdir. Makine öğrenmesi kullanan bir tasarımı, 20 kişilik tasarımcı ekibi ile bir atölye çalışması gerçekleştirmişlerdir. Kâğıda çizilen tasarımlar prototip makine öğrenmesi algoritmaları ile dijital ortama aktarılmıştır. Prototipin çıktıları tasarımcıların çizim programları kullanarak ürettikleri taslaklar ile çok benzer bir çıktı üretmiştir. Kullanıcı deneyimi tasarımcıları için bir makine öğrenmesi uygulaması tasarlamadan araştırılması gereken yerler üzerinde durmuştur. Buschek ve arkadaşları önemli bir bulgu olarak makine öğreniminin, yinelenen manuel takip çalışmalarını azaltacağını, daha çekici ve uygulanabilir hale getireceğini; gelecekte manuel tasarım adımları arasında bir "yapıştırıcı" görevi göreceğini belirtmiştir (Buschek, Anlauff , & Lachner, 2021).




Görsel 1.1. Kullanıcıların kağıt üstünde oluşturdukları çizimlerin manuel ve “Paper2Wire” ile dijitalleştirilmiş tasarımları

Tauhid 2018 yılında yayımladığı tez çalışmasında, makine öğreniminin tasarımcılar için nasıl yeni kullanıcı deneyimi aracı haline geldiğini ve geleceğini araştırmak amacıyla “Coupon Buddy” adında bir prototip tasarlamıştır. 83 kişinin katıldığı uygulamada, katılımcılara el ile çizilmiş ve 2 programda tasarlanmış farklı tasarım kalitesinde 3 farklı çizim üzerinden anlatım yapılmıştır. Ardından kullanıcı deneyimi ile makine öğrenmesi konuları üzerinden anket yapılmış, yazılı ve sözlü görüşleri alınmıştır. Prototip, kupon biriktiren insanların biriktirdikleri kuponların yönetimini kolaylaştırmayı hedeflemektedir. Yapılan bu uygulamada tasarımcılar ve makine öğrenmesi uygulayıcıları gruplar halinde birlikte çalışmalar yürütmüş ve fikir paylaşımları olmuştur. Tauhid uzun geri bildirimlerin, yalnızca gelecekteki tasarım geliştirmelerini test etmede fayda sağlamakla kalmadığını, aynı zamanda mümkün olduğunca çok geri bildirim toplamak, kullanıcı deneyimi tasarımcılarının kullanıcı davranış kalıplarını keşfetmesine yardımcı olduğunu belirtmiştir. Yapılan araştırmada, prototiplerin katılımcılara olabildiğince çok yanıtta katkıda bulunmaya ve potansiyel olarak makine öğrenmesi için sistemi eğitmeye nasıl teşvik ettiğini belirlemeye yardımcı olduğu belirtilmiştir. Araştırma sonuçlarında, el ile çizilen prototipin, katılımcılarda bir hayal gücü uyandırdığını ve onları analizlerinde daha eleştirel olmaya, hatta prototip tasarımcılarının başlangıçta düşünmediği iyileştirmeleri kullanma ve ekleme fırsatları aramaya teşvik ettiğini gösterdiği belirtilmiştir. Daha gösterişli prototipler daha pasif, daha az kullanışlı bir yaklaşımı ortaya çıkardığı düşünülmektedir (Ahmed, 2018).



Görsel 1.2. “Coupon Buddy” Adlı Uygulamanın Üç Farklı Prototipi (Ahmed, 2018)



Görsel 1.3. “Coupon Buddy” Adlı Uygulamada Kullanılan Ekranlar (Ahmed, 2018).

Robertson 2020’de bir blog üzerinde “ML nedir ve UX/UI tasarımcıları için neden önemlidir?” isimli bir makale paylaşmıştır. En kullanışlı ürünleri oluşturmak için makine öğrenimi kullanma becerisinin iş birliği yapma becerilerine bağlı olacağını düşünmektedir. Tasarımcıların, veri bilimcilerin ve programcıların yapay zekânın faydasını anlamaları için ortak bir dil ile vizyon paylaşımları gerektiğini vurgulamıştır. Tasarımcılar dahil, tüm ekiplerin sürece dahil olması gerektiğini ve uyumlu, kişiselleştirilmiş bir deneyimin; kullanıcılar için sezgisel ve yardımcı ürünler tasarlanmasının daha gerçekçi olacağını belirtmiştir (Robertson, 2022).

Kullanıcı deneyimi alanında uzman, ürün mimarı Lancher ve arkadaşları 2018’de yayınladığı makalede, makine öğrenmesi yöntemlerinin, kullanıcı etkileşimlerinden öğrenerek sistemlerin kişiselleştirilmesi gibi yeni değer sunmaktan öte, kullanıcı deneyimlerini geliştirmek için çok daha fazlasının yapılabileceğini belirtmiştir. Geleneksel kullanıcı deneyimi değerlendirme yöntemleri kaynaklarının genellikle yoğun ve ölçeklenebilir olmadığını; genellikle kullanıcı deneyimi anketi olarak standart anketler kullanıldığını belirtmiştir (Pettersson, Lachner, Frison, & Riener, 2018).

Chromik ve arkadaşları 2020’de raporladıkları araştırmada, kullanıcı deneyimi uygulayıcılarının empati odaklı kullanıcı deneyimi çalışması ile veriye dayalı makine öğrenmesi teknikleri arasındaki sinerjiyi nasıl tasavvur ettiğini daha iyi anlamak için kullanıcı deneyimi ve makine öğrenmesi konularında deneyimli 49 uygulayıcı ile anket yapmış ve kullanıcı deneyimi uzmanlarıyla 13 yarı yapılandırılmış görüşme gerçekleştirmişlerdir. Makine öğreniminin mevcut kullanıcı deneyimi araştırma faaliyetleri üzerindeki etkisinin ve uygulayıcıların potansiyelleri hakkındaki tahminlerinin bir envanterini çıkararak, makine öğrenmesi yöntemlerinin sıradan görevleri otomatikleştirmeye, kararları veriye dayalı bilgilerle tamamlamaya ve kullanıcı deneyimi araştırmalarını, kullanıcıların duygusal dünyalarından elde edilen bilgilerle zenginleştirmeye yardımcı olabileceğini tartışmışlardır. Verileri kullanmak için potansiyel bir zorunluluktan ve kullanıcı verilerine daha kısıtlayıcı bir erişimden zorluklar ortaya çıkabileceğini belirtmişlerdir. Kullanıcı deneyimi ekipleri, teknik temelleri anlamadıkları için araçların varsayılan ayarlarına körü körüne güvenmek zorunda olduklarını ve hiç kodlama yapmamış hiç kimse için kesinlikle erişilemeyeceğini raporlamıştır. İnsanlar alışlagelmiş modellere güvendiğini ve onları projelerine dahil ettiklerini belirtmiştir. Son akademik çalışmaların, kullanıcı deneyimi uygulayıcılarının zihinsel modellerini, eğlenceli keşif ve metaforlar için araçlarla iyileştirmelerine olanak tanıdığını, bu tür eğitim materyallerinin, makine öğreniminin kullanıcı deneyimi araştırmalarına nasıl uygulanacağına ilişkin örnek olay incelemelerini önermiştir (Chromik, Lachner, & Butz, 2020).

2020 yılında yayınladıkları makalede Winter ve Jackson tarafından, tüketici düzeyinde, donanım üzerinde, yerel olarak çalışan ve son kullanıcılar tarafından kendi özel bağlamları ve kullanım durumlarına göre eğitilebilen ve özelleştirilebilen yeni nesil etkileşimli makine öğrenmesi uygulamaları oluşturma konusunda tasarımcıların nasıl desteklenebileceği incelenmiştir. Araştırmada, tasarımcıların makine öğrenmesi ile

etkileşimlerinde karşılaştıkları zorlukları ve yeni uygulamaları tasarlama konusundaki ilgileri incelenmiştir. Tasarımcıların makine öğrenimine olan ilgileri, makine öğrenmesi yetenekleri ile kavramları anlamaları arasındaki ilişkiyi ve makine öğrenmesi hakkında öğrenme tercihlerini araştıran bir anketin bulguları raporlanmıştır. Makalede, önce evde bir kurulum süreci gerektiren demonte mobilyalara atıfta bulunarak ve “Flatpack ML” terimi kullanılarak makine öğrenmesi algoritması anlatılmıştır. Tasarımcıların makine öğrenimine olan ilgisini ve anlayışını ölçmek ve makine öğrenmesi uygulamalarını tasarlama ve prototiplemede nasıl desteklenebileceklerini öğrenmek için 102 tasarım uzmanı ve öğrenciyle bir anket gerçekleştirilmiştir. Sonuçlar, tasarımcılar arasında makine öğrenimine güçlü bir ilgi olduğunu ve bu konuda bilgi edinmeye hazır olduklarını göstermektedir. Birçok tasarımcı, makine öğrenmesi için hangi sorunların çözülmesinin gerekliliği zorluk derecesi konusunda adil bir anlayışa sahip gibi görünse de bulgular, tasarımcıların genellikle temel makine öğrenmesi kavramlarını çok az anladıklarına dair literatürdeki iddiaları büyük ölçüde desteklemektedir. Anket sonuçlarına ve literatürden elde edilen bulgulara dayanarak, makale, önerilen yeni nesil makine öğrenmesi uygulamalarını tasarlamak, tasarlamak ve prototipini oluşturmak için tasarımcıları desteklemede birbiriyle örtüşen üç araştırma zorluğu belirlenmiştir (Winter & Jackson , 2020).

- Tasarımcıların makine öğrenmesi ile uygulamalı etkileşimlerini ve keşiflerini desteklemek için uygun ortamlar ve araçlar geliştirmesi.
- Deneyimsel öğrenmelerini desteklemek için bu ortamlar ve araçlarla etkileşim kurarken tasarımcıların derinlemesine düşünmesi.
- Eğitim ve özelleştirme uygulamalarına ilişkin son kullanıcı deneyimini geliştirmek için makine öğrenimine ilişkin kavramsal ve operasyonel bilgilerini tasarımlarda kodlanması.

Bu zorlukları ele alınmasının gerektiğini, önemli ve çok yönlü araştırmalar gerektireceğini belirtmiştir (Winter & Jackson , 2020).

Sankar ve arkadaşları yayınladıkları makalede, kullanıcı istatistiklerini ve beğenilerini izlemek için k-ortalamalar kümelemesini ve tekrarlayan sinir ağlarını içeren basit tekniklerin kullanımını önermekte ve çeşitli kullanıcı grupları için özelleştirilmiş arayüzler oluşturmak üzere tahminler yapmaktadır. Otuz üç kişiyle, dinamik olmayan arayüzler hakkında bir kapalı bir çalışma yapılmıştır. Geliştirilen çerçeve, kullanıcı beğenileri hakkında etkin bir şekilde tahminlerde bulunmuştur. Otuz üç kişinin katıldığı

ankette güncel trendler ve kullanıcı ruh halleri hakkında önemli verilere ulaşılmıştır. Toplam otuz üç adaydan yirmi dokuzu, uygulamaların kullanılabilirliği artırmak için daha fazla özelleştirme seçeneği gerektirdiği görüşünü belirtmiş ve kalan kullanıcılar, mevcut özelleştirilemeyen uygulamaların kullanımı engellemediğini belirtmiştir. Ayrıca, yirmi üç kullanıcı, bu özelleştirmelerin kullanıcı tercihleri ve beğenileri izlenerek otomatik olarak oluşturulması gerektiğine ve kullanıcının manuel olarak karar vermemesini gerektiğine inanmaktadır. Bu değişiklikler, kullanım stresini en aza indirmek için arka planda alınan kararlardan kaynaklandığı düşünülmektedir (Sankar, Amudha, Madhavan, & Lamba, 2020).

Srivastava 2021 yılında yayınladığı tez çalışmasında, önceki çalışmaların, kullanıcı deneyimi tasarım uygulayıcılarının makine öğrenimi için tasarım yaparken karşılaştıkları zorlukları tanımlamaya ve tartışmaya odaklanmıştır. Tasarımcıların makine öğrenimini anlama konusundaki eksikliklerine çözüm önermiş ve değerlendirmek için çok fazla araştırma olmadığının altını çizmiştir. Ayrıca, makine öğrenimi alanı için kullanıcı deneyimi tasarımıyla ilgili araştırmaların hiçbiri şu ana kadar kullanıcı deneyimi tasarım öğrencilerine veya eğitimine odaklanmadığını ve çoğu tasarımcıların makine öğrenmesi konusunda eğitim eksikliğini önemli bir sorun olarak tanımlanmıştır. Bu araştırmada, makine öğrenimi için kullanıcı deneyimi tasarımına ilişkin 88 giriş niteliğindeki eğitim kaynağının analitik bir incelemesi yapılmış ve lisans düzeyinde makine öğrenimi için kullanıcı deneyimi tasarımına giriş eğitimine yönelik bir kılavuz hazırlanmıştır. Bu kılavuz kullanıcı deneyimi tasarım öğrencilerinin ikinci yıllarında müfredatlarında uygulanmak üzere bir 15 haftalık bir eğitim prototip niteliğindedir (Srivastava, 2021).

Dove ve arkadaşları 2017 yılında yazdıkları makalede, makine öğreniminin ne olabileceğini ve neler yapabileceğini yeniden hayal etmek için tasarım düşüncesinin gücünü açığa çıkarmasına yardımcı olabileceği alanları tartışmıştır. 51 kullanıcı deneyimi uygulayıcısı ile yapılan çevrimiçi bir ankette, tasarımcıların %63'ünün makine öğrenmesi ile çalıştığını ve çoğunun makine öğrenmesi yazılım geliştiricileri ve mühendisleriyle iş birliği içinde çalıştığını belirtmişlerdir. Makine öğrenimi ile çalışan tasarımcılar tarafından, makine öğrenmesi ile prototip oluşturma zorluğuyla ilgili hayal kırıklıklarını dile getirilmiş ve makine öğreniminin yeteneklerini, sınırlamalarını ve potansiyelini anlama ve ifade etme konusundaki zorlukları vurgulanmıştır. Katılımcıların geneli tarafından, kullanıcı deneyimi tasarımı bağlamında makine öğreniminin yeteneklerini, sınırlamalarını ve potansiyelini anlama ve dolayısıyla ifade etme

konusundaki zorlukları tanımlanmış ve bu tür etkileşimler dinamik olduğundan ve sonuçları potansiyel olarak tahmin edilemez olduğundan makine öğrenmesi ile etkileşimlerin prototipinin zor olduğu düşünülmektedir (Dove, Halskov, Forlizzi, & Zimmerman, 2017).

Bu çalışmada, kullanıcı deneyimi, makine öğrenmesi ve asansör olmak üzere üç önemli bileşen vardır. Kullanıcı deneyimini artırmak için asansör sektöründeki montaj firmalarının kullandığı ELEPORT web sitesinde, makine öğrenmesi algoritmalarını baz alan bir karar destek sistemi üzerine çalışma yapılmıştır. Bu sebeple bu üç önemli bileşen iki, üç ve dördüncü bölümlerde ayrı ayrı özel olarak incelenmiştir. Beşinci bölümde ise yapılan uygulama detaylı bir şekilde anlatılmıştır. Altıncı ve son bölümde yapılan çalışmanın bulguları anlatılmış ve ilerleyen süreçte yapılabilecek çalışmalara değinilmiştir.

2. KULLANICI DENEYİMİ

“Kullanıcı deneyimi kişilerin bir ürün, sistem ya da servisi kullanırken hissettikleri duygu ve davranışları ifade eder. İnsan- bilgisayar etkileşimi ve ürün sahipliğinin uygulamalı, deneysel, duygulanımlı, anlamlı ve değerli yönlerini kapsar. Kullanıcıları çok iyi ve derinlemesine anlamak üzerine odaklanarak ihtiyaçları neler, nelere değer verirler, neleri yapabilirler ve neleri yapamazlar (limitleri nelerdir) gibi soruların cevaplarıyla ilgilenir. Buna ek olarak iş hedeflerini ve projeyi yöneten grubun hedeflerini de dikkate alır. Yazılım mühendisliği alanında, özellikle de web ve mobil alanında kullanıcı arabirim tasarımının öne çıkması ile birlikte kullanıcı deneyimi teriminin popülaritesi de artmıştır” (Kullanıcı Deneyimi, 2022).

1988 yılında kullanıcı deneyimi teriminin mucidi Don Norman, “Hiçbir ürün bir ada değildir. Bir ürün, üründen daha fazlasıdır. Uyumlu, bütünleşik bir deneyimler dizisidir. Bir ürün veya hizmetin tüm aşamalarını baştan sona düşünüldüğünde- ilk niyetlerden nihai yansımalara, ilk kullanımdan yardıma, servise ve bakıma kadar. Hepsinin sorunsuz bir şekilde birlikte çalışmasını sağlayın.” sözüyle deneyim ve memnuniyet kavramlarından daha çok bir süreç olduğunun altını çizmiştir (User Experience Design, 2022).

Kullanıcı deneyimi için ilk gereksinim, müşterinin ihtiyaçlarını tam olarak, sorunsuz ve zahmetsizce karşılamaktır. Gerçek kullanıcı deneyimi, müşterilere istediklerini söylemenin veya kontrol listesi özelliklerini sağlamanın çok ötesine geçmektedir. Bir şirketin tekliflerinde yüksek kalite kullanıcı deneyimi elde etmek için mühendislik, pazarlama, grafik ve endüstriyel tasarım ve arayüz tasarımı dahil olmak üzere birden çok disiplinin ve hizmetin sorunsuz bir şekilde birleştirilmesi gerekir (Kullanıcı Deneyimi Eğitimi, 2022).

Kullanıcı deneyimi ve kullanılabilirliği birbirine yakın kavramlar olmakla birlikte, kullanılabilirlik kavramı kullanıcı arayüzünün bir kalite özelliğidir. Kullanılabilirlik tanımına göre kullanıcı deneyimi, sistemin öğrenmesinin kolay, kullanımının verimli, hoş ve benzeri olup olmadığını kapsamaktadır. Kullanıcı deneyimi ise kullanılabilirlik ve arayüz kavramlarının üzerinde daha da geniş bir kavramdır.

“Kullanıcı deneyimi tasarımı, tasarım ekiplerinin kullanıcılara anlamlı ve alakalı deneyimler sağlayan ürünler oluşturmak için kullandıkları süreç tasarımıdır. Kullanıcı deneyimi tasarımı, markalaşma, tasarım, kullanılabilirlik ve işlev yönleri de dahil olmak üzere ürünü edinme ve entegre etme sürecinin tamamının tasarımını içerir. Bir kullanıcı

deneyimi tasarımcısı, markalaşma, tasarım, kullanılabilirlik ve işlev yönleri de dahil olmak üzere bir ürünü edinme ve entegre etme sürecinin tamamıyla ilgilenir. Bu süreç, ürün kullanıcının eline geçmeden başlamaktadır” (User Experience Design, 2022).

Bir deneyim tasarlamak, yalnızca yazılımın kullanımını kolaylaştırmakla kalmayıp aynı zamanda ürünle ilgili pazarlama kampanyası, paketlenme ve satış sonrası destek gibi diğer süreçlerin de tasarlanmasını içerir. En önemlisi, kullanıcı deneyimi tasarımı, sorunlu noktaları ve ihtiyaçları ele alan çözümler sunmakla ilgilenir. Sonuç olarak amacına hizmet etmeyen bir ürünü kimse kullanmayacaktır. Mobil uygulama, web sitesi, oyun veya başka bir dijital ürün oluşturmak isteyen herkesin verimli bir kullanıcı deneyimi tasarım süreci geliştirmesi gerekmektedir. Projenin başarısı için bu süreç çok önemlidir (User Experience Design, 2022).

2.1. Bulut Bilişim

Bulut bilişim, internet ağı üzerinden istenilen zamanda ve yerde, kullanıcılara hizmet sunmak için donanım ve yazılım hizmetlerinin genel adıdır. Bulut bilişim, internet tabanlı yardımcı bilgi işlem hizmetleri sunmak için bir model olarak ortaya çıkmıştır. Bulut bilişim ile kullanıcılar, internet altyapısı olan bilgisayar, tablet veya telefon gibi bir cihaz yardımıyla dosyalara ulaşabilir ve uygulamaları kullanabilir. Altyapı hizmeti (IaaS), platform hizmeti (PaaS), yazılım hizmeti (SaaS) olmak üzere üç temel modelde hizmet çeşidi vardır (Bulut Bilişim, 2022).

Bulut bilişim mimarisi, iletişim bağlantısının her iki ucuna bir sunucunun yerleştirildiği mevcut istemci-sunucu mimarisinin bir uzantısıdır. Öncelikle, veriler geliştirme sunucusunda yerel bir kopya olarak depolanır ve bunun üzerine internet somutlaştırılarak bulut tarafındaki ana kopya ile senkronize edilir. Kullanıcılar, gerçek bir web sitesinin yerel bir web formu olan yerel geliştirme sitesindeki verilere göz atabilir, bunları okuyabilir, yazabilir veya bunlara veri ekleyebilir (Ray, 2017).

İstemci- sunucu ilişkisi, bir istek-yanıt mesajlaşma modelinde iletişim kurar ve kullanılacak kuralları, dili ve diyalog modellerini resmî olarak tanımlayan ortak bir iletişim protokolüne bağlı kalır. Bulut bilişim, olağanüstü durum kurtarma, müşterilere dönük web uygulamaları, test etme, sanal masaüstleri, büyük veri analizi, e-posta, veri yedekleme, yazılım geliştirme gibi alanlarda kullanılmaktadır.

2.2. Kullanıcı Deneyimi ve Makine Öğrenmesi

“Makine öğrenmesi, insanların öğrenme şeklini taklit ederek, veriler ile algoritmaların kullanımına odaklanan, doğruluğunu kademeli olarak artıran bir yapay zekâ ve bilgisayar bilimi dalıdır” (IBM, 2022). Makine öğrenmesi algoritmaları görüntü ve konuşma tanıma, tüketici önerileri, dolandırıcılık tespiti ve daha fazlası gibi farklı uygulama alanlarında karar vermeye yardımcı olmak için büyük ve karmaşık veri kümelerindeki kalıpları tanımak için matematiksel modeller kullanır.

Makine öğrenmesi, geçmiş verilerdeki önemli tanımlar arasında ilişki kurarak, işletmelerdeki endişelere genel bir bakış sağlar. Teknolojinin gelişmesi ve yapay zekânın ilerlemesi ile birlikte makine öğrenmesi hayatımızın her alanında yer almaya başlamış ve kâr amacı güden çoğu yenilikçi firma makine öğrenmesi algoritmalarını kullanmaya başlamıştır.

Örneğin Google, kullanıcılara ücretsiz olarak sunduğu Gmail hizmetinde, e-postaları (sosyal, birincil veya promosyon) kullanıcıya göre farklı şekilde etiketlemek için yapay zekâyı kullanır. Makine öğrenmesi, e-posta sınıflandırmasında neyin birincil e-posta olarak sınıflandırılacağını geçmiş e-posta gönderme alışkanlıklarından öğrenir. Ancak bu geçmiş davranışlara bağlı olarak herkes için farklı sonuçlar verir (Robertson, 2022).

Aynı şekilde Samsung ve Apple gibi telefon markaları telefonda bulunan fotoğrafları görüntü işleme ile otomatik olarak etiketlemektedir. Telefondaki fotoğraflarda resmedilmiş canlı-cansız alan, yer veya cisimlerin adı ile arama yapılabilir ve bunlar hızlı bir şekilde bulunabilir. Örneğin, “deniz” kelimesi aranarak, deniz içerikli fotoğraflar filtrelenebilmektedir.

Netflix'in büyümesine yol açan önemli faktör, kullanıcılara nasıl pazarlayacağını bilen etkileyici ve güçlü bir yapay zekâyı sahip olmasıdır. Netflix, makine öğrenmesi teknolojisiyle bütün filmleri tarar ve kullanıcının izleme geçmişine ve tercihiğine göre en uygun sahneyi seçerek, filmin adını ve gerekli logoları bu sahneye ekleyerek yeniden bir kapak görseli tasarlar. Ayrıca, kullanıcının sevdiği bir oyuncuyu da filmin kapak görseline ekleyebilir. Bu sayede Netflix izleyicilere uygun kapak fotoğrafları sunar (Küçük, 2022).

Başka bir örnek olarak Trendyol, Amazon veya Hepsiburada gibi alışveriş siteleri verilebilir. Bu tarz siteler kullanıcının beğendiği veya aldığı ürünler doğrultusunda,

makine öğrenmesi algoritmalarıyla optimize edilerek filtrelenmiş ürünleri kullanıcıya sunmaktadır.

Elon Musk, tasarımından üretimine kadar her alanında yer aldığı Tesla otonom araçlarının altyapısında çok ileri seviyede gelişmiş makine öğrenmesi algoritmaları kullanmaktadır. İsveç merkezli kamyon, otobüs ve deniz araç motorları üreticisi Scania, İsveç içerisinde yaklaşık 300 kilometrelik sevkiyatı sürücüsüz otonom tırlara yaptırmaktadır (Euronews, 2022).

Makine öğrenmesi veya yapay zekâ karmaşık olsa da temel kavramları hem veri bilimcileri hem de kullanıcı deneyimi tasarımcıları tarafından anlaşılabilir ve bu anlaşılabilirlik, uygulama ve web tasarımının geleceğinde önemli yeniliklere yol açabilir. Makine öğreniminin tasarım çalışmasına entegre edilmesi daha geniş bağlamda, tasarımcıların bilgi ve araçlarına saygı duymayı, otomasyon çağında yaratıcılık ile "yaparak düşünmeye" ve tasarımcıların beklentilerini pratikte karşılama gibi yönleri vurgulamaktadır (Buschek, Anlauff , & Lachner, 2021).

Makine öğrenmesi, en az elli yıldır aktif bir araştırma, ilgi ve uygulama alanı olmuştur. Teknolojinin teknik, istatistiksel ve etik karmaşıklıkları nedeniyle, makine öğrenimini tasarım sürecine ve dolayısıyla tasarım sonuçlarına dahil eden tasarım veya tasarımcı liderliğindeki inovasyonda genel bir eksiklik vardır. Son zamanlarda yapılan birkaç çalışma, göreceli yeterlilik eksikliğini vurgulamıştır.

Kullanıcı deneyimi tasarım çalışmalarında makine öğreniminin en çok aranan ve değerli kullanımlarından biri, kullanıcılara benzeri görülmemiş derecede kişiselleştirme sunma yeteneğidir. “Kullanıcı deneyimi tasarımcılarının yalnızca kullanılabilirlik, fayda ve etkileşim estetiğine dikkat ederek kullanıcı deneyimini iyileştirmesi artık yeterli değil. Bunun yerine, en iyi kullanıcı deneyimleri, tekliflerini kullanıcıya ve bağlama göre otomatik olarak kişiselleştiren hizmetlerden ve yeni değer sağlamak için insanlar ve dünya hakkında daha ayrıntılı anlayışlardan yararlanan sistemlerden gelebilir” (Dove, Halskov, Forlizzi, & Zimmerman, 2017).

Tasarımcılar, makine öğrenimini kullanmak için basit fırsatları gözden kaçırmakta ve yaptıkları tasarımlarda makine öğreniminin tasarım odaklı inovasyonu günümüzde nadir denilecek kadar düşük düzeyde tutmaktadırlar. Bunun yerine, makine öğreniminin birçok kullanıcı deneyimi uygulaması hala yazılım geliştiricileri ve mühendisler tarafından tasarlanmakta ve yürütülmektedir. Ek olarak, makine öğreniminin birçok arayüzle ilişkili kullanıcı deneyimi tasarımı genellikle sonradan akla gelmekte ve bu

nedenle çok sayıda tasarım fırsatı kaçırılmaktadır (Dove, Halskov, Forlizzi, & Zimmerman, 2017).

Makine öğreniminin kullanıcıları ortak davranışlara göre gruplandırma yeteneği, tasarımcıların bir ürünü kullanan farklı tüketicileri daha iyi anlamalarına ve daha iyi hizmet sunmalarına yardımcı olabilir. Farklı kişilere göre farklı kullanıcı akışları oluşturulabilir ve yapay zekâ, kullanıcının bir web sitesindeki deneyimini, bu tür bir kullanıcı için en iyi neyin işe yaradığına göre uyarlayabilir. Her kullanıcı türü için yeni bir kullanıcı akışı tasarlamak maliyeti çok fazla artırdığı için, bunun yerine tasarımcılar bileşenler oluşturabilir ve yapay zekâ bileşenleri kullanıcının ihtiyaçlarına göre birleştirerek kullanıcı akışını belirlemektedir. Bir siteye giriş yapıldığında makine öğrenmesi, sizin hakkınızda hâlihazırda bildiklerine ve sitedeki mevcut davranışınıza (tıklama sayısı, arama çubuğuna yazılan kelimeler vb.) dayalı olarak siteyi geliştirir ve kullanıcıya özel bilgiler sunabilir. Böylece davranışlara ve ihtiyaçlara göre yapılmaya başlanılan görevi daha verimli bir şekilde gerçekleştirmeye yardımcı olacaktır. İleride tasarımcılar, tasarladıkları bilgi mimarisinde makine öğrenmesi olarak isimlendirilen bu güçlü aracı nasıl kullanacağımız konusunda yaratıcı olma fırsatına sahip olacaklardır (Robertson, 2022).

Makine öğreniminin diğer bir tanımı, bir makineyi bir görevin çözümünde yardımcı olmak için veri kullanarak öğrenmeyi sağlayan bir tekniktir. Örneğin, bir e-ticaret sitesi, makine öğrenimini kullanarak, müşterilerinin ne tür ürünleri tercih ettiğini anlayarak onlara benzer ürünler önerebilir. Bu, kullanıcıların deneyimlerini iyileştirerek o siteyi daha sık ziyaret etmelerini sağlayabilir. Makine öğrenmesi, birçok farklı alanda ve birçok farklı amaç için kullanılabilir (AI, 2022).

3. ASANSÖR

Asansör kelimesi, “Fransızca ascenseur mekanik tırmanma aracı sözcüğünden alıntıdır. (İlk kullanımı: 1867 Léon Edoux, Fr. mühendis.) Bu sözcük Fransızca ascendre (yükselmek, tırmanmak) fiilinden türetilmiştir” (Asansör Kelimesi, 2022).

İnsanları veya yükleri bir yapının katları arasında dikey olarak taşıyan makaralı ray veya hidrolik silindir destekli makinelere asansör denir (Asansör, 2022).

Günümüzde yaygın olarak kullanılan dikey taşıma sistemleri olan asansörler, en çok kullanılan ulaşım araçlarıdır. Yüksek ve derin yapıların artmasıyla, insanların ve yüklerin üst ve alt katlara ulaşabilmesi ihtiyacı asansörleri zorunlu kılmış ve ulusal ve uluslararası yönetmeliklerce zorunlu hale getirilmiştir. Bahsi geçen yönetmelikler hem yolcu güvenliğini hem de konforunu arttırmak amacıyla, asansör yapısının imarında uygulanması zorunlu olan kısıtlamaları ve şartları da beraberinde getirmiştir.

Avrupa standardı EN 81-20: 50 (2020) asansör yönetmeliği çoğu ülkeye rehberlik etmektedir. Dünya genelinde çoğu ülke, Avrupa standardını baz alıp kendi standart ve yönetmeliklerini çıkartarak kendi ülkelerine uygulamaktadır. Sektörde Türkiye’de çıkarılmış olan TS 81-20: 50 (2020) Türk Asansör Standardı, Avrupa standardı kılavuzluğunda çıkarılmıştır (Türk Standartları Enstitüsü, 2020).

Türkiye’de ilk asansör, 1892 yılında İstanbul’da Pera Palas Otelinde Fransız Mimar Alexander Valley tarafından yapılmıştır (Ertürk, 2008).

Roma mimarı Vitruvius’un el yazılarında, M.Ö. 285- 212 yılları arasında yaşayan Archimedes'in tasarladığını ve elle işletilen basit bir vinçi MÖ 236’da ürettiği anlaşılmaktadır (Kalcık, 2020).

“1750’li yıllara gelindiğinde asansörleri hareket ettirmek için insan ya da hayvan gücü yerine buhar gücü kullanılmaya başlanmıştır. Bu asansörlerde buhar makinesi bir tamburu döndürerek, asansör kabinini çeken halat da bu tamburun üzerine sarılarak asansörü hareket ettirmektedir. Ancak asansörler halatların kopma riski taşıması nedeniyle insan taşımak için kullanılmamıştır” (Sığırcı, 2021).

ABD’li mucit Elisha Otis, gerektiğinde devreye girerek kabinin düşmesini engelleyecek bir emniyet freni icat ederek asansörleri insanlar için güvenli hâle getirmiştir. Otis, 1853’te, New York’ta düzenlenen bir fuarda icadına olan güvenini çok sayıda insanın karşısında kanıtlamıştır. Otis açık bir platformda yüksek bir katta durarak, asistanından platformu destekleyen halatın kesilmesini istemiştir. Halatın kesilmesinin ardından asansör, Otis’in yaptığı fren sistemi sayesinde havada asılı kalmıştır. Otis,

hareket etmeyen platformun üzerinde şapkasını sallayarak insanları selamlamış ve icadını tanıtmıştır (Britannica, 2022).



Görsel 3.1. *Elisha Otis'in Asansör Emniyet Frenini Tanıtma Anı (Sığircı, 2021)*


3.1. Kullanım Amacına Göre Asansörler

Kullanım amacına göre asansörler geçmiş kaynaklarda hasta, yük, insan ve servis olarak dört grupta incelenmiştir (İmrak & Erdemligil, 2000). Gelişen teknoloji ve kullanım sıklıklarının azlığı sebebi ile şu an insan ve yük asansörleri olarak iki grupta incelenmektedir.

İnsan asansörleri, özellikle insanların taşınması için kullanılan, kullanım rahatlığı ve kabin konforu ön planda tutulmuş olan asansörlerdir. Tekerlekli sandalye ve sedye ile hasta taşıyabilecek kabin formunda olan asansörler, “Hasta Asansörleri” olarak isimlendirirler (İmrak & Erdemligil, 2000).

Yük asansörleri, yükün genellikle insanlar tarafından taşınması amacıyla tasarlanmıştır. Depolar, alışveriş merkezleri ve fabrikalar gibi işyerlerinde yük taşıma işlemleri sıkça yapıldığında bu asansörler kullanılır. Bu asansörler ayrıca, yüklerin rahatlıkla taşınmasını sağlamak amacıyla imal edilebilir (Tavaslıoğlu, 2005).

3.2. Konstrüksiyon ve Tahrik Sistemlerine Göre Asansörler




Şekil 3.1. Asansörlerin sınıflandırılması (İmrak & Erdemligil, 2000)

Halatlı Asansörler; halat sistemlerini baz alan asansör grubudur. Tahrik kasnaklı ve tamburlu olarak iki grupta incelenmektedir. Tamburlu asansörler kısa mesafeli taşıma sistemlerinde tercih edilmektedir. Tamburlu asansörlerde tek halat kullanılabilir, tahrik kasnaklı asansörlerde birden fazla halat kullanılabilir.

Paternoster Asansörler; birden fazla kabinin aynı sistemde sürekli hareket halinde olduğu sistemlerdir. Yan yana duran iki asansörün biri alt katlara iniş diğeri ise üst katlara çıkış amacıyla kullanılmakta ve kullanılan kabinlerinin kapasiteleri bir veya iki kişiliktir. Hız sınırı en fazla 0,3 m/s olarak kullanılabilir. Eskiden devlet daireleri gibi kamusal alanlarda tercih sebebi iken, günümüzde tercih edilmemektedir (Arıtan, 1994).

Hidrolik Asansörler; tahrik yeteneği hidrolik bir pompa ile sağlanan asansörlerdir. Elektronik bir hidrolik basınç pompası ile hidrolik tankındaki sıvıyı silindirin içine iterek pistonu yükseltir ve asansörün yukarı hareket etmesini sağlar. Sistem aşağı yönlü hareketini kabin ve beyan yükleri ile gerçekleştirir. Düşük katlı binalarda uygulanmakta ve genellikle yük asansörlerinde tercih edilmektedir (Tavaslıoğlu, 2005).

Direkt, indirekt olarak ikiye ayrılır. Hidrolik pistonun direk kabin süspansiyonuna bağlı olması durumun direkt tahrikli, 2:1 palanga sistemi ile çalışan hidrolik asansörlere ise indirekt veya indirekt tahrikli hidrolik asansör olarak adlandırılmaktadır (Demirbağ, 2012).



Görsel 3.2. Hidrolik Asansör Elemanları (DD, 2022)

Kremayerli ve Vidalı Asansörler: “Bir vidalı mil aracılığı ile krikoya benzer şekilde, kabinin hareketinin sağlandığı küçük kaldırma yükseklikleri ve düşük hızlarda çalışan asansörlerdir. Vidalı mildeki otoblokajdan dolayı, kabinin aşağı düşme tehlikesi yoktur. Kremayerli asansörler daha çok inşaat işlerinde dış cephe ile ilgili çalışmalar için kullanılmaktadır. Kremayerli kısım istenildiği boyda ayarlanabilme yeteneği ile, inşaat yüksekliği arttıkça asansörün seyir mesafesi ayarlanabilmektedir” (İmrak & Erdemligil, 2000).

Eğimli Asansörler: asansör dikey açısının 15 dereceden fazla olan asansörlerdir. Açık alanlardaki dik yamaçlarda ve eğimli binalarda kullanılmaktadır. Eğimli asansörlerin tasarlanması ve uygulanması, diğer halat tahrikli asansörlere göre daha zor olmakla birlikte bu tarz asansörler daha fazla teknik donanım ve alan gerektirir (Tavaslıoğlu, 2005).

3.3. Halat Sistemli Asansörlerin Güvenlik Hesapları

3.3.1. Motor hesabı

Kullanılan motorun gücünün yeterliliğinin ispatlandığı hesaptır. Basit olarak hesap, askı oranı, seyir mesafesi, verimlilik ve halat parametreleri ile gerekli motor gücü hesaplanabilmektedir.

Makine motor grubunun gerçek verimliliği üzerinden motor gücünün hesaplanması gerekir. Ayrıca, makinede kullanılan motor gücünün hesaplanan değerden daha büyük olup olmadığı da kontrol edilmelidir. Böylece, makine motor grubunun gerçek verimliliğine uygun bir motor gücü seçilebilir. Motor hesabının amacı, makineyi daha etkin bir şekilde çalıştırmak ve daha uzun ömürlü hale getirmektir.

3.3.2. Halat hesabı

Halat ile ilgili yedi kritik konunun kontrolünün yapıldığı hesaptır. Bunlar aşağıda listelenmiştir.

- Halat güvenlik faktörü kontrolü,
- Kabin yükleme esnasında tahrik yeteneğinin kontrolü,
- Kabin boş ve en üst durağa çıkarken acil frenle duruş anında tahrik yeteneğinin kontrolü,
- Kabin anma yükü ile dolu ve en alt durağa inerken acil frenle duruş anında tahrik yeteneğinin kontrolü,
- Boş kabin en yukarıda, karşı ağırlık tampona oturmuş durumda, kabinin asılı kalma şartı ile tahrik yeteneği kontrolü,
- Tahrik Kasnağı Çap Kontrolü,
- Saptırma Kasnağı Çap Kontrolü

Yapılan kontrollerin standartlarda bahsedilen sınırlar içerisinde olması gerekmektedir. Kullanılan halat sayısı ve halat çapı üzerinden yapılan denemeler ile minimizasyon yapılarak maliyet düşürülebilmektedir. Montaj firması için kâr sağlayacak en önemli ikinci hesaptır.

3.3.3. Ray hesabı

Ray hesabı, binada kullanılacak olan kabin ve karşı ağırlık raylarında oluşabilecek durumlar karşısında raylarda hasar meydana gelmemesi için yapılan hesaptır. Hesaplanması diğer hesaplara göre daha zordur. Güvenlik tertibatının devreye girmesi, normal çalışma- işletme, normal çalışma- yükleme olarak tanımlanan üç durumda aşağıdaki kuvvet kontrolleri yapılmaktadır.

- Eğilme gerilmesi,
- Burkulma gerilmesi,

- Bileşik gerilmeler,
- Flanş eğilme gerilmesi,
- Sehim miktarı

Bunlara ek olarak ray tırnağının açılma kontrolü yapılmaktadır. Bina ihtiyacına göre standartlardaki şartları sağlayan kesit alanı en düşük ray seçilerek maliyet azaltılarak montaj firmasına kâr sağlayacak en önemli hesaptır.

3.3.4. Kolon hattı kesit hesabı

Kolon hattı kesit hesabında, binada kullanılan kablo tipi, kullanılan kablonun montaj metodu ve bina hattının parametrelerine bağlı olarak, iletkenin bağıl gerilim düşümünün ve akım taşıma kapasitesinin kontrolü yapılmaktadır.

3.3.5. Trafik hesabı

Bina asansör trafiği “TS EN 21-50:2020” standardında bahsi geçen şartlar ile minimumda tutulması gerekmektedir. Buradaki amaç, binada yaşayacak insanların konforunu arttırmaktır. Günün herhangi bir anında oluşacak insan trafiğini minimuma indirmesi gerekir. 5 dakika içerisinde bina yüzdesinin belirli bir kısmını taşıyabilecek asansör kapasite ve hızının yeterli olması bu konforu sağlayacaktır. Bina çizimini yapan mimarın, binanın ihtiyacı doğrultusunda asansör sistemi için belirli bir alan bırakması gerekmektedir. Bina inşaatı başlamadan önce teknik çiziminin gerekli kurumlara ibrazı sırasında, ayrılan alanın yeterliliğinin raporu ile birlikte sunulmalıdır.

“Asansör trafik akış hesabının temel amacı, insanların katlarda bekleme sürelerini en aza indirmek ve ergonomi sağlamaktır. Katta bekleme süreleri, kullanıcının çağrı düğmesine basmasıyla başlar, asansörün bu çağrıya cevap vermesiyle son bulur. Binanın kullanım amacına göre (örnek olarak tek kullanıcı bir apartman verilebilir) yolculuk süresinin 60 ila 90 saniye arasında olması nominal değerin yakalandığını göstermektedir. Asansöre ulaşım oranının 5 dakikalık süreçte bina nüfusunun %15’i olduğu durumda 90 saniyenin üzerine çıkan değerler düşük servis seviyesi, 60 saniyenin altında kalan değerler ise iyi servis seviyesi olarak görülebilir” (Sarıbaş, 2006).

3.3.6. Binaya gelen kuvvetler hesabı

Binaya gelen kuvvetler hesabı, kuyu üstündeki motor ve şasesinin perde betona uyguladığı kuvvetler ile kuyu altında ray altlarına gelecek yüklerin uyguladığı kuvvetlerin ayrıntılı hesaplarını içermekte ve herhangi bir karşılaştırma yapılmamaktadır.

3.3.7. Toplam çekilen güç hesabı

Asansörün elektriksel gücü, asansör kolon hattı diye adlandırılan bir kablo grubu ile bina girişindeki elektrik ana dağıtım panosundan, binanın en üst katındaki asansör makine dairesindeki asansör besleme panosuna gelir. Yanlış bir akım hesabı asansör motoru için büyük bir gerilim kaybı anlamına gelmektedir. Bu durumda asansör motoru normal verimi ile çalışmayacak ve ısınacaktır. Bu kablo kesit hesabında genelde motorun çektiği akım baz alınır. Motorda harcanan gücün yanında, motor sürücüsünde harcanan güç, motor kumanda panosunda harcanan güç, kabin-kuyu-makine dairesi aydınlatmasında harcanan güç gibi birçok ilave güçler ve akımlar söz konusudur. Toplam çekilen güç hesabında kolon hattından çekilen akım ayrıntılı incelenmektedir.

3.3.8. Kabin süspansiyonu hesabı

Asansör beyan yükünü ve asansör kabinini taşıyan sisteme kabin süspansiyonu denir. Sac kesitlerinin mukavemet ve atalet momentleri hesaplanarak, gerilim ve deformasyon hesapları yapılmaktadır.

3.3.9. Karşı ağırlık şase hesabı

Asansörün karşı ağırlıklarını taşıyan sisteme karşı ağırlık şasesi denir. Kabin süspansiyonunda olduğu gibi sac kesitlerinin mukavemet ve atalet momentleri hesaplanarak, karşı ağırlık sisteminin gerilim ve deformasyon hesapları yapılmaktadır.

3.3.10. Motor şase hesabı

Son yıllarda hızla artan makine dairesiz asansörlerde motorlar kuyu içinde, kuyu duvarlarına ya da kılavuz rayların en üst bölgelerine motor şaseleri ile sabitlenmektedir. Genelde montaj firmaları motor şaselerini kendileri imal etmektedir. Makine dairesiz asansörlerde kılavuz rayların en üst tarafına bağlanmaktadır. Motor şase hesabında motor şasesinin eğilme gerilmesinin ve sehim miktarının kontrolü yapılmaktadır.

3.3.11. D bel hesabı

Makine dairesiz asans rlerin, motor  asesinin kuyu  st ndeki perde betonlara baėlanması halinde, kullanılacak  elik d bellerin hesabıdır. Motor  asesi sadece motordan gelen y k  deėil, motor kasnaėının bir tarafında beyan y k  ve kabin k tlesinin uyguladıėı kuvvetleri, diėer tarafında ise kar ı aėırlıėın uyguladıėı kuvvetleri ta ımaktadır. Hatta bazen kar ı aėırlıėın diėer ucu da bu  aseye baėlanmaktadır. Dolayısıyla asans r kullanıcıları i in, asans r sistemini ta ıyan d bellerin hesabı hayati derecede  onemlidir. Uygulamada baėlantı  ekilleri doėru olmayan  aseler g r lmektedir.

3.3.12. Reg lat r hesabı

Asans r sisteminde halatın kopması durumunda, kabin s spansiyonu  zerinde bulunan ve kabini raylara kilitleyerek durmasını saėlayan bir g venlik tertibatı bulunmaktadır. Bu g venlik tertibatı reg lat r sistemi ile devreye girmektedir. Reg lat r sistemi kuyu  st nde, reg lat r  elik halatı ile kabine baėlıdır. Bu  elik halatın gerginliėi kuyu altında bulunan reg lat r aėırlıėı ile saėlanır. Kullanılan eski sistemlerde reg lat r sistemleri tek y nl  ve sadece a aėı hızlanmalarda devreye girmektedir. Yeni standartta kabinin yukarı hızlanmasında kabini durdurma ve yava latma  artı ile reg lat r sistemleri  ift y nl  yapılmaya ba lanmı tır (T rk Standartları Enstit s , 2020). Reg lat r hesabında halatın ger ekle en g venlik katsayısının kontrol  yapılmaktadır.

3.4. Halat Tahrikli Asans rlerin Mekanik Donanımı


Bu b l mde halat tahrikli asans r sistemlerinin  onemli mekanik komponentleri anlatılmı tır.

Kuyu, yapı i inde tasarlanmış, i erisinde asans r kar ı aėırlıėının ve kabininin hareket ettiėi kapalı alandır. Kesiti genellikle dikd rtgen  eklinde olmakla birlikte binanın temelinden  atısına kadar uzanan bo luktur (Cansız, 1998). Asans r kuyusu, kılavuz raylar  zerinde kabinin ve kar ı aėırlıėın hareket ettiėi, binanın iki ucu arasında yer alan bo luk olarak tanımlanabilir. Diėer komponentler ile kar ıla tırıldığında asans r sisteminde in a edilen ilk komponent olduėundan diėerlerine g re daha farklı bir  oneme sahiptir.

Makine Dairesi, asans r kuyusunun bir par ası olarak genellikle kuyunun  zerinde, yanında veya altında bulunmaktadır. Asans r  harekete ge iren makineyi, te hizatını ve

tahrik kasnağını bulunduran alandır. Makine dairesi, asansörün beyini gibi düşünülebilir (Eryiğit, 2012).

Motor, asansör sistemini tahrik kasnağı vasıtası ile harekete geçiren makinedir. Genel yapı itibari ile dişlili ve dişlisiz motorlar olmak üzere ikiye ayrılır. Sistemin önemli komponentleri ve Görsel (3.3)'de gösterilmiştir.



Görsel 3.3. Asansörün mekanik donanımı (FEMA, 2019)

Tahrik Kasnağı, mil ile motora bağlı olan ilk kasnağa denir. Tahrik kasnağı motordan aldığı hareketi, sürtünme kuvveti ile halatlara aktarır ve asansörü yukarı veya aşağı hareket ettirmektedir.

Kasnak, motordan aldığı enerjiyi bir veya birden fazla halat yardımıyla sistemin farklı yerlerine aktaran makine elemanlarına denir. Kasnak kullanımı arttıkça motor gücüne olan gereksinim azalır ve hız düşer.

Kabin, yapının katları arasında hareket ederek insan veya yükleri taşıyan, kapalı veya açık taşıma odasıdır.

Karşı Ağırlık, kabin ve beyan yükünün bir kısmının dengelenmesini sağlayarak, kabinin hareketini kolaylaştırır, kullanılması gereken motor gücünü düşürerek enerji tasarrufu sağlar.

Kat ve Kabin Kapısı, kat ve kabin arasında, can güvenliğinin artırılması amacı ile asansör boşluğu ile bağlantıyı kesen panellerdir.

Kılavuz Raylar, karşı ağırlığın ve kabinin, yatay hareketlerini minimuma indirerek, dikey eksenlere paralel hareket etmesine kılavuzluk eden demir parçalarıdır.

Hız Regülatörü, asansörün öngörülen hızın üzerine çıkması durumunda asansörü durdurmak için özel olarak tasarlanmış bir cihazdır. Hareket halindeki bir asansörün hızı, kendisine bağlı halat vasıtasıyla bir regülatör tarafından sürekli izlenir.

Emniyet Freni, kabinin belli hız sınırlarını geçmesi durumunda kilitleme görevi yaparak düşmeyi engelleyen ve asansörün emniyetini sağlayan güvenlik sistemidir.

Tamponlar, asansörün en düşük veya son katı algılamaması durumunda, asansörün veya karşı ağırlığın zemine çarpmasını engellemek için kullanılan asansör güvenlik ekipmanlarıdır.

Kumanda Panosu, asansörün beyni ve güç kaynağıdır. Makine sisteminin elektrik beslemesini yapmaktadır. Meydana gelebilecek kısa devre ve aşırı akım gibi problemlerde çalışma adımlarını ve asansörü kontrol altında tutar.


Şaseler, asansör sisteminde kabin, karşı ağırlık ve motor şasesi olmak üzere 3 farklı tipi mevcuttur. Karşı ağırlık şasesine karkas, kabininkine ise süspansiyon denmektedir. Parçaya gelen kuvvetler şase yardımı ile dağıtılarak sistemin güvenli bir şekilde çalışması sağlanmaktadır.

4. MAKİNE ÖĞRENMESİ

Yapay zekâ, insan yeteneklerini hem taklit edecek hem ötesine geçecek şekilde davranabilen bilgisayar ve robotlar geliştirme alanıdır. Yapay zekâ özellikli programlar, bilgi sağlamak veya insan müdahalesi olmadan eylemleri otomatik olarak tetiklemek için verileri analiz edip bağlamsallaştırabilir.

Makine öğrenmesi, yapay zekâyâ giden bir yoldur. Yapay zekânın bu alt kategorisi, içgörülerini otomatik olarak öğrenmek ve verilerden kalıpları tanımak için algoritmalar kullanır ve bu öğrenmeyi giderek daha iyi kararlar almak için uygular. Programcılar, makine öğrenmesi üzerinde çalışarak ve deneyler yaparak bir bilgisayar sisteminin algısını, bilişini ve eylemini ne kadar geliştirebileceklerinin sınırlarını test ederler.

Derin öğrenme, makine öğrenmesi altında yer alan bir kavramdır ve sinir ağları (verileri mantıksal olarak analiz etmek için insan beyni gibi işlev gören ağlar) gibi yapay zekâ tekniklerini içerir. Bu ağların derinliklerinde yer alan çok sayıda katmanlar vardır. Bu sayede, derin öğrenme, çok daha karmaşık görevleri analizleyerek çözebilir ve bu analizler daha yüksek doğruluk oranlarına sahip olabilir (AI, 2022).



Görsel 4.1. AI, ML, Derin Öğrenme Kavramları Arasındaki İlişki (Intelligenza Artificiale: hanno vinto le Reti Neurali?, 2022)


Neredeyse her sektörde başarılı olmak için kuruluşların verilerini eyleme dönüştürülebilir içgörülere dönüştürebilmesi gerekir. Yapay zekâ, makine öğrenmesi ve derin öğrenme, kuruluşlara veri ve karar vermeyi içeren çeşitli manuel süreçleri otomatikleştirme avantajı sağlar. Liderler, yapay zekâ ve makine öğrenimini sistemlerine

ve stratejik planlarına dahil ederek, veriye dayalı içgörülerini daha hızlı ve verimli bir şekilde anlayabilir ve bunlara göre hareket edebilir (AI vs. Machine Learning, 2022).

Yapay zekâ, makine öğrenmesi ve derin öğrenme teknolojileri arasında benzerlikler vardır. Her üç teknolojiye, insan gibi düşünme, verilerle çalışma, öğrenme, insan yerine kullanım ve işletmelerde kullanım açısından benzerlikleri vardır. Bu teknolojileri arasında bazı önemli farklılıklar bulunmaktadır; Uygulama alanları, amaçları, veri etiketleme ihtiyaçları, kullandıkları algoritmalar açısından farklılıklar gösterirler.

Makine öğrenmesi günümüzde kullanıcı deneyiminden yararlanarak yeni ürün veya hizmet tasarımlarının geliştirilmesinden finansa, sağlık alanından otonom sürüş sistemlerine, metin veya görsel üreten yapay zekâlara kadar birçok alanda karşımıza çıkmaktadır.

Makine öğrenmesi süreci genel hatlarıyla dört adımdan oluşmaktadır: ön işlem, öğrenme, değerlendirme ve kestirim. Bu adımlar aşağıdaki görsel ile ifade edilmiştir.



Görsel 4.2. Makine Öğrenmesi Yöntemlerinin Çalışma Mantığı (Raschka & Mirjalili, 2015)

Ön işlem aşaması makine öğrenim sürecinin en önemli ve uğraştırıcı aşamasıdır. Öncelikle ham veriler analiz edilerek gereksiz veriler çıkarılır, değişim aralığı yüksek olan veriler ölçeklendirilerek etkilendirilir. Ardından veri seti, eğitim ve test veri seti olarak ikiye ayrılır. Öğrenme aşamasında, makine öğrenmesi yöntemleri seçilir ve yardımcı parametreler ile optimizasyon yapılarak kestirim modelleri oluşturulur.

Değerlendirme aşamasında, oluşturulmuş olan kestirim modeli test veri seti ile değerlendirilir. Farklı makine öğrenmesi modelleriyle yapılan tahminler, gerçek değerler performans metrikleri ile değerlendirilir ve kestirim modeli belirlenir. Eğer ön işlem aşamasında veri seti k parçaya bölünürse, değerlendirme aşamasında oluşturulmuş olan modeller çapraz olarak doğrulanabilir. Oluşturulan modellerin başarılarının yetersiz

bulunması durumunda ön işlem ve öğrenme aşamalarına geri dönülerek veri seti veya makine öğrenmesi modelinin parametrelerinde çeşitli değişiklikler yapılabilir. Bu işlemler model başarısını doğrudan etkileyecektir.

Kestirim aşamasında, ön üç aşama tamamlanmış ve makine öğrenmesi modelinin başarısı çeşitli parametrelerle maksimize edilmiştir. Oluşturulan bu model oluşturulduğu nihai amacı için hazırdır ve yeni veri setiyle tahminler yapılabilir.

Makine öğrenmesi problemleri genel olarak üç başlık altında ele alınmaktadır: denetimli, denetimsiz ve takviyeli öğrenme. Denetimli öğrenmede ilgilenilen olay için geçmiş verilerden yararlanılır ve burada hem örnekleri temsil eden özellik vektörleri hem de ilgilenilen olaya ait sonuç verileri elimizde mevcuttur. Bu aşamada temel amaç örnekler ile çıktı arasındaki ilişkiyi en iyi şekilde ortaya çıkaran bir model geliştirilmesidir. Denetimi öğrenme problemleri de tahmin edilmeye çalışılan verinin kesikli veya sürekli olmasına göre sırasıyla sınıflandırma ve regresyon olarak iki ana probleme ayrılır.

Denetimsiz öğrenmede elimizde ilgilenilen olaylar için özellik vektörleri mevcuttur ancak sonuç verileri bulunmamaktadır. Denetimli öğrenme problemleri tahmin edici (predictive), denetimsiz öğrenme problemleri de açıklayıcı (descriptive) olarak anılmaktadır.

Her iki kategori de makine öğrenmesi algoritmalarının öğrenme yeteneğini kullanarak verileri işler ve yeni bilgiler öğrenir. Ancak, denetimli öğrenme kategorisi verilerin etiketli olduğu durumlarda kullanılırken, denetimsiz öğrenme kategorisi verilerin etiketli olmadığı durumlarda kullanılır. Denetimli öğrenme denetimsiz öğrenme ile karşılaştırıldığında daha doğru sonuçlar verir ve algoritmaları daha az karmaşıktır ve çevrim dışı analiz yapabilmektedir. Denetimsiz öğrenmenin, algoritmaları daha çok karmaşık, analiz sonuçları orta derecede güvenilir ve gerçek zamanlı analiz yapabilmektedir.


Takviyeli (Pekiştirmeli) öğrenme, bir dizi karar vermek için makine öğrenmesi modellerinin eğitimidir. Algoritma, potansiyel olarak karmaşık bir ortamda bir hedefe ulaşmayı öğrenir. Takviyeli öğrenmede yapay zekâ, oyun benzeri bir durumla karşı karşıyadır. Bilgisayar, soruna bir çözüm bulmak için deneme yanılma yöntemini kullanır. Makineye programcının istediğini yaptırmak için yapay zekâ, gerçekleştirdiği eylemler için ya ödül ya da ceza alır. Amaç, toplam ödülü maksimize etmektir. Ödül politikası tasarımcı tarafından belirlenir fakat modele oyunun nasıl çözüleceğine dair hiçbir ipucu

veya öneri verilmez. Model, tamamen rastgele denemelerden oluşan taktikler ile kazanılan ödül miktarını en üst düzeye çıkarmak ister. Takviyeli öğrenme, yapay zekânın yapabildiklerini ortaya koymak için en etkili yöntemdir (Aytekin, 2021).

4.1. Makine Öğrenmesi Yöntemleri

Çalışmanın bu bölümünde özellikle kullanılan denetimli ve denetimsiz makine öğrenmesi yöntemleri vurgulanmıştır. Kullanıcı deneyimlerine dayalı tasarım parametrelerinin tahmin edilmesi, denetimli öğrenme yöntemleriyle ele alınmış ve bu problemin çözümü için kullanılan farklı yaklaşımlar kısaca aktarılmıştır.

Denetimli öğrenmede sınıflandırma ve regresyon problemleri, denetimsiz öğrenme ise kümeleme ve birliktelik analizi problemleri ile karşılaşmaktadır. Bu yapı Şekil (4.1)'de gösterilmiştir.



Şekil 4.1. Makine Öğrenmesi Yöntemleri

Veri kümelerini belirli sınıflara ayıran işleme 'sınıflandırma'denir. Bu işlem hem yapılandırılmış veriler hem de yapılandırılmamış veriler üzerinde uygulanabilir. Sınıflandırma, verilen veri noktalarının hangi sınıfa ait olduğunu tahmin etmeyi amaçlar. Bu sınıflar genellikle hedef, etiket veya kategoriler olarak adlandırılır.

Makine öğrenmesi algoritmalarının görevlerinden biri olan sınıflandırma, belirli bir girdi verisi örneği için tahmine dayalı bir model ile bir sınıf etiketinin verilmesini ifade eder. Mevcut veriler ile tahmin edilen kategorik verilerin gruplandırılması problemi sınıflandırma problemi olarak adlandırılır. E-postanın spam olup olmadığı ya da el yazısı

bir karakter verildiğinde, onun bilinen karakterlerden biri olarak algılanması sınıflandırma problemlerine örnek olarak verilebilir.

Makine öğrenmesi istatistiksel olarak, kategori üyeliği bilinen gözlemleri (veya örnekleri) içeren bir eğitim veri kümesine dayanarak, yeni bir gözlemin bir dizi kategoriden (alt popülasyon) hangisine ait olduğunu belirlenmesidir.

Regresyon problemi, sebep-sonuç ilişkisi içinde bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirleme problemi olarak tanımlanabilir. Regresyon analizi, bağımsız değişkenlerin(x) bağımlı değişken (y) üzerindeki düzey etkisini tahmin etmek için yapılan istatistiksel bir yöntemdir. Bağımsız değişkenler, yapılan hesaplamalar çıkarımlar yardımıyla bağımlı değişkene katkısını tahmin etmemize yardımcı olur. Başka bir deyişle, bir dizi bağımsız nicel veya nitel değişken ile bağımlı değişkenler arasındaki ilişkileri anlamak ve açıklamak için kullanılır. Regresyon analizinin bir sonucu olarak, genellikle regresyon denklemi olarak adlandırılan matematiksel bir denklem veya model elde edilir.

Kümeleme, en önemli denetimsiz öğrenme problemi olarak kabul edilmektedir. Bu türden diğer tüm problemlerde olduğu gibi, etiketlenmemiş verilerden oluşan bir koleksiyonda bir yapı bulmakla ilgilenir. Kümeleme probleminin diğer bir tanımı, “nesneleri bir şekilde benzer olan gruplar halinde düzenleme süreci” olarak ifade edilebilir. Bu nedenle bir küme, aralarında "benzer" olan ve diğer kümelere ait nesnelere "benzer olmayan" nesnelerin bir koleksiyonudur. Sınıflandırma problemlerinde mevcut girdi ve çıktı verisi arasındaki ilişki modellenmektedir, kümeleme problemlerinde ise çıktı değişkenleri (kümeleri) mevcut olmadığından; çıktı verileri kümeler halinde gruplandırılarak diğer kümelerden ayrıştırılır.

Kümeleme problemi çözüldüğünde, küme içi mesafeler küçük olmalıdır, yani küme üyeleri birbirine yakın ve benzerdir. Küme dışı mesafeler ise büyük olmalıdır, yani farklı kümelerin üyeleri uzak ve farklıdır.

Birliktelik analizi madenciliği, büyük veri ögeleri kümeleri arasında ilginç ilişkiler bularak bir işlemde bir ilişki kümesinin ne sıklıkta oluştuğunu gösterir. Bir dizi işlem verildiğinde, işlemdeki diğer öğelerin oluşumlarına bağlı olarak bir öğenin oluşumunu tahmin edecek kurallar bulunabilir.

Genel bir örnek olarak Pazar Tabanlı Analiz düşünüldüğünde, süper marketler satılan ürünler arasındaki ilişkileri göstermek için kullanılan temel tekniklerden biridir. Perakendecilerin, insanların sıklıkla birlikte satın aldığı ürünler arasındaki ilişkileri

belirlenmesine olanak tanır. Böylece, belirli ürün gruplarının sürekli olarak birlikte satın alınıp alınmadığını öğrenilebilir ve bu verilerle mağaza ürün yerleşimleri düzenlenerek, çapraz satışlar artırılabilir. Aynı zamanda istatistiklere dayalı promosyonların ayarlanması için kullanılabilir.

4.1.1. Doğrusal Regresyon (Linear Regression)

Doğrusal regresyon, iki değişken arasındaki ilişkiyi modellemek için gözlemlenen verilere doğrusal bir denklem uydurmayı amaçlar. Bu iki değişken arasındaki ilişkiyi modelleme çalışmasında, bir değişken bağımsız (açıklayıcı) değişken, diğer değişken ise bağımlı değişken olarak kabul edilir. Eğer bir model içinde bağımsız değişkenlerden sadece biri varsa, o zaman doğrusal regresyon olarak adlandırılır; birden fazla bağımsız değişken varsa, o zaman çoklu doğrusal regresyon olarak adlandırılır.


Doğrusal regresyon modeli kurulmadan önce dağılım grafiği herhangi bir artan veya azalan eğilim göstermezse ve iki değişken arasında bir ilişki yoksa, verilere doğrusal bir regresyon modeli uydurmak yararlı bir model sağlamayacaktır. İki değişken arasındaki ilişkinin değerini ölçmek için, -1 ile 1 arasında bir değer olan korelasyon katsayısı kullanılır. Bu, gözlenen verilerin ilişkisinin gücünü ve yönünü göstermektedir (Elidolu, 2019). Korelasyon katsayısı aşağıdaki denklem ile ifade edilir.

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n s_x s_y}$$

Regresyon çizgisi, X'lerin bağımsız değişkenler ve Y'nin bağımlı değişken olduğu aşağıdaki gibi bir denkleme sahiptir. Burada Y değeri bağımlı değişkeni, β_0 değeri denklem sabitini, β_p değerleri bağımsız değişken katsayılarını ve X_p değerleri bağımsız değişkenleri ifade eder.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon$$

ε ise, hata terimi olarak adlandırılır ve gözlem değerinin regresyon doğrusuna uzaklığıdır. En küçük kareler yöntemi kullanılarak çizilen regresyon doğrusu, öyle bir noktaya çizilmelidir ki verilerin olduğu iki boyutlu düzlemde, diğer tüm verilere olan uzaklıklarının kareleri toplamı, oluşturulabilecek diğer bütün ihtimallerdeki kareler toplamından düşük olmalıdır.



Şekil 4.2. Gelir ve gider arasındaki doğrusal regresyon grafiği

Regresyon modeli, verilerin normal dağılım sergilediği durumlarda en iyi tahminleri vermektedir. Verilerin dağılımının normal dağılıma uygunluğu Kolmogrov-Smirnov veya Shapiro-Wilk gibi uyum iyiliği testleri ile test edilebilmektedir.


4.1.2. Destek vektörleri (Support vectors)

İlk olarak sınıflandırma problemleri için geliştirilmiştir ve daha sonra birçok uygulamadaki ampirik başarısından dolayı regresyon problemlerinin çözümünde uygulanmıştır. SVR, tahmin için geliştirilmiş denetimli bir yapay zekâ modelidir (Vapnik, 2013). Model, çekirdek işlevlerinin kullanımıyla regresyonları hesaplar. Çekirdek işlevleri, orijinal düşük boyutlu girdi verilerini daha yüksek boyutlu özellik uzaylarına dönüştürebilir. SVR, optimallik sorununun dışbükey yapısından dolayı benzersiz bir çözüm üretir. SVM algoritmasında, yaklaşık fonksiyon aşağıdaki gibidir.

$$f(x) = \omega \varphi(x) + \varepsilon$$

Burada (x) , giriş vektörü x 'ten dönüştürülen daha yüksek boyutlu öznitelik uzayını temsil eder; b , ağırlık vektörünü ve düzenli risk fonksiyonunun aşağıdaki şekilde minimizasyonu yoluyla belirlenen bir eşiği temsil eder.


Destek vektör regresyonu modele uygulandığında, çizilen aralık doğrusal regresyonun tersine maksimum noktayı içerisine alması gerekir.



Şekil 4.3. SVR Grafiği (Chanklan, ve diğerleri, 2018)

“Doğrusal ve doğrusal olmayan olmak üzere iki tip SVR sınıflandırması mevcuttur ve örnekleri Şekil (4.4)’de gösterilmiştir. ε olarak tanımlanan alan içindeki veriler için hata toleransı sıfırdır. Özellikle, ξ değişkeni hassas alanın dışındaki hata toleransını temsil eder ve literatürde eğitim hatası olarak da adlandırılır. Hassas alan içindeki bölgede ξ değeri sıfırdır. Hata toleransı denklem aşağıdaki gibi ifade edilebilir” (Mikail, 2022).

$$L(\xi) = \begin{cases} |\xi| - \varepsilon, & |\xi| > \varepsilon \\ 0, & |\xi| \leq \varepsilon \end{cases}$$



Şekil 4.4. Doğrusal ve Doğrusal Olmayan SVR


Yüksek doğruluklu SVR modellemesi için, maliyet (cost) olarak ifade edilen, deneysel hata ile ağırlık vektörü arasındaki dengeyi sağlamaya yarayan C sabitinin iyi

belirlenmesi gerekir. Hata oranı ne kadar küçük girilirse işlem zamanı o kadar uzun olacaktır.

Eğer bir veri kümesinin doğrusal olmayan şekillerde ayrılabilir olduğu düşünülürse, bu veri kümesindeki örnekler doğrusal olarak ayrılamaz. Bu durumlarda, SVR doğrusal olmayan bir haritalama fonksiyonu kullanarak, verileri yüksek boyutlu bir nitelik uzayına dönüştürür ve bu sayede doğrusal olarak tahmin yapabilir. Bu, çekirdek fonksiyonları kullanarak verilerin tekrar tekrar çarpımını hesaplamak yerine, doğrudan çekirdek fonksiyonunda değerlerin kullanılmasını sağlar ve böylece nitelik uzayındaki değerler daha kolay bulunur (Acı, Avcı, & Acı, 2017).

4.1.3. Karar ağaçları (Decision trees)

Karar ağacı, bir ağaç yapısı oluşturularak edindiği bilgiyi modelleyen ve ilerleyen bir algoritmadır. Bu ağaç yapısında, yapraklar sınıf etiketlerini temsil eder. Şekil (4.5) de karar ağacı yapısı gösterilmiştir (Pekel, 2018).



Şekil 4.5. Karar Ağacı Yapısı

Karar ağaçları hem sınıflandırma hem de regresyon problemleri için uygulanabilen, parametrik olmayan bir denetimli öğrenme yöntemidir. Basit bir ifadeyle, girdi uzayını safsızlık gibi istatistiksel ölçümler kullanarak birkaç yerel bölgeye ayırır ve ardından her bir yerel bölge için genellikle ilgili eğitim örneklerinin moduna (sınıflandırma durumunda) veya ortalamasına (gerileme durumunda) dayalı olarak bir yanıt değeri ayarlar. Daha sonra verilen bir gözlem için ait olduğu yerel bölgeye göre tahminde bulunur.

Ağaç öğrenme algoritması sırasında, üzerinde eğitim yapılan veri seti, çeşitli niteliklerine göre alt veri gruplarına bölünür. Bu işlem özyinelemeli olarak tekrarlanır ve yinelenmelerin tahmin üzerindeki etkisi azalana kadar devam eder. Karar ağaçları, alan bilgisi veya parametre ayarı gerektirmeyen, keşifsel bilgi keşfi için uygun bir tümevarım


yöntemidir ve yüksek boyutlu verileri işleyebilirler. Genellikle iyi doğruluk oranına sahiptirler.

4.1.4. Rassal orman (Random forest)

Rassal Orman, makine öğrenmesi problemleri için en ünlü regresyon teknikleri arasındadır. Yöntem özellikle öğrenenler olarak karar ağaçlarını kullanır ve ardından torbalama yöntemi olarak alt kümeler oluşturur.

Rastgele Orman Algoritması, son derece popüler olan ve makine öğrenmesi sınıflandırma ve regresyon problemlerinde kullanılan denetimli bir makine öğrenmesi algoritmasıdır. Bir ormanın çok sayıda ağaçtan oluştuğunu ve ne kadar çok ağaç olursa sağlam olacağını bilinmektedir. Benzer şekilde, Rastgele Orman Algoritmasındaki ağaç sayısı arttıkça, doğruluğu ve problem çözme yeteneği de artar. Rastgele Orman, verilen veri kümesini çeşitli alt kümelere bölerek birkaç karar ağacı oluşturan ve bu karar ağaçlarının tahmin doğruluğunu ortalayarak iyileştiren bir sınıflandırıcıdır. Bu, birden çok sınıflandırıcıyı birleştirme süreci olan topluluk öğrenme kavramına dayanır ve karmaşık bir sorunu çözmek ve modelin performansını iyileştirmek amacıyla kullanılır.

Belirli bir veri veya eğitim setinden rastgele örnekler seçilir ve her bir eğitim verisi için bir karar ağacı oluşturulur. Karar ağacının ortalaması alınarak oylama yapılır ve nihai tahmin sonuç olarak en çok oylanan tahmin sonucunu seçilir. Random Forest algoritması diğer regresyon modellerinden çok daha hızlı ve sağlamdır.



Şekil 4.6. Rassal Orman'ın Yapısı

4.1.5. K- en yakın komşu (K- nearest neighbor)

K en yakın komşu (KNN) algoritması, uygulaması basit ve esnek bir sınıflandırma veya regresyon yöntemlerinden biridir. KNN sınıflandırması, genellikle veri setinin nümerik olduğu durumlarda tercih edilir. KNN, veri kümesini bütünüyle hafızaya alıp işlem yaptığından dolayı parametrik olmayan bellek tabanlı bir yaklaşımdır. KNN temel olarak tüm noktaları saklar, ardından bir sorgu yaptığınızda bu verileri kullanır. Özel bir fonksiyonla veri setinden ayırarak öğrenme yapmadığı için bu yöntemlere yavaş öğrenme (lazy learning) denir (Raschka & Mirjalili , 2015).

KNN, mevcut tüm durumları saklayan ve bir benzerlik ölçüsüne dayalı olarak sayısal hedefi tahmin eden bir algoritmadır. Başka bir yaklaşım, K en yakın komşunun ters mesafe ağırlıklı ortalamasını kullanır. KNN regresyonu ve sınıflandırması, aynı uzaklık fonksiyonlarını ile hesaplama yapar.

“Test edilmek istenilen bir örneğin veri setinde mevcut olan diğer tüm örnekler ile arasındaki uzaklıklar hesaplanır. Bu şekilde en düşük uzaklığa sahip en yakın k adet örneğin ait olduğu sınıflardan hangisi daha fazla ise test edilen örneğin sınıfı o gruba dahil olarak belirlenir. KNN basit yapısı sebebiyle literatürdeki makine öğrenmesi çalışmalarına göre daha popüler olduğu görülmektedir” (Sakarya, 2019).

KNN regresyon çıktısı, değişkenin özellik değeri olmakla birlikte, en yakın komşularının değerlerinin ortalaması alınarak hesaplanır. “Hem sınıflandırma hem de regresyon için, komşuların katkılarına ağırlık koymak, böylece yakın komşuların ortalamaya daha uzak olanlardan daha fazla katkıda bulunmaları yararlı olabilir. Örneğin, ortak bir ağırlıklandırma şeması, her komşuya 1/d ağırlığının verilmesini içerir; burada d komşuya olan uzaklıktır” (Türkalp, 2019).

Uzaklıklar bulunurken Öklid, Manhattan, Minkowski gibi mesafe fonksiyonları kullanılmaktadır.

Öklid

$$D_{euc} = \left(\sum_{i=1}^n (p_i - q_i)^2 \right)^{1/2}$$

Manhattan

$$D_{man} = \sum_{i=1}^n |p_i - q_i|$$

Minkowski

$$D_{min} = \left(\sum_{i=1}^n |p_i - q_i|^p \right)^{1/p}$$

4.2. Performans Metrikleri

Bu bölümde sınıflandırma problemlerinde kullanılan performans metrikleri kısaca bahsedilmiş ve regresyon problemlerinde kullanılan performans metrikleri ise detaylı bir şekilde anlatılmıştır.

Performans ya da hata metrikleri, belirli amaçlar doğrultusunda kurulmuş olan makine öğrenmesi modellerinin başarı ölçüsüdür. Modelin performansını betimlemek ve modeller arası performans karşılaştırmalarında kullanılmaktadır. Sınıflandırma ve regresyon modelleri için farklı metrikler uygulanmaktadır.

Sınıflandırma problemleri duyarlılık (Sensitivity), keskinlik (precision), özgüllük (specificity), hatasızlık (accuracy) gibi performans metrikleri ile değerlendirilir. Hesaplanma aşamasında ilk olarak 2x2 boyutlarında olan hata matrisi çıkarılması gereklidir. Bu matrisin elemanları, doğru ve yanlış yapılan sınıflandırmaların sayılarını ifade eder. Bu oranlar birbiri ile tekrar oranlanarak modelin performansı ölçülebilmektedir (Ay, 2022).

Regresyon problemlerinde ise R^2 , MSE, MAE ve MAPE gibi performans metrikleri kullanılmaktadır. Bu metrikler bağımsız değişkenler ile yapılan bağımlı değişkenin tahminleri ve gerçekleşen değerlerin oranlarından oluşmaktadır; gerçekleşen ve beklenen durumların farklı şekillerde oranları olarak ifade edilebilir. Aşağıda bu metrikler detaylı olarak ifade edilmiştir.

R^2 belirlilik katsayısı, gerçekleşen ve tahmin edilen değerlerin karelerinin toplamının, gerçekleşen değerlerin ortalamadan farklarının toplamının birbirine oranının, 1'den çıkarılması ile bulunur. Burada pay, artık kareler toplamı olarak, payda ise toplam kareler toplamı olarak ifade edilir. R^2 formülü aşağıdaki denklem ile ifade edilmiştir (Eren, 2022).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Hata Kareler Ortalaması (Mean square error- MSE), gerçekleşen ve tahmin edilen bağımsız değişkenin kareler toplamının gözlem sayısına bölünmesi ile bulunur. MSE formülü aşağıdaki denklem ile ifade edilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Ortalama mutlak hata (Mean absolute error- MAE) hesaplanırken öncelikle, gerçekleşen ve gözlenen tahmin değerlerinin farklarının mutlak değeri alındıktan sonra gözlem sayısına bölünerek hesaplanmaktadır. MAE formülü aşağıdaki denklem ile ifade edilmiştir.

$$MAE = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Ortalama mutlak yüzde hata (Mean absolute percent error- MAPE) hesaplanırken, her bir gözlenen ve gerçekleşen tahmin değerlerinin farkları gerçekleşen değere bölünür. Hesaplanan dizinin mutlak değer toplamı gözlem sayısına bölünür ve çıkan değer yüzdesi MAPE değerini vermektedir. MAPE formülü aşağıdaki denklem ile ifade edilmiştir. “MAPE, negatif ve pozitif hataların birbirini yok etmesi sorunu da ortadan kaldırmaktadır” (Eren, 2022).

$$MAPE = \frac{100}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

5. UYGULAMA

Bu bölümde makine öğrenmesi algoritmaları ile bulut temelli Eleport Endüstriyel Hesap Portalında, asansör parametre tahmini üzerine bir uygulama yapılmıştır. Kurulan tahmin modelleri portala aktarılmış ve kullanıcıların deneyimi artırılmıştır. Uygulama gerçek hayat problemleri üzerine odaklanmaktadır. Ayrıca tasarlanan arayüz ile birlikte kullanıcılar için model yönelimli bir karar destek sistemi niteliğindedir.

Yapılan literatür taramasında, makine öğrenmesi yardımıyla kullanıcıların tercihlerine göre değişebilen dinamik kullanıcı arayüzlerinin oluşturulması ile kullanıcı deneyimleri artış göstermekte ve müşteri memnuniyeti üst seviyelere çıkmaktadır. Bu tür arayüzler, kullanıcıya en iyi şekilde hitap edebileceği şekilde önceden depolanan veya öğrenilen verilere bağlı olarak kendilerini ayarlayabilirler. Bu nedenle, uygulamanın genel kullanılabilirliğini ve anlaşılabilirliğini azaltılabilecektir.

Bu çalışmada motor gücü, halat sayısı, kabin anma hızı, halat çapı, kanal açısı ve tahrik kasnağı çapı parametreleri tahmin edilmek amacıyla seçilmiştir. Bunların tahminleri için regresyon problemleri tanımlanmış ve birçok farklı yöntem ile ön sonuçlar elde edilmiştir. Python programı ile yapılan analizler sonrasında “Random Forest” makine öğrenmesi yönteminin diğerlerine göre daha iyi sonuçlar vermesi sebebiyle uygulamada kullanılmak istenmiştir.


5.1. Mühendislik Hesaplamaları için Bulut Bilişim Temelli Portal – ELEPORT

Eleport Asansör Hesap ve Çizim Portalı’nda yapılan çalışmalar, 130943 proje numarası ile TÜBİTAK-TEYDEB Çağrılı 1507 KOBİ Ar-Ge Başlangıç Destek Programı’ndan yararlanılarak geliştirilmiştir.

Eleport Endüstriyel Hesap Portalı asansör sektöründeki KOBİ’ler için tasarlanmış olup asansör ruhsat belgelendirmesinde gerekli olan hayati derecede önem taşıyan 12 farklı hesabı kullanıcıya pratik bir şekilde sunmaktadır. Bu hesapların manuel olarak el veya Excel gibi programlar hesaplanması ve optimizasyonu uzun zaman almaktadır. Ayrıca Eleport portalı, teknik hesaplarıyla birlikte asansörün farklı kesitlerinden milimetrik hassasiyetle vektörel olarak 12 adet teknik çizim yapabilmektedir. Yapılan iki boyutlu çizimler ile asansör kuyusu dahil olmak üzere bütün komponentler üç boyutlu olarak simüle edilebilmektedir. Yapılan hesaplamalarda kullanılan formüller ve yapılan kabuller ayrıntılı bir şekilde pdf uzantılı rapor olarak indirilebilmektedir.

5.2. Hesaplamalarda Kullanılan Kullanıcı Arayüzleri

Bu bölümde Eleport'un hesap arayüzleri anlatılmaktadır. Görsel (5.1)'de ekran ile sayfanın başlık kısmındaki “Projeler” sekmesi gösterilmiştir. Bu sayfada kullanıcı tarafından oluşturulmuş olan asansörler isteğe göre soldaki panelden filtrelenerek listelenmektedir. İlgilenilen asansöre çift tıklandığında menü açılarak ve bu menü üzerinden hesap veya çizim arayüzlerine geçiş yapılabilen, tıklanan asansör silme, kopyalama veya daha detaylı olarak inceleme işlemleri gerçekleştirilebilmektedir.



Görsel 5.1. Eleport Sitesi Projeler Sekmesi

Herhangi bir hesap yapıldıktan sonra kontrol sonuçları standartlarda belirtilen aralıklarda başarılı sonuçlanması durumunda, Görsel (5.2)'de sağ tarafta bulunan ilgili hesabın butonu yeşil renk ile kullanıcıya aktarılmaktadır. Herhangi bir hesapta girilen ve diğer hesaplarda kullanılan veriler, otomatik olarak hesaplar ve çizimler arası iletilmektedir.

1. Motor Güç, Statik Yük ve Tork Hesabı

Tahrik Makinesi Tipi: Y

Volaj: Hz

Motor: Y

Tahrik Makinesinin Yeli: Y

Tahrik Kasnağı ile Makara (Dairesi) Arasındaki Mesafe: m

Tahrik Kasnağı Halat Sarmı Şekli: Y

Akıl Şekli: Y

Makara Sayısı: adet

Beyan Yüklü: kg

Beyan Kütlesi: kg

Kablolama: mm

Halat Çapı: mm

Halat Sayısı: adet

Halat Tipi: Y

Halat Birim Kütlesi: kg/m

Halat Sayma Kuvveti: kg

Sayı Mesafesi: m

Karşı Ağırlık Dengesi Faktörü: %

Dengeleme Halat Oranı: %

Tahrik Kasnağı Çapı: mm

Montaj Verimi: %

Motor Verimi: %

Diğer Verimi: %

Toplam Verim: %

Flexible Kablo Sayısı: adet

Flexible Kablo Birim Kütlesi: kg/m

Motorun Nominal Gücü: kW

Motor/Makine Statik Yük: kg

İsteğe Bağlı Hesaplar

2. İvmesiz hareket motor tork hesabı

3. İvme ile hareket motor tork hesabı

4. Motor operasyonel çalışmada frekans hesabı (Çok 2 numara hesap yapılmamıştır)

5. Motor Akımının Hesabı (Çok 2 ve 3 numara hesap yapılmamıştır)

Hesapla **İzle**

Sonuçlar

Seyir Kabinlerinin Göreceli Kütlesi	M_{rel}	kg
Akıl halatlarının dengeliçlik yaratan kısmının kütlesi <td>M_{1h} <td>13.56</td> </td>	M_{1h} <td>13.56</td>	13.56
Karşı ağırlık kütlesi <td>M_{2h} <td>1115.00</td> </td>	M_{2h} <td>1115.00</td>	1115.00
Dengeleme cihazının kütlesi <td>M_{3h} <td>4.30</td> </td>	M_{3h} <td>4.30</td>	4.30
Tahrik kasnağı giriş hızı <td>V_{g1} <td>4.30</td> </td>	V_{g1} <td>4.30</td>	4.30
Sabit V hızında tahrik kasnağına gelen en büyük kuvvet (a=0) <td>T_1 <td>7147</td> </td>	T_1 <td>7147</td>	7147
Sabit V hızında tahrik kasnağına gelen küçük kuvvet (a=0) <td>T_2 <td>5465</td> </td>	T_2 <td>5465</td>	5465
Sabit hız halinde tahrik kasnağına gelen max. dengeliçlik kuvvet (a=0) <td>T <td>1678</td> </td>	T <td>1678</td>	1678
Tahrik kasnağına gelen operasyonel statik yük <td>T_{op} <td>1286</td> </td>	T_{op} <td>1286</td>	1286
Gerekli operasyonel giriş gücü <td>N_{op} <td>12.9</td> </td>	N_{op} <td>12.9</td>	12.9

MOTOR GÜÇ KONTROL

✓ Kullanılan motor gücü yeterlidir.

Motorun Nominal Gücü: $N_{nom} \geq N_{op}$: Gerekli operasyonel giriş gücü olmamaktadır.

$40 \text{ kW} \geq 12.9 \text{ kW}$

MOTOR/MAKİNE STATİK YÜK KONTROL

✓ Tahrik kasnağına gelen max. statik yük uygundur.

Motor/Makine Statik : $T_{st} \geq T_{op}$: Tahrik kasnağına gelen operasyonel statik yük olmamaktadır.

$3000 \text{ kg} \geq 1286 \text{ kg}$

Atanmış Tahmin

Motor: Y

Halat: Y

Kabin Roly: Y

Karşı Ağırlık Roly: Y

Birleşik Roly: Y

Trafik: Y

Toplam Çıkış Gücü: Y

Kabin Stajasyonu: Y

Karşı Ağırlık Stajasyonu: Y

Motor Sarmı: Y

Çap: Y

Düzeltilme: Y

Maliyet: Y

Görsel 5.2. Eleport Motor Hesabı Arayüzü

Motor hesabında 27 adet değişken ile hesaplama yapılabilmektedir. Yapılan tüm hesaplarda ileri seviye ve hassas- gelişmiş formüller kullanılmaktadır.

Görsel (5.1) ve (5.2) de tahmin edilmek istenen; motor gücü, halat sayısı, halat çapı, tahrik kasnağı çapı, kanal açısı ve kabin anma hızı isimli 6 parametrenin, veri girişi kutularının (input box) yanında yeşil kutular bulunmaktadır. Bu yeşil kutular, makine öğrenmesi algoritmaları ile ilişkilendirilmiş ve kullanıcılara hız ve zaman kazandırarak deneyimlerini artırmaktadır. Yeşil kutuların üzerine fare ile gelindiğinde kutu büyümekte ve Görsel (5.3)’deki gibi “Tahmin Et” butonu çıkmaktadır.

Makara Sayısı	n_p	3	adet
Beyan Yüku	Q	630	kg
Boş Kabin Kütlesi	P	800	kg
Kabin Hızı	V	2	Tahmin Et m/s
Halat Çapı	d_r	6	mm
Halat Sayısı	n_s	4	adet
Halat Tipi		PFEIFERDRAKO, P1	
Halat Birim Kütlesi	m_s	0,113	kg/m
Halat kopma kuvveti	S_h		kN
Seyir Mesafesi	H_{travel}	30	m
Karşı Ağırlık Denge Faktörü	q	50	%
Dengeleme Halatı Oranı	λ	0	%
Tahrik Kasnağı Çapı	D_t	320	m/s
Montaj Verimi	η_{inv}	82	%
Motor Verimi	η_{motor}	90	%
Dişli Verimi	η_{gear}	70	%
Toplam Verim	η_{Total}	52	%
Flexible Kablo Sayısı	n_f	1	adet
Flexible Kablo Birim Kütlesi	m_f	0,44	kg/m
Motorun Nominal Gücü	N_{nom}	40	kW
Motor/Makine Statik Yük	T_{st}	3000	kg

©2022 Eleport

Görsel 5.3. Makine Öğrenmesi Tahmin Butonları

Butona tıklandığında, bağımsız değişkenler kullanılarak bağımlı değişken tahmin edilmekte ve Görsel (5.4)'teki gibi bir ekranla tahmin sonucu kullanıcıya bildirilmektedir. Uygula butonu ile yapılan tahmin kullanıcının parametrelerine aktarılmaktadır.

×

Makine öğrenmesi motorumuzun bu parametre için tahmini: "1.03" m/s

Uygula

Görsel 5.4. Makine Öğrenmesi Tahmin Sonuç Ekranı

5.3. Tahmin Parametreleri

Bu bölümde yapılan analizlerde kullanılan yardımcı parametrelerden bahsedilmiştir. Tahmin parametreleri ise detaylı bir şekilde anlatılmıştır.

Motor gücü ve kabin hızı değişkenleri tahmininde motor hesabı verileri kullanılmıştır. Halat çapı, halat sayısı, tahrik kasnağı çapı ve kanal açısı değişkenleri ise halat hesabı değişkenleri ile tahmin edilmiştir. Çalışmada kullanılan bağımsız değişkenler aşağıdaki tabloda kısaca tanımlanmıştır.

Tablo 5.1. Çalışmada kullanılan bağımsız değişkenler ve açıklamaları


Değişken Adı	Açıklaması
<i>HalatSayisi</i>	Kullanılan halatın sayısını göstermektedir.
<i>EnKucukKopmaKuvveti</i>	Kullanılan halatın en küçük kopma kuvvetini göstermektedir.
<i>HalatAskiSekli</i>	Kullanılan halatın bağlantı şeklini göstermektedir.
<i>HalatCap</i>	Kullanılan halatın çapını göstermektedir.
<i>SeyirMesafesi</i>	Asansörün hareket mesafesini göstermektedir.
<i>KabinAnmaYuku</i>	Asansörün alabileceği maksimum yükü göstermektedir.
<i>KabinKutlesi</i>	Boş kabinin kütlesini göstermektedir.
<i>HalatBirimKutlesi</i>	Kullanılan halatın birim kütlesini göstermektedir.
<i>KabinAnmaHizi</i>	Kabinin yapabileceği maksimum hızı göstermektedir.
<i>SisteminToplamVerimi</i>	Kullanılan motorun toplam verimini göstermektedir.
<i>KompanzasyonOrani</i>	Kabin ve karşı ağırlık arasındaki zincirin, sistem verimliliğine etkisini göstermektedir.
<i>MotorunYeri</i>	Tahrik makinesinin yerini göstermektedir.
<i>HalatAskiSekli</i>	Halat sarım şeklinin katsayısını göstermektedir.
<i>TahrikKasnagi</i>	Kullanılan tahrik kasnağının çapını göstermektedir.
<i>KesmeAcisi</i>	Tahrik kasnağı alt kanal kesme açısını göstermektedir.
<i>SarimTipi</i>	Tahrik kasnağının üzerindeki halatın sarım şeklini göstermektedir.
<i>HalatSarimAcisi</i>	Halatın, tahrik kasnağına temas ettiği uç noktalar arasında oluşan açığı göstermektedir.
<i>KarsiAgirlikDengeFaktoru</i>	Kabinin, karşı ağırlık ile ağırlıklıları üzerinden dengelenme oranını göstermektedir.
<i>KompanzasyonOrani</i>	Denge zinciri ile asansör sisteminin dengelenme oranını göstermektedir.

5.3.1. Kabin hızı

Kabin hızı ya da kabin beyan hızı, asansörün katlar arasındaki hareketinde maksimum hızını ifade etmektedir. Binanın yüksekliğine göre, asansör kullanıcılarını makul sürelerde istedikleri yere gidebilmelerini sağlamak üzere belirlenirler. TS- EN 81.20:2020 Türk Asansör Trafik Standardı'nda kabin giriş katından en yüksek kata en fazla bir dakikada gidebilmesi gerekmektedir (Türk Srtandarları Enstitüsü, 2021).

5.3.2. Halat çapı ve Halat sayısı

Asansörün katlar arasındaki hareketini sağlayan çelik halatların çapları ve halatların kopma kuvvetleri üretici firmalar tarafından ilgili standartlar doğrultusunda belirlenir. Türk asansör standardında, asansör sisteminde en az iki halatın kullanılmasının zorunlu olduğu bahsedilmektedir. Asansörlerde kullanılan halatların çapları 6, 6.5, 8, 9, 10, 11, 12, 13, 14, 15, 16 ve 18 mm şeklinde sıralanabilir. Kullanılan halatın çapı ile kopma kuvveti ile doğru orandadır. Halat hesabında asansörün taşıma kapasitesi, kabin ağırlığı ve bir güvenlik katsayısı ile halatların dayanmaları gereken yükler hesaplanmaktadır. Bu yüklere karşılayacak dayanım kuvvetini hesaplanarak, güvenlik sınırları dahilinde halat çapı ve halat adedi tespit edilir. Gereksiz yere halatın çapını veya adedini yüksek tutmak maliyeti artırmaktadır. Aşağıdaki görselde çelik bir halatın çapı gösterilmiştir.



Görsel 5.5. Çelik Halatın Çapı ve Sarmal Yapısı

5.3.3. Tahrik kasnağı çapı

Halat tahrikli asansörlerde kabinin hareketi, başka bir deyişle tahriki, motor üzerindeki tahrik kasnağı ile gerçekleşir. Halatlar, tahrik kasnağı üzerindeki kesitleri milimetrik olarak tasarlanmış kanallardan geçerken halat bir sıkışmaya maruz kalır. Bu sıkışmadan doğan sürtünme, kabini hareket ettiren kuvveti oluşturur. Buna tahrik

kasnağının tahrik yeteneği denmektedir. Bahsi geçen sürtünme kuvvetinin, boş veya dolu kabin yüklerinde, kabinin tahrik kasnağı üzerinden kaymasını önleyebilecek derecede büyük olması gerekir. Ayrıca bu sürtünme kuvveti kabini, kalkışta belirli bir ivmede beyan hızına ulaşmasını, beyan hızında hedef katına gitmesini ve orada güvenle sabit bir şekilde durdurulması gerekmektedir. Türk asansör standardına göre tahrik kasnağı çapı kullanılan halat çapının en az 40 katı kadar büyük olmalıdır (Türk Standartları Enstitüsü, 2020). Tahrik kasnağının çapı, motor devir hızı, redüktörün tahvil oranı ve asansörün hızı göz önüne alınarak imalatçı firma tarafından belirlenir.



Görsel 5.6. Tahrik Kasnağı (Astim Toro, 2022)

5.3.4. Motorun nominal gücü

Bir motor, belirtilen sıcaklık ve nem gibi uygun çevre koşullarında, üreticinin öngördüğü saatteki duruş-kalkış miktarına göre güvenle çalışabildiği durumda, çektiği elektriksel güce nominal güç denir ve nominal gücün birimi kilowatttır. Elektriksel olarak bu gücü alan motor, verim değeri oranının üzerinde gücü kaybederek kalanını mekanik güce çevirir. Bu mekanik güç, asansörü beyan kapasitesinde ve hızında hareket ettirmesi gerekir. Özellikle kalkış sırasında ivmeli hareket dolayısıyla atalet kuvvetleri devreye girecektir ve motor (gerekli mekanik güç) hesabında bu durumun dikkate alınması gerekir.




Görsel 5.7. *Makine Dairesi ve Tahrik Makinesi (Motor) (Yönel Asansör, 2022)*

5.3.5. Tahrik kasnağı kanal açısı

Tahrik kasnağı çapı konusunda belirtildiği üzere asansör kabininin hareketi(tahriki), tahrik kasnağı kanallarında oluşan sürtünme kuvveti ile yapılır. Burada kanal üzerinde gerçekleşen düşük sürtünme kuvveti, halatların kabini kaldırmadan tahrik kasnağı üzerinde patinaj yapmasına sebep olur.

Diğer taraftan fazla sürtünme kuvveti, karşı ağırlığın kuyu altında tampon üzerine oturduğu ve asansör motorunun çalışmaya devam ettiği durumda, halatların kabini yukarıya götürmeye devam etmesine neden olur. Bu istenmeyen bir durum olmakla birlikte, bir süre sonra halatların kanal üzerinde boşa çıkmasına ve ardından kabinin serbest düşüşe geçmesine sebep olabilir. Böyle bir durumda halatların kasnak üzerinde patinaj yapması can ve mal kaybı açısından daha iyimser bir durumdur. Sonuç olarak fazla tahrik veya eksik tahrik yani sürtünme kuvveti durumlarının ikisi de istenmemektedir.

Halatların tahrik kasnağı kanallarında oluşturacakları tahrik miktarı, tahrik kasnağının kanal şekli ile bağlantılıdır. Piyasada dört çeşit kanal olmakla birlikte, V kanal, U kanal, V altı kesik kanal, U altı kesik kanal olarak isimlendirilmektedir. Burada her tip içinde farklı açı kombinasyonları vardır ve farklı tip kanal açılarında farklı tahrik yetenekleri oluşur. Hesaplarda basit bir açı düzenlemesi ile daha az halat kullanımına gidilebilir ve bu olay maliyette açısından ciddi bir tasarruf sağlayabilir.



Görsel 5.8. *V Kanal Açısı*

5.4. Sayısal Sonuçlar ve Model Seçimi

Çalışmanın bu bölümde uygulamada kullanılan veri seti incelenmiş, yapılan analizde kullanılan makine öğrenmesi yöntemleri ile elde edilen sonuçlar karşılaştırılmıştır. Uygulamanın gizliliği açısından kurulan modellere bir adet örnek verilmiş ve örnek üzerinden kullanılan fonksiyonlar detaylı olarak anlatılmıştır.

Uygulamada, Eleport'un beta sürümünden elde edilen, 31 Mayıs 2020 ve 3 Aralık 2022 tarihleri arasında toplanmış olan 2889 adet motor ve 6510 adet halat hesabı verisi kullanılmaktadır. Hesaplar incelendiğinde, sırasıyla 119 ve 83 adet veri eksik gözlem değerleri içermektedir. Boş gözlem değerine sahip olan veri satırları, veri setinden çıkarılmıştır.

Uygulamadaki 19 adet nümerik değişkenin, 10 adedi tam sayı(int), 9 adedi ise ondalıklı sayıdır(float) ve 1 adet kategorik(object) değişken mevcuttur. Halat türü (HalatTuru) isimli kategorik değişken regresyon problemine dahil edilmek için, "sklearn" kütüphanesinin etiket kodlayıcı fonksiyonu ile otomatik olarak nicel hale dönüştürülmüştür. Kullanılan değişkenlerin tiplerine ait program çıktısı aşağıda Tablo (5.2)'de gösterilmektedir.

Tablo 5.2. Çalışmada kullanılan değişken tipleri

HalatTuru	object
MotorunYeri	int64
HalatAskiSekli	int64
KabinAnmaYuku	int64
KabinKutlesi	int64
KabinAnmaHizi	float64
SeyirMesafesi	float64
TahrikKasnagi	int64
HalatCap	float64
HalatSayisi	int64
HalatBirimKutlesi	float64
EnKucukKopmaKuvveti	float64
KompanzasyonOrani	int64
KanalAcisi	int64
KesmeAcisi	int64
SarimTipi	int64
HalatSarimAcisi	float64
SeyirMesafesi	float64
KarsiAgirlikDengeFaktoru	float64
MotorGucu	float64
dtype:	object

Veri setindeki nicel değişkenler hakkında bilgi veren betimleyici istatistik değerleri Tablo (5.3), (5.4) ve (5.5)'de verilmiştir.

Tablo 5.3. Motor hesabı veri setine ait betimleyici istatistikler

Değişken Adı	Katsayı	Ortalama	Std	Min	25%	50%	75%	Max
KabinAnmaYuku	2770	1399,67	1270,52	0	800	1000	1600	14500
KabinKutlesi	2770	1493,13	1274,53	10	1000	1200	1575	18250
HalatAskiSekli	2770	2,06	0,65	1	2	2	2	6
SeyirMesafesi	2770	39,69	31,57	1	21	30	45	200
HalatCap	2770	8,62	1,90	6,5	6,5	8	10	16
HalatBirimKutlesi	2770	0,31	0,15	0,1	0,2	0,27	0,4	1,13
HalatSayisi	2770	6,81	1,76	2	6	7	8	10
KADengeFaktoru	2770	50,04	2,53	30	50	50	50	70
KompanzasyonOrani	2770	36,29	43,70	0	0	0	90	100
KabinAnmaHizi	2770	1,33	0,60	0,2	1	1	1,6	6
TahrikKasnagi	2770	349,28	106,52	41	240	320	400	800
MotorGucu	2770	11,88	7,88	0,1	6,4	10,3	15,9	100

Tablo 5.4. *Halat hesabı veri setine ait betimleyici istatistikler*

Değişken Adı	Katsayı	Ortalama	Std	Min	25%	50%	75%	Max
<i>MotorunYeri</i>	6417	1,00	0,06	1	1	1	1	2
<i>HalatAskiSekli</i>	6417	2,14	0,70	1	2	2	2	4
<i>KabinAnmaYuku</i>	6417	1690,46	1762,57	100	800	1150	1600	17000
<i>KabinKutlesi</i>	6417	1721,99	1470,53	100	1000	1300	1850	16000
<i>KabinAnmaHizi</i>	6417	1,40	0,82	0,2	1	1	1,6	6
<i>SeyirMesafesi</i>	6417	44,51	44,01	1	15	26	48	200
<i>TahrikKasnagi</i>	6417	355,18	108,14	120	240	320	400	800
<i>HalatCap</i>	6417	8,79	1,95	6,5	6,5	8	10	20
<i>HalatSayisi</i>	6417	7,01	1,88	2	6	7	8	10
<i>HalatBirimKutlesi</i>	6417	0,32	0,15	0,1	0,18	0,27	0,42	1,73
<i>EnKucukKopmaKuvveti</i>	6417	48,78	22,43	1	31,5	43,3	61,8	246
<i>KompanzasyonOrani</i>	6417	32,11	43,97	0	0	0	90	100
<i>KanalAcisi</i>	6417	37,79	7,91	30	30	35	40	60
<i>KesmeAcisi</i>	6417	66,36	41,90	0	0	90	95	105
<i>SarimTipi</i>	6417	1,00	0,06	1	1	1	1	2
<i>HalatSarimAcisi</i>	6417	175,98	10,97	150	180	180	180	280

Tablo 5.5. *Tahmin değişkenlere ait betimleyici istatistikler*

Değişken Adı	Katsayı	Ortalama	Std	Min	25%	50%	75%	Max
<i>MotorGucu</i>	2770	11,88	7,88	0,1	6,4	10,3	15,9	100
<i>KabinAnmaHizi</i>	2770	1,33	0,60	0,15	1	1	1,6	6
<i>HalatCap</i>	6417	8,79	1,95	6,5	6,5	8	10	20
<i>TahrikKasnagi</i>	6417	355,18	108,14	120	240	320	400	800
<i>KanalAcisi</i>	6417	37,79	7,91	30	30	35	40	60

Tahmin değişkenleri için çarpıklık (skewness) ve basıklık (kurtosis) değerleri aşağıdaki tabloda verilmiştir. Hesaplamalarda Python programına ait “scipy.stats” kütüphanesi kullanılmıştır.

Tablo 5.6. Tahmin parametrelerinin çarpıklık ve basıklık değerleri

Parametre Adı	Çarpıklık	Basıklık
<i>Motor Gücü</i>	2.12	10.28
<i>Kabin Hızı</i>	1.96	8.52
<i>Halat Çapı</i>	0.71	0.61
<i>Halat Sayısı</i>	-0.21	-0.62
<i>Kanal Açısı</i>	1.22	0.89
<i>Tahrik Kasnağı Çapı</i>	0.63	0.34

Verilerin normal dağılıma uygunluğu test edilmek istenmiştir. Bu doğrultuda aşağıdaki hipotezler her bir parametre için kurulmuştur.

H_0 : Veriler normal dağılıma uygundur.

H_1 : Veriler normal dağılıma uygun değildir.


Hipotezlerin test edilmesi için “scipy.stats” kütüphanesindeki Shapiro-Wilk Testi kullanılmıştır. Altı tahmin parametresine ait test sonuçları aşağıda Tablo (5.7) ile gösterilmiştir.

Tablo 5.7. Tahmin Parametrelerinin Shapiro- Wilk Teti Sonuçları

Parametre	Test İstatistiği	P-Value
<i>MotorGucu</i>	0,843	0
<i>KabinAnmaHizi</i>	0,7926	0
<i>HalatCap</i>	0,8704	0
<i>HalatSayisi</i>	0,954	0
<i>KanalAcisi</i>	0,8342	0
<i>TahrikKasnagi</i>	0,9366	0


Parametrelerin Shapiro-Wilk Testi sonucunda hesaplanan p-value değerleri incelendiğinde ve anlamlılık düzeyi $\alpha = 0.05$ alındığında, H_0 hipotezleri %95 güvenle red edilir. Dolayısıyla altı tahmin parametresinin verileri normal dağılıma uygun değildir.

Aşağıdaki tabloda altı tahmin parametresinin verilerine ait histogram grafikleri verilmiştir. Grafikler çizdirilirken “matplotlib.pyplot” kütüphanesindeki histogram fonksiyonu kullanılmıştır.




Şekil 5.1. Tahmin Parametrelerine Ait Histogram Grafikleri

Çalışmada kullanılan motor ve halat hesap parametrelerinin aralarındaki ilişkiyi göstermek amacıyla korelasyonları Şekil (5.2) ve (5.3)’te ısı haritası ile gösterilmiştir. Korelasyon matrisinin görselleştirilmesinde “seaborn” kütüphanesindeki ısı haritası fonksiyonu kullanılmıştır.



Şekil 5.2. Motor Parametrelerinin Korelasyonlarının Isı Haritası



Şekil 5.3. Halat Parametrelerinin Korelasyonlarının Isı Haritası

Yapılan analizlerde çoklu doğrusal regresyon, destek vektör regresyonu, karar ağaçları regresyonu, rassal orman regresyonu ve k en yakın komşu regresyonu olmak üzere 5 farklı makine öğrenmesi modeli kullanılmıştır. Makine öğrenmesi modelleri için sklearn kütüphanesinden faydalanılmıştır. Ayrıca model performansını ölçmekte kullanılan “sklearn.metrics” kütüphanesi, model seçimi yapmak için “sklearn.model_selection” kütüphanelerinden çeşitli fonksiyonlar kullanılmıştır.

Veri manipülasyonu için pandas ve numpy, kurulan modelleri kaydetmek veya yüklemek için pickle kütüphaneleri kullanılmıştır. Aşağıdaki kod bloğunda kullanılan bütün kütüphaneler içeri aktarılmıştır.

```
import pandas as pd
import numpy as np
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.metrics import (mean_absolute_percentage_error,
mean_absolute_error, mean_squared_error, r2_score)
import pickle

from sklearn import preprocessing

from sklearn.tree import DecisionTreeRegressor
from sklearn.svm import SVR
from sklearn.ensemble import RandomForestRegressor
from sklearn.neighbors import KNeighborsRegressor
```

✓ 0.2s Python

Görsel 5.9. Çalışmada kullanılan kütüphaneler

Pandas kütüphanesi “read_excel” fonksiyonu ile motor ve halat excel dosyalarındaki veriler okunarak kaydedilmiştir. “dropna” fonksiyonu yardımı ile eksik gözleme değerlerine sahip veri satırları ve “drop” fonksiyonu ile gerekli olmayan veri sütunları silinmiştir.

```
import pandas as pd
motor_data = pd.read_excel('../model-data/motor_data.xlsx').dropna().drop(
columns=["ID", "UserId", "FirmaAdi", "ProjeAdi", "CreateTime"])
halat_data = pd.read_excel('../model-data/halat_data.xlsx').dropna().drop(
columns=["ID", "UserId", "FirmaAdi", "ProjeAdi", "CreateTime",
"D", "L1", "L2", "LangCode", "Certificate"])
```

Python


Görsel 5.10. Pandas kütüphanesi ile veri okuma

Motor gücü, kabin beyan hızı, halat sayısı, halat çapı, kanal açısı ve tahrik kasnağı çapı olmak üzere, 6 farklı parametre tahmini için aşağıdaki adımlar ayrı ayrı uygulanmıştır. 6 tahmin parametresine ayrı ayrı, 5 farklı makine öğrenmesi algoritması uygulanmıştır. Toplamda 30 farklı model çalıştırılmıştır.

Modelin uygulama adımlarında öncelikle, tahmin edilecek parametre (y) değişkeni olarak, kalan parametreler (X) değişkeni olarak atanır ve veri seti eğitim (X_train, y_train) ve test (X_test, y_test) seti olarak sırasıyla %67’ye %33 oranında ikiye bölünür. Ardından regresyon modeli seçilerek modelde kullanılabilecek parametreler belirlenir.

Kullanılabilecek parametrelerin farklı kombinasyonları ile model eğitilir. Bu aşamada hiper parametre optimizasyonu yapılır ve model k adet çapraz doğrulama yapılarak test edilir. Kullanılabilecek parametrelerin farklı kombinasyonları ile yapılan denemelerde performansı en yüksek model otomatik olarak seçilir. Son olarak modeller arası performansı değerlendirmek için kullanılan modelin performans metrikleri hesaplanır.

Yukarıdaki adımlar 6 adet tahmin parametresi için bütün modellere uygulanmıştır. Aşağıdaki kod bloklarında, motor gücü parametresinin tahmininde kullanılan doğrusal regresyon modeli örnek olarak gösterilmiş ve anlatılmıştır.



```
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split, GridSearchCV

X = np.array(motor_data.drop(columns=["MotorGucu"]))
y = np.array(motor_data["MotorGucu"])
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.33, random_state=42)

model = LinearRegression()

parameters = {"fit_intercept": [True, False],
              "positive": [True, False],
              }

reg = GridSearchCV(model, param_grid=parameters, scoring='r2', cv=10, verbose=3)

reg.fit(X_train, y_train)
```

Python

Görsel 5.11. Izgara Arama ile Doğrusal Regresyon Modeli Adımları

Motor gücü parametresinin tahmininde “MotorGucu” değişkeni, veri setinden çıkarılarak kalan parametreler ile (X) değişkeni oluşturulmuş ve “MotorGucu” değişkeni (y) değişkenine atanmıştır. Doğrusal Regresyon modeli belirlenerek, kullanılabilecek parametreler belirlenmiştir. Burada “fit_intercept” parametresi doğru ve yanlış olarak belirtilmiştir. Bu kurulan modelde kesme noktasının kullanılıp kullanılmayacağını belirtir. Diğer parametre “positive” ise regresyon denklemindeki katsayıların sadece pozitif olacağını veya olmayacağını anlatmaktadır.

Sklearn kütüphanesinde bulunan “gridSearchCv” olarak bilinen model seçim fonksiyonu ile hiper parametre optimizasyonu yapılarak ızgara modeli oluşturulmuştur. Fonksiyona girdi olarak seçilen model, kullanılacak parametreler, skor performansları değerlendirme ölçütü ve çapraz doğrulama için örneklem sayısı verilmiştir. Performans


ölçütü R^2 olarak seçilmiş ve kullanılan veriler çapraz doğrulama için 10 parçaya bölünmüştür. Ardından bu kullanılacak parametreler “fit” fonksiyonu ile eğitim setine uygulanarak modeller eğitilmiş ve oluşturulan modeller karşılaştırılarak en iyi sonuçlar seçilmiştir. Ardından oluşturulan modelin en iyi parametrelerini görüntülemek için çalıştırılan kod bloğu ve çıktısı aşağıda gösterilmiştir.



```
reg.best_params_
✓ 0.5s Python
{'fit_intercept': True, 'positive': True}
```

Görsel 5.12. *Izgara Arama ile En İyi Doğrusal Regresyon Parametreleri*

Motor gücü parametresi, ızgara modeli ile belirlenen doğrusal regresyon modeli eğitim ve test veri setleri için hesaplanmıştır. Eğitim ve test veri kümeleri için ayrı ayrı en iyi regresyon modelinin performans metrikleri analiz edilmiştir. Hesaplama model seçim kütüphanesindeki MSE, MAE, MAPE, R^2 özel fonksiyonları kullanılarak aşağıdaki kod bloğu ile ölçülmüştür.



```
y_pred_train = reg.predict(X_train)
print(mean_squared_error(y_train, y_pred_train))
print(mean_absolute_error(y_train, y_pred_train))
print(mean_absolute_percentage_error(y_train, y_pred_train))
print(r2_score(y_train, y_pred_train))

y_pred_test = reg.predict(X_test)
print(mean_squared_error(y_test, y_pred_test))
print(mean_absolute_error(y_test, y_pred_test))
print(mean_absolute_percentage_error(y_test, y_pred_test))
print(r2_score(y_test, y_pred_test))
✓ 0.3s Python
```

Görsel 5.13. *Sklearn Kütüphanesi ile Hesaplanan Performans Metrikleri*

Yukarıda motor gücü parametresi için yapılan kodlama farklı model ve tahmin parametreleri için uygulanmıştır. Motor gücü, halat sayısı, halat çapı, kabin hızı, kanal açısı ve tahrik kasnağı çapı olmak üzere altı adet parametrenin tahmini için uygulanan 5 farklı modelin performans metrikleri aşağıda Tablo (5.8), (5.9), (5.10), (5.11), (5.12) ve (5.13) ile gösterilmiştir.

Tablo 5.8. Motor gücü parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R ²	MAPE	MSE	MAE	R ²	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,675	0,232	21,901	2,431	0,634	0,530	18,751	2,438
<i>SVR</i>	0,946	0,112	3,650	0,999	0,727	0,505	13,996	1,868
<i>DT</i>	0,743	0,175	17,322	1,867	0,755	0,455	12,530	1,965
<i>RF</i>	0,942	0,051	3,911	0,577	0,843	0,486	8,048	1,125
<i>KNN</i>	0,920	0,059	5,403	0,663	0,782	0,449	11,153	1,323

Motor gücü için yukarıdaki Tablo (5.8) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R² performansını yaklaşık 0,84 ile rassal orman tahmincisi sağlamakla birlikte en küçük MSE ve MAE değerlerini vermiştir.

Tablo 5.9. Halat sayısı parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R ²	MAPE	MSE	MAE	R ²	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,386	0,194	2,204	1,144	0,366	0,188	2,154	1,123
<i>SVR</i>	0,905	0,046	0,340	0,282	0,829	0,069	0,582	0,417
<i>DT</i>	0,830	0,083	0,611	0,512	0,805	0,086	0,663	0,531
<i>RF</i>	0,927	0,046	0,260	0,285	0,877	0,060	0,418	0,373
<i>KNN</i>	0,911	0,045	0,320	0,275	0,818	0,067	0,618	0,417

Halat sayısı için yukarıdaki Tablo (5.9) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R² performansını yaklaşık 0,88 ile rassal orman tahmincisi sağlamakla birlikte en küçük MAPE, MSE ve MAE değerlerini vermiştir.

Tablo 5.10. Kabin hızı parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R ²	MAPE	MSE	MAE	R ²	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,679	0,207	0,111	0,208	0,582	0,181	0,169	0,226
<i>SVR</i>	0,938	0,083	0,021	0,092	0,623	0,144	0,153	0,177
<i>DT</i>	0,757	0,124	0,084	0,128	0,559	0,123	0,179	0,164
<i>RF</i>	0,953	0,024	0,016	0,030	0,726	0,056	0,111	0,087
<i>KNN</i>	0,940	0,029	0,021	0,036	0,644	0,074	0,144	0,108

Kabin hızı için yukarıdaki Tablo (5.10) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R^2 performansını yaklaşık 0,73 ile rassal orman tahmincisi sağlamakla birlikte en küçük MAPE, MSE ve MAE değerlerini vermiştir.

Tablo 5.11. Halat çapı parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R^2	MAPE	MSE	MAE	R^2	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,952	0,033	0,184	0,286	0,964	0,033	0,138	0,287
<i>SVR</i>	0,994	0,009	0,024	0,081	0,963	0,018	0,141	0,158
<i>DT</i>	0,985	0,001	0,057	0,015	0,994	0,001	0,024	0,011
<i>RF</i>	0,994	0,002	0,023	0,016	0,997	0,002	0,011	0,019
<i>KNN</i>	0,997	0,000	0,013	0,002	0,964	0,007	0,139	0,062

Halat çapı için yukarıdaki Tablo (5.11) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R^2 performansını yaklaşık 0,99 ile rassal orman tahmincisi sağlamakla birlikte en küçük MSE değerini vermiştir. Alternatif olarak diğer dört modelin R^2 test skorları 0,96'nın üzerindedir.

Tablo 5.12. Kanal açısı parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R^2	MAPE	MSE	MAE	R^2	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,422	0,107	36,029	4,283	0,438	0,108	35,412	4,262
<i>SVR</i>	0,789	0,048	13,130	1,860	0,692	0,065	19,385	2,535
<i>DT</i>	0,685	0,071	19,620	2,831	0,638	0,076	22,797	3,018
<i>RF</i>	0,845	0,041	9,688	1,652	0,765	0,053	14,797	2,118
<i>KNN</i>	0,829	0,039	10,637	1,548	0,691	0,058	19,498	2,291

Kanal açısı için yukarıdaki Tablo (5.12) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R^2 performansını yaklaşık 0,77 ile rassal orman tahmincisi sağlamakla birlikte en küçük MAPE, MSE ve MAE değerini vermiştir.

Tablo 5.13. Tahrik kasnağı çapı parametresi için kurulan modellerin performans metrikleri

Model	Train				Test			
	R ²	MAPE	MSE	MAE	R ²	MAPE	MSE	MAE
<i>Lin-Reg</i>	0,802	0,083	2320,150	27,660	0,815	0,083	2143,513	27,027
<i>SVR</i>	0,968	0,035	375,955	11,310	0,908	0,054	1063,931	17,379
<i>DT</i>	0,905	0,045	1110,341	14,073	0,897	0,049	1195,630	15,397
<i>RF</i>	0,984	0,014	190,968	4,107	0,957	0,025	498,724	7,749
<i>KNN</i>	0,986	0,005	164,178	1,652	0,876	0,033	1436,355	10,170

Tahrik kasnağı çapı için yukarıdaki Tablo (5.13) incelendiğinde, kurulan modellerin test sonuçlarında en iyi R² performansını yaklaşık 0,96 ile rassal orman tahmincisi sağlamakla birlikte en küçük MAPE, MSE ve MAE değerini vermiştir.

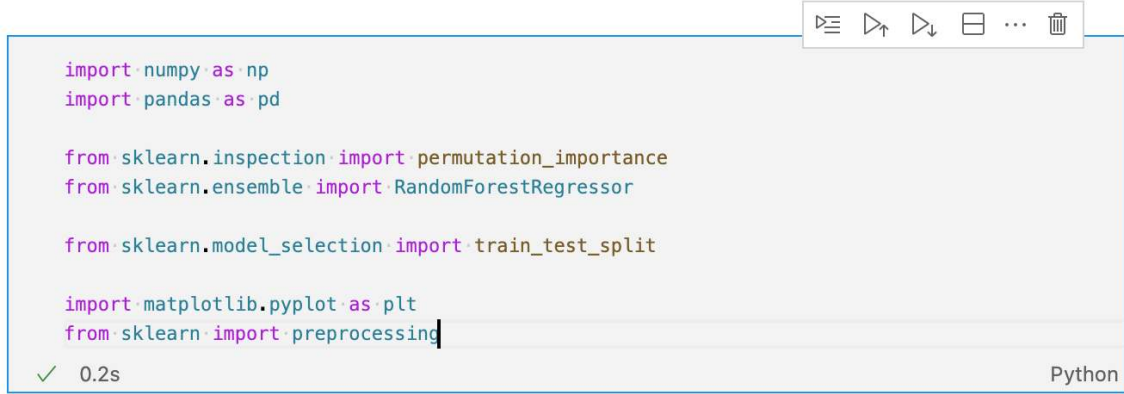
Yapılan bütün analiz sonuçları yukarıdaki tablolarda gösterilmiş ve anlatılmıştır. Öncelikli olarak R² performans metriği ile değerlendirildiğinde, RF modeli diğer modellere göre daha başarılı sonuçlar vermiştir.

5.5. Parametre Seçimi

Çalışmanın bu bölümünde, yapılan tahminlerde etkisi yüksek olan yardımcı parametrelerin analizi yapılmaktadır. Parametre seçiminde kullanılan kodlar sadece motor gücü parametresinde anlatılmış, diğer parametrelerin ise sonuçları paylaşılmıştır.

“Hangi özelliklerin tahminler üzerinde en büyük etkisi vardır?” sorusuna cevap aranmaktadır. Parametre seçimindeki bu kavram “feature importance” yani özellik önemi olarak adlandırılır.

Önemi yüksek olan parametrelerin seçimi ile ilgili çalışmada “sklearn.inspection” kütüphanesindeki “permutation_importance” fonksiyonu kullanılmıştır. Permütasyon özellik önemi, tahmin sonuçları arasındaki ilişkiyi bozan özelliğin değerlerini değiştirdikten sonra, modelin tahmin hatasındaki artışı ölçmesidir. Aşağıdaki kod bloğunda parametre seçiminde kullanılan kütüphaneler içeri aktarılmıştır.



```
import numpy as np
import pandas as pd

from sklearn.inspection import permutation_importance
from sklearn.ensemble import RandomForestRegressor

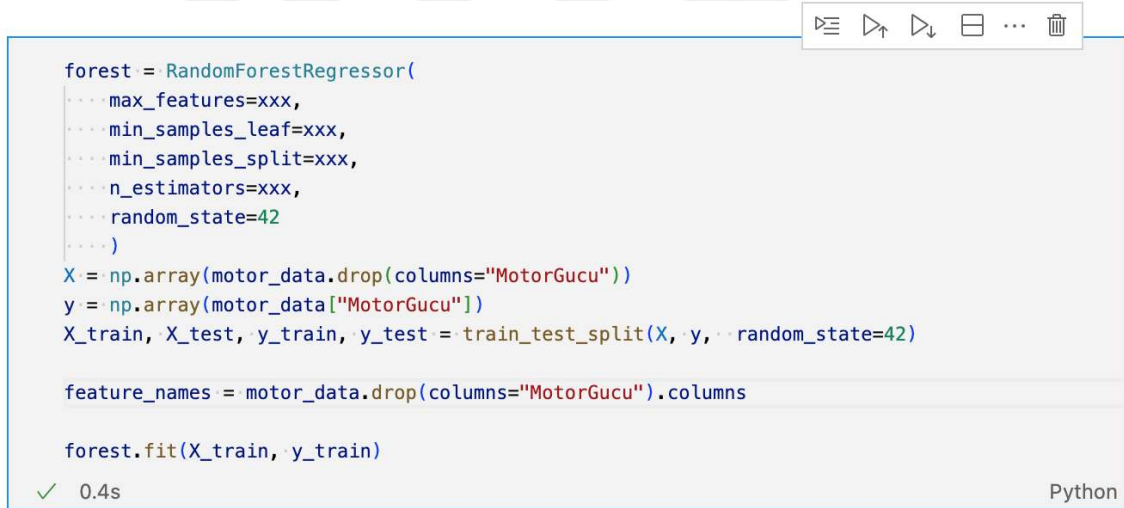
from sklearn.model_selection import train_test_split

import matplotlib.pyplot as plt
from sklearn import preprocessing
```

✓ 0.2s Python

Görsel 5.14. Parametre Seçiminde Kullanılan Kütüphaneler

Parametre seçimine başlamadan önce modelin oluşturulması gereklidir. Kullanılacak modeller “5.4. Sayısal Sonuçlar ve Model Seçimi” başlığı altında analiz edilerek oluşturulmuş ve en iyi skorları veren modeller seçilmiştir. En iyi skorları veren model parametreleri ile aşağıdaki kod bloğu tekrar çalıştırılmıştır.



```
forest = RandomForestRegressor(
    max_features=xxx,
    min_samples_leaf=xxx,
    min_samples_split=xxx,
    n_estimators=xxx,
    random_state=42
)
X = np.array(motor_data.drop(columns="MotorGucu"))
y = np.array(motor_data["MotorGucu"])
X_train, X_test, y_train, y_test = train_test_split(X, y, random_state=42)

feature_names = motor_data.drop(columns="MotorGucu").columns

forest.fit(X_train, y_train)
```

✓ 0.4s Python

Görsel 5.15. En İyi Parametrelerle Oluşturulan RF Modeli Kod Bloğu

Görsel (5.15)’de gösterilen kod bloğu ile en iyi parametreler ile model tekrar oluşturulmuştur. Özellik önemi fonksiyonu Görsel (5.16)’deki kod bloğu ile çalışmaya eklenmiştir.

```


result = permutation_importance(
    forest, X_test, y_test, n_repeats=10, random_state=42, n_jobs=-1
)
forest_importances = pd.Series(result.importances_mean, index=feature_names)
fig, ax = plt.subplots()
forest_importances.plot.bar(yerr=result.importances_std, ax=ax)
ax.set_title("Permütasyon Modeli Kullanarak Parametrelerin Önemi")
ax.set_ylabel("Ortalama doğruluk derecesi")
fig.tight_layout()
plt.show()

```

✓ 0.4s Python

Görsel 5.16. Özellik Önemi Fonksiyonu ve Değişkenlerin Önem Grafiği


Yukarıdaki kod bloğunda özellik önemi fonksiyonuna makine öğrenmesi modeli, test verileri ve k çapraz doğrulama adedi parametre olarak eklenmiştir. Fonksiyona, çapraz doğrulama sayısı k, “n_repeats” etiketi ile 10 olarak uygulanmıştır. Önem fonksiyonu her bir değişken için 10 adet önem skoru hesaplamış ve bu skorların ortalaması alınarak, “matplotlib” kütüphanesi yardımıyla bar grafiği çizdirilmiştir. Motor gücü parametresi için bar grafiği aşağıda gösterilmiştir. Aşağıdaki grafiklerde, değişkenlerin modele olan katkıları yani açıklama düzeyleri karşılaştırırken, modeldeki diğer değişkenlerin skor değerleri göz önünde bulundurulmuştur.



Şekil 5.4. Motor Gücünün Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları


Motor gücü parametresinin tahmininde kabin anma yükü ve kabin anma hızı parametrelerinin yüksek oranda etkisi vardır. Kabin kütlesi, seyir mesafesi ve halat birim kütlesi değişkenlerinin orta düzeyde, diğer altı değişkenin ise etkisi yok denecek kadar az etkisi olduğu söylenebilir.

Kabin hızı, halat sayısı, halat çapı, kanal açısı ve tahrik kasnağı çapı değişkenlerinin özellik önemine ait bar grafikleri aşağıda Şekil (5.5), (5.6), (5.7), (5.8) ve (5.9) ile gösterilmiş ve altlarında yorumlanmıştır.




Şekil 5.5. Kabin Hızı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları

Kabin hızı parametresinin tahmininde kabin anma yükü, seyir mesafesi ve motor gücü parametrelerinin yüksek oranda etkisi vardır. Diğer sekiz değişkenin etkisi oldukça düşüktür.




Şekil 5.6. Halat Sayısı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları

Halat sayısı parametresinin tahmininde kabin anma yükü yaklaşık 0,70 skor ile açıklayıcılık oranı en yüksek olan değişkendir. Kabin kütlesi ve tahrik kasnağı çapı parametresinin orta düzeyde etkisi vardır.




Şekil 5.7. Halat Çapı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları

Halat çapı parametresi ile halatın birim kütlesi arasında yaklaşık 0,70 skor ile çok yüksek bir ilişki vardır. En küçük kopma kuvvetinin açıklayıcılık oranı yaklaşık 0,25 ile orta derece olduğu söylenebilir.



Şekil 5.8. Kanal Açısı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları

Kanal açısı parametresi, halat türü ve kesme açısı parametreleri ile yaklaşık 0,30 skoru ile yüksek oranda ilişkilidir. Motorun yeri, askı şekli ve sarım tipi parametrelerinin kurulan modele etkisi yoktur. Diğer 11 parametrenin modele orta ve düşük seviyede etkisi vardır.



Şekil 5.9. Tahrik Kasnağı Çapı Tahmininde Kullanılan Parametrelerin Açıklayıcılık Oranları

Tahrik kasnağı çapı parametresi ile halat çapı arasında 0,37 skor değeri ile yüksek bir ilişki vardır. Halat birim kütlesi parametresinin açıklayıcılık oranı yaklaşık 0,15 ile orta seviyede olduğu söylenebilir.

6. SONUÇ

Bu çalışmada asansör sektöründeki montaj firmalarının asansör tasarımı ve üretimi aşamasında kullandıkları bulut bilişim temelli bir sistemin üzerinde çalışılmıştır. Bu sistemde kullanıcı deneyimlerinin artırılması için asansör parametrelerinin tahmininde kullanılmak üzere makine öğrenmesi algoritmaları geliştirilmiştir.

Kullanıcı deneyimi üzerine yapılmış önceki çalışmalar incelenmiş, araştırmanın önemi vurgulanmış ve makine öğrenmesi algoritmaları ile kullanıcı deneyiminin artırılmasının mümkün olduğu aktarılmıştır. Fakat yapılan araştırmalarda hâlen sistem tasarım süreçlerinde kullanıcı deneyimi ve makine öğrenimi uzmanlığı arasında bir diyalog eksikliğinin var olduğu sonucuna varılmıştır. Bu amaçla tahmin parametreleriyle tasarlanacak olan asansörlerin yapısı incelenmiş ve halat tahrikli asansörlerin ruhsat belgesinin çıkartılabilmesi için ihtiyaç duyulan asansör hesapları ve halat tahrikli asansörlerin önemli komponentleri açıklanmıştır.

Makine öğrenmesi algoritmaları ile asansör parametrelerinin tahmini üzerine bir uygulama yapılmıştır. Yapılan uygulamada motor gücü, halat sayısı, halat çapı, kabin beyan hızı, kanal açısı ve tahrik kasnağının çapı olmak üzere 6 adet parametre destek vektörleri, karar ağaçları, rassal orman, k en yakın komşu ve doğrusal regresyon olmak üzere beş model ile tahmin edilmiştir. Bu algoritmaların tahmin performansları karşılaştırılmış ve en yüksek başarı oranına sahip olan algoritma belirlenmiştir. Elde edilen sonuçlara göre, asansör parametrelerini en yüksek doğruluk oranıyla tahmin edebilen algoritma Rassal Orman Regresyon Tahmincisi seçilmiştir.

Toplamda 30 adet model uygulanmış ve model parametreleri ızgara arama yöntemi ile optimize edilerek skor başarı değerleri maksimize edilmiştir. Modellerin R^2 , MAPE, MSE ve MAE skor değerleri test ve eğitim veri setleri için ayrı ayrı tablolastırılmıştır. İlk olarak R^2 skorları karşılaştırıldığında RF modeli en düşük 0.72 ve en yüksek 0,99 oranıyla diğer modellere göre başarılı olmuştur. İkinci olarak MSE skorları karşılaştırıldığında RF modeli, en düşük 0,01 ve en yüksek 497,2 değeri ile diğer modellere göre başarılı olmuştur.

Montaj firmaları tarafından tasarım aşamasında ELEPORT web sitesi kullanılarak asansör parametreleri tahmin edilecektir. RF algoritması ile kurulan modeller, bulut üzerinde çalışan endüstriyel hesap portalı ELEPORT web sitesine aktarılmıştır.

Montaj firmalarının çalışma süreçlerinin verimliliğinin artırılması hedeflendiğinde, kullanıcı deneyimi önemli bir faktördür. Portalın kullanımı kolay olması, tasarımının

modern olması, veri giriş sırasında makine öğrenmesi tahminlerinin kullanılmasının pratikliği kullanıcılara yardımcı olarak kullanıcı deneyimini olumlu etkileyecektir. Bu sayede montaj süreci daha hızlı tamamlanabilecek ve doğru tahminler sayesinde firmaların maliyetleri azalacak veya zaman kaybı önlenecektir.

Makine öğrenmesi tahminlerinin site arayüzüne aktarılması konusunda farklı arayüz çalışmaları gerçekleştirilmiş ve kararlaştırılan arayüz çalışması detaylı olarak açıklanmıştır. Yapılan bütün çalışmalar ELEPORT web sitesine aktarıldıktan sonra asansör sektöründeki deneyimli montaj uzmanları ile görüşülmüş ve sistem hakkında olumlu dönütler alınmıştır.

Yapılan bütün tahminlerde tahmin edilmek istenen parametre veri setinden çıkarılarak bağımlı değişken, kalan parametreler ise bağımsız değişkenler olarak ele alınmıştır. Modelin çalıştırılabilmesi için kullanıcının bağımsız değişkenlere karşı gelen parametreleri doğru bir şekilde girilebilmesi için gerekli önlemler alınmış ve arayüz tasarımları buna göre gerçekleştirilmiştir. Ayrıca bağımsız değişkenlerin hangilerinin etkili olduğuna yönelik analizler de yapılmıştır. Bağımlı değişkenin daha az parametre ile tahmin edilmesi, kullanıcıya daha hızlı geri dönüş sağlama imkânı sunmaktadır. Bu sebeple daha az sayıda özellik kullanarak benzer başarı oranlarının elde edilip edilemeyeceği de araştırılmış ve hangi parametrelerin tahminde etkili olduğu sunulmuştur.

Bu çalışma, özel olarak asansör sektörü ile ilgili olsa da diğer sektörlerde ortaya çıkan benzer sistemlerde kullanılan arayüz parametrelerinin tahmininde de kullanılabilir. Bu anlamda önerilen yaklaşımın, süreçlerin verimliliğinin artırılmasına önemli düzeyde katkı sağlama potansiyeli söz konusudur.

Gelecekte, farklı algoritmaların karşılaştırılması ve bu algoritmaların performanslarının daha da iyileştirilmesi üzerine çalışmalar yapılabilir. Ayrıca sistemde kullanılan modeller yeni gelen verilerin kullanılması ile belirli bir yapı içerisinde tekrar eğitilebilir ve böylece “Uyarlanabilir (Adaptive) Öğrenme” yapısı oluşturulabilir.

KAYNAKÇA

- Ray, P. (2017). An Introduction to Dew Computing: Definition, Concept and Implications. Gangtok: IEEE.
- (2022, 11 30). Euronews: <https://tr.euronews.com/2022/11/30/isvecli-tir-ureticisi-scania-avrupada-otonom-tir-ile-ticari-mal-tasiyan-ilk-firma-oldu> adresinden alındı
- (2022, 11 10). Britannica: <https://www.britannica.com/biography/Elisha-Otis> adresinden alındı
- Acı, M., Avcı, M., & Acı, Ç. (2017). Destek vektör regresyonu yöntemiyle karbon nanotüp benzetim süresinin kısaltılması. Journal of the Faculty of Engineering and Architecture of Gazi University.
- Ahmed, T. (2018). Integrating Machine Learning into the UX Design Process. Washington: University of Baltimore, Division of Science, Information Arts, and Technologies.
- AI. (2022, 12 1). chatGPT. open AI: <https://chat.openai.com/chat> adresinden alındı
- AI vs. Machine Learning. (2022, 12 12). Columbia Engineering: <https://ai.engineering.columbia.edu/ai-vs-machine-learning/> adresinden alındı
- Aritan, T. (1994). Asansörlerin Projelendirilmesi Montajı İşletilmesi ve Bakımı Seminer Notları. İstanbul.
- Asansör. (2022, 11 15). Wikipedia: <https://tr.wikipedia.org/wiki/Asans%C3%B6r> adresinden alındı
- Asansör Kelimesi. (2022, 8 27). Nişanyan Sözlük: <https://www.nisanyansozluk.com/kelime/asans%C3%B6r> adresinden alındı
- Astim Toro. (2022, 12 25). Dişlisiz Makina Tahrik Kasnakları. Astim Toro: <http://astimtoro.com/urunlerimiz/dislisiz-makina-tahrik-kasnaklari/> adresinden alındı
- Ay, Ş. (2022, 12 10). Medium: <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1> adresinden alındı
- Aytekin, H. T. (2021, 6 15). Makine Öğreniminin Araştırmacıların Veri Analizi Bağlamında Potansiyel Önemi. Ufuk Üniversitesi, 1. Uluslararası Sosyal Bilimler Kongresi. Ankara: Ufuk Üniversitesi.
- Bulut Bilişim. (2022, 12 2). Wikipedia: https://tr.wikipedia.org/wiki/Bulut_bili%C5%9Fim adresinden alındı
- Buschek, D., Anlauff, C., & Lachner, F. (2021). Paper2Wire-A case study of user-centred development of machine learning tools for UX designers. I-com, s. 19-32.
- Cansız, H. (1998). Asansörlerin Bilgisayar Yardımıyla Çizimi. SAU Fen Bilimleri Enstitüsü Dergisi, 65-70.
- Chanklan, R., Kaoungku, N., Suksut, K., Kerdprasop, N., Suksut, K., & Kerdprasop, K. (2018, 2 1). Runoff prediction with a combined artificial neural network and support vector regression. International Journal of Machine Learning and Computing.

- Chromik, M., Lachner, F., & Butz, A. (2020). ML for UX? - An Inventory and Predictions on the Use of Machine Learning Techniques for UX Research. Proceedings of the 11th Nordic Conference on Human-Computer Interaction: Shaping Experiences, Shaping Society (s. 1-11). New York: Association for Computing Machinery.
- DD. (2022, 12 25). Asansör nasıl çalışır? Peki nasıl çalışır ? : <http://pekinasilcalisir.blogspot.com/2015/11/asansor-nasl-calsr.html> adresinden alındı
- Demirbağ, M. (2012). Hidrolik Asansörler. Asansör Sempozyumu Kurs Notları: Hidrolik Asansörlerde Test ve Muayene (s. 1-30). İzmir: TMMOB Elektrik Müh. Odası.
- Dove, G., Halskov, K., Forlizzi, J., & Zimmerman, J. (2017). UX Design Innovation: Challenges for Working with Machine Learning as a Design Material. Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems (s. 278-288). Colorado: Special Interest Group on Computer-Human Interaction.
- Elidolu, G. (2019). Gemiadamların Emniyetli Çalışma Davarışlarının Makine Öğrenmesi İle Tahminlenmesi Yüksek Lisans Tezi. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Deniz Ulaştırma Mühendisliği Anabilim Dalı Deniz Ulaştırma Mühendisliği Programı.
- Eren, M. (2022). İstanbul Metro Hatları için Makine Öğrenmesi ile Yolcu Sayılarının Tahminlenmesi Yüksek Lisans Tezi. Eskişehir: Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Yöneylem Araştırması Bilim Dalı.
- Eryiğit, M. (2012). Tahrik Sistemleri. Karabük: Academia.
- FEMA. (2019, 6 4). Elevator Installation. FEMA: https://www.fema.gov/sites/default/files/2020-07/fema_using-technical-bulletins_guide.pdf adresinden alındı
- IBM. (2022, 12 3). <https://www.ibm.com/topics/machine-learning> adresinden alındı
- İmrak, C., & Erdemligil, İ. (2000). Asansörler ve Yürüyen Merdivenler. İstanbul: Birsen Yayınevi.
- Intelligenza Artificiale: hanno vinto le Reti Neurali? (2022, 12 23). Akite: <https://www.akite.net/it/news/intelligenza-artificiale-hanno-vinto-le-reti-neuronal> adresinden alındı
- Kalcık, Y. (2020, 4). Türkiye'nin Asansör Tarihi. Yunus Kalcık: <https://yunuskalcik.net/turkiyenin-asansor-tarihi/#:~:text=M.%C3%96.,kulland%C4%B1%C4%9F%C4%B1%20konusund a%20baz%C4%B1%20%C5%9F%C3%BCpheler%20var.> adresinden alındı
- Kullanıcı Deneyimi. (2022, 11 20). Wikipedia: https://tr.wikipedia.org/wiki/Kullan%C4%B1c%C4%B1_deneyimi adresinden alındı
- Kullanıcı Deneyimi Eğitimi. (2022, 12 13). Zemin İstanbul: <https://zeministanbul.ist/tr/kullanici-deneyimi-egitimi/> adresinden alındı
- Küçük, Z. (2022, 12 6). Netflix Yapay Zeka İle Zihnimizi Yönetiyor. womaneng: <https://womaneng.com/netflix-yapayzeka/> adresinden alındı

- Mikail, P. (2022). Dağıtık Üretim Sistemlerinin Akıllı Şebekeler Üzerine Etkilerinin İncelenmesi, Doktora Tezi. İstanbul: İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Mühendisliği Anabilim Dalı Elektrik Mühendisliği Programı.
- Pekel, E. (2018). Farklı Makine Öğrenmesi Algoritmalarının Karşılaştırılması Yüksek Lisans Tezi. Samsun: Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Akıllı Sistemler Mühendisliği Anabilim Dalı.
- Pettersson, I., Lachner, F., Frison, A.-K., & Riener, A. (2018, 4). A Bermuda Triangle?: A Review of Method Application and Triangulation in User Experience Evaluation. Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems, s. 1–16.
- Raschka, S., & Mirjalili, V. (2015). Python Machine Learning (s. 23). içinde Pact Publishing.
- Robertson, H. (2022, 12 1). Medium: <https://bootcamp.uxdesign.cc/what-is-machine-learning-and-why-does-it-matter-for-ux-ui-designers-f0ce1498b2b2> adresinden alındı
- Sakarya, M. (2019). Seçilen Sigil Tedavi Yöntemlerinin Farklı Makine Öğrenmesi Algoritmaları İle Başarımının Tahmin Edilmesi. Zonguldak: Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Elektrik- Elektronik Müh. Anabilim Dalı Yüksek Lisans Tezi.
- Sankar, S., Amudha, S., Madhavan, P., & Lamba, D. (2020, 12 3-5). Personalized Dynamic User Interfaces. Yenilenebilir ve Sürdürülebilir Enerji Sistemlerindeki Gelişmeler Konferansı.
- Sarıbaş, Ü. (2006). Akıllı Bir Asansör Sisteminin Benzetimi. Ankara: Yüksek Lisans Tezi Gazi Üniversitesi Fen Bilimleri Enstitüsü.
- Sığırcı, M. (2021, 2 20). Asansör. Tübitak: <https://bilimgenc.tubitak.gov.tr/makale/asansor-kim-ne-zaman-icat-etti> adresinden alındı
- Srivastava, A. (2021). Developing Functional Literacy of Machine Learning Among UX Design Students. Ohio: Univ. Cincinnati, Master's Thesis.
- Şapçı, B., & Taşlı Pektaş, Ş. (2021, 3 31). Makine Öğrenmesi Aracılığı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Süreçleriyle Bütünleştirilmesi. DergiPark Akademik.
- Tavaslıoğlu, S. (2005). Asansör Uygulamaları. İzmir: Final Matbaacılık ve Ticaret.
- Türk Srtandarları Enstitüsü. (2021). ISO 8100-32 : İnsanların ve malların taşınması için asansörler - Bölüm 32: Ofis, otel ve konut binalarına kurulacak yolcu asansörlerinin planlanması ve seçimi. Ankara: TSE.
- Türk Standartları Enstitüsü. (2020). TS EN 81 20: 2020- Asansörlerin yapım ve kurulumu için güvenlik kuralları - İnsan ve eşyanın taşınması için asansörler - Bölüm 20: İnsan ve eşya asansörleri. Ankara: TSE.
- Türkalp, M. V. (2019). Twitter Verileri Üzerinde Sınıflandırma Algoritmaları Kullanarak Hisse Senedi Değerleri İçin Yön Tahmini Yüksek Lisans Tezi. Konya: Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Mühendisliği Anabilim Dalı.

- User Experience Design. (2022, 12 1). [https://www.interaction-design.org/literature/topics/ux-design#:~:text=User%20experience%20\(UX\)%20design%20is,%2C%20design%2C%20usability%20and%20function](https://www.interaction-design.org/literature/topics/ux-design#:~:text=User%20experience%20(UX)%20design%20is,%2C%20design%2C%20usability%20and%20function). adresinden alındı
- User Experince. (2022, 12 15). Sortext: <https://sortext.com/ecommerce-glossary> adresinden alındı
- Vapnik, V. (2013). The Nature of Statistical Learning Theory. Springer.
- Winter , M., & Jackson , P. (2020). Flatpack ML: How to Support Designers in Creating a New Generation of Customizable Machine Learning Applications. Design, User Experience, and Usability. Design for Contemporary Interactive Environments (s. 175-193). Brighton: Springer.
- Yang, Q. (2017). The Role of Design in Creating Machine-Learning-Enhanced User. Proceedings Conference on Artificial Intelligence, s. 1-6.
- Yönel Asansör. (2022, 12 30). Asansör Makine Motorları. Yönel Asansör: <https://yonelasansor.com/asansor-makine-motorlari/> adresinden alındı
- Yürekli, A. (2019). Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzu. Eskişehir Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, 1-12.

ÖZGEÇMİŞ

ORCID NO: 0000-0002-0148-1198

Ad Soyad : Burak DEMİREL

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2023, Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstatistik Bölümü, İstatistik Anabilim Dalı
- 2021, Full-Stack Developer, İncir Ar-Ge San. ve Tic. Ltd. Şti.
- 2019, Eskişehir Osmangazi Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü