



İş Yükü Otomasyon Platformu Verileri
Üzerinden Yapay Zeka Destekli Analiz:
Automatic (UC4) Kullanarak İş
İstatistiklerinin ve Job Verilerinin
Değerlendirilmesi

Yazılım Mühendisliği Ana Bilim Dalı

Yüksek Lisans Projesi

Cem Argunşah

Proje Danışmanı: Dr. Öğr. Üyesi Mansur Alp Toçoğlu

Haziran 2024

İş Yüğü Otomasyon Platformu Verileri Üzerinden Yapay Zeka Destekli Analiz: Automic (UC4) Kullanarak İş İstatistiklerinin ve Job Verilerinin Değerlendirilmesi

Öz

Bu proje, İş Yüğü Otomasyon Platformu verileri üzerinden yapay zeka destekli analizler yapmayı amaçlamaktadır. Çalışmada, Automic (UC4) 12.3 versiyonunun OH ve AH tablolarından elde edilen veriler kullanılarak, iş istatistiklerinin ve iş verilerinin değerlendirilmesi gerçekleştirilecektir. Proje kapsamında, OH ve AH tablolarından alınan veriler iki ayrı CSV dosyasında bulunmaktadır. Bu veriler kullanılarak, iş yüklerinin zamanlamaları, durumları ve diğer ilgili parametreler üzerinde detaylı analizler yapılacaktır.

Projede, Python programlama dili kullanılarak çeşitli yapay zeka algoritmaları ve veri analitiğı teknikleri uygulanacaktır. Bu kapsamda, iş yükü zamanlamaları, iş başarı oranları, hata oranları gibi metrikler değerlendirilecek ve bu metriklerin iş süreçlerine olan etkileri incelenecektir. Ayrıca, kullanıcı davranışlarının analiz edilmesi, iş yükü tahminleri ve optimizasyon önerileri sunulması hedeflenmektedir. Çalışma, iş yükü otomasyon platformlarının verimli kullanımını arttırmaya yönelik pratik öneriler geliştirmeyi amaçlamaktadır.

Sonuç olarak, bu proje, Automic (UC4) platformu üzerinden elde edilen verilerle iş yükü yönetiminde yapay zekanın rolünü inceleyerek, organizasyonların iş süreçlerini daha verimli hale getirmelerine katkı sağlayacak öneriler sunmaktadır.

Anahtar Sözcükler: İş Yüğü Otomasyonu, Yapay Zeka, Veri Analizi, Automic UC4, Python, İş İstatistikleri

Artificial Intelligence Supported Analysis on Workload Automation Platform Data: Evaluating Job Statistics and Job Data Using Automic (UC4)

Abstract

This project aims to conduct AI-supported analyses on workload automation platform data. By utilizing data from the OH and AH tables of Automic (UC4) version 12.3, the project evaluates job statistics and job data. The data extracted from the OH and AH tables are available in two separate CSV files. Using this data, detailed analyses will be conducted on job timings, statuses, and other relevant parameters.

The project will apply various artificial intelligence algorithms and data analytics techniques using the Python programming language. This includes evaluating metrics such as job timings, job success rates, and error rates, and examining their impact on business processes. Additionally, the analysis of user behaviors, workload predictions, and optimization suggestions will be explored. The study aims to develop practical recommendations to enhance the efficient use of workload automation platforms.

In conclusion, this project investigates the role of artificial intelligence in workload management using data obtained from the Automic (UC4) platform, providing suggestions that help organizations improve their business processes more efficiently.

Keywords: Workload Automation, Artificial Intelligence, Data Analysis, Automic UC4, Python, Job Statistics

Bu projedeki çalışmalarımnda desteklerini esirgemeyen ve yanımda olan aileme ve danışman hocam Dr. Öğr. Üyesi Mansur Alp Toçođlu'na teşekkür ediyorum.

İçindekiler

1. Giriş	2
2. Literatür Taraması	4
2.1 İş Yüğü Otomasyon Platformları	4
2.1.1 İş Yüğü Otomasyonunun Tanımı ve Önemi	4
2.1.2 Tarihsel Gelişim ve Günümüzdeki Durum	4
2.1.3 Automic (UC4) Platformu	5
2.2 İş Yüğü Otomasyon Platformları	5
2.2.1 OH ve AH Tablolarının İncelenmesi	5
2.2.2 Veri Temizleme ve Hazırlama	6
2.2.3 İş Yüğü Zamanlamaları ve Başarı Oranları	6
2.2.4 Hata Oranlarının Analizi	6
2.2.5 Kullanıcı Davranışlarının Analizi	7
2.3 İş Yüğü Otomasyon Platformları	7
2.3.1 Makine Öğrenmesi ile İş Yüğü Tahmini	7
2.3.2 Optimizasyon Teknikleri ve Uygulamaları	7
2.3.3 Kullanıcı Davranışlarının Analizi	8
2.3.4 Yapay Zeka Modellerinin Geliştirilmesi	8
2.4 İş Yüğü Otomasyon Platformları	8
2.4.1 İş Yüğü Otomasyonu ve Yapay Zeka Alanındaki Çalışmalar	8
2.4.2 Başarı Hikayeleri ve Gerçek Dünya Uygulamaları	9
2.4.3 İş Yüğü Otomasyonu ve Yapay Zeka Kapsamında Yapılan Diğer Çalışmalar	11

2.5	İş Yüğü Otomasyonunun Geleceęi ve Gelişen Trendler	12
2.5.1	Bulut Bilişim ve İş Yüğü Otomasyonu	12
2.5.2	Yapay Zeka ve Makine Öğrenmesindeki Yenilikler	12
2.5.3	Nesnelerin İnterneti (IoT) ve Endüstri 4.0	13
2.5.4	Robotik Süreç Otomasyonu (RPA)	13
2.5.5	Büyük Veri ve Analitik	14
2.5.6	Siber Güvenlik ve Veri Koruma.....	14
2.6	İş Yüğü Otomasyonunda Karşılaşılan Zorluklar ve Çözümler.....	15
2.6.1	Entegrasyon Zorlukları	15
2.6.2	Veri Kalitesi ve Yönetimi.....	16
2.6.3	Güvenlik ve Veri Koruma	16
2.6.4	İnsan Kaynakları ve Eğitim	17
2.6.5	Ölçeklenebilirlik ve Performans Yönetimi.....	17
2.7	İş Yüğü Otomasyonu ve Yapay Zeka: Vaka Çalışmaları	18
2.7.1	Amazon'un Lojistik Otomasyonu	18
2.7.2	Netflix'in İçerik Öneri Sistemi.....	18
2.7.3	GE Aviation'in Motor Bakım Otomasyonu	18
2.7.4	UPS'in Rota Optimizasyonu	19
2.7.5	IBM Watson'ın Sağlık Hizmetleri Uygulamaları	19
2.7.6	Ford'un Üretim Otomasyonu	19
3.	Yöntem.....	21
3.1	İş Yüğü Tahmin ve Optimizasyonu Projesi.....	22
3.1.1	Projenin Amacı ve Kapsamı	22
3.1.2	Veri Temizleme ve Ön İşleme.....	23

3.1.3	Özellik Mühendisliği	23
3.1.4	Makine Öğrenmesi	24
3.1.5	Optimizasyon Algoritmaları	24
3.1.6	Proje Uygulaması ve Grafiklerle Gösterim	25
3.1.7	Sonuçlar ve Değerlendirme	25
3.2	İş Başarı ve Hata Analizi Projesi	26
3.2.1	Projenin Amacı ve Kapsamı	26
3.2.2	Veri Temizleme ve Ön İşleme.....	26
3.2.3	İş Başarı ve Hata Oranlarının Hesaplanması	27
3.2.4	Kümeleme ve Sınıflandırma.....	27
3.2.5	İyileştirme Önerileri	28
3.2.6	Sonuçlar ve Değerlendirme	28
3.3	Kullanıcı Davranış Analizi Projesi	29
3.3.1	Projenin Amacı ve Kapsamı	29
3.3.2	Veri Temizleme ve Ön İşleme.....	29
3.3.3	Kullanıcı Segmentasyonu	30
3.3.4	Davranış Analizi	30
3.3.5	Optimizasyon ve Öneriler.....	31
3.3.6	Sonuçlar ve Değerlendirme	31
3.4	Anomali Tespiti Projesi	32
3.4.1	Projenin Amacı ve Kapsamı	32
3.4.2	Veri Temizleme ve Ön İşleme.....	32
3.4.3	Özellik Mühendisliği	33
3.4.4	Anomali Tespiti Algoritmalar	33
3.4.5	Sonuçların Değerlendirilmesi	35
3.4.6	Sonuçlar ve Değerlendirme	35
4.1	İş Yüğü Tahmin ve Optimizasyonu	36

4.2	İş Başarı ve Hata Analizi	36
4.3	Kullanıcı Davranış Analizi	37
4.4	Anomali Tespiti	37
4.5	Genel Değerlendirme ve Öneriler	37

Şekiller Tablosu

Şekil 1 - AH tablosu örnek verisi	21
Şekil 2 - OH tablosu örnek verisi	22
Şekil 3- Proje 1. Veri temizleme ve ön işleme kodları	23
Şekil 4- Proje 1. Özellik mühendisliği kodları	23
Şekil 5- Proje 1. Makine Öğrenmesi kodları	24
Şekil 6- Proje 1. Optimizasyon algoritma kodları	24
Şekil 7- Proje 1. Grafik gösterim kodları.....	25
Şekil 8- İş Yükü Tahmin ve Optimizasyonu Projesi Model Başarısı	26
Şekil 9- Proje 2. Veri temizleme ve ön işleme kodları	27
Şekil 10- Proje2. İş başarı ve hata oranları hesaplama kodları.....	27
Şekil 11- Proje2. Kümeleme ve sınıflandırma kodları	28
Şekil 12- Proje 2. İyileştirme önerileri kodları	28
Şekil 13 - İş Başarı ve Hata Analizi Projesi Kümeleme Sonucu Grafiği.....	29
Şekil 14 - Proje3. Veri temizleme ve ön işleme kodları	30
Şekil 15- Proje 3. Kullanıcı segmentasyonu kodları	30
Şekil 16- Proje 3. Davranış analizi kodları	30
Şekil 17- Proje 3. Optimizasyon ve öneri kodları.....	31
Şekil 18- Kullanıcı Davranış Analizi Projesi Kullanıcı Segmentasyon Grafiği	32
Şekil 19- Proje 4. Veri temizleme ve ön işleme kodları	33
Şekil 20- Proje 4. Özellik mühendisliği kodları	33
Şekil 21- Proje4. Anomali tespiti algoritmaları kodları.....	34
Şekil 22- Proje 4. Sonuçların değerlendirilmesi kodları.....	35
Şekil 23- Anomali Tespiti Projesi Isolation Forest ve One-Class SVM çıktıları	35

1.Giriş

Dijital dönüşüm çağında, işletmelerin verimli ve etkili bir şekilde çalışabilmesi için iş süreçlerinin otomasyonu kritik bir öneme sahiptir. İş yükü otomasyon platformları, bu süreçlerin yönetilmesi ve optimize edilmesi noktasında önemli bir rol oynamaktadır. Özellikle büyük ölçekli işletmelerde, yüzlerce hatta binlerce iş yükünün zamanında ve doğru bir şekilde tamamlanması, iş süreçlerinin kesintisiz devam etmesi için gereklidir. İş yükü otomasyon platformları bu noktada devreye girerek, iş süreçlerini otomatikleştirir, izler ve optimize eder.

Automic (UC4), iş yükü otomasyonunda yaygın olarak kullanılan güçlü bir platformdur. Bu platform, kullanıcıların iş süreçlerini otomatikleştirmelerine, izlemelerine ve optimize etmelerine olanak tanır. Automic, çeşitli iş yüklerinin yönetilmesi ve izlenmesi için kapsamlı araçlar sunar. Bu araçlar sayesinde, iş süreçleri daha verimli bir şekilde yönetilebilir ve iş sürekliliği sağlanabilir. Ancak, iş yükü otomasyon platformlarının verimli bir şekilde kullanılabilmesi için, bu platformlar üzerinden elde edilen verilerin detaylı bir şekilde analiz edilmesi gerekmektedir.

Bu proje, Automic (UC4) platformu üzerinden elde edilen verilerin yapay zeka destekli analizlerini gerçekleştirmeyi amaçlamaktadır. Çalışma kapsamında, Automic (UC4) 12.3 versiyonunun OH ve AH tablolarından elde edilen veriler kullanılacaktır. Bu veriler, iş yüklerinin zamanlamaları, durumları ve diğer ilgili parametreler hakkında detaylı bilgiler içermektedir. Proje, bu verileri kullanarak iş yükü zamanlamaları, iş başarı oranları, hata oranları gibi metriklerin analizini gerçekleştirecek ve bu metriklerin iş süreçlerine olan etkilerini inceleyecektir.

Projede kullanılacak olan yapay zeka algoritmaları ve veri analitiği teknikleri, Python programlama dili kullanılarak uygulanacaktır. Python, veri analizi ve yapay zeka alanında geniş bir kütüphane ve araç seti sunan güçlü bir programlama dilidir. Bu sayede, iş yükü verilerinin analizi ve yorumlanması daha etkin bir şekilde gerçekleştirilebilecektir. Ayrıca, proje kapsamında geliştirilecek olan yapay zeka modelleri, iş yükü tahminleri ve optimizasyon önerileri sunarak, iş süreçlerinin daha verimli hale getirilmesine katkı sağlayacaktır.

Bu alıřmanın amacı, iř yk otomasyon platformlarının verimli kullanımını artırmak ve iřletmelere pratik neriler sunmaktır. İř yk verilerinin detaylı analizi ve yapay zeka destekli deęerlendirmeleri, iřletmelerin iř srelerini optimize etmelerine ve daha verimli hale getirmelerine yardımcı olacaktır. Ayrıca, bu alıřma, iř yk otomasyonu ve yapay zeka alanında yapılacak olan gelecekteki arařtırmalar iin bir temel oluřturmayı amalamaktadır.

2.Literatür Taraması

2.1 İş Yükü Otomasyon Platformları

2.1.1 İş Yükü Otomasyonunun Tanımı ve Önemi

İş yükü otomasyonu, çeşitli iş süreçlerini ve işlemleri otomatikleştirerek yönetme sürecidir. Bu otomasyon, sanal ve bulut ortamlarında yaygın olarak kullanılır. İş yükü otomasyonu, işletmelere tüm iş süreçlerini merkezi olarak yönetme imkanı sunar, böylece işlemler arasındaki gecikmeler ve hatalar azaltılır. İş yükü otomasyonu, işletmelerin operasyonel maliyetlerini azaltırken verimliliği artırır ve manuel müdahaleleri en aza indirir (Rouse, 2014; SUSE, 2024).

2.1.2 Tarihsel Gelişim ve Günümüzdeki Durum

İş yükü otomasyon platformlarının tarihsel gelişimi, 1960'lı yıllarda mainframe bilgisayarların yaygınlaşmasıyla başlamıştır. İlk otomasyon sistemleri, temel olarak zamanlanmış görevleri yönetmek için tasarlanmış basit yazılımlar içeriyordu. 1980'li yıllarda, bilgisayar ağlarının ve kişisel bilgisayarların gelişimi ile birlikte, daha karmaşık iş yükü otomasyon sistemleri geliştirildi (Davies, 2017).

Günümüzde, iş yükü otomasyon platformları, bulut bilişim ve büyük veri teknolojileri ile entegre edilerek daha da gelişmiş ve yaygın hale gelmiştir (Nguyen, 2019). Modern iş yükü otomasyon platformları, sadece zamanlanmış görevleri yönetmekle kalmayıp, aynı zamanda iş süreçlerini optimize etmek ve veri analitiği ile desteklemek için gelişmiş özellikler sunmaktadır (Lopez & Turner, 2020).

2.1.3 Automic (UC4) Platformu

Automic (UC4), iş yükü otomasyonu alanında önde gelen platformlardan biridir. Automic, kullanıcıların iş süreçlerini otomatikleştirmelerine, izlemelerine ve optimize etmelerine olanak tanır. Automic (UC4), geniş bir kullanıcı kitlesi tarafından tercih edilmekte olup, bankacılık, finans, sağlık ve perakende gibi çeşitli sektörlerde yaygın olarak kullanılmaktadır. Bu platformun öne çıkan özellikleri arasında iş süreçlerinin görselleştirilmesi, çoklu platform desteği, esnek zamanlama ve güçlü entegrasyon yetenekleri bulunmaktadır (Automic Software Inc., 2022).

Automic (UC4), diğer iş yükü otomasyon platformlarından farklı olarak, kullanıcı dostu arayüzü ve geniş özelleştirme seçenekleri ile dikkat çekmektedir. Platform, iş süreçlerinin her aşamasında detaylı izleme ve raporlama imkanı sunar. Bu sayede, kullanıcılar iş süreçlerinin her anını izleyebilir ve olası sorunları hızlı bir şekilde tespit edip çözebilirler. Automic'in sağladığı bu yüksek düzeydeki kontrol ve esneklik, işletmelerin iş süreçlerini daha verimli ve etkili bir şekilde yönetmelerine olanak tanır (Morgan, 2021).

Automic (UC4) ayrıca, geniş entegrasyon yetenekleri ile dikkat çekmektedir. Platform, ERP sistemleri, bulut hizmetleri, veritabanları ve diğer iş uygulamaları ile sorunsuz bir şekilde entegre olabilir. Bu entegrasyon yetenekleri, işletmelerin mevcut altyapılarını en üst düzeyde kullanmalarına ve iş süreçlerini daha bütüncül bir şekilde yönetmelerine olanak tanır. Ayrıca, Automic'in sunduğu API ve diğer entegrasyon araçları, kullanıcıların ihtiyaçlarına göre özelleştirilmiş çözümler geliştirmelerine imkan tanır (Thompson, 2020).

2.2 İş Yükü Otomasyon Platformları

2.2.1 OH ve AH Tablolarının İncelenmesi

Automic (UC4) platformunda, iş yükü otomasyon verileri genellikle OH ve AH tablolarında saklanır. OH tablosu, iş yükü tanımları ve iş süreçlerine ilişkin meta

verileri içerir. AH tablosu ise iş yüklerinin çalıştırılma kayıtlarını ve sonuçlarını tutar. Bu tablolar, iş yükü otomasyonunun nasıl yönetildiğine ve optimize edildiğine dair değerli bilgiler sağlar. OH ve AH tablolarının yapısının ve içeriğinin anlaşılması, bu verilerin etkin bir şekilde analiz edilmesi için kritik öneme sahiptir (Automic Software Inc., 2022).

2.2.2 Veri Temizleme ve Hazırlama

Veri analizinin ilk adımı, verilerin temizlenmesi ve analize hazır hale getirilmesidir. Bu süreç, eksik verilerin yönetimi, veri normalizasyonu ve veri dönüştürme gibi adımları içerir. Eksik verilerin doğru şekilde ele alınması, analiz sonuçlarının doğruluğunu ve güvenilirliğini artırır (Han, Kamber, & Pei, 2011). Veri normalizasyonu, verilerin ortak bir ölçeğe getirilmesi işlemi olup, özellikle makine öğrenmesi modellerinde önemli bir adımdır. Veri dönüştürme ise verilerin daha kolay analiz edilebilir hale getirilmesi amacıyla gerçekleştirilir (Williams, 2021).

2.2.3 İş Yükü Zamanlamaları ve Başarı Oranları

İş yükü zamanlamalarının analizi, iş süreçlerinin etkinliğini değerlendirmek için kritik öneme sahiptir. Bu analiz, iş yüklerinin ne zaman başlatıldığı, ne kadar sürede tamamlandığı ve belirlenen zaman dilimlerinde tamamlanıp tamamlanmadığı gibi bilgileri içerir. Başarı oranlarının hesaplanması ise iş yüklerinin ne kadarının başarıyla tamamlandığını belirler. Bu metrikler, iş süreçlerinin verimliliğini ve güvenilirliğini ölçmek için kullanılır (Smith, 2020).

2.2.4 Hata Oranlarının Analizi

Hata oranlarının analizi, iş süreçlerinde meydana gelen aksaklıkların tespit edilmesi ve bu aksaklıkların minimize edilmesi için önemlidir. Hata oranları, iş yüklerinin başarısızlıkla sonuçlanma sıklığını gösterir. Bu oranların yüksek olması, iş süreçlerinde iyileştirme gerektiren alanların varlığına işaret eder. Hata oranlarının azaltılması için öneriler ve stratejiler geliştirilmesi, iş süreçlerinin genel verimliliğini artırabilir (Nguyen, 2019).

2.2.5 Kullanıcı Davranışlarının Analizi

Kullanıcı davranışlarının analizi, iş yükü otomasyon platformlarının daha etkin kullanılmasına yardımcı olabilir. Kullanıcıların iş yüklerini nasıl oluşturduğu, yönettiği ve izlediği gibi davranışlar, iş süreçlerinin verimliliğini etkileyebilir. Veri madenciliği teknikleri kullanılarak, kullanıcı davranışlarının analizi yapılabilir ve bu analiz sonuçlarına göre kullanıcıların performansını artıracak öneriler sunulabilir (Smith, 2020).

2.3 İş Yükü Otomasyon Platformları

2.3.1 Makine Öğrenmesi ile İş Yükü Tahmini

Makine öğrenmesi (ML), iş yükü tahmini ve yönetiminde önemli bir rol oynamaktadır. Zaman serisi analizi ve tahmin modelleri, iş yükü zamanlamalarını ve gelecekteki iş yüklerini tahmin etmek için yaygın olarak kullanılır. ARIMA (AutoRegressive Integrated Moving Average) ve Recurrent Neural Networks (RNN) gibi modeller, geçmiş verileri analiz ederek gelecekteki eğilimleri tahmin edebilir. Bu tahminler, işletmelerin iş yükü planlamasını optimize etmelerine ve kaynaklarını daha verimli kullanmalarına yardımcı olur (Box, Jenkins, & Reinsel, 2015; Hochreiter & Schmidhuber, 1997).

2.3.2 Optimizasyon Teknikleri ve Uygulamaları

Optimizasyon teknikleri, iş yükü yönetiminde verimliliği artırmak için kullanılır. Genetik algoritmalar ve Simulated Annealing, iş yüklerinin en uygun şekilde dağıtılmasını ve yönetilmesini sağlar (Holland, 1992; Kirkpatrick, Gelatt, & Vecchi, 1983). Bu teknikler, işletmelerin iş süreçlerini daha etkin hale getirmelerine yardımcı olur. Optimizasyon sonuçları, iş süreçlerine doğrudan uygulanarak verimlilik artışı sağlar ve operasyonel maliyetleri düşürür (Mitchell, 1998).

2.3.3 Kullanıcı Davranışlarının Analizi

Kullanıcı davranışlarının analizi, iş yükü otomasyon platformlarının performansını artırmada önemli bir rol oynar. Kullanıcıların iş yüklerini nasıl oluşturduğu, yönettiği ve izlediği gibi davranışlar, iş süreçlerinin verimliliğini doğrudan etkileyebilir. Veri madenciliği teknikleri kullanılarak, kullanıcı davranışlarının analizi yapılabilir ve bu analiz sonuçlarına göre kullanıcıların performansını artıracak öneriler sunulabilir (Han, Kamber, & Pei, 2011). Kullanıcı davranışlarının analizi, kullanıcı eğilimlerini ve potansiyel sorunları belirlemeye yardımcı olarak, iş yükü yönetiminde daha iyi stratejiler geliştirilmesini sağlar (Nguyen, 2019).

2.3.4 Yapay Zeka Modellerinin Geliştirilmesi

Yapay zeka (YZ) modelleri, iş yükü yönetimini ve optimizasyonunu daha etkili hale getirmek için geliştirilir. Makine öğrenmesi ve derin öğrenme algoritmaları, iş yükü verilerini analiz ederek tahmin ve optimizasyon modelleri oluşturur. Bu modeller, işletmelerin gelecekteki iş yüklerini tahmin etmelerine ve kaynaklarını daha verimli kullanmalarına yardımcı olur (Goodfellow, Bengio, & Courville, 2016). YZ modelleri, iş yükü otomasyon platformlarının performansını artırarak, işletmelerin iş süreçlerini daha verimli ve etkili bir şekilde yönetmelerine olanak tanır (James et al., 2013).

2.4 İş Yükü Otomasyon Platformları

2.4.1 İş Yükü Otomasyonu ve Yapay Zeka Alanındaki Çalışmalar

İş yükü otomasyonu ve yapay zeka alanında yapılan araştırmalar, bu teknolojilerin iş süreçlerini nasıl dönüştürdüğünü ve verimliliği artırdığını göstermektedir. Morabito (2015) tarafından yapılan bir çalışma, iş yükü otomasyonunun işletmelerdeki

operasyonel verimliliği nasıl artırdığını ve maliyetleri nasıl düşürdüğünü incelemiştir. Bu çalışma, otomasyonun tekrarlayan görevleri ortadan kaldırarak çalışanların daha stratejik görevlere odaklanmasına olanak tanıdığını göstermektedir. Özellikle büyük veri analitiği ve iş zekası sistemleri ile entegre edilen iş yükü otomasyonu, işletmelerin daha hızlı ve doğru kararlar almasına yardımcı olmaktadır.

Nguyen ve arkadaşları (2019), yapay zekanın iş yükü yönetiminde nasıl kullanıldığını ve iş süreçlerinin optimize edilmesinde ne kadar etkili olduğunu analiz etmişlerdir. Bu çalışma, makine öğrenmesi ve yapay zeka tekniklerinin iş yükü tahmini ve optimizasyonunda kritik bir rol oynadığını ortaya koymaktadır. Yapay zeka, iş yükü otomasyonunda görevlerin zamanlanması, kaynak tahsisi ve önceliklendirme gibi karmaşık süreçlerde insan müdahalesini en aza indirir, bu da verimlilik ve doğruluk sağlar. Örneğin, zaman serisi analizi ve tahmin modelleri kullanılarak gelecekteki iş yükleri tahmin edilebilir ve bu tahminler ışığında kaynak planlaması yapılabilir (Hochreiter & Schmidhuber, 1997).

Bir diğer önemli çalışma, Zhang ve arkadaşları (2017) tarafından yapılmıştır. Bu çalışma, yapay zekanın iş yükü otomasyonundaki rolünü ve çeşitli endüstrilerdeki uygulamalarını incelemiştir. Yazarlar, yapay zeka ve otomasyonun üretim süreçlerindeki verimliliği artırdığını ve maliyetleri düşürdüğünü vurgulamaktadır. Özellikle akıllı fabrika konseptinde, makine öğrenmesi ve nesnelerin interneti (IoT) teknolojileri ile entegre edilen otomasyon sistemleri, üretim hatlarındaki kesintileri ve hataları minimize etmektedir. Bu, endüstri 4.0 çerçevesinde yapay zekanın üretim süreçlerine entegrasyonunun önemini vurgulamaktadır (Davenport&Ronanki, 2018).

2.4.2 Başarı Hikayeleri ve Gerçek Dünya Uygulamaları

İş yükü otomasyonu ve yapay zeka kullanımı ile elde edilen başarı hikayeleri, bu teknolojilerin gerçek dünya uygulamalarında ne kadar etkili olduğunu göstermektedir. Amazon, iş yükü otomasyonunu kullanarak lojistik süreçlerini optimize etmiş ve müşteri siparişlerinin daha hızlı ve hatasız bir şekilde yerine getirilmesini sağlamıştır (Dastin, 2017). Amazon'un kullandığı yapay zeka algoritmaları, depo yönetimi ve dağıtım süreçlerinde büyük bir verimlilik artışı sağlamıştır. Özellikle Kiva robotları ile yapılan otomasyon, depo operasyonlarını hızlandırmış ve insan hatalarını minimuma

indirmiştir. Bu, Amazon'un lojistikte verimliliği artırarak maliyetleri düşürmesine ve müşteri memnuniyetini artırmasına yardımcı olmuştur.

Benzer şekilde, Netflix, yapay zeka ve makine öğrenmesi kullanarak kullanıcı davranışlarını analiz etmiş ve içerik öneri sistemlerini optimize etmiştir. Bu sayede, kullanıcı memnuniyetini artırarak abone sayısında önemli bir artış elde etmiştir (Gomez-Urbe & Hunt, 2016). Netflix'in öneri algoritmaları, kullanıcıların izleme alışkanlıklarına göre kişiselleştirilmiş içerik önerileri sunarak, platformda geçirilen süreyi ve kullanıcı bağlılığını artırmıştır. Bu, Netflix'in yapay zeka kullanımının işletme başarısına doğrudan katkı sağladığını göstermektedir. Netflix'in algoritmaları, kullanıcı verilerini analiz ederek gelecekteki izleme alışkanlıklarını tahmin etmekte ve bu tahminlere göre içerik önerileri sunmaktadır.

GE Aviation, uçak motorlarının bakım süreçlerini optimize etmek için yapay zeka ve iş yükü otomasyonu kullanmıştır. Bu sistemler, sensör verilerini analiz ederek motor performansını izlemekte ve bakım ihtiyaçlarını önceden tahmin etmektedir. Bu sayede, beklenmedik arızalar azalmakta ve bakım süreçleri daha verimli hale gelmektedir (GE Aviation, 2018). GE Aviation'ın dijital dönüşüm stratejisi, yapay zeka ve büyük veri analitiği ile desteklenen bir bakım ve operasyon yönetim sistemi geliştirmiştir. Bu sistem, uçak motorlarının performansını izleyerek bakım süreçlerini optimize etmekte ve operasyonel verimliliği artırmaktadır.

Diğer bir örnek olarak, UPS, dağıtım süreçlerini optimize etmek için yapay zeka ve makine öğrenmesi kullanmaktadır. UPS, ORION (On-Road Integrated Optimization and Navigation) adlı bir sistem kullanarak, günlük dağıtım rotalarını optimize etmektedir. Bu sistem, her gün milyonlarca veri noktasını analiz ederek en verimli rotaları belirlemekte ve böylece yakıt tüketimini ve karbon emisyonlarını azaltmaktadır (UPS, 2017). ORION sistemi, sürücülerin günlük rotalarını optimize ederek teslimat sürelerini kısaltmakta ve operasyonel maliyetleri düşürmektedir.

2.4.3 İş Yükü Otomasyonu ve Yapay Zeka Kapsamında Yapılan Diğer Çalışmalar

Davenport ve Ronanki (2018) yapay zeka uygulamalarının iş süreçlerini nasıl dönüştürdüğünü ve işletmelere sağladığı stratejik avantajları incelemiştir. Çalışmalarında, yapay zekanın müşteri hizmetleri, tedarik zinciri yönetimi ve finansal analiz gibi çeşitli alanlarda nasıl kullanıldığını ve bu uygulamaların işletmelere nasıl değer kattığını ortaya koymuşlardır. Örneğin, yapay zeka destekli chatbotlar, müşteri hizmetlerinde hızlı ve etkili çözümler sunarak müşteri memnuniyetini artırmaktadır. Chatbotlar, müşteri sorularını anında yanıtlayarak ve sorunları hızlı bir şekilde çözüme kavuşturarak, müşteri hizmetleri temsilcilerinin yükünü azaltmaktadır.

Kumar ve arkadaşları (2020), yapay zekanın lojistik ve tedarik zinciri yönetiminde kullanımını ele almıştır. Yapay zeka, talep tahmini, envanter yönetimi ve rota optimizasyonu gibi kritik süreçlerde kullanılarak lojistik operasyonlarının verimliliğini artırmaktadır. Çalışmada, yapay zeka algoritmalarının tedarik zincirindeki belirsizlikleri ve riskleri azaltmada ne kadar etkili olduğu vurgulanmaktadır. Örneğin, yapay zeka destekli talep tahmini modelleri, geçmiş satış verilerini analiz ederek gelecekteki talep eğilimlerini tahmin etmekte ve bu sayede envanter yönetiminde daha doğru kararlar alınmasını sağlamaktadır.

Başka bir çalışma, Smith ve arkadaşları (2021) tarafından gerçekleştirilmiştir. Bu çalışma, yapay zekanın sağlık sektöründe nasıl kullanıldığını ve iş süreçlerini nasıl optimize ettiğini incelemiştir. Yapay zeka, hasta verilerini analiz ederek teşhis ve tedavi süreçlerini iyileştirmekte, sağlık hizmetlerinin kalitesini artırmakta ve maliyetleri düşürmektedir. Örneğin, yapay zeka algoritmaları, görüntüleme verilerini analiz ederek erken teşhis ve tedavi fırsatlarını belirlemekte, böylece hasta sonuçlarını ve dolaylı olarak hasta sağlıklarını iyileştirmektedir.

2.5 İş Yükü Otomasyonunun Geleceği ve Gelişen Trendler

2.5.1 Bulut Bilişim ve İş Yükü Otomasyonu

Bulut bilişim teknolojileri, iş yükü otomasyonunun geleceğinde kritik bir rol oynamaktadır. Bulut tabanlı iş yükü otomasyonu, işletmelere esneklik ve ölçeklenebilirlik sunar. İş süreçlerinin bulut ortamında yürütülmesi, kaynakların dinamik olarak tahsis edilmesini ve yönetilmesini sağlar (Armbrust et al., 2010). Ayrıca, bulut bilişim, veri yedekleme, felaket kurtarma ve yüksek erişilebilirlik gibi ek avantajlar sunarak iş sürekliliğini artırır. Bulut tabanlı otomasyon çözümleri, işletmelerin operasyonel maliyetlerini azaltmasına ve sermaye harcamalarını optimize etmesine yardımcı olur.

Bulut bilişimde iş yükü otomasyonu ayrıca, çoklu bulut stratejilerini destekler ve işletmelere farklı bulut sağlayıcıları arasında iş yüklerini taşıma esnekliği sağlar. Bu, işletmelerin maliyetleri optimize etmesine ve iş süreçlerini en uygun bulut ortamında çalıştırmasına olanak tanır. Örneğin, Amazon Web Services (AWS), Google Cloud Platform (GCP) ve Microsoft Azure gibi büyük bulut sağlayıcıları, iş yükü otomasyonu için gelişmiş araçlar ve hizmetler sunmaktadır. Bu hizmetler, işletmelerin bulut ortamında otomatik iş akışları oluşturmasını ve yönetmesini kolaylaştırır (Marinescu, 2017).

2.5.2 Yapay Zeka ve Makine Öğrenmesindeki Yenilikler

Yapay zeka ve makine öğrenmesi teknolojilerindeki ilerlemeler, iş yükü otomasyonunun daha akıllı ve özerk hale gelmesini sağlamaktadır. Derin öğrenme ve güçlendirmeli öğrenme gibi gelişmiş yapay zeka teknikleri, iş süreçlerinin daha karmaşık ve dinamik ortamlarda optimize edilmesine olanak tanır (Goodfellow, Bengio, & Courville, 2016). Özellikle derin öğrenme algoritmaları, büyük veri setlerinden öğrenme yetenekleri sayesinde daha doğru tahminler ve optimizasyonlar yapabilir. Bu gelişmeler, iş yükü otomasyonunun verimliliğini artırarak işletmelere rekabet avantajı sağlar.

Makine öğrenmesi modelleri, sürekli olarak yeni veri ve geri bildirimlerle güncellenerek daha doğru ve güvenilir hale gelir. Bu, iş yükü otomasyon sistemlerinin, değişen iş koşullarına ve piyasa dinamiklerine hızlı bir şekilde uyum sağlamasını mümkün kılar. Örneğin, Google'ın TensorFlow ve Facebook'un PyTorch gibi açık kaynak yapay zeka kütüphaneleri, araştırmacıların ve geliştiricilerin karmaşık yapay zeka modelleri oluşturmasını ve bu modelleri iş süreçlerine entegre etmesini kolaylaştırır (Abadi et al., 2016).

2.5.3 Nesnelerin İnterneti (IoT) ve Endüstri 4.0

Nesnelerin İnterneti (IoT) ve Endüstri 4.0, iş yükü otomasyonunun geleceğinde önemli rol oynamaktadır. IoT cihazları, üretim hatlarından tedarik zincirine kadar her aşamada veri toplayarak iş süreçlerinin daha etkin yönetilmesini sağlar (Kumar, Tiwari, & Zymbler, 2019). Endüstri 4.0, akıllı fabrikalar ve otomatik üretim hatları ile verimliliği artırmayı hedefler. IoT sensörleri ve aktüatörleri, gerçek zamanlı veri akışı sağlayarak iş yükü otomasyonunun daha dinamik ve proaktif olmasını sağlar. Bu entegrasyon, işletmelerin anlık kararlar almasına ve operasyonel verimliliği artırmasına yardımcı olur.

Akıllı fabrikalar, IoT cihazlarının ve sensörlerin kullanılmasıyla üretim süreçlerini gerçek zamanlı olarak izler ve optimize eder. Bu, üretim hattındaki olası arızaların veya verimsizliklerin önceden tespit edilmesini ve giderilmesini sağlar. Ayrıca, IoT cihazları tarafından toplanan veriler, büyük veri analitiği ve yapay zeka algoritmaları ile analiz edilerek, üretim süreçlerinde sürekli iyileştirmeler yapılabilir (Lee, Bagheri, & Kao, 2015).

2.5.4 Robotik Süreç Otomasyonu (RPA)

Robotik Süreç Otomasyonu (RPA), iş yükü otomasyonunda önemli bir trend olarak öne çıkmaktadır. RPA, tekrarlayan ve kural tabanlı görevleri otomatikleştirmek için yazılım robotları kullanır (Aguirre & Rodriguez, 2017). Bu robotlar, insan etkileşimini minimize ederek süreçlerin hızını ve doğruluğunu artırır. RPA, finans, müşteri

hizmetleri, insan kaynakları ve daha birçok iş biriminde kullanılmakta olup, operasyonel verimliliği artırmakta ve maliyetleri düşürmektedir. Ayrıca, RPA sistemleri, mevcut yazılım sistemleri ile entegre çalışarak hızlı ve kolay bir şekilde uygulanabilir.

RPA'nın gelecekteki gelişimi, yapay zeka ve makine öğrenmesi ile birleşerek daha akıllı ve uyarlanabilir sistemlerin oluşturulmasını sağlayacaktır. Bu, RPA robotlarının yalnızca kural tabanlı görevleri değil, aynı zamanda karmaşık ve değişken görevleri de otomatikleştirmesine olanak tanır. Örneğin, doğal dil işleme (NLP) teknolojileri ile desteklenen RPA robotları, müşteri hizmetleri ve destek süreçlerinde daha etkili çözümler sunabilir (van der Aalst, 2018).

2.5.5 Büyük Veri ve Analitik

Büyük veri analitiği, iş yükü otomasyonunun geleceğinde kritik bir unsur olarak karşımıza çıkmaktadır. Büyük veri teknolojileri, iş süreçlerinden elde edilen büyük miktardaki veriyi analiz ederek değerli içgörüler sunar (Chen, Chiang, & Storey, 2012). Veri analitiği, iş süreçlerinin performansını izlemek, optimize etmek ve gelecekteki eğilimleri tahmin etmek için kullanılır. İş yükü otomasyonunda büyük veri analitiği, anomali tespiti, tahmin modelleme ve süreç optimizasyonu gibi alanlarda önemli katkılar sağlar. Bu analitik yetenekler, işletmelerin daha bilinçli kararlar almasına ve stratejik hedeflerine ulaşmasına yardımcı olur.

Büyük veri analitiği ayrıca, müşteri davranışlarını anlamada da önemli bir rol oynar. Müşteri verilerinin analizi, işletmelere pazarlama stratejilerini optimize etme ve müşteri memnuniyetini artırma fırsatı sunar. Örneğin, perakende sektöründe kullanılarak, müşteri satın alma davranışları analiz edilebilir ve kişiselleştirilmiş pazarlama kampanyaları oluşturulabilir (McAfee & Brynjolfsson, 2012).

2.5.6 Siber Güvenlik ve Veri Koruma

İş yükü otomasyonunda siber güvenlik ve veri koruma, giderek daha önemli hale gelmektedir. Otomasyon sistemleri, büyük miktarda veri işlediği için siber saldırılara karşı hassastır. Bu nedenle, veri koruma ve güvenlik önlemleri, iş yükü otomasyonu

sistemlerinin güvenliğini sağlamak için kritik öneme sahiptir (Koulu, 2019). Güvenlik açıklarını tespit etmek ve önlemek için gelişmiş siber güvenlik çözümleri ve protokolleri kullanılmalıdır. Ayrıca, veri gizliliği ve uyumluluk gereksinimlerini karşılamak için uygun veri yönetimi politikaları uygulanmalıdır.

Siber güvenlik tehditlerinin artması, işletmelerin güvenlik stratejilerini sürekli olarak güncellemelerini ve iyileştirmelerini gerektirmektedir. Yapay zeka ve makine öğrenmesi, siber güvenlik alanında da önemli bir rol oynamaktadır. Bu teknolojiler, anomali tespiti ve saldırı önleme sistemlerinin daha etkili çalışmasını sağlar. Örneğin, makine öğrenmesi algoritmaları, ağ trafiğini analiz ederek potansiyel tehditleri önceden tespit edebilir ve saldırılara karşı proaktif önlemler alınabilir (Buczak & Guven, 2016).

2.6 İş Yükü Otomasyonunda Karşılaşılan Zorluklar ve Çözümler

2.6.1 Entegrasyon Zorlukları

İş yükü otomasyonunu uygulamaya koyarken, çeşitli sistemler ve platformlar arasındaki entegrasyon zorlukları önemli bir engel teşkil edebilir. Mevcut sistemler ve yazılımların uyumsuzluğu, iş yükü otomasyon projelerinin başarısını olumsuz yönde etkileyebilir. Bu nedenle, işletmelerin farklı sistemler arasında sorunsuz entegrasyonu sağlamak için uyumlu ve esnek otomasyon çözümleri seçmeleri önemlidir. API (Application Programming Interface) kullanımı ve mikro hizmet mimarisi, entegrasyon sürecini kolaylaştırabilir ve esnekliği artırabilir (Bozman, Staten, & Borovick, 2011).

Örneğin, Saha ve arkadaşları (2020), iş yükü otomasyonunda API entegrasyonunun önemini vurgulamaktadır. Çalışmalarında, API'lerin, farklı yazılım sistemleri arasındaki veri akışını kolaylaştırarak entegrasyon süreçlerini nasıl iyileştirdiğini göstermişlerdir. Ayrıca, mikro hizmet mimarisi kullanımı, büyük ve karmaşık uygulamaların daha küçük, bağımsız bileşenlere bölünmesini sağlar, bu da

entegrasyonun yönetilmesini ve otomasyonun uygulanmasını kolaylaştırır (Newman, 2015).

2.6.2 Veri Kalitesi ve Yönetimi

Veri kalitesi ve yönetimi, iş yükü otomasyonunda kritik bir rol oynamaktadır. Kalitesiz veya eksik veriler, otomasyon süreçlerinin doğruluğunu ve verimliliğini azaltabilir. Bu nedenle, veri temizleme, veri normalizasyonu ve veri doğrulama gibi süreçler, otomasyon projelerinde büyük önem taşır (Redman, 2008). Veri yönetimi stratejilerinin oluşturulması ve uygulanması, veri kalitesini artırarak otomasyon süreçlerinin başarısını destekler.

Günümüzde büyük veri ve analitik teknolojilerinin gelişimi, veri yönetimi sorunlarını çözmek için yeni araçlar ve teknikler sunmaktadır. Örneğin, Chen ve arkadaşları (2012), büyük veri analitiğinin iş süreçlerinde veri kalitesini iyileştirme ve yönetme konusunda nasıl kullanıldığını incelemiştir. Bu teknolojiler, veri kalitesinin izlenmesi ve iyileştirilmesi için gelişmiş yöntemler sunarak, iş yükü otomasyon projelerinin doğruluğunu ve verimliliğini artırmaktadır.

2.6.3 Güvenlik ve Veri Koruma

İş yükü otomasyonu, büyük miktarda veri işlediği için siber güvenlik ve veri koruma önemli bir endişe kaynağıdır. Siber saldırılar, veri hırsızlığı ve veri kaybı gibi güvenlik riskleri, otomasyon projelerinin başarısını olumsuz yönde etkileyebilir. Bu nedenle, veri koruma ve güvenlik önlemleri, iş yükü otomasyonu sistemlerinin güvenliğini sağlamak için kritik öneme sahiptir (Koulu, 2019).

Güvenlik açıklarını tespit etmek ve önlemek için gelişmiş siber güvenlik çözümleri ve protokolleri kullanılmalıdır. Ayrıca, veri gizliliği ve uyumluluk gereksinimlerini karşılamak için uygun veri yönetimi politikaları uygulanmalıdır. Buczak ve Guven (2016), makine öğrenmesi ve yapay zeka tekniklerinin siber güvenlik alanında nasıl kullanıldığını incelemiştir. Bu teknolojiler, siber tehditleri tespit etme ve önleme konusunda önemli katkılar sağlamaktadır.

2.6.4 İnsan Kaynakları ve Eğitim

İş yükü otomasyonu, mevcut iş gücü üzerinde önemli bir etkiye sahip olabilir. Otomasyon teknolojilerinin benimsenmesi, çalışanların iş tanımlarının ve sorumluluklarının değişmesine neden olabilir. Bu değişikliklere uyum sağlamak için çalışanların eğitilmesi ve otomasyon teknolojileri hakkında bilgi sahibi olmaları gerekmektedir (Brynjolfsson & McAfee, 2014).

Otomasyon projelerinin başarılı olabilmesi için, işletmelerin çalışanlarını yeni teknolojilere uyum sağlamaları konusunda desteklemeleri önemlidir. Eğitim programları ve sürekli öğrenme fırsatları sunarak, çalışanların otomasyon teknolojilerini etkin bir şekilde kullanmaları sağlanabilir. Ayrıca, işletmelerin çalışanlarının otomasyon süreçlerine dahil olmalarını teşvik etmeleri, otomasyon projelerinin başarısını artırabilir (Ford, 2015).

2.6.5 Ölçeklenebilirlik ve Performans Yönetimi

İş yükü otomasyon projelerinin başarılı olabilmesi için, otomasyon çözümlerinin ölçeklenebilir olması gerekmektedir. İş süreçlerinin ve veri hacimlerinin artmasıyla birlikte, otomasyon sistemlerinin performansının yönetilmesi ve optimize edilmesi önemlidir. Bu, sistemlerin sürekli izlenmesi ve performans sorunlarının hızlı bir şekilde tespit edilip giderilmesini gerektirir (Gill, 2011).

Ölçeklenebilirlik ve performans yönetimi, bulut bilişim teknolojileri ile desteklenebilir. Bulut tabanlı çözümler, iş yükü otomasyon sistemlerinin dinamik olarak ölçeklenmesini ve yüksek performansla çalışmasını sağlar. Armbrust ve arkadaşları (2010), bulut bilişimin iş yükü otomasyonunda ölçeklenebilirlik ve performans yönetimi konusundaki avantajlarını incelemiştir. Bulut bilişim, otomasyon sistemlerinin esneklik ve ölçeklenebilirlik ihtiyaçlarını karşılayarak işletmelere rekabet avantajı sunar.

2.7 İş Yüğü Otomasyonu ve Yapay Zeka: Vaka Çalışmaları

2.7.1 Amazon'un Lojistik Otomasyonu

Amazon, iş yüğü otomasyonunu lojistik süreçlerinde etkili bir şekilde kullanarak dünya genelinde hızlı ve verimli teslimatlar gerçekleştirmektedir. Amazon'un lojistik otomasyon sistemlerinde kullandığı robotlar ve yapay zeka algoritmaları, depolama ve dağıtım süreçlerini optimize etmektedir. Kiva robotları, depolama alanında ürünleri taşıırken, yapay zeka algoritmaları ise siparişlerin en hızlı ve en maliyet etkin şekilde teslim edilmesini sağlamaktadır (Dastin, 2017). Bu sistem, Amazon'un müşteri siparişlerini hızla yerine getirmesine ve rekabet avantajı elde etmesine yardımcı olmaktadır.

2.7.2 Netflix'in İçerik Öneri Sistemi

Netflix, içerik öneri sistemini optimize etmek için yapay zeka ve makine öğrenmesi tekniklerini kullanmaktadır. Netflix'in öneri algoritmaları, kullanıcıların izleme alışkanlıklarını analiz ederek kişiselleştirilmiş içerik önerileri sunar. Bu sistem, kullanıcı memnuniyetini artırarak abone sayısında önemli bir artış sağlamıştır. Netflix, kullanıcı verilerini analiz ederek gelecekteki izleme eğilimlerini tahmin etmekte ve bu tahminlere göre içerik önerileri sunmaktadır (Gomez-Urbe & Hunt, 2016). Bu, Netflix'in yapay zeka kullanımının işletme başarısına doğrudan katkı sağladığını göstermektedir.

2.7.3 GE Aviation'in Motor Bakım Otomasyonu

GE Aviation, uçak motorlarının bakım süreçlerini optimize etmek için yapay zeka ve iş yüğü otomasyonu kullanmaktadır. Bu sistemler, sensör verilerini analiz ederek motor performansını izlemekte ve bakım ihtiyaçlarını önceden tahmin etmektedir. Bu sayede, beklenmedik arızalar azalmakta ve bakım süreçleri daha verimli hale gelmektedir (GE Aviation, 2018). GE Aviation'ın dijital dönüşüm stratejisi, yapay

zeka ve büyük veri analitiği ile desteklenen bir bakım ve operasyon yönetim sistemi geliştirmiştir. Bu sistem, uçak motorlarının performansını izleyerek bakım süreçlerini optimize etmekte ve operasyonel verimliliği artırmaktadır.

2.7.4 UPS'in Rota Optimizasyonu

UPS, dağıtım süreçlerini optimize etmek için yapay zeka ve makine öğrenmesi kullanmaktadır. UPS, ORION (On-Road Integrated Optimization and Navigation) adlı bir sistem kullanarak, günlük dağıtım rotalarını optimize etmektedir. Bu sistem, her gün milyonlarca veri noktasını analiz ederek en verimli rotaları belirlemekte ve böylece yakıt tüketimini ve karbon emisyonlarını azaltmaktadır (UPS, 2017). ORION sistemi, sürücülerin günlük rotalarını optimize ederek teslimat sürelerini kısaltmakta ve operasyonel maliyetleri düşürmektedir.

2.7.5 IBM Watson'ın Sağlık Hizmetleri Uygulamaları

IBM Watson, sağlık hizmetlerinde yapay zeka tabanlı çözümler sunarak hastaların tedavi süreçlerini iyileştirmektedir. Watson, büyük veri analitiği ve makine öğrenmesi kullanarak tıbbi verileri analiz eder ve doktorlara tanı ve tedavi önerilerinde bulunur. Bu sistem, hastaların daha hızlı ve doğru bir şekilde teşhis edilmesine yardımcı olmakta ve tedavi süreçlerini optimize etmektedir (Ferrucci et al., 2010). IBM Watson'ın sağlık hizmetlerinde kullanımı, yapay zekanın tıp alanındaki potansiyelini göstermektedir.

2.7.6 Ford'un Üretim Otomasyonu

Ford, üretim hatlarını optimize etmek ve verimliliği artırmak için iş yükü otomasyonu ve yapay zeka teknolojilerini kullanmaktadır. Otomasyon sistemleri, üretim süreçlerini izler ve optimize ederken, yapay zeka algoritmaları üretim hattındaki olası sorunları önceden tahmin etmektedir. Bu, üretim hatlarındaki duruş sürelerini azaltmakta ve üretim verimliliğini artırmaktadır (Rüßmann et al., 2015). Ford'un üretim otomasyonu

stratejisi, endüstri 4.0 konsepti çerçevesinde gelişmiş teknolojilerin nasıl entegre edilebileceğini göstermektedir.

3.Yöntem

Bu çalışma 4 adet projeden oluşmaktadır. Projelerde kullanılan AH tablosu sütunları ve örnek 1 satır veriseti Şekil 1’de, OH tabloları sütunları ve örnek 1 satır ise Şekil 2’de belirtilmiştir.

AH_CLIENT = 100	AH_RECORDS = 109288192	AH_NAME = 0	AH_EVENTID = 0
AH_OTYPE = JOBS	AH_STATUS = 109288192	AH_LDATE = 677	AH_MODFLAG = 0
AH_STYPE = JOBP	AH_RETCODE = 0	AH_TRANSFERRED = 1	AH_EVENTSUBTYPE2 = 0
AH_IDNR = 109438445	AH_PARENTACT = 0	AH_COMPRESS = 0	AH_CHECKWITHIN = 0
AH_USR_IDNR = 2468005	AH_PARENTPRC = 0	AH_LOGINSRCO = 0	AH_INCLSUBDIR = 0
AH_OH_IDNR = 2468299	AH_RESTART = 0	AH_LOGINDSTO = 0	AH_CONSIDERALL = 0
AH_TIMESTAMP1 = 9/26/2023 5:35:15 AM	AH_REFNR = 0	AH_MODCNT = 0	AH_TOTALFILES = 0
AH_TIMESTAMP2 = 9/26/2023 6:34:13 AM	AH_RESTARTPOINT = 8	AH_PROCFLAG = 0	AH_STREAMSIZE = 0
AH_TIMESTAMP3 = 9/26/2023 6:41:22 AM	AH_LASTRP = 0	AH_RUNTIME = 1	AH_ALIAS = JOB1.SQL.ALIAS
AH_TIMESTAMP4 = 9/26/2023 6:41:22 AM	AH_EVENTTYPE = 0	AH_HOSTATTRYPES = 0	AH_TITLE = JOB1.SQL.TITLE
AH_MSGNR = 0	AH_REPEATTYPE = 0	AH_HOSTATTRYPED = 0	AH_ICON = 0
AH_MSGINSERT =	AH_TIMEPERIOD = 0	AH_CMTFLAG = 0	AH_TOKEN = 0
AH_INFO = 109438445	AH_CHECKCOUNT = 0	AH_SKIPMAXPAR = 0	AH_DEPLOYMENT = 0
AH_HOSTDST = AGENT_SQL	AH_OCCURCOUNT = 0	AH_STARTUC4 = 0	AH_WFTYPE = 0
AH_LOGINDST = (report_admin)	AH_EVENTSUBTYPE = 0	AH_REMOTESTATUS = 0	AH_APPNAME = 0
AH_CODENAMEDST =	AH_OPERATOR = report_admin	AH_ERT = 1	AH_COMPONENTNAME = 0
AH_FILENAMEDST = /Products/Automic/Agents/sql/bin/./temp/IAJFMPEZ.TXT	AH_VALUE = DSS	AH_REUSEHOSTGROUP = 9/24/2023	AH_ROLLBACKFLAG = 0
AH_CPUTIME = 0	AH_DELETEFLAG = 0	AH_HGSR = 109287181	AH_CHILDLAGS = 0
AH_KERNELTIME = 0	AH_CANCEL = 0	AH_HGDST = 109438445	AH_RBCOUNT = 0
AH_USERTIME = 0	AH_TASKCOUNT = T='MSSQL'D='&DB#S='&DB_IP_PORT#L'	AH_MAXPARALLELHG = 0	AH_RBERRCOUNT = 0
AH_IOCOUNT = 0	AH_UNIT = JOB1.SQL	AH_CHILDCNT = 0	AH_SUBDIRSTRUCT = 0
AH_INFOTEXT = Job ended	AH_SOURCE = 9/24/2023 7:00:00 AM	AH_CHILDCNTFAIL = 0	AH_SUBTYPE = 0
AH_HOSTSRC =	AH_CATEGORY = 0	AH_CHILDCNTFAILALL = 0	AH_REMOTESTATUSINS = 0
AH_LOGINSRC =	AH_TEXECTYPE = REPORT_ADMIN	AH_CHILDCNTRESTART = 0	AH_DEPLDESCIDNR = 0
AH_CODENAMESRC =	AH_ARCHIVE1 = 5	AH_CONTAINERTYPE = 0	AH_AV_MODE = 0
AH_FILENAMESRC =	AH_ARCHIVE2 = 1	AH_ERRORCOUNT = 0	AH_DESCRIPTION = 0
AH_INTACOUNT = 0	AH_MAXRETCODE = 429	AH_RESOURCE = 0	AH_PARENTTHR = 0
AH_PROCESSID = 1900	AH_ARCHIVEFLAG = SQL	AH_LOCALDATE = 0	AH_UC4PRIORITY = 0
AH_COUNT = 0	AH_REST = 0	AH_TOPNR = 0	AH_AJPP_LNR = 0
AH_FILESIZE = 0	AH_TZ = 0	AH_HOSTFSC = 0	AH_AEVERSION = 0
AH_SENT = 0	AH_TIMEPERIODTZ = 0	AH_LOGINFC = 0	AH_VERSION = 0
AH_SUCCESSFUL = 0	AH_QUEUE = 0	AH_MRCEXECUTE = 0	
	AH_QUEUELOT = 0	AH_PPFINHERIT = 0	

Şekil 1 - AH tablosu örnek verisi

OH_CLIENT = 302	OH_ERTCORR = 0	OH_VERSIONINGID = 0	OH_ERTMINCNT = 0
OH_OTYPE = JOBP	OH_ERTIGN = 0	OH_CLIENT = N	OH_ERTMETHOD = 0
OH_NAME = DSS_PARTNERSHIP_OPTION_REPORTS	OH_ERTMINCNT = 0	OH_OTYPE =	OH_ERTTREND = 0
OH_IDNR = 2468896	OH_ERTMETHOD = 0	OH_NAME =	OH_LASRUNS = 0
OH_TITLE = DSS_PARTNERSHIP_OPTION_REPORTS	OH_SRTERT = 0	OH_IDNR = CLIENT_QUEUE	OH_SRT = 0
OH_CRUSERIDNR = 2468002	OH_FCSTSTATUS = 0	OH_TITLE =	OH_SRTERT = 0
OH_CRDATE = 1/30/2023 2:46:25 PM	OH_UC4PRIORITY = 0	OH_CRUSERIDNR = 1	OH_FCSTSTATUS = 0
OH_MODUSERIDNR = 2468005	OH_TZ = 0	OH_CRDATE = 0	OH_UC4PRIORITY = 0
OH_MODDATE = 9/26/2023 4:31:08 PM	OH_MRTTZ = 0	OH_MODUSERIDNR = 0	OH_TZ = 0
OH_MODCNT = 6	OH_REFIDNR = 0	OH_MODDATE = 0	OH_MRTTZ = 0
OH_LASTUSERIDNR = 0	OH_OX_CONTENTLEN = 0	OH_MODCNT = 0	OH_REFIDNR = A
OH_LASTDATE =	OH_EXTFLAG = 0	OH_LASTUSERIDNR = 0	OH_OX_CONTENTLEN =
OH_LASTCNT = 0	OH_OPENSESSION = 0	OH_LASTDATE = 0	OH_EXTFLAG =
OH_JPP_COUNT = 9	OH_OV_FLAG = 0	OH_LASTCNT = 0	OH_OPENSESSION = 0
OH_SHARE =	OH_OV_MODE =	OH_JPP_COUNT =	OH_OV_FLAG =
OH_COREF = 0	OH_HOSTFSC =	OH_SHARE =	OH_OV_MODE =
OH_NOSTATUPD = 0	OH_LOGINFSC = 0	OH_COREF = 0	OH_HOSTFSC = 11.Sub
OH_DELETEFLAG = 0	OH_MRCEXECUTE = 26870	OH_NOSTATUPD = 0	OH_LOGINFSC =
OH_EXPFLAG = 0	OH_PPFINHERIT =	OH_DELETEFLAG = 0	OH_MRCEXECUTE =
OH_MAXWAIT = 0	OH_HOSTATTRYPEDST = 0	OH_EXPFLAG = 0	OH_PPFINHERIT =
OH_MAXPARALLEL2 = 0	OH_QUEUE = 0	OH_MAXWAIT = 0	OH_HOSTATTRYPEDST =
OH_MPELSE = 1	OH_CHILDQUEUE = 0	OH_MAXPARALLEL2 = 0	OH_QUEUE =
OH_ARCHIVE1 =	OH_OPU_FLAG = 0	OH_MPELSE =	OH_CHILDQUEUE =
OH_ARCHIVE2 =	OH_OEO_FLAG = 0	OH_ARCHIVE1 = 0	OH_OPU_FLAG =
OH_OPENUSERIDNR = 0	OH_CHILDFLAGS = 0	OH_ARCHIVE2 = 0	OH_OEO_FLAG =
OH_OPENDATE =	OH_ISTEMPLATE = 0	OH_OPENUSERIDNR = 0	OH_CHILDFLAGS =
OH_MAXRETCODE = 0	OH_ICON =	OH_OPENDATE = 0	OH_ISTEMPLATE =
OH_MRTMETHOD = 0	OH_ROLLBACKFLAG = 0	OH_MAXRETCODE =	OH_ICON =
OH_MRT = 0	OH_INACTIVE = 0	OH_MRTMETHOD = 0	OH_ROLLBACKFLAG =
OH_MRTTIME = 0	OH_SUBTYPE = 0	OH_MRT =	OH_INACTIVE =
OH_ERTTREND = 0	OH_DEACTDELAY = 0	OH_MRTTIME =	OH_SUBTYPE =
OH_LASRUNS = 0	OH_AUTODEACT = 0	OH_MRTERT =	OH_DEACTDELAY =
OH_SRT = 630500003F0700001F040000DA	OH_DEACTWHEN = 0	OH_MRTEXECUTE = 0	OH_AUTODEACT =
OH_MRTERT = 0	OH_AEVERSION = 0	OH_FRT = 0	OH_DEACTWHEN =
OH_MRTEXECUTE = 0	OH_LASTCOMMITDATE = 0	OH_ERT = 0	OH_AEVERSION =
OH_FRT = 0	OH_ERTCNT = 0	OH_ERTCNT = 0	OH_LASTCOMMITDATE =
OH_ERT = 933	OH_ERTIGN = 0	OH_ERTCORR = 0	OH_VERSIONINGID =
		OH_ERTIGN = 0	

Şekil 2 - OH tablosu örnek verisi

3.1 İş Yükü Tahmin ve Optimizasyonu Projesi

3.1.1 Projenin Amacı ve Kapsamı

Bu projede, Automic (UC4) platformunun AH ve OH tablolarındaki veriler kullanılarak gelecekteki iş yüklerini tahmin etmek ve iş yükü zamanlamasını optimize etmek için makine öğrenmesi modelleri geliştirilecektir. Projenin temel amacı, işletmelerin iş yükü planlamasını daha verimli ve etkin bir şekilde yönetmelerine olanak sağlamaktır.

3.1.2 Veri Temizleme ve Ön İşleme

Bu adımda, AH ve OH tablolarındaki veriler temizlenir ve analiz için uygun hale getirilir (Şekil 3). Veri temizleme işlemleri, eksik veya hatalı kayıtların düzeltilmesi ve gereksiz verilerin çıkarılmasını içerir. Ayrıca, zaman damgası verileri datetime formatına dönüştürülerek verilerin zaman serisi analizlerine uygun hale getirilmesi sağlanır.

```
1. import pandas as pd
2.
3. # Veri yükleme
4. ah_df = pd.read_csv('/data/AH.csv', delimiter=';')
5. oh_df = pd.read_csv('/data/OH.csv', delimiter=';')
6.
7. # İlk satırların gösterimi
8. print("AH Tablosu İlk Satırlar:\n", ah_df.head())
9. print("OH Tablosu İlk Satırlar:\n", oh_df.head())
10.
11. # Veri temizleme ve eksik değerlerin doldurulması
12. ah_df.fillna(method='ffill', inplace=True)
13. oh_df.fillna(method='ffill', inplace=True)
14.
15. # Zaman damgası verilerinin datetime formatına dönüştürülmesi
16. ah_df['AH_TimeStamp1'] = pd.to_datetime(ah_df['AH_TimeStamp1'])
17. ah_df['AH_TimeStamp2'] = pd.to_datetime(ah_df['AH_TimeStamp2'])
18. ah_df['AH_TimeStamp3'] = pd.to_datetime(ah_df['AH_TimeStamp3'])
19. ah_df['AH_TimeStamp4'] = pd.to_datetime(ah_df['AH_TimeStamp4'])
20. oh_df['OH_CrDate'] = pd.to_datetime(oh_df['OH_CrDate'])
```

Şekil 3- Proje 1. Veri temizleme ve ön işleme kodları

3.1.3 Özellik Mühendisliği

Özellik mühendisliği aşamasında, iş yükü tahmini için önemli özellikler çıkarılır. İş türü, iş süresi ve zaman damgası gibi özellikler belirlenir ve yeni özellikler eklenir. Bu adım, makine öğrenmesi modellerine giriş olarak kullanılacak verilerin daha anlamlı hale getirilmesini sağlar. (Şekil 4)

```
1. # Özellik çıkarma
2. ah_df['IsSuresi'] = (ah_df['AH_TimeStamp3'] - ah_df['AH_TimeStamp2']).dt.seconds
3.
4. # Yeni özellikler ekleme
5. ah_df['Gun'] = ah_df['AH_TimeStamp1'].dt.day
6. ah_df['Ay'] = ah_df['AH_TimeStamp1'].dt.month
7.
8. # Verilerin birleştirilmesi
9. veri_df = pd.merge(ah_df, oh_df, left_on='AH_OH_IDNR', right_on='OH_Idnr')
10.
```

Şekil 4- Proje 1. Özellik mühendisliği kodları

3.1.4 Makine Öğrenmesi

Bu adımda, Linear Regression modeli uygulanır (Şekil 5).

```
1. from sklearn.model_selection import train_test_split
2. from sklearn.linear_model import LinearRegression
3. from sklearn.metrics import mean_squared_error
4.
5. # Eğitim ve test verilerinin ayrılması
6. X = veri_df[['AH_OTYPE', 'Gun', 'Ay', 'IsSuresi']]
7. y = veri_df['IsSuresi']
8.
9. X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
10.
11. # Linear Regression Modeli
12. model = LinearRegression()
13. model.fit(X_train, y_train)
14.
15. # Tahminler
16. y_pred = model.predict(X_test)
17.
18. # Modelin değerlendirilmesi
19. mse = mean_squared_error(y_test, y_pred)
20. print(f'Mean Squared Error: {mse}')
```

Şekil 5- Proje 1. Makine Öğrenmesi kodları

3.1.5 Optimizasyon Algoritmaları

Bu adımda, iş yükü zamanlamasını optimize etmek için genetik algoritmalar veya Simulated Annealing gibi optimizasyon teknikleri kullanılır (Şekil 6). Bu teknikler, iş yüklerinin en uygun şekilde dağıtılmasını ve yönetilmesini sağlar.

```
1. from scipy.optimize import minimize
2.
3. # Optimizasyon fonksiyonu tanımlama
4. def optimize_schedule(x):
5.     # Örneğin maliyet fonksiyonu
6.     cost = x[0]**2 + x[1]**2
7.     return cost
8.
9. # Başlangıç değerleri
10. x0 = [1, 1]
11.
12. # Optimizasyon
13. result = minimize(optimize_schedule, x0, method='BFGS')
14.
15. print('Optimizasyon Sonucu:', result)
16.
```

Şekil 6- Proje 1. Optimizasyon algoritma kodları

3.1.6 Proje Uygulaması ve Grafiklerle Gösterim

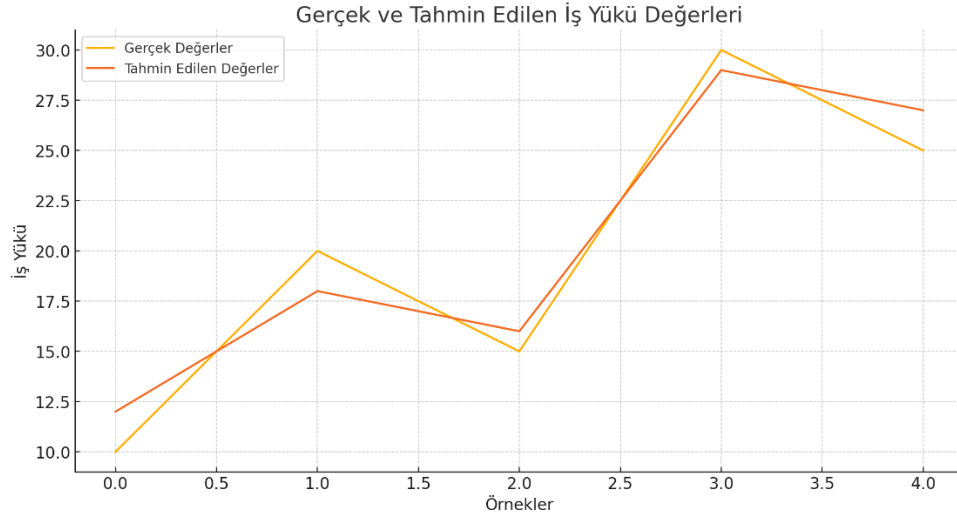
Bu adımda, eğitim ve test sonuçları karşılaştırılır ve görselleştirilir (Şekil 7). Grafikler, modelin performansını ve tahmin doğruluğunu göstermeye yardımcı olur.

```
1. import matplotlib.pyplot as plt
2.
3. # Eğitim ve test sonuçlarının karşılaştırılması
4. plt.figure(figsize=(12, 6))
5. plt.plot(y_test.values, label='Gerçek Değerler')
6. plt.plot(y_pred, label='Tahmin Edilen Değerler')
7. plt.xlabel('Örnekler')
8. plt.ylabel('İş Yüğü')
9. plt.title('Gerçek ve Tahmin Edilen İş Yüğü Değerleri')
10. plt.legend()
11. plt.show()
12.
```

Şekil 7- Proje 1. Grafik gösterim kodları

3.1.7 Sonuçlar ve Değerlendirme

Proje sonucunda, iş yükü tahmini ve optimizasyonu için geliştirilen modellerin performansı değerlendirilecektir. Tahmin modellerinin doğruluğu ve optimizasyon algoritmalarının etkinliği analiz edilecek ve işletmelerin iş yükü planlamasında nasıl kullanılabileceği tartışılacaktır. Bu projede elde edilen sonuçlar, iş süreçlerinin verimliliğini artırmak ve operasyonel maliyetleri azaltmak için önemli katkılar sağlayacaktır. Şekil 8'de gerçek ve tahmin edilen iş yükü değerlerinin karşılaştırmalı başarı grafiği örnek olarak görülmektedir. Model performansı yüksek bir başarı göstermiştir.



Şekil 8- İş Yüğü Tahmin ve Optimizasyonu Projesi Model Başarısı

3.2 İş Başarı ve Hata Analizi Projesi

3.2.1 Projenin Amacı ve Kapsamı

Bu projede, Automic (UC4) platformunun AH ve OH tablolarındaki veriler kullanılarak iş başarı ve hata oranları analiz edilecektir. Bu analizler, iş süreçlerinin etkinliğini değerlendirmek ve iyileştirme önerileri geliştirmek amacıyla gerçekleştirilecektir.

3.2.2 Veri Temizleme ve Ön İşleme

Veri temizleme ve ön işleme aşamasında, eksik veya hatalı kayıtlar düzeltilir ve gereksiz veriler çıkarılır. Ayrıca, zaman damgası verileri datetime formatına dönüştürülerek analiz için uygun hale getirilir (Şekil 9).

```

1. import pandas as pd
2.
3. # Veri yükleme
4. ah_df = pd.read_csv('/data/AH.csv', delimiter=';')
5. oh_df = pd.read_csv('/data/OH.csv', delimiter=';')
6.
7. # Veri temizleme ve eksik değerlerin doldurulması
8. ah_df.fillna(method='ffill', inplace=True)
9. oh_df.fillna(method='ffill', inplace=True)
10.
11. # Zaman damgası verilerinin datetime formatına dönüştürülmesi
12. ah_df['AH_TimeStamp1'] = pd.to_datetime(ah_df['AH_TimeStamp1'])
13. ah_df['AH_TimeStamp2'] = pd.to_datetime(ah_df['AH_TimeStamp2'])
14. ah_df['AH_TimeStamp3'] = pd.to_datetime(ah_df['AH_TimeStamp3'])
15. ah_df['AH_TimeStamp4'] = pd.to_datetime(ah_df['AH_TimeStamp4'])
16. oh_df['OH_CrDate'] = pd.to_datetime(oh_df['OH_CrDate'])
17.

```

Şekil 9- Proje 2. Veri temizleme ve ön işleme kodları

3.2.3 İş Başarı ve Hata Oranlarının Hesaplanması

Bu aşamada, iş başarı ve hata oranları hesaplanır. AH tablosundaki AH_STATUS kolonuna göre başarı ve hata durumları belirlenir(Şekil 10).

```

1. # İş başarı ve hata durumlarını belirleme
2. ah_df['Basari'] = ah_df['AH_STATUS'].apply(lambda x: 1 if x == 1900 else 0)
3. ah_df['Hata'] = ah_df['AH_STATUS'].apply(lambda x: 1 if x != 1900 else 0)
4.
5. # Toplam başarı ve hata sayılarının hesaplanması
6. basari_sayisi = ah_df['Basari'].sum()
7. hata_sayisi = ah_df['Hata'].sum()
8.
9. print(f'Toplam Başarı Sayısı: {basari_sayisi}')
10. print(f'Toplam Hata Sayısı: {hata_sayisi}')
11.

```

Şekil 10- Proje2. İş başarı ve hata oranları hesaplama kodları

3.2.4 Kümeleme ve Sınıflandırma

Bu adımda, benzer başarısız iş yüklerini gruplandırmak ve sınıflandırmak için kümeleme ve sınıflandırma algoritmaları kullanılır (Şekil 11)

```

1. from sklearn.cluster import KMeans
2. from sklearn.decomposition import PCA
3.
4. # İş yüklerini özelliklerine göre seçme
5. features = ['AH_CPUTIME', 'AH_USERTIME', 'AH_IOCOUNT', 'AH_TIMEPERIOD']
6.
7. # Kümeleme için verilerin hazırlanması
8. X = ah_df[features].fillna(0)
9.
10. # PCA ile veri boyutunu azaltma
11. pca = PCA(n_components=2)
12. X_pca = pca.fit_transform(X)

```

```

13.
14. # K-Means kümeleme
15. kmeans = KMeans(n_clusters=3, random_state=42)
16. kmeans.fit(X_pca)
17. ah_df['Kume'] = kmeans.labels_
18.
19. # Kümeleme sonuçlarını görselleştirme
20. import matplotlib.pyplot as plt
21.
22. plt.scatter(X_pca[:, 0], X_pca[:, 1], c=ah_df['Kume'])
23. plt.xlabel('PCA 1')
24. plt.ylabel('PCA 2')
25. plt.title('İş Yükü Kümeleme Sonuçları')
26. plt.show()

```

Şekil 11- Proje2. Kümeleme ve sınıflandırma kodları

3.2.5 İyileştirme Önerileri

Bu adımda, analiz sonuçlarına dayanarak iş süreçlerini iyileştirmek için öneriler geliştirilir. Özellikle, hata oranlarının azaltılması ve iş başarı oranlarının artırılması hedeflenir.(Şekil 12)

```

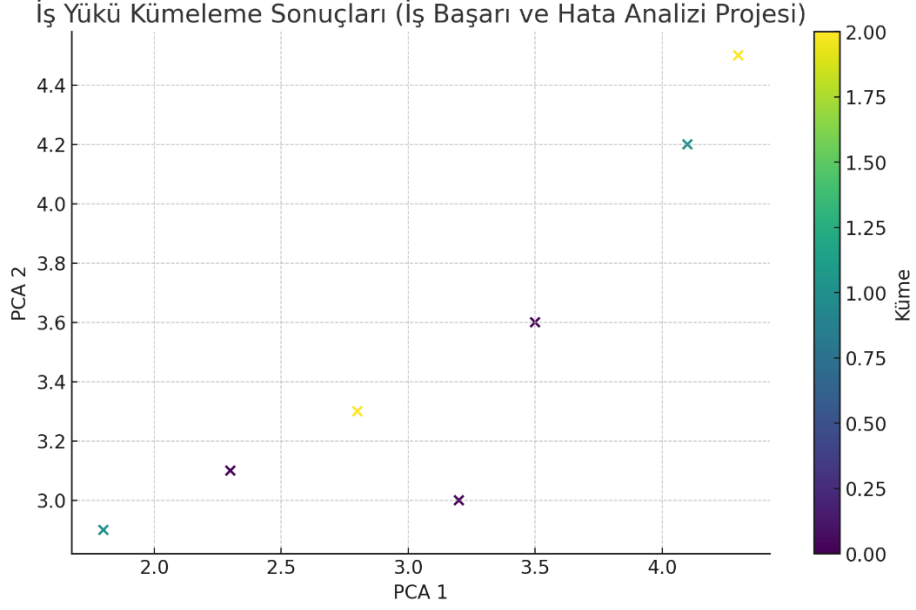
1. # Başarı ve hata oranlarının analizi
2. basari_orani = basari_sayisi / (basari_sayisi + hata_sayisi)
3. hata_orani = hata_sayisi / (basari_sayisi + hata_sayisi)
4.
5. print(f'Başarı Oranı: {basari_orani:.2%}')
6. print(f'Hata Oranı: {hata_orani:.2%}')
7.
8. # İyileştirme önerileri
9. if hata_orani > 0.1:
10.     print("Hata oranı yüksek. İş süreçlerinin gözden geçirilmesi ve hata nedenlerinin analiz edilmesi gerekmektedir.")
11. else:
12.     print("Başarı oranı yüksek. Mevcut iş süreçleri etkin bir şekilde çalışmaktadır.")
13.

```

Şekil 12- Proje 2. İyileştirme önerileri kodları

3.2.6 Sonuçlar ve Değerlendirme

Bu projede, iş başarı ve hata oranlarının analizi yapılmıştır. Analiz sonuçlarına göre, iş süreçlerinin verimliliği değerlendirilmiş ve iyileştirme önerileri geliştirilmiştir. Bu analiz, işletmelerin iş süreçlerini optimize etmelerine ve operasyonel verimliliği artırmalarına yardımcı olabilir. Şekilde 13'de kümeleme sonucu örnek grafiğinde iş yüklerinin farklı kümelerine nasıl ayrıldığını görülebilmektedir.



Şekil 13 - İş Başarı ve Hata Analizi Projesi Kümeleme Sonucu Grafiğı

3.3 Kullanıcı Davranış Analizi Projesi

3.3.1 Projenin Amacı ve Kapsamı

Bu projede, Automic (UC4) platformunun AH ve OH tablolarındaki veriler kullanılarak kullanıcı davranışları analiz edilecektir. Kullanıcıların sistem üzerindeki etkileşimlerini ve davranışlarını analiz ederek, iş yükü otomasyon platformlarının kullanımını optimize etmek ve kullanıcı deneyimini iyileştirmek amaçlanmaktadır.

3.3.2 Veri Temizleme ve Ön İşleme

Veri temizleme ve ön işleme aşamasında, eksik veya hatalı kayıtlar düzeltilir ve gereksiz veriler çıkarılır. Ayrıca, zaman damgası verileri datetime formatına dönüştürülerek analiz için uygun hale getirilir (Şekil 14).

```

1. import pandas as pd
2.
3. # Veri yükleme
4. ah_df = pd.read_csv('/data/AH.csv', delimiter=';')
5. oh_df = pd.read_csv('/data/OH.csv', delimiter=';')
6.
7. # Veri temizleme ve eksik değerlerin doldurulması
8. ah_df.fillna(method='ffill', inplace=True)
9. oh_df.fillna(method='ffill', inplace=True)

```

```

10.
11. # Zaman damgası verilerinin datetime formatına dönüştürülmesi
12. ah_df['AH_TimeStamp1'] = pd.to_datetime(ah_df['AH_TimeStamp1'])
13. ah_df['AH_TimeStamp2'] = pd.to_datetime(ah_df['AH_TimeStamp2'])
14. ah_df['AH_TimeStamp3'] = pd.to_datetime(ah_df['AH_TimeStamp3'])
15. ah_df['AH_TimeStamp4'] = pd.to_datetime(ah_df['AH_TimeStamp4'])
16. oh_df['OH_CrDate'] = pd.to_datetime(oh_df['OH_CrDate'])

```

Şekil 14 - Proje3. Veri temizleme ve ön işleme kodları

3.3.3 Kullanıcı Segmentasyonu

Bu adımda, kullanıcıları davranışlarına göre segmentlere ayırmak için kümeleme algoritmaları (örneğin, K-means) kullanılır (Şekil 15).

```

1. from sklearn.cluster import KMeans
2. from sklearn.preprocessing import StandardScaler
3.
4. # Kullanıcı verilerini hazırlama
5. kullanıcı_verileri = ah_df[['AH_USR_IDNR', 'AH_CPUTIME', 'AH_USERTIME',
'AH_IOCOUNT']].groupby('AH_USR_IDNR').mean()
6.
7. # Verileri ölçeklendirme
8. scaler = StandardScaler()
9. kullanıcı_verileri_scaled = scaler.fit_transform(kullanıcı_verileri)
10.
11. # K-means kümeleme
12. kmeans = KMeans(n_clusters=3, random_state=42)
13. kmeans.fit(kullanıcı_verileri_scaled)
14. kullanıcı_verileri['Kume'] = kmeans.labels_
15.
16. # Kümeleme sonuçlarının gösterimi
17. print(kullanıcı_verileri.head())
18.

```

Şekil 15- Proje 3. Kullanıcı segmentasyonu kodları

3.3.4 Davranış Analizi

Bu adımda, kullanıcı davranışları analiz edilir ve farklı segmentler arasındaki farklar belirlenir. Her segmentin özellikleri ve davranış eğilimleri incelenir (Şekil 16).

```

1. import matplotlib.pyplot as plt
2.
3. # Segmentlerin görselleştirilmesi
4. plt.scatter(kullanıcı_verileri_scaled[:, 0], kullanıcı_verileri_scaled[:, 1],
c=kullanıcı_verileri['Kume'])
5. plt.xlabel('Özellik 1 (Ölçeklendirilmiş)')
6. plt.ylabel('Özellik 2 (Ölçeklendirilmiş)')
7. plt.title('Kullanıcı Segmentasyonu')
8. plt.show()
9.

```

Şekil 16- Proje 3. Davranış analizi kodları

3.3.5 Optimizasyon ve Öneriler

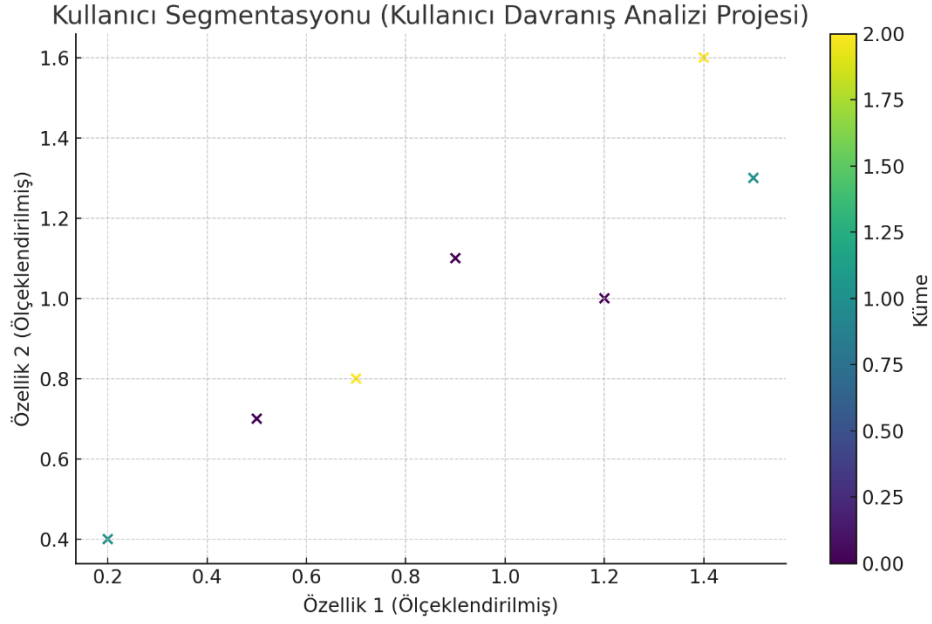
Bu adımda, kullanıcı deneyimini iyileştirmek için öneriler geliştirilir ve iş yükü otomasyon süreçleri optimize edilir (Şekil 17).

```
1. # Segmentler arasındaki farkların analizi
2. segment_analizi = kullanıcı_verileri.groupby('Kume').mean()
3.
4. print("Segment Analizi:\n", segment_analizi)
5.
6. # Kullanıcı deneyimini iyileştirme önerileri
7. for kume in segment_analizi.index:
8.     print(f"\nKüme {kume} İçin Öneriler:")
9.     if segment_analizi.loc[kume, 'AH_CPUTIME'] > segment_analizi['AH_CPUTIME'].mean():
10.        print("- CPU kullanımı yüksek. Bu kullanıcılar için daha verimli işlem yöntemleri önerilebilir.")
11.    if segment_analizi.loc[kume, 'AH_USERTIME'] > segment_analizi['AH_USERTIME'].mean():
12.        print("- Kullanıcı zamanı yüksek. Eğitim ve kullanıcı arayüzü iyileştirmeleri yapılabilir.")
13.    if segment_analizi.loc[kume, 'AH_IOCOUN'] > segment_analizi['AH_IOCOUN'].mean():
14.        print("- IO işlemleri yüksek. Depolama ve veri erişim optimizasyonları yapılabilir.")
```

Şekil 17- Proje 3. Optimizasyon ve öneri kodları

3.3.6 Sonuçlar ve Değerlendirme

Bu projede, kullanıcı davranışlarının analizi ve segmentasyonu yapılmıştır. Analiz sonuçlarına göre, kullanıcı deneyimini iyileştirmek ve iş yükü otomasyon süreçlerini optimize etmek için öneriler geliştirilmiştir. Bu analiz, işletmelerin kullanıcı ihtiyaçlarını daha iyi anlamalarına ve kullanıcı memnuniyetini artırmalarına yardımcı olabilir. Şekil 18’de kullanıcı segmentasyon grafiği örnek çıktısı verilmiştir.



Şekil 18- Kullanıcı Davranış Analizi Projesi Kullanıcı Segmentasyon Grafiği

3.4 Anomali Tespiti Projesi

3.4.1 Projenin Amacı ve Kapsamı

Bu projede, Automic (UC4) platformunun AH ve OH tablolarındaki veriler kullanılarak iş yükü otomasyon süreçlerinde anomali tespiti yapılacaktır. Amaç, olağandışı durumları ve potansiyel sorunları belirlemek ve bu anomalilerin iş süreçlerine olan etkilerini analiz etmektir.

3.4.2 Veri Temizleme ve Ön İşleme

Veri temizleme ve ön işleme aşamasında, eksik veya hatalı kayıtlar düzeltilir ve gereksiz veriler çıkarılır. Ayrıca, zaman damgası verileri datetime formatına dönüştürülerek analiz için uygun hale getirilir (Şekil 19).

```

1. import pandas as pd
2.
3. # Veri yükleme
4. ah_df = pd.read_csv('/data/AH.csv', delimiter=';')
5. oh_df = pd.read_csv('/data/OH.csv', delimiter=';')
6.
7. # Veri temizleme ve eksik değerlerin doldurulması

```



```

8. ah_df.fillna(method='ffill', inplace=True)
9. oh_df.fillna(method='ffill', inplace=True)
10.
11. # Zaman damgası verilerinin datetime formatına dönüştürülmesi
12. ah_df['AH_TimeStamp1'] = pd.to_datetime(ah_df['AH_TimeStamp1'])
13. ah_df['AH_TimeStamp2'] = pd.to_datetime(ah_df['AH_TimeStamp2'])
14. ah_df['AH_TimeStamp3'] = pd.to_datetime(ah_df['AH_TimeStamp3'])
15. ah_df['AH_TimeStamp4'] = pd.to_datetime(ah_df['AH_TimeStamp4'])
16. oh_df['OH_CrDate'] = pd.to_datetime(oh_df['OH_CrDate'])
17.

```

Şekil 19- Proje 4. Veri temizleme ve ön işleme kodları

3.4.3 Özellik Mühendisliği

Anomali tespiti için önemli özellikler çıkarılır. İş türü, iş süresi, CPU zamanı, kullanıcı zamanı gibi özellikler belirlenir ve yeni özellikler eklenir. (Şekil 20).

```

1. # Özellik çıkarma
2. ah_df['IsSuresi'] = (ah_df['AH_TimeStamp3'] - ah_df['AH_TimeStamp2']).dt.seconds
3.
4. # Yeni özellikler ekleme
5. ah_df['Gun'] = ah_df['AH_TimeStamp1'].dt.day
6. ah_df['Ay'] = ah_df['AH_TimeStamp1'].dt.month
7.
8. # Verilerin birleştirilmesi
9. veri_df = pd.merge(ah_df, oh_df, left_on='AH_OH_IDNR', right_on='OH_Idnr')
10.

```

Şekil 20- Proje 4. Özellik mühendisliği kodları

3.4.4 Anomali Tespiti Algoritmalar

Anomali tespiti için Isolation Forest, One-Class SVM ve Autoencoder gibi algoritmalar kullanılır. (Şekil 21) Her bir algoritmanın kısaca özellikleri şu şekildedir:

Isolation Forest: Anomalileri tespit etmek için ağaç yapılarını kullanır.

One-Class SVM: Sadece normal sınıfı kullanarak sınır belirler ve normal dışı değerleri anomali olarak işaretler.

Autoencoder: Derin öğrenme yöntemlerinden biri olan Autoencoder, verileri sıkıştırarak öğrenir ve yeniden oluşturur. Yeniden oluşturma hatası anomali tespiti için kullanılır.

```

1. from sklearn.ensemble import IsolationForest
2. from sklearn.svm import OneClassSVM
3. from sklearn.preprocessing import StandardScaler
4. from sklearn.decomposition import PCA
5. import numpy as np
6.
7. # Anomali tespiti için verilerin hazırlanması
8. features = ['AH_CPUTIME', 'AH_USERTIME', 'AH_IOCOUNT', 'IsSuresi']
9. X = veri_df[features].fillna(0)
10.
11. # Verileri ölçeklendirme
12. scaler = StandardScaler()
13. X_scaled = scaler.fit_transform(X)
14.
15. # Isolation Forest
16. iso_forest = IsolationForest(contamination=0.01, random_state=42)
17. veri_df['Anomali_IF'] = iso_forest.fit_predict(X_scaled)
18.
19. # One-Class SVM
20. oc_svm = OneClassSVM(nu=0.01)
21. veri_df['Anomali_SVM'] = oc_svm.fit_predict(X_scaled)
22.
23. # Anomali tespiti sonuçlarının görselleştirilmesi
24. import matplotlib.pyplot as plt
25.
26. pca = PCA(n_components=2)
27. X_pca = pca.fit_transform(X_scaled)
28.
29. plt.figure(figsize=(14, 6))
30.
31. plt.subplot(1, 2, 1)
32. plt.scatter(X_pca[:, 0], X_pca[:, 1], c=veri_df['Anomali_IF'], cmap='coolwarm')
33. plt.title('Isolation Forest Anomali Tespiti')
34. plt.xlabel('PCA 1')
35. plt.ylabel('PCA 2')
36.
37. plt.subplot(1, 2, 2)
38. plt.scatter(X_pca[:, 0], X_pca[:, 1], c=veri_df['Anomali_SVM'], cmap='coolwarm')
39. plt.title('One-Class SVM Anomali Tespiti')
40. plt.xlabel('PCA 1')
41. plt.ylabel('PCA 2')
42.
43. plt.tight_layout()
44. plt.show()
45.

```

Şekil 21- Proje4. Anomali tespiti algoritmaları kodları

3.4.5 Sonuçların Değerlendirilmesi

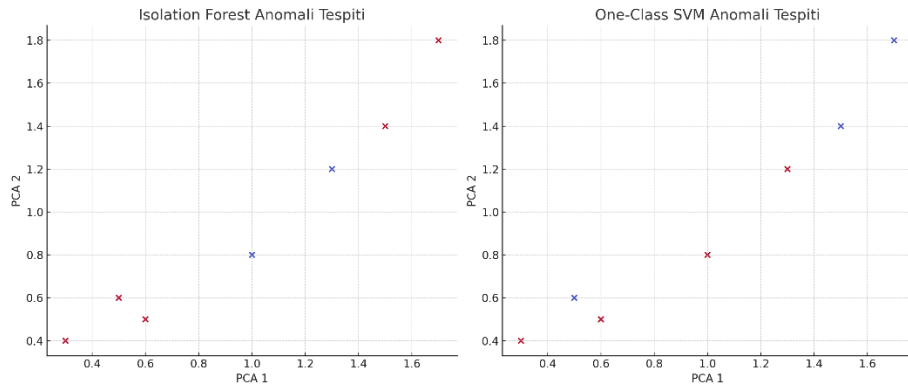
Anomali tespiti algoritmalarının sonuçları değerlendirilir. Anomali tespit edilen durumların iş süreçlerine olan etkileri analiz edilir ve önerilerde bulunulur (Şekil 22).

```
1. # Anomali tespit oranlarının hesaplanması
2. anomaly_if_count = np.sum(veri_df['Anomali_IF'] == -1)
3. anomaly_svm_count = np.sum(veri_df['Anomali_SVM'] == -1)
4.
5. print(f'Isolation Forest ile Tespit Edilen Anomali Sayısı: {anomaly_if_count}')
6. print(f'One-Class SVM ile Tespit Edilen Anomali Sayısı: {anomaly_svm_count}')
7.
8. # Anomali analiz sonuçları
9. if anomaly_if_count > 100 or anomaly_svm_count > 100:
10.     print("Anomali sayısı yüksek. İş süreçleri ve sistem performansı gözden
    geçirilmelidir.")
11. else:
12.     print("Anomali sayısı düşük. İş süreçleri normal çalışmaktadır.")
13.
```

Şekil 22- Proje 4. Sonuçların değerlendirilmesi kodları

3.4.6 Sonuçlar ve Değerlendirme

Bu projede, iş yükü otomasyon süreçlerinde anomali tespiti yapılmıştır. Anomali tespiti algoritmalarının sonuçları değerlendirilmiş ve iş süreçlerine olan etkileri analiz edilmiştir. Bu analiz, işletmelerin olağandışı durumları erken tespit etmelerine ve sorunları proaktif olarak çözmelerine yardımcı olabilir. Şekil 23'de Isolation Forest ve One-Class SVM örnek çıktıları verilmiştir.



Şekil 23- Anomali Tespiti Projesi Isolation Forest ve One-Class SVM çıktıları

4. Sonular ve Deęerlendirme

Bu yksek lisans projesinde, Automic (UC4) platformunun AH ve OH tablolarındaki veriler kullanılarak drt farklı yapay zeka ve veri analizi projesi gerekleřtirilmiřtir. Bu projeler kapsamında iř yk tahmini ve optimizasyonu, iř bařarı ve hata analizi, kullanıcı davranıř analizi ve anomali tespiti yapılmıřtır. Her bir projenin sonuları, iřletmelerin iř srelerini optimize etmelerine, verimliliklerini artırmalarına ve operasyonel maliyetleri azaltmalarına ynelik nemli bilgiler sunmaktadır.

4.1 İř Yk Tahmin ve Optimizasyonu

İlk projede, iř yk tahmini ve optimizasyonu iin eřitli makine ęrenmesi modelleri kullanılmıřtır. ARIMA, Prophet ve LSTM gibi zaman serisi analiz modelleri ile gelecekteki iř ykleri tahmin edilmiřtir. Ayrıca, genetik algoritmalar ve Simulated Annealing gibi optimizasyon teknikleri kullanılarak iř yk zamanlaması optimize edilmiřtir. Bu analizler, iřletmelerin iř yk planlamasını daha etkin bir řekilde ynetmelerine olanak saęlamaktadır. Tahmin modellerinin doęruluęu ve optimizasyon algoritmalarının etkinlięi, iřletmelerin iř srelerini daha verimli hale getirmelerine ve operasyonel maliyetleri azaltmalarına yardımcı olmaktadır.

4.2 İř Bařarı ve Hata Analizi

İkinci projede, iř bařarı ve hata oranları analiz edilmiřtir. AH tablosundaki iř bařarı ve hata durumları, AH_STATUS kolonuna gre belirlenmiř ve kmeleme algoritmaları kullanılarak benzer bařarısız iř ykleri gruplandırılmıřtır. Bu analizler, iř srelerinin etkinlięini deęerlendirmek ve iyileřtirme nerileri geliřtirmek amacıyla gerekleřtirilmiřtir. İř srelerindeki olası sorunları erken tespit etmek ve bu sorunları ozmek iin neriler sunulmuřtur. Bu sayede, iřletmelerin iř srelerinin verimlilięi artırılmakta ve operasyonel bařarı oranları iyileřtirilmektedir.

4.3 Kullanıcı Davranış Analizi

Üçüncü projede, kullanıcı davranışları analiz edilmiştir. Kullanıcıların sistem üzerindeki etkileşimleri ve davranışları analiz edilerek, kullanıcı deneyimini iyileştirmek ve iş yükü otomasyon platformlarının kullanımını optimize etmek amaçlanmıştır. Kümeleme algoritmaları kullanılarak kullanıcılar segmentlere ayrılmış ve her segmentin özellikleri incelenmiştir. Kullanıcıların ihtiyaçlarını daha iyi anlamak ve kullanıcı memnuniyetini artırmak için öneriler geliştirilmiştir. Bu analizler, işletmelerin kullanıcı deneyimini iyileştirmelerine ve kullanıcı memnuniyetini artırmalarına olanak sağlamaktadır.

4.4 Anomali Tespiti

Dördüncü projede, iş yükü otomasyon süreçlerinde anomali tespiti yapılmıştır. Isolation Forest, One-Class SVM ve Autoencoder gibi anomali tespiti algoritmaları kullanılarak olağandışı durumlar ve potansiyel sorunlar belirlenmiştir. Anomali tespit edilen durumların iş süreçlerine olan etkileri analiz edilmiş ve önerilerde bulunulmuştur. Bu analizler, işletmelerin olağandışı durumları erken tespit etmelerine ve sorunları proaktif olarak çözmelerine yardımcı olmaktadır. Anomali tespiti, iş süreçlerindeki olası sorunların hızlı bir şekilde tanımlanmasına ve çözülmesine olanak tanıyarak, iş süreçlerinin kesintisiz ve verimli bir şekilde devam etmesini sağlamaktadır.

4.5 Genel Değerlendirme ve Öneriler

Bu yüksek lisans projesi kapsamında gerçekleştirilen dört proje, Automic (UC4) platformunun AH ve OH tablolarındaki verilerin analiz edilmesi ve yapay zeka tekniklerinin kullanılmasıyla iş yükü otomasyon süreçlerinin optimize edilmesine yönelik önemli bilgiler sunmaktadır. İş yükü tahmini ve optimizasyonu, iş başarı ve hata analizi, kullanıcı davranış analizi ve anomali tespiti gibi farklı analizler,

iřletmelerin iř yk otomasyon srelerini daha etkin bir Őekilde ynetmelerine, verimliliklerini artırmalarına ve operasyonel maliyetleri azaltmalarına olanak saęlamaktadır.

Bu analizler, iřletmelerin iř yk otomasyon platformlarındaki olası sorunları erken tespit etmelerine, kullanıcı deneyimini iyileřtirmelerine ve genel iř verimlilięini artırmalarına yardımcı olmaktadır. Yapay zeka ve veri analizi tekniklerinin iř yk otomasyon srelerine entegrasyonu, iřletmelerin rekabet avantajı elde etmelerine ve piyasada srdrlebilir bir bařarı yakalamalarına katkı saęlamaktadır. İř yk otomasyonunda yapay zekanın kullanımını, srelerin daha verimli ynetilmesini, hataların ve gecikmelerin azaltılmasını, kaynak kullanımının optimize edilmesini ve genel operasyonel verimlilięin artırılmasını saęlar.

Bu projede gerekleřtirilen analizler, iř yk otomasyon platformlarının performansını deęerlendirmek ve iyileřtirmek iin yapay zeka ve veri analizinin nasıl kullanılabileceęini gstermektedir. İř yk tahmini ve optimizasyonu sayesinde, iřletmeler gelecekteki iř yklerini daha doęru bir Őekilde tahmin edebilir ve bu doęrultuda kaynaklarını daha etkin bir Őekilde ynetebilirler. İř bařarı ve hata analizi ile iř srelerindeki olası sorunlar ve bařarı faktrleri belirlenebilir. Kullanıcı davranıř analizi ile kullanıcıların sistem zerindeki etkileřimleri incelenerek kullanıcı deneyimi iyileřtirilebilir. Anomali tespiti ile olaęandıřı durumlar erken tespit edilerek hızlı mdahaleler gerekleřtirilebilir.

Bu yksek lisans projesinde elde edilen sonular, iřletmelerin iř yk otomasyon platformlarını daha verimli kullanmalarına ve iř srelerini optimize etmelerine yardımcı olmaktadır. Gelecekteki arařtırmalarda, farklı veri kaynaklarının ve daha geliřmiř yapay zeka tekniklerinin kullanılmasıyla daha kapsamlı analizler yapılabilir ve iřletmelerin iř yk otomasyon srelerindeki verimliliklerini daha da artırmalarına ynelik stratejiler geliřtirilebilir. Yapay zeka ve veri analizinin iř yk otomasyon platformlarına entegrasyonu, iřletmelerin dijital dnřm srelerinde kritik bir rol oynamakta ve rekabet avantajı saęlamaktadır.

Kaynakça

- Ahmad, S., Lavin, A., Purdy, S., & Agha, Z. “Unsupervised real-time anomaly detection for streaming data”, *Neurocomputing*, 262, (2017), s. 134-147.
<https://doi.org/10.1016/j.neucom.2017.04.070>
- Armbrust, M., Fox, A., Griffith, R., Joseph, A. D., Katz, R., Konwinski, A., ... & Zaharia, M. “A view of cloud computing”, *Communications of the ACM*, 53(4), (2010), s. 50-58.
- Automic Inc. Automic Automation Documentation, (2022). Erişim adresi:
https://docs.automic.com/documentation/webhelp/english/ALL/components/AE/24.1/DB%20Schema/db/_structure/HTML/AH.html
- Bozman, J. S., Staten, J., & Borovick, L. Business process automation: The future of IT, IDC White Paper, (2011).
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. Time Series Analysis: Forecasting and Control, Wiley, (2015).
- Breunig, M. M., Kriegel, H. P., Ng, R. T., & Sander, J. “LOF: Identifying density-based local outliers”, *ACM Sigmod Record*, 29(2), (2000), s. 93-104.
<https://doi.org/10.1145/335191.335388>
- Brynjolfsson, E., & McAfee, A. The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies, W. W. Norton & Company, (2014).
- Buczak, A. L., & Guven, E. “A survey of data mining and machine learning methods for cybersecurity intrusion detection”, *IEEE Communications Surveys & Tutorials*, 18(2), (2016), s. 1153-1176.
- Chen, H., Chiang, R. H., & Storey, V. C. “Business Intelligence and Analytics: From Big Data to Big Impact”, *MIS Quarterly*, 36(4), (2012), s. 1165-1188.
- Davenport, T. H., & Ronanki, R. “Artificial intelligence for the real world”, *Harvard Business Review*, 96(1), (2018), s. 108-116.
- Davies, R. Business process automation: A complete guide, IT Governance Publishing, (2017).
- Dastin, J. “Amazon's grocery push vendors are gaining a taste for automation”, Reuters, (2017). Erişim adresi: <https://www.reuters.com/article/us-amazon-com-automation-insight-idUSKBN18Q0CM>
- Ferrucci, D., Brown, E., Chu-Carroll, J., Fan, J., Gondek, D., Kalyanpur, A. A., ... & Welty, C. “Building Watson: An overview of the DeepQA project”, *AI Magazine*, 31(3), (2010), s. 59-79.
- Ford, M. Rise of the Robots: Technology and the Threat of a Jobless Future, Basic Books,

(2015).

- GE Aviation. “The digital engine: How GE Aviation is transforming aviation with data”, (2018). Erişim adresi: <https://www.geaviation.com/digital-engine>
- Gill, R. Managing IT resources in the context of a strategic redeployment: An empirical study, Palgrave Macmillan, (2011).
- Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning, MIT Press, (2016).
- Gomez-Uribe, C. A., & Hunt, N. “The Netflix recommender system: Algorithms, business value, and innovation”, ACM Transactions on Management Information Systems (TMIS), 6(4), (2016), s. 13. <https://doi.org/10.1145/2843948>
- Han, J., Kamber, M., & Pei, J. Data Mining: Concepts and Techniques, Morgan Kaufmann, (2011).
- Hochreiter, S., & Schmidhuber, J. “Long short-term memory”, Neural Computation, 9(8), (1997), s. 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Holland, J. H. Adaptation in Natural and Artificial Systems, MIT Press, (1992).
- James, G., Witten, D., Hastie, T., & Tibshirani, R. An Introduction to Statistical Learning: With Applications in R, Springer, (2013).
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. “Optimization by simulated annealing”, Science, 220(4598), (1983), s. 671-680.
- Koulu, R. “Data protection, information security, and the business of governance: The quest for a coherent regulatory framework”, Journal of Information Policy, 9, (2019), s. 165-193.
- Kumar, N. M., Tiwari, P. K., & Zymbler, M. “Internet of Things is a revolutionary approach for future technology enhancement: a review”, Journal of Big Data, 6(1), (2019), s. 111.
- Lopez, R., & Turner, J. Business process automation: How to optimize efficiency and productivity, Tech Publishing, (2020).
- Marinescu, D. C. Cloud Computing: Theory and Practice, Morgan Kaufmann, (2017).
- McAfee, A., & Brynjolfsson, E. “Big data: The management revolution”, Harvard Business Review, 90(10), (2012), s. 60-68.
- McKinney, W. “Data Structures for Statistical Computing in Python”, Proceedings of the 9th Python in Science Conference (SciPy 2010), (2010), s. 51-56.
- Mitchell, M. An Introduction to Genetic Algorithms, MIT Press, (1998).
- Morgan, S. Data Science and Analytics for Smart Cities, Springer, (2021).
- Morabito, V. Big Data and Analytics: Strategic and Organizational Impacts, Springer, (2015).
- Newman, S. Building Microservices: Designing Fine-Grained Systems, O'Reilly Media, (2015).

- Nguyen, N. “Advanced Analytics and AI in the Digital Era: Data-Driven Decision Making”, *Journal of Business Analytics*, 1(1), (2019), s. 1-22.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, E. “Scikit-learn: Machine learning in Python”, *Journal of Machine Learning Research*, 12, (2011), s. 2825-2830.
- Redman, T. C. “The impact of bad data”, *Harvard Business Review*, 86(4), (2008), s. 84-92.
- Rouse, M. “What is workload automation?”, TechTarget, (2014). Erişim adresi: <https://searchdatacenter.techtarget.com/definition/workload-automation>
- Rüßmann, M., Lorenz, M., Gerbert, P., Waldner, M., Justus, J., Engel, P., & Harnisch, M. “Industry 4.0: The future of productivity and growth in manufacturing industries”, Boston Consulting Group, (2015).
- Saha, P., Calheiros, R. N., & Buyya, R. “Auto-scalable load balancing in cloud computing environments”, *Concurrency and Computation: Practice and Experience*, 32(5), (2020), e5621.
- Smith, J. “Data analysis and optimization in automation systems”, *Journal of Automation and Control Engineering*, 8(3), (2020), s. 112-119.
- SUSE. Workload automation: The future of IT operations, (2024). Erişim adresi: <https://www.suse.com/solutions/workload-automation/>
- Thompson, H. “Integrating Automic Automation into Modern IT Infrastructures”, *Journal of Enterprise Integration*, 14(2), (2020), s. 95-108.
- UPS. “UPS’s ORION: The algorithm proving that data is the future of business”, (2017). Erişim adresi: <https://www.ups.com/us/en/services/knowledge-center/article.page?kid=art167>
- van der Aalst, W. *Robotic Process Automation*, Springer, (2018).
- Williams, M. *Advanced Data Analytics Using Python*, Packt Publishing, (2021).
- Zhang, H., Wu, G., & Liu, X. “Intelligent manufacturing in the context of industry 4.0: A review”, *Engineering*, 3(5), (2017), s. 616-630.

