

BURSA TEKNİK ÜNİVERSİTESİ ❖ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ÜRETİM PLANLAMA VE KONTROL SÜREÇLERİNDE
DİJİTAL İKİZ TEKNOLOJİSİNİN KULLANILMASI:
TEKSTİL SEKTÖRÜNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

Aysel KOÇAK

Akıllı Sistemler Mühendisliği Anabilim Dalı

OCAK 2022

BURSA TEKNİK ÜNİVERSİTESİ ❖ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ÜRETİM PLANLAMA VE KONTROL SÜREÇLERİNDE
DİJİTAL İKİZ TEKNOLOJİSİNİN KULLANILMASI:
TEKSTİL SEKTÖRÜNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

Aysel KOÇAK

Akıllı Sistemler Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Aytaç YILDIZ

OCAK 2022

20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.



İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Aysel KOÇAK



ÖNSÖZ

Çalışmalarımı yönlendiren, araştırmalarımın her aşamasında bilgi, öneri ve yardımlarını esirgemeyen danışman hocam Doç. Dr. Aytaç YILDIZ'a, çalışmalarım sırasında desteğini esirgemeyen değerli firmamıza ve tüm çalışma süreci boyunca beni destekleyen aileme teşekkür ederim.

Ocak 2022

Aysel KOÇAK
Endüstri Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vi
İÇİNDEKİLER	vii
KISALTMALAR	viii
SEMBOLLER	ix
ÇİZELGE LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xii
SUMMARY	xiii
1. GİRİŞ.....	1
2. ENDÜSTRİ 4.0	4
2.1 Endüstri 4.0 Teknolojileri	5
2.2 Endüstri 4.0'da Veri	16
3. DİJİTAL İKİZ VE UYGULAMALARI	19
3.1 Dijital İkiz	19
3.2 Dijital İkiz Uygulamaları	22
4. MATERYAL VE YÖNTEM.....	29
4.1 Birinci Faz Çalışması	29
4.2 İkinci Faz Çalışması	30
4.3 Üçüncü Faz Çalışması	31
5. BULGULAR VE TARTIŞMA	36
5.1 Birinci Faz Çalışmasından Elde Edilen Bulgular.....	36
5.1.1 Ham madde depolama ve sevk süreçleri	36
5.1.2 Üretim hattı giriş ve çıkış süreçleri	37
5.1.3 Yarı mamul kabul ve sevk süreçleri.....	38
5.2 İkinci Faz Çalışması	39
5.2.1 Ham madde depolama ve sevk süreçleri ERP aktarımı	40
5.2.2 Üretim hattı giriş ve çıkış süreçleri ERP aktarımı	42
5.2.3 Yarı mamul kabul ve sevk süreçleri ERP aktarımı	44
5.3 Üçüncü Faz Çalışması	46
5.3.1 Süre tahminleme	46
5.3.2 Makine duruş takibi	56
5.3.3 Üretim çizelgeleme	57
6. SONUÇ VE ÖNERİLER.....	58
KAYNAKLAR	61
ÖZGEÇMİŞ.....	70

KISALTMALAR

AI	: Artificial Intelligence
BD	: Big Data
BW	: Business Warehouse
CAD	: Bilgisayar Destekli Tasarım
CC	: Cloud Computing
CIoT	: Tüketici Nesnelerin İnterneti
CPS	: Siber Fiziksel Sistem
ERP	: Kurumsal Kaynak Planlama
HIoT	: İnsan Nesnelerin İnterneti
IIoT	: Endüstriyel Nesnelerin İnterneti
IoT	: Internet of Things
MAE	: Mean Absolute Error
MSE	: Mean Squared Error
NIST	: Ulusal Standartlar ve Teknoloji Enstitüsüne
PLM	: Ürün Yaşam Döngüsü Yönetimi
Power BI	: Power Business Intelligence
RFID	: Radio Frequency Identification
RMSE	: Root Mean Square Error
SAP BI	: Program Development Objects Business Intelligence
SAP GUI	: Systems Analysis and Program Development Graphical User Interface
STL	: Standart Mozaikleme Dili
UWB	: Ultra Broadband

SEMBOLLER

$\hat{y}_i$	: Öngörülen Gözlem
$\bar{y}$	: Gerçek Değer Ortalaması
y_i	: Gerçek Gözlem
y'_i	: Tahmin Edilen Değer
n	: Gözlem Sayısı
f, g	: Fonksiyon
y	: Bağımlı Değişken
x	: Bağımsız Değişken
k	: Polinom Derecesi
R^2	: Belirleme Kat Sayısı
β_0	: Doğrunun y Eksenini Kestiği Nokta
β_1	: Eğim
ε	: Doğrusal Regresyon Hata Terimi

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 5.1 : Kalite kontrol sistemi hata puanları.....	41
Çizelge 5.2 : Örnek veri seti.	47
Çizelge 5.3 : Knime istatistik sonuçları.	48
Çizelge 5.4 : Knime ön işleme yapılmış veri istatistik sonuçları.	49
Çizelge 5.5 : Lineer regresyon sonuçları.	50
Çizelge 5.6 : Polinomal regresyon sonuçları.	52
Çizelge 5.7 : Gradyan destekli karar ormanı regresyonu sonuçları.....	53
Çizelge 5.8 : Rassal orman regresyon algoritması sonuçları.	55
Çizelge 5.9 : Tüm modellerden elde edilen sonuçlar..	55

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Endüstri devrimlerinin gelişimi.....	4
Şekil 2.2 : Endüstri 4.0'ın temel teknolojileri devrimlerinin gelişimi.....	6
Şekil 2.3 : Kategorize edilmiş IoT sistemleri kullanım alanları	7
Şekil 2.4 : Veritabanlarında bilgi keşfi süreci	9
Şekil 2.5 : Bulut bilişim bileşenleri	11
Şekil 2.6 : Bulut bilişim modeli	12
Şekil 2.7 : Giyilebilir teknoloji tasarımı.	12
Şekil 2.8 : Modern üretim teknolojilerine sahip bir fabrika tasarımında kullanılan araçlar.	13
Şekil 2.9 : Çeşitli parametreler ile 3B modelleme örneği.....	15
Şekil 2.10 : Makine öğrenimi modeli.	15
Şekil 2.11 : Endüstri 4.0 çerçevesi.....	16
Şekil 2.12 : Endüstri 4.0'ı gerçekleştirme yolunda veri dönüşümünün aşamaları. ...	17
Şekil 2.13 : Bir akıllı fabrikayı etkinleştiren teknolojiler	17
Şekil 3.1 : Bir ürün için dijital ikiz teknolojisi	20
Şekil 3.2 : Dijital ikiz teknolojisini etkinleştirme.....	21
Şekil 4.1 : Ensemble platformu süreç yönetim ekranı.....	30
Şekil 4.2 : Jira platformu proje yönetim ekranı	31
Şekil 5.1 : Satın alma siparişi oluşturma ve onay ekranı	40
Şekil 5.2 : Kalite kontrol makinesi	41
Şekil 5.3 : Kalite kontrol yazılım uygulaması	42
Şekil 5.4 : Proses bazlı işlem ekranları.....	42
Şekil 5.5 : Üretime alınacak sipariş bilgilendirme ekranı	43
Şekil 5.6 : Üretim bilgi görüntüleme ekranı	43
Şekil 5.7 : Performans gösterge raporu	44
Şekil 5.8 : Paket takip QR kodları	44
Şekil 5.9 : Sepet ve adres QR kodları	45
Şekil 5.10 : Saha personeli app uygulaması	45
Şekil 5.11 : Sevk süreçleri dashboard ekranı.....	46
Şekil 5.12 : Knime statistics modülü	48
Şekil 5.13 : Knime ön işleme yapılmış veri ve statistics modülü.....	48
Şekil 5.14 : Knime lineer regresyon modülü	49
Şekil 5.15 : Çalıştırılan model lineer regresyon grafiği.....	50
Şekil 5.16 : Knime polinomal regresyon modülü.....	51
Şekil 5.17 : Çalıştırılan model polinomal regresyon grafiği	51
Şekil 5.18 : Knime gradyan destekli karar ormanı regresyonu modülü	53
Şekil 5.19 : Knime rassal orman regresyon modülü.....	54
Şekil 5.20 : Çalıştırılan model ağaç grafiği	54
Şekil 5.21 : ERP makine duruş, bakım ve onarım modülü.....	56
Şekil 5.22 : Bakım ve onarım kayıtlarının yapılması	56
Şekil 5.23 : Üretim çizelgeleme çalışması hat görünümü	57

ÜRETİM PLANLAMA VE KONTROL SÜREÇLERİNDE DİJİTAL İKİZ TEKNOLOJİSİNİN KULLANILMASI: TEKSTİL SEKTÖRÜNDE BİR UYGULAMA

ÖZET

Günümüzde, mevcut üretim ve tasarım teknolojilerinin modern bilgi ve iletişim teknolojileriyle birleşmesiyle birlikte üretim ve tasarımda dijitalleşme süreci başlamıştır. Özellikle nesnelerin interneti, bulut bilişim, büyük veri analitiği, yapay zeka ve dijital ikiz gibi Endüstri 4.0 teknolojilerinin ortaya çıkmasıyla birlikte günümüzün üretim paradigması akıllı üretime dönüşmeye başlamıştır. Bu teknolojilerden biri olan dijital ikiz, üretim sistemlerinin veya bileşenlerinin sanal ve gerçek zamanlı bir temsilini oluşturarak sürekli toplanan verilerle ürünler veya üretim sistemleri hakkında geleceğe yönelik bilgiler vermektedir. Ayrıca, süreçlerdeki sorunları tespit etmek, ürünlerin tasarım döngüsünü hızlandırmak, kalite sorunlarının kaynağını belirlemek ve hataları önlemek gibi birçok avantajlar sağlamaktadır. Bu avantajlarından dolayı da akıllı imalat, akıllı bina yönetimi, akıllı şehir, sağlık, petrol, gaz ve daha pek çok alanda giderek daha fazla uygulanmaya başlamıştır. Ancak, ürün ya da sistemlerin dijital ikizlerinin oluşturulması ve uygulanması için öncelikle gerekli olan verilerin toplanması, düzenlenmesi, işlenmesi ve anlamlı hale getirilmesi gerekmektedir.

Bu çalışmada, hazır giyim sektöründe faaliyet gösteren öncü bir firmanın üretim tesisinde, veri dijitalleştirme projesi kapsamında süreçlerin uçtan uca incelenmesi ve yeni nesil bilgi teknolojileri kullanılarak veri odaklı süreç tasarımlarının yapılması amaçlanmıştır. Buna bağlı olarak, yeni gelişen ve hızlı büyüyen bir teknoloji olan dijital ikiz modellerinin yapılabilmesi için gerekli olan süreç altyapılarının oluşturulması hedeflenmiştir. Yapılan çalışmada ilk olarak, süreç haritaları oluşturulmuş ve süreçlere ait sürekli değişen verilerin sensörler ve arayüzler yardımıyla elde edilerek sisteme aktarılması sağlanmıştır. Daha sonra, üretim hattındaki makinelerden alınan süreç bazlı süreler ile üretilecek ürüne ait nitelikler arasında bağlantı kurularak, herhangi bir ürünün sürece girdiğinde ne kadar sürede tamamlanacağı lineer regresyon, polinomal regresyon, gradyan destekli karar ormanı regresyonu ve rassal orman regresyon algoritmaları kullanılarak Knime platformunda tahmin edilmiştir. Yapılan tahmin sonuçlarına göre rassal orman regresyon modelinin, en düşük hata metrik değerlerine sahip olduğu tespit edilmiş ve bu regresyon modeli ERP altyapısına entegre edilmiştir. Tahminleme ile ürünler için klasman ve tedarik bazında standart süreler elde edilmiş olup bu standart süreler ile maliyetlendirme, verimlilik ölçme, raporlama ve performans değerlendirme çalışmaları yapılmıştır. Ayrıca, tahmin edilen üretim süreleri ve hat üzerindeki çeşitli parametrelere göre üretim çizelgeleme çalışması tasarımı yapılmış olup firma tarafından test edilecektir. Yapılan çalışma, kendi kendine karar verebilen akıllı bir sistemin altyapısının oluşturulması bakımından önemli olup süreçlerin dijital ikizlerinin oluşturulmasına katkı sağlayacağı düşünülmektedir.

Anahtar kelimeler: Endüstri 4.0, Dijital İkiz, Akıllı Üretim, Hazır Giyim Sektörü

USING DIGITAL TWIN TECHNOLOGY IN PRODUCTION PLANNING AND CONTROL PROCESS: AN APPLICATION IN TEXTILE INDUSTRY

SUMMARY

Today, with the combination of existing production and design technologies with modern information and communication technologies, the digitalization process in production and design has begun. Especially with the emergence of Industry 4.0 technologies such as the internet of things, cloud computing, big data analytics, artificial intelligence and digital twin, today's production paradigm has begun to transform into intelligent production. One of these technologies, the digital twin, creates a virtual and real-time representation of production systems or components, providing future-oriented information about products or production systems with constantly collected data. In addition, it provides many advantages such as detecting problems in processes, speeding up the design cycle of products, identifying the source of quality problems and preventing errors. Because of these advantages, it has started to be applied more and more in areas such as smart manufacturing, smart building management, smart city, health, oil, gas and many more. However, in order to create and implement digital twins of products or systems, first of all, necessary data must be collected, organized, processed and made meaningful.

In this study, it is aimed to examine the processes from end to end within the scope of the data digitization project in the production facility of a leading company operating in the garment industry and to make data-oriented process designs using new generation information technologies. Accordingly, it is targeted to create the necessary process infrastructures for making digital twin models, which is a newly developing and rapidly growing technology. In the study, first of all, process maps were created and the constantly changing data of the processes were obtained with the help of sensors and interfaces and transferred to the system. Then, by establishing a connection between the process-based times taken from the machines on the production line and the characteristics of the product to be produced, how long it will take for any product to be completed when it enters the process was estimated on the Knime platform using linear regression, polynomial regression, gradient boosting decision forest regression and random forest regression algorithms. According to the estimation results, it was determined that the random forest regression model had the lowest error metric values and this regression model was integrated into the ERP infrastructure. With estimation, standard times were obtained for products on the basis of classification and supply, and costing, productivity measurement, reporting and performance evaluation studies were carried out with these standard times. In addition, the production scheduling study has been designed according to the estimated production times and various parameters on the line and will be tested by the company. The study is important in terms of creating the infrastructure of a smart system that can decide on its own, and it is thought that it will contribute to the creation of the digital twins of the processes.

Keywords: Industry 4.0, Digital Twin, Smart Manufacturing, Garment Industry

1. GİRİŞ

Günümüze gelinceye kadar üç adet büyük sanayi devrimi gerçekleşmiştir (Can ve Kıymaz, 2016). Birinci Sanayi Devrimi (Endüstri 1.0), 18. yüzyılda buhar makinaları ile başlamış ve üretimin artırılması amacıyla ortaya çıkmıştır. İkinci Endüstri Devrimi (Endüstri 2.0), 20. yüzyılın başında elektrik enerjisinin kullanılarak seri üretime geçiş için yapılmıştır. Sonrasında ise, analog üretim sistemlerinin yerini dijital üretim sistemlerinin almasıyla Üçüncü Endüstri Devrimi (Endüstri 3.0) ortaya çıkmıştır (Sayer ve Ülker, 2014; Can ve Kıymaz, 2016). Ortaya çıkan bu üç sanayi devriminin de amacı, üretimde verimliliği arttırmaktır (Can ve Kıymaz, 2016). Ancak sadece verimliliği artırmak, dünyadaki üretim şirketlerini ön plana çıkaramamıştır. Şirketler, o dönemlerde yaşanan çevresel, toplumsal, ekonomik ve teknolojik gelişmelere bağlı olarak ciddi zorluklarla karşı karşıya kalmışlardır. Bu zorlukların üstesinden gelebilmek için, tasarımdan dağıtıma kadar tüm yaşam döngüsü boyunca yakın işbirliği ve hızlı adaptasyona izin veren sanal ve fiziksel yapılara ihtiyaç duymuşlardır (Schumacher ve diğ, 2016; Yıldız, 2018). Bu yüzden, son olarak siber teknolojilerin gelişmesi ve bunların hepsinin dijital ekosistemlere entegre edilmesi ile beraber “Endüstri 4.0” adı verilen dördüncü sanayi devrimi ortaya çıkmıştır. Genel olarak yenilikçi bilgilerin geliştirilmesini ve entegrasyonunu kapsayan bir sanayi devrimi olarak adlandırılan Endüstri 4.0, iş dünyasının dönüşümü olarak da adlandırılabilir. Fiziksel dünya ile sanal dünyanın Siber-Fiziksel Sistemler (CPS) olarak birleştiği bir olgu olan Endüstri 4.0, üretim sistemleri için dijital, özerk ve merkezi olmayan kontrol paradigması getiren üretim süreçlerinin entegrasyonunu yaparak firmaların daha yüksek performans elde etmelerine olanak sağlayan bir endüstriyel devrim olarak kabul edilmektedir (Dündar ve Yıldız, 2021). Bu endüstri devriminde, geleneksel üretim teknolojileri modern bilgi ve iletişim teknolojileri ile birleştirilmiştir (Cattaneo ve Macchi, 2019). Çünkü, geleneksel üretim yöntemleri büyük veriyi barındırmaya yönelik olmadıklarından dolayı veri odaklı ürün tasarımını desteklemek için doğrudan kullanılamamaktadır. Bunun sonucu olarak, dinamik olarak değişen verilere ve ortaya çıkan yeni durumlara hızlı bir şekilde cevap verememektedir (Karagöz ve Yıldız,

2020). Bu yüzden geleneksel imalat endüstrileri, Bulut Bilişim (Cloud Computing-CC), Nesnelerin İnterneti (Internet of Things-IoT), Büyük Veri (Big Data-BD) ve Yapay Zekâ (Artificial Intelligence-AI) gibi yeni bilgi ve iletişim teknolojilerinden yararlanarak tasarımlarını ve üretimlerini dijitalleştirmek için büyük bir gayret göstermektedirler (Carolis ve diğ, 2017; Tao ve Zhang, 2017; Cattaneo ve Macchi, 2019).

Endüstri 4.0 devrimiyle ortaya çıkan bilgi ve iletişim teknolojileriyle birlikte büyük veri odaklı ürün tasarımları ve üretimleri dönemine gelinmiştir (Karagöz ve Yıldız, 2019). Bu dönemde, şirketlerin verileri kullanarak üretimlerini akıllı hale getirmeleri için üretim süreçleriyle bu teknolojilerini entegre etmeleri aiamalarında akıllı ara bağlantı, akıllı etkileşim, akıllı kontrol ve yönetim dahil olmak üzere bir dizi akıllı operasyon gerçekleştirmeleri gerekmektedir (Carolis ve diğ, 2017; Tao ve Zhang, 2017). Burada, temel bir üretim birimi olarak, sadece akıllı üretimin zorunlu talebi değil, aynı zamanda fiziksel ve sanal alanlar arasındaki etkileşim ve entegrasyonu sağlamak için bir teknoloji tabana ihtiyaç duyulmaktadır (Tao ve Zhang, 2017). Bu bağlamda, gittikçe daha fazla işletme tarafından benimsenen bir kavram olan siber-fiziksel entegrasyona ulaşmak için yeni gelişen ve hızlı büyüyen bir teknoloji olan dijital ikiz teknolojisi benzersiz bir kolaylık sağlamaktadır (Cattaneo ve Macchi, 2019; Qi ve diğ, 2019).

Dijital ikiz, ürünün gerçek fiziksel dünyadaki davranışlarını sergileyen sanal bir kopyasıdır. Sorunları tespit etmeye, yeni ayarları test etmeye, her türlü senaryoyu simüle etmeye, analiz edilmesi gereken şeyleri analiz etmeye, aslında hemen hemen fiziksel dünyada yapılmasına ihtiyaç duyulan her şeyin sanal ürün üzerinde yapılmasına yardımcı olmaktadır. Dijital ikiz esasen, herhangi bir fiziksel sistemin yapısını, bağlamını ve davranışını temsil eden verilerle, geleceğe yönelik öngörüler yapmayı sağlayan bir arayüz sunmaktadır. Bunlar, fiziksel dünyayı optimize etmek için kullanılabilir, operasyonel performansı ve iş süreçlerini önemli ölçüde geliştiren çok güçlü dijital nesnelerdir. Ek olarak, bizler için fiziksel ve dijital dünya arasındaki köprüdür (Khajavi ve diğ, 2019). Dijital ikiz, süreçlere ait gerçek verileri kullanarak sanal ortamlar oluşturur ve hem ürünlerin hem de süreçlerin etkili bir şekilde kolaylıklar sağlamaktadır (Tao ve diğ, 2019).

Süreçlerin ya da ürünlerin dijital ikizlerinin oluşturulmasındaki en önemli aşamalardan biri tasarım, üretim, dağıtım, kullanım, bakım, yükseltme ve geri dönüşüm dahil olmak


üzere bir ürünün yaşam döngüsünün farklı aşamalarında oluşan verilerin toplanması ve işlenmesidir (Tao ve diğ, 2019).

Bundan dolayı bu çalışmada, hazır giyim perakende sektöründe faaliyet gösteren öncü olan bir firmanın veri dijitalleştirme projesi kapsamında, fiziksel ortamın sanal kopyasının oluşturulması ile üretimi her yönden analiz etmeye yardımcı olacak dijital ikiz çalışmalarının altyapısının oluşturulması amaçlanmıştır. Bunun için, mevcut ve olması istenen sistem süreç haritalarının oluşturulmuş, tüm verilerin arayüzler ile veritabanında tutulmasının sağlanmış ve son olarak Knime platformu aracılığıyla dört farklı regresyon algoritması kullanılarak süre tahminlemesi yapılmıştır.

Yapılan tezin ikinci bölümünde Endüstri 4.0 anlatılmış, üçüncü bölümde dijital ikiz teknolojisinin amaçları, önemi, içeriği ve uygulama alanlarını incelenmiş, dördüncü bölümde çalışmada kullanılan materyal ve metod açıklanmış, beşinci bölümde çalışmadan elde edilen bulgulara yer verilmiş ve son bölümde sonuç ve değerlendirmeler yapılmıştır.

2. ENDÜSTRİ 4.0

Belli bir alandaki hızlı, köklü ve nitelikli değişimler devrim olarak adlandırılırlar. Genel kabule göre insanoğlu iki temel devrim yaşamıştır. Bunlardan ilki avcı ve toplayıcı toplumlar halinde yaşayan insanları, çiftçi ve çoban toplumlarına dönüştüren tarım devrimidir. Diğerisi ise çiftçi ve çoban toplumlarının nüfusunu radikal biçimde azaltarak onları artan ölçüde hizmet ve mamul mal üreticisi haline getiren endüstri devrimidir. Endüstri devrimiyle insanlar sınırsız bir biçimde mal ve hizmet üretebilme imkânı elde etmişlerdir. İnsanlar endüstri devrimini sahiplenerek Şekil 2.1'deki gibi safha safha geliştirmişlerdir. İlk safha, 18. yüzyılda insan gücünün yerini buharlı makinelerin almaya başlamasıyla birlikte, üretimi önemli şekilde değiştiren I. Endüstri Devrimidir. İkinci safha, 20. yüzyılda elektriğin üretime entegrasyonu ile seri üretimin başlamasına neden olan II. Endüstri Devrimi'dir. 1970'li yılların başında ise, üretimde ileri otomasyon sistemlerinin kullanılmasıyla üçüncü safha olarak III. Endüstri Devrimi insan hayatına girmiştir. Günümüzde ise insansız üretim gerçekleştirecek fabrikaların ön plana çıktığı dördüncü safha olan Endüstri 4.0 olarak adlandırılan IV. Endüstri Devrimindeyiz (Özbek ve Yıldız, 2020).



Şekil 2.1: Endüstri devrimlerinin gelişimi (Kagermann ve diğ., 2013).


Endüstri 4.0, mevcut üretim teknolojilerinin modern bilgi ve iletişim teknolojileri ile birleşmesi olup arkasındaki itici güç, endüstrinin ve toplumun hızla dijitalleşmesidir

(Bitkom ve diğ, 2015). Endüstri 4.0'ın temel amacı, sipariş yönetimi, araştırma ve geliştirme, üretimin devreye alınması, kullanımı ve ürünlerin geri dönüştürülmesi gibi alanları etkileyen bireysel müşteri ihtiyaçlarını karşılamaktır (Bitkom ve diğ, 2015).

Endüstri 4.0, normal makineleri kendi kendini tanıyan ve kendi kendine öğrenen makinelere dönüştürerek performanslarını ve çevre etkileşimi ile süreç yönetimini iyileştirmenin yanı sıra endüstriyel ağ bağlantılı bilgi uygulamasıyla açık ve akıllı bir üretim platformunun inşasını amaçlamaktadır (Lee ve diğ, 2014; Bahrin ve diğ, 2016). Endüstri 4.0 paradigması, sensörler, cihazlar ve kurumsal varlıklar gibi fiziksel öğelerin hem birbirine hem de internete bağlanmasını teşvik eder (Sipsas ve diğ, 2016). Gerçek zamanlı veri izleme, ürünün durum ve konumlarının takibi ve üretim süreçlerini kontrol etmek için talimatların tutulması Endüstri 4.0'ın temel ihtiyaçlarıdır (Almada ve Lobo, 2015). Şirketler, Endüstri 4.0' ın başarılı bir şekilde uygulanmasını sağlamak için akıllı ürün ve akıllı süreçleri; ürün geliştirme, üretim, lojistik, pazarlama, satış ve satış sonrası hizmetler gibi temel işlevlerine dahil etmeye ve yeniden tanımlamaya odaklanmalıdır (Porter ve Heppelmann, 2015).


2.1 Endüstri 4.0 Teknolojileri

Endüstri 4.0'ın temelini; nesnelerin interneti, büyük veri analitiği, siber güvenlik, bulut bilişim, artırılmış gerçeklik, simülasyon, otonom robotlar, eklemeli (katmanlı-3B) imalat, bulut gibi Şekil 2.2'de gösterilen teknolojiler oluşturmaktadır (Bortolini ve diğ, 2017). Belirtilen bu teknolojilerden bazıları aşağıda kısaca açıklanmıştır.



Şekil 2.2: Endüstri 4.0'ın temel teknolojileri devrimlerinin gelişimi (Bortolini ve diğ, 2017).

Nesnelerin interneti (IoT): Çok sayıda benzersiz şekilde adreslenebilir nesnenin birbirleriyle iletişim kurmasına ve mevcut internet veya uyumlu ağ protokolleri üzerinden veri aktarmasına izin verir (Ray, 2016). Aynı zamanda, fiziksel nesnelerin bilgi ağına sorunsuz entegre edildiği imalat endüstrilerinin sayısallaştırılarak üretimin gerçek zamanlı olarak gerçekleşmesine imkan tanımaktadır (Ustundag ve Cevikcan, 2017). IoT, insanları, süreçleri, cihazları ve teknolojileri sensörler ve aktüatörlerle birleştirir. IoT'nin iletişim, işbirliği ve teknik analitik açısından insanla genel entegrasyonu, gerçek zamanlı kararların alınmasını sağlar (Giusto ve diğ, 2010). IoT, fiziksel ve sanal nesnelerin kimliklere, fiziksel niteliklere ve sanal kişiliklere sahip olduğu, akıllı arayüzler kullandığı, sorunsuz bir şekilde çalıştığı standart ve birlikte çalışabilir iletişim protokollerine dayanan kendi kendini yapılandırma yeteneklerine sahip dinamik bir küresel ağ altyapısı ile bilgi ağına entegre olarak genellikle kullanıcılar ve ortamları ile ilişkili verileri iletir (Smith, 2012). IoT teknolojisinin artan üstünlüğü, RFID, UWB, ZigBee, sensör ağları ve konum tabanlı teknolojiler gibi çeşitli kısa menzilli kablosuz teknolojilerin internete bağlanmasını kolaylaştırılmaktadır (Feki ve diğ, 2013). IoT, internetin etkisini insanların günlük yaşamlarında daha yaygın hale getirmektedir.



Şekil 2.3: Kategorize edilmiş IoT sistemleri kullanım alanları (Teich, 2014).


Örneğin araç elektroniği, ev çevre yönetim sistemleri, telefon ağları ve yerel kamu hizmetlerinin kontrolünü sağlamak için IoT kullanılabilir (Miraz ve diğ, 2018). IoT, kullanım türüne bağlı olarak; Endüstriyel Nesnelerin İnterneti (IIoT), Tüketici Nesnelerin İnterneti (CIoT) ve İnsan Nesnelerin İnterneti (HIoT) olarak kategorize edilebilir (Miraz ve diğ, 2018). Kategorize edilmiş IoT sistemlerinin kullanım alanları Şekil 2.3’te gösterilmektedir.

Burada kullanılan IIoT; ürünlerin, ekipmanların, üretim hatlarının, fabrikaların, tedarikçilerin, müşterilerin ve diğer işletmelerin her türlü iç ve dış verilerini birbirine bağlayabilir ve iletişim teknolojisi aracılığıyla cihazlar, sistemler, fabrikalar ve bölgeler arasında ara bağlantı ve birlikte çalışabilirliği gerçekleştirebilir ayrıca bilgi teknolojisine dayalı devasa endüstriyel verileri araştırabilir ve analiz edebilir (Wang ve diğ, 2021).

Büyük veri analitiği: 2000’lerin başında veri hacimleri hızla yükselmeye başladığında, depolama ve işlemci teknolojileri, çok sayıda terabaytlarca büyük veri tarafından dolduruldu. Bu durum bilgi teknolojilerinin bir veri ölçeklenebilirlik kriziyle karşı karşıya kalmasına neden oldu (Russom, 2011). Ancak geleneksel veri

analitikleri ile bu kadar büyük miktarda veriyi işlemek, takip etmek ve hangi durumlarda kullanıma hazır olduklarını belirlemek zordur (Russom, 2011; Tsai ve diğ, 2015). Bununla birlikte, işletmeler büyük verileri yönetemedikleri için toplama ve analiz işlemlerine büyük miktarlarda bütçeler ayırmışlardır. Günümüzde ise işletmeler, daha önce bilmedikleri gerçekleri keşfetmek için büyük verileri araştırıyorlar ve gelişmiş analitiği kullanarak işletmenin mevcut durumunu anlamlandırmayla müşteri davranışı gibi halen gelişen yönleri izlemek için büyük verileri incelemektedirler (Russom, 2011). Elde ettikleri verilerin bir kısmı sensörlerden, cihazlardan, web uygulamaları ve sosyal medya gibi üçüncü şahıslardan gelmektedir. Bazı büyük veri kaynakları, verileri kesintisiz olarak gerçek zamanlı besler. Büyük veri, yalnızca devasa veri hacimleriyle ilgili olmayıp aynı zamanda çeşitli hızlarda ve frekanslarda sunulan olağanüstü veri türleri çeşitliliğiyle de ilgilidir (Russom, 2011). Büyük verileri, verimli bir şekilde analiz etmek için yüksek performanslı bir platformun nasıl geliştirileceği ve büyük verilerden yararlı şeyleri bulmak için uygun bir madencilik algoritmasının nasıl tasarlanacağı sorunu ortaya çıkmaktadır. Aslında, büyük ölçekli verileri analiz etme sorunları yıllardır devam etmektedir. Çünkü veri oluşturmak genellikle verilerden faydalı şeyler bulmaktan çok daha kolaydır. Günümüz bilgisayar sistemleri 1930'lardakinden çok daha hızlı olsa da, büyük ölçekli veriler bugün sahip olduğumuz bilgisayarlar tarafından analiz edilmesi gereken bir yüküdür (Tsai ve diğ, 2015). Büyük ölçekli verileri analiz etme sorunlarına çözüm olarak, oldukça az sayıda verimli yöntem bulunmaktadır. Büyük veri analizinde ayrıntılı bilgi için büyük miktarda verilerle birlikte tahmine dayalı analitik, veri madenciliği, istatistik, yapay zeka, doğal dil işleme, örnekleme, veri yoğunlaştırma, yoğunluğa dayalı yaklaşımlar, ızgara tabanlı yaklaşımlar, böl ve yönet yaklaşımları, artımlı öğrenme ve dağıtılmış hesaplama gibi gelişmiş analitik araç türleri bir araya gelerek bilgi teknolojilerindeki en yeni uygulama olan büyük veri analitiğini meydana getirmiştir (Xu ve Wunsch, 2009; Russom, 2011). Bu yöntemler, veri analitiği sürecinin performansını iyileştirmek için sürekli olarak kullanılmaktadır (Lyman ve Varian, 2003). Büyük veri, mevcut bilgi sistemleri veya yöntemlerinin çoğu tarafından işlenemeyecek ve tek bir makineye yüklenemeyecek kadar büyük bir boyuttadır. Ayrıca, merkezi bir veri analizi süreci için geliştirilen çoğu geleneksel veri madenciliği yönteminin veya veri analitiğinin doğrudan büyük verilere uygulanamayacağı anlamına gelir (Fisher ve diğ, 2012). Veritabanlarında, tüm bilgi keşfi sürecini daha açık hale getirmek için veritabanı süreci; seçme, ön işleme, dönüştürme, veri

madenciliği ve yorumlama/değerlendirme olmak üzere birkaç işlemle özetlenmektedir (Fayyad ve diğ, 1996). Verinin toplanmasının ardından verilerden bilgi bulmak ve bilgiyi kullanıcıya göstermek için eksiksiz bir veri analitiği sistemi Şekil 2.4'te gösterilmektedir.




Şekil 2.4: Veritabanlarında bilgi keşfi süreci (Tsai ve diğ, 2015).

Şekil 2.4'te gösterildiği gibi, toplama, seçme, ön işleme ve dönüştürme operatörleri veri girişi kısmındadır. Seçim operatörü genellikle veri analizi için hangi tür verilerin gerekli olduğunu bilme ve toplanan verilerden veya veri tabanlarından ilgili bilgileri seçme rolünü oynar. Bu nedenle, farklı veri kaynaklarından toplanan verilerin hedef verilere entegre edilmesi gerekecektir. Ön işleme operatörü; gereksiz, tutarsız ve eksik verileri yararlı veriler haline getirmek için algılamayı, temizlemeyi ve filtrelemeyi amaçlar. Seçim ve ön işleme operatörlerinden sonra, ikincil verilerin özellikleri farklı veri formatında olabilir. Veritabanlarında bilgi keşfi sürecinin, dönüştürme operatörü tarafından gerçekleştirilen veri madenciliği özellikli bir biçime dönüştürmesi gerekir. Karmaşıklığı azaltma ve verileri, veri analizi bölümünde kullanılmak üzere yararlı hale getirmek için veri ölçeğini küçültme yöntemleri, genellikle boyut indirgeme, örnekleme, kodlama veya dönüştürme gibi dönüşümde kullanılır (Tsai ve diğ, 2015).

Siber-fiziksel sistem (CPS): CPS, çok sıkı bir ara bağlantıya sahip siber yetenekleri olan fiziksel sistem bileşenlerinin bir kombinasyonudur. CPS, elektrik güç sistemleri, iletişim, ulaşım ve sağlık sistemleri dahil olmak üzere birçok uygulamada yaygın olarak kullanılan bir teknolojidir. Bunlar kritik ulusal altyapılardır. Siber güvenlik saldırısı, çeşitli sistem bileşenleri arasındaki karmaşıklık ve karşılıklı bağımlılıklar, iletişim, bilgi işlem ve kontrol teknolojisinin entegrasyonu dahil olmak üzere birçok nedenden dolayı bir CPS için en büyük tehditlerden biridir. Siber güvenlik saldırıları,


retim ve performansın bozulması, kritik hizmetlerin kullanılamaması ve ynetmeliğın ihlali dahil olmak zere kritik altyapı iř srekliliğini etkileyen eřitli risklere yol aabilir (Kure ve diğ, 2018). CPS'ler iin mevcut birok risk ynetimi yntemi vardır (Cardenas ve diğ, 2011; Cherdantseva ve diğ, 2016). Bununla birlikte CPS'lerde risk ynetimi; sistemlerin artan karmařıklıėı, risk seviyelerinin evrimi, kasıtsız gvenlik ihlallerinden oluřan insan faktr tehditleri, hassas bilgileri aıėa ıkaran virsl bilgi medyasının řpheli olmayan kullanımı, farkındalık eksikliėi ve insan hataları nedeniyle zorludur (Peng ve diğ, 2013). Siber gvenlik risklerini ynetmek, CPS'yi korumak iin ok nemlidir (Kure ve diğ, 2018). Genel olarak siber-fiziksel sistemler, yksek performans gereksinimleri olan gerek zamanlı ve saėlam baėımsız sistemlerdir (Wu ve diğ, 2015). Kritik altyapıların CPS'leri, karmařıklıkları ve siber-fiziksel baėlantıları nedeniyle gvenlik tehditlerinden etkilenererek her zaman suluların hedefi olmuřtur. Bu CPS'ler; insan, sre, teknoloji gibi bileřenler saldırıya uėradıėında veya risk ynetim sistemleri eksik, yetersiz olup herhangi bir řekilde bařarısızlık meydana geldiėinde gvenlik ihlalleriyle karřı karřıya kalınır. Saldırganlar, mřteri bilgileri veya diėer deėerli kayıtlar gibi gizli verileri hedefler (Marvell, 2015). Sistemlerin kullanımı yaygınlařtıėa CPS tehditlerinin artması muhtemeldir. Ancak, kuruluřların yıkımlarından kaynaklanan kayıpları en aza indirmek iin dikkate alabilecekleri makul gvenlik nlemleri vardır (Adar ve Wuchner, 2005). CPS, sadece anlık gvenlik riskini ynetmek veya tm riskleri ortadan kaldırmakla ilgili deėildir. Olayların risk derecesini belirlemek, anlamak ve bunları organizasyonun risk tolerans dzeyine gre ynetmek iin doėru sreleri veya kontrolleri uygulamaya koymakla ilgilidir. Risk ynetimi tek seferlik bir olay deėil, srekli bir sretir (Abouzakhar, 2013). Bir olaya yanıt olarak, kuruluřların siber-fiziksel gvenlik durumlarını gerekten anlamaları ve zayıflıkları gidermek iin gerekli ve dzeltici eylemleri gerekleřtirmelerine acil bir ihtiya vardır (Marvel, 2015). Bileřenler ve altyapılar arasındaki karřılıklı baėımlılıklar nedeniyle kademeli arızalar meydana gelir. Daha da nemlisi, bir CPS' in bir blmn etkileyen tehditler, birbirine baėlanan aė aracılıėıyla diėer blmlere yayılabilir. Gvenlik tehditleri bydke kuruluř, benzersiz siber gvenlik tehditlerini ve eėilimlerini belirlemek iin kapsamlı bir siber gvenlik risk ynetim sistemine ihtiya duyar (Kure ve diğ, 2018).

Bulut bilişim: Bulut teknolojisi, potansiyel olarak milyarlarca sensörü, kamerayı, ekranı, akıllı telefonu ve diğer akıllı iletişim cihazlarını uçtan uca bağlayan, bulut veri merkezlerine entegre eden sistemdir (Georgakopoulos ve diğ., 2016). Ulusal Standartlar ve Teknoloji Enstitüsüne (NIST) göre bulut bilişim, “en az yönetim hizmeti veya servis sağlayıcı müdahalesiyle hızla alınabilen ve verilebilen esnek yapıdaki ayarlanabilir bilişim kaynaklarının (ağ hizmeti, sunucu hizmeti, depolama hizmeti, uygulamalar ve diğer hizmetler gibi) paylaşıldığı havuza istendiğinde uygun bir şekilde ağ erişimi sağlayan bir modeldir” olarak tanımlanmaktadır (Kavzoğlu ve Şahin, 2012). Bulut bilişim, hizmet odaklı bir mimari, son kullanıcı için azaltılmış bilgi teknolojisi yükü, büyük esneklik, azaltılmış toplam sahip olma maliyeti, isteğe bağlı hizmetler gibi daha birçok şeyi ifade eder. Bulut bilişim, isteğe bağlı bilgi teknolojisi hizmetleri ve ürünlerinin evriminde bir sonraki doğal adımdır (Vouk, 2008). Bulut bilişimin bileşenleri Şekil 2.5’de gösterilmektedir (Kavzoğlu ve Şahin, 2012).



Şekil 2.5: Bulut bilişim bileşenleri (Kavzoğlu ve Şahin, 2012).


Farklı hizmetler kullanan bulut bilişim, geleneksel bilgi işlemde daha fazla fayda sağlar. Maliyet tasarrufu, ölçeklenebilirlik, mobil depolama, her yerden erişim, daha iyi güvenlik, enerji tasarrufu, çevre faydaları bulut bilişimin faydalarından bazılarıdır. Geleneksel bilgi işlemde bulut bilişime geçiş giderek artmaktadır (Sether, 2016). Kuruluşlar ve bireyler bundan faydalanan uygun maliyetli modellerde, örneğin abonelik ve kiralama tabanlı maliyet modelleri gibi birçok farklı bulut bilişim hizmeti kullanmaktadır (Sether, 2016). Şekil 2.6’da ise bulut bilişim modeli gösterilmektedir (Bugiel ve diğ., 2011).



Şekil 2.6: Bulut bilişim modeli (Bugiel ve diğ, 2011).

Şekil 2.6’da gösterilen bulut bilişim modelinde; emtia bulut güvenilmeyen depolama sağlar ve iki bulut, güvenli olmayan, yüksek bant genişliğine sahip bir kanalla birbirine bağlanır. İstemci, güvenilir bulut ile düşük bant genişliğine sahip, güvenli bir kanal üzerinden iletişim kurar. Güvenli kanal ve bant genişlikleri, oluşturulan bulut modeline göre değişkenlik göstermektedir (Bugiel ve diğ, 2011).

Arttırılmış gerçeklik: Arttırılmış gerçeklik gerçek dünyadaki nesne ve mekanların, bilgisayar sistemlerinde oluşturulmuş sanal öğeler kullanılarak zenginleştirilmesiyle elde edilir (Altınpulluk, 2015). Arttırılmış gerçeklik teknolojisi akıllı üretim alanında yeni modellerin, araçların, formların, sistem mimarisinin ve teknoloji sistemlerinin geliştirilmesini kolaylaştırmaktadır (Li ve diğ, 2014). Arttırılmış gerçekliğin ana özellikleri arasında yoğun derin öğrenme için veriye dayalı sezgisel algılama yeteneğine sahip olması, internet tabanlı sürü zekası, teknoloji odaklı insan-makine hibrit arttırılmış zeka ve ayrıca çapraz medya akıl yürütmenin yükselişi yer almaktadır (Pan, 2016). Çevremizdeki fiziksel dünyayı, dijital bilgilerle zenginleştiren ve bu bilgilerle etkileşim mekanizması olarak doğal el hareketleri öneren, bilgisayarla görü tabanlı giyilebilir ve hareketle ilgili bir bilgi arabirimi tasarlayan Pranav Mistry arttırılmış gerçeklik ile giyilebilir cihazlara verilebilecek en güzel örneklerdendir. Şapkaya monte edilmiş kamera ve küçük bir projektör veya mobil giyilebilir cihaz gibi bir kolyeden oluşan tasarım Şekil 2.7’de verilmiştir.



Şekil 2.7: Giyilebilir teknoloji tasarımı (Mistry ve diğ, 2009)

Kamera, kullanıcının gördüğünü görür ve projektör kullanıcının etkileşimde olduğu yüzeyleri veya fiziksel nesneleri görsel olarak artırır. Arayüz bilgileri, kullanıcının etrafındaki yüzeylere, duvarlara ve fiziksel nesnelere yansır. Kullanıcının doğal el hareketleri, kol hareketleri veya nesnenin kendisinin doğrudan manipülasyonu yoluyla yansıtılan bilgilerle etkileşime girmesini sağlar (Mistry ve diğ, 2009).

Simülasyon: Ürün, süreç ve sistem tasarımı ve konfigürasyonunun denenmesine ve doğrulanmasına izin verdiğinden, dijital üretimin başarılı bir şekilde uygulanması için vazgeçilmez bir dizi teknolojik araç ve yöntem içerir. Özellikle küreselleşme gibi mega trendlerden daha yüksek derecede ürün özelleştirmesi ve kişiselleştirme için sürekli artan gereksinimlerden etkilenen günümüzün çalkantılı üretim ortamında, simülasyonun değeri oldukça önemlidir. Dikkate alınan simülasyon yöntemleri ve araçları arasında bilgisayar destekli egzersizler, fabrika yerleşim tasarımı, malzeme ve bilgi akışı tasarımı, imalat ağları tasarımı, imalat sistemleri planlaması ve kontrolü, imalat ağları planlaması ve kontrolü, ürün ve süreç tasarımında artırılmış ve sanal gerçeklik, planlama ve doğrulama (ergonomik, robotik) yer alır (Mourtzis ve diğ, 2014). Modern üretim teknolojilerine sahip bir fabrika tasarımında kullanılan bu araçlar Şekil 2.8’de gösterilmektedir.




Şekil 2.8: Modern üretim teknolojilerine sahip bir fabrika tasarımında kullanılan araçlar (Mourtzis ve diğ, 2014).

Otonom Robotlar: Endüstri 4.0 devriminde öngörülen verimlilik ve etkinlik kazanımlarını elde etmek için makineler ve robotlar için yüksek oranda otomasyon gereklidir (Bibby ve Dehe, 2018). Bu gereksinimlerden dolayı robotlar her geçen gün daha özerk, esnek ve işbirlikçi hale gelerek otonom olmaktadır (Vaidya ve diğ,

2018). Otonom robotlar olarak da bilinen gelişmiş robotlar, Endüstri 4.0'ın tanıtımı için önemli bir etkinleştiricidir. Sensörler, artırılmış yapay zeka ve makine öğrenimi ile donatılmış otonom robotlar Endüstri 4.0 devriminin ilerlemesini sağlayan kilit teknolojilerden biridir (Bibby ve Dehe, 2018). Otonom bir robot, otonom üretim yöntemini daha hassas bir şekilde gerçekleştirmek için kullanılır ve insanların çalışmakla sınırlandırıldığı yerlerde çalışır. Otonom robotlar, verilen süre içinde verilen görevi hassas ve akıllı bir şekilde tamamlayabilir. Ayrıca güvenlik, esneklik, çok yönlülük ve işbirliğine odaklanabilir (Vaidya ve diğ., 2018). Üretim endüstrilerinde otomasyonun kullanılması, kuruluşların normalde yapabileceklerinden daha fazla çıktı vermelerini sağlamaktadır. Otonom robotların kullanımı, insan işçilerden daha hızlı, daha güçlü ve daha hassas olarak endüstrilerin üretkenliğini büyük ölçüde artırmaktadır. Günümüzde robotlar yalnızca çok tekrar eden, düşük vasıflı işler için değil, aynı zamanda orta vasıflı, oldukça rutin faaliyetlerde de kullanılmaktadır (Bibby ve Dehe, 2018).

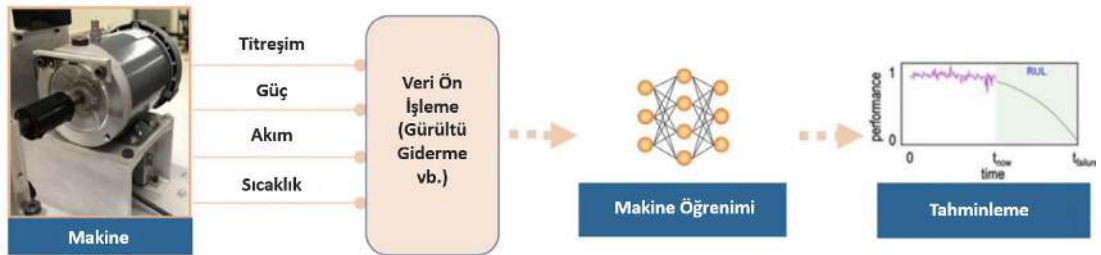
Katmanlı (Eklemeli - 3B) üretim: Malzemeleri füzyon, bağlama veya sıvı reçine ve tozlar gibi katılaştırma yoluyla karıştırma tekniği olarak tanımlanabilir. 3B CAD modellemeyi kullanarak katman katman şekilde parça oluşturur. 3B baskı, hızlı prototipleme, doğrudan dijital üretim, hızlı üretim ve katı serbest biçimli üretim gibi terminolojiler, eklemeli üretim süreçlerini tanımlamak için kullanılabilir. Eklemeli üretim süreçleri, nesnenin geometrisi ile ilgili bilgileri içeren 3B bilgisayar verilerini veya Standart Mozaikleme Dili (STL) dosyalarını kullanarak bileşenler üretir. Eklemeli üretim, düşük üretim hacimleri, yüksek tasarım karmaşıklığı ve sık tasarım değişiklikleri gerektiğinde çok kullanışlıdır. Geleneksel üretim yöntemlerinin tasarım kısıtlamalarını aşarak karmaşık parçalar üretme imkanı sunar. Eklemeli üretimin birçok faydası olmasına rağmen, CNC makinelerine kıyasla düşük doğruluğu ve uzun yapım süreleri nedeniyle uygulamaları hala sınırlıdır (Abdulhameed ve diğ., 2019). Geleneksel yaklaşımlar üretimde çoğunlukla 2B CAD çizimlerinin oluşturulmasına odaklanırken, mevcut yeniden yapılandırmalar giderek artan şekilde 3B modelleme tekniklerini uygulamaktadır (Boeykens, 2011). Çeşitli parametreler için 3B modelleme tasarımına örnek Şekil 2.9'da gösterilmektedir. Bu tasarımlarda, parametrelerden bir veya birden fazlasında gerçek ortamda olmaksızın modelleme esnasında değişiklik yapılarak şartlara en uygun modelin oluşturulması sağlanır (Talut, 2018).



Şekil 2.9: Çeşitli parametreler ile 3B modelleme örneği (Talu, 2018).

Yapay zeka: Yapay zeka terimi, ağırlıklı bir girdi toplamını kullanarak bir insan sinir sistemini simüle etmek için tasarlanmış bir sinir ağı yapısı olan algılayıcının icadına dayanır (Cardon ve diğ, 2018; Wang, 2019). Bilgisayarların algılama, akıl yürütme, öğrenme ve problem çözme gibi insan zihniyle ilişkili bilişsel işlevleri yerine getirme yeteneği olarak tanımlanabilir (Chui ve diğ, 2018).

Yapay zeka; büyük veri olarak bilinen, üretilen büyük miktardaki üretim verisini işlemek için gelişmiş analitik araçları aracılığıyla üretim alanını dönüştürmek için büyük bir potansiyel göstermiştir. Kritik süreç/makine verilerinin toplanması için algılama teknolojisinin yanı sıra hesaplama donanımındaki son gelişmeler, yapay zeka tekniklerinin uygulanmasını pratik anlamda mümkün kılmıştır. Makine performansının doğrudan ölçülmesinin zor olduğu durumlarda, makine performansını temsil etmek için genellikle sensörler aracılığıyla veriler alınarak yapay zeka uygulamalarında tahminleme yapılır (Arinez ve diğ, 2020). Yapay zekâ biliminin bir alt bilimsel çalışma dalı olan ve Şekil 2.10’da modeli gösterilen makine öğrenimi, verilerden öğrenebilen ve veriler üzerinde tahminlerde bulunabilen algoritmaların çalışılmasını ve oluşturulmasını araştırır (Arinez ve diğ, 2020; Yılmaz ve diğ, 2021).




Şekil 2.10: Makine öğrenimi modeli (Arinez ve diğ, 2020).

Yapay zeka teknikleri benzersiz üretim sorunlarının belirlenmesine yardımcı olur. Böylece üretkenliği, kaliteyi, esnekliği, güvenliğini artırarak maliyeti önemli ölçüde azaltır (Arinez ve diğ, 2020).


2.2 Endüstri 4.0'da Veri

İnternetin günümüzde yaygınlaşması, sensörlerin evrensel varlığı, büyük verilerin ortaya çıkması, e-ticaretin gelişmesi, bilgi topluluğunun yükselişi, veri ve bilginin toplum, fiziksel alan ve siber uzay ile ara bağlantı kurarak kaynaşmasıyla bilgi ortamı derinden değişti ve yeni bir evrim aşamasına yol açtı (Pan, 2016). Elde edilen veriler tasarım, üretim, dağıtım, kullanım, bakım, yükseltme ve geri dönüşüm dahil olmak üzere bir ürünün yaşam döngüsünün farklı aşamalarında toplanabilir. Verilerin toplanmasında ise IoT'dan büyük ölçüde faydalanılmaktadır. IoT teknolojilerini kullanarak mümkün kılınan veriler, gerçek zamanlı olarak doğrudan fiziksel ürünlerden toplanabilmektedir (Tao ve diğ, 2019). Şekil 2.11'de gösterilen Endüstri 4.0 genel çerçevesi, verinin endüstri 4.0 teknolojilerinin gerçekleştirilmesindeki fonksiyonunu göstermektedir.




Şekil 2.11: Endüstri 4.0 çerçevesi (Ustundag ve Cevikcan, 2017).

Şekil 2.12’de ise elde edilen verilerin Endüstri 4.0’ı gerçekleştirme yolundaki dönüşümlerini göstermektedir.



Şekil 2.12: Endüstri 4.0’ı gerçekleştirme yolunda veri dönüşümünün aşamaları (Arden ve Sarah, 2021).

Bu dönüşüm aşamalarında; veriler, bir sistemden alınan ham sinyallerden tam dijital olgunluğa dönüştürülür. Veriler ilk olarak bir üretim sürecinden toplanır, daha sonra verilerin sayısallaştırılması ve analiz edilmesiyle büyük veri dönüşümü gerçekleşir, sonrasında yapay zeka yoluyla algılanan anlamla bilgi olarak sentezlenir ve son olarak dijital olgunluğun birleşik içgörülerıyla elde edilen eyleme dönüştürülür (Arden ve Sarah, 2021). Verilerin bu şekilde dönüştürülmesi ve eyleme geçilmesi Şekil 2.13’te gösterilen akıllı fabrikalara ve akıllı üretime geçiş yapılmasına olanak sağlamaktadır.



Şekil 2.13: Bir akıllı fabrikayı etkinleştiren teknolojiler (Arden ve Sarah, 2021).

Bununla birlikte, akıllı üretime ulaşmak için üretim dünyası ile teknolojilerin entegre edilmesi zorluklardan birisidir. Bu entegreyi sağlayabilmek için sanal dünya, akıllı ara bağlantı, akıllı etkileşim, akıllı kontrol ve yönetim, vb. dahil olmak üzere bir dizi akıllı operasyon gerçekleştirilecektir. Bu bağlamda, temel bir üretim birimi olarak, sadece akıllı üretimin zorunlu talebi değil, aynı zamanda kendisinin gelişen trendi olan fiziksel ve sanal alanlar arasındaki etkileşim ve entegrasyonu sağlamak için bir teknoloji tabana ihtiyaç duyulmaktadır (Tao ve Zhang, 2017). Gittikçe daha fazla işletme tarafından benimsenen bir kavram olan siber-fiziksel entegrasyona ulaşmak için dijital ikiz teknolojisi benzersiz bir yol sağlamaktadır (Qi ve diğ, 2019). Dijital ikiz, aynı zamanda gerçek zamanlı etkileşim ve fiziksel alan ile bilgi alanı arasında daha fazla yakınlaşma için gelişen etkili bir yöntemdir (Zhu ve diğ, 2019).



3. DİJİTAL İKİZ VE UYGULAMALARI

3.1 Dijital İkiz

Sanayi ve ürün tasarımında yeni nesil bilgi teknolojilerinin ortaya çıkmasıyla birlikte, büyük veri odaklı ürün ve süreç tasarımı dönemi başladı. Buna bağlı olarak, fiziksel ve sanal dünyayı birbirine bağlayan, yeni gelişen ve hızlı büyüyen bir teknoloji olan dijital ikiz kavramı ortaya çıkmıştır (Tao ve diğ, 2019). NASA'nın eşleme teknolojisi sonucunda ortaya çıkan dijital ikiz teknolojisi ilk olarak Grieves'in 2003 yılında Ürün Yaşam Döngüsü Yönetimi (PLM) hakkındaki sunumunda ifade edilmiştir (Grieves, 2014).

NASA tarafından geliştirilen dijital ikiz modeli, mevcut fiziksel modellerin geçmiş ve gerçek zamanlı verilerinin kullanılarak ikizinin ömrünü yansıtabilecek entegre, çok katmanlı, olasılıksal ve ultra gerçekçi simülasyon sistemi veya ürünler olduğunu kabul etmektedir (Glaessgen ve Stargel, 2012). Rosen ve diğ, (2015) dijital ikizin, otonom sistem davranışları ile fiziksel dünyadaki çevre arasında etkileşebilen bir model olduğunu söylemektedirler. Bununla birlikte, o zaman dijital ikiz kavramı teknoloji sınırlamaları nedeniyle yeterince olgun değildi. IoT, bulut bilişim, simülasyon teknolojisi ve diğer birçok teknolojinin gelişmesi ile birlikte, dijital ikiz kavramı olgunlaştı ve son zamanlarda dünya çapında büyük ilgi görmeye başladı (Qi ve Tao, 2018).


Algılama, modelleme ve hesaplama gibi bilgi teknolojilerini kapsamlı bir şekilde kullanan dijital ikiz, sanal ortamda dijital formdaki fiziksel alanla tutarlı, yüksek kaliteli bir model oluşturur. Fiziksel alandaki bilgi, gerçek zamanlı geri bildirimi ve veri bütünleşmesi sayesinde nesnelerin davranışlarını simüle edebilir, fiziksel alanı izleyebilir, teşhis edebilir, tahmin edebilir ve kararlar alarak fiziksel alan ve sanal alan arasındaki etkileşimi gerçekleştirebilir (Tao ve Qi, 2019).

Dijital ikiz, sanal ortam ile fiziksel ortam arasındaki gerçek zamanlı etkileşim, yinelemeli operasyon, optimizasyon ve tam personel/süreç/iş verisi odaklı özelliklere sahip olduğundan, ürün geliştirme, tasarım, işletme, bakım, servis ve üretimin tüm yaşam döngüsü sürecinde yaygın olarak kullanılmaktadır. İmalat endüstrisi için dijital

dönüşümü destekleyen anahtar etkinleştirme teknolojisi haline gelmiştir ve aynı zamanda endüstriyel internet uygulamasının da temelini oluşturmaktadır (Wang ve diğ, 2021).

Dijital ikiz, bilgisayar destekli simülasyonlara dayanan tüm üretim döngüsündeki aşamaların yanı sıra üretim sistemlerinin sanal olarak devreye alınması, karar destek sistemleri davranış tahminleri ve tüm ürün yaşam döngüsü boyunca bilgi devamlılığını sağlamaya yardımcı olabilir (Rosen ve diğ, 2015; Abramovici ve diğ, 2016; Schluse ve Rossmann, 2016; Kraft, 2016)

Bir ürünün genel dijital ikiz modeli, Şekil 3.1’de gösterildiği gibi fiziksel alandaki fiziksel varlıklar, sanal alanda sanal modeller ve fiziksel ve sanal dünyaları birbirine bağlayan bağlı veriler olmak üzere üç bölümden oluşur.




Şekil 3.1: Bir ürün için dijital ikiz teknolojisi (Tao ve diğ, 2019).

Şekil 3.1’deki fiziksel dünya, kullanıcılar tarafından çalıştırılabilen gerçek ürünler olup üretim, kullanım, bakım, onarım, revizyon ve diğer işlemler sırasında farklı özellikte davranışlara ve performansa sahip birçok veri üretmektedir. Sanal dünya ise fiziksel ürünlerin sanal alandaki ayna görüntüleri ve eşlemesidir. Tüm yaşam döngüsü sürecini yansıtabilmesinin yanı sıra karşılık gelen fiziksel dünyanın durumunu ve davranışlarını simüle edebilir, izleyebilir, teşhis edebilir, tahmin edebilir ve kontrol edebilir. Sanal modeller sadece geometrik modelleri değil, aynı zamanda malzeme özellikleri, mekanik analiz, sağlık izleme gibi tüm kural ve davranışları da içerir. Bağlı veriler, fiziksel verilerin ve sanal verilerin entegrasyonu, füzyonu ve analizi sonrasında

elde edilen bazı yeni verileri içerir. Tasarım ve üretim sürecinde, sanal modellerin parametreleri üretim hattına aktarılır ve sanal modeller gerçek fiziksel ürünlere dönüştürülür (Tao ve diğ, 2019; Khajavi ve diğ, 2019).

Veri, dijital ikizin temelidir. Dijital ikiz için toplam eleman verilerini toplamak için sensörler, göstergeler, RFID etiketleri, okuyucular, kameralar, tarayıcılar vb. seçilmeli ve entegre edilmelidir. Veriler daha sonra gerçek zamanlı veya gerçek zamanlıya yakın bir şekilde iletilmelidir. Ancak, dijital ikizin ihtiyaç duyduğu veriler genellikle büyük hacimli, yüksek hızlı ve çok çeşitlidir, bu da bulut sunucusundaki dijital ikize iletilmesi zor ve maliyetlidir. Bu nedenle, uç bilgi işlem, ağ yükünü azaltmak ve veri sızıntısı olasılığını ortadan kaldırmak için toplanan verileri önceden işlemek için ideal bir yöntemdir ve 5G teknolojisi ile gerçek zamanlı veri aktarımı mümkün olur (Liu ve diğ, 2021).

Mevcut bir fiziksel ürünün, tam fonksiyonel bir dijital ikizinin oluşturulması için Şekil 3.2’de gösterildiği gibi altı aşama (sanal ürünle iletişim, verileri ölçme, sanal ürün oluşturma, analiz ve görselleştirme, davranışları simüle etme, davranışları kontrol etme) gerçekleşir ve çeşitli teknolojik araçlar kullanılır.



Şekil 3.2: Dijital ikiz teknolojisini etkinleştirme (Tao ve diğ, 2019).

Bu adımlar ile oluşturulan dijital ikiz ayrıca fiziksel ürün ve sanal ürünün birbirleriyle gerçek zamanlı iletişim kurmasını ve zaman içinde birbirleriyle işbirliği yapmasını sağlar (Tao ve diğ, 2019).

Dijital ikiz, bir ürün veya yapının farklı dijital modellerin bir bileşimi olup daha yüksek fayda ve güvenilirlik sağlamaktadır. Ancak dijital ikiz oluşturmak çok sayıda zorluğa sahiptir. Uygulanması için belirli bir yol haritası yoktur ve hangi bilgi veya modellerin entegre edilmesi gerektiği de net değildir. Bunlar bir ürün veya yapının dijital ikiz gelişimi için en büyük zorluklardandır (Tuegel, 2012).

Sanal ürün, fiziksel ürünün gerçek dünya durumunu doğru bir şekilde yansıtmak için daha gerçekçi hale getirilebilir. Geçmişte dijital ikiz çoğunlukla arıza teşhisi, arıza tahmini, bakım ve performans analizi için kullanılmıştır (Glaessgen ve Stargel, 2012).

3.2 Dijital İkiz Uygulamaları

Dijital ikiz teknolojisinin, endüstride mevcut birincil uygulamaları kısaca aşağıdaki şekilde özetlenmiştir.

Başlangıçta, hava sahası alanından gelen konsept, ABD Hava Kuvvetleri Araştırma Laboratuvarı tarafından hava taşıtında daha doğru bir yorgunluk tahmini oluşturmak için kullanılmıştır. Ayrıca, uçak yapısındaki hasar ve kusurları tespit etmek ve izlemek için uçak kanat modelini oluşturmak için de uygulanmıştır. Sonuçların geleneksel yöntemlerden daha yüksek verimlilik ve doğruluk gösterdiği onaylanmıştır (Tuegel ve diğ., 2011).

Tüm dünyada ve Türkiye’de elektrifikasyon, otomasyon ve dijitalizasyon konularında çalışmalar yürüten ve dijital dönüşümün rehberi olmayı hedefleyen Siemens’in geliştirdiği dijital fabrika ile fabrika kurulmadan önce, tüm bileşenlerinin bilgisayar ortamında uygun yazılımlarla tasarlanarak fabrikanın çalıştırılması ve sonuçlarının değerlendirilmesi sağlanmaktadır. Böylelikle, fabrikanın kendisi ortada yokken fabrikanın nasıl çalıştığı öğreniliyor ve en iyi çalışma sisteminin kurulması için gerekli önlemler alınabiliyor (Lee ve diğ., 2014).

Dijital ikiz uygulamaları akıllı şehir, inşaat, sağlık, tarım, kargo taşımacılığı, sondaj platformu, otomobil, havacılık, üretim, elektrik vb. alanlarda bulunabilir. Nispeten yeni bir teknoloji olarak, dijital ikizin uygulanmasına önde gelen şirketler (örneğin, GE, PTC, Siemens, ANSYS, Dassault, vb.) öncülük etmiştir (Schleich ve diğ., 2017). Dassault, “Dijital İkiz Singapur” oluşturmak için 3B deneyim platformunu kullanmıştır. Sağlık alanında Sim&Cure, anevrizmaların tedavisi için hasta bazlı dijital ikiz geliştirmiştir. Tesla, otomobil ve tesis arasında eşzamanlı veri aktarımını

sağlamak için her elektrikli otomobil için bir dijital ikiz geliştirmeye çalışmıştır (Qi ve diğ., 2021).

General Electric ise uçakların yanısıra, ürün yaşam döngüsünde ürün sağlığını tahmin etmek için dijital ikiz teknolojisini kullanmış ve sonuç olarak operasyonları ve bakımları daha verimli hale getirmiştir (Qi ve Tao, 2018).

Havacılık endüstrisinde, Airbus, Boeing, AFRL ve NASA, gerçek koşulları yansıtmak, kusurları belirlemek, olası hataları tahmin etmek ve uçak gövdesi bakım sorununu çözmek için dijital ikizi kullanmışlardır (Zheng ve diğ., 2019).

Gockel ve diğ., (2012) uçuş zamanını değerlendirmek için dijital ikizi kullanarak gerçek zamanlı olarak hasar tespiti önerisinde bulunmuşlardır (Gockel ve diğ., 2012).

Seshadri ve Krishnamurthy (2017) uçak yapısal sağlık yönetimi için dijital ikize dayanan bir hasar karakterizasyonu yöntemini önermişlerdir. Bu durum, hasar yeri, büyüklüğü ve yönelimini tahmin etmede büyük ilerlemeler göstermiştir.

Um ve diğ., (2017) modüler, çok satıcılı montaj hatlarında tak ve çalıştır özelliğini desteklemek için dijital ikizi temel alan evrensel bir veri modeli önermişlerdir.

Zhang ve diğ., (2017) içi boş camın otomatik üretim hattı için dijital ikiz odaklı hızlı bir özelleştirme tasarımı ve optimizasyon yaklaşımı ortaya koymuşlardır.

Magargle ve diğ., (2017) farklı modelleme biçimlerini; izleme, teşhis ve öngörü için kullanılabilen entegre bir fren sistemi modelinde simülasyon tabanlı bir dijital ikiz modelin oluşturulmasını önermişlerdir.

Vathoopan ve diğ., (2018) bir otomasyon modülünün dijital ikizini kullanan yeni bir modüler düzeltici bakım metodolojisini önermişlerdir.

Coronado ve diğ., (2018) verileri operatörlerden toplayarak üretim verileriyle birleştiren, android cihazlar ve bulut bilişim araçları tarafından desteklenen özellikle küçük imalat işletmeleri için uygun olan yeni bir üretim yürütme sisteminin geliştirilmesini ve uygulanmasını önermişlerdir. Titanyum parçaların üretim çalışmasını izlemek için üretim yürütme sistemini kullanan bir vaka çalışmasıyla üretim kontrolü ve optimizasyonu için kullanılabilen bir atölye dijital modelini gerçekleştirmişlerdir.

Cunbo ve diğ., (2018) karmaşık bir ürün montaj süreci için dijital ikiz tabanlı bir akıllı yönetim ve kontrol yöntemi önermişlerdir.

Liau ve diğ, (2018), fiziksel süreçlerin iki yönlü kontrolünü sağlamak için enjeksiyonlu kalıplamanın tüm aşamalarını sanal modeller olarak modelleyerek, enjeksiyonlu kalıplama endüstrisine dijital bir ikiz uygulamışlardır.

Botkina ve diğ, (2018) süreç planlaması için optimize edilmiş işleme çözümlerini geliştirmek için dijital ikiz modelini uygulamışlardır.

Guivarch ve diğ, (2019), mekanik bileşenlerin hizmet ömrünü daha iyi tahmin etmek için helikopter güç sistemleri için bir dijital ikiz geliştirmişlerdir.

Guo ve diğ, (2019) yaptıkları çalışmada, fabrika tasarımında kullanılmak üzere esnek dijital ikiz oluşturmaya ve buna uygun değişiklikleri gerçekleştirmeye yardımcı olmak için modüler bir yaklaşım önermişlerdir.

Mukherjee ve DebRoy (2019), 3B baskı makinesinin dijital ikizinin oluşturulması çalışmasını yapmışlardır. 3B baskı, makine öğrenimi, büyük veri ve istatistiksel modellerden oluşan kapsamlı bir dijital 3B baskı makinesi ikizinin, deneme yanılma test hacmini ve kusurları azaltabileceğini ve tasarım ile üretim arasındaki süreyi kısaltabileceğini göstermişlerdir.

Chakshu ve diğ, (2019) birleştirilmiş kan akışı ve kafa titreşim modeli yardımıyla bir insan yüzünün videosundan karotis darlığının ciddiyetini tespit etmek için dijital ikiz tabanlı bir metodoloji önermişlerdir. Dijital ikiz model, bir hastanın yüzünün videosunu karotis tıkanıklığı yüzdesine bağlama girişimiyle, karotis arter stenozlarının yaklaşık ciddiyetini saptamaya çalışmıştır. Sağlıklı denekler ve bir hasta üzerinden elde edilen ön sonuçlar, modelin doğru olduğunu ve karotis arter stenozlarının yaklaşık ciddiyetini saptama potansiyeline sahip olduğunu göstermiştir.

Shim ve diğ, (2019) daha güvenilir karar verme için dijital ikiz model konseptini kullanarak yeni nesil bir köprü bakım sistemi önermişlerdir. Görüntü işleme teknolojilerini kullanarak bir dijital denetim sistemiyle birlikte bir 3B bilgi modeline dayalı bakım bilgi yönetim sistemi tasarlamışlardır. Tasarım, inşaat, işletme ve bakım dahil olmak üzere bir projenin tüm yaşam döngüsünden gelen bilgiler kullanılarak beton köprülerin bakımı için ikiz modeller tanımlanmış ve kullanıma sunulmuştur.

Ghosh ve diğ, (2019) endüstri 4.0 üretim sistemleri için gizli Markov modellerini kullanarak dijital ikizlerin oluşturulmasını önermişlerdir. Önerilen dijital ikiz modeli taşlama işlemlerinde oluşan yüzey pürüzlülüğünün dijital ikizinin oluşturulmasına uygulanmıştır.

Coraddu ve diğ, (2019) gemideki sensörlerden toplanan büyük miktarda bilgidan yararlanarak, geminin veri güdümlü bir dijital ikizini oluşturmuşlar ve deniz kirliliğinden kaynaklanan hız kaybını tahmin etmek için kullanmışlardır. Önerilen yöntemle daha iyi hız kaybı tahmin doğruluğu sağlandığı sonucuna varılmış ve böylece kirlenme nedeniyle yakıt tüketiminin azaltılmasına olanak tanındığı vurgulanmıştır.

Bao ve diğ, (2019) üretim proseslerinde dijital ikiz için bir modelleme ve operasyon yaklaşımı önermişlerdir. Üretim proseslerinde dijital ikizin konsept ve uzantısı, bir fabrika için sanal-fiziksel yakınsama ve bilgi entegrasyonunun uygulama yöntemlerini sağlamak için detaylandırılmıştır. Ürün dijital ikizleri, süreç dijital ikizleri ve operasyon dijital ikizlerinin modelleme yaklaşımları sunulurken, bu dijital ikizler arasındaki birlikte çalışma modunu açıklamışlardır. Ürün, süreç ve kaynak arasındaki işlemlerin nasıl yürütüleceğini detaylandırmak için, bir yapısal parça işleme hücresini modellemede otomasyon işaretleme dilini kullanarak üretim verimliliğinin gelişimini göstermede performans artışı sağlandığı gösterilmiştir.

Bilberg ve Malik (2019), üretim sistemi tasarım aşamasında geliştirilen sanal simülasyon modellerinin kullanımını uygulama kontrolüne, insan ve makine görev atamasına ve görev sıralamasına kadar genişleyen bir dijital ikiz modeli oluşturmak için montaj birimine bir dijital ikiz uygulamışlardır.

Luo ve diğ, (2020) CNC takım tezgahının güvenilir kestirimci bakımını gerçekleştirmek için dijital ikiz tarafından yönlendirilen hibrit bir yaklaşım önermişlerdir. Önerilen çerçeve ile dijital ikiz modeli ve dijital ikiz verilerine dayalı hibrit bir kestirimci bakım algoritması geliştirmişlerdir.

Liu ve diğ, (2021) yaptıkları çalışmada, atölyelerin hızlı ve verimli bir şekilde süreç planları oluşturması için akıllı bir zamanlama yöntemi geliştirmede dijital ikiz ve süper ağın avantajlarını bütünleştirmişlerdir. Akıllı atölye planlamasını gerçekleştirirken, çizelgeleme şemasını simüle ve optimize etmek için sanal bir atölye kullanılmıştır. Önerilen akıllı çizelgeleme stratejisinin verimliliği, bir uçak motoru dişli üretim atölyesinin bir vaka çalışması kullanılarak doğrulanmıştır.

Qian ve diğ, (2021) dijital ikiz oluşturma sürecinde veri modelleme ve dijital modelin doğrulanma sorununu çözmek için çok boyutlu veri modelleme ve model doğrulama yöntemlerini önermişlerdir. İlk olarak, fiziksel atölyeden ve sanal atölyeden gelen

veriler birleştirilmiş ve üretim elemanlarını temsil etmek için beş dereceli tensör modeller kurulmuştur. Daha sonra, dijital ikiz modelini doğrulamada matematiksel yöntem önerilmiştir. Önerilen yöntemin işlerliğini ve etkinliğini doğrulamak için bir havacılık işleme atölyesinin vaka çalışması gerçekleştirilmiştir.

Suljagı ve Çelebi (2021) yaptıkları çalışmada, düşük maliyetli bir robot kolunun dijital ikizi elde ettikten sonra gerçek zamanlı verilerle bir simülasyon uygulaması yapmışlardır.

White ve diğ, (2021) akıllı şehir uygulamasında kullanılmak üzere İrlanda'daki Docklands bölgesinde bir dijital ikiz çalışması yapmışlardır. Bu model, kullanıcıların etkileşime girmesine ve planlanan değişiklikler hakkında geri bildirimde bulunmasına olanak tanıyarak şehir görseli ve yeşil alan planlaması çalışmalarında kullanılmıştır. Ayrıca dijital ikiz, taşkın tahliye planlaması gibi 3B verilerin gerekli olduğu durumlarda da kullanılarak bir şehrin doğru bir 3B modelinin oluşturularak kentsel planlama ve politikada nasıl kullanılabileceğini göstermiştir. Bununla birlikte, akıllı bir şehirde IoT sensörlerinden üretilen büyük verilerle birleştirilen giderek daha büyük ve doğru bina bilgi modelleriyle artık dijital ikiz akıllı şehirler oluşturmmanın mümkün olduğu sonucuna varılmıştır.

Burgos ve Ivanom (2021) Covid-19 pandemisinin gıda perakende tedarik zincirleri ve dayanıklılıkları üzerindeki etkisini tespit edebilmek için gerçek hayattaki pandemi senaryolarına dayanarak, anyLogistix dijital tedarik zincirleri ikizinin yardımıyla tedarik zincirleri operasyonlarını ve performans dinamiklerini ayrık olay simülasyon modeli geliştirerek incelemişlerdir.

Yi ve diğ, (2021) akıllı montaj süreci tasarımı için dijital bir ikiz referans modeli sunmakta ve üç katmanlı DT tabanlı akıllı montaj için bir uygulama çerçevesi önermişlerdir.

Wang ve diğ, (2021) yaptıkları çalışmada, izole edilmiş makineleri birbirine bağlı bir sisteme bağlamak ve makine koşullarını gerçek zamanlı olarak izlemek için bir dijital ikiz çerçevesi önermişlerdir. Uygulamalarını bir kalıp kesme makinesi için uygulamışlardır. Makinenin gerçek zamanlı durumunu görüntülemek için pano tabanlı ve üç ana işlevden (gerçek zamanlı makine izleme, genel ekipman etkinliği ve sipariş planlama) oluşan bir görev merkezi oluşturulmuştur.

Priyanka ve diğ, (2021), petrol boru hattı sisteminin risk olasılık oranını analiz etmek ve tahmin etmek için makine öğrenimi ve prognostik algoritmalar modeline dayalı dijital ikiz çerçeve yapısını sağlamayı amaçlamışlardır.

Choi ve diğ, (2022), derin öğrenme ve dijital ikizi kullanan güvenlik bilincine sahip insan-robot işbirliği için yeni entegre bir karma gerçekliğe sahip bir sistem önermişlerdir. Bu çalışma, robotun dijital ikizi ve insan iskeletine dayalı basit ama etkili bir 3B uzaklık tabanlı güvenlik mesafesi hesaplama yöntemi önermektedir. Önerilen yaklaşım, gerçek zamanlı olarak minimum güvenli mesafeyi doğru bir şekilde ölçmekte ve insan operatöre karma gerçeklik tabanlı görev yardımı sağlayabilmektedir.

Lari ve diğ, (2022) yapılan ölçümler ile belirli bölgelerin derinliğini simüle etmek için doğal kaynak bölgesi tükenmesi süreçlerinin ve gelecekteki eğilimlerin genel bir dijital ikizini oluşturma önerisinde bulunmuşlardır. Çalışma, karmaşık yeraltı sistemlerinin hesaplama altyapısındaki ilerlemelerle dijital bir ikiz geliştirme fikrini ilerletmek için uygun fiyatlı simülasyona olanak sağlamıştır.

Gao ve diğ, (2022) belirsiz liman sevkiyatı için dijital ikiz ile etkinleştirilmiş otomatik bir depolama sahası çizelgeleme çerçevesi önermişlerdir. Dijital ikiz teknolojisi, sanal ancak gerçekçi depolama alanı ve bunlar arasındaki bağlantıyı kurmak için kullanılarak pratik operasyon sırasında bozulan senaryolar izlenmiş ve zamanla değişen ortama uyum sağlamak için gerçek zamanlı veriler sanal alanda görselleştirilmiştir. Otomatikleştirilmiş depolama alanı çizelgelemesindeki dijital ikiz uygulamaların operatörlerin optimizasyon kararları almasına yardımcı olduğunu göstermiştir.

Granacher ve diğ, (2022) karar vericilerin ihtiyaçlarını ve tercihlerini etkileşimli olarak optimizasyon tabanlı bir modele dönüştüren ve anlamlı çözümler üreten bir süreç ve enerji sistemi tasarımının dijital ikizini önermişlerdir. Önerilen metodoloji, entegre bir çok ürünli biyorafineri tasarım örneğine uygulanmıştır.

Yang ve diğ, (2022), bir iletim sisteminin performans düşüşünü tahmin etmek için dijital ikiz teknolojisi tarafından yönlendirilen bir hibrit yaklaşım çerçevesi sunmuşlardır.

Fang ve diğ, (2022) yaptıkları çalışmada, deniz yapılarının çatlak büyüme eğilimini doğru bir şekilde tahmin etmek için dijital ikize dayalı açık deniz platformlarında

yorulma çatlağı büyüme tahmin yöntemini önermişlerdir. Yöntem yalnızca karmaşık yükler altında çatlak büyümesi tahmini üzerindeki belirsiz faktörlerin etkisini azaltmakla kalmayıp, aynı zamanda dinamik izleme yoluyla çatlak büyümesinin doğruluğunu da sağladığını göstermektedir.



4. MATERYAL VE YÖNTEM

Yapılan çalışmada, hazır giyim perakende sektöründe öncü olan bir firmanın veri dijitalleştirme projesi kapsamında, fiziksel ortamın sanal kopyasının oluşturulması ile üretimi her yönden analiz etmeye yardımcı olacak dijital ikiz çalışmalarının altyapısının oluşturulması amaçlanmıştır.


Firmadaki veri dijitalleştirme projesi kapsamında yapılacak olan; mevcut ve olması istenen sistem süreç haritalarının oluşturulması, tüm verilerin arayüzler ile veritabanında tutulmasının sağlanması ve olması istenen fiziksel ve sanal sistemin kurulması çalışmaları üç fazdan oluşmaktadır. Bu fazların kapsamaları aşağıda sırasıyla açıklanmıştır.

4.1 Birinci Faz Çalışması

Üretim sahasında bulunan,

- Ham madde depolama ve sevk,
- Üretim hattı giriş ve çıkış,
- Yarı mamul kabul, adresleme ve sevk süreçleri için mevcut ve olması gereken süreç haritaları işlemleri,

süreç yönetim sistemi olan ve kurumların fonksiyonel odaklı yönetim anlayışından süreç odaklı yönetim anlayışına geçiş için mevcut süreçlerin modellenmesi, görsel olarak dokümanite edilmesi, süreç performans göstergelerinin belirlenmesi ve yönetilmesi gibi işlevler ile gerekli altyapıyı sağlayan ve Şekil 4.1’de gösterilen ensemble platformu üzerinde oluşturulmuştur.




Şekil 4.1: Ensemble platformu süreç yönetim ekranı.

Bu çalışmada ensemble platformuna tüm birimlerdeki çalışan bilgileri, görev tanımları ve talimatlar eklenerek tüm çalışanlar tarafından görüntülenebilmesi sağlanmıştır.

4.2 İkinci Faz Çalışması

Süreçlerde kullanılan form, program, talimat ve kullanıcılar incelenerek süreçlerdeki verinin veritabanında tutulabilmesi için bir kurumsal kaynak planlama (ERP) sistemi oluşturulmuştur. Kurumsal kaynak planlama, organizasyonel hedeflerin gerçekleştirilmesi ve işletmenin tüm fonksiyonlarını bütünleştirmek için, işletmenin tüm ihtiyaçlarını, bir organizasyonun tüm süreçlerini göz önünde tutarak yöneten ve planlayan bir yazılım çözümüdür (Kumar, 1998). Yazılım projelerinde, bütçe ve zaman kısıtına uygun olarak müşteri gereksinimlerinin karşılanabilmesi için proje yönetimi büyük önem taşımaktadır. Proje yönetimi, bir projenin hedef ve amaçlarına ulaşip bitirilmesi için kaynakların planlanması, organize edilmesi, tedarik edilmesi ve yönetilmesi disiplini. Yazılım projesinin kalitesini etkileyen en önemli unsurlardan birisi kullanılan proje yönetimi metodolojisi. Bu metodolojilerden en çok kullanılanları: şelale (waterfall), helezonik (spiral), artırımsal (incremental) ve çevik (agile) metodolojileridir. Bir yazılım projesinin en önemli kalite isteklerinden biri kullanıcı gereksinimlerinin tam ve doğru olarak karşılanabilmesidir. Gereksinimlerdeki belirsizlik, gereksinim değişkenliğinin yüksek olması ve teknolojik gelişmelere bağlı olarak hızlı üretimin değer kazanması nedeniyle zamanla şelale vb. geleneksel yaklaşımlar önemini kaybetmiş ve çevik yöntemler uygulanmaya başlanmıştır (Başar ve diğ., 2015). Çevik (agile) proje yönetimi, yazılım projelerinin geliştirilmesi için kullanılabilecek yinelemeli ve artırımlı proje yönetim biçimidir.

Piyasaya çok çabuk ürün çıkarabilmeyi, değişen isteklere hızlıca yanıt verebilmeyi ve en kısa sürede bir yazılım ürününü müşteri hizmetine sunabilmeyi amaçlaması açısından çevik metotlar avantajlı bulunmaktadır (Boehm ve Turner, 2003). Bu yüzden, bu çalışmada kurumsal kaynak planlama sistemi oluşturulurken, proje yönetimi metodolojilerinden çevik metodu kullanılmıştır. Ayrıca, iş takibi, proje yönetimi, hata takibi, iş akış yönetimi ve raporlama gibi birçok işlemin online platform aracılığıyla yapılmasını ve tüm ekip tarafından görüntülenebilmesini sağlayan Jira proje takip platformu da çevik metodu ile birlikte kullanılmıştır. Buna bağlı olarak, projelerin girişi, proje ekibinin oluşturulması ve proje takibi Şekil 4.2’de gösterilen jira platformu aracılığıyla yapılmıştır. Böylelikle, ihtiyaçlara ve kurumsal yapılanmaya göre düzenlenebilen bir sistem oluşturulmuştur.



Şekil 4.2: Jira platformu proje yönetim ekranı.

Bu fazda, sahada el terminali, tablet ve televizyon kullanılırken ofiste bilgisayar ve yazıcılar kullanılmıştır. ERP sisteminin oluşturulması süreçler bazında gerçekleştirilmiş olup Systems Analysis and Program Development Graphical User Interface (SAP GUI), Systems Analysis and Program Development FIORI, web ve android uygulamalar kullanılmıştır. Raporlama ve dashboard araçları olarak Business Warehouse (BW), Power Business Intelligence (Power BI) ve Systems Analysis and Program Development Objects Business Intelligence (SAP BI) kullanılmıştır.

4.3 Üçüncü Faz Çalışması

Fiziksel ortamdaki tüm verilerin sanal ortama aktarılması sağlanarak istenilen parametreler ve algoritmalar ile süre tahminleme, duruş takibi ve üretim çizelgeleme gibi çalışmalar ile haberleşebilen ve kendi kendine karar verebilen bir sistem inşası için altyapı çalışması yapılmıştır. Makinelardan sensörler vasıtasıyla ve çalışanlardan arayüzler ile alınan veriler ERP sisteminde depolanarak büyük bir veri elde edilmesi sağlanmıştır. Elde edilen büyük veri ile farklı özelliklere sahip bir ürünün üretiminin

ne kadar sürede tamamlanabileceği sonucuna ulaşmak için tahminleme çalışması yapılmıştır.

Tahminleme çalışmasında; verinin işlenmesi, yorumlanması, görselleştirmesi ve raporlanmasını sağlayan bir veri analiz platformu kullanılmıştır. Knime kütüphanesinde bulunan ve sayısal tahminlemede kullanılabilen lineer regresyon, polinomal regresyon, rassal orman regresyon algoritması ve gradyan destekli karar ormanı regresyonu olmak üzere dört algoritma seçilmiştir. Bu algoritmalarla model kurularak veri seti için üretim süresi tahminlemesi yapılmıştır. Seçilen algoritmalar aşağıda kısaca açıklanmıştır.

- *Lineer regresyon*: Bir tür regresyon modellemesidir ve makine öğreniminde tahmine dayalı analiz için en kullanışlı istatistiksel tekniktir. Lineer regresyondaki her gözlem bağımlı ve bağımsız değişken olmak üzere iki değere bağlıdır ve lineer regresyon bağımlı (y) ve bağımsız (x) değişkenler arasındaki doğrusal ilişkiyi belirler. Lineer regresyona ait denklem aşağıda verilmiştir.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

Burada; ε , doğrusal regresyonun hata terimini temsil eder ve x ile y arasındaki değişkenliği açıklamak için kullanılır. β_0 , doğrunun y eksenini kestiği noktayı temsil ederken β_1 eğimi temsil eder (Rustam ve diğ., 2020).

- *Polinom regresyon*: Yalnızca bir bağımsız değişken (x) ile çoklu regresyonun özel bir durumudur (Ostertagova, 2012). Polinom regresyon analizi, regresyon modelinde yer alan bağımsız değişkenin, bağımlı değişken üzerine olan etkisinin toplanabilir olmadığı (eğrisel, üstel, çarpımsal vb.) varsayımına dayanan regresyon yöntemlerini içerir (Rawlings ve diğ., 2001; Aggrey, 2002). Tek değişkenli polinom regresyon modeli denklem (2)'deki gibi ifade edilir.

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \dots + \beta_k x_i^k, \quad i = 1, 2, \dots, n \quad (2)$$

Burada; k , polinomun derecesidir ve polinomun derecesi modelin derecesidir.

- *Rassal orman regresyon algoritması*: Orijinal örneklemden, yerine koyarak örneklem boyutunu değiştirmeden yeniden B kere örneklem alan Bootstrap örnekleme yöntemini kullanan ve tahmin için karar ağaçlarını birleştiren istatistiksel bir öğrenme yöntemidir. Girdinin çıktısını yani sonucu almak için karar ağaçlarının verdiği ortalama tahmini alır. Rassal orman regresyon algoritması

klasik karar ağacı metodunun bir uzantısı olan ve tahmin doğruluğunu iyileştirmek için birden fazla karar ağacından oluşan topluluk öğrenme yöntemidir (Juo ve diğ., 2016). Rassal orman regresyon algoritması en başarılı sınıflandırma yöntemlerinden biri olarak bilinir. Doğası gereği çok farklı disiplinlere hitap etmesinden dolayı farklı alanlarda çalışan araştırmacıların dikkatini çekmektedir (Akar ve Güngör, 2012).

- *Gradyan destekli karar ormanı regresyonu*: Stokastik gradyan artırılmalı hesaplama yaklaşımı 21. yüzyılın başlarında öngörülü veri madenciliği için en güçlü yöntemlerden biri olarak ortaya çıkmıştır. Aslında, sınıflandırma problemleri için yazılmış olan bu algoritma aynı zamanda regresyon için de kullanılmaktadır. Gradyan destekli karar ormanı regresyonu, baz alınan modeldeki alt bölümlerde bulunan kararları birleştirerek tahmin yürüten ilaveli bir modeldir. Genel fikir, ardışık her bir ağacın, önceki ağacın tahmini kalıntılarından oluşturulduğu, basit ağaçların kombinasyonu olan bir dizi hesaplama işlemidir. Bu model matematiksel olarak bir “g” fonksiyonunun daha basit “f” fonksiyonları toplamı olarak yazılması şeklinde olup denklem (3)’deki gibi gösterilebilir.

$$g(x)=f_0(x) + f_1(x) + f_2(x) + \dots + f_n(x) \quad (3)$$

Rassal orman regresyon algoritmasından farklı olarak, her biri bir alt veri örneği kullanarak destekli karar ormanı regresyonunda gradyan artırma adı verilen belirli bir model oluşturma tekniği kullanır. Ağaçların “ilave ağırlıklı genişlemeleri”, açıklayıcı değişkenler ve ilgilenilen bağımlı değişken arasındaki ilişkilerin spesifik niteliği çok karmaşık olsa bile, nihayetinde öngörülen değerlerin gözlenen değerlere iyi bir şekilde uyduğu gösterilebilir. Bu nedenle, gradyant artırma yöntemi oldukça genel ve güçlü bir makine öğrenme algoritmasıdır (Poyarkov ve diğ., 2016). Gradyan destekli karar ormanı modellerinin özellikle doğrusal olmayan fonksiyonlarda başarılı olduğu gözlemlenmiştir (Johnson ve Zhang, 2014).

Süre tahminlemede veriyi hazırlama ve tahmin modellerinin karşılaştırılması önemli adımlardandır. Yapay sinir ağları ve makine öğrenmesi yöntemlerinin performans değerlendirmelerinde sıklıkla kullanılan temel performans göstergeleri R^2 , ortalama mutlak hata (Mean Absolute Error-MAE), ortalama kare hata (Mean Squared Error-MSE) ve kök ortalama kare hata (Root Mean Square Error-RMSE) ve sayılabilir (Karasu, 2018). Çalışmamızda kullanılan tahmin algoritmaları ile oluşturulan

modellerin performanslarını deęerlendirmede temel alınan bu performans göstergeleri ařaęıda kısaca açıklanmıştır.

- R^2 : tahmin edilen doęrusal regresyon denkleminin genel olarak örnekleme uygun olup olmadığı belirleme kat sayısıdır ve denklem (4)'te verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Burada; y_i : Gerçek gözlemi, $\hat{y}_i$: Öngörülen gözlemi, $\bar{y}$: Gerçek deęerin ortalamasını ifade eder.

Çıkarımsal analizde R^2 deęeri bulunur ve bulunan deęer doęru hesaplanmışsa 0 ile 1 arasında olmalıdır. Eęer R^2 deęeri sıfıra yakınsa, uyum iyilięi uygun olmadığı kabul edilir. Bu sonuç ortaya çıkarsa toplanan verilere kullanılan modelin uygun olmadığı sonucu çıkarılır ve bu uygunsuzluk modelinin deęiřtirilmesini gerektirir. Eęer R^2 deęeri bire yakınsa, uyum iyilięi uygun olduęu sonucu çıkarılır (Gujarati ve dię, 2012).

- MAE: Kolay yorumlanabilir olduęu sebebiyle regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır. Denklem (5)'te MAE performans metrięinin denklemi verilmiştir. Bu denkleme göre, iki sürekli deęiřken arasındaki farkın ölçüsü MAE deęerini verir. Yani gerçekleşen ve tahmin edilen deęerler arasındaki farkların mutlak deęerlerinin toplamıdır. MAE deęeri 0'dan ∞ 'a kadar deęiřebilir (Chai ve Draxler, 2014).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i'| \quad (5)$$

Burada;

y_i : Gerçek deęeri

y_i' : Tahmin edilen deęeri

n : Gözlem sayısını temsil etmektedir.

- MSE: Bir regresyon eęrisinin bir dizi noktaya ne kadar yakın olduęunu söyler. MSE, bir makine öęrenmesi modelinin performansını ölçer, her zaman pozitif deęerlidir ve sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdięi

söylenebilir (Chai ve Draxler, 2014). MSE değerini elde etmek için kullanılan formül denklem (6)'da verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2 \quad (6)$$

Burada;

y_i : Gerçek değeri

y_i' : Tahmin edilen değeri

n : Gözlem sayısını temsil etmektedir.

- RMSE: Bir makine öğrenmesi modelinin, tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen ikinci dereceden bir hata metriğidir ve denklem (7)'de gösterildiği gibi hesaplanmaktadır. RMSE, gerçek değerlerle tahmin edilen değerler arasındaki farkın (tahmin hatalarının) standart sapmasıdır. Yani, tahmin hataları, regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür. RMSE ise bu kalıntıların ne kadar yayıldığına bir ölçüsüdür. RMSE değeri 0'dan ∞ 'a kadar değişebilir. RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelmektedir. RMSE'nin avantajı, büyük hataları daha fazla cezalandırmasıdır. Bu sebeple bazı durumlara daha uygun olabilir. RMSE, birçok matematiksel hesaplamada istenmeyen mutlak değer kullanıldığını da engeller (Chai ve Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2} \quad (7)$$

Burada;

y_i : Gerçek değeri, y_i' : Tahmin edilen değeri, n : Gözlem sayısını temsil etmektedir.

Bu performans ölçüleri içerisinde R^2 , modelin doğruluk oranı karar verme katsayısıdır. Bu katsayı değerinin yüksek olması tahmin ilişkisinin iyi olduğu gösterir. MSE, RMSE ve MAE ise birer hata ölçüsü olmaları dolayısıyla buradaki düşük sonuçlar, performans ile ters orantılı olarak yüksek performans gösterir (Wang ve Xu, 2004).

5. BULGULAR VE TARTIŞMA

5.1 Birinci Faz Çalışmasından Elde Edilen Bulgular

5.1.1 Ham madde depolama ve sevk süreçleri

Bu aşamada, ham maddelerin, üretilecek ürünlere göre satın alma işlemi tamamlandıktan sonra depolama alanına alışı, kalite kontrol, adresleme, stoklama ve üretim yapılacak sahalara sevk işlemleri yapılmaktadır.

5.1.1.1 Mevcut süreçler

- Ham maddeler termin tarihi referans alınarak satın alınır.
- Ham madde kabul için manuel olarak kapasite yönetimi yapılarak tedarikçilere mail üzerinden randevu verilmektedir.
- Verilen randevu tarih ve saatinde fiziksel ve sistemsel alış işlemi gerçekleştirilir.
- Kalite kontrol işlemi yapılarak kontrol formu doldurulup ilgili kişilere iletilir.
- Sonuç onayı gerekiyor ise adresleme için ilgili kişi onayı beklenir.
- Kalite kontrolden geçen veya onay alan ham maddeler raflara konularak manuel adreslenir.
- Üretime çıkış için ilgili kişiler tarafından hazırlama emri verilir.
- Çıkış işlemi için adresteki ham madde bulunarak ilgili birime sevk irsaliyesi ile teslim edilir.

5.1.1.2 Olması istenen süreçler

- Ham maddelerinin termin tarihi referans alınarak satın alınması.
- Ham madde kabulde kapasite yönetiminin ve randevu sürecinin sistemsel olarak yapılması.

- Tedarikçi tarafından alınan randevu tarih ve saatine göre fiziksel ve sistemsel alış işleminin alt ve üst tolerans değerleri arasında gerçekleştirilmesi.
- Tolerans değerlerinin sistem tarafından satın alma siparişi miktarına göre kontrol edilmesi ve toleransı aşan durumlar için yönetici onayına düşmesi.
- 4 puan kalite kontrol sistemi kullanılarak sonuçların kontrol esnasında sisteme saha görevlisi tarafından girilmesi.
- Girilen kalite kontrol sonuçlarına göre onay alınması gereken ham maddelerin ilgili kişinin sistem üzerinden onayına düşmesi ve tüm sonuçlar ile onaylarının veritabanında tutulması.
- Barkod adresleme sistemi ile kalite kontrolsüz de olsa adresleme yapılabilmesi.
- Kalite kontrol işlemi tamamlanmayan ham maddenin üretime sevk edilememesi.
- Üretime çıkış için ilgili üretici ve miktar seçimi ile sistem üzerinden hazıredim yapılması.
- Hazıredimin ilgili birime sistemsel çıkış işlemi ile sevk edilmesi.
- Sevk irsaliyesinin sistem tarafından yazdırılması.

5.1.2 Üretim hattı giriş ve çıkış süreçleri

Bu aşamada ise ham maddeler, üretim hattı doluluğu ve üretim terminlerine üretim alanlarına gönderilip ön işlemlerden geçmesi sağlanır. Ön işlemler tamamlanıp gerekli onaylar alındıktan sonra ham madde üretim proseslerinde, üretim özelliklerine göre işlenir ve yarı mamul olarak torbalanır.

5.1.2.1 Mevcut süreçler

- İlgili çıkışa istinaden ham madde kabul edilir.
- Çıkış irsaliyesine göre iş talimatı çıktısı alınır.
- Ham maddede ölçüm yapılarak sonuçlar iş talimatına el ile yazılır.
- Ölçümlere göre kalıp çizimleri yapılır ve veriler iş talimatına el ile yazılır.
- Yapılan ölçümlere göre müşteriden excel formu ile onay alınır.
- Onay işleminden sonra ham madde üretim hattına girerek 3 farklı prosesten geçer.
- Proseslerde yapılan işlemler manuel olarak iş talimatı ve ilgili defterlere kayıt edilir.

- Yarı mamul operasyonlara göre torbalanılarak sevk birimine teslim edilir.
- Yarı mamul üretim hattından çıktıktan sonra gerçekleşen bilgiler müşteriye mail ile iletilir.

5.1.2.2 Olması istenen süreçler

- Ham madde kabulünün barkod okutma yapılarak üretim stoğuna alınması.
- Barkod okutma ile ham maddeye ait tüm sipariş bilgilerinin sistemde görüntülenebilmesi.
- Ham maddeye ait tüm ölçümlerin saha görevlisi tarafından sistemsel giriş yapılması.
- Giriş yapılan ölçülere göre kalıp çizimlerinin yapılarak ilgili bilgilerin sistemsel giriş yapılması.
- Giriş yapılan bilgilere göre müşteriye otomatik mail düşmesi ve sistemsel onayın verilmesi.
- Verilen onayın üretim birimine otomatik mail ile iletilmesi.
- Onay gelen kayıtları saha personelinin görerek yapılan işlemleri kayıt yapabileceği bir sistemin kurulması.
- Ekipman bakım, onarım ve duruş takibinin yapılabilmesi.
- Üretim çizelgelemesinin sistem tarafından yapılmasının sağlanması.
- Üretilecek ürün detayının saha personeli tarafından görülebilmesinin sağlanması.
- Gerçekleşen veriler ile planlanan verilerin haberleşmesi sağlanarak bir karar destek sistemi kurulması ve hat dengelemenin belirlenen kriterlere göre sistem tarafından otomatik olarak yapılmasının sağlanması.

5.1.3 Yarı mamul kabul ve sevk süreçleri

Burada, yarı mamul, üretim termin süresine göre adreslenerek stoklanır ve termini yaklaşanlar için randevu sistemi ile sevk planlanır.

5.1.3.1 Mevcut süreçler

- Üretim hattından çıkan yarı mamuller excel formu doldurularak teslim alınır.
- Yarı mamuller operasyon bazında sepetlere konur ve ürün bilgilerinin bulunduğu excel formları sepetlere yapıştırılır.

- Sepetler saha personeli tarafından raflara yerleştirilir ve stok formu doldurulur.
- Stok girişı yapacak personele form iletilerek excele giriş yapılması sağlanır.
- Sevk olacak yarı mamul için ilgili kişı mail üzerinden randevu talep formu ile randevu talebini iletir.
- Randevu bilgisine göre hazırlanacak ürünler listenelenip saha personeline iletilir.
- Personel sahayı gezerek ürünleri bulur ve sepetleri sevk alanına çeker.
- Ürünlerin irsaliyesi kesilerek ilgili randevu için araca yüklemesi gerçekleştirilir.
- Sevk olan yarı mamul bilgileri sevk kağıdına yazılarak stok listesinden çıkış yapacak personele iletilir.
- Sevk olan yarı mamuller stok excelinden çıkarılarak stoğun güncellenmesi sağlanır.
- Belirli periyotlar ile randevu talep edecek birime stok raporu hazırlanarak mail üzerinden iletilir.

5.1.3.2 Olması istenen süreçler

- Üretim hattından çıkan yarı mamullerin sistemsel olarak kabul edilmesinin sağlanması.
- Yarı mamullerin sepetlere ve raflara sistemsel olarak adreslenmesinin sağlanması.
- Tüm form ve excellerin sistem üzerine aktarılması ve sistemsel raporlama yapılmasının sağlanması.
- Stokların anlık olarak görölmesi ve system üzerinden randevu talebinin oluşturulmasının sağlanması.
- İlgili randevu talebine göre sevk işleminin yapılarak stoktan düşme sağlanması.
- Saha personelinin raf adreslerindeki ürünleri görerek işlem yapmasının sağlanması.

5.2 İkinci Faz Çalışması


Bu fazda, mevcut ve olması istenen süreç haritaları oluşturulduktan sonra tüm süreçlerin ERP'ye aktarım çalışmaları yapılmıştır.

5.2.1 Ham madde depolama ve sevk süreçleri ERP aktarımı

Ham madde satın alma siparişlerinin oluşturulabilmesi için sisteme ham madde tanımları ve tedarikçi firma bilgileri eklenmiştir. SAP satın alma siparişi oluşturma ekranı, ham madde ve tedarikçi seçimi seçenekleri eklenerek, satın alınacak miktar ve ödenecek ücret bilgilerinin girilmesi ile oluşturulmuştur. Tüm kayıtlar kullanıcı bazında tutularak onay süreçleri kullanıcı bilgisi üzerinden ilerlemiştir. Tedarikçi ile entegrasyon çalışması yapılarak sipariş ve fiyat bilgilerinin iletilmesi sağlanmıştır.

Tedarikçi tarafından randevu alınabilecek randevu sistemi geliştirilmiş olup depolama kapasitesi her birim için sipariş yoğunluğuna göre değişkenlik gösterebilecek şekilde tasarlanmıştır.

Tedarikçiden gelen ürünler lojistik birimine teslim edildiğinde entegrasyon ile sipariş detay bilgileri alınmış ve fiili olarak az ya da fazla gelme durumları için onay süreci işletilmiştir. Onay süreci için sisteme tolerans değerleri verilmiş olup gelen sipariş bilgilerinin aralığa uymaması durumunda satın alma siparişini oluşturan ilgili kişinin onayına sistemsal olarak düşmektedir ve onay işleminden sonra ham madde kabul gerçekleştirilebilmektedir. Yapılan satın alma siparişi oluşturma ve onay ekranı Şekil 5.1’de verilmiştir.



Şekil 5.1: Satın alma siparişi oluşturma ve onay ekranı.

Ham madde satın alındıktan sonra tedarikçi firma tarafından depolama alanına getirilir ve depo girişi yapılır. Depo girişinden sonra satın alma siparişinin durumu kalite kontrole girecek olarak güncellenir ve el terminali ile ham madde üzerindeki barkod

okutma işlemi yapılarak raf alanına yönlendirilir. Ham madde hata kontrolü Şekil 5.2’de verilen ışıklı kalite kontrol makinelerinde yapılmaktadır.



Şekil 5.2: Kalite kontrol makinesi.

Kalite kontrol işlemi proses doluluğuna göre örneklem seçimi yapılarak yürütülmektedir. Yapılan kontrol sonrası elde edilen değerlere göre Çizelge 5.1’de gösterilen hata puanları verilir.

Çizelge 5.1: Kalite kontrol sistemi hata puanları.

Kumaş hata uzunluğu (Uzunluk veya genişlik boyunca)	Hata puanı
0-3 inç arası	1
3-6 inç arası	2
6-9 inç arası	3
9 inç yukarısı	4
Delik ve açıklık 1 inç ya da daha düşük	2
Delik ve açıklık 1 inç üzeri	4

Sonrasında, 4 puanlık kalite kontrol sistemi için arayüz ile saha personelinin işlem bilgilerinin girişini yapacağı Şekil 5.3’te gösterilen bir uygulama geliştirilmiştir.

Kalite kontrol makinesindeki sensörler ile tabletteki uygulamanın haberleşmesi sağlanarak ilgili bilgilerin alınması sağlanmıştır. 4 puanlık sisteme göre kalite kontrolden geçen satın alma siparişinin durumu puan bilgisine göre “uygun”, “kusurlu” veya “uygunsuz” olarak güncellenmektedir. Kalite kontrol işlemi

yapılmadan ve durumu uygunsuz olarak görünen ham maddeler için çıkış işlemine sistem tarafından izin verilmemektedir.



Şekil 5.3: Kalite kontrol yazılım uygulaması.

Çıkış işlemi için ilgili kişi tarafından ham maddeler siparişe bağlanır ve ilgili üretim yeri için sistemsal çıkış talebinde bulunur. Yapılan talep lojistik birimi tarafından toplu olarak rezervasyon ekranından takip edilir. Çıkış işlemi yapılacak ham maddeler el terminali ile toplanarak sistemden barkodlu sevk irsaliyeleri alınır ve ilgili birime teslim edilir. Sistem ile ham madde kabul süresi, adresleme süresi, kapasite doluluk oranı, kalite kontrol oranı, sevk süresi ve hazırlama süresi gibi bilgiler raporlama araçlarıyla raporlanabilmektedir.

5.2.2 Üretim hattı giriş ve çıkış süreçleri ERP aktarımı

Çıkış işlemi yapılan sevk irsaliyesindeki barkod okutularak üretim birimine sistemsal giriş yapılır ve ham madde için yapılan ölçüm bilgileri saha personeli tarafından sisteme girilir. Burada, herhangi bir kağıt çıktı alınmasına gerek olmadan tüm işlemler sahadaki tablet, bilgisayar ve televizyon üzerinden takip edilebilmektedir. Yapılan bu faaliyetlerin proses bazlı işlem ekranları Şekil 5.4'te gösterilmektedir.



Şekil 5.4: Proses bazlı işlem ekranları.

Bu aşamada, ölçüm bilgileri girilen ham maddeler ilgili kişilere sistemsel olarak onaya gönderilir ve onay gelmeden sistemsel olarak işleme alınması mümkün olmamaktadır. Onay gelen siparişler onay ekranına düşmekte ve durumu onaylandı olarak görülmektedir. Durumu onaylı olan siparişler onay tarihine ve termin bilgisine göre sistem tarafından sıralanarak üretim hattı girişindeki birinci ekrana yansır. Sonrasında, hat doluluk ve çalışan bilgisine göre sistem tarafından üretim çizelgeleme yapılır ve hatta çalışan kişilerin önüne üretim yapılacak siparişler Şekil 5.5'te gösterilen üretime alınacak sipariş bilgilendirme ekranına düşer. Her bir üretim hattındaki görevli personel tarafından tablet ile ilgili sipariş için üretim başladı olarak durumu güncellenir. Tablet ekranında personelin ihtiyacı olan tüm bilgiler görüntülenebilmektedir. Siparişin durumu “*üretim başladı*” olarak güncellendiğinde sipariş bilgilendirme ekranından kaybolmakta ve üretim çizelgeleme ekranı da güncellenmektedir.

SerimID	PastalID- gerber	Parti	Satıcı Partisi	Pastal Beden Sayısı	En	Malzeme Kodu	Malzeme Tanımı	Model Adı	MS Mik.	YML
12290	165-23107-MTRJ-175A	21Y3489869	17769-1-1-3	Pastal Beden Sayısı	En	1030123655	30/1 Penye LQJ BLA SUP EMPRM	GPJ,COOKING-B 21K 3010	3.408	3.40
12288	115-34942-SYH-187	21Y3237668	2988	Pastal Beden Sayısı	En	1030063171	30/1 PNY PAM LYC SUP DÜZ CVL LCW YENİ Sİ	TYT,KUŞAK-ALT 21Y 3010	11.340	11.3
12282	145-25673-RED184A	21K3486435	8334-1-1	Pastal Beden Sayısı	En	1030130242	26/1 Penye HMW SUP DÜZ BYA	TKM,DINNA-INT-A 21K 3010	1.976	1.97
12278	110-06674-SARI-194A	21K3472013	K96440	Pastal Beden Sayısı	En	1030107161	30/70/20 VRTKS PAM PES 3IP DÜZ QA6 YELLO	SWT,SETA 21K 3010	2.196	2.19
12276	110-06674-SARI-194A	21K3472013	K96440	Pastal Beden Sayısı	En	1030107161	30/70/20 VRTKS PAM PES 3IP DÜZ QA6 YELLO	SWT,SETA 21K 3010	2.196	2.19

Şekil 5.5: Üretime alınacak sipariş bilgilendirme ekranı.

Birinci prosesteki işlem bittiğinde siparişin durumu “*üretim bitti*” olarak güncellenir ve gerçekleşen verinin makineden alınması sağlanır. İşlemler tüm prosesler için aynı şekilde girilir.

Status	Serim Başl	Serim Btl	Serim Bti	Kullanı	Model Adı	Üretim Sp	Renk	Müşteri sps	Mstr.spr	İplik	Kumaş Kal	Kumaş Cnsi	Net Boy	Gramaj	Serim Past	Kat Sayı	Asortö T	Toplam Adet	Meto No
SR	14.06.2021	22:25:07	14.06.2021	23:03:58	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,240	0,235	273,540	97,000	12	1164	921-19-1-02
SRMF	14.06.2021	22:25:07	14.06.2021	22:25:54	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,240	0,235	267,900	95,000	12	1140	921-19-1-04
SRMF	14.06.2021	22:25:07	14.06.2021	22:25:31	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,240	0,235	267,900	95,000	12	1140	921-19-1-06
SRMF	16.06.2021	09:14:42	16.06.2021	09:15:15	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,410	0,237	236,301	83,000	12	996	921-5-1-13
SRMF	16.06.2021	09:14:42	17.06.2021	00:11:55	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,410	0,237	207,831	73,000	12	876	921-5-1-14
SRMF	16.06.2021	09:14:42	17.06.2021	00:11:23	UK.BDY,DARLY-1W 21K 30	1202049671	FFB	1010100795	100	220	122	30/1-TEK TOP PIKE	8,410	0,237	219,219	77,000	12	924	921-5-1-15

Şekil 5.6: Üretim bilgi görüntüleme ekranı.

Sonrasında, proses ve kullanıcı bazlı tüm bilgilerin sistemde tutularak günlük, haftalık ve aylık performansların görüntülenebileceği dashboard Şekil 5.7'deki gibi oluşturularak ilgili birimlere konumlandırılmıştır.

İşe Gelen Personel Sayısı:		Serim Kg		Toplam Adet		Serim Sayısı		14. HAFTA PAZARTESİ		Serim Kg		Toplam Adet		Serim Sayısı	
PAZARTESİ	80	125,000		250		850,000	250			23,000		120,000	80		
SALI	82														
ÇARŞAMBA	85	130,000		300		900,000	300			20,000		200,000	60		
PERŞEMBE	80	135,000		350		910,000	350			30,000		180,000	55		
CUMA	78	130,000		250		790,000	250			28,000		250,000	75		
CUMARTESİ		130,000		250		870,000	250			24,000		230,000	80		
PAZAR										MESAJ VARSA EKLENCEK					

Serim Personeli		Görgekleme Kg								Serim Sayısı								Görgekleme Adet							
		10. HAFTA	11. HAFTA	12. HAFTA	13. HAFTA	14. HAFTA	10. HAFTA	11. HAFTA	12. HAFTA	13. HAFTA	14. HAFTA	10. HAFTA	11. HAFTA	12. HAFTA	13. HAFTA	14. HAFTA	10. HAFTA	11. HAFTA	12. HAFTA	13. HAFTA	14. HAFTA				
SAHİ	1	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
BAŞLİ KLİNYAKA KONTROLÖRÜ	2	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
OPERASYON TEKNİSYENİ	3	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
TEKNOLOJİ PAZARI UZMANI	4	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KALİBRASYON TEKNİSYENİ	5	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK UZMANI	6	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	7	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK YARDIMCI KLİNİK	8	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	9	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	10	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	11	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	12	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	13	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	14	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	15	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	16	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	17	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	18	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	19	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	20	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	21	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	22	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	23	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	24	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	25	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	26	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	27	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	28	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	29	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	30	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	31	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	32	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	33	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	34	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	35	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	36	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	37	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	38	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	39	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	40	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	41	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	42	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	43	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	44	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	45	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	46	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	47	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	48	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	49	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	50	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KLİNİK	51	15,000	15,000	15,000	15,000	15,000	100	100	100	100	100	100	100	100	100	100	100,000	100,000	100,000	100,000	100,000				
KLİNİK YARDIMCI KL																									

Şekil 5.7: Performans gösterge raporu.

Proseslerde yarı mamul için Şekil 5.8'deki QR kodlu barkod yazdırması yapılarak üretime ait tüm bilgiler QR kod içerisinde tutulmuştur. Yarı mamuller QR kodları ile paketlenerek sevk birimine teslim edilir. Oluşturulan QR sistemiyle onay süresi, proses bazlı çevrim süresi, kullanıcı bazlı işlem süresi, üretim gün süresi ve makine duruş oranı gibi bilgiler ölçülebilmektedir.



TORBA-202110057900

Şekil 5.8: Paket takip QR kodları.

5.2.3 Yarı mamul kabul ve sevk süreçleri ERP aktarımı


QR kodlar el terminali ile okutularak yarı mamul sevk biriminin stoğuna alınır ve yarı mamuller operasyon bazında sepetlere adreslenir. Sistem yarı mamul için operasyon bilgisini kontrol ederek yalnızca ilgili operasyona ait sepetlere adreslenmesine izin vermektedir. Bir sepete başka bir siparişe ait yarı mamul paketi eklenmek istendiğinde uyarı vererek siparişlere ait paketlerin karışmasını önlemektedir. Sepetler alınarak el

terminali ile raflara adreslenir. Her bir operasyon için farklı raf alanları olup operasyon tipine uymayan sepetler ilgili raflara adreslenememektedir. Burada kullanılan araç ve alan QR kodları Şekil 5.9’da gösterilmektedir.



Şekil 5.9: Sepet ve adres QR kodları.

Stokta görünen yarı mamul sevki için ilgili kişi ilgili firma için sistemden randevu talebini yapar. İlgili randevu bilgisine göre saha personeli Şekil 5.10’daki uygulamadan el terminaline sepetleri okutarak sevk alanına transfer sağlar.



Şekil 5.10: Saha personeli app uygulaması.

Her bir sepet ve paket QR kodu okutması el terminali ile gerçekleştirilerek kontrol listesi oluşturulur ve sevk irsaliyesi kesilir. Sevk ve kontrol listesi bilgileri otomatik mailer ile ilgili kişilere yönlendirilir.

Randevu ve sevk alacak araç bilgileri Şekil 5.11’deki dashboard ile sahadaki personele yansıtılarak işlem kolaylığı ve sevk süresinin minimuma indirilmesi hedeflenmiştir.



Şekil 5.11: Sevk süreçleri dashboard ekranı.

Tüm işlemler kullanıcı bazlı yapılmakta ve sistem üzerinden takip edilmektedir. Sistem ile kapasite doluluk oranı, stok bekleme gün süresi, sevk süresi ve adresleme süresi gibi bilgiler raporla araçlarıyla raporlanabilmektedir.

5.3 Üçüncü Faz Çalışması

Bu faz çalışmasında, tüm süreçlerin kurumsal kaynak planlama ERP sistemine aktarımı yapıldıktan sonra sistemde oluşan veriler ile süre tahminleme, makine duruş takibi ve üretim çizelgeleme çalışmaları yapılmıştır.

5.3.1 Süre tahminleme

Üretim hattındaki makinelerden alınan proses bazlı süreler ile üretilecek ürüne ait nitelikler arasında bağlantı kurularak herhangi bir ürünün prosese girdiğinde ne kadar sürede tamamlanacağı dört farklı algoritma ile Knime platformunda denenmiştir.

Bunun için kayıtlara ait aşağıdaki maddelerde yer alan bilgiler sistemden alınmış ve veri seti oluşturulmuştur.

- Tedarik
- Klasman
- Kumaş
- Serim Yönu
- Personel İsmi


- Makine Hızı
- Adet
- Gramaj
- Toplam Ağırlık
- Süre

Herhangi bir ürünün prosese girdiğinde ne kadar sürede tamamlanacağını tahmin etmek için bir kısmı Çizelge 5.2’de verilen 2000 adet veriden oluşan bir veri seti kullanılmıştır.

Çizelge 5.2: Örnek veri seti.

RowID	Tedarik	Klasman	Kumaş	Serim Yünü	Personel İsmi	Makine Hızı	Adet Aralık	Top Ağırlık	Süre (Dk)
Row0	Kız Çocuk	Tayt	LYC SUP	Kapak	Personel4	Yavaş	0-1000	133	48
Row1	Bebek	Swt	3IP	Tek	Personel4	Hızlı	2000-3000	672	74
Row2	Erkek Büyük	Kk.Tsh	SUP	Kapak	Personel8	Hızlı	2000-3000	570	85
Row3	Bayan Büyük	Tnk	LYC SUP	Kapak	Personel2	Orta	0-1000	370	50
Row4	Kız Çocuk	Kk.Tsh	SUP	Kapak	Personel5	Hızlı	2000-3000	241	68
Row5	Yenidogan	Tulum	LYC SUP	Tek	Personel10	Yavaş	4000-5000	426	81
Row6	Erkek Büyük	Kk.Tsh	SUP	Kapak	Personel11	Orta	2000-3000	461	119
Row7	Erkek Büyük	Sort	SUP	Kapak	Personel5	Hızlı	1000-2000	438	73
Row8	Erkek Büyük	Kk.Tsh	TTP	Kapak	Personel5	Hızlı	2000-3000	541	67
Row9	Garni	Garnı	RIB	Kapak	Personel4	Yavaş	0-1000	136	25
Row10	Erkek Büyük	Kk.Tsh	SUP	Kapak	Personel11	Hızlı	0-1000	181	44
Row11	Bayan Büyük	U.Kol	LYC SUP	Kapak	Personel2	Yavaş	0-1000	321	56
Row12	Erkek Büyük	Kk.Tsh	SUP	Kapak	Personel11	Hızlı	1000-2000	273	65
Row13	Erkek Büyük	Kk.Tsh	SUP	Kapak	Personel5	Hızlı	1000-2000	375	84
Row14	Erkek Büyük	Kk.Tsh	TTP	Kapak	Personel4	Hızlı	0-1000	155	53
Row15	Bebek	Kk.Tsh	SUP	Tek	Personel8	Hızlı	4000-5000	327	110
Row16	Erkek Çocuk	Swt	3IP	Kapak	Personel9	Hızlı	0-1000	161	33
Row17	Kız Çocuk	U.Kol	3IP	Kapak	Personel8	Hızlı	0-1000	160	28
Row18	Bayan Büyük	U.Kol	LYC SUP	Kapak	Personel2	Yavaş	0-1000	328	57
Row19	Erkek Büyük	Sort	SUP	Kapak	Personel7	Orta	1000-2000	350	77
Row20	Bayan Büyük	Atlet	VIS SUP	Kapak	Personel2	Yavaş	1000-2000	454	53

Veri seti knime platformuna alınarak istatistiksel değerleri Şekil 5.12’deki “statistics” modülü kullanılarak çıktı alınmış olup elde edilen sonuçlar Tablo 5.3’te verilmiştir.




Şekil 5.12: Knime statistics modülü.

Çizelge 5.3: Knime istatistik sonuçları.

Kolon	Min.	Max.	Ortalama	Standart sapma	Varyans	Skewness	Kurtosis	Genel toplam
Süre (Dk)	10	171	59,706	25,637	657,256	1,1196	1,9634	16419,383

Veriler alındıktan sonra temizleme, eksik verilerin tamamlanması, aykırı verilerin bulunması ve ilişkisiz olan alanların veri setinden çıkarılması ön hazırlık çalışmaları Şekil 5.13’te gösterildiği gibi yapılmıştır.



Şekil 5.13: Knime ön işleme yapılmış veri ve statistics modülü.

Ön hazırlık çalışmalarının ardından alınan istatistik değerleri Çizelge 5.4’te verilmiştir. Eksik verilerin tamamlanması ve aykırı verilerin veri setinden çıkarılması ile standart sapma ve varyans gibi değerlerin düştüğü görülmüştür. Ön hazırlık yapılan veri seti süre tahminleme algoritmalarında kullanılmıştır.

Çizelge 5.4: Knime ön işleme yapılmış veri istatistik sonuçları.


Kolon	Min.	Max.	Ortalama	Standart sapma	Varyans	Skewness	Kurtosis	Genel toplam
Süre (Dk)	10	119	57,317	21,704	471,088	0,5070	-0,2708	15303,883

Ön hazırlıktan alınan veri setinin *test* ve *eğitim* verileri olarak bölünmesi için Knime Analytics içerisinde bulunan “Partitioning” modülü kullanılmıştır.

Eğitim veri seti kullanılarak dört adet model oluşturulmuş ve oluşturulan model diğer veri setleri ile çalıştırılarak sonuçlar incelenmiştir. Modeller lineer regresyon, polinomal regresyon, gradyan destekli regresyon ağaçları ve rassal orman regresyon algoritması kullanılarak oluşturulmuştur. Modeller ile numerik değere sahip süre (Dk) kolonu tahminleme çalışması yapılmıştır.


Bu modellerin eğitilmesi ve test edilmesi yine Knime Analytics üzerinde bulunan modüller ile yapılmıştır. Model oluşturma ve test işlemi tamamlandıktan sonra Knime üzerinden bulunan “scorer” modülü kullanılarak başarı oranları çıkarılmıştır.

Değişkenler arasındaki doğrusal ilişki var olup olmadığının ve algoritmanın modelimize uygunluğunun tespiti için ilk olarak Şekil 5.14’te gösterilen Knime Linear Regression modülü ile lineer regresyon algoritması modele uygulanarak tahminleme yapılmış ve scorer modülünden başarı oranları alınmıştır.



Şekil 5.14: Knime lineer regresyon modülü.

Algoritmanın çalıştırılmasıyla Knime üzerinden alınan lineer regresyon grafiği Şekil 5.15’te verilmiştir. Elde edilen grafik bir doğru üzerinde tahmin edilen verilerin dağılımını göstermektedir.



Şekil 5.15: Çalıştırılan model lineer regresyon grafiği.

Knime Linear Regression modülünde veri setinde sayısal değerlere sahip olan Toplam Ağırlık ve Süre (Dk) arasındaki ilişkiye bakılarak test verisindeki Süre (Dk) sayısal değerinin tahminlenmesi sağlanmıştır. Regresyon modelleri tahminleme sonuçlarının değerlendirilmesinde MAE, MSE, RMSE hata metriklerinin kullanımı yaygın olup lineer regresyon modelimiz için de elde edilen bu sonuçlar Çizelge 5.5'te verilmiştir.

Çizelge 5.5: Lineer regresyon sonuçları.

Değerlendirme Metrikleri	Değer
R^2	0,339
MAE	18,018
MSE	618,792
RMSE	24,876
MSD	-6,335
MAPE	0,282

Modelden elde edilen R^2 değeri tüm modeller için 0,256 - 0,384 aralığında sonuçlanmış olup lineer regresyon modelinin R^2 değeri 0,339 olarak sonuçlanmıştır. Bu değer veri setine uyumlu olması için 1 değerine yakın olması istenmektedir.


MAE değeri tüm modeller için 14,637 - 18,028 aralığında sonuçlanmış olup lineer regresyon modelinin MAE değeri 18,018 olarak sonuçlanmıştır.

MSE değeri tüm modeller için 385,607 - 618,792 aralığında sonuçlanmış olup lineer regresyon modelinin MSE değeri 618,792 olarak sonuçlanmıştır.


RMSE değeri tüm modeller için 19,637 - 24,876 aralığında sonuçlanmış olup lineer regresyon modelinin RMSE değeri 24,876 olarak sonuçlanmıştır. Tahminlemedeki hatanın düşük sonuçlanması için MAE, MSE, RMSE değerlerinin en düşük seviyede olması istenmektedir.

Daha sonra, Knime Polynomial Regression modülü kullanılarak polinomal regresyon algoritması ile tahminleme yapılmış ve scorer modülünden başarı oranları alınmıştır.

Knime Polynomial Regression modülünde de aynı şekilde veri setinde sayısal değerlere sahip olan Toplam Ağırlık ve Süre (Dk) arasındaki ilişkiye bakılarak test verisindeki Süre (Dk) sayısal değerinin tahminlenmesi sağlanmıştır. Kullanılan Knime Polynomial Regression modülü Şekil 5.16'da verilmiştir.



Şekil 5.16: Knime polinomal regresyon modülü.



Şekil 5.17: Çalıştırılan model polinomal regresyon grafiği.

Algoritmanın çalıştırılması ile Knime üzerinden alınan polinomal regresyon grafiği ise Şekil 5.17'de verilmiştir.

Grafik bir doğru üzerinde tahmin edilen verilerin dağılımını göstermektedir. Yapılan tahminleme sonuçları Çizelge 5.6’da verilmiştir.

Çizelge 5.6: Polinomal regresyon sonuçları.

Değerlendirme Metrikleri	Değer
R^2	0,301
MAE	17,189
MSE	529,120
RMSE	23,003
MSD	0,575
MAPE	0,419

Tahminleme sonuçlarına göre, R^2 değeri tüm modeller için 0,256 - 0,384 aralığında sonuçlanmış olup polinomal regresyon modelinin R^2 değeri 0,301 olarak sonuçlanmıştır. Bu değer veri setine uyumlu olması için 1 değerine yakın olması istenmektedir.


MAE değeri tüm modeller için 14,637 - 18,018 aralığında sonuçlanmış olup polinomal regresyon modelinin MAE değeri 17,189 olarak sonuçlanmıştır.

MSE değeri tüm modeller için 385,607 - 618,792 aralığında sonuçlanmış olup polinomal regresyon modelinin MSE değeri 529,120 olarak sonuçlanmıştır.

RMSE değeri ise tüm modeller için 19,637 - 24,876 aralığında sonuçlanmış olup polinomal regresyon modelinin RMSE değeri 23,003 olarak sonuçlanmıştır.

Üçüncü olarak hem regresyon hem de sınıflandırma problemlerinde başarılı bir makine öğrenmesi algoritması olan gradyan destekli karar ormanı regresyonu algoritması modele uygulanmıştır.

Knime Gradient Boosted Trees Regression modülü kullanılarak tahminleme yapılmış ve scorer modülünden başarı oranları alınmıştır. Knime Gradient Boosted Trees Regression modülünde veri setinde bulunan nümerik ve nominal değerler birlikte kullanılarak test verisindeki süre (Dk) sayısal değerinin tahminlenmesi sağlanmıştır. Kullanılan Knime Gradient Boosted Trees Regression modülü Şekil 5.18’de gösterilmiştir. Elde edilen tahminleme sonuçları ise Çizelge 5.7’de verilmiştir.



Şekil 5.18: Knime gradyan destekli karar ormanı regresyonu modülü.

Çizelge 5.7: Gradyan destekli karar ormanı regresyonu sonuçları.

Değerlendirme Metrikleri	Değer
R^2	0,256
MAE	16,506
MSE	530,386
RMSE	23,03
MSD	0,385
MAPE	0,296


Çizelge 5.7’deki sonuçlara göre, R^2 değeri tüm modeller için 0,256 - 0,384 aralığında sonuçlanmış olup gradyan destekli karar ormanı regresyonu modelinin R^2 değeri 0,256 olarak sonuçlanmıştır. Bu değer veri setine uyumlu olması için 1 değerine yakın olması istenmektedir.

MAE değeri tüm modeller için 14,637 - 18,018 aralığında sonuçlanmış olup gradyan destekli karar ormanı regresyonu modelinin MAE değeri 16,506 olarak sonuçlanmıştır.

MSE değeri tüm modeller için 385,607 - 618,792 aralığında sonuçlanmış olup lineer regresyon modelinin MSE değeri 530,386 olarak sonuçlanmıştır.


RMSE değeri tüm modeller için 19,637 - 24,876 aralığında sonuçlanmış olup lineer regresyon modelinin RMSE değeri 23,03 olarak sonuçlanmıştır. Tahminlemedeki hatanın düşük sonuçlanması için MAE, MSE, RMSE değerlerinin en düşük seviyede olması istenmektedir.

Son olarak birden fazla karar ağacını kullanarak daha uyumlu modeller üretebilen ve isabetli tahminlerde bulunmaya yarayan rassal orman regresyon algoritması modele uygulanmıştır. Knime Random Forest Regression modülü kullanılarak tahminleme yapılmış ve scorer modülünden başarı oranları alınmıştır. Knime Random Forest Regression veri setinde bulunan nümerik ve nominal değerler birlikte kullanılarak test verisindeki süre (Dk) sayısal değerinin tahminlenmesi sağlanmış ve Knime Random Forest Regression modülü Şekil 5.19’da verilmiştir.



Şekil 5.19: Knime rassal orman regresyon modülü.

Algoritmanın çalıştırılması ile Knime platformundan elde edilen karar ağacı görüntüsü Şekil 5.20’de verilmiştir.



Şekil 5.20: Çalıştırılan model ağaç grafiği.

Algoritmadan elde edilen tahminleme sonuçları Çizelge 5.8’deki gibi elde edilmiştir.

Çizelge 5.8: Rassal orman regresyon algoritması sonuçları.

Değerlendirme Metrikleri	Değer
R^2	0,384
MAE	14,637
MSE	385,607
RMSE	19, 637
MSD	1,229
MAPE	0,364

Çizelge 5.8’deki sonuçlara göre, R^2 değeri tüm modeller için 0,256 - 0,384 aralığında sonuçlanmış olup rassal orman regresyon modelinin R^2 değeri 0,384 olarak sonuçlanmıştır.

MAE değeri tüm modeller için 14,637 - 18,018 aralığında sonuçlanmış olup rassal orman regresyon modelinin MAE değeri 14,637 olarak sonuçlanmıştır. MSE değeri tüm modeller için 385,607 - 618,792 aralığında sonuçlanmış olup rassal orman regresyon modelinin MSE değeri 385,607 olarak sonuçlanmıştır. RMSE değeri tüm modeller için 19,637 - 24,876 aralığında sonuçlanmış olup rassal orman regresyon modelinin RMSE değeri 19,637 olarak sonuçlanmıştır. Tahminlemedeki hatanın düşük sonuçlanması için MAE, MSE, RMSE değerlerinin en düşük seviyede olması istenmektedir.

Tüm algoritmalar için oluşturulan modellerden elde edilen değerlendirme sonuçlarının karşılaştırılması Çizelge 5.9’da verilmiştir.

Çizelge 5.9: Tüm modellerden elde edilen sonuçlar.

Değerlendirme Metrikleri	Lineer Regresyon	Polinomal Regresyon	Gradyan Destekli Karar Ormanı Regresyonu	Rassal Orman Regresyonu
R^2	0,339	0,301	0,256	0,384
MAE	18,018	17,189	16,506	14,637
MSE	618,792	529,120	530,386	385,607
RMSE	24,876	23,003	23,03	19, 637
MSD	-6,335	0,575	0,385	1,229
MAPE	0,282	0,419	0,296	0,364

Çizelge 5.8’de yer alan özet tablodaki verilere göre en yüksek R^2 değeri 0,384 ile rassal orman regresyonu modelinden elde edilmiştir. Aynı zamanda 14,687 MAE, 385,607

MSE ve 19,637 RMSE değerleri ile en düşük hata metrikleri de rassal orman regresyonu modelinden elde edilmiştir. Dolayısıyla bu değerlerin en düşük olduğu modelin, veri setiyle en iyi uyumu sağlayacağı öngörüldüğü için yapılan tahminleme çalışmaları için en iyi uyumu rassal orman regresyonu modelinin sağladığı tespit edilmiştir. Bundan dolayı rassal orman regresyonu algoritması ERP sistemi planlama modülü içerisine aktarılmıştır. Böylelikle, sistemde proses ve ürün niteliği bazında tutulan veriler üretim devam ettikçe sahadan alınmakta ve sanal ortamda büyük veri olarak depolanmaktadır. Algoritma büyük veriden beslenerek veri hacmi arttıkça daha doğru bir tahminleme sunmaktadır.

5.3.2 Makine duruş takibi

Üretim hattında yer alan makineler üzerindeki sensörler ve makine operatörleri aracılığı ile Şekil 5.21’de gösterilen ERP makine duruş, bakım ve onarım modülü oluşturularak makine ile ilgili çalışma hızı, çalışma süresi, bekleme süresi gibi verilerin ilgili ürün ve hat için tutulması sağlanmıştır.

Şekil 5.21: ERP makine duruş, bakım ve onarım modülü.

Verimlilik takibinin ve arttırımının yapılabilmesi için ise Şekil 5.22’de gösterilen bakım ve onarım tiplerinin süre olarak kayıt altına alınması sağlanmıştır. Hat durumu verileri üretim çizelgeleme modülünde hat dengeleme ve çizelgeleme çalışmasında kullanılmıştır.


0030	PM01	Motor arızası		60	DAK
0040	PM02	Günlük bakım			DAK
0050	PM01				DAK

Şekil 5.22: Bakım ve onarım kayıtlarının yapılması.

5.3.3 Üretim çizelgeleme

Uygulamadaki çizelgeleme çalışmasında, 5 hat ve 3 iş için alınan tahminleme süreleri ve hat doluluğu gibi veriler referans alınarak üretim çizelgeleme çalışması yapılmıştır. Çalışma yapılırken ham madde kalite kontrol sonucu, hatta çalışan personel, makine bakım ve arızaları, standart zaman ve hat doluluğu gibi parametreler sistem üzerinden alınarak üretim hattında üretilen ürünlerin tahmin edilen sürelerine bu parametrelere özel ağırlıklandırma yapılarak hat doluluğu hesaplanmıştır.

Hat doluluk durumuna ve hat üzerinde çalışan personel bilgisine göre ürünlerin çizelgelemesinin sistem tarafından yapılıp çalışan personelin ekranlarına bilgilerin iletilmesi sağlanmıştır. Çalışmada üretim hattında tamamlanma zamanı, toplam akış zamanı ve makinelerin toplam boş bekleme zamanının minimum olacak şekilde sonuçlar elde edilmesi amaçlanmıştır. Çizelgeleme çalışmasının geliştirme çalışmaları devam etmekte olup ve şematik olarak Şekil 5.23'te verilmiştir.



Şekil 5.23: Üretim çizelgeleme çalışması hat görünümü.

6. SONUÇ VE ÖNERİLER

Bilgi teknolojilerinin hızlı gelişimi ile birlikte, son yıllarda tüm sektörlerde ürünlere yönelik üretim görevlerinin sayısı önemli ölçüde artmış ve bu da ürün verilerinin miktarında hızlı bir artışa neden olmuştur. Bu devasa miktardaki verinin gerçek zamanlı olarak toplanması ve sınıflandırılması ve bu verilerin süreç izlenebilirliğini ve ürün tasarımı ve sürecinin sürekli iyileştirilmesini sağlamak için yapısal olarak yönetilmesi ve analiz edilmesi temel veri yönetimi konuları haline gelmiştir.

Verilerin artmasıyla birlikte artan dijitalleşme herkes tarafından benimsenen bir durum haline gelmiştir. Özellikle IoT, bulut bilişim, büyük veri analitiği ve yapay zeka gibi yeni nesil bilgi teknolojilerinin ortaya çıkmasıyla birlikte dijitalleşme süreci de büyük ölçüde hızlanmıştır.

Dijitalleşme sürecindeki verileri kullanan teknolojilerden biri de dijital ikizdir. Dijital ikiz, çift yönlü etkileşimler yoluyla birbirleriyle karşılıklı olarak iletişim kuran, teşvik eden ve birlikte gelişen organik bir fiziksel varlık ve bunun dijitalleştirilmiş temsili anlamına gelmektedir. Dijital ikizde fiziksel dünyadaki varlıklar, davranışlar ve ilişkiler, aslına uygun sanal modeller oluşturmak için bütünsel olarak dijitalleştirilir. Oluşturulan bu sanal modeller ise fiziksel dünyadaki gerçek dünya verilerine bağlı olmaktadır. Dijital ikiz, makinelerin veya sistemlerin sanal kopyalarını oluşturarak endüstride devrim yaratmakta ve birçok şirket tarafından sorunları tespit etmek ve verimliliği artırmak için halihazırda kullanılmaktadır. Ayrıca dijital ikiz sistemleri, müşteri taleplerini hızlı bir şekilde anlamada, modellerdeki zayıflıkları erken belirlemede ve hatta tahmin etmede, değişen çevreye zamanında yanıt vermek için üretim süreçlerini kontrol etmede ve tesisi optimize etmek için değerli önerilerde bulunmada yardımcı olabilen ürün tasarımı ve üretiminde yaygın olarak uygulanmaktadır. Dijital ikizin, sistem mimarilerinin mevcut ve gelecekteki koşullarını temsil etme, tahmin etme ve yönetme konusunda potansiyel olarak geniş bir uygulama beklentisine sahip olduğu kanıtlanmıştır. Dijital ikizin üretimdeki bu başarısı nedeniyle, tüm sektörlerde dijital gelişmeyi desteklemek için siber-fiziksel model oluşturmaya yönelik çeşitli çalışmalar yapılmaktadır.

Bu çalışmada, hazır giyim sektöründe faaliyet gösteren öncü bir firmanın bir üretim tesisinde, süreçlerin dijital ikiz modelinin oluşturulabilmesi için altyapı geliştirme çalışmaları yapılmıştır.

Yapılan çalışmada ilk olarak, tüm süreçlerde süreç haritaları oluşturularak süreç geliştirme çalışmaları sistem üzerine aktarılmıştır. Sürekli değişen verilerin sensörler ve arayüzler ile alınması, işlenmesi, depolanması ve raporlanması sağlanarak manuel yürütülen süreçlerin sistem üzerinden takip edilmesi ve yönetilmesi sağlanmıştır.

Makine öğrenmesi yöntemlerinden olan lineer regresyon, polinomal regresyon, gradyan destekli karar ormanı regresyonu ve rassal orman regresyon algoritmaları kullanılarak bir ürünün üretim süresi tahmin edilmiş ve sonuçlar karşılaştırılmıştır. Elde edilen model sonuçlarında en yüksek R^2 ve en düşük MAE, MSE ve RMSE hata metrik değerlerine sahip olan rassal orman regresyon algoritması en uygun algoritma olarak tespit edilmiştir. Bu algoritmayla oluşturulan modelin tahminlemede başarılı olmasının sebebi veri setinin nümerik ve nominal değerlerden oluşması ve algoritmanın sınıflandırma ile birlikte sayısal değerleri tahmin edilebilmesidir.

Daha sonra rassal orman regresyonu modeli ERP altyapısına entegre edilmiştir. Tahminleme ile ürünler için klasman ve tedarik bazında standart süreler elde edilmesi sağlanmış olup bu standart süreler ile maliyetlendirme, verimlilik ölçme, raporlama ve performans değerlendirme gibi çalışmalar yapılmıştır. Tahminlemeyle, farklı niteliklere sahip herhangi bir ürün üretim hattına girdiğinde makine öğrenmesi algoritması ile üretim süresinin tahminlenmesi sağlanmıştır. Bu durum daha önce üretilmemiş çeşitlilikteki ürünler için de maliyetlendirme ve üretim planlama gibi çalışmaların yapılabilmesini sağlamıştır.

Tahmin edilen üretim süreleri ve hat üzerindeki çeşitli parametrelere göre üretim çizelgeleme çalışması tasarımı yapılmış olup geliştirme ve testlerden sonra uygulamaya alınacak olup hat doluluğuna göre sistemin kendi kendine karar vererek üretim çizelgeleme yapması öngörülmektedir. Çizelgeleme çalışmasından sonra sistemin termin ve üretim süresine göre otomatik sevk planlama yapması sağlanıp uçtan uca kendi kendini yönetebilen bir sistem kurulması hedeflenmektedir.

Makine bakım ve onarım modülünün kullanılmaya başlanması ile duruş takibinin yapılması sağlanarak önleyici bakım ile verimlilikte artış hedeflenmiştir.

Sistemden sürekli beslenen büyük veri ile daha doğru bir tahminleme yapılacağı öngörülmektedir. Tahmin edilen süreler ile her bir ürün için standart süre belirlenmiş olup bu standart süreler ile maliyetlendirme, performans değerlendirme ve işletme verimliliğinin ölçülmesi gibi çalışmalar yapılmıştır.

Sonuç olarak, bu tez çalışmasında kendi kendine karar verebilecek bir sistem için altyapı çalışmaları oluşturulmuş olup bundan sonraki süreçlerde fiziksel ortamdan alınan verilerin işlenmesiyle sanal ortamdaki modelin çalışması ve üretimi yönlendirmesi hedeflenmektedir.



KAYNAKLAR

- Abdulhameed, O., Al-Ahmari, A., Ameen, W., & Mian, S. H.** (2019). Additive manufacturing: Challenges, trends, and applications. *Advances in Mechanical Engineering*, 11(2), 1687814018822880.
- Abouzakhar, N.** (2013). Critical infrastructure cybersecurity: A review of recent threats and violations. *12th European Conf on Cyber Warfare and Security*, Finland, 11-12 July, 1-10.
- Abramovici, M., Göbel, J. C., & Dang, H. B.** (2016). Semantic data management for the development and continuous reconfiguration of smart products and systems. *CIRP Annals*, 65(1), 185-188.
- Adar, E., & Wuchner, A.** (2005). Risk management for critical infrastructure protection (CIP) challenges, best practices & tools. In *First IEEE International Workshop on Critical Infrastructure Protection (IWCIP'05)*, IEEE, 8.
- Aggrey, S. E.** (2002). Comparison of three nonlinear and spline regression models for describing chicken growth curves. *Poultry science*, 81(12), 1782-1788.
- Akar, Ö., & Güngör, O.** (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 1(2), 139-146.
- Almada-Lobo, F.** (2015). The industry 4.0 revolution and the future of Manufacturing Execution Systems (MES). *Journal of innovation management*, 3(4), 16-21.
- Altınpulluk, H.** (2015). Artırılmış gerçekliği anlamak: kavramlar ve uygulamalar. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 1(4), 123-131.
- Arden, N. S., Fisher, A. C., Tyner, K., Lawrence, X. Y., Lee, S. L., & Kopcha, M.** (2021). Industry 4.0 for pharmaceutical manufacturing: Preparing for the smart factories of the future. *International Journal of Pharmaceutics*, 602, 120554.
- Arinez, J. F., Chang, Q., Gao, R. X., Xu, C., & Zhang, J.** (2020). Artificial intelligence in advanced manufacturing: Current status and future outlook. *Journal of Manufacturing Science and Engineering*, 142(11), 110804.
- Vouk, A. M.** (2008). Cloud computing—issues, research and implementations. *Journal of computing and information technology*, 16(4), 235-246.
- Bahrin, M. A. K., Othman, M. F., Azli, N. H. N., & Talib, M. F.** (2016). Industry 4.0: A review on industrial automation and robotic. *Jurnal Teknologi*, 78(6-13).

- Bao, J., Guo, D., Li, J., & Zhang, J.** (2019). The modelling and operations for the digital twin in the context of manufacturing. *Enterprise Information Systems*, 13(4), 534-556.
- Başar, A., Özkaya, A., & Kesgin, F.** (2015). Yazılım geliştirme süreçlerinde şelale yönteminden çevik yaklaşıma geçiş: bir teknoloji şirketinde uygulama, *9. Ulusal Yazılım Mühendisliği Sempozyumu (UYMS'15)*, 09-11 Eylül, İzmir.
- Bibby, L., & Dehe, B.** (2018). Defining and assessing industry 4.0 maturity levels—case of the defence sector. *Production Planning & Control*, 29(12), 1030-1043.
- Bilberg, A., & Malik, A. A.** (2019). Digital twin driven human–robot collaborative assembly. *CIRP Annals*, 68(1), 499-502.
- Bitkom, V. D. M. A.** (2015). ZVEI: Umsetzungsstrategie Industrie 4.0, Ergebnisbericht der Plattform Industrie 4.0. *Plattform Industrie*, 4.
- Boehm, B., & Turner, R.** (2003, June). Observations on balancing discipline and agility. *In Proceedings of the Agile Development Conference*, 32-39.
- Boeykens, S.** (2011). Using 3D design software, BIM and game engines for architectural historical reconstruction. *Designing Together-CAADfutures*, 493-509.
- Bortolini, M., Ferrari, E., Gamberi, M., Pilati, F., & Faccio, M.** (2017). Assembly system design in the industry 4.0 era: a general framework. *IFAC-PapersOnLine*, 50(1), 5700-5705.
- Bugiel, S., Nurnberger, S., Sadeghi, A., & Schneider, T.** (2011). Twin clouds: An architecture for secure cloud computing. *In Workshop on cryptography and security in clouds (WCSC 2011)*, 1217889.
- Botkina, D., Hedlind, M., Olsson, B., Henser, J., & Lundholm, T.** (2018). Digital twin of a cutting tool. *Procedia Cirp*, 72, 215-218.
- Burgos, D., & Ivanov, D.** (2021). Food retail supply chain resilience and the COVID-19 pandemic: A digital twin-based impact analysis and improvement directions. *Transportation Research Part E: Logistics and Transportation Review*, 152, 102412.
- Can, A. V., & Kıymaz, M.** (2016). Bilişim teknolojilerinin perakende mağazacılık sektörüne yansımaları: muhasebe departmanlarında endüstri 4.0 etkisi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 107-117.
- Cardenas, A. A., Amin, S., Lin, Z. S., Huang, Y. L., Huang, C. Y., & Sastry, S.** (2011, March). Attacks against process control systems: risk assessment, detection, and response. *In Proceedings of the 6th ACM symposium on information, computer and communications security*, 355-366.
- Cardon, D., Cointet, J. P., Mazières, A., & Libbrecht, E.** (2018). Neurons spike back. *Reseaux*, (5), 173-220.

- Cattaneo, L., & Macchi, M.** (2019). A digital twin proof of concept to support machine prognostics with low availability of run-to-failure data. *IFAC-PapersOnLine*, 52(10), 37-42.
- Chai, T., & Draxler, R. R.** (2014). Root mean square error (RMSE) or mean absolute error (MAE)? –Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- Chakshu, N. K., Carson, J., Sazonov, I., & Nithiarasu, P.** (2019). A semi-active human digital twin model for detecting severity of carotid stenoses from head vibration—A coupled computational mechanics and computer vision method. *International journal for numerical methods in biomedical engineering*, 35(5), e3180.
- Cherdantseva, Y., Burnap, P., Blyth, A., Eden, P., Jones, K., Soulsby, H., & Stoddart, K.** (2016). A review of cyber security risk assessment methods for SCADA systems. *Computers & security*, 56, 1-27.
- Choi, S. H., Park, K. B., Roh, D. H., Lee, J. Y., Mohammed, M., Ghasemi, Y., & Jeong, H.** (2022). An integrated mixed reality system for safety-aware human-robot collaboration using deep learning and digital twin generation. *Robotics and Computer-Integrated Manufacturing*, 73, 102258.
- Chui, L., Kamalnath, V., & McCarthy, B.** (2018). *An Executive's Guide to AI*, McKinsey.
- Coraddu, A., Oneto, L., Baldi, F., Cipollini, F., Atlar, M., & Savio, S.** (2019). Data-driven ship digital twin for estimating the speed loss caused by the marine fouling. *Ocean Engineering*, 186, 106063.
- Coronado, P. D. U., Lynn, R., Louhichi, W., Parto, M., Wescoat, E., & Kurfess, T.** (2018). Part data integration in the Shop Floor Digital Twin: Mobile and cloud technologies to enable a manufacturing execution system. *Journal of manufacturing systems*, 48, 25-33.
- Cunbo, Z., Liu, J., & Xiong, H.** (2018). Digital twin-based smart production management and control framework for the complex product assembly shop-floor. *The international journal of advanced manufacturing technology*, 96(1-4), 1149-1163.
- De Carolis, A., Macchi, M., Negri, E., & Terzi, S.** (2017, June). Guiding manufacturing companies towards digitalization a methodology for supporting manufacturing companies in defining their digitalization roadmap. In *2017 International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, IEEE, 487-495.
- Dündar, A., & Yıldız, A.** (2021). Analysis of the Use of Industry 4.0 Technologies in Firms: The Case of Bursa Province. *Electronic Letters on Science and Engineering*, 17(2), 105-116.
- Fang, X., Wang, H., Li, W., Liu, G., & Cai, B.** (2022). Fatigue crack growth prediction method for offshore platform based on digital twin. *Ocean Engineering*, 244, 110320.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P.** (1996). From data mining to knowledge discovery in databases. *AI magazine*, 17(3), 37-37.

- Feki, M. A., Kawsar, F., Boussard, M., & Trappeniers, L.** (2013). The internet of things: the next technological revolution. *Computer*, 46(2), 24-25.
- Fisher, D., DeLine, R., Czerwinski, M., & Drucker, S.** (2012). Interactions with big data analytics. *Interactions*, 19(3), 50-59.
- Gao, Y., Chang, D., Chen, C. H., & Xu, Z.** (2022). Design of digital twin applications in automated storage yard scheduling. *Advanced Engineering Informatics*, 51, 101477.
- Georgakopoulos, D., Jayaraman, P. P., Fazia, M., Villari, M., & Ranjan, R.** (2016). Internet of Things and edge cloud computing roadmap for manufacturing. *IEEE Cloud Computing*, 3(4), 66-73.
- Ghosh, A. K., Ullah, A. S., & Kubo, A.** (2019). Hidden Markov model-based digital twin construction for futuristic manufacturing systems. *AI EDAM*, 33(3), 317-331.
- Giusto, D., Iera, A., Morabito, G., & Atzori, L.** (Eds.). (2010). *The internet of things: 20th Tyrrhenian workshop on digital communications*. Springer Science & Business Media.
- Glaessgen, E., & Stargel, D.** (2012, April). The digital twin paradigm for future NASA and US Air Force vehicles. In *53rd AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics and materials conference*, 1818.
- Gockel, B., Tudor, A., Brandyberry, M., Penmetsa, R., & Tuegel, E.** (2012). Challenges with structural life forecasting using realistic mission profiles. In *53rd AIAA/ASME/ASCE/AHS/ASC structural dynamics and materials conference*, 1813.
- Granacher, J., Nguyen, T. V., Castro-Amoedo, R., & Maréchal, F.** (2022). Overcoming decision paralysis-A digital twin for decision making in energy system design. *Applied Energy*, 306, 117954.
- Grieves, M.** (2014). Digital twin: manufacturing excellence through virtual factory replication. *White paper*, 1, 1-7.
- Guivarch, D., Mermoz, E., Marino, Y., & Sartor, M.** (2019). Creation of helicopter dynamic systems digital twin using multibody simulations. *CIRP Annals*, 68(1), 133-136.
- Gujarati, D. N., Porter, D. C., Şenesen, Ü., & Günlük-Şenesen, G.** (2012). *Temel ekonometri*. Literatür Yayıncılık.
- Guo, J., Zhao, N., Sun, L., & Zhang, S.** (2019). Modular based flexible digital twin for factory design. *Journal of Ambient Intelligence and Humanized Computing*, 10(3), 1189-1200.
- Johnson, R., & Zhang, T.** (2013). Learning nonlinear functions using regularized greedy forest. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 36(5), 942-954.
- Kagermann, H., Wahlster, W., & Helbig, J.** (2013). Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group. *Forschungsunion*: Berlin, Germany.

- Karasu, S., Altan, A., Saraç, Z., & Hacıoğlu, R.** (2018, May). Prediction of Bitcoin prices with machine learning methods using time series data. *In 2018 26th signal processing and communications applications conference (SIU)*, IEEE, 1-4.
- Kavzoğlu, T., & EK, Ş.** (2012). Bulut bilişim teknolojisi ve bulut CBS uygulamaları. *IV. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS 2012)*, 19 Ekim 2012, Zonguldak.
- Khajavi, S. H., Motlagh, N. H., Jaribion, A., Werner, L. C., & Holmström, J.** (2019). Digital twin: vision, benefits, boundaries, and creation for buildings. *IEEE Access*, 7, 147406-147419.
- Kraft, E. M.** (2016). The air force digital thread/digital twin-life cycle integration and use of computational and experimental knowledge. *In 54th AIAA aerospace sciences meeting*, 0897.
- Kure, H. I., Islam, S., & Razzaque, M. A.** (2018). An integrated cyber security risk management approach for a cyber-physical system. *Applied Sciences*, 8(6), 898.
- Lari, K. S., Davis, G. B., & Rayner, J. L.** (2022). Towards a digital twin for characterising natural source zone depletion: A feasibility study based on the Bemidji site. *Water Research*, 208, 117853.
- Lee, J., Kao, H. A., & Yang, S.** (2014). Service innovation and smart analytics for industry 4.0 and big data environment. *Procedia Cirp*, 16, 3-8.
- Lee, J., Bagheri, B., & Kao, H. A.** (2014, July). Recent advances and trends of cyber-physical systems and big data analytics in industrial informatics. *In International proceeding of int conference on industrial informatics (INDIN)*, 1-6.
- Li, B. H., Zhang, L., & Chai, X.** (2014). Smart cloud manufacturing (cloud manufacturing 2.0)-a new paradigm and approach of smart manufacturing. *In ISPE CE*, 26.
- Liau, Y., Lee, H., & Ryu, K.** (2018, March). Digital Twin concept for smart injection molding. *In IOP Conference Series: Materials Science and Engineering*, 324(1), IOP Publishing, 012077.
- Liu, M., Fang, S., Dong, H., & Xu, C.** (2021). Review of digital twin about concepts, technologies, and industrial applications. *Journal of Manufacturing Systems*, 58, 346-361.
- Liu, Z., Chen, W., Zhang, C., Yang, C., & Cheng, Q.** (2021). Intelligent scheduling of a feature-process-machine tool supernetwork based on digital twin workshop. *Journal of manufacturing systems*, 58, 157-167.
- Luo, W., Hu, T., Ye, Y., Zhang, C., & Wei, Y.** (2020). A hybrid predictive maintenance approach for CNC machine tool driven by digital twin. *Robotics and Computer-Integrated Manufacturing*, 65, 101974.
- Lyman P, Varian H.** (2003). *How much information 2003?* Technical Report. Retrieved from: <http://www.sims.berkeley.edu/research/projects/how-much-info-2003/>.

- Magargle, R., Johnson, L., Mandloi, P., Davoudabadi, P., Kesarkar, O., Krishnaswamy, S., ... & Pitchaikani, A.** (2017, July). A simulation-based digital twin for model-driven health monitoring and predictive maintenance of an automotive braking system. *In Proceedings of the 12th International Modelica Conference*, Prague, Czech Republic, May 15-17, 132, 35-46.
- Marvell, S.** (2015). The real and present threat of a cyber breach demands real-time risk management. *Acuity Risk Management*, 26-27.
- Miraz, M. H., Ali, M., Excell, P. S., & Picking, R.** (2018). Internet of nano-things, things and everything: future growth trends. *Future Internet*, 10(8), 68.
- Mistry, P., Maes, P., & Chang, L.** (2009). WUW-wear Ur world: a wearable gestural interface. *In CHI'09 extended abstracts on Human factors in computing systems*, 4111-4116.
- Mourtzis, D., Doukas, M., & Bernidaki, D.** (2014). Simulation in manufacturing: Review and challenges. *Procedia Cirp*, 25, 213-229.
- Mukherjee, T., & DebRoy, T.** (2019). A digital twin for rapid qualification of 3D printed metallic components. *Applied Materials Today*, 14, 59-65.
- Ostertagova, E.** (2012). Modelling using polynomial regression. *Procedia Engineering*, 48, 500-506.
- Özbek, A., & Yildiz, A.** (2020). Digital supplier selection for a garment business using interval type-2 fuzzy topsis. *Textile and Apparel*, 30(1), 61-72.
- Pan, Y.** (2016). Heading toward artificial intelligence 2.0. *Engineering*, 2(4), 409-413.
- Peng, Y., Lu, T., Liu, J., Gao, Y., Guo, X., & Xie, F.** (2013, October). Cyber-physical system risk assessment. *In 2013 Ninth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, IEEE, 442-447.
- Porter, M. E., & Heppelmann, J. E.** (2015). How smart, connected products are transforming companies. *Harvard business review*, 93(10), 96-114.
- Poyarkov, A., Drutsa, A., Khalyavin, A., Gusev, G., & Serdyukov, P.** (2016, August). Boosted decision tree regression adjustment for variance reduction in online controlled experiments. *In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 235-244.
- Priyanka, E. B., Thangavel, S., Gao, X. Z., & Sivakumar, N. S.** (2021). Digital twin for oil pipeline risk estimation using prognostic and machine learning techniques. *Journal of Industrial Information Integration*, 100272.
- Qi, Q., & Tao, F.** (2018). Digital twin and big data towards smart manufacturing and industry 4.0: 360-degree comparison. *IEEE Access*, 6, 3585-3593.
- Qi, Q., Tao, F., Hu, T., Anwer, N., Liu, A., Wei, Y., ... & Nee, A. Y. C.** (2021). Enabling technologies and tools for digital twin. *Journal of Manufacturing Systems*, 58, 3-21.
- Qian, W., Guo, Y., Cui, K., Wu, P., Fang, W., & Liu, D.** (2021). Multidimensional Data Modeling and Model Validation for Digital Twin Workshop.

Journal of Computing and Information Science in Engineering, 21(3), 031005.

- Rawlings, J. O., Pantula, S. G., & Dickey, D. A.** (2001). *Applied regression analysis: a research tool*. Springer Science & Business Media.
- Ray, P. P.** (2016). Internet of robotic things: concept, technologies, and challenges. *IEEE Access*, 4, 9489-9500.
- Rosen, R., Von Wichert, G., Lo, G., & Bettenhausen, K. D.** (2015). About the importance of autonomy and digital twins for the future of manufacturing. *IFAC-PapersOnLine*, 48(3), 567-572.
- Russom, P.** (2011). Big data analytics. *TDWI Best Practices Report, Fourth Quarter*, 19(4), 1-34.
- Rustam, F., Reshi, A. A., Mehmood, A., Ullah, S., On, B. W., Aslam, W., & Choi, G. S.** (2020). COVID-19 future forecasting using supervised machine learning models. *IEEE Access*, 8, 101489-101499.
- Sayer, S., & Ülker, A.** (2014). Ürün yaşam döngüsü yönetimi. *Mühendis ve Makina*, 55(657), 65-72.
- Schleich, B., Anwer, N., Mathieu, L., & Wartzack, S.** (2017). Shaping the digital twin for design and production engineering. *CIRP Annals*, 66(1), 141-144.
- Schluse, M., & Rossmann, J.** (2016, October). From simulation to experimentable digital twins: Simulation-based development and operation of complex technical systems. In *2016 IEEE International Symposium on Systems Engineering (ISSE)*, IEEE, 1-6.
- Seshadri, B. R., & Krishnamurthy, T.** (2017). Structural health management of damaged aircraft structures using digital twin concept. In *25th AIAA/AHS Adaptive Structures Conference*, 1675.
- Sether, A.** (2016). Cloud computing benefits. Available at SSRN 2781593, <http://dx.doi.org/10.2139/ssrn.2781593>.
- Shim, C. S., Dang, N. S., Lon, S., & Jeon, C. H.** (2019). Development of a bridge maintenance system for prestressed concrete bridges using 3D digital twin model. *Structure and Infrastructure Engineering*, 15(10), 1319-1332.
- Sipsas, K., Alexopoulos, K., Xanthakis, V., & Chryssolouris, G.** (2016). Collaborative maintenance in flow-line manufacturing environments: An Industry 4.0 approach. *Procedia Cirp*, 55, 236-241.
- Smith, I. G.** (2012). *The Internet of Things: New Horizon*. Halifax, U.K.: IERC-Internet of Things European Research Cluster.
- Suljagic, H., & Çelebi, N.** (2021). Düşük maliyetli bir robot kolunun dijital ikizinin elde edilmesi. 6. *Uluslararası Öğrenci Sempozyumu Bildiriler Kitabı 1-Mühendislik Bilimleri*, 118-126.
- Tao, F., & Zhang, M.** (2017). Digital twin shop-floor: a new shop-floor paradigm towards smart manufacturing. *IEEE Access*, 5, 20418-20427.

- Tao, F., Sui, F., Liu, A., Qi, Q., Zhang, M., Song, B., ... & Nee, A. Y.** (2019). Digital twin-driven product design framework. *International Journal of Production Research*, 57(12), 3935-3953.
- Tao, F., & Qi, Q.** (2019). Make more digital twins. *Nature*, 573, 490-491.
- Talu, M., & Talu, Ş.** (2018). Optimal engineering design of a pressurized paralepipedic fuel tank. *Annals of Faculty of Engineering Hunedoara-International Journal of Engineering*, Hunedoara, Romania, 16, 193-200.
- Teich, P.** (2014). *Segmenting the Internet of Things (IoT); White Paper*. Moor Insights & Strategy: Austin, TX, USA.
- Tsai, C. W., Lai, C. F., Chao, H. C., & Vasilakos, A. V.** (2015). Big data analytics: a survey. *Journal of Big Data*, 2(1), 1-32.
- Tuegel, E. J., Ingraffea, A. R., Eason, T. G., & Spottswood, S. M.** (2011). Reengineering aircraft structural life prediction using a digital twin. *International Journal of Aerospace Engineering*, 154798, doi:10.1155/2011/154798.
- Tuegel, E.** (2012, April). The airframe digital twin: some challenges to realization. In *53rd AIAA/ASME/ASCE/AHS/ASC structures, structural dynamics and materials conference*, 23 - 26 April, Honolulu, Hawaii 1812.
- Um, J., Weyer, S., & Quint, F.** (2017). Plug-and-Simulate within modular assembly line enabled by digital twins and the use of automationML. *IFAC-PapersOnLine*, 50(1), 15904-15909.
- Ustundag, A., & Cevikcan, E.** (2017). *Industry 4.0: managing the digital transformation*. Springer.
- Vaidya, S., Ambad, P., & Bhosle, S.** (2018). Industry 4.0—a glimpse. *Procedia Manufacturing*, 20, 233-238.
- Vathoopan, M., Johny, M., Zoitl, A., & Knoll, A.** (2018). Modular fault ascription and corrective maintenance using a digital twin. *IFAC-PapersOnLine*, 51(11), 1041-1046.
- Wang, K. J., Lee, Y. H., & Angelica, S.** (2021). Digital twin design for real-time monitoring—a case study of die cutting machine. *International Journal of Production Research*, 59(21), 6471-6485.
- Wang, L.** (2019). From intelligence science to intelligent manufacturing. *Engineering*, 5(4), 615-618.
- Wang, W., & Xu, Z.** (2004). A heuristic training for support vector regression. *Neurocomputing*, 61, 259-275.
- Wang, Z., Feng, W., Ye, J., Yang, J., & Liu, C.** (2021). A study on intelligent manufacturing industrial internet for injection molding industry based on digital twin. *Complexity*, 8838914, <https://doi.org/10.1155/2021/8838914>.
- White, G., Zink, A., Codecá, L., & Clarke, S.** (2021). A digital twin smart city for citizen feedback. *Cities*, 110, 103064.

- Wu, W., Kang, R., & Li, Z.** (2015, October). Risk assessment method for cyber security of cyber physical systems. *In 2015 First International Conference on Reliability Systems Engineering (ICRSE)*, IEEE, 1-5.
- Xu, R., & Wunsch, D. C.** (2009). *II, Clustering*. Hoboken, NJ: Wiley/IEEE Press, 6, 583-617.
- Yang, X., Ran, Y., Zhang, G., Wang, H., Mu, Z., & Zhi, S.** (2022). A digital twin-driven hybrid approach for the prediction of performance degradation in transmission unit of CNC machine tool. *Robotics and Computer-Integrated Manufacturing*, 73, 102230.
- Yıldız, A.** (2018). Endüstri 4.0 ve akıllı fabrikalar. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(2), 546-556.
- Yılmaz, M., Şahin, H., & Yıldız, A.** (2021). Sectoral application analysis of studies made with deep learning models. *Electronic Letters on Science and Engineering*, 17(2), 126-140.
- Yi, Y., Yan, Y., Liu, X., Ni, Z., Feng, J., & Liu, J.** (2021). Digital twin-based smart assembly process design and application framework for complex products and its case study. *Journal of Manufacturing Systems*, 58, 94-107.
- Zhang, H., Liu, Q., Chen, X., Zhang, D., & Leng, J.** (2017). A digital twin-based approach for designing and multi-objective optimization of hollow glass production line. *IEEE Access*, 5, 26901-26911.
- Zhang, K., Qu, T., Zhou, D., Jiang, H., Lin, Y., Li, P., ... & Huang, G. Q.** (2020). Digital twin-based opti-state control method for a synchronized production operation system. *Robotics and Computer-Integrated Manufacturing*, 63, 101892.
- Zheng, Y., Yang, S., & Cheng, H.** (2019). An application framework of digital twin and its case study. *Journal of Ambient Intelligence and Humanized Computing*, 10(3), 1141-1153.
- Zhu, Z., Liu, C., & Xu, X.** (2019). Visualisation of the digital twin data in manufacturing by using augmented reality. *Procedia Cirp*, 81, 898-903.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı SOYADI : Aysel KOÇAK

ÖĞRENİM DURUMU

<u>Derece</u>	<u>Alan</u>	<u>Üniversite adı</u>	<u>Mezuniyet Yılı</u>
Lisans	Endüstri Mühendisliği	Uludağ Üniversitesi	2018
Çift Anadal	Tekstil Mühendisliği	Uludağ Üniversitesi	2019

MESLEKİ DENEYİM VE ÖDÜLLER

Bizim Toptan Satış Mağazaları: 09.2021 – Devam ediyor

LC Waikiki: 05.2019 – 09.2021

Güncel Yazılım: 12.2018 – 05.2019

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER

Karagöz, A. ve Yıldız, A. (2019). Dijital ikiz teknolojisinin üretim ve tasarım sistemlerinde kullanılması. 5. *Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi*, 21-22 Aralık, İstanbul, Türkiye.

DİĞER ESERLER, SUNUMLAR VE PATENTLER

Yıldız, A. ve Karagöz, A. (2019). Yeni ürün geliştirme performansının ahp temelli gri ilişkisel analiz yöntemiyle değerlendirilmesi, 5. *Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi*, 21-22 Aralık, İstanbul, Türkiye.