



**T.C.**

**ALANYA ALAADDİN KEKUBAT ÜNİVERSİTESİ**

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNLENME DEMİR -  
ÇELİK SEKTÖRÜNDE BİR UYGULAMA**

**Yüksek Lisans Tezi**

**Nurselin SÜLLÜ**

**Danışman  
Dr. Öğretim Üyesi Atıl Kurt**

**ALANYA  
2024**



T.C.  
ALANYA ALAADDİN KEYKUBAT ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNLENME DEMİR -  
ÇELİK SEKTÖRÜNDE BİR UYGULAMA

Yüksek Lisans Tezi

Nurselin Süllü

Anabilim Dalı: Endüstri Mühendisliği Anabilim Dalı

Program Adı: Endüstri Mühendisliği Tezli Yüksek Lisans Programı

Danışman

Dr. Öğr. Üyesi Atıl Kurt

ALANYA

(2024)

## ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilemeyen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmamın Alanya Alaaddin Keykubat Üniversitesi tarafından kullanılan “bilimsel intihal tespit programıyla tarandığını ve “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm.

Nurselin SÜLLÜ

## TEŐEKKÜR SAYFASI

Yüksek lisans bitirme tezi çalışmalarım boyunca her daim yönlendirici fikirleri ile desteklerini esirgemeyen danışman hocam Sayın Dr. Öğr. Üyesi Atıl KURT'a ve değerli katkıları adına jüri üyeleri hocalarıma teşekkürlerimi sunarım.

Çalışma kapsamında elde edilen verilerin temininde yardımlarını sunan değerli yöneticilerim, çalışma arkadaşlarıma ve Ahmet ERDEN'e teşekkürü bir borç bilirim.

Çalışma sürecimin tamamında yanımda olan, bana olan inançlarıyla destek veren, sevgili aileme ve arkadaşlarıma teşekkürlerimi sunuyorum.



## ÖZET

### MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİNLENME – DEMİR ÇELİK SEKTÖRÜNDE BİR UYGULAMA

Nurselin SÜLLÜ

Endüstri Mühendisliği Anabilim Dalı

Alanya Alaaddin Keykubat Üniversitesi, Lisansüstü Eğitim Enstitüsü,

Kasım, 2024 (82 Sayfa)

Firmalar, mevcut personeli elde tutmanın maliyetinin yeni bir personelin işe alınmasının maliyetinden daha düşük olduğundan, iş gören devir oranının düşük olmasını hedeflemektedir. Demir çelik sektörünün zorlu çalışma koşullarına sahip olmasından ötürü işten ayrılışların fazla olduğu göz önünde bulundurularak makine öğrenmesi algoritmaları kullanılmış ve işten ayrılma olasılığı bulunan personellerin tahminlenmesi amaçlanmıştır. Çalışmada, makine öğrenmesi algoritmaları, Knime ve Python programlama dili üzerinden uygulanmıştır. Veri seti, yaklaşık 16 yıllık süreçte, 2318 kişiye ait veriden ve 14 farklı nitelikten oluşmaktadır. Nitelikler, personellerin istifa etmesinde etkisi olduğu düşünülen özelliklerden seçilmiştir. Beş farklı makine öğrenmesi algoritması uygulanmış ve Knime uygulamasında %78,40 ve Python programlama dilinde %76,88 doğruluk oranı ile en başarılı tahminleme yapan, Rastgele Orman Algoritması olduğu gözlemlenmiştir. Rastgele Orman Algoritmasına göre işten ayrılmadaki en önemli nitelik sıralaması yapılarak, en önemli kriterlerin yaş ve kıdem olduğu görülmüştür. Rastgele Orman Algoritması ile Karar Ağacı üzerinden örnek elde edebilmek için varsayım yapılarak niteliklere değer verilmiş ve işten ayrılma potansiyelinin olup olmadığı değerlendirilmiştir. Bu çalışma sonucunda mevcut personelin işten ayrılma potansiyelinin olup olmadığı, işe alımda hangi kriterlere öncelik verilmesi gerektiği ve personelin işe devamlılığın sağlanması için alınması gereken aksiyon kararlarının verilmesi sağlanacaktır.

**Anahtar Sözcükler:** Yapay Zeka, Makine Öğrenmesi, İnsan Kaynakları, Personel Tutundurma, İşten Ayrılma Tahminlenmesi

## ABSTRACT

### PREDICTION WITH MACHINE LEARNING METHODS – AN APPLICATION IN THE IRON AND STEEL INDUSTRY

Nurselin SÜLLÜ

Department of Industrial Engineering

Graduate School of Alanya Alaaddin Keykubat University,

November, 2024

Firms aim to have a low turnover rate since the cost of retaining existing staff is lower than the cost of hiring a new employee. Considering that the iron and steel industry has a high turnover rate due to the tough working conditions. In this study, machine learning algorithms were used and it was aimed to predict the personnel who are likely to leave the job. Moreover, machine learning algorithms were implemented using Knime and Python programming language. The dataset consists of 2318 rows, each corresponding to one employee, and 14 different attributes over a period of approximately 16 years. The attributes were selected from the attributes that are thought to have an impact on the resignation of employees. Five different machine learning algorithms were applied, and it was observed that the Random Forest Algorithm provide most successful results with an accuracy rate of 78.40% in Knime and 76.88% in Python programming language. According to the Random Forest Algorithm, age and seniority are the most important criteria by ranking the most important qualifications for leaving a job. With the Random Forest Algorithm, the attributes were valued by making assumptions and it was evaluated whether the considered personnel had the potential to leave the job. As a result of this study, it was determined whether the existing staff has the potential to leave the job, which criteria should be prioritized in recruitment, and which measures should be taken to ensure the continuity of the staff.

**Keywords:** Artificial Intelligence, Machine Learning, Human Resources, Employee Retention, Turnover Prediction

## İÇİNDEKİLER

İÇ KAPAK SAYFASI	
JÜRİ VE ENSTİTÜ ONAYI .....	i
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ .....	ii
TEŞEKKÜR SAYFASI.....	iii
ÖZET .....	iv
ABSTRACT .....	v
İÇİNDEKİLER .....	vi
ŞEKİLLER LİSTESİ .....	viii
TABLolar LİSTESİ.....	x
SİMGELER ve KISALTMALAR LİSTESİ.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR .....	3
3. YÖNTEM .....	11
3.1. İnsan Kaynakları Yönetimi .....	11
3.1.1. İnsan kaynakları yönetimi tanımı .....	11
3.1.2. İnsan kaynakları gelişimi .....	12
3.1.3. İnsan kaynakları amaçları .....	15
3.1.4. İnsan kaynakları stratejileri.....	16
3.1.5. İnsan kaynakları fonksiyonları.....	17
3.2. Yapay Zeka .....	19
3.2.1. Yapay zeka tanımı .....	19
3.2.2. Yapay zeka tarihçesi .....	20
3.2.3. Yapay zekanın geleceği .....	21
3.2.4. Yapay zeka uygulamaları.....	21
3.2.5. Makine öğrenmesi.....	23
3.2.6. Makine öğrenmesi kavramının tarihsel süreci .....	25
3.2.7. Makine öğrenmesi türleri.....	26
3.2.7.1. Denetimli öğrenme .....	29
3.2.7.2. Denetimsiz öğrenme .....	31
3.2.7.3. Pekiştirmeli öğrenme .....	32

3.2.8. Makine öğrenmesi algoritmaları .....	33
3.2.8.1. Rastgele orman algoritması .....	33
3.2.8.2. Naive bayes algoritması .....	35
3.2.8.3. Karar ağacı algoritması .....	36
3.2.8.4. Destek vektör makineleri algoritması .....	37
3.2.8.5. K-en yakın komşu algoritması .....	38
3.3. İnsan Kaynaklarında Yapay Zeka .....	39
3.3.1. İnsan kaynaklarında yapay zeka uygulamaları .....	40
3.3.2. İnsan kaynaklarında yapay zekanın avantajları ve dezavantajları .....	41
4. BULGULAR .....	42
4.1. Demir-Çelik Sektöründe Uygulama .....	42
4.1.1. Verilerin tanımlanması .....	42
4.1.2. Kullanılacak programların belirlenmesi .....	46
4.1.3. Verilerin değerlendirilmesi .....	47
4.1.4. Algoritmaların uygulanması .....	54
4.1.4.1. Rastgele orman algoritma uygulaması .....	58
4.1.4.2. Naive bayes algoritma uygulaması .....	61
4.1.4.3. Karar ağacı algoritması uygulaması .....	62
4.1.4.4. Destek vektör makineleri algoritması uygulaması .....	64
4.1.4.5. K-en yakın komşu algoritması uygulaması .....	65
4.1.5. Kullanılan algoritmaların karşılaştırılması .....	67
4.1.6. Tahminlemelerin gerçekleştirilmesi .....	70
5. TARTIŞMA, SONUÇ VE ÖNERİLER .....	75
6. KAYNAKLAR .....	77
ÖZGEÇMİŞ .....	82

## ŞEKİLLER LİSTESİ

Şekil 3.1 İnsan kaynakları yönetimi kavramı zaman içerisindeki değişimi .....	13
Şekil 3.2 Yapay zekada makine öğrenmesinin yeri.....	25
Şekil 3.3 Makine öğrenmesi tarihsel süreci.....	26
Şekil 3.4 Makine öğrenmesi çeşitleri .....	28
Şekil 3.5 Makine öğrenmesi aşamaları.....	28
Şekil 3.6 Denetimli makine öğrenmesi aşamaları .....	29
Şekil 3.7 Sınıflandırma yaklaşımı .....	30
Şekil 3.8 Denetimsiz öğrenme modellemesi .....	32
Şekil 3.9 Pekiştirmeli öğrenme yapısı .....	33
Şekil 3.10 Rastgele orman algoritması .....	34
Şekil 3.11 Karar ağacı algoritması .....	36
Şekil 3.12 Destek vektör makineleri.....	37
Şekil 3.13 K-en yakın komşu algoritması .....	39
Şekil 4.1 Verilerin nokta grafiği .....	48
Şekil 4.2 Matrix grafiği .....	48
Şekil 4.3 İstifa etme durumu histogram grafiği.....	52
Şekil 4.4 Maaş düzeyine göre istifa eden ve etmeyen dağılımı.....	52
Şekil 4.5 Kıdem seviyesine göre istifa eden ve etmeyen kutu dağılımı .....	53
Şekil 4.6 Yaş değişkenine göre istifa eden ve etmeyen kutu dağılımı .....	53
Şekil 4.7 Korelasyon analizi.....	54
Şekil 4.8 Knime rastgele orman algoritması .....	58
Şekil 4.9 Knime rastgele orman algoritması sınıflandırıcı .....	59
Şekil 4.10 Knime rastgele orman algoritması öğrenme seti.....	59
Şekil 4.11 Knime rastgele orman algoritması tahminleme.....	60
Şekil 4.12 Knime rastgele orman algoritması tahminleme örnekleri .....	60
Şekil 4.13 Knime rastgele orman algoritması tahminleme skor düğümü.....	61
Şekil 4.14 Knime naive bayes algoritması .....	62
Şekil 4.15 Knime karar ağacı algoritması .....	62
Şekil 4.16 Knime karar ağacı algoritması veri seti ayrıştırma alternatifi.....	63
Şekil 4.17 Knime karar ağacı algoritması modeli .....	63
Şekil 4.18 Knime destek vektör makineleri algoritması.....	65
Şekil 4.19 Knime K-en yakın komşu algoritması.....	66

<b>Şekil 4.20</b> Knime K-en yakın komşu algoritması k değeri belirleme k = 3 .....	66
<b>Şekil 4.21</b> KNN algoritması n sayısına göre doğruluk değışimi .....	67
<b>Şekil 4.22</b> Knime rastgele orman algoritması karar ağacı gösterimi.....	71
<b>Şekil 4.23</b> Knime rastgele orman algoritması karar ağacı gösterimi-2 .....	72



## TABLULAR LİSTESİ

<b>Tablo 2.1</b> Yapay zeka uygulamaları.....	5
<b>Tablo 3.1</b> Personel yönetimi ile insan kaynakları yönetimi arasındaki farklılıklar .....	13
<b>Tablo 3.2</b> İnsan kaynakları gelişim aşamaları.....	14
<b>Tablo 3.3</b> İnsan kaynakları stratejileri.....	16
<b>Tablo 3.4</b> İnsan kaynakları fonksiyonları.....	17
<b>Tablo 3.5</b> Yapay zeka gelişimi.....	20
<b>Tablo 3.6</b> İnsan kaynaklarında yapay zekanın avantaj ve dezavantajları .....	41
<b>Tablo 4.1</b> Veri seti örneği.....	45
<b>Tablo 4.2</b> Knime verilerin tablolaştırılması .....	49
<b>Tablo 4.3</b> Knime verilerin tablolaştırılması-2.....	50
<b>Tablo 4.4</b> Karışıklık matrisi .....	56
<b>Tablo 4.5</b> Tahminleme performans ölçümleri.....	56
<b>Tablo 4.5</b> Tahminleme performans ölçümleri (Devamı) .....	57
<b>Tablo 4.6</b> Cohen kappa ve ayırt edilebilirlik katsayısı.....	57
<b>Tablo 4.7</b> Knime programında doğru veri sınıflandırma karşılaştırılması.....	68
<b>Tablo 4.8</b> Knime programında algoritmaların karşılaştırılması .....	68
<b>Tablo 4.9</b> Python programında algoritmaların karşılaştırılması .....	69
<b>Tablo 4.10</b> Algoritmaların başarı ölçütlerine göre karşılaştırılması .....	69
<b>Tablo 4.11</b> Tahminleme örneği .....	70
<b>Tablo 4.12</b> Tahminleme örneği çıktısı .....	70
<b>Tablo 4.13</b> Karar ağacı ayırıştırma kriteri ve önerileri.....	73

## SİMGELER ve KISALTMALAR LİSTESİ

### Kısaltmalar

İK	İnsan Kaynakları
İKY	İnsan kaynakları yönetimi
İSG	İş Sağlığı ve Güvenliği
EWS	Erken Uyarı Sistemi (Early Warning System)
IBM	Uluslararası İş Makineleri (International Business Machines)
LogReg	Lojistik regresyon (Logistic Regression)
RF	Rastgele orman (Random Forest)
KA	Karar Ağacı (Decision Tree)
NB	Naive Bayes (Bernoulli Naive Bayes)
K-NN	K-En Yakın Komşu (K Neighbors)
DVM	Destek Vektör Makineleri (Support Vector Machines)

## 1. GİRİŞ

İşletmelerde iş görenlerin ihtiyaçlarına karşılık verme ve ücret, izin, işe alım gibi süreçlerin tek bir birimden yürütülmesi amacıyla personel yönetimi ortaya çıkmıştır. Ancak zaman içerisinde faaliyetlerin artması ve kapsamlı olması nedeniyle insan kaynakları yönetimi adıyla anılmaya başlanmıştır. İnsan kaynakları yönetimi, personel yönetimine kıyasla yürütülen faaliyetler açısından daha kapsamlıdır (Tiftik, 2021). İnsan kaynakları anlayışının merkezinde insan faktörü bulunduğundan, insana değer verme, çalışanları motive etme ve çalışanı tutundurma faaliyetleri önem taşımaktadır. Bu çalışmada da makine öğrenimi uygulamaları insan kaynakları faaliyetlerinden olan çalışan tutundurma üzerinde değerlendirmeler yapılmıştır.

İnsan kaynakları yönetimi makro ölçekte, çalışanların bilgi birikimine sahip olması ve kurumların pazarda rekabet edebilmeleri için oluşturdukları planda insanı baş unsur olarak gösterilmesi gerektiğine dayanmaktadır. Mikro ölçekte ise, kurum içi organizasyonda uyum ve yeteneklerin yönetilmesi ile açıklanmaktadır (Ceylan, 2023).

Demir çelik sektöründe yer alan işletmelerin nitelikli personel ihtiyacına sahip olmasından kaynaklı işe alım süreçleri uzun soluklu olmakta ve yetenekli ve bilgi birikimine sahip olan mevcuttaki personellerin kaybedilmemesi konusu önem taşımaktadır. Personel kaybı yaşanması sahadaki işlerin aksamasına, çalışanların iş yükünün artmasına ve mesaili çalışma düzenine geçilmesine neden olmaktadır. Tüm bu sorunlar ile karşılaşmamak adına ve iş gören devir oranının düşük olması hedeflendiğinden mevcut personellerin tutundurulması adına çalışmalar yapılması gerekliliği oluşmuştur. Bu çalışmada, demir çelik sektöründe yer alan büyük ölçekteki şirketin mevcut ve geçmiş personellerinin nitelikleri ele alınmış ve makine öğrenmesi algoritmaları kullanılarak çalışanların işten ayrılma niyetinin olup olmayacağına dair tahminlemeler gerçekleştirilmiştir.

Araştırmalar incelendiğinde makine öğrenmesinin, yapay zekanın bir alt dalı olarak tanımlandığı görülmektedir. Makine öğrenmesi, verilerin belirli bir probleme uygun olarak modellenmesine yarayan algoritmalarıdır. Makine öğrenmesinin probleme özgü olması daha etkili sonuçlar vermesini sağladığı için çeşitli metotlar geliştirilmiştir.

Çalışma uygulama kapsamında ise yöntem olarak yapay zekanın alt dallarından birisi olan makine öğrenmesi uygulanmıştır. Firmadan alınan gerçek veriler üzerinde çalışılmış ve elde edilen ham veri seti eğitim seti ve test seti olarak ayrılmıştır.

Personellerin işten ayrılma üzerinde etkisi bulunabileceği tahminlenen nitelikler ele alınmış ve bu nitelikler girdi özelliği taşımıştır. Tahminlemedeki çıktı ise işten ayrıldı ya da ayrılmadı şeklinde değerlendirilmiştir. Kullanımı, değerlendirmesi ve başarı oranları göz önüne alınarak Python ve paket program olan Knime kullanılmıştır. Her iki platformda da Rastgele (Rassal) Orman, Naive Bayes, Karar Ağacı, Destek Vektör Makineleri ve K-En Yakın Komşu algoritmaları üzerinde veri seti üzerinden tahminlemeler gerçekleştirilmiş ve karşılaştırmalar yapılarak en iyi tahminlemede bulunan algoritma tespiti gerçekleştirilmiştir.

Çalışmanın özgün değeri, yapay zeka uygulamalarının araştırmalarda genellikle teorik olmasına rağmen bu çalışmada ele alınan problem uygulamalar ile de hayata geçirilmesidir. Aynı zamanda çalışmanın detaylı incelemesi yapıldığında uygulama adımları ile gelecekteki projeler için de yol gösterici niteliği taşıyabilecektir. İnsan kaynakları alanında makine öğrenmesi uygulamaları zaman içerisinde kuruluşlar tarafından kullanılmaya başlanmıştır ancak Türkçe yayın kapsamında insan kaynakları ve yapay zeka konusunda uygulamalı araştırmalar sınırlı sayıdadır. Tüm bu faktörler göz önüne alındığında araştırma, ülkemizdeki insan kaynakları alanında makine öğrenmesi algoritmalarının uygulanması konusunda özgün değere sahiptir.

Çalışma kapsamında, insan kaynakları yönetimi, yapay zeka ve makine öğrenmesi hakkında detaylar verilecektir. Ardından insan kaynaklarında yapay zeka uygulamaları örneklendirilmiş, avantaj ve dezavantajlarından bahsedilmiştir. Demir çelik sektöründeki problem ve firmadan elde edilen veriler tanımlanmıştır. Problem, Knime ve Python ile değerlendirilmiş ve tahminlemeler gerçekleştirilmiştir ve karşılaştırmalar yapılmıştır. Çalışmanın son kısmında ise sonuçlar yorumlanmış ve önerilerde bulunulmuştur. Araştırma ile ilgili genel bilgiler giriş kısmında söz edilmiş, bundan sonraki bölümde ise insan kaynaklarında yapay zeka uygulamaları gerçekleştirilen araştırmalar hakkında bilgilere yer verilecektir.

## 2. LİTERATÜR

Bu kısımda insan kaynaklarında yapay zeka ve çalışmanın konusu olan işten ayrılma durumunun yapay zeka uygulamaları ile tahminlenmesi alanlarında literatürde yer alan benzer araştırmalar incelenmiştir.

Çalışma kapsamında literatürdeki araştırmalar incelenerek son yıllarda bilgi ve iletişim teknolojilerinin gelişmesiyle birlikte sektörde ve departmanlarda yapay zeka uygulamalarının artmasına rağmen insan kaynaklarında beklenen gelişme olmadığı çıkarımı yapılmıştır. Yapay zekanın insan kaynakları üzerindeki araştırma sayılarının yıllar içerisindeki değişimi incelenmiş ve en büyük yükselişin 2018'de gerçekleştiği belirtilmiştir. İnsan kaynaklarında yapay zeka uygulaması, eğitim, geliştirme, personel rotasyonu gibi işlevlerin yanı sıra personel alımı ve seçimi gibi uygulamalarda da odaklanılmıştır. Çalışmada, firmalar tarafından yeteneğin yalnızca bulunmasının değil korunması ve geliştirilmesi gerektiğinin de unutulmaması gerektiği belirtilmiştir (Palos-Sánchez vd., 2022).

Araştırmada, literatür taraması doğrultusunda insan kaynakları yaşam döngüsü altı boyutla sınıflandırıldığı belirtilmiştir. Araştırmacılar bu çalışma kapsamında, yasal ve etik sorunlar başlığı altında yedinci bir boyutun daha olduğunu belirleyerek İK yaşam döngüsüne entegre etmişlerdir. Boyutlarda yapay zekanın kullanımı; stratejik planlamada; finansal, piyasa, performans gibi verilerin analiz edilerek maliyet tasarrufu sağlanması, işe alım ve görevlendirmede; başvuruların objektif ve tarafsız değerlendirilerek zaman tasarrufunun sağlanması, eğitim ve gelişimde; sunum otomasyonu ile eğitimlerin kişiselleştirilmesi, performans yönetiminde; çalışan performansının otomatik olarak izlenmesi ile geri bildirimlerin zamanında verilmesi, ücret yönetiminde; büyük çalışan veri kümelerinin analiz edilerek ücret memnuniyetinin sağlanması, insan ilişkileri yönetiminde; müzakere stratejilerinin geliştirilerek büyük veri kümelerinin incelenmesi sayesinde İK hizmetlerinin kişiselleştirilmesi, yasal ve etik sorunlarda; karar almaya yardımcı olmak için nesnel ve tarafsız veri analizi ile adalet algısının artmasının sağlandığı belirtilmiştir (Gélinas vd., 2022).

Çalışma kapsamında 2004-2022 yılları arasında 100'den fazla yapay zeka araştırması incelenerek gerçekleştirilmiş ve bu araştırmalar üzerinde analiz sonuçlarına göre değerlendirmeler yapılmıştır. Araştırmalarda genellikle yapay zekaya önyargı ve ayrımcılığın önüne geçtiği, adalet ve kararlara güven duyulurken gizlilik endişelerini de beraberinde getirdiğinden bahsedilmiştir. Araştırmacılar, yapay zekanın geçmiş verilere

dayanarak tahmin ve analiz yaptığından sonuçlara bakılırken adaletin tamamen sağlanamadığının farkında olunması gerektiğini, teknolojiye fazla güvenin maliyetleri de beraberinde getirdiğini ve eşitlik, çeşitlilik ve kapsayıcılık konularına önem vermeleri gerektiğini vurgulamıştır (Bujold vd., 2024).

Çalışmada insan kaynakları alanında yapay zeka uygulamalarının gelişimini inceleme amaçlanmıştır. Literatürde yapılan araştırmalar incelendiğinde, genellikle ekip tahmini, işe alma ve seçim, istihdam edilebilirlik, aday seçimi, işten ayrılma, İK performansı, kurumsal eğitim ve gelişim, yönetim yeterliliği, işyeri yaşam kalitesi konularında yapay zeka uygulamalarının ele alındığı görülmüştür. En sık ele alınan konunun işe alma ve personel seçimi olduğundan bahsedilmiştir. 2000 ile 2018 yılları arasındaki araştırmalar 2009-2010 yıllarında artış gösterdikten sonraki altı yıl boyunca düşük seyrederken 2017 ve 2018 yıllarında gözle görülür artıştan bahsedilmiştir (Jatoba vd., 2019).

Araştırmacılar inceledikleri literatür çalışmalarında nedensel değişkenlerden; doğruluk, otomasyon, gerçek zamanlı deneyimin sonuç değişkeni, hesaplama gücü ve kapasitesi, kişiselleştirme, zaman tasarrufu, maliyet azaltma olmak üzere yedi olası sonuç çıkarımı elde ederek ilişkiyi araştırmıştır. Araştırmalar sonucunda beş olası yapay zeka sonuç değişkenine karşı iyimser yaklaşırken, hesaplama gücü ve kapasitesi ve kişiselleştirme konularının zaman ve maliyet açısından tasarruf sağlayıp sağlamayacağı konusunda bir kanıya varamadıklarını belirtmiştir. Genel olarak ise firmalarda insan kaynaklarının, çalışanları insan-makine iş birliğinin sağlanması konusunda teşvik etmesi ve bilgi teknolojileri ile el ele verilmesinin yapay zeka teknolojilerinin insan kaynakları uygulamalarına daha hızlı ve kolay şekilde entegre edilmesini sağlayacağı belirtilmiştir (Nawaz vd., 2024).

Çalışmada, yapay zekanın hem kuruluşlar hem de İKY üzerindeki etkilerini inceleyen araştırmalar konu edinmiştir. Gelecekte iş performansını arttırmada, piyasanın belirsizliği ve değişkenliğine dinamik olarak uyum sağlayabilme adına hibrit işgücü oluşturma ve organizasyonlar içinde de stratejilerin ve yeteneklerin geliştirilmesini kolaylaştıracağı belirtilmiştir. Kuruluşlar içindeki yapay zeka vb. yenilikler çalışanlarının değişimi, yeniliği benimsemesi, kolay ve hızlı uyum sağlama ve gelişme motivasyonu ve paylaşımcı kültür gibi özellikler sağlamasına yardımcı olabileceği savunulmuştur. Yapay zeka ile sağlanan veri analitiği ile çıktı yanıtlarını anlama kabiliyeti, iş operasyonlarında karar alma süreçlerindeki önyargıları azaltmakta ve adalet hissini de arttıracaktır çıkarımı yapılmıştır. Son olarak, yalnızca yapay zekanın iş sorunlarına tek başına bir çözüm

olamayacağı, İK organizasyonu tarafından benimsenmesi gerektiği ve kaynakları doğru yönetebilen stratejilerin izlenmesi gerektiği sonuçlarına ulaşılmıştır (Chowdhury vd., 2023).

İnsan kaynakları fonksiyonlarında yapay zeka tabanlı uygulamalarının olgusu ele alınan bu çalışmada, 186 insan kaynakları profesyonelleri ile çevrimiçi anket yöntemi kullanılarak uygulama gerçekleştirilmiştir. Yapılarda; benimseme faktörlerinde, üst yönetim desteği, rekabetçi baskı, davranışsal niyet ve performans beklentisi, İK rollerinde ise, stratejik ortak, çalışan şampiyonu, idari uzman ve değişim temsilcisi değişkenleri 'Likert ölçeği' kullanılarak kovaryans tabanlı yapısal eşitlik modelleme tekniği ile deneysel olarak test edilmiştir. Sonuçlar, üst yönetim desteği ve performans beklentisinin yapay zeka benimseme niyetinin önemli öngörücüleri olduğu, rekabet baskısının ise böyle bir niyetle önemli bir ilişkisinin olmadığını ortaya koymuştur (Hmoud, 2021).

Araştırmada, Bahreyn Krallığı'nda yer alan Zain Telekom adlı şirketinden elde edilen verilerle yapay zeka ile işe alım süreci incelenmiştir. Açık bir pozisyon için başvuran aday sayısının zaman içerisinde gözle görülür artışın, aday inceleme ve seçme süreçlerini zorlaştırdığı ve süreci uzattığı belirtilmiştir. Çalışmada görüş bildiren uzmanların fikirlerinin birliği ile; maliyetleri azaltabileceği, işe alım süreçlerinin daha hızlı ve verimli olabileceği, tekrarlayan işlerin otomatikleştirilerek zaman tasarrufu sağlayabileceği bu sayede İK profesyonellerinin yaratıcılık ve eleştirel düşünme ile ilgili işlere daha fazla zaman ayırabileceği gibi sonuçlar elde edilmiştir (Aldulaimi vd., 2021).

Yapay zeka uygulamaları konularındaki Türkiye'de yapılan araştırmalar Tablo 2.1'de özetlenerek gösterilmiştir. Tablodaki araştırmalarda genel anlamda teorik olarak yapay zekanın uygulamaları ve insan kaynakları yönetimi faaliyetlerinin yapay zekadaki yerini konu edinen çalışmalar incelenmiştir.

**Tablo 2.1** Yapay zeka uygulamaları

Kahraman, (2023)	Endüstri 4.0 ile bütünleşik dijitalleşme ve yapay zeka uygulamaları destek olduğundan bahsedilmiştir. Yapay zeka ile büyük verilerin analizi gerçekleştirilebilmektedir. İnsan kaynakları fonksiyonlarından işe giriş ve işten ayrılış gibi durumlarda makine öğrenmesi tekniklerinden yararlanılarak geçmiş verilere dayalı tahminleme yapılabildiği belirtilmiştir.
Uğurlu, Doğan (2023)	İnsan kaynaklarında dijitalleşme, e-İKY, sanal İKY, web tabanlı İKY, bilgisayar tabanlı İKY sistemleri, insan kaynakları bilgi sistemleri, dijital İKY gibi kavramlarla ortaya çıktığı belirtilmiştir. Yapay zeka sayesinde işe alım süreçlerinde büyük verilerin kolay analiz edilmesi ve değerlendirmelerin otomatikleşmesi sağlandığı ifade edilmiştir.

**Tablo 2.1** Yapay zeka uygulamaları (Devamı)

Şahin T., (2022)	Günümüzde yapay zekayı firmalar, insan kaynakları faaliyetlerinde yaklaşık olarak %40 olarak kullanmakta olduğu ve gelecekte ise yine yaklaşık olarak %33 artması beklendiği belirtilmiştir.
Oruçoğlu, (2022)	İnsan kaynaklarında yapay zeka teknolojileri işe seçme ve yerleştirme, yetenek gelişimi, raporlama, bordro, performans yönetimi, eğitim ve geliştirme, tutundurma, terfi potansiyel tespiti gibi farklı fonksiyonlarında kullanılabilirdiğinden söz edilmiştir.
Kambur, (2021)	Yapay zekanın, insan kaynakları faaliyetleri ile birlikte kullanıldığında çalışan deneyimine fayda olarak; aday ön eleme, video mülakatları, oryantasyon süreçleri, eksiklerinin tespit edilerek eğitim atanması, mentörlük desteği, izin planlanması, yetenek gelişimi, performans değerlendirme gibi uygulamalar geliştirilebileceği belirtilmiştir.
Kırılmaz, (2020)	Rutin ama zaman alan insan kaynakları işlemlerinin (evrak işlemleri vb.) dijitalleşme ve yapay zeka desteğiyle otomatik hale getirilmesi sayesinde insan kaynaklarının önemli metriklerinden olan; stratejik insan kaynakları, kariyer planlama ve çalışan bağlılığı vb. alanlar hakkında yapılan çalışmaların gelişmesini de katkı sağlayacağı konuları ele alınmıştır.
Yılmaz, (2022)	Yapay zeka, insan kaynakları yönetiminde işe alım süreçlerinde adayların özgeçmişlerinin taranmasında, adaylar ile ön görüşme aşamasında, uygun aday seçilmesinde kullanılabilir. Yapay zekanın bu süreçlerde kullanılması, insan kaynakları yetkililerin adaylar arasında ayrımcılık yapılmaması, zamanın etkili ve verimli kullanılması gibi olumlu etkileri olduğundan söz edilmiştir.
İbiş, (2022); Uçacak, (2020)	Günümüzde eğitim alan kişiler ve eğitimcilerin birbiri ile uzakta olmaları halinde de eğitim uygulamalarının gerçekleştirilmesi, eğitimlerin akılda kalıcılığının artırılması gibi amaçlarla sanal gerçeklik veya metaverse gibi platformlarda eğitimlerin gerçekleştirilmeye başladığından bahsedilmiştir.
Ereken ve Tarhan (2021)	Yapay zeka günümüzde, sosyal medya, sanal oyunlar vb. yanı sıra insan kaynaklarında özgeçmiş değerlendirme, video mülakat, ön görüşmelerde jest ve mimik analizinde kullanıldığı belirtilmiştir.

Yapılan çalışmada potansiyel istifaları makine öğrenmesi algoritmalar ile tahminleme amaçlanmıştır. Veri seti, çevrimiçi veri havuzu olan Kaggle üzerinden elde edilmiş ve Knime paket programı üzerinde çalışılmıştır. Veri setinde, işten ayrılma üzerinde etkisi olduğu belirlenen; Memnuniyet düzeyi, proje sayısı, ortalama aylık çalışma saati, şirkette geçirdiği süre, iş kazası sayısı, son beş yılda aldığı promosyon sayısı, satış sayısı, maaş düzeyi vb. kriterler üzerinde çalışılmıştır. Naive Bayes algoritması için veri seti %80 öğrenme, %20 test seti olarak belirlenmiş ve eksik, geçersiz vb. veriler ön işleme aşamasında elenmiştir. Algoritmanın doğruluk başarısı %81,16 olarak başarılı şekilde yorumlanmıştır (Widiyawati, 2023).

Çalışanların istifa durumu tahminlenmesi için yapılan araştırmada, 15.000 adet çalışan ve 10 farklı nitelikten oluşan veri seti üzerinde çalışılmıştır. Veriler kategorilerine göre ayrılarak değerlendirilmiş ve yorumlanmıştır. Veri seti %70 öğrenme, %30 test seti olarak ayrılmıştır. Rastgele Orman, Destek Vektör Makineleri, Lojistik Regresyon, K-En Yakın Komşu ve Naive Bayes algoritmaları kullanılmıştır. Uygulama sonucunda ise Rastgele Orman Algoritması en iyi performansı göstermiştir. Çalışma sonucu elde edilen

başarı sonuçlarının önceki çalışmalarla paralel olduğu ve istifada etkin rol oynayan kriterlerin önem sıralaması yapılmıştır (Arromrit vd., 2023).

Araştırmada, 1470 gözlem ve 34 özellikten oluşan veri seti kullanılarak makine öğrenmesi yaklaşımları ile çalışan kaybı tahmini yapmayı hedeflemiştir. Yaş, günlük ücret, departman, evden uzaklık, çevre memnuniyeti, eğitim, unvan, iş memnuniyeti, medeni durum, önceki şirket sayısı, kıdem, mevcut roldeki kıdem gibi niteliklerin işten ayrılma tahmininde kriter olarak kullanılmıştır. Veriler ile korelasyon analizi yapıldığında; deneyimli, memnuniyeti düşük, evinden uzakta çalışan, sık seyahat eden, fazla mesai yapan, daha önce çok sayıda şirkette çalışanların istifa etme olasılığı yüksek olduğu yorumu yapılmıştır. Kesinlik, doğruluk ve  $f_1$  skoru gibi başarı kriterlerine göre algoritmalar karşılaştırılmış ve %88'lik performans göstergesi ile en başarılı tahmin yapan Lojistik regresyon algoritması olmuştur (Guerranti ve Dimitri, 2022).

Çalışmada yaygın olarak kullanılan Kaggle IBM İK analitiği çalışan kaybı ve performansı veri seti kullanılmış ancak veri sayısı yetersiz olabileceğinden yapay veriler eklenerek veri büyüklüğü artırılmıştır. Veri kümesinin %70'i eğitilmiş, %30 ise başarı için test edilmiştir. Var olan veri setinin büyümesi makine öğrenmesi algoritmalarındaki başarıyı da arttırdığı gözlemlenmiştir. En yüksek doğruluk oranı %98 ile Rastgele Orman Algoritması olmuştur. Araştırma sonucunda, çalışanın sadakatini, şirket kültürü, ücretlendirme ve çalışan-yönetici ilişkilerinin olduğu sonucuna varılmıştır (Özakça vd., 2024).

Yapılan araştırmada makine öğrenmesi teknikleri ile çalışan kaybını tahminleme gerçekleştirilmiştir. Kaggle platformunda yer alan hazır veri seti kullanılarak, altı farklı makine öğrenmesi algoritmasında uygulanarak başarı oranları karşılaştırılmıştır, başarılı tahmin en yüksek Naive Bayes'te elde edilmiştir. Veriler analiz edildiğinde, genç yaştakilerin, düşük maaşlıların, iş – ofis mesafesi uzak olanların, kıdemi az olanların, iş katılımı az olanların işten ayrılma ihtimalinin arttığı gözlemlenmiştir. Makine öğrenmesi uygulamalarının son kullanıcı tarafından pratikte benimseyebilmesi için kolay ve erişilebilir olması gerektiğinden Python'da analiz ve bulgular doğrultusunda sürüm yayınlanmıştır. Bu sürüm arka planda Naive Bayes kullanılarak, kullanıcıdan gerekli bilgiler girildiğinde o çalışanın işten ayrılma potansiyelinin olup olmadığını tespit edebilecek şekilde tasarlanmıştır (Fallucchi ve Coladangelo, 2020).

Ele alınan çalışmada çalışanların e-posta iletişim analizi yapılarak işten ayrılma durumunun tahminlenmesi incelenmiştir. E-posta alıcısı, gönderen, tarihler, iş saatleri içerisinde ya da mesai saati dışında, amirden ya da çalışma arkadaşından alınması gibi

kriterler incelenerek yapay sinir ağıları kullanılmıştır. Tekrarlayan sinir ağıları kullanımı sayesinde işten ayrılma olasılığı bulunan çalışanlar %74 oranında başarılı şekilde tahminlenmiştir (Korytkowski vd., 2022).

Mohbey'in, çalışmasında Rastgele Orman, Naive Bayes, Lojistik Regresyon, Destek Vektör Makineleri ve Karar Ağacı Algoritmalarını çalışan kaybı tahmini için kullanmıştır. Lojistik regresyon algoritmasının yaklaşık %86 doğruluk oranı ile diğer algoritmalarından daha iyi performans gösterdiği belirtilmiş ve çalışan kaybı tahminin maliyet tasarrufu yönü vurgulanmıştır (Mohbey, 2020).

Derin sinir ağıları kullanılarak çalışan kaybı tahmini konulu araştırmada, derin sinir ağıları kullanımına odaklanılmıştır. Çalışan kaybı tahminiaranın, yönetim ve insan kaynakları planlaması adına kritik olduğu, doğruluğu ve verimliliğin bu teknikler ile artırılabilceğinin önemini belirtmiştir (Al-Darraji vd., 2021).

Yapılan araştırmada diğer uygulamalardan farklı olarak hazır veri seti üzerinden değil, Endonezya'nın ünlü telekomünikasyon şirketinin iki yıllık gerçek verileri ile tahminlemeler gerçekleştirilmiştir. Naive Bayes, Karar Ağacı ve Rastgele Orman olmak üzere üç farklı algoritma kullanılmıştır. Çalışanın işinin yeri, bölüm ve alt bölümü, pozisyon, kıdem, maaş vb. nitelikler kullanılarak %70-%30 öğrenme ve test seti olarak ayrılmıştır. Doğruluk sonuçları karşılaştırılarak %97,5 doğruluk ile en yüksek başarı Rastgele Orman Algoritması olmuştur (Alamsyah ve Salma, 2018).

Çalışanları elde tutma tahmini için makine öğrenimi yaklaşımları incelenen araştırmada, kişinin mevcut işini bırakmasına neden olan sorunları tespit etmek üzerine tasarlanmıştır. Çalışanların mevcut nitelikleri, demografik bilgileri ve deneyim verilerini içeren modeller kullanılarak, hedef adayın elde tutulmasının kararını verme olasılığı tahmin edilebilir ve adayın kararını etkileyen faktörler de yorumlanabilmekte olduğu belirtilmiştir. Şehir, cinsiyet, deneyim, eğitim vb.12 farklı nitelik ve Lojistik Regresyon, Naive Bayes, K-En Yakın Komşu, Karar Ağacı, Rastgele Orman, Gradyan Arttırma, XgBoost, LightGBM olmak üzere 8 farklı algoritma kullanılmıştır. Doğruluk sonuçlarına göre en başarılı algoritma Rastgele Orman Algoritması olarak elde edilmiştir (Marvin vd., 2021).

Çalışmada istifa üzerinde yaş, kıdem, ücret, iş tatmini, cinsiyet, etnik köken, eğitim ve medeni durumun önemli bir etkisinin olduğu öne sürülmüştür. Uygulamada veri seti üzerinde, Naive Bayes, Rastgele Orman, K-En Yakın Komşu, Doğrusal Ayrım Analizi, Destek Vektör Makinesi, Aşırı Gradyan Güçlendirme Algoritmaları uygulanmış ve en başarılı algoritma aşırı gradyan güçlendirme olduğu belirtilmiştir. Araştırmacılar,

çalışma kapsamında yalnızca hangi çalışanların risk altında olduğu değil aynı zamanda potansiyel istifalarda ne yapabiliriz sorusunun da araştırıldığı modeller ve derin öğrenme modellerinin de uygulaması ile incelenmesini önermiştir (Rohit ve Ajit, 2016).

Araştırmada işten ayrılmayı doğru tahminleme için, istifaya etki eden başlıca nitelikleri belirlemenin gerektiği belirtilmiştir. İlgili çalışmada, yaş, maaş, mutluluk indeksi, işyerine olan uzaklık, yıpranma durumu ve medeni durumu nitelik olarak seçilmiştir. Lojistik regresyon, Karar Ağacı, K-En Yakın Komşu, Naive Bayes, Destek Vektör Makineleri, xgboost algoritmaları kullanılmış ve en başarılı algoritma xgboost olarak elde edilmiştir. Erken uyarı sistemi (EWS) adlı arayüz tasarlanarak mevcut çalışanların risk gruplarına göre sınıflandırma yapılmış ve önlem alma imkanı sağlanmıştır (Mhatre vd., 2020).

Çalışmada, Kaggle üzerinden açık veri kümesi kullanılarak personel kaybı tahminlenmiştir. Ele alınan nitelikler; çalışanın doğum tarihi, işe giriş tarihi, yaşı, çalışma süresi, şehir adı, departman, unvan, bayi adı, cinsiyeti, iş birimi ve çalışma durumu, tahminlemede ise Karar Ağacı, Rastgele Orman, Destek Vektör Makinası, Lojistik Regresyon, Yapay Sinir Ağı, K-En Yakın Komşu ve sıralı modeller olan geçitli tekrarlayan hücre, uzun-kısa süreli hafıza makine öğrenmesi algoritmaları kullanılmıştır. Doğruluk ve başarı ölçütlerine göre algoritmalar kıyaslanmış ve Rastgele Orman algoritmasının en başarılı tahmin oranına sahip olduğu belirlenmiştir (Bahadır vd., 2021).

Araştırmada, telekomünikasyon şirketinin gerçek verilerinin gizlilik nedeniyle türetilerek üretilmiş veriler üzerinde çalışılmıştır. İşten ayrılma tahminlemede kullanılacak nitelikler; unvan, birim, kıdem, lokasyon, cinsiyet, medeni hal, çocuk sayısı, askerlik, okul türü ve yaş olarak belirlenmiştir. Lojistik Regresyon, K-En Yakın Komşu, Destek Vektör Makineleri, Regresyon Ağacı, Rastgele Orman, Gradyan Arttırma Makineleri, Yapay Sinir Ağları ve Aşırı Gradyan Arttırma Makineleri olmak üzere sekiz farklı makine öğrenmesi algoritması Python üzerinde öğrenme işlemleri gerçekleştirilmiş ve tahmin başarı sonuçları kıyaslanmıştır. Başarı metrikleri; doğruluk, çapraz doğrulama skoru, kesinlik, duyarlılık vb. göre en başarılı tahmin Rastgele Orman Algoritmasında elde edilmiştir (Uzak, 2022).

Çalışmada incelenen araştırmaların genellikle veri seti oluşturucusu Kaggle programı üzerinden IBM İK analitiği ve çalışan kaybı ve performansı adlı data seti kullanılarak uygulandığı ve ülkemizde çalışan kaybı üzerinde gerçek veriler ile uygulanan çalışmaların yeterli sayıda olmadığı görülmüştür. Yapılan araştırma, ülkemizde yapılan “Telekomünikasyon sektöründe çalışan kaybı tahmini için makine öğrenmesi modeli

seçimi” (Uzak, 2022) adlı çalışma ile çalışan kaybının makine öğrenmesi algoritmalarından Lojistik Regresyon, K-NN, Destek Vektör Makineleri, Regresyon Ağacı, Rastgele Orman, Gradyan Arttırma Makineleri ve Yapay Sinir Ağları ile tahminlemesi konusunda benzer başlıkta incelenmiş olduğu ancak çalışma uygulama aşamasında büyük farklılıklar ile birbirinden ayrıldığı görülmüştür. Bu çalışmanın daha önce yapılan araştırmalardan farkı, demir çelik sektöründe gerçekleştirilmesi, gerçek verilerin kullanılması, birden fazla makine öğrenmesi platformunda ve farklı makine öğrenmesi algoritmalarının uygulanarak karşılaştırılmasıdır.



### 3. YÖNTEM

Bu bölümde araştırmanın amacını oluşturan insan kaynaklarında makine öğrenmesi ile tahminleme yapılmasında kullanılan yöntem ve bu yönteme ilişkin insan kaynakları, yapay zeka ve insan kaynaklarında yapay zeka başlıkları altında incelenmiştir.

#### 3.1. İnsan Kaynakları Yönetimi

İnsan kaynakları yönetimi bölümünde ilk olarak tanımlama yapılacak, insan kaynaklarının zaman içerisindeki gelişimi incelenecek, ardından sırasıyla amaçları, stratejileri ve fonksiyonları incelenecektir.

##### 3.1.1. İnsan kaynakları yönetimi tanımı

İnsan kaynakları kavramı ilk olarak ekonomist Springer tarafından kullanılmıştır. İnsan kaynaklarında yönetim kavramı ise günümüz İKY teriminin gelişiminde önemli rol oynayan Taylor ve Fayol'un düşünceleri ile ortaya çıkmıştır. İnsan kaynakları terimi zaman içerisinde farklı adlandırmalar ile anılmış ve günümüzde ortak hedeflerin var olması ve çözüm yollarının bulunmasıyla zorunlu bir durum olarak günümüzdeki konumuna ulaşmıştır. Personel yönetimi kavramının insan kaynakları yönetimi kavramına doğru yönelmesiyle, insan kaynakları yönetimi personel edinme süreçleri, eğitim ve gelişim süreçleri, ücret / performans / kariyer yönetimi, iş sağlığı ve güvenliği sağlama faaliyetleri olmak üzere daha kapsamlı hale gelmiştir.

İnsan kaynakları, kâr amacı güden ve devamlılığını sağlamak isteyen işletmelerin, örgüt içerisinde üretebilen insan gücüne ulaşması, bu kaynağı ilerletebilmesi ve sürdürülebilirliğini sağlayabilmesi için var olan çalışanların ve var olma potansiyeli olan kişilerden faydalanma yöntemlerinin araştırıldığı kavramdır. İnsan kaynakları yönetimi, işletmenin gerekli işgücüne sahip olması adına adayların bulunması, adayların seçim süreçlerine tabi tutulması, seçilmiş adayların işletmenin süreçleri ve etik değerleri ile uyumlandırılması, kurum amaçları doğrultusunda çalışabilecek şekilde adaptasyonun gerçekleştirilmesi, çalışanların motivasyonlarının sağlanması, adil ücret politikasının oluşturulması, işgücü kaybının önlenmesi, eğitim ve gelişim süreçlerinin yönetilmesi faaliyetlerinin tamamıdır.

İnsan kaynakları, süreç için gerekli diğer sermaye, makine teçhizat, hammadde vb. kaynaklar gibi kıt kaynaklar arasında yer almaktadır ve bu kaynağa da gerekli yatırımların yapılması gerekmektedir. İnsan kaynakları, organizasyona dahil olan, üst yönetici ya da alt kademe çalışanların tamamını ifade eder. İnsan kaynakları yönetimi,

organizasyona bünyesindeki tüm çalışanların belirlenen stratejilere uygun şekilde yönltilmesini ve koordine edilmesini ve insan kaynağının verimli şekilde kullanılmasını ifade etmektedir. İnsan kaynaklarının başlıca amacı çalışanların motivasyonunu ve çalışma performansını yükseltebilecek etkinlikleri gerçekleştirmektir. Çalışan sayısının ve çalışanların farklı kişiliklere sahip olması motivasyon artırıcı politikaların belirlenmesini de zorlaştırmaktadır bu sebeplerden ötürü insan kaynakları bir kurumda en zorlayıcı alanlardan biri olduğu sonucuna ulaşılabilir (Arslan, 2021). Firmanın sürdürülebilirliğinin sağlanabilmesi için çalışanların verimli, kararlı ve başarılı bir şekilde işlerini yürütmesi gerektiğinden çalışanlar işletmeler için kilit noktayı oluşturmaktadır. İşletme bünyesindeki insanların işini memnuniyetle yapmaması ya da yapılan teknolojik yatırımları kullanma konusunda yetkinliğe sahip olmaması durumunda yüklü bir kayba uğrayacağından firmalar insan kaynağına önem vermeye başlamıştır.

İnsan kaynakları yönetiminin ilkeleri aşağıdaki gibi belirtilmiştir. Belirtilen bu ilkeler insan kaynakları yönetiminde tutarlılığı ve devamlılığı konusunda önem taşımaktadır (Midem, 2016).


- Tarafsızlık ilkesi
- Eşitlik ilkesi
- Yeterlilik ilkesi
- Kariyer ilkesi
- İnsancıl davranış ilkesi
- Güvence ilkesi
- Verimlilik ilkesi
- Açıklık ilkesi
- Gizlilik ilkesi
- Liyakat ilkesi
- Katılımcılık ilkesi

### **3.1.2. İnsan kaynakları gelişimi**

İnsan kaynakları yönetiminin ilk ortaya çıkışı, sanayi öncesi dönemde pamuk temelli lonca sistemi esnasında zanaatkarlar ve çırakları ile yapılan çalışma düzenlemeleri olmuştur. Çıraklar, ustaları ile yaşar ve usta çırağının sağlığı ve yaşam ihtiyaçları ile ilgilenmekteydi. 18. Yüzyılda gerçekleşen sanayi devrimi ile üretim büyük fabrikalarda yapılmaya başlanmış ve makine sayıları ile çalışan işçi sayısı da artmaya başlamıştır. Fabrikalardaki, kirlilik, zorlu çalışma koşulları gibi nedenlerden çalışanların temel hak ve korunma ihtiyaçlarını sağlayabilmek adına hükümet devreye girmiştir. Kurum sahipleri, yasal düzenlemelere uymakla yükümlü olmuş ve sorunların ortadan kaldırabilme adına hükümet, kurumlar ve çalışanlar arasında mekanizma oluşturulmuştur. 20. Yüzyılın başlarında ise personel yönetimi kavramı gelişmeye başlamıştır ve ikinci dünya savaşı

sonrasında arařtırmalara konu olmuřtur. Birinci dnya savařı sırasında uygulamada olan refah sekreterlikleri ve iře alım ynetimleri ise personel ynetimi kavramı atısı altında birleřtirilmiřtir. Kavramların belirginleřmesi ve literatrde yer edinmesiyle birlikte kurumlarda personel yneticisi unvanıyla alıřanlar iř bařı yapmıř ve geniř yelpazeli grevlere sahip olmuřtur.

İnsan kaynakları ynetimi kavramı ile ilgili yetkili alıřan kiřilerin unvanlarının zaman ierisindeki deęiřimi Őekil 3.1’de gsterilmiřtir. Personel ynetimi zerine anılan terim geliřimini tamamladıka insan temeli zerinde geliřmiřtir (Őařmaz, 2023).



**Őekil 3.1** İnsan kaynakları ynetimi kavramı zaman ierisindeki deęiřimi

Zaman ierisinde kurumların alıřanlarına deęer vererek nceliklendirmesi ile odak noktası insan olmuř ve personel ynetimi kavramı insan kaynakları ynetimine doęru ynelmiřtir. Personel ynetimi ile insan kaynakları ynetimi arasındaki farklılıklar ise Tablo 3.1’de gsterilmiřtir (Cingz, 2011).

**Tablo 3.1** Personel ynetimi ile insan kaynakları ynetimi arasındaki farklılıklar

PERSONEL YNETİMİ	İNSAN KAYNAKLARI YNETİMİ
İř odaklı	İnsan odaklı
İřletme hedefleri	Personel memnuniyeti
İř verimlilięi	İřgc verimlilięi
Operasyonel faaliyet	Danıřmanlık hizmeti
Kayıt sistemi	Kaynak anlayıřı
İnsan maliyet unsuru	İnsan nemli girdi
Klasik ynetim	Toplam kalite ynetimi
İřte alıřan insan	İři ynlendiren insan

İnsan kaynakları geliřimini ařamalar halinde listelemiř olup, drt farklı ařamada geliřimi aıklamıřtır. Ařamalar ve aıklamaları Tablo 3.2’de listelenmiřtir (Arslan, 2021).

**Tablo 3.2** İnsan kaynakları gelişim aşamaları

AŞAMA	YILLAR	AÇIKLAMA
<b>Birinci Aşama</b>	1900'lü yılların başı	<ul style="list-style-type: none"><li>• Refah aşaması olarak adlandırılmaktadır.</li><li>• Genel müdür, istihdamı sağlayan memurlar ve eğitimciler refah memurları personel işlevleri konusunda temeli oluşturmuştur.</li><li>• Bilimsel yönetim yaklaşımı olarak adlandırılmaktadır.</li></ul>
<b>İkinci Aşama</b>	1900'lü yılların ikinci yarısı	<ul style="list-style-type: none"><li>• Refah ve idare aşaması olarak adlandırılmaktadır.</li><li>• Avustralya'da personel yönetimi kapsamında daha kıdemli ve uzmanlaşan bir bakış açısının başlangıcı oluşturulmuştur.</li><li>• İnsani ilişkileri yaklaşımı olarak da adlandırılmaktadır.</li></ul>
<b>Üçüncü Aşama</b>	1900'lü yılların sonu	<ul style="list-style-type: none"><li>• İnsan kaynakları yönetimi kavramı Avustralya'da belirgin bir şekilde kullanılmaya başlanmıştır.</li><li>• İnsan kaynakları kapsamında endüstriyel ilişkiler ve ödüllendirme sistemleri oluşmaya başlamıştır.</li><li>• Personel yönetimi aşaması olarak adlandırılmaktadır.</li></ul>
<b>Dördüncü Aşama</b>	Günümüz ve gelecek	<ul style="list-style-type: none"><li>• Gelecekteki insan kaynakları uygulamalarını teknoloji ile gelişen sistemlere sahip ve küresel insan kaynakları yönetimi modellerinin uygulanma zorunluluğu gibi bakış açılarının benimseneceği belirtilmektedir.</li><li>• İnsan kaynakları yönetimi yaklaşımı olarak adlandırılmaktadır.</li></ul>

İnsan kaynakları yönetimi kavramı güncel dördüncü aşamada ve geleceğinde şunlar beklenmektedir.

- Her çalışanın örgüt içerisindeki katılımının artırılmasını
- Grup çalışmalarının önemini artırması
- Personellerin kariyer yönetimi ve danışmanlıkların verilmesi
- Dikey örgütlenmenin yatay olarak değişmesi
- İnsan kaynakları yapısının küçülmesine rağmen sorumlulukların artması
- E-İKY anlayışı ve dijital insan kaynakları bakış açısının genişlemesi
- Yapay zeka ve gelişmiş teknoloji konularında nitelikli personel ihtiyacının oluşması
- İnsan kaynakları birimi idari kadrodan stratejik kadroya geçiş yapması ve farklı kuşaklardaki personellerin aynı ekip içerisinde uyumlu şekilde çalışmasını sağlama

İnsan kaynaklarının geleceğinde kilit nokta teknolojidir. Teknolojik gelişmeler ile insan kaynakları yönetimi süreçlerinde standardizasyon sağlanması ve insan

kaynakları yetkililerine daha az iş gücü gerekliliği yükleneyeceği öngörülmektedir. İleri teknoloji, yapay zeka, makine öğrenimi gibi veri kaynaklı gelişmelerden kaynaklı olarak yüksek miktarda verilerin saklanması gerekliliği tahmin edilmektedir. Çalışanların fikirlerine değer verme, yeni fikirlerin ortaya atılmasına teşvik etme gibi değerlerin öne çıkması, personel odaklı inovasyon ile internet ve bilişim alanında da yeniliklerin ortaya çıkacağı belirtilmektedir (Arslan, 2021).

### 3.1.3. İnsan kaynakları amaçları

Firmalar tarafından, insan faktörünün ürün ya da hizmet üretiminde amaçlarına ulaşabilmesinde temel unsur olduğu anlaşılmıştır. Örgütün yüksek verimle çalışmasını sağlamak insan kaynaklarının en önemli amacı olarak görülmektedir. İnsan kaynaklarının başlıca amaçları, kurum bünyesindeki iş gücü sermayesinin bilgi, yetenek ve becerilerini geliştirerek firmaya sağladığı faydayı arttırmak, personellerin işten maksimum doyumunu alabilmesinde katkıda bulunmak, iş gücü maliyetlerini optimal seviyede tutmayı, değişimlere uyum sağlamayı, çalışanlarda olumsuz durumları öngörerek engellemeyi ve evrensel yenilikleri takip etmeyi amaçlamaktadır.

Kurumlarda insan kaynakları biriminin başlıca amacı firmayla ortak hedefler doğrultusunda rekabet üstünlüğü sağlamaktır. İnsan kaynakları fonksiyonu bu amaç doğrultusunda personellerin memnuniyeti ve devamlılığını sağlayarak destek olmaktadır. İnsan kaynakları yönetimi geniş bir çerçeveden incelendiğinde çalışmalarda genellikle toplumsal, işlevsel, örgütsel ve kişisel amaç olmak üzere dört başlıkta incelendiği belirtilmiştir (Abdulrahman, 2023; Cingöz, 2011).

**Toplumsal amaç:** Toplumsal amaçlara örnek olarak iş kazalarının neden olduğu maddi ve manevi kayıpların azaltılması, değişime adapte olunmasını sağlamak, evrensel yenilikleri takip etmek

**İşlevsel amaç:** Ürün ya da hizmet çıktısının verimli ve kaliteli olmasına katkıda bulunulması, iş gücü maliyetlerini optimal seviyede tutmak, iş gücü verimliliğini arttırmak

**Örgütsel amaç:** Sürekli eğitim ve gelişim imkanının sunulması, iş gücü devir oranının azaltılması, işten ayrılmaların minimuma düşürülmesi, işe devamlılığın yükseltilmesi, ekip içi iletişimlerin güçlendirilmesi, işgören ile işveren arasında köprü görevi görerek iletişimin kolaylaştırılması, kurum kültürü oluşturmak, adaletli terfiler gerçekleştirmek

**Kişisel amaç:** Personel memnuniyet ve motivasyonunun sağlanması, işgörenlerin istek ve ihtiyaçlarını karşılamak, mesleki açıdan gelişimi sağlamak, çalışanlarda olumsuz durumları öngörerek engellemek, kariyer gelişimi ve iş tatmini sağlamak olarak belirtmiştir.

Bir çalışanın elde tutulması maliyeti, yeni bir personelin işe alım maliyetinden daha düşüktür. Bu nedenle, firmalar işe aldığı personelleri, uzun vadeli olarak çalıştırma amacı gütmektedir. Hem işe alım maliyetlerinden kaçınmak hem de işe alım gibi uzun bir süreçten kaynaklı zaman kaybından da kaçınmak istenmektedir. Firma yetkilileri mevcut nitelikli personelleri kaybetmemek için çalışmalar yürütmektedir. Bu çalışmalara örnek olarak ise güncel tekniklerden olan yapay zeka ve makine öğrenmesinden faydalanılarak işten ayrılma ihtimali bulunan personellerin tahminlenmesi olabilmektedir (Bahadır vd., 2021).

İşletmelerin iş gören devir oranını optimal seviyede tutmayı hedeflemektedir. İş gören devir oranının çok yüksek olması, nitelikli personellerin kaybına, zaman ve maliyet zararına uğratabilmektedir. İş gören devir oranının beklenenden düşük olması ise değişkenliğin düşük olması ve durağanlık gibi sorunlara sebebiyet verebilmektedir. İşletmeler çalışan sirkülasyonuna her zaman sahip olacağı açıktır. Bu konuda önemli olan kaybedilen çalışanın niteliğidir. Yetenekli, deneyimli ve yüksek kabiliyetli personellerin kaybı işletmeler için gerçekten kayıp olarak; adaptasyon, motivasyon ve uyum konusunda düşük performanslı çalışanlar ise kayıp olarak nitelendirilmeyebilir.

### 3.1.4. İnsan kaynakları stratejileri

İnsan Kaynakları stratejileri (Şaşmaz, 2023) tarafından yenilik, kariyer geliştirme ve maliyet azaltma ana başlıkları altında listelenmiş olup Tablo 3.3'te sunulmuştur. İnsan kaynakları stratejileri, kurumun hedeflerine yönelik oluşturduğu stratejiler ile paralel olduğu görülmektedir.

**Tablo 3.3** İnsan kaynakları stratejileri

İşletme Hedefi	İnsan Kaynakları Yönetimi Stratejisi
Yenilik	Ekip içerisindeki iletişim ve koordinasyonu sağlayacak işler
	Farklı becerileri güçlendirebilmek adına geniş yelpazeli kariyer yolları
	Kurum içi öz kaynakları göz önüne alacak ücret sistemleri
	Çalışanın mevcut pozisyonundan farklı pozisyonlarda da kullanabileceği becerileri güçlendirmek
	Uzun süreli ekip başarılarını amaçlayan performans değerlendirmesi

**Tablo 3.3** İnsan kaynakları stratejileri (Devamı)

<b>İşletme Hedefi</b>	<b>İnsan Kaynakları Yönetimi Stratejisi</b>
<b>Kariyer Geliştirme</b>	Açık ve anlaşılır görev tanımları
	Yüksek çalışan katılımını sağlamak
	Sonuç odaklı, kısa süreli performans değerlendirmesi
	İş sağlığı ve güvenliğini eşit şekilde sağlamak
	Sürekli eğitim ve gelişimi desteklemek
<b>Maliyet Azaltma</b>	Uzmanlık gerektiren dar kapsamlı işler ve bu alanda tanımlanan kariyer yolu
	Piyasa ücret düzeylerinin takip edilmesi
	Optimum düzeyde çalışan eğitimi ve gelişimi

### 3.1.5. İnsan kaynakları fonksiyonları

İnsan kaynakları fonksiyonları altı ana başlık altında incelendiğini belirtmiştir. Bunlar; planlama, kadrolama (işe alma), değerlendirme ve ödüllendirme, yetiştirme ve geliştirme (eğitim ve geliştirme), endüstri ilişkileri, korunma ve geliştirme (iş güvenliği ve çalışan sağlığı)'dir. Alt başlıklar ise Tablo 3.4'te gösterilmiştir. İnsan kaynakları fonksiyonları farklı ana başlık altında inceleniyor olsalar da birbirinden ayrılamaz halde gerçekleştirilmesi gereken faaliyetler bütünüdür (Niray, 1999).

**Tablo 3.4** İnsan kaynakları fonksiyonları

<b>Planlama</b>	<b>Kadrolama</b>	<b>Değerlendirme Ödüllendirme</b>	<b>Yetiştirme ve Geliştirme</b>	<b>Endüstri İlişkileri</b>	<b>Korunma ve Geliştirme</b>
<ul style="list-style-type: none"><li>• İş analizleri</li><li>• İnsan kaynakları planlaması</li></ul>	<ul style="list-style-type: none"><li>• Personel sağlama</li><li>• Seçme ve yerleştirme</li><li>• Oryantasyon</li></ul>	<ul style="list-style-type: none"><li>• Değerleme</li><li>• Ücret ve maaşlar</li><li>• Özendirici sistemler</li><li>• Yan ödüller</li></ul>	<ul style="list-style-type: none"><li>• Eğitim ve yetiştirme</li><li>• Kariyer planlaması</li></ul>	<ul style="list-style-type: none"><li>• Toplu pazarlık şikayet yöntemleri</li><li>• Örgütlenme</li></ul>	<ul style="list-style-type: none"><li>• İş güvenliği</li><li>• İşgören sağlığı</li><li>• İş yaşamının kalitesi</li><li>• Veri toplama ve kullanma</li></ul>

**Planlama:** İstenilen sonuca başarılı bir şekilde ulaşılabilmesi için her süreçte olduğu gibi insan kaynakları süreçlerinde de planlama ile başlamaktadır. Planlama; iş analizleri ve İKY planlaması adımlarından oluşmaktadır. İş analizinde, işin gereklilikleri, kullanılan araçlar, alet ve malzemeler, çalışanda bulunması gereken özellikler yer alır. Planlama aşamasında ise, insan kaynağını seçme ve yerleştirme, eğitim ve geliştirme, iş değerlemesi ve ücretlendirme, performans yönetimi, çalışma ilişkilerini güçlendirme iş güvenliğini sağlama planlamaları gerçekleştirilir. Zaman içerisinde değişen ve sürekli olarak yenilenen ekonomik, siyasal ve çevre koşulları çerçevesinde kurum bünyesindeki çalışanlarında güncel ihtiyaçlarının belirlenmesi ve bu ihtiyaçlara yönelik politikaların belirlenmesi ve uygulanması planlama sürecinde gerçekleştirilmektedir.

**Kadrolama:** Kurumların rekabet üstünlüğü sağlayabilmesi adına gerekli malzeme ve araç gereçleri etkin şekilde kullanabilecek yetkinlikte, kurum kültürüyle uyumlu, deneyim ve yeteneklere sahip, işletmeye katma değer sağlayabilecek ikame edilmesi zor olan aday çalışanların bulunması ve istihdam edilmesi süreçlerini kapsamaktadır. İnsan kaynaklarının planlanmasının ardından doğru pozisyona en uygun adayın yerleştirilmesi adımı yer almaktadır. Doğru iş görenin seçilmesi, işin verimli şekilde yürütülmesi adına önem taşımaktadır. Seçim süreci; iş gören bulma stratejisinin belirlenmesi, başvuruların toplanması, ön elemelerin yapılması ve aday havuzunun oluşturulması ile sürdürülür. Aday havuzundaki başvurular ise değerlendirme kriterlerine göre analizlerin gerçekleştirilmesi ile kabul ya da red sonucu elde edilir. Seçme ve yerleştirme adımlarının tamamlanması halinde seçilen iş görenlerin oryante edilmesi gerçekleştirilir.

**Değerlendirme ve Ödüllendirme:** Çalışanların farklı karakterleri, yetenekleri, ilgileri ve yetkinlikleri olması gibi nedenlerden işe gösterdikleri performansta değişiklik göstermesine neden olmaktadır. Bu sebeplerden ötürü her bir çalışanın performansının izlenmesi ihtiyacı doğmuştur. Değerleme; iş gören değerlendirme ve iş değerlendirme olarak iki başlıkta incelenmektedir. İş gören değerlendirme, performans yönetimi ve iş görenin değerlendirmesi olarak incelenir. Performansın değerlendirilmesiyle elde edilen verilere göre ödüllendirme, terfi ya da iş görenin işine son verilmesi sonuçları elde edilebilir. İş değerlendirme, işin önemi, zorluğu, gerektirdiği tecrübe vb. unsurların tespit edilmesi amacı ile gerçekleştirilir. İşin niteliklerinin tespit edilmesi, departmanların ve unvanların doğru şekilde ücretlendirilmesini sağlamaktadır. Adil bir ücretleme sistemi ile potansiyeli yüksek personellerin istihdamının sağlanması ve mevcut personellerin motivasyonunun yükselmesi amaçlanır.

**Yetiştirme ve Geliştirme:** Personellerin mevcutta yaptığı faaliyetleri ve gelecekte yapması gereken işleri gerçekleştirirken verimli ve başarılı bir şekilde gerçekleştirebilmesi adına eğitimler ve geliştirme programlarına dahil edilmektedir. Eğitim ve geliştirme fonksiyonu ile iş görenlerin kariyer gelişimine de katkıda bulunulur. Var olan yeteneklerin gelişimi ve potansiyel yeteneklerin ortaya çıkarılması konusunda yetiştirme ve geliştirme fonksiyonu önem taşımaktadır. Eğitim yalnızca bireysel gelişime değil, stratejik açıdan zaman içerisinde örgüt gelişimine de katkı sağlamaktadır.

**Endüstri İlişkileri:** Endüstri ilişkileri dar çerçevede sadece sanayi sektöründeki iş gücü ile ilgilenmesi, geniş çerçevede incelendiğinde ise maaş karşılığı çalışan herkesin çalışma koşulları ile ilgilenmesi olarak tanımlanmaktadır. Endüstri ilişkileri, işçi

örgütlenmeleri, işveren örgütlenmeleri ve devlet birimleri arasındaki bağların tamamını kapsamaktadır. Endüstri ilişkilerine örnek olarak işçi sendikaları ile gerçekleştirilen toplu iş sözleşmeleri verilebilir. Bu sayede işçi hak ve çıkarları gözetilmektedir.

**Korunma ve Geliştirme:** Kurumlarda çalışan personellerin fiziki ve psikolojik olarak her türlü zarardan korunma çabası bu fonksiyon başlığı altında incelenir. Başlıca unsur olan güvenlik, personelin kendisinden ve çevresinden her türlü tehlikeden korunması amaçlanmaktadır. Korunma kapsamında, iş güvenliği ve işçi sağlığı, sağlığa zarar verebilecek makine-teçhizat kullanımı, karşılaşılabilecek iş kazaları ya da meslek hastalıklarına karşı önlem alınmasını amaçlamaktadır.

### **3.2. Yapay Zeka**

Bu bölümde ilk olarak yapay zekanın tanımı yapılacak, tarihçesi ve geleceği, uygulama alanları ve alt dallarından bahsedilecektir. Yapay zekanın alt alanlarından olan makine öğrenmesinin tanımı, tarihsel süreci ve türleri açıklanacaktır. Makine öğrenmesi algoritmalarından beş farklı örnek verilerek açıklamalar yapılacaktır.

#### **3.2.1. Yapay zeka tanımı**

İhtiyaçlar, insanlığın başlangıcından bu yana gelişim içerisinde ve zaman içerisinde değişmekte ve genişlemektedir. Bu ihtiyaçlar doğrultusunda, ihtiyaçları karşılayan teknolojik gelişmeler de hız kazanmış ve ivme kazanarak ilerlemeye başlamıştır. Bu yeniliklere örnek olarak yapay zeka verilebilir. Yapay zeka sayesinde insan zeka gücünün de sınırlarını aşması beklenmektedir.

Yapay zeka, insan, hayvan ya da doğa olaylarının bilgisayar yazılımları ya da bilgisayar kontrollü robot ile taklit edilerek verilerin toplanması, öğrenme yetisi ve amaçlara uygun şekilde verileri kullanma faaliyetlerine uyarlanarak rutin, kendini tekrar eden işlemleri klasik bilgisayar algoritmalarından daha hızlı ve kolay şekilde çözümlenebilmektedir. Yapay zeka, klasik algoritmalarından pek çok yönden farklılıkları ile ayrılmaktadır. Yapay zeka algoritması olmayan durumlarda verideki düzenden yola çıkarak daha karmaşık problemleri, yüksek miktarda veri ile hızlı bir şekilde çözümlenebilmektedir. Belirli kural ve yöntemlerin dışında öğrenme ile sonuca daha kolay ve hızlıca ulaşabilmektedir.

Yapay zeka, insana özgü olan zeka kavramı, düşünme, yorumlama ve öğrenme gibi yetenekleri bilgisayar algoritmaları sayesinde problemlere çözüm ve öneri sunabilmektedir. İlk düşünüldüğünde akla yalnızca bilgisayar bilimi gelen yapay zeka

bilgisayar dışında mühendislik, tıp, sosyoloji, felsefe, matematik, kavram bilimi ve psikoloji, biyoloji, dil bilimi gibi daha bir çok alanda faaliyet göstermektedir. Yapay zeka uygulamalarında, verilerin modellenmesi, problemlerin çözümlenmesi, doğal dil ve görüntü işleme, robotik sistemler, genetik algoritmalar, yapay sinir ağları ve bulanık mantık şeklinde sınıflandırılabilir (Öcal, 2023).

### 3.2.2. Yapay zeka tarihçesi

Yunan Mitolojisinde Talos'un Tanrı Hephaestus tarafından hayat verilen ilk akıllı robot olduğundan bahsedilmektedir. Akıllı otomasyon sistemlerine ilk zamanlarda değinildiğinden bahseden daha birçok örnek mevcuttur. Lakin bunlar hiçbir kanıt olmayan dilde dolanan rivayetlerdir (Makaritou, 2019). Zaman aralıklarına göre yapay zeka kavramının gelişimi Tablo 3.5'te gösterilmiştir.

**Tablo 3.5** Yapay zeka gelişimi

Zaman Aralığı	Yapay Zeka Gelişimi
1950'li Yıllar	Turing Testi denemeleri
1980'li Yıllar	Yapay zeka yazılımları
2000'li Yıllar ve Günümüz	Yapay zeka uygulamalarının günlük hayata yansması

1950 yılında bilim insanı Alan Turing tarafından makineler düşünebilir mi sorusuna yanıt olarak yapay zeka ile insanı birbirinden ayırmaya yarayan Turing Testi oluşturulmuştur. İnsan gibi davranan sistemlere örnek olan Turing testinde iki taraf birbirini görmeden mesajlaşmış ve gerçek insan kendisine cevap verenin insan mı yoksa yapay zeka mı olduğunu anlamaya çalışmıştır. 1956 yılında John McCarthy tarafından yapay zeka kavramı akıllı makine üretme mühendisliği şeklinde açıklanmıştır. Yapay zeka, talepleri algılama, talebe yönelik faaliyetleri yürütebilme kabiliyetine sahip bilgisayar koludur. Yapay zeka, çıkarımlarda bulunabilen, mantık kurallarına aykırı olmayacak şekilde akıllı davranışlar sergileyebilen cihazların tasarlanmasında kullanılmaktadır (Yüksel, 2023). İnsanlar tarafından yapay zeka kelimesi ilk duyulduğunda bilim kurgu olarak anlaşılmıştır. 1956 yılından bu yana bu konuda birçok kitap yazılmıştır. Temel konu düşünen makineler olsa da yapay zeka tanımını yapmak oldukça zor olup çok fazla süreç gerektirmiştir. 1966 yılında Weizenbaum tarafından Eliza adında bir yazılım geliştirilmiştir. Bu yazılım gerçek insan ve makine arasındaki iletişimi yüzeysel olarak aktarabilmekteydi. Bu sebeple Eliza yazılımı da yapay zeka konusunda yetersiz kalmıştır.

1980'li yıllarda bir endüstri haline gelen yapay zeka 1985 yılında yapay sinir ağları çalışmalarıyla hız kazanmıştır. 1988 yılında yapay zeka bir bilim olarak kabul edilmiştir. İlerleyen yıllarda Siri ve Watson's gibi yazılımların oluşumu gözlemlenmiştir.

2000'li yıllarda yapay zeka günlük yaşama dahil olmuştur. Akıllı telefonlar, televizyonlar olmak üzere birçok teknolojik alette yapay zeka sistemlerine rastlanmıştır. Yapay zeka ile zor olan bazı işler daha kolay hale gelmiştir. Olumlu olarak görünen yapay zeka gelecek kaygıları da içermektedir. Her ne kadar korkular yaşansa da işletmelerin yatırımları bu konuda hızla devam etmektedir (Seyitoğlu, 2019).

### 3.2.3. Yapay zekanın geleceği

İnsanlar geçmişten günümüze olmak üzere senelerdir insan müdahalesine gerek duyulmayan sistemler oluşturma peşinde koşmuştur. Fakat sürmeye devam eden araştırmalar halen insan zekasının makinelerin kapasitesinin çokça üzerinde olduğunu söylemektedir. Endüstri 4.0 devrimiyle yazılımsal algoritmalar sayesinde gelişen teknolojiyle birlikte birçok alanda yapay zeka kullanılmaya başlanmış olacaktır. Bu alanlara örnek olarak; tıp, eğitim, otomasyon, finans, hukuk, ulaşım, sanat, tarım, sosyal güdüleme, siyaset, biyoloji, matematik ve psikoloji verilebilir.

Birçok alanda sağladığı faydalarla nikbin durumlara yol açarken, araştırmacıların bazıları yapay zekanın tehlikeli olduğunu savunmaktadırlar. Yapay zekanın geleceği düşünüldüğünde iyimser ve kötümser iki tutumla karşılaşılır: Trafik kazalarını önleme, uçak iptallerinde erken teşhis, iç sıkıcı ve rutin işlerin daha kısa sürede ve daha kolay halledilebilmesi yapay zekanın iyi tarafıyken; çalışanları işsiz bırakabilecek ve savunma sanayisinde kötü kullanımının yaşanabilecek olması yapay zekanın kötümser tarafıdır (Armağan, 2019).

### 3.2.4. Yapay zeka uygulamaları

Yapay zekanın başlıca uygulamaları; ses tanıma, görüntü işleme, doğal dil işleme ve muhakemedir (Öcal, 2023).

**Ses Tanıma**, yapay zeka uygulamalarından günümüze kadar hızlıca ilerleme kaydeden alanlardan biridir. Android tabanlı, Google asistan ve IOS tabanlı Siri kullanıcıların seslerini işlemede, analiz etmede ve geliştirmeler ile cevap verme konusunda ihtiyaçlara karşılık verebilmektedir.

**Görüntü İşleme**, bir dizi öğretilen görsellerden öğrenim işlemleri sayesinde test görüntüsünü tahminleme ya da benzetme yapılması uygulamasıdır. Face ID olarak

adlandırılan akıllı cihazlardaki kimlik tanıma yüz algılama sistemleri ve sürücüsüz araçlarda nesnelere algılanması görüntü işleme uygulamalarına örnek olarak verilebilir.

**Doğal Dil İşleme**, rutin işlemlerin otomatik hale getirilmesi, arama motorlarının daha doğruya yakın önerilerde bulunması, taleplerin algılanması ve önerilerde bulunulması uygulamalarının bütünüdür.

**Muhakeme**, fikir karşılaştırması yaparak daha doğru olan savın belirlenmesinde, durumun analiz edilerek mantıklı karar alma süreçlerinde destek niteliğindedir.

Yapay zeka uygulamaları, makine öğrenmesi, optimize edilmiş donanımlar, karar verme donanımları, derin öğrenme, robotik otomasyon gibi çeşitli alanlarda karşılaşılmaktadır (Tiftik, 2021).

Dünyada önemli gelişmelere yol açan yapay zeka matematiksel algoritmalar sayesinde sınıflandırmalar, tahmin etmeler, teşhis etmeler, kontrol etmeler, veri düzenlemeler ile bir çok alanda yol açıcı bir bilim haline gelmiştir. Bu tekniklerin var olduğu uygulama alanları örnekler ile aşağıda açıklanmıştır.

- Üretim Sektöründe: Üretim verimliliğini artırma, ürün tasarımı, talep tahmin çalışmaları, üretim planlama
- Otomotiv Sektöründe: İnsansız araç tasarımları, yol bilgisayarları
- Tıp Alanında: Hastalık nedenlerinin daha kısa sürede teşhisi, tedavi sürelerinin kısalması, ilaçların yan etki yaratıp yaratmayacağını analizi
- Havacılık ve Uzay Sektöründe: Otomatik pilot uygulamaları, uçuş iptal tahminlemeleri, uçuş simülasyonları, gezegenlerin daha net görüntülenmesi, dronlar
- Savunma Sanayi Alanında: Daha net hedef belirleme, sensörler ve sinyaller görüntü işleme çalışmaları, silah kullanım kolaylıkları
- Elektronik Alanda: Uzaktan kumandalı aletler, rota belirlemede optimum sonuca ulaşma
- Dil Bilimi Alanında: Yazı ve konuşmayı başka bir dile çevirme yani makine çevirileri, veri türünün metin olduğu dosyaları sayısal veri dosyasına çevirme, şekil tanıma
- Mimarlık Alanında: Akıllı ev sistemleri, mekan tasarımları
- Güvenlik Alanında: Yüz ve parmak izi tanıma sistemleri, oluşabilecek kredi kartı hilelerini saptama elektronik ortamlarda hesap doğrulama sistemleri (Armağan, 2019).

Teknoloji alanında kendisini ilerletmeyi amaçlayan tüm işletmeler yapay zeka uygulama alanlarını yakından takip etmektedir. Veri muhafazasının titizlikte yürütüldüğü firmalarda makine öğrenmesi teknikleri kullanılabilir olmaktadır. Verilerin analizi ve yorumlanması adına kullanılan istatistiksel metotlar makine öğrenmesi sayesinde etkin bir şekilde kullanılabilir. Makine öğrenmesi verilerin ve istatistiksel yöntemlerin kullanıldığı tüm sektör ve işletmelerde aktif olarak kullanılabilir. Örnek olarak bankacılık sektöründe bankalar dolandırıcılığı önceden tespit edebilmek adına, müşterilerin borç ödeme verilerinden yola çıkarak kredi notu hesaplama vb. gibi faaliyetlerinde makine öğrenmesinden yararlanmaktadır. Güvenlik adına yazılım oluşturan firmalar ise, ses, yüz, parmak izi tanıma vb. işlemleri için makine öğrenmesi tekniklerini kullanmaktadır. Sigorta firmaları tarafından akıllı güvenlik sistemleri kullanımında, üretim yapan işletmelerde bakım, üretim, satış tahminlemelerinde, turizm firmalarında hava durumu tahminlemelerinde, sağlık hizmetinde sağlıklı hücrelerin belirlenmesinde kullanılmaktadır. Teknolojiyi yakından takip eden firmalar makine öğrenme uygulamasını tüm departmanlarında kullanımını yaygınlaştırabilir. Örneğin; üretim planlama, satış-pazarlama, insan kaynakları, kalite kontrol birimi, lojistik aktivitelerde ve kaynak planlamasına makine öğreniminden yararlanılabilir (Şekerli, 2019).

Yapay zeka çok geniş kapsamlı bir bilim olduğu için alt dalları da oldukça fazladır. Makine öğrenmesi, yapay sinir ağları (sibernetik yapay zeka), bulanık mantık, doğal dil işleme (dil ile düşünme), konuşma sentezi (yapay konuşma), konuşma analizi, uzman sistemler, örüntü tanıma, genetik algoritmalar, genetik programlama ve çoklu örnekle öğrenme yapay zekanın alt dallarıdır. Yapay sinir ağları, insan öğrenmesi ve algılamasından yola çıkılarak sinir sistemi modellenmiştir. Yapay sinir ağıyla asıl modellenmek istenen şey biyolojik sinir sisteminin modellenmesidir. Sinir hücreleri grup halinde olduklarından dolayı yüzlerce veya binlerce nöron bulunmaktadır. Bu doğrultuda yapay sinir ağları nöronların bir arada bulunmasıyla oluşmaktadır. Yapay sinir ağları ile ilgili detaylı bilgiler (Köklü, 2010; Ülker, 2007) kaynaklarından erişilebilmektedir. Diğer alt dallar için ise (İtü, 2023) yapay zeka içeriğinden ulaşılabilmektedir.

### **3.2.5. Makine öğrenmesi**

Çalışma kapsamında incelenen insan kaynaklarında işten çıkış tahminlemeleri yapay zeka alt uygulamalarından olan makine öğrenmesi üzerinde gerçekleştirilmiştir. Bu bölümde makine öğrenmesi tanımlamaları, amaçları ve kullanım alanları incelenmiştir.

Yapay zekanın alt dallarından olan makine öğrenmesi veriler arasındaki ilişkileri analiz etmek, ilişkiyi en iyi şekilde öngörebilecek modeli belirlenerek ve gelecekteki verilerde bu model ile tahminleme işlemlerinin gerçekleşmesini sağlamaktadır. Makine öğrenmesi problemin amacına göre, çıktı tahminleme ya da sınıflandırma yöntemleri kullanılabilir (Öcal, 2023). Makine öğrenmesinin diğer algoritmalarından farkı öğrenme kabiliyetinin bulunmasıdır. Öğrenme yetisi ile girdi verileri kaydedilir ve tecrübe olarak bir sonraki test verilerinin analizi için kullanılır. Makine öğrenmesini farklı metodları ile pek çok probleme çözüm sunabilmektedir. Verilerin değerlendirilmesi makine öğrenmesi ile daha kısa zamanda yapılabilir hale gelmiştir. Makine öğrenmesi ile gerçekleştirilen tahminler ile geleceğe yönelik planlamalar yapılabilir (Kutlugün, 2017).

Makine öğrenmesi, insan zekası gibi davranarak öğrenme ve tecrübe etme gibi yetenekleri istatistiksel yöntemler yardımı ile taklit etmektedir. Analiz yapma ve öngöründe bulunma sayesinde problemlerin çözümünde ve karar destek sistemlerinde, geçmiş verilere dayanarak çözüm önerisi sunmada rol oynamaktadır. Geçmiş olaylardaki tecrübe ve deneyimlere bağlı olarak yapılan incelemeler “Raporlama”, mevcut durumun tespiti ve incelemesi “Analiz”, gelecekte olması beklenen durumların incelenmesi ise “Öngörüselsel Analiz” olarak adlandırılmaktadır. Makine öğrenmesi algoritmalarında girdi olarak kullanılan ham verilerin toplanması için belirli bir sürece ihtiyaç duyulmaktadır ve verilerin az olmaması, tutarlı ve güvenilir kaynaklardan elde edilmiş olması gerekmektedir. Algoritmalar sayesinde işlenmemiş veriler analiz edilir, değerlendirilebilir, yorum ve çıkarım yapılabilir bilgi haline gelmektedir. Makine öğreniminde, test verileri üzerinde tahminde bulunma ya da karar alma amacıyla, eğitim veri setinde istatistiksel veri modeli oluşturulmaktadır. Süreç içerisinde etkileşimli makineler sayesinde veriler kolaylıkla saklanabilir ve kullanılabilir hale gelmiştir.

Makine öğrenmesi algoritmalarıyla, görsel öğretimi sayesinde görüntü işleme, ses öğretimi sayesinde ses işleme, nesnelerin sınıflandırılması, sayısal değer, davranış ya da benzeri sonuçların tahminlenmesi işlemlerini gerçekleştirilebilir (Şahin, 2023). Günümüzde ise makine öğrenmesi ile geliştirilen algoritmalar çeşitli alanlardan örnekler verilebilir. İnternet üzerinden daha önce araştırılan bir ürünün reklam olarak yeniden gösterilmesi, bazı film / dizi platformlarının afiş tasarımlarında, insan yüzü / parmak izi algılama, bankacılıkta güvenliği sağlama amaçlı ya da bazı tahminleme durumlarında makine öğrenmesi algoritmaları kullanılmaktadır. Yapay zekanın geleneksel algoritmalarından farkı tecrübelerine dayanarak karar verebiliyor olmasıdır. Tecrübelerini ise daha önceden deneme yanılma yoluyla elde ettiği verilerden sağlamaktadır.

Geleneksel algoritma ile yazılmış bir oyuncak araba bir kere çarptığı yere yeniden çarpabilmektedir. Ancak makine öğrenmesi ile tasarlanmış araba daha önce çarptığı yerleri hafızasına kaydederek bir daha çarpmamayı öğrenmektedir. Bu sayede sürücüsüz arabalar tasarlanabilmektedir. Büyük veriler, makine öğrenmesinin içerisinde barındırdığı istatistiksel yöntemler sayesinde analiz edilebilmektedir. Gerekli analizler yapılarak makine öğrenmesi sayesinde elle hesaplaması zor olan tahminlemeleri gerçekleştirebilmektedir (Şahinarslan, 2019). Makine öğrenmesi uygulama alanları; bankacılık ve finans hizmetlerinde, müşterilerin kredi ödemelerinin değerlendirilmesi ile gecikme olup olmayacağını tahmininde, sağlık hizmetlerinde hastaların geniş rahatsızlık ve şikayetleri incelenerek mevcut hastalığının teşhis ve tahmininde, perakende hizmetlerinde müşterilerin hangi ürünleri birlikte tercih ettiği ya da tüketimi yavaş veya hızlı olan ürünlerin tespit ve tahminlemede makine öğrenmesi algoritmalarından faydalanılmaktadır.



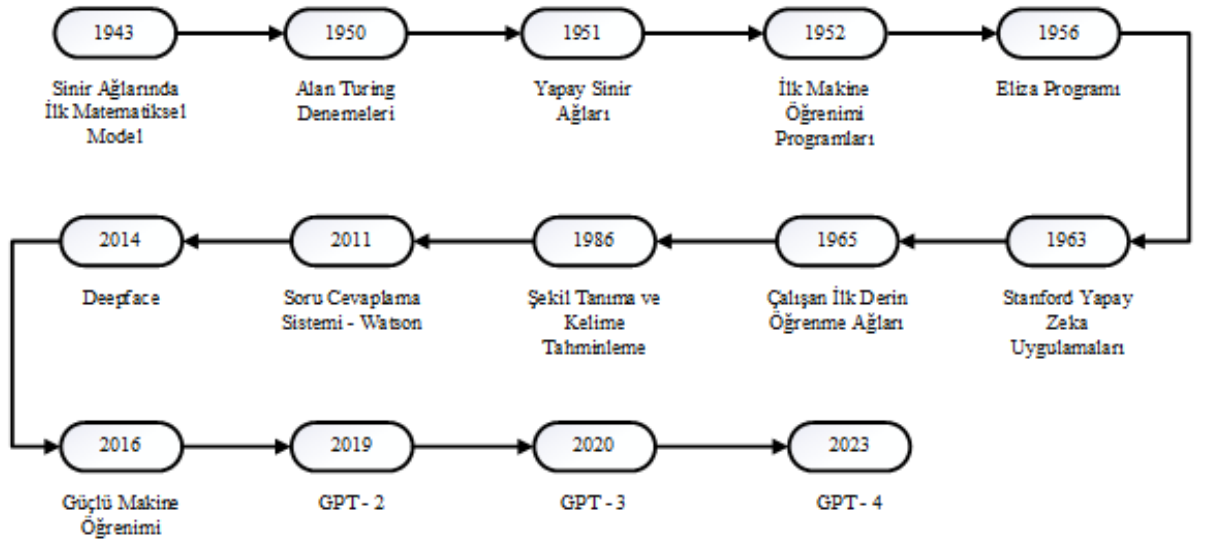
Şekil 3.2 Yapay zekada makine öğrenmesinin yeri

Yapay zekanın makine öğrenmesini, makine öğrenmesinin ise derin öğrenmeyi kapsadığını Şekil 3.2'deki gibi görselleştirilmiştir (Kurtboğan, 2023).

### 3.2.6. Makine öğrenmesi kavramının tarihsel süreci

Günümüzde sıklıkla çalışmalara konu olan ve günlük yaşantımızda da karşımıza çıkan makine öğrenmesi kavramının temeli 1940'li yıllara dayanmaktadır. Alan Turing, makinelerin öğrenebilme ihtimalini araştırmasıyla makine öğrenme terimini 1950'li yılında anmıştır. Turing denemeleri ile pek çok araştırmanın da önü açılmıştır. Yine bu senelerde, ilk makine öğrenimi programları, Dean Edmonds ve Marvin Minsky'nin yapay sinir ağları ile gerçekleştirilen bilgisayarı Stokastik Sinirsel Analog Güçlendirme Hesaplayıcısı ve Arthur Samuel'in makine öğrenmesi faaliyetleri kapsamında geliştirdiği satranç uygulaması örnek olarak verilebilir. 1956'da İngilizce diyalog kurarak insanlar ve bilgisayar programları arasındaki iletişimi sağlama amacı güdülmüştür. Eliza uygulaması psikiyatr davranışlarını taklit ederek danışanlar ile iletişim kurmuş ve onlara uygun

cevaplar vermiştir. 1963 yılında Stanford Üniversitesi'nde Yapay Zeka çalışmalarının yürütüldüğü laboratuvarı kurulmuştur. 1965'te derin öğrenme çalışmaları başlamıştır. 1986'da şekil tanıma ve kelime tahminlemelerde ilerlemeler kaydedilmiştir. 2011'de IBM tarafından soru cevaplama sistemi olan Watson adlı program geliştirilmiştir. 20. yüzyılın sonlarına doğru ise toplanmış verilerin işlenmesi ihtiyacına yönelik çalışmalar yapılmaya başlanmıştır. Bu sayede veri bilimi ortaya çıkmış ve makine öğrenme algoritmaları istenen faaliyete göre spesifik hale getirilmiştir. 1990'da e-postaların istenmeyen mailleri spam kutusuna düşmesi için algoritmalar geliştirilmiştir. 2016'da, Nvidia ve Microsoft tarafından güçlü makine öğrenimi ürünleri tanıtılmıştır. 2019'dan sonra ise yüksek parametrelili konuşma botları ortaya çıkmıştır. Son yıllarda ChatGPT gibi sohbet robotları sayesinde insan dilini insanlar kadar anlayabilme amacı güdülmeye başlamıştır.



Şekil 3.3 Makine öğrenmesi tarihsel süreci

Makine öğrenmesi sırasıyla yıllara göre gelişim süreci Şekil 3.3'te gösterilmiştir. Sinir ağlarında ilk matematiksel model kurulması ile başlayan süreç zaman içinde belirgin şekilde gelişim göstererek günümüzde GPT-4 uygulamasına kadar gelmiştir. Tarihsel süreçte son yıllarda makine öğrenmesi ile ilgili çalışmalar ivme kazanmıştır. Günümüzde yapay zeka ve makine öğrenmesi kavramları kolay erişilebilir bir konuma gelmiştir.

### 3.2.7. Makine öğrenmesi türleri

Yapay zekanın alt dallarından olan makine öğrenmesi, öğrenim algoritmaları sayesinde çıktılardaki başarıya göre performans ölçümü yapılmasını sağlamaktadır. Makine öğrenimi tahminlemeyi geçmiş tecrübelerle dayanarak gerçekleştirmektedir.

Sınıflandırmalar çıktıya bağlı olarak yapılmıştır. Örneğin denetimli (gözetimli) öğrenmede, girdiler ile amaçlara göre belirlenen çıktı arasındaki bağlantı incelenmektedir. Girdi ve çıktı verileri ele alınarak öğrenme modeli oluşturulmaktadır. Bu model sayesinde ileriye dönük tahminlemeler yapılabilmektedir. Sınıflandırma ve bağlanım denetimli öğrenme başlığı altında incelenmektedir. Denetimsiz (gözetimsiz) öğrenmede, yalnızca girdi değerleri arasındaki ilişki analiz edilerek gerekli sınıflandırmalar yapılmaktadır. Denetimsiz öğrenmede amaç, veriler arasındaki düzenlilikleri bulmaktır. Bu tip öğrenmede tek tip veriler değerlendirilmektedir. Denetimli ile denetimsiz öğrenme arasındaki fark; denetimsiz öğrenmede girdi ve çıktı verilerinin bulunmaması olarak belirtilmektedir. Girdi ve çıktı verisi olmamasına karşın benzer nitelik taşıyan veriler gruplandırma yöntemleri ile sınıflandırılmaktadır. Etiketlenmiş verilerin az, etiketlenmemiş veri sayısının fazla olduğu durumlarda denetimli ya da denetimsiz öğrenme yeterli olmayabilmektedir. Bu durumlarda yarı denetimli öğrenme yöntemi kullanılarak, az sayıda etiketlenmiş veriden yola çıkılır ve etiketlenmemiş veriler hakkında bilgi edinme amaçlanmaktadır (Kızılkaya ve Oğuzlar, 2018). Takviyeli (pekiştirmeli) öğrenme ise, denetimli ve denetimsiz öğrenmedeki gibi sınıflandırma ya da amaçlanmış bir çıktı bulunmamaktadır. Takviyeli öğrenme, birden fazla çeşitte çıktı üretilebilmektedir. Bu öğrenme çeşidi fiil düzümü olarak belirtilebilir (Atalay ve Çelik, 2017). Literatür uygulamalarında en sık denetimli ve denetimsiz makine öğrenmesi türleri kullanıldığı görülmektedir.

Makine öğrenmesi verilerin çeşidine ve problemin çözüm amacına göre farklı kullanım türlerine sahiptir. Makine öğrenmesinin dört farklı çeşidi bulunmaktadır. Denetimli makine öğrenmesi sınıflandırma ve regresyon başlıkları altında incelenir. Sınıflandırma yöntemleri Destek Vektör Makineleri, Diskrimant Analizi, Navie Bayes ve K-En Yakın Komşu algoritmaları ile örneklendirilebilir. Regresyon yöntemleri ise; Doğrusal Regresyon, Destek Vektör Regresyonu, Rastgele Orman ve Karar Ağaçlarıdır. Denetimsiz makine öğrenmesi ise kümeleme başlığı altında, K-Ortalama, Yapay Sinir Ağları, Hiyerarşik Kümeleme, Temel Bileşenler Analizi şeklinde örneklendirilmiştir. Literatür uygulamalarında en sık denetimli ve denetimsiz makine öğrenmesi türleri kullanıldığı görülmektedir. Şekil 3.4'te makine öğrenmesi çeşitleri gösterilmiştir (Şengül, 2022).

MAKİNE ÖĞRENMESİ				
Denetimli		Denetimsiz	Yarı Denetimli	Takviyeli
Sınıflandırma	Regresyon	Kümeleme		
Destek Vektör Makineleri	Doğrusal Regresyon	K-Ortalama		
Diskrimant Analizi	Destek Vektör Regresyonu	Yapay Sinir Ağları		
Naive Bayes	Rastgele Orman	Hiyerarşik Kümeleme		
K-En Yakın Komşu	Karar Ağaçları	Temel Bileşenler Analizi		

Şekil 3.4 Makine öğrenmesi çeşitleri

Makine öğrenmesi algoritmalarının uygulamasında beş ana aşama bulunmaktadır. Bu basamaklar Şekil 3.5'te gösterilmiştir.



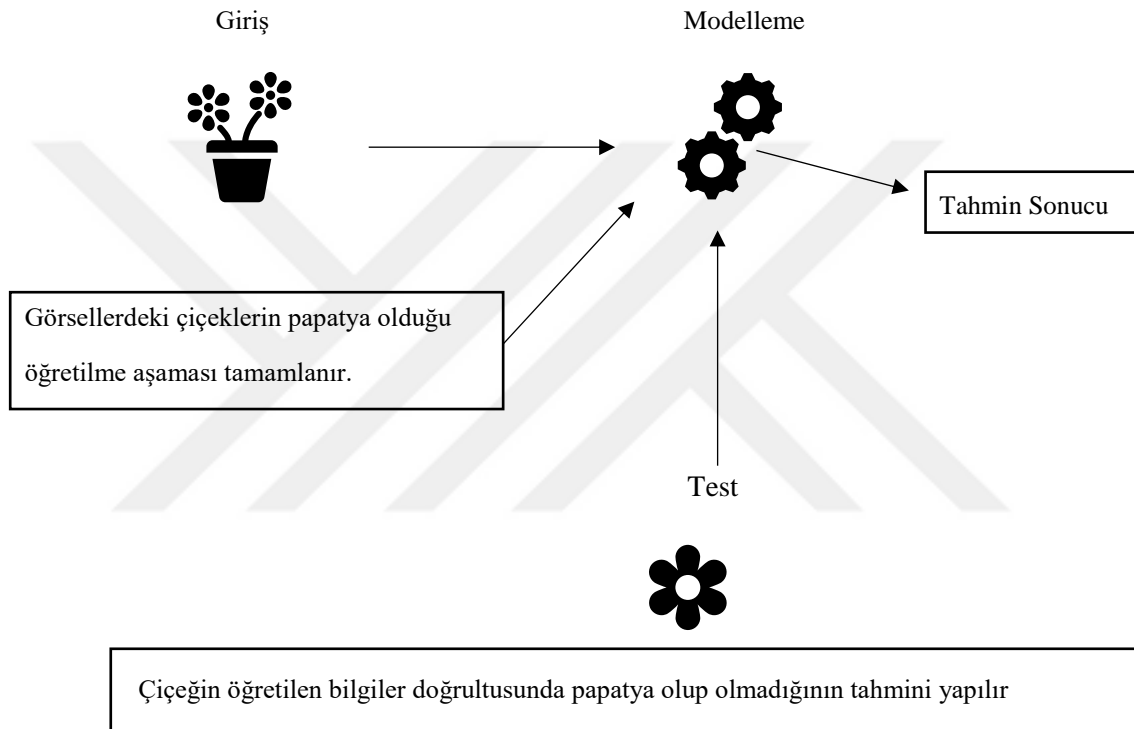
Şekil 3.5 Makine öğrenmesi aşamaları

Makine öğrenmesi aşamalarının ilk basamağını verilerin toplanması oluşturmaktadır. İkinci aşamada, veriler içerisindeki (anlamsız) uç değerler, boş (null) değerlerin elimine edilmesi, çıktıya anlam katmayacağı düşünülen niteliklerin silinmesi vb. uygulamalar ile kullanıma hazır hale getirilmesi amaçlanmaktadır. Üçüncü aşamada, makine öğrenmesi algoritmaları ile kullanılacak modeller belirlenmektedir. Model üzerinde veriler ile algoritma kurallarına uygun şekilde uygulamalar gerçekleştirilmektedir. Dördüncü adımda, model performansının değerlendirilmesi gerçekleştirilir. Bir modelde birden fazla makine öğrenmesi algoritmaları kullanılabilen ve modellerin başarı kriterlerine göre performansları değerlendirilerek karşılaştırma yapılabilmektedir. Son adım olan beşinci aşamada ise seçilen en başarılı algoritmanın başarısının artırılması hedeflenmektedir. Alternatif algoritmaların denenmesi, başarılı tahminleme yapabilmek için verilerin optimum sayıya ulaşması adına

sayısının artırılması veya azaltılması ya da geliştirilmiş farklı yöntemlerin denenmesi, model performansının artırılması konusunda örnek olarak verilebilir.

### 3.2.7.1. Denetimli öğrenme

Denetimli makine öğrenmesinde ilk aşamada, makinenin öğrenmesi beklenen eğitim seti makineye öğretilmesi için verilir. Eğitim setindeki her bir verinin, etiket adı verilen bir çıktısı bulunmaktadır. Test aşamasında ise, makinenin girdi – çıktı arasındaki ilişki analizi sayesinde girdi sunulduğunda çıktı tahminlenebilmektedir (Kurtboğan, 2023).



Şekil 3.6 Denetimli makine öğrenmesi aşamaları

Denetimli makine öğrenmesinde tahminlemeler etiketli veriler üzerinde yapılmaktadır. Tahmin ya da analizi yapılacak veriler eğitim verisi ve test verisi olmak üzere farklı yöntemler kullanılarak iki kısma ayrılmaktadır. Eğitim adımında edinilen bilgiler ile test verisi üzerinde test edilir ve doğruluğu tespit edilerek performans değerlendirmeleri gerçekleştirilmektedir.

#### 3.2.7.1.1. Regresyon analizi

Regresyon analizinde bir veya daha fazla bağımsız değişken ile bağımlı değişken arasındaki ilişkinin matematiksel olarak belirtilmesidir. Regresyon analizinde, bağımlı değişken ile bağımsız değişken arasındaki ilişkinin geçmişte gerçekleşen verileri

incelenerek bağımsız değişkenin bağımlı değişkeni ne oranda etkilediğinin değerlendirilmesi yapılmaktadır.

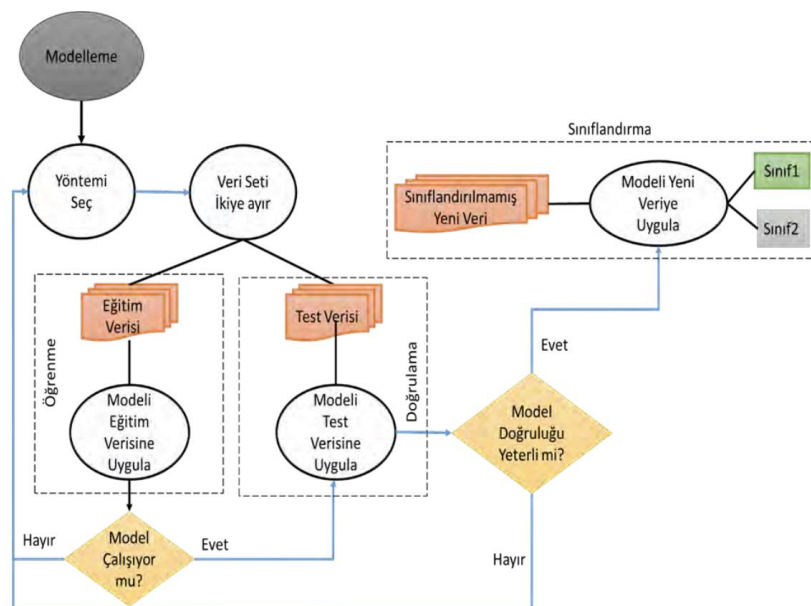
$$Y_i = \beta_0 + \beta_1 X_1 + \epsilon \quad (3.1)$$

Regresyon analizi 3.1 denkleminde  $Y_i$ , bağımlı değişken,  $X_1$  bağımsız değişken,  $\beta_0$  ve  $\beta_1$  regresyon katsayılarını ifade etmektedir.  $\beta_0$  sabit katsayı terimidir.  $\epsilon$  ise hatayı belirtmektedir (Şengül, 2022).

### 3.2.7.1.2. Sınıflandırma

Sınıflandırma ile sınıflandırılmış verilerin göz önüne alınarak yeni gözlemin hangi sınıfa dahil olacağını tahminlenmesi gerçekleştirilmektedir. Veri kümesine dahil olan gözlemlerin kategorilenmiş verilerden yola çıkarak karar süreci yürütülmektedir. Sınıflandırmaya, problemde “Uygun” ya da “Uygun Değil” şeklinde etiketlenerek sınıflandırılması örnek olarak verilebilir (Şengül, 2022).

Makine öğrenmesinde tahmin edici modellerin temelini, geçmişteki veriler (tecrübe) ve verilere ait gerçek çıktıların öğrenimi sayesinde gelecekte olması muhtemel durumlarda sonucun tahmin edilmesi oluşturmaktadır. Sınıflandırma yöntemleri ile veri setinin tamamı kategorik olarak sınıflandırılmakta ve tahminleme işlemleri gerçekleştirilmektedir. Sınıflandırma ve tahmin modellerinde sıklıkla kullanılan metotlar; karar ağaçları, yapay sinir ağları, genetik algoritmalar, K-En Yakın Komşu metodu, regresyon analizi ve Naive Bayes metodudur (Bilekdemir, 2010).



Şekil 3.7 Sınıflandırma yaklaşımı

Makine öğrenmesi algoritmalarında sınıflandırma amacıyla kullanılan algoritmaların akış şeması Sınıflandırma Yaklaşımı olarak Şekil 3.7’de belirtilmiştir (Demir ve Çalık, 2020).

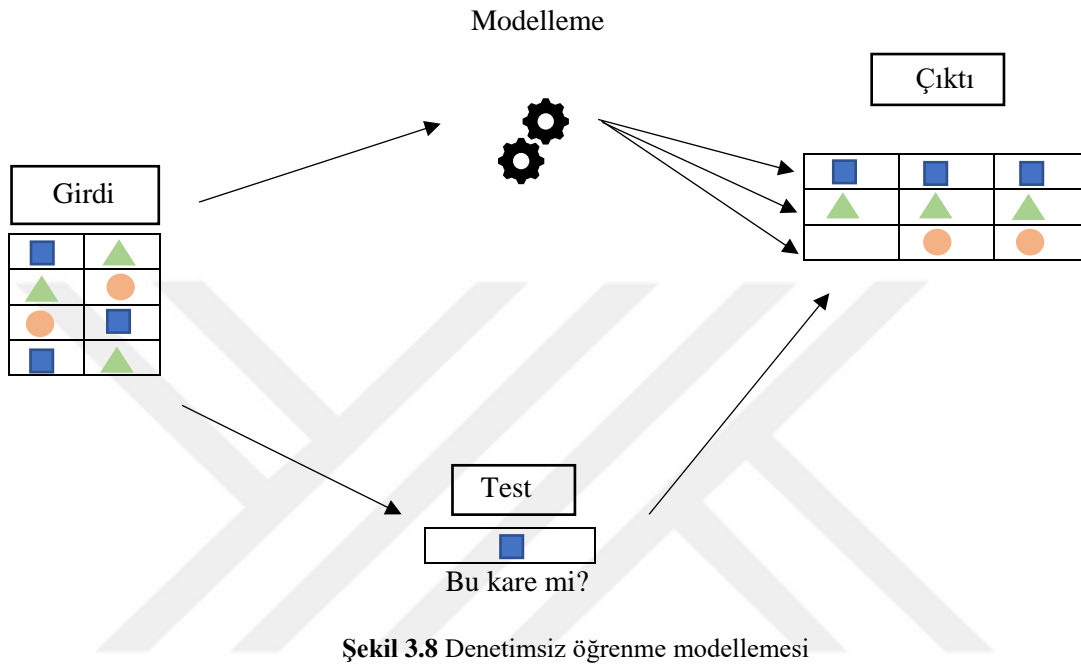
Modelleme aşaması veri setinin tamamının oluşturulduğu aşamadır. Veri setindeki, satırlar (gözlemler), sütunlar (nitelikler) oluşturulur, eksik veriler elimine edilir veya eksik veriler tahminleme gibi yöntemlerle tamamlanır. Veri setinin tamamlanmasının ardından modelde uygulanacak yöntem seçilir ve veri seti eğitim verisi ve test verisi olmak üzere ikiye ayrılır. Veri setinin ikiye ayrılmasında eğitim ve test setlerinin oluşturulması için veri setinin başından itibaren alınması, rastgele seçim, doğrusal örnekleme, tabakalı örnekleme vb. farklı yöntemler de uygulanabilmektedir. Literatürde yer alan makine öğrenmesi çalışmalarında genellikle veri setinin %70-%80 oranında eğitim seti olarak, %20-%30 oranında ise test seti olarak ayrılmakta olduğu incelenmiştir (Zilyas ve Yılmaz, 2023). Veri setinin ayrılmasından sonra, seçilen model eğitim setindeki verilere uygulanarak öğrenme işlemi gerçekleşir, aynı şekilde seçilmiş olan model test setindeki verilere de uygulanarak doğrulama/test etme işlemi gerçekleştirilir. Öğrenme işleminden sonra modelin çalışıp çalışmadığının kontrolü gerçekleştirilir, eğer model çalışmıyorsa sürecin en başına dönülerek yöntem yeniden seçilir, yöntemin çalışması halinde ise test etme aşamasına geçilir. Test etme aşamasında yeterli doğruluk oranının sağlanması gerekmektedir. Bu nedenle test aşamasından sonra model doğruluğunun yeterli olup olmadığının kontrolü gerçekleştirilir. Literatürde yapılan araştırmalara göre makine öğrenme algoritmalarının doğruluk oranlarının %70’i geçmesi başarılı bir performans gösterdiği görülmüştür (Kartal, 2020). Bu oranı sağlayamayan modelin, sürecin en başına dönülerek yeniden modelin belirlenmesi gerekmektedir. Eğer modelin doğruluğu yeterli seviyede ise modelin yeni veriye uygulanması aşamasına geçilebilir. Bu sayede sınıflandırılmamış veriler model uygulamasıyla *sınıf<sub>1</sub>* ve *sınıf<sub>2</sub>* olmak üzere sınıflandırma işlemleri gerçekleştirilmiş olunur.

### **3.2.7.2. Denetimsiz öğrenme**

Denetimsiz makine öğrenmesi algoritmalarında herhangi bir çıktı verisi bulunmamaktadır. Çıktı bilgisi ya da doğruluğu tespit edilmesi gereken tahminlenmiş veriler yer almamaktadır. Karmaşık haldeki verilerin birbirleri ile olan benzerlik ve farklılıkları göz önünde bulundurularak oluşturulan algoritmalar sayesinde

sınıflandırılmış veri seti elde edilir. Sınıflandırma sonucunda iki ya da daha fazla veri kümesi oluşturulabilir (Karaahmetođlu, 2023).

Denetimsiz öğrenmede Şekil 3.8’de de görüldüğü gibi, neden sonuç ya da girdi çıktı gibi etiketleme yapılmadan öğrenim sağlandığı makine öğrenim türüdür. Veri setindeki yapının analizi ile kümeleme ya da boyut indirgeme hedeflenmektedir (Kurtbođan, 2023).

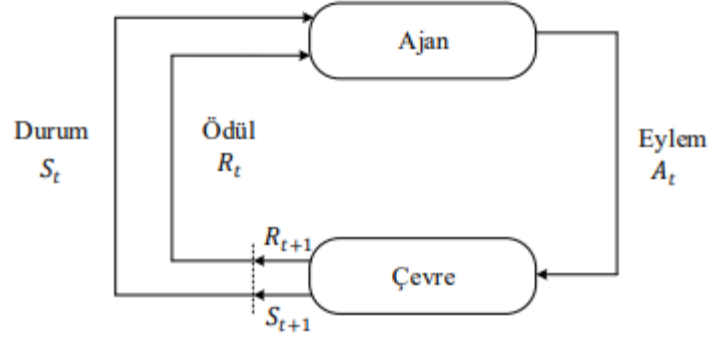


Şekil 3.8 Denetimsiz öğrenme modellemesi

Denetimsiz makine öğrenmesi algoritmalarında verilerde etiket bulunması gerekmemektedir. Denetimli öğrenmeden farklı olarak çıktıların sınıflandırılması yerine gözlem (deney) arasındaki benzerliklerin tespit edilmesi amaçlanmaktadır. Kategorilendirme ihtiyacı bulunmadığından büyük veri setlerinde genellikle denetimsiz makine öğrenmesi algoritmalarından yararlanılmaktadır (Şengül, 2022).

### 3.2.7.3. Pekiştirmeli öğrenme

Herhangi bir çıktı ya da sınıflandırma çözümü sunulamayan problemlerde kullanılan makine öğrenmesi çeşididir. Örnek olarak satranç gibi oyunlarda bir sonraki hamleyi tahminleme verilebilir. Sürekli değişen koşullar altında strateji ve taktik belirleme pekiştirmeli makine öğrenmesi algoritmaları tercih edilmektedir (Kurtbođan, 2023).



Şekil 3.9 Pekiştirmeli öğrenme yapısı

Pekiştirmeli öğrenmenin temel bileşenlerinde Şekil 3.9’da belirtildiği gibi; ajan, eylem, çevre, durum ve ödüdür (Akyol, 2023).

**Ajan:** Ajan, çevre ile etkileşime girerek, pekiştirmeli öğrenmede karar verebilen yazılım programıdır.

**Eylem:** Ajanın verdiği kararlar doğrultusunda gerçekleştirebileceği potansiyel eylemlerin kümesini belirtmektedir. Ajan, eylemler yürütüldüğü takdirde kazanacağı ödülü de tahminleyebilmektedir.

**Çevre:** Fiziksel ya da simülasyon olabilen çevre, gerçekleştirilen eylem ve toplanılan ödüller ile etkileşim içerisinde olduğu kısımdır.

**Durum:** Ajana çeşitli şekillerde gösterilebilen, çevrede bulunan durumun belirtilmesidir.

**Ödül:** Ajanın belirli durum ve eylemdeki iyiliğini belirten fonksiyondur. Çevreden gelen geri bildirim değeri büyükse uygunluğu, değer küçüklüğü ise daha az uygun olduğunu göstermektedir (Eteman, 2024).

### 3.2.8. Makine öğrenmesi algoritmaları

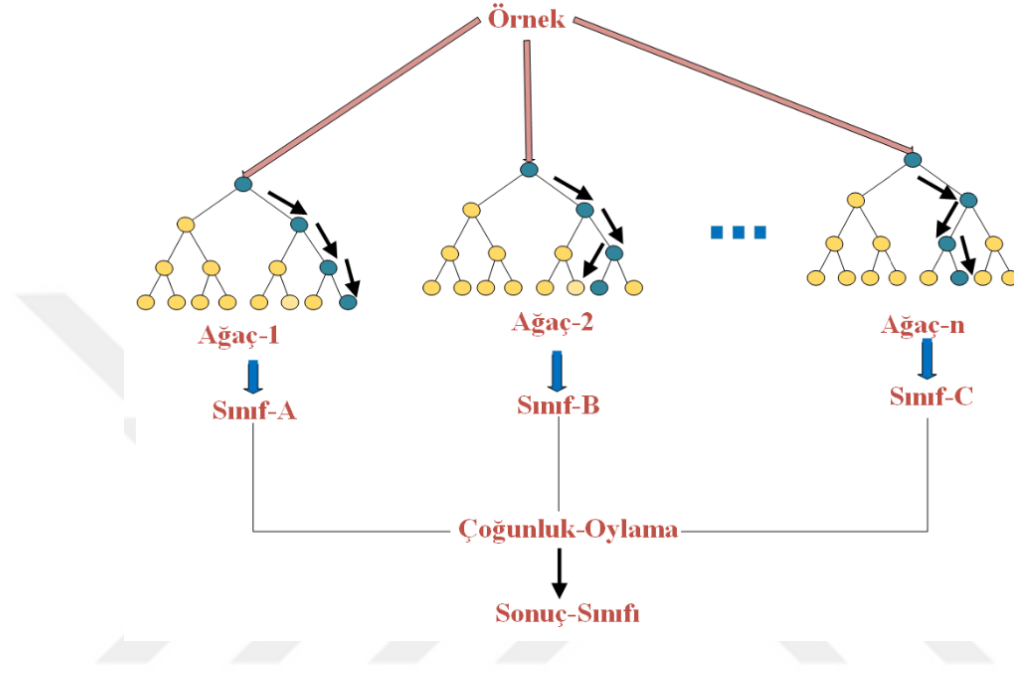
Makine öğrenmesi algoritmaları, karışık haldeki veri kümelerini analiz ederek anlamlı sonuçlar çıkarmaya yarayan yapay zekanın alt dallarından biridir. Sınıflandırma ile girdi – çıktı değerleri arasındaki ilişkiyi inceler ve sistem tarafından öğrenilen eğitim verileriyle test verileri üzerinde tahminleme yapılabilmektedir. Modelin öğrenme başarısı ve test doğruluk başarısı ölçülerek en başarılı algoritma tercih edilmektedir.

#### 3.2.8.1. Rastgele orman algoritması

Rastgele Orman Algoritmasında veriler öğrenme seti için rastgele seçilir, dallanmalar ile farklı alt karar ağaçları elde edilir. Literatürdeki araştırmalarda yüksek başarı tahmin oranı, yüksek sayıda veri ile çalışabilme, eksik veri bulunması halinde

başarılı tahmin ile tamamlama gibi avantajlardan kaynaklı olarak sıklıkla tercih edilmektedir. Tüm bu avantajların yanında, aşırı öğrenme durumu oluşabilme ihtimali de dezavantaj olarak değerlendirilebilir.

Rastgele Orman Algoritmasının dallara ayrılarak yeni ağaçlar ile sınıflandırmaların oluşturulması Şekil 3.10'da gösterilmiştir (Karaahmetoğlu, 2023).



Şekil 3.10 Rastgele orman algoritması

Eğitim aşamalarının sona ermesi ile test aşamasına geçilir ve elde edilmiş olan karar ağaçları ile sınıflandırma yapılır. Rastgele Orman sınıflandırma algoritması, karar ağaçlarına benzer şekilde veri setindeki özniteliklerin önem derecesine göre sınıflandırma önceliği belirlenmektedir (Yazıcı, 2023).

Sınıflandırma amacı ile kullanılan makine öğrenmesi algoritmalarından olan Karar Ağacı metodu bazı durumlarda ağacın veya dallanmaların doğru kurulamaması gibi nedenlerden kaynaklı olarak düşük performans gösterebilmektedir. Rastgele Orman Algoritması ise Karar Ağacı topluluğundan oluşmaktadır bu sayede Karar Ağacı Algoritmalarında karşılaşılan problemlerin çözümü oluşmuştur. Rastgele Orman metodu, sınıflandırma ve regresyon problemlerinde uygulanabilmektedir. Problemlerin amacına yönelik uyarlanabiliyor oluşu, Karar Ağacına göre daha yüksek performans gösterebilmesi, ön işlemeye gerek olmaması, veri dönüştürme ve değiştirmede ölçeklendirmeye ihtiyaç duyulmaması gibi avantajlar sunmaktadır. n adet örneklem torbalama metodu ile oluşturulmaktadır. Verilerin 2/3 oranında eğitim verisi, kalan 1/3 oranındaki veri ise test verisi olarak kullanılmaktadır.

Rastgele Orman Algoritmasında kullanılan Gini saflık ölçüsü değişimi diğer bir ifadeyle Gini kazancı formülü 3.2’de belirtilmiştir.

Rastgele Orman yönteminde, her bir Karar Ağacı birbirinden bağımsızdır ve etkilenme durumu söz konusu olmamaktadır. Ağaç oluşturma aşamasında en iyi bölünme için formülde belirtilen Gini indeksinden yararlanılmaktadır.  $T$ , eğitim veri kümesini,  $C_i$  gözlemin ait olduğu sınıfı,  $f(C_i, T) / |T|$  oranı belirlenen gözlemin  $C_i$  sınıfında olma olasılığını,  $f(C_j, T) / |T|$  ise gözlemin  $C_i$  sınıfı dışında olma olasılığını belirtmektedir.

$$\sum_{j, j \neq i} \sum_i \left( \frac{f(C_i, T)}{|T|} \right) \left( \frac{f(C_j, T)}{|T|} \right) \quad (3.2)$$

Gini formülü 3.3 numaralı formül ile ifade edilmiştir.

$$Gini = 1 - \sum_{i=1}^c (p_i)^2 \quad (3.3)$$

Formülde yer alan  $p_i$ , sınıf  $i$  için olasılığı,  $c$  ise, toplam sınıf sayısını temsil etmektedir. Gini indeksi 0 ile 1 arasında değer alabilmektedir. Rastgele Orman yöntemi ile eğitim verileri ile öğrenim tamamlanır ve test verileri üzerinde denemeler yapılarak hata oranlar tespit edilir. Hata oranı düşük olan ağacın ağırlığı yüksek, hata oranı yüksek olan ağaçlara ise düşük ağırlıklandırma yapılarak oluşturulmuş olan ağaçların ortalaması ile ortalama hata oranı tespit edilir.

### 3.2.8.2. Naive bayes algoritması

Naive Bayes algoritması, kategorik değişkenli veri modellerinde başarılı sonuçlar vermektedir. Karmaşık problemlerde, sınıflandırma işlemleri gerçekleştirme olanağı sağlayabilmektedir.

Naive Bayes,  $C$  değişkeninin,  $F$  değişkeninin özelliklerini gösterdiği tabirde, şartlı olasılıkların tamamının çarpımı 3.4’teki formül şeklinde gösterilmektedir.

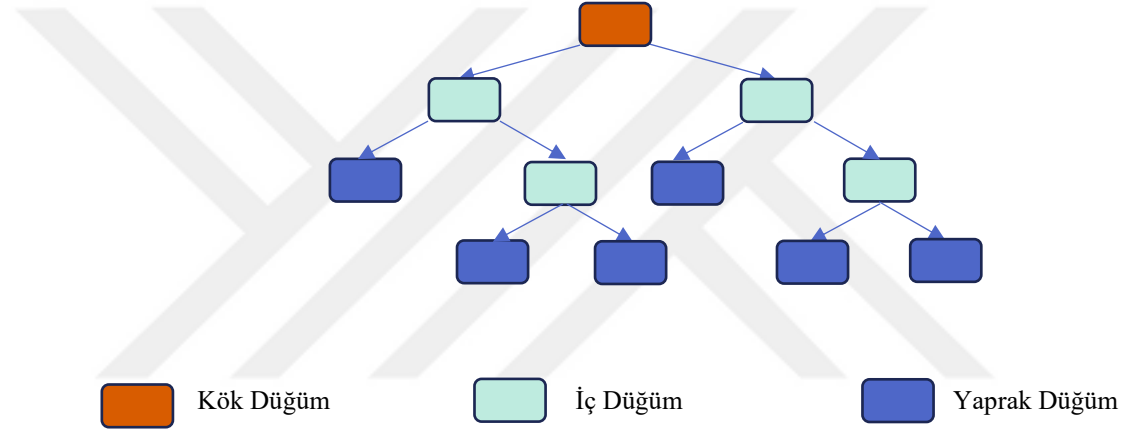
$$p(C | F_1, \dots, F_n) = \frac{P(C)p(F_1, \dots, F_n | C)}{p(F_1, \dots, F_n)} \quad (3.4)$$

Naive Bayes algoritması ile ilgili detaylar ve uygulamalar için (Yaldız, 2020) adlı çalışma incelenebilir.

### 3.2.8.3. Karar ağacı algoritması

Karar Ağacı, bir tür sınıflayıcıdır ve sıralı basit mantıksal testleri birleştiren modeldir. Her bir testte sayısal bir özelliği belirlenen değere ya da nominal bir özellik diğer dizideki olası değerlerle kıyaslamaktadır. Karar Ağacı algoritmaları, görselleştirilebilir olması, kolay anlaşılması ve yorumlanması gibi avantajlarından kaynaklı olarak sıklıkla araştırmalarda karşımıza çıkmaktadır (Yazıcı, 2023).

Karar Ağacı Algoritmasının ilk aşamasında kök düğüm ile başlar ve dallanarak Evet / Hayır yanıtları ile ilerler. Kök düğüm ile başlayan yapı, bir sonraki iç düğüm olarak adlandırılan adımda dallanarak karar verim noktasından yaprak düğümler ile son bulmaktadır. Şekil 3.11’de karar Ağacı görselleştirilmiştir.



Şekil 3.11 Karar ağacı algoritması

Karar Ağacı yapısında gereksiz dallanmaların önüne geçilmesi, güçlü bir Karar Ağacı oluşturmada ve sonuca hızlı ulaşmada önem taşır (Yıldırım, 2021).

$$I_G = 1 - \sum_{n=1}^c [(p)_n] \quad (3.5)$$


$$I_H = - \sum_{n=1}^c p_n \log_2^{p_n}, \quad p \neq 0 \text{ iken} \quad (3.6)$$

Gini endeksi ve kirlilik ölçütleri 3.5 ve 3.6 gösterilmiştir.  $p_n$ , her  $c$  sınıfına ait gözlemlerin oranını belirtir ve  $p$  değeri sıfıra eşit ise entropi değeri sıfır olarak kabul edilir.

### 3.2.8.4. Destek vektör makineleri algoritması

Doğrusal olmayan problemlerin çözümünde kullanılabilen, fazla veri olmadan da uygulanabilmesi mümkün olan optimizasyona dayalı algoritmadır. Denetimli sınıflandırma tekniklerinden Destek Vektör Makineleri, amaca göre verileri iki ya da daha fazla sınıfa ayırmada kullanılabilir. Verileri sınıflara ayırmada hiper düzlemler kullanılmaktadır. Hiper düzlemler, sınıf elemanları arasındaki uzaklıkları en yüksek olacak şekilde konumlandırılır ve hiper düzleme en yakın olarak kalan vektörler ise destek vektör olarak adlandırılmaktadır. Modellemede yüksek başarı elde edilebildiğinden literatürdeki araştırmalarda sıklıkla karşımıza çıkmaktadır.

Destek Vektör Makineleri Algoritmasının koordinat sistemi üzerinde iki doğru arasındaki uzaklığın  $b$  ile ilişkisi Şekil 3.12’de gösterilmiştir (Yang vd., 2019).



Şekil 3.12 Destek vektör makineleri

Tahminlenen verinin hangi sınıfta konumlandırılacağını belirleme amacıyla sınıflar arasında doğru çizilir. Doğrunun -1 ve +1 arasındaki kısmı margin olarak adlandırılmaktadır. Margin değerinin yüksek olması sınıfların iyi ayrıştığını göstermektedir. Margin maksimum oldukça  $w$  değeri de minimum olmaktadır.

$$y_i = \begin{cases} +1 & \text{için } wx_i + b \geq +1 \\ -1 & \text{için } wx_i + b \leq -1 \end{cases} \quad (3.7)$$

Denklemden yer alan  $w$ , hiper düzlem normali,  $x$  düzlemin yerini ve  $b$  ise bias terimini ifade etmektedir. Bias, eğilim değeri, hiper düzlemin orijine olan mesafesidir.

$$y_i(w * x_i + b) \geq +1, \forall_i, \min_{w,b} ||w|| \quad (3.8)$$

Şeklinde tek bir denklem olarak ifade edilebilmektedir. Destek vektör makinesi öğrenimi gerçekleşmesinin ardından yeni bir  $x_c$  elde edilir.  $x_c$ 'nin sınıfını belirleme amacıyla,

$$x_c \rightarrow \text{sgn} ( wx_c + b) \quad (3.9)$$

$\text{sgn}$  fonksiyonu kullanılmaktadır.  $(wx_c+b)$  sonucu negatif olduğunda -1, pozitif olduğunda ise +1 grubuna dahil olmaktadır (Ak, 2021).

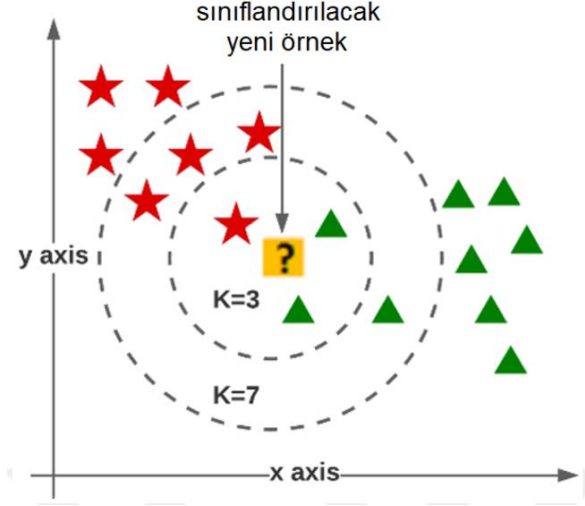
### 3.2.8.5. K-en yakın komşu algoritması

K-En Yakın Komşu Algoritmasında amaç, örnek uzayda bir noktaya mesafesi en az olan  $k$  tane noktanın belirlenmesidir.  $k$  adet nokta ile seçilen nokta arasındaki uzaklıklar incelenerek, yakınlıkları yoğunluğa göre sınıf tespit edilir. Bu algoritmada, farklı öznitelikler farklı değer aralıklarında olabileceğinden, sınıflandırıcının olumsuz etkilenmemesi için normalizasyon adımları uygulanmaktadır. Seçilen nokta sayısını ifade eden  $k$  değeri, K-En Yakın Komşu Algoritmasının en önemli parametresidir (Yazıcı, 2023). Algoritmanın aşamaları;

- $k$  tane merkez noktası tespit edilir.
- $k$  tane noktanın merkez noktasına olan uzaklıkları uzaklık hesaplama fonksiyonlarından (Öklid, Manhattan, Minkowskii vb.) yararlanılarak hesaplanır ve kümeleme işlemi gerçekleştirilir.
- Elde edilen kümeler arasında karşılaştırmalar yapılır ve küme elemanları içerisinde yer değişiminin gerekliliği olup olmadığı kontrol edilir.
- Değişim gerekliliği devam ettiği sürece algoritma adımları sürdürülür, olmadığında ise durdurulur.
- Test edilmesi istenen yeni verinin noktası belirlenerek, öğrenme veri kümelerine en yakın olduğu küme tespit edilir.

Algoritmanın başarısını doğrudan etkileyen  $k$  değerinin değiştirilerek, performansa etkisinin gözlemlenmesi zaman kaybına neden olabilmektedir. Zaman kaybının önüne geçebilmek adına  $k$ 'ya en uygun değeri verebilmek adına uzaklıklar ağırlıklandırılmaktadır.

K-En Yakın Komşu Algoritması ile sınıflandırma Şekil 3.13'te gösterilmiştir (Karaahmetoğlu, 2023).



Şekil 3.13 K-en yakın komşu algoritması

Problemin amacına göre sınıflandırma ya da regresyon tahminlerinde uygulanabilir olduğundan kullanımı yaygındır. K-En Yakın Komşu algoritmalarındaki her bir veri nokta olarak belirlenir ve  $k$  noktasına olan uzaklıkları hesaplanır, bu hesaplama sayesinde sınıflandırma işlemleri gerçekleştirilir. Uzaklık hesaplamasında Öklid eşitliği kullanımı yaygındır. 3.10 numaralı formülde gösterilen  $n$  nesne sayısını, herhangi bir  $x_1$  ve  $x_2$  değerlerine sahip olan gözlem için  $y$  bağımlı değişken tahmini yapılmak amaçlandığında Öklid uzaklık hesabı gerçekleştirilmektedir.

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.10)$$

Örnek olarak Şekil 3.13'te verilen gözlem uzayında, boy ve yaş niteliklerine göre gittiği okul sınıflandırılması K-En Yakın Komşu Algoritması ile uygulanmıştır. Oluşturulan iki boyutlu düzlemde  $x$  ekseninde boy,  $y$  ekseninde yaş olmak üzere gözlem değerleri nokta şeklinde görselleştirilmiştir. Herhangi boy ve yaş bilgisine sahip bir gözlem değeri  $k = 3$  olduğu varsayılması halinde  $k$  değeri uzaklıkların hesaplanması gereken gözlem değerini ifade etmekte olduğundan en yakın üç gözlem ile uzaklıklar hesaplanır. Ele alınan nokta (gözlem) en yakın komşuların sınıflandırılmış grubuna dahil edilmesi ile sınıflandırma işlemi gerçekleştirilmektedir (Şengül, 2022).

### 3.3. İnsan Kaynaklarında Yapay Zeka

Bu bölümde insan kaynakları alanında kullanılan yapay zeka uygulamaları ve bu uygulamaların avantaj – dezavantajlarından bahsedilecektir.

### 3.3.1. İnsan kaynaklarında yapay zeka uygulamaları

Sektör ve pazardaki gelişmeler ile birlikte yapay zeka uygulamaları işletme içerisindeki tüm departmanlarda benimsenmeye ve uygulanmaya başlamıştır. İnsan kaynakları yönetimi bünyesinde bulunan faaliyetlerde yapay zeka uygulamaları literatürdeki araştırmalarda detaylıca incelenmiştir.

Literatürdeki araştırmalarda insan kaynakları metriklerini ve bu metriklere karşılık gelen sorunlara yönelik yapay zekanın kullanım alanlarını incelenmiştir.

- İşe alma ve alınması muhtemel adayları seçme: İyi adayı bulma,
- İş başvurusu yapan adaya uygun pozisyon belirleme: Adayı doğru pozisyona yerleştirme
- Eğitim ve gelişim: Çalışana uygun ve ihtiyacına yönelik eğitim tespiti
- Performans yönetimi: Personelin performansının tespiti ve iyileştirme çalışmaları
- Ödüllendirme ve Terfi: Personeller arasında iyi performans gösteren kişiyi tespit etme
- Tutundurma: İşten çıkması olasılığı bulunan personelleri belirleme
- Çalışana sağlanan fayda: Personelin firmada devamlılığını sağlayabilmek adına faaliyetler sunma olarak listelenmiştir (Tiftik, 2021).

İnsan kaynakları yönetiminde yapay zeka destekli asistanlar da kullanılmaya başlanmıştır. Bunlara; Amelia ve Google Analytics Intelligence örnek olarak verilebilir.

Amelia, çalışanların karşılaştıkları problemleri toplamak, sınıflandırmak ve çözüm önerileri sunmaktadır. Amelia, klasik sohbet robotları gibi önceden programlanmış dar kalıplı cevaplar veren bir algoritmaya göre çok daha gelişmiş şekilde yanıtlar veren bir sistemdir. Doğal dil işleme sayesinde insana benzer şekilde konuşma yeteneğine sahip sanal bir asistandır. Amelia sohbet ettiği çalışanların yanıtlarını irdeleyerek incelemekte ve içerisinde bulunduğu ruh halini analiz etmekte, durum analizi sonucunda mutlu olması için öneriler sunmakta ya da risk altındaki çalışanları tespit edebilmektedir.

Google Analytics Intelligence, insan kaynakları uzmanının oluşturmak istediği raporlar konusunda destek olmaktadır. İşe alınan personellerin bilgileri, işgören devir oranı, terfi ve atamalar gibi farklı konular hakkında raporlar oluşturabilmektedir. Aynı zamanda insan kaynakları yetkilileri tarafından dikkatsizlik gibi hatalardan kaynaklı yanlışlıkların da önüne geçebilmek adına öneriler sunmaktadır. Maaş hesaplamalarındaki

yanlılıkları, işte devamsızlık yapılması gibi olağan dışı durumlarda yetkilileri uyarma ve öngörülerde bulunma imkânı sunmaktadır.

### 3.3.2. İnsan kaynaklarında yapay zekanın avantajları ve dezavantajları

İnsan kaynaklarında yapay zekanın kullanılmasında çok sayıda avantaj ve dezavantaj bulunmaktadır. (Kambur, 2021; Tiftik, 2021; Oruçoğlu, 2022) yaptıkları çalışmalarında bu avantaj ve dezavantajlardan detaylı olarak bahsetmiştir. Çalışmalar doğrultusunda Tablo 3.6'daki şekilde özetleri listelenmiştir.

**Tablo 3.6** İnsan kaynaklarında yapay zekanın avantaj ve dezavantajları

<b>Avantajlar</b>	<b>Dezavantajlar</b>
Zaman faydası ile rekabet üstünlüğü sağlar.	Tahminleme sonuçlarının etkili olabilmesi için büyük veri setlerine ihtiyaç duyulur.
İşe alım aşamalarında, hız, kontrol ve standardizasyon sağlar.	İnsan faktörü oldukça karmaşık olduğundan tahmin başarı yüzdeleri düşük olabilir.
Ön eleme aşamasında makine öğrenmesi destekli video mülakatlar zaman tasarrufu sağlar.	Yapay zeka konularında yetkin ve gerekli niteliklere sahip personel gerekliliği bulunur.
İşe alım yetkilisinin adayın etnik özellikleri nedeniyle önyargıya varmasının önüne geçilir.	Verimliliğin sağlanması adına kullanılan büyük verilerin gizliliğinin sağlanamaması endişesi ortaya çıkarır.
Performans değerlemede birim yöneticilerinin kişisel görüşlerinden kaynaklı pozitif ya da negatif ayrımcılık durumları önlenir.	Halihazırda bulunmayan ancak değerlendirilmesi gereken verilerin toplanması ve işlenmesi zaman kaybına neden olur.
Çalışanların geliştirilmeye açık yönlerinin yapay zeka ile tespit edilerek doğru eğitimin doğru zamanda verilerek devamlılığı sağlanır.	İşe alım yetkilileri tarafından veri setleri oluşturma aşamasında taraflı davranılması geleceğe dair tahminlemelerde de taraflılık bulunması riski taşır.
Bordrolama, hukuki süreçlerin takibi, iş alım ve ayrılma prosedürlerinde hata payının en aza indirilmesini sağlar.	Yapay zeka yatırımları, zaman ve maliyet açısından sürdürülebilirliği olumsuz etkilemektedir.
Rutin işlerin otomatik hale getirilmesi sayesinde insan kaynakları yetkililerinin diğer İK metriklerine kaliteli vakit ayırabilmesini sağlar.	Makine öğrenimi aşamasında yanlış öğrenim nedeniyle karar alma mekanizmasını olumsuz etkileme olasılığı bulunur.

## 4. BULGULAR

Bu bölümde araştırma kapsamında incelenecek olan problemin tanımı, probleme dahil olan verilerin tanımlanması, kullanılan programlar ve algoritmalar hakkında bilgiler, algoritmaların problem üzerinde test edilmesi ve karşılaştırılarak yeni tahminlemelerin gerçekleştirilmesi üzerinde çalışılmıştır.

### 4.1. Demir-Çelik Sektöründe Uygulama

Yapılan araştırmada yapay zeka alt dallarından olan makine öğrenme algoritmalarından yararlanarak, geçmişte istifa etmiş çalışanların özellikleri incelenerek, mevcuttaki veya istihdam edilmesi planlanan adayların gelecekte istifa etme olasılığı tahminlenecektir. Çalışmada aynı zamanda işten ayrılma durumu ortaya çıkmadan önce önlem alma konusu ele alınacaktır. Bu sayede istihdam edilme aşamasında istifa etme olasılığı yüksek olan adayın işe alım süreci askıya alınabilecektir. Makine öğrenmesi algoritmaları Python programlama dilinde ve Knime paket programında uygulanacaktır. Mevcut organizasyon bünyesinde çalışmaya devam eden personellerden işten ayrılma olasılığı bulunan personeller için de tutundurma çalışmaları yapılarak istifa durumunun önüne geçilmesi sağlanabilecektir.

#### 4.1.1. Verilerin tanımlanması

Çalışanların görevinden istifa etme kararını almasında etkili olabilecek iç ve dış olmak üzere pek çok farklı etmen bulunmaktadır. Bu çalışmada personellerin işten istifa etmesinde önemli rol oynayabilecek etmenler ele alınmıştır. Değerlendirmeye alınan nitelikler ile işten istifa edip etmediği kontrol edilerek gelecekteki istifa durumunun tahmin edilmesi amaçlanmıştır. Nitelikler, kişisel deneyim ve insan kaynakları fonksiyonlarında deneyimli karar vericiler tarafından ortak görüşler doğrultusunda belirlenmiştir.

**Pozisyon:** Çalışanın unvanını temsil etmektedir. Veri setinde; Formen, Genel müdür, İşçi, Kıdemli mühendis, Kıdemli uzman, Müdür, Müdür yardımcısı, Mühendis, Şef, Uzman, Uzman Yardımcısı ve Vardiya amiri olmak üzere on iki farklı pozisyon türü bulunmaktadır.

**Kıdem:** Kıdem çalışanın işyerinde fiilen çalıştığı süreyi belirtmektedir. İşten ayrılan personeller için işten ayrılış tarihinden işe giriş tarihinin çıkarılması ile elde

edilmiştir. İşe devam eden personeller için ise kıdem, temsili olarak cari yılın son günü 31.12.2023 tarihinden işe giriş tarihinin çıkarılması ile elde edilmiştir.

**Yaş:** Çalışanların yaşını göstermektedir. Yaş, işten ayrılan personeller için işten ayrılış tarihinden doğum tarihinin çıkarılması ile elde edilmiştir. İşe devam eden personeller için ise yaş, temsili olarak 31.12.2023 tarihinden doğum tarihinin çıkarılması ile elde edilmiştir.

**Doğum Yeri:** Çalışanların doğum yerini belirtmektedir. Veri setinde 68 farklı şehir bulunmaktadır.

**Medeni Durum:** Çalışanların medeni durumunu belirtmektedir. Evli ya da bekar olmak üzere iki alternatif bulunmaktadır.

**Çocuk Sahibi:** Çalışanların çocuk sahibi olup olmadığını göstermektedir. Çocuk sahibi olan çalışanla “Evet”, olmayanlar ise “Hayır” olarak gösterilmiştir.

**Engellilik:** Çalışanların engelli olup olmadığı ve engelli olması durumunda kaçınıcı dereceden engelli olduğunu belirtmektedir. Engelli olmayan çalışanlar “Yok” olarak girilmiştir, engelli olan çalışanların ise ikinci derece, üçüncü derece engelli şeklinde açıklanmıştır.

**Emeklilik:** Çalışanların emeklilik durumunu göstermektedir. Emekli olan personeller “Emekli”, emekli olmayan personeller ise “Normal” şeklinde ifade edilmiştir.

**Tehlike Durumu:** Demir çelik sektörü iş sağlığı ve güvenliği bakımından yüksek risk barındırdığından tehlike durumu yüksektir. İşin yükü ve riski değerlendirilerek yüksek risk taşıyan pozisyonlar “Çok Tehlikeli”, diğer pozisyonlar ise “Tehlikeli” olarak değerlendirilmiştir.

**Eğitim Düzeyi:** Çalışanların eğitim seviyesini belirtmektedir. Personellerin eğitim düzeyleri; ilköğretim, lise (düz lise, açıköğretim lisesi, Anadolu lisesi vb.), meslek lisesi, önlisans, lisans ve yüksek lisans olmak üzere veri setinde altı farklı öğrenim düzeyi bulunmaktadır.

**Maaş Düzeyi:** Çalışanların almış olduğu ücret seviyesini göstermektedir. Çok düşük, düşük, orta, yüksek ve çok yüksek olmak üzere beşli ölçek tercih edilmiştir. Düzeyler, işten ayrılan personeller için çalışanların işten ayrıldığı tarihteki maaşının yine aynı dönemdeki asgari ücrete oranlanması ile belirlenmiştir. İşten ayrılmayan personeller için ise mevcut ücretlerinin 2023 güncel asgari ücrete oranlanması ile elde edilmiştir. Oranlar küçükten büyüğe doğru sıralanarak çok düşükten çok yükseğe doğru sıralanmıştır. Beyaz yaka personellerin maaşları aynı şekilde alınmış, mavi yaka personellerin ise ücretleri saatlik şeklinde ödendiğinden, mavi yaka çalışanların ücretli

otuz günlük bir ay şeklinde 225 saat ile saatlik ücretinin çarpılması ile aylık ücrete çevrilmiştir. Şirket politikası gereği ücret gizliliği saklı tutulduğundan gerçek veriler kullanılmış ancak oran kullanılması tercih edilmiştir.

**Yaka Türü:** Şirket bünyesinde çalışanların pozisyonlara göre beyaz ya da mavi yaka olmak üzere iki farklı şekilde sınıflandırılmıştır. Beyaz yaka personeller, uzman, mühendis, şef, formen, müdür vb. mavi yaka personeller ise işçiler şeklinde örneklendirilebilir. Beyaz yaka çalışanlar aylık ücretli, mavi yaka personeller ise saatlik ücretli şekilde çalışmaktadır.

**Avans:** Çalışanların şirketten nakit avans talep edip etmediğini ifade etmektedir. Sağlık sorunu vb. nedenler ile çalışanların talep etmiş olduğu avansın var olup olmadığı belirtilmiştir. Hiç avans talep etmeyen personeller 0 şeklinde gösterilmiştir. 0 ile 9 arasında avans talebi bulunmaktadır.

**İcra:** Çalışanın icra dava dosyasının bulunup bulunmadığını göstermektedir. İcrası bulunmayan personeller “Yok”, olanlar ise “Var” şeklinde ifade edilmiştir.

**İstifa Mı:** Çalışanın işten ayrılışının istifa olup olmadığını belirtmektedir. İşine devam eden ve zorunlu nedenlerle (askerlik, emeklilik, evlilik vb.) işten ayrılan personeller “Hayır”, belirsiz süreli iş sözleşmesinin işçi tarafından feshi, ve deneme süresinde belirsiz süreli iş sözleşmesinin işçi tarafından feshi şeklinde çıkış kodu bulunan personeller ise “Evet” şeklinde gösterilmiştir. İstifa mı sütunu veri setinin çıktısı şeklinde belirtilmektedir, veri setinin etiketi niteliğini taşımaktadır.

Veri setinde SAP sistemine eksik bilgi kayıtları nedeniyle makine öğrenimi için birleştirilen veriler arasında 13 adet satır silinmiştir. 14 adeti nitelik 1 tanesi ise çıktı (etiket) olmak üzere toplamda 15 tane sütun, 2318 adet satır, 34.770 adet veri bulunmaktadır. Tabloda işlenen verilerin örnek olarak yirmi adet satırın görüntüsü Tablo 4.1’de verilmiştir. Verilmiş olan satırlardaki veriler veri gizliliği politikası gereği temsili şekilde gösterilmiştir, makine öğrenmesi algoritmalarında ise gerçek veriler işlenmiştir.

Tablo 4.1 Veri seti örneđi

Sıra No	Pozisyon	Kıdem	Yaş	Doğum Yeri	Medeni Durum	Çocuk Sahibi	Engellilik	EMEKLİLİK	TEHLİKE DURUMU	Eğitim Düzeyi	Maaş Düzeyi	Yaka Türü	Avans	İcra	İşten Ayrıldı	İstifa Mı
1	Müdür	7,09	50,08	KASTAMONU	Evli	Evet	Yok	Normal	Tehlikeli	İlköğretim	ÇOK YÜKSEK	Beyaz Yaka	0	Yok	İşten Ayrıldı	Hayır
2	İşçi	4,00	27,89	OSMANİYE	Evli	Evet	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet
3	İşçi	3,30	27,32	OSMANİYE	Bekar	Hayır	Yok	Normal	Tehlikeli	İlköğretim	DÜŞÜK	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
4	İşçi	3,67	28,45	OSMANİYE	Bekar	Hayır	Yok	Normal	Tehlikeli	İlköğretim	DÜŞÜK	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet
5	Kıdemli Uzman	14,46	38,02	OSMANİYE	Evli	Evet	Yok	Normal	Tehlikeli	Lisans	YÜKSEK	Beyaz Yaka	0	Yok	Etkin	Hayır
6	İşçi	8,36	34,40	OSMANİYE	Evli	Evet	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
7	İşçi	14,46	40,36	OSMANİYE	Evli	Evet	Yok	Normal	Tehlikeli	Lise	ORTA	Mavi Yaka	0	Var	Etkin	Hayır
8	Uzman Yardımcısı	3,72	26,41	HATAY	Evli	Evet	Yok	Normal	Tehlikeli	Lisans	YÜKSEK	Beyaz Yaka	0	Yok	İşten Ayrıldı	Evet
9	İşçi	2,98	28,09	HATAY	Bekar	Hayır	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet
10	Formen	14,46	52,41	OSMANİYE	Evli	Hayır	Yok	Emekli	Tehlikeli	Meslek Lisesi	ÇOK YÜKSEK	Beyaz Yaka	0	Yok	Etkin	Hayır
11	İşçi	3,67	28,81	KAHRAMANMARAŞ	Bekar	Hayır	Yok	Normal	Çok Tehlikeli	İlköğretim	DÜŞÜK	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
12	İşçi	7,32	33,53	OSMANİYE	Evli	Evet	Yok	Normal	Çok Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
13	Formen	14,46	40,24	OSMANİYE	Evli	Evet	Yok	Normal	Tehlikeli	Önlisans	ÇOK YÜKSEK	Beyaz Yaka	0	Yok	Etkin	Hayır
14	İşçi	12,54	43,70	KAHRAMANMARAŞ	Evli	Evet	3. Derece Engelli	Normal	Tehlikeli	Lisans	YÜKSEK	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
15	İşçi	8,33	35,10	HATAY	Evli	Evet	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Hayır
16	İşçi	8,31	31,31	OSMANİYE	Evli	Evet	Yok	Normal	Çok Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet
17	İşçi	14,46	38,42	HATAY	Evli	Evet	Yok	Normal	Tehlikeli	Meslek Lisesi	YÜKSEK	Mavi Yaka	0	Yok	Etkin	Hayır
18	İşçi	3,03	29,85	İSTANBUL	Evli	Evet	Yok	Normal	Çok Tehlikeli	İlköğretim	DÜŞÜK	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet
19	Formen	14,46	39,58	ANKARA	Evli	Hayır	Yok	Normal	Tehlikeli	Önlisans	ÇOK YÜKSEK	Beyaz Yaka	0	Yok	Etkin	Hayır
20	İşçi	2,87	28,37	HATAY	Bekar	Hayır	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	İşten Ayrıldı	Evet

#### 4.1.2. Kullanılacak programların belirlenmesi

Makine öğrenmesi algoritmaları farklı avantajlar sunması nedeniyle hem Knime paket programında hem de Python programlama dilinde uygulanmıştır. Bu sayede başarı kriterlerine göre doğruluk oranları farklı algoritmalar ve farklı programlar üzerinden karşılaştırmalar yapılarak değerlendirilebilecektir.

Knime açık kaynak kodlu ücretsiz bir yazılımdır ve veri bilimi, yapay zeka, makine öğrenmesi gibi disiplinlerin uygulanmasına imkan sunmaktadır. Knime, uçtan uca verileri değerli, yorumlanabilen ve herhangi bir amaca yönelik hizmet edebilecek hale getirilmesini sağlamaktadır. Knime, nodların sürükle bırak yöntemi ile akış oluşturulması ile çalışmaktadır (Şeker ve Erdoğan, 2018). Knime'nin kod bilgisi ya da ileri bilgisayar kullanım becerileri gerektirmemesi gibi nedenlerden veri bilimi alanında yeni olan kişiler veya yapay zeka, makine öğrenmesi alanlarında başlangıç düzeyinde olan araştırmacıların kullanımına elverişlidir. Knime içerisinde, veri madenciliği algoritmaları, makine öğrenmesi paketlerini güçlü şekilde desteklemektedir. Knime, genişletilebilirdir, esnektir, kullanımı ve öğrenimi kolaydır, hatasız çalışabilir, dökümantasyon yapabilir, eklenebilir paketler sunabilir, istatistiksel hesaplamalar yapabilir, veri analizi, önişleme, sınıflama, kümeleme, birliktelik kuralları çıkarımı, nitelik seçimi gerçekleştirebilir.

Knime yazılımı, istatistiksel değerlendirmelerin yapılmasını basit, sade ve anlaşılır yapısı ve arayüzü ile kullanıcı dostudur. Knime, Excel, csv vb. dosyaların içeri aktarılması ve okunması konusunda Excel reader vb. nodlar ile mümkün kılmaktadır. Excel dosyasındaki verilerin değerlendirilmesi, görselleştirilmesi histogram, dağılım grafikleri ile sağlanabilmektedir.

Python, diğer yazılım dillerine göre yazım biçimi açısından daha kolaydır ve herhangi bir derleyiciye de ihtiyaç bulundurmamaktadır. Python programlama dili, ücretsizdir, açık kaynak kodludur ve içerisinde pek çok farklı kütüphane bulunmaktadır. Python, programlama dili uygulama kolaylığı açısından Jupyter Notebook ve makine öğrenimi, veri bilimi gibi alanlarda kullanımına yönelik Anaconda üzerinden de kullanılabilir (Aydoğan vd., 2024). Python, bilimsel, mühendislik ve akademi alanlarında hesaplama işlemlerinde 2000'li yılların başından itibaren kullanıma başlanmış ve günümüzde de en sık kullanılan diller arasında yer almaktadır.


Python, programlama dili lisans sorunu yaşanmaması sayesinde özgür olması, öğrenilebilirlik açısından kullanımının kolay olması, yorumlanabilen bir dil olması ile etkileşimli olması, temel paradigmaları sahip olduğundan nesne yönelimli programlamayı desteklemesi, genel topluluklar tarafından sıklıkla kullanılan programlama dili olması, bilimsel araştırmalara yönelik çalışmalar yürüten kişilerin, barındığı kütüphanelerin ve araçlarının geniş olması, öğrenme kaynaklarının fazla ve erişilmesi kolay olması, kullanım yelpazesinin geniş olması ve kullanıcı topluluklarının fazla olması, verimli, güvenilir ve hızlı hizmet sunabilmesi, otomasyon ile çalışabilme esnekliği sunması, büyük veri (Big Data), yapay zeka, makine öğrenmesi, bulut bilişim gibi günümüz yeniliklerine uyumlanması, çok amaçlı bir programlama dili olması, oyun ve internet sitesi geliştirilebilmesi, makine öğrenmesi ve derin öğrenme uygulamalarına elverişli olması, veri bilimi, veri analizi, veri görselleştirme imkanları sunar.

#### **4.1.3. Verilerin değerlendirilmesi**

Knime paket programı üzerinden, nokta grafiği, kutu diyagramı, pasta grafiği ve histogram gibi pek çok farklı veri görselleştirme imkanı sunması sayesinde veriler analiz edilebilmektedir. Verilerin görselleştirilmesi, verilerin daha yakından tanınması ya da verilerin konu alanında uzman olmayan kişilerin de anlayabilmesi açısından önem taşımaktadır.

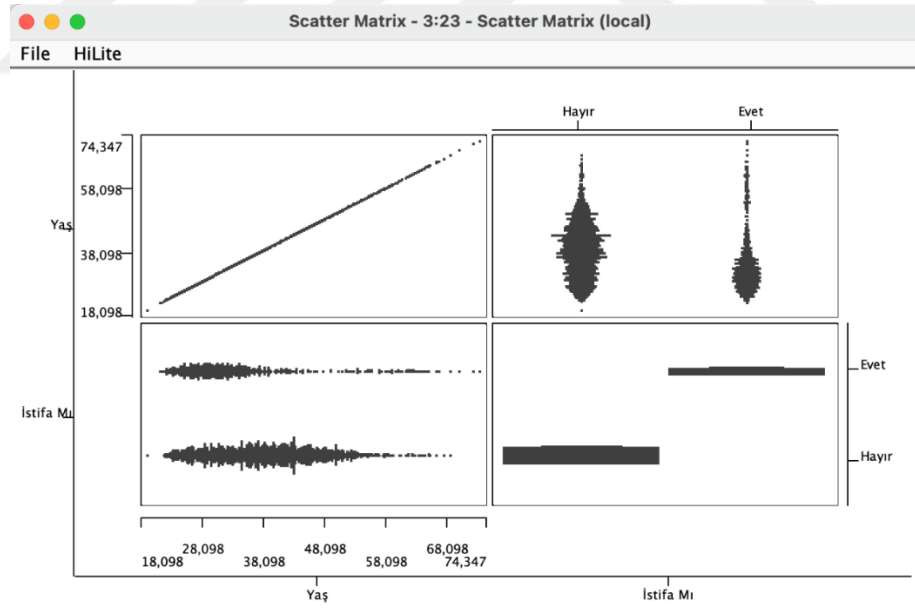
Verilerin anlamlı olabilmesi, eksik verilerin tamamlanması vb. işlemleri kullanılmaması adına veri eksikliği bulunan satırlar veri hazırlığı aşamasında elimine edilmiştir. Kodlama esnasında ise yeniden 2318 adet satır incelenerek herhangi boş (null) değer olup olmadığı kontrol edilmiştir. Kontrol sonucunda tüm nitelikler sıfır değerine sahip olduğu görülmüştür, bunun sonucunda veri setinde herhangi boş değer olmadığı yorumu yapılabilmektedir.

Veri setinde niteliklerde sahip olunan değerlerin birbirleri ile aynı olan satır (gözlem) olup olmadığının kontrolü sağlanmıştır. Niteliklerin altında herhangi bir satırın bulunmaması yinelenen satır bulunmadığının göstergesi niteliğini taşımaktadır.



Şekil 4.1 Verilerin nokta grafiği

Şekil 4.1’de x ekseninde pozisyonlar, y ekseninde ise kıdemler gösterilmiştir. Bu sayede hangi pozisyonların ne kadar süre kıdeme sahip olduğu görselleştirilmiştir. Pozisyonlar; Formen, Genel müdür, İşçi, Kıdemli mühendis, Kıdemli uzman, Müdür, Müdür yardımcısı, Mühendis, Şef, Uzman, Uzman Yardımcısı ve Vardiya amir olarak 12 adet sıralanmış, kıdem ise 0’dan başlayarak 15 yıla kadar devam ettiği görülmüştür.



Şekil 4.2 Matrix grafiği

Scatter Plot Matrisi ile iki değişken arasındaki ilişkinin serpilme diyagramı Şekil 4.2’de görselleştirilmiştir. Knime üzerinden Include (Yeşil alan)’a dahil edilen nitelikler arasında inceleme yapılabilmektedir. Bu görselde “Yaş” ile “İstifa Etme” durumu arasındaki ilişki incelenmiştir. Yaş aralıkları arasında istifa etme durumu incelendiğinde

genç grup olarak belirtilebilecek olan 18-35 yaş aralığında istifa oranının daha yüksek olduğu yorumlanabilmektedir. Bu durumda yaşın küçük olması istifa etme olasılığını arttırdığı öngörüsünde de bulunulabilir.

**Tablo 4.2** Knime verilerin tablolaştırılması

NİTELİK	Veri Değerleri	İSTİFA DURUMU	
		Evet	Hayır
Avans	Veri Sayısı	524	1130
	Ortalama	0,01718	0,04361
	Std. Sapma	0,39317	0,29476
	Oran	28%	72%
Kıdem	Veri Sayısı	524	1330
	Ortalama	2,88025	5,79305
	Std. Sapma	2,64342	4,79789
	Oran	28%	72%
Yaş	Veri Sayısı	524	1130
	Ortalama	33,38206	39,1367
	Std. Sapma	10,01742	8,85609
	Oran	28%	72%

Tablo 4.2’de Naive Bayes algoritmasının öğrenme düğümü ile veri incelemesi yapmam mümkündür. Veri setinde toplam 2318 adet veri bulunmaktadır. Naive Bayes algoritmasının öğrenim ve test seti olmak üzere iki sınıfa ayrılmıştır. Bu veri incelemeleri verinin %80’ini oluşturduğundan 524 istifa etme, 1330 istifa etmeme durumu olmak üzere  $2318 \cdot 0,8$  olarak 1854 adet veri incelenmiştir.

Verilerin incelenmesi esnasında bazı nitelikler nitelikteki alternatif sayısının fazla olması nedeniyle gösterilememektedir. Bu çalışmada yalnızca doğum yeri niteliği çok çeşitli veri olması nedeniyle atlanmış ve incelemeye alınamamıştır. Çıktı / etiket olarak tüm öğrenme algoritmalarında istifa etme durumu seçildiğinden incelenen tablolarda yer alan tüm tablolarda da “Evet”, “Hayır” olmak üzere sütun ya da satırlarda değerlendirmeye alınmıştır.

Avans verisi için sütunda istifa etme durumu evet ve Count satırında ise 524 adet “Evet”, 1330 adet “Hayır” olduğu belirtilmiştir. Normal dağılıma (Gaussian Distribution) göre Mean satırında istifa etme durumunun evet olduğu verilerin avans ortalamasının 0,017, hayır olan verilerde ise ortalama 0,04 olduğu görülmüştür. Normal dağılıma (Gaussian Distribution) göre (Std. Deviation) standart sapma Evet durumu için 0,39, Hayır için ise 0,29’dur.

Tablo 4.2'nin ikinci kısmında yer alan Kıdem kriteri için ise istifa etme durumunun ortalamaya göre değişimi gösterilmiştir. Eğitim setindeki toplam 1854 adet veriden yaklaşık %72'lik kısmı istifa etmemiş ve kıdem ortalamasının 5.79, standart sapmasının 4.79 olduğu görülmüştür. Verinin kalan %28'lik kısmı ise istifa etmiş ve kıdemi ise ortalaması 2.88 ve standart sapması ise 2.64'tür.

Son bölümde ise sayısal verilerden oluşan yaş kriterinin istifa etme ya da etmeme durumu için sayı değerleri, ortalamaları ve standart sapmaları gösterilmiştir. Yaşın ilerlemesi istifa etme durumunu düşürdüğü gözlemlenebilmektedir.

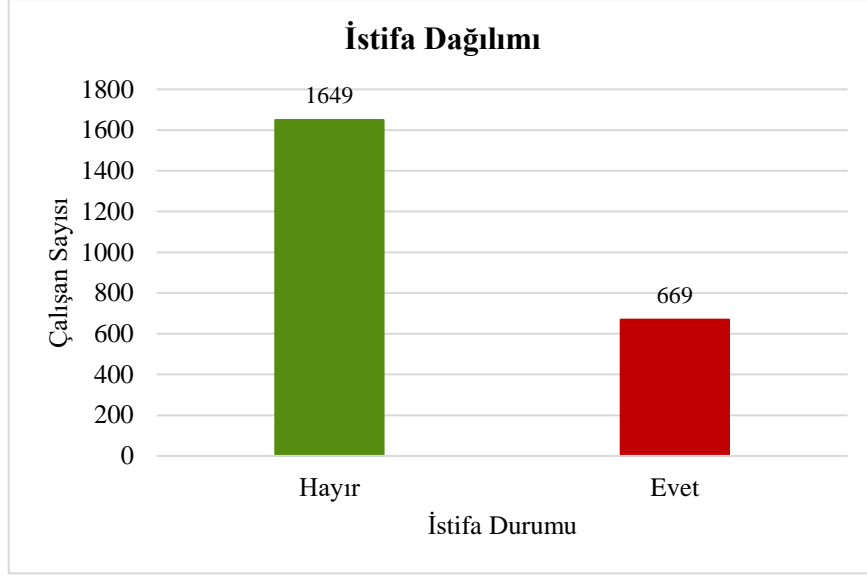
**Tablo 4.3** Knime verilerin tablolaştırılması-2

NİTELİK	Durum	İSTİFA DURUMU		Oran
		Evet	Hayır	
Emeklilik	Emekli	50	109	9%
	Normal	474	1221	91%
Medeni Durum	Bekar	165	238	22%
	Evli	359	1092	78%
Tehlike Durumu	Tehlikeli	461	1194	89%
	Çok Tehlikeli	63	136	11%
Yaka Türü	Beyaz Yaka	132	344	26%
	Mavi Yaka	392	986	74%
Çocuk Sahibi	Evet	304	981	69%
	Hayır	220	349	31%
İcra	Var	26	132	9%
	Yok	498	1198	91%
Engellilik	1. Derece Yakını E.	0	6	0%
	2. Derece E.	3	9	1%
	3. Derece E.	8	23	2%
	3. Derece Yakını E.	0	2	0%
	Yok	513	1290	97%
Eğitim Düzeyi	Lisans	16	79	5%
	Lise	26	120	8%
	Meslek Lisesi	47	290	18%
	Yüksek Lisans	0	8	0%
	Önlisans	43	209	14%
	İlköğretim	392	624	55%
Maaş Düzeyi	Düşük	142	228	20%
	Orta	88	293	20%
	Yüksek	66	307	20%
	Çok Düşük	146	222	20%
	Çok Yüksek	82	280	20%

**Tablo 4.3** Knime verilerin tablolaştırılması-2 (Devamı)

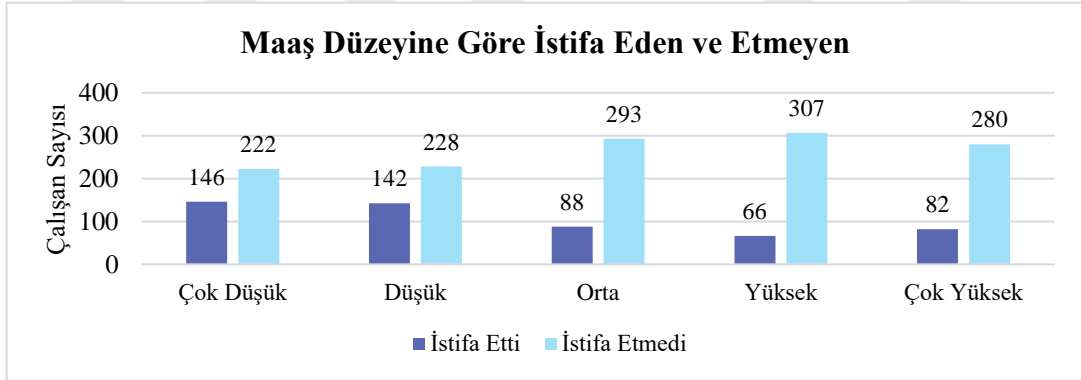
NİTELİK	Durum	İSTİFA DURUMU		Oran
		Evet	Hayır	
Pozisyon	Formen	36	129	9%
	Genel Müdür	0	1	0%
	Kıdemli Mühendis	3	5	0%
	Kıdemli Uzman	0	5	0%
	Müdür	3	26	2%
	Müdür Yardımcısı	0	12	1%
	Mühendis	23	41	3%
	Uzman	4	18	1%
	Uzman Yardımcısı	1	9	1%
	Vardiya Amiri	2	10	1%
	İşçi	446	1042	80%
	Şef	6	32	2%

Emeklilik niteliği için 524 adet istifa Evet durumundan 50 adet verinin emekli olması nedeniyle (Rate) satırında oran %9, Hayır durumunda ise 1221 adet verinin normal olmasıyla oran %91'dir. Medeni durumu bekar olan kişilerin verinin %22'lik kısmını oluşturarak istifa durumunun evlilere göre daha yüksek olduğu çıkarımı yapılabilmektedir. Üçüncü kısımda tehlikeli sınıfta yer alan verilerin tamamının %89'unu oluşturarak çok tehlikeli sınıfına göre istifa etme durumunun yalnızca bu kriter göz önüne alındığında daha az olduğu çıkarımı yapılabilmektedir. Yaka türüne göre mavi yakaların daha yoğunlukta olduğu ancak bu kriter bazında istifa etme durumunun bir diğer sınıfa göre baskın olmadığı görülmektedir. Çocuk sahibi olan çalışanların olmayanlara oranla istifa etme durumunun yarı yarıya düştüğü çıkarımı yapılabilmektedir. İcra niteliğinde, icrası olan çalışanların oranının oldukça düşük olduğu ve istifa etme durumunda bu oranın daha da düşük olduğu görülmektedir. Engellilik niteliğindeki veriler, toplam veriler içerisinde oldukça düşük olduğundan oranları %0 ile %2 arasında değişmektedir. Engellilik kriteri için de istifa etme durumları yüzde oranlar ile gösterilmiştir. Eğitim düzeyi kriteri için ilköğretim, lise, meslek lisesi, önlisans, lisans ve yüksek lisans olarak istifa durumu evet ve hayır durumlarına göre sayısal değerleri ve oranları gösterilmiştir. Maaş düzeyi kriteri de çok düşük, düşük, orta, yüksek ve çok yüksek olarak beş farklı şekilde istifa durumu üzerinden sayısallaştırılarak oranları gösterilmiştir. Son kısımdaki pozisyon kriterine göre ise istifa etme durumu alternatiflerde incelenerek oranlar ve veri sayıları gösterilmiştir.



Şekil 4.3 İstifa etme durumu histogram grafiği

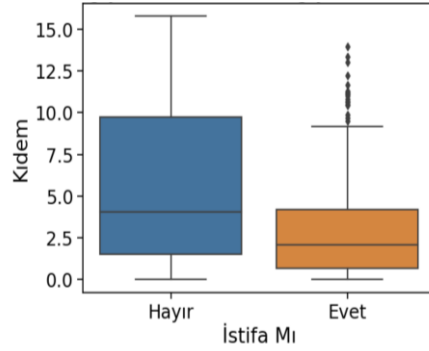
Şekil 4.3'te makine öğrenmesi algoritmaları uygulanmadan önce verileri daha yakından tanımak ve analiz edebilmek amacıyla veri görselleştirmesi yapılmıştır. İstifa Dağılımı başlıklı bu histogram grafiğinde toplam 2318 adet veriden, yeşil bölge ile taranan sütunda 669 tane personelin istifa ettiği, kırmızı bölge ile taranan sütunda 1649 personelin ise istifa etmediği gösterilmiştir.



Şekil 4.4 Maaş düzeyine göre istifa eden ve etmeyen dağılımı

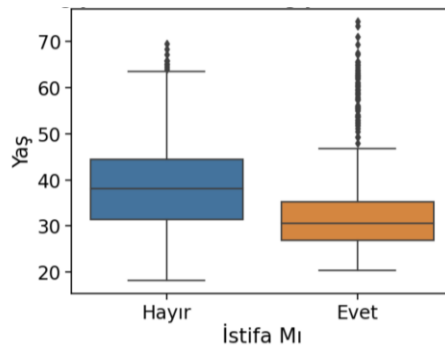
Veri setinde bulunan tüm niteliklerin istifa etme durumuna göre değişimi incelenmiş ve istifa eden personellerin niteliklerdeki aldıkları değer sıralamaları ile istifa etmeyen personellerin değer sıralamalarının aynı olduğu görülmüştür. Pozisyon durumundaki gibi, istifa durumu evet olan çalışanlar ile istifa durumu hayır olan çalışanların unvan sıralamaları aynı olmuştur. Ancak bu durum maaş düzeyi niteliği için değişkenlik göstermiştir. İstifa etmeyen çalışanların maaş dağılımı sırasıyla yüksek, çok yüksek ve orta şeklinde ilerlemektedir. İstifa eden çalışanların maaş sıralamasında ise

sırasıyla çok düşük, düşük ve orta şeklinde olmuştur. Bu grafiklere dayanarak maaş düzeyi çok düşük ve düşük olan personellerin istifa etme durumunun daha yüksek olduğu çıkarımı yapılabilmektedir. Aynı şekilde maaş düzeyi yüksek ve çok yüksek olan çalışanların ise istifa etme durumu daha azdır yorumu yapılabilir.



**Şekil 4.5** Kıdem seviyesine göre istifa eden ve etmeyen kutu dağılımı

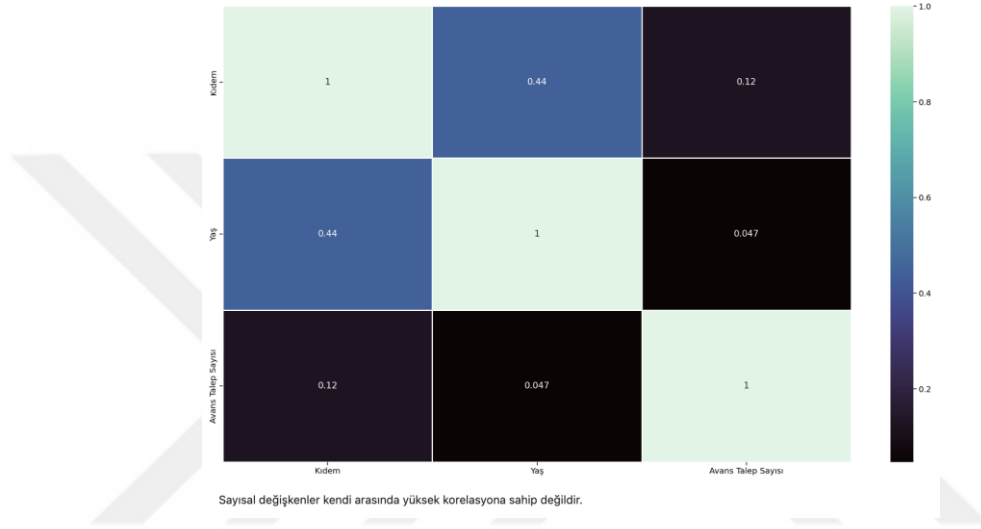
Şekil 4.5'te kıdem değişkeni ile istifa mı değişkeni arasındaki ilişkinin incelenebilmesi adına kutu diyagramı oluşturulmuştur. x ekseninde istifa etme durumu hayır ve evet olma durumları, x ekseninde ise kıdem yılları gösterilmiştir. İstifa etmeyen personellerin, kıdemlerinin minimum olarak yaklaşık 2,5 yıla yakın olduğu, ortalamasının 3,5-4 yıl arasında olduğu ve maksimum ise 10 yıla yakın olduğu görülmüştür. İstifa eden personellerin ise kıdemlerinin minimum 1 yıl olduğu, ortalama 2,5 yıla yakın olduğu ve maksimum ise 3,5-4 yıl olduğu görülmüştür. Bu bağlamda kutu diyagramları göz önüne alındığında istifa etme durumunun kıdemle ilişkili olduğu, kıdemi az olan çalışanların istifa etme durumunun daha yüksek olduğu çıkarımı yapılabilir. Kıdem ile şirket bağlılığının arttığı göz önüne alındığında kıdemi yüksek olan personellerin de istifa etme durumunun daha az olduğu görülebilmektedir.



**Şekil 4.6** Yaş değişkenine göre istifa eden ve etmeyen kutu dağılımı

Yaş değişkeni ile istifa mı değişkeni arasındaki ilişki incelemesi için, x ekseninde istifa etme durumu ve y ekseninde yaş bilgileri yer alan kutu diyagramı Şekil 4.6'da

oluşturulmuştur. İstifa etmeyen personellerin minimum yaşının 30'dan fazla olduğu, ortalama 40'a yakın olduğu ve uç nokta ve üstü göz önüne alınmadığında ise maksimum 45 yaşına yakın olduğu gözlemlenmiştir. İstifa eden personellerin yaşının ise minimum 30'a yakın olduğu, ortalama 30 olduğu ve yine uç gözlemler göz önüne alınmadığı takdirde maksimum 35 yaşına yakın olduğu görülmüştür. İstifa eden personellerin yaşlarının birbirine daha yakın olduğu ve yoğunluğun 30 yaş olduğu çıkarımı yapılabilir. Bu doğrultuda yaşı küçük olan çalışanların işten ayrılmaya daha eğilimli olduğu yorumu da yapılabilmektedir.



Şekil 4.7 Korelasyon analizi

Korelasyon analizinde; avans talep sayısı, yaş ve kıdem niteliklerinin birbiri ile olan ilişkisi Şekil 4.7'de incelenmiştir.

Kıdem niteliği ile yaş niteliği arasındaki korelasyon 0,44 olduğundan korelasyonun pozitif orta derece olduğunun, avans talep sayısı niteliği ile kıdem niteliği arasındaki korelasyon 0,12 olduğundan pozitif düşük ve avans talebi niteliği ile yaş niteliği arasındaki korelasyon 0,047 olduğundan pozitif düşük olduğu yorumlanabilir.

#### 4.1.4. Algoritmaların uygulanması

Makine öğrenmesi algoritmaları Knime ve Python üzerinden Rastgele Orman Algoritması, Naive Bayes Algoritması, Karar Ağacı Algoritması, Destek Vektör Makineleri Algoritması ve K-En Yakın Komşu Algoritması olmak üzere beş farklı algoritma kullanılmıştır.

Knime uygulaması üzerinden beş farklı algoritma kullanılmıştır. Kodlama esnasında makine öğrenimi aşamasında geçmeden önce veri setinde nümerik olmayan nitelikler sayısal değişkenlere dönüştürülmüştür. Sayısal değerlere dönüştürülme

adımında niteliğe bağlı olarak verilerin birbirilerine göre üstünlük ilişkisi olup olmadığı göz önüne alınmıştır. Doğum yeri niteliğinde 68 benzersiz değer bulunmaktadır ve her bir şehir birbirinden farksızdır yani herhangi üstünlük bulunmamaktadır. Bu nedenle şehirler numaralandırılmıştır ancak üstünlük ilişkisi kurulmamıştır. Çıktı olarak nitelendirilen sütun olan “İstifa mı” ise istifa eden durumu “Evet” olan veriler 1, istifa etmeyenlerin durumu ise “Hayır” olan veriler 0 olarak gösterilmiştir. Eğitim düzeyi niteliğinde ise verilerin birbirine üstünlüğü bulunmaktadır. Bu nedenle, eğitim seviyesi düşükten yükseğe doğru puanı artacak şekilde sıralanmıştır. Eğitim düzeyi, ilköğretim 1, meslek lisesi ve lise denk olduğundan eşit puan 2, ön lisans 3, lisans 4 ve yüksek lisans 5 şeklinde nümerik hale getirilmiştir. Maaş düzeyi ise veri seti oluşturulması esnasında beşli ölçeklendirilmiştir. Buna göre maaş düzeyi için sayısallaştırma işlemi çok düşükten çok yükseğe artacak şekilde numaralandırılmıştır. Çok düşük 1, düşük 2, orta 3, yüksek 4 ve çok yüksek 5 sayısallaştırılmıştır. Engellilik kriterinde personelin engellilik durumundan etkilenme durumuna göre sıralama yapılmıştır, yani bu kriterde üstünlük mevcuttur. Engellilik durumu bulunmayan personel 0, üçüncü derece yakını engelli olan personel 1, birinci derece yakını engelli olan 2, personelin kendisi üçüncü derece engelli olması 3 ve personelin kendisinin ikinci derece engelli olması ise 4 olmak üzere nümerik hale getirilmiştir. Son olarak pozisyon niteliğinde de unvanların birbirine karşı hiyerarşik açıdan üstünlüğü bulunmaktadır. Firmanın organizasyon şeması göz önüne alındığında saha mühendisleri ile idari kısımda görev alan uzmanın birbirine karşı üstünlüğü bulunmadığı bilinmektedir. Bu nedenle birbirine üstünlüğü bulunmayan birbirine eş değer sayılabilecek nitelikteki unvanlar aynı puanı almıştır. Hiyerarşinin en alt kademesi en düşük puan, en üst kademesi ise en yüksek değeri alacak şekilde sıralanmıştır. Buna bağlı olarak, işçi 1, formen 2, uzman yardımcısı 3, mühendis ve uzman 4, kıdemli mühendis ve kıdemli uzman 5, vardiya amiri ve şef 6, müdür yardımcısı 7, müdür 8 ve son olarak genel müdür ise 9 şeklinde sayısallaştırılmıştır.

Python dilinde kullanılacak algoritmalar “sklearn” komutu ile “import” içe aktarılmıştır. Veri setindeki, bağımlı ve bağımsız değişkenler tanımlanmıştır. Python programlama dili makine öğrenmesi kütüphanesi olan “Pandas” kullanılmış ve veri seti ilgili algoritmalar ile öğrenim işlemleri gerçekleştirilmiştir. Tüm algoritmalarda veri setinin %80’i eğitim seti, kalan %20’si ise test seti olarak kullanılmıştır. Test setindeki tahminleme başarısı ile ekrana bastırılmıştır.

**Tablo 4.4** Karışıklık matrisi

		Tahmin edilen sınıf		
		Pozitif	Negatif	
Gerçek Sınıf	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)	Duyarlılık
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)	Özgüllük
		Hassaslık	Negatif Tahmin Değeri	Doğruluk

Tablo 4.4'te gösterimi verilmiş olan pozitif, personelin istifa etme durumunu, negatif ise personelin istifa etmeme bilgisini ifade etmektedir.

- Doğru pozitif (True Positive / TP), veriler gerçekte pozitifdir ve pozitif olarak tahmin edilmiştir. Yani, gerçekte istifa eden personel istifa etmiştir şeklinde tahminlenmiştir.
- Yanlış negatif (False Negative / FN), veriler gerçekte pozitifdir ancak negatif olarak tahmin edilmiştir. Gerçekte personelin istifa ettiği verisi istifa etmemiştir şeklinde tahminlenmiştir.
- Yanlış pozitif (False Positive / FP), veriler gerçekte negatiftir ancak pozitif olarak tahmin edilmiştir. Yani, gerçekte personelin istifa etmediği verisi istifa etmiştir şeklinde tahminlenmiştir.
- Doğru Negatif (True Negative / TN), veriler gerçekte negatiftir ve negatif olarak tahmin edilmiştir. Yani, gerçekte personelin istifa etmediği verisi istifa etmemiştir şeklinde tahminlenmiştir.

Tahmin edilen / öngörülen sınıf (Predicted Class), tahmin edilen verileri kapsamaktadır.

Gerçek sınıf (Actual Class), kullanıcı tarafından verilen verileri belirtmektedir.

- Tip I (Type I Error), yanlış pozitif ifade etmektedir.
- Tip II Hata (Type II Error), yanlış negatif ifade etmektedir.

**Tablo 4.5** Tahminleme performans ölçümleri

Tahminleme Performans Ölçümleri	Formül
Duyarlılık	$\frac{TP}{(TP + FN)}$
Özgüllük	$\frac{TN}{(TN + FP)}$
Hassaslık	$\frac{TP}{(TP + FP)}$

**Tablo 4.6** Tahminleme performans ölçümleri (Devamı)

Tahminleme Performans Ölçümleri	Formül
Negatif Tahmin Değeri	$\frac{TN}{(TN + FN)}$
Doğruluk	$\frac{TP + TN}{(TP + TN + FP + FN)}$
$F_1$ Skoru	$2 \times \frac{Hassaslık \times Duyarluluk}{Hassaslık + Duyarluluk}$
Cohen Kappa	$k = \frac{\bar{P} - \bar{P}_e}{1 - \bar{P}_e}$

Algoritmaların başarılı tahminleme performanslarını ölçmek ve birbirleri ile karşılaştırarak en başarılı tahmini gerçekleştirebilen algoritmayı bulabilme amacıyla, her bir algoritma için performans ölçüm kriteri olan; Duyarluluk, özgüllük, hassaslık, negatif tahmin değeri, doğruluk ve  $F_1$  skoru formülleri Tablo 4.5'te gösterilmiştir.  $F_1$  skoru, hassaslık ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Basit ortalama alındığında uç noktalar göz ardı edildiğinden kullanılamamaktadır.  $F_1$  skoru ile harmonik ortalaması alınır ve uç noktalar da göz önüne alınmış olmaktadır (Öğündür, 2019). Cohen Kappa formülü ile gözlem uyumu hesaplanmaktadır  $P$ , gözlenen uyum oranını,  $P_e$ , rastgele uyum beklentisini ifade etmektedir (Bıkmaz Bilgen ve Doğan, 2017).

**Tablo 4.7** Cohen kappa ve ayırt edilebilirlik katsayısı

Cohen Kappa Katsayısı		Ayırt Edilebilirlik Katsayısı	
Uyum yok	< 0	Ayırt edilemez	$k \leq 0$
Önemsiz uyum	0,00 - 0,20	Önemsiz ayırt edilebilirlik	$0,00 < k \leq 0,55$
Orta derecede uyum	0,21 - 0,40	Orta derecede ayırt edilebilirlik	$0,56 \leq k \leq 0,81$
Ekseriyetle uyum	0,41 - 0,60	Ekseriyetle ayırt edilebilirlik	$0,82 \leq k \leq 0,93$
Önemli derecede uyum	0,61 - 0,80	Önemli derecede ayırt edilebilirlik	$0,94 \leq k \leq 0,98$
Neredeyse mükemmel uyum	0,81 - 1,00	Neredeyse mükemmel ayırt edilebilirlik	$0,99 \leq k \leq 1,00$

Tablo 4.6'da görüldüğü gibi  $k$ ,  $-\infty$  ile 1 arasında değer almaktadır.

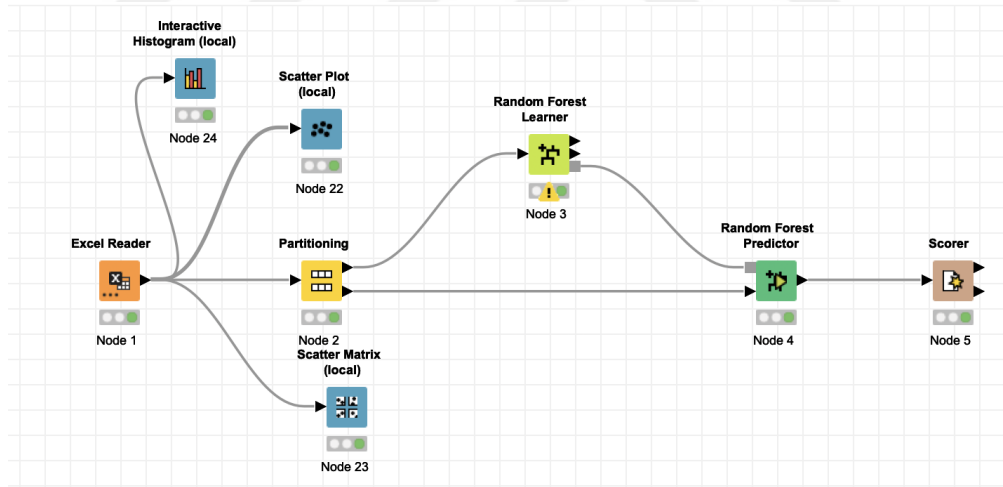
$$P_e = \sum_{i=1}^k (P_{i1} \times P_{i2}) \quad (4.1)$$

4.1 ile gösterilen formüldeki şart ile  $k$  kategori sayısı,  $P_{i1}$  ve  $P_{i2}$  birinci ve ikinci gözlemcinin her bir kategori için yapmış olduğu gözlemlerin oranlarıdır.  $k$ , 1 olması

halinde kategori çiftlerinin tamamen ayırt edilebilir olmasını,  $k \leq 0$  olması halinde ise tüm kategori çiftlerinin ayırt edilemez olmasını ifade etmektedir. Uyum çalışmalarında uyum katsayılarının tek başına kullanımları yeterli olmamaktadır, aynı zamanda ayırt edilebilirlik derecesinin de kullanılması güvenilirlik seviyesi açısından önem taşımaktadır (Doğan ve Doğan, 2022). Knime programı üzerinden uygulanan algoritmaların başarı oranları sonuç ekranında Cohen Kappa yüzdeliği çıktısı elde edilir bu sayede başarı sıralaması yapmada kriter olarak göz önünde bulundurulabilmektedir.

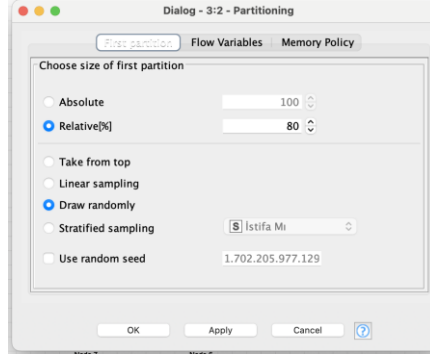
#### 4.1.4.1. Rastgele orman algoritma uygulaması

Rastgele Orman Algoritması uygulaması için ilk olarak verilerin bulunduğu Excel dosyası Excel okuyucusu (Excel Reader) ile Knime programında içeri aktarılmaktadır. Okunan Excel dosyasının içeriğine yine bu modül üzerinden erişilebilmek mümkündür. Excel okuyucusuna bağlantılar sayesinde yeni modüller eklenerek histogram grafiği (Interactive Histogram), serpilme diyagramı (Scatter Plot), serpilme diyagram matrisi (Scatter Matrix) ya da pasta grafiği gibi görselleştirmeler yapılabilmektedir.



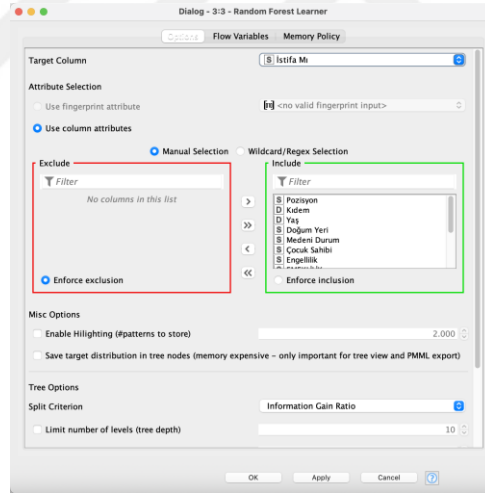
Şekil 4.8 Knime rastgele orman algoritması

Şekil 4.8’de ikinci aşamada “Partitioning” sınıflandırıcısı ile veri seti eğitim seti ve test seti olmak üzere ikiye ayrılmaktadır. Knime, sınıflandırıcıyı çeşitli şekillerde konfigüre etme imkanı sunmaktadır. Eğitim setinin, veri setinin yüzde kaçını oluşturması istendiği kullanıcının tercihine bırakılmaktadır, bu çalışma için eğitim seti %80, test seti ise %20 olarak belirlenmiştir.



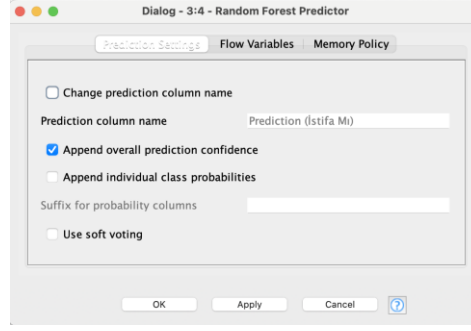
Şekil 4.9 Knime rastgele orman algoritması sınıflandırıcı

Şekil 4.9’da sınıflandırıcının eğitim seti oran seçimi “Relative” seçeneğinden ayarlanabildiği seçim alanı verilmiştir. Eğitim setinin, veri seti içerisinde seçilme seçenekleri de yine kullanıcı tarafından belirlenmektedir. Alternatifler; veri setinden belirlenen oran kadarının baştan başlayarak alınması (Take from top), doğrusal örnekleme (Linear sampling), rastgele seçim (Draw randomly), tabakalı örnekleme (Stratified sampling) olmak üzere dört farklı seçenek sunulmaktadır. Bu çalışmada eğitim verileri veri setinden rastgele seçilmiştir.



Şekil 4.10 Knime rastgele orman algoritması öğrenme seti

Şekil 4.10’da Rastgele Orman Algoritması öğrenme modülünde kullanılması istenen ya da değerlendirmeye alınması istenmeyen nitelikler belirlenebildiği görülmektedir. Sol kısımda bulunan “Exclude” kırmızı alanında yer alan nitelikler makine öğrenim eğitim setine dahil edilmezken sağ kısımda bulunan “Include” yeşil alanda yer alan nitelikler ise eğitim setine dahil edilmektedir. Bu çalışmada yer alan tüm nitelikler eğitim setine dahil edilmiştir. Tahmin edilmesi istenen (çıkıtı/etiket) ise “Target Column” hedef sütun “İstifa mı” sütunu seçilmiştir.



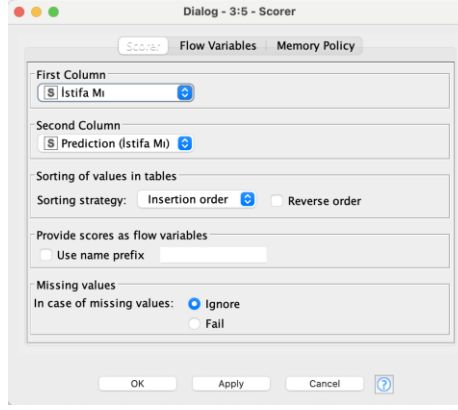
Şekil 4.11 Knime rastgele orman algoritması tahminleme

Şekil 4.11’de Rastgele Orman Algoritması öğrenme modülünde Rastgele orman test (Random Forest Predictor) modülünde ise test edilmesi / tahmin edilmesi beklenen sütunun seçimi gerçekleştirilmiştir. Tahmin sütun adı “Prediction column name” Knime programında otomatik olarak son sütun atanmaktadır ancak bu alanda seçim değişikliği yapılabilmektedir. Bu çalışmada, personellerin istifa etme durumu tahmin edileceğinden tahmin sütununda “İstifa Mı” seçilmiştir.

Row ID	S Pozisy...	D Kidem	D Yaş	S Doğum...	S Mede...	S Çocuk...	S Engell...	S EMEK...	S TEHL...	S Eğitim...	S Maaş ...	S Yaka ...	I Avans	S İkra	S İstifa Mı	S Predic...	D Predic...
Row8	İşçi	2.981	28.09	HATAY	Bekar	Hayır	Yok	Normal	Tehlikeli	İlköğretim	ORTA	Mavi Yaka	0	Yok	Evet	Evet	0.85
Row11	İşçi	7.315	33.534	OSMANIYE	Evlil	Evet	Yok	Normal	Çok Tehli...	İlköğretim	ORTA	Mavi Yaka	0	Yok	Hayır	Evet	0.54
Row12	Formen	14.46	40.236	OSMANIYE	Evlil	Evet	Yok	Normal	Tehlikeli	Onlisans	ÇOK YÜKSEK	Beyaz Yaka	0	Yok	Hayır	Hayır	1
Row15	İşçi	8.307	31.312	OSMANIYE	Evlil	Evet	Yok	Normal	Çok Tehli...	İlköğretim	ORTA	Mavi Yaka	0	Yok	Evet	Evet	0.58

Şekil 4.12 Knime rastgele orman algoritması tahminleme örnekleri

Şekil 4.12’de “Random Forest Predictor” modülünde her bir test veri satırının algoritma tarafından çıktığı tahminini görebilir ve yapılan tahminin yüzde kaç başarı ile gerçekleştirildiği incelenebilmektedir. Örnek olarak (Row 8) sekizinci satırdaki personele ait veriler S (İstifa mı) gerçek veri, “Prediction” İstifa mı satırı ise tahminlenen verileri içeren sütundur. Sekizinci satır için bu durum incelendiğinde gerçekte istifa ettiğini ve Rastgele Orman Algoritması tarafından da istifa eder şeklinde tahminlendiği ve bu tahminin %85 başarılı şekilde tahminlendiği görülmektedir.



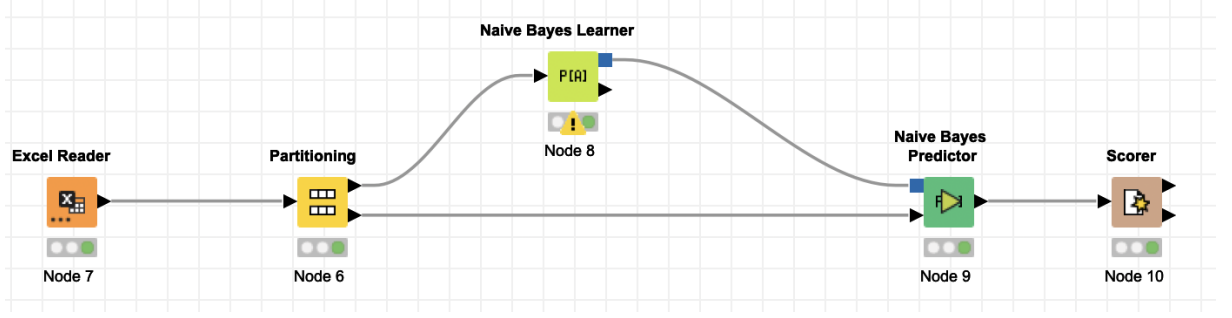
Şekil 4.13 Knime rastgele orman algoritması tahminleme skor düğümü

Makine öğrenimi akışının son modülünde ise Başarı oranı / Skor tespiti (Scorer) ile algoritmanın başarılı tahmin yapıp yapmadığının kontrolü Şekil 4.13'te gerçekleştirilmektedir. "Scorer" modülünün konfigürasyonunda ise ilk sütun / gerçekleşen değer (First column) ile tahminlenen sütun (Second column) arasında karşılaştırma yapılarak doğru tahmin yüzdeliği hesaplanmaktadır. Bu düğüm içerisinde son satırda, kayıp veriler (Missing values) silme işlemi de gerçekleştirilebilmektedir. Uygulamada kullanılan veri setinde bir kayıp/eksik veri bulunmadığından bu alanda herhangi bir değişiklik yapılmamıştır.

Skor tespiti modülünde "Scorer" Rastgele Orman Algoritmasının, doğru sınıflandırılan veri sayısı (Correct classified) 362, yanlış sınıflandırılan veri sayısı (Wrong classified) 102 olduğu görülmektedir. Doğruluk (Accuracy) oranı ise %78, hata oranı (Error) ise %21 olarak belirtilmiştir. Algoritmaların başarı oranını doğruluk yüzdesinin karşılaştırılması ile yapılması mümkündür.

#### 4.1.4.2. Naive bayes algoritma uygulaması

Naive Bayes algoritması Knime üzerinde sırasıyla, Şekil 4.14'te gösterimi yapıldığı şekilde Excel okuyucusu, eğitim ve test verilerinin ayrılması, Naive Bayes makine öğreniminin gerçekleştirilmesi, Naive Bayes algoritmasının test edilmesi ve başarı performansının değerlendirilmesi için gerekli modüller düğüm şeklinde yerleştirilmiş ve ilişkilendirilmesi adına birbirlerine bağlanmıştır.



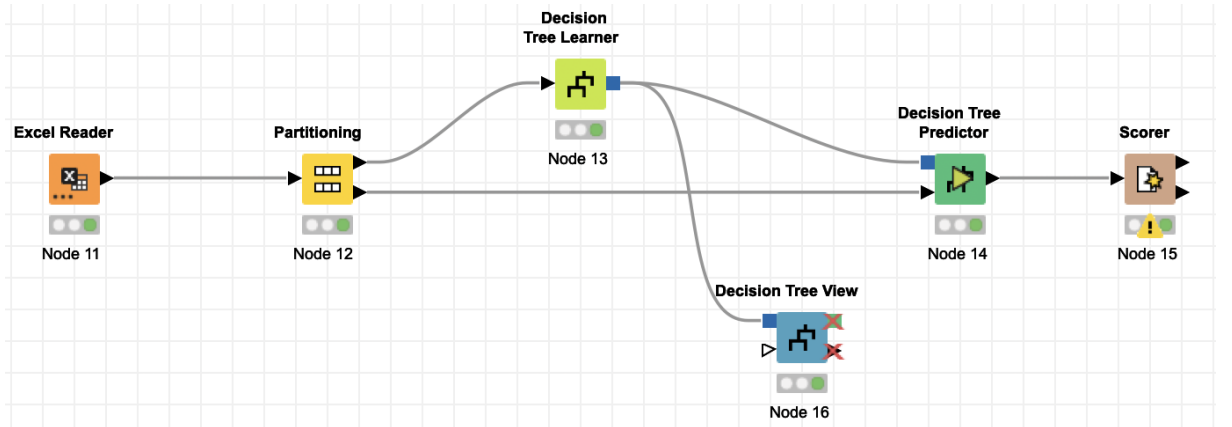
Şekil 4.14 Knime naive bayes algoritması

Seçimlerde, Rastgele Orman Algoritmasında da olduğu gibi “Partitioning” modülü ile ikinci aşamada eğitim seti %80, test seti %20 olarak ayrılmıştır. Naive Bayes öğrenim ve test modülleri için gerekli yapılandırmalar gerçekleştirilmiştir.

“Scorer” modülünde ise algoritmanın başarılı tahmin gerçekleşip gerçekleşmediğinin kontrolü yapılmıştır. Naive Bayes algoritmasında doğru sınıflandırılan veri sayısı 332, yanlış sınıflandırılan veri sayısı ise 132’dir. Algoritmanın performans ölçütlerinden olan Doğruluk oranı %71,5’tir.

#### 4.1.4.3. Karar ağacı algoritması uygulaması

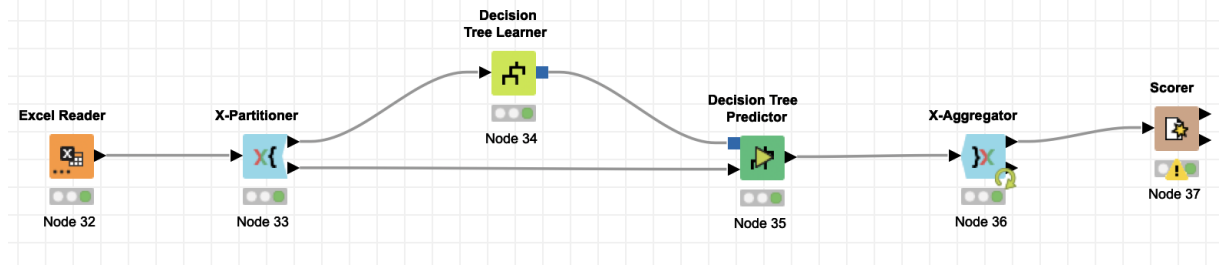
Karar Ağacı Algoritması Knime üzerinde sırasıyla, Excel okuyucusu, eğitim ve test verilerinin ayrılması, Karar Ağacı makine öğreniminin gerçekleştirilmesi, Karar Ağacı Algoritmasının test edilmesi ve başarı performansının değerlendirilmesi için gerekli modüller düğüm şeklinde yerleştirilmiş ve ilişkilendirilmesi adına birbirlerine bağlanmıştır.



Şekil 4.15 Knime karar ağacı algoritması

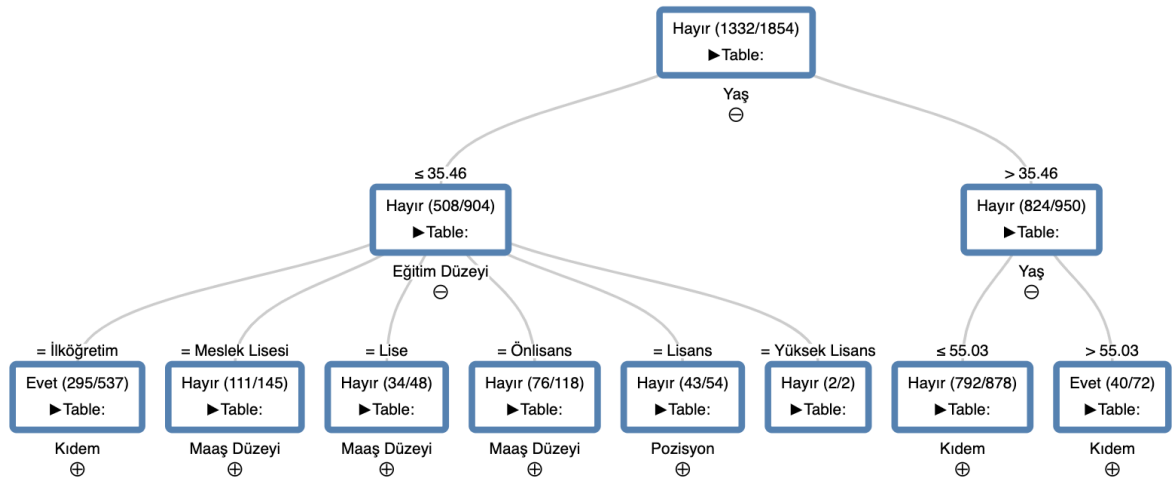
Şekil 4.15’te gösterilmiş olan modüllerdeki seçimler, diğer algoritmalarda olduğu gibi “Partitioning” ile ikinci aşamada eğitim seti %80, test seti %20 olarak ayrılmıştır. Karar Ağacı öğrenim ve test modülleri için gerekli yapılandırmalar gerçekleştirilmiştir.

Karar Ağacının görüntüsü (Decision Tree Learner) Karar Ağacı öğreticisi modülünden görüntülenebilmektedir. Ancak basit ve detaylı Karar Ağacı için ayrıca “Decision Tree View” Karar Ağacı görüntüsü modülü eklenerek de görüntülemek mümkündür.



Şekil 4.16 Knime karar ağacı algoritması veri seti ayrıştırma alternatifi

Knime üzerinde gerçekleştirilen makine öğrenim algoritmalarında eğitim ve test setlerinin ayrılması “Partitioning” modülü ile gerçekleştirilmiştir. Karar Ağacı Algoritması üzerinde Knime programının eğitim ve test seti ayrıştırılması “X-Partitioner” ile gerçekleştirilmesi, ayrıştırma yönteminin değiştirilmesi nedeniyle algoritmanın tahmin başarısını da etkileyecektir.



Şekil 4.17 Knime karar ağacı algoritması modeli


Karar Ağacı Algoritması, verilerin görselleştirilmesinin sağlanması ve karar alma süreçlerinde dallanma yapısıyla analizlerin kolaylaşması açısından avantaj sağlamaktadır. Knime paket programında detaylı görselleştirilen Karar Ağacının bir kısmı Şekil 4.17’de verilmiştir, detaylı Karar Ağacının tamamı ise veri setinin büyük olmasından kaynaklı dallanmanın fazla olması, görüntünün karmaşıklaşması gibi nedenlerden çalışmanın ek kısmında paylaşılmıştır.

Karar Ağacı Algoritmasının öğretici modülünden ağaç görüntüsü alındığından toplam veri setinde 2318 adet veri bulunmakta ve yüzde sekseni eğitim seti olarak alındığından 1854 adeti değerlendirmeye alınmıştır. 1854 adet veri içerisinde 1332 adet veride istifa etme durumu “Hayır” olarak belirtilmiş ve karar süreci dallanma şeklinde devam etmektedir. İlk aşamada dallanma “Yaş” kriteri ile olmuştur. Yaş’ı 35,46’dan küçük olan 904 adet istifa etme durumu hayır olarak belirtilmiş ve bir sonraki aşamada eğitim düzeyi olarak dallandırılmıştır. Yaşı 35,46’dan büyük olan verilerde 950 adet veriden 824 tane verinin istifa durumu hayır olarak belirtilerek yeniden “Yaş” kriteri değerlendirilmiştir. Yeniden değerlendirilen Yaş niteliğinde 55,03 yaşından küçük olan verilerden 878 adet veriden 792 tanesinin istifa etme durumu hayır olarak, sonraki aşamada Kıdem kriteri değerlendirilmiş, 55,03’ten büyük olan personellerin 72 adet veriden 40 tanesinin istifa etme durumu ise evet olarak değerlendirilerek sonraki adımda Kıdem niteliği incelenmiştir. Eğitim kriterinde yer alan alternatiflerde ilköğretim düzeyindeki personellerin işten ayrılma durumu 537 adet veriden 295 Evet olarak, sonrasında ise Kıdem kriteri incelenmekte, eğitim düzeyi meslek lisesi olan personellerin işten ayrılma durumu 145 adet veriden 111 tanesi hayır, sonraki aşamada ise Maaş düzeyi kriter incelenmekte, eğitim düzeyi lise olan çalışanların 46 tane veriden 34 tanesinin istifa durumu hayır, sonraki adımda Maaş düzeyi niteliği incelenir, eğitim düzeyi önlisans olan personellerin 118 tanesinin 76 adet verinin istifa durumu hayır olarak, sonrasında ise Maaş düzeyi niteliğine bakılır, eğitim düzeyi lisans olan çalışanların 54 tane veriden 43 adet veri istifa etme durumu hayır olarak, sonrasında ise Pozisyon niteliği incelenmektedir.

Karar Ağacı Algoritması için son düğüm olan “Scorer” modülünde algoritmanın başarılı tahmin gerçekleşip gerçekleşmediğinin kontrolü yapılmıştır. Karar Ağacı Algoritmasında doğru sınıflandırılan veri sayısı 343, yanlış sınıflandırılan veri sayısı ise 119’dir. Algoritmanın performans ölçütlerinden olan Doğruluk oranı %74,2’dir.

#### **4.1.4.4. Destek vektör makineleri algoritması uygulaması**

Destek Vektör Makineleri Algoritması Knime üzerinde sırasıyla diğer algoritmalarda da olduğu şekilde, Excel okuyucusu, eğitim ve test verilerinin ayrılması, Destek Vektör Makineleri Algoritması makine öğreniminin gerçekleştirilmesi, Destek Vektör Makineleri Algoritmasının test edilmesi ve başarı performansının değerlendirilmesi için gerekli modüller düğüm şeklinde yerleştirilmiş ve ilişkilendirilmesi adına birbirlerine bağlanmıştır.



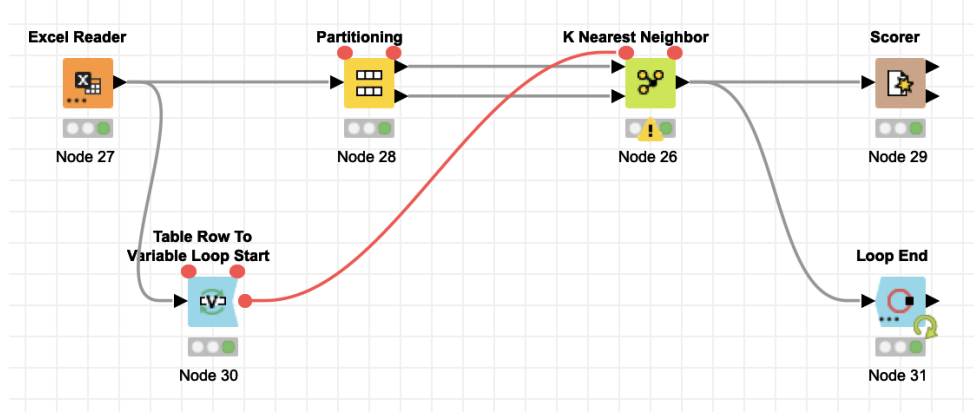
Şekil 4.18 Knime destek vektör makineleri algoritması

Seçimlerde, diğer algoritma uygulamalarıyla aynı doğrultuda olacak şekilde “Partitioning” ikinci aşamada eğitim seti %80, test seti %20 olarak ayrılmıştır. Destek Vektör Makineleri öğrenim ve test modülleri için gerekli yapılandırmalar gerçekleştirilmiştir. Son adımda ise “Scorer” modülü ile Destek Vektör Makineleri Algoritmasının performansı değerlendirilmiştir.

Destek Vektör Makineleri Algoritması için son düğüm olan “Scorer” modülünde algoritmanın başarılı tahmin gerçekleşip gerçekleşmediğinin kontrolü yapılmıştır. Destek Vektör Makineleri Algoritmasında doğru sınıflandırılan veri sayısı 346, yanlış sınıflandırılan veri sayısı ise 118’dir. Algoritmanın performans ölçütlerinden olan Doğruluk oranı %74,5’dir. Ancak performans değerlendirme kriterlerinden olan Cohen kappa değeri, Destek Vektör Makinelerinde %0 olarak elde edilmiştir. Kappa katsayısı değerinin sıfır olması iki gözlemci arasındaki uyumun şansa bağlı olabilecek uyumdan farksızdır şeklinde yorumlanmaktadır ve bu değerın sıfırdan farklı olması beklenmekte tam uyum için +1, tam uyumsuzluk için ise -1 olması beklenmektedir.

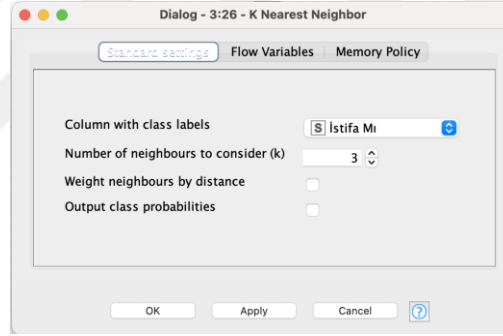
#### 4.1.4.5. K-en yakın komşu algoritması uygulaması

K-En Yakın Komşu Algoritması algoritması Knime üzerinde sırasıyla diğer algoritmalarda da olduğu şekilde, Excel okuyucusu, eğitim ve test verilerinin ayrılması, K-En Yakın Komşu Algoritması makine öğreniminin gerçekleştirilmesi, K-En Yakın Komşu Algoritmasının test edilmesi ve başarı performansının değerlendirilmesi için gerekli modüller düğüm şeklinde yerleştirilmiş ve ilişkilendirilmesi adına birbirlerine bağlanmıştır.



Şekil 4.19 Knime K-en yakın komşu algoritması

Seçimlerde, diğer algoritma uygulamalarıyla aynı doğrultuda olacak şekilde “Partitioning” ikinci aşamada eğitim seti %80, test seti %20 olarak ayrılmıştır. K-En Yakın Komşu Algoritması öğrenim ve test modülleri için gerekli yapılandırmalar gerçekleştirilmiştir. Son adımda ise “Scorer” modülü K-En Yakın Komşu Algoritmasının performansı değerlendirilmiştir.




Şekil 4.20 Knime K-en yakın komşu algoritması  $k$  değeri belirleme  $k = 3$

Şekil 4.20’de K-En Yakın Komşu Algoritmasında  $k$  değeri kullanıcı tarafından Knime uygulaması üzerinden değiştirilebildiği gösterilmiştir. Otomatik olarak dikkate alınacak  $k$  komşu sayısı 3 olarak atanmıştır. Çalışmadaki veri setinde uygulanacak K-En Yakın Komşu için  $k$  değeri 3 olarak uygulanmıştır.

K-En Yakın Komşu Algoritması  $k = 3$  için son düğüm olan “Scorer” modülünde algoritmanın başarılı tahmin gerçekleşip gerçekleşmediğinin kontrolü yapılmıştır. K-En Yakın Komşu Algoritmasında (Correct classified) doğru sınıflandırılan veri sayısı 323, (Wrong classified) yanlış sınıflandırılan veri sayısı ise 141’dir. Algoritmanın performans ölçütlerinden olan Doğruluk oranı (Accuracy) %69,6’dır.

Knime programında K-En Yakın Komşu Algoritmasındaki  $k$  parametresine 1’den 50’ye kadar rastgele değerler atanmış ve tahmin performansının başarı ölçütlerine göre karşılaştırma yapılmıştır.



Şekil 4.21 KNN algoritması n sayısına göre doğruluk değişimi

K-En Yakın Komşu Algoritmasındaki  $k$  parametresinin doğruluk yüzdesi ve doğru sınıflandırılmış veri sayısına göre karşılaştırılmıştır. Şekil 4.21’de doğruluk yüzdelерinin  $k$  komşu sayısına göre değişimi grafik ile görselleştirilmiş ve en iyi tahminleme performansı  $k$  değerinin 33 olarak belirlendiğinde sahip olduğu görülmüştür.

K-En Yakın Komşu Algoritmasında  $k$  değeri 33 olarak belirlenmiştir. “K Nearest Neighbor” modülünde varsayılan olarak gelen dikkate alınan komşu sayısı “Number of neighbours to consider” değiştirilmiştir.

K-En Yakın Komşu Algoritması  $k = 33$  için son düğüm olan “Scorer” modülünde algoritmanın başarılı tahmin gerçekleşip gerçekleşmediğinin kontrolü yapılmıştır. K-En Yakın Komşu Algoritmasında doğru sınıflandırılan veri sayısı 348, yanlış sınıflandırılan veri sayısı ise 116’dır. Algoritmanın performans ölçütlerinden olan Doğruluk oranı %75’tir.

#### 4.1.5. Kullanılan algoritmaların karşılaştırılması

Knime ve Python programlama dillerinde uygulanmış olan algoritmaların eğitim ve test setleri rastgele olarak belirlendiğinden karşılaştırmaların anlamlı olabilmesi için iki programda da beş kere deneme gerçekleştirilmiştir. Sonuç doğrultusunda alınacak olan karar ya da yapılan tahminlerin güvenilirliğini sağlamak adına her denemeye ait sonuçlar kaydedilmiş ve ilgili değerlerin ortalaması alınmıştır.

Knime programında uygulanan algoritmaların istifa durumu evet iken ilgili algoritma tarafından da evet ve hayır olarak ve istifa durumu hayır iken de hayır ve evet olarak tahmin edilenler olarak sınıflandırılan veriler Tablo 4.7’de gösterilmiştir. Bu tablo

doğrultusunda doğru pozitif, yanlış negatif, yanlış pozitif ve doğru negatif değerleri elde edilmiştir. Tabloda yapılan beş farklı denemenin ortalamaları ele alınmıştır.

**Tablo 4.8** Knime programında doğru veri sınıflandırma karşılaştırılması

		İstifa Durumu İle İlgili Tahmin									
		Rastgele Orman		Naive Bayes		Karar Ağacı		Destek Vektör Makineleri		K-En yakın komşu	
		Hayır	Evet	Hayır	Evet	Hayır	Evet	Hayır	Evet	Hayır	Evet
İstifa Durumu	Hayır	289	40	247	80	272	56	331	0	294	44
	Evet	60	75	63	74	62	74	133	0	83	43

Makine öğrenimi algoritmaları birbirleri ile başarılı tahminleme performans ölçütlerine göre kıyaslanır ve en yüksek başarı sağlayan algoritma tercih edilir. Knime paket programı üzerinden çalışmanın konusunu oluşturan personellerin istifa etme durumunun tahminlenmesinde; Rastgele Orman, Naive Bayes, Karar Ağacı, Destek Vektör Makineleri ve K-En Yakın Komşu Algoritmaları kullanılmıştır. Her bir algoritma için, doğru sınıflandırılan veri sayısı, yanlış sınıflandırılan veri sayısı, doğruluk oranı, hata oranı ve Cohen Kappa katsayısı olmak üzere performans ölçütlerinde sahip olduğu değerler beş farklı denemenin ortalamaları alınarak Tablo 4.8’de işlenmiştir. Başarı performans ölçütlerinden doğru sınıflandırılan veri sayısının yüksek olması, yanlış sınıflandırılan veri sayısının düşük olması, doğruluk oranının yüksek olması, hata oranının düşük olması, Cohen Kappa katsayısının ise +1 ya da -1’e yakın olması beklenmektedir. Tüm bu ölçütler göz önüne alınarak en başarılı algortmadan başarısız olan algortmaya kadar sıralama gerçekleştirilebilir, tahminleme aşamasında ise en başarılı algoritma tercih edilmektedir.

**Tablo 4.9** Knime programında algoritmaların karşılaştırılması

KNIME	Rastgele Orman	Naive Bayes	Karar Ağacı	Destek Vektör Makineleri	K-En yakın komşu
Doğru Sınıflandırılmış	364	320	345	331	337
Yanlış Sınıflandırılmış	100	144	119	133	127
Doğruluk	%78,40	%69,05	%74,47	%71,42	%72,71
Hata	%21,60	%30,95	%25,53	%28,58	%27,29
Cohen Kappa Katsayısı	0,451	0,283	0,373	0,000	0,240

Tablo 4.8’de Knime paket programında uygulanan Rastgele Orman, Naive Bayes, Karar Ağacı, Destek Vektör Makineleri ve K-En Yakın Komşu algoritmalarında başarıları karşılaştırma amacıyla kullanılan metriklerde elde etmiş olduğu veriler işlenmiştir. Bu tablo göz önüne alındığında Knime programında işten ayrılma durumunu

en başarılı tahminde bulunan algoritmanın “Rastgele Orman Algoritması”nın olduğu görülmüştür.

**Tablo 4.10** Python programında algoritmaların karşılaştırılması

<b>PYTHON</b>	Rastgele Orman	Naive Bayes	Karar Ağacı	Destek Vektör Makineleri	K-En Yakın Komşu
Kesinlik	75,99%	65,24%	71,88%	50,70%	72,58%
Duyarlılık	76,88%	66,82%	71,79%	71,14%	74,07%
$F_1$ Skoru	0,7619	0,6556	0,7178	0,5918	0,7256
Cohen Kappa Katsayısı	0,4038	0,1388	0,309	0	0,3094
Doğruluk Skoru	76,88%	66,82%	71,79%	71,14%	74,07%

Tablo 4.9’da Python programlama dilinde uygulanan algoritmaların doğruluk parametrelerine aldığı değer ve yüzdelik oranlar denemelerin ortalamaları alınarak gösterilmiştir.

**Tablo 4.11** Algoritmaların başarı ölçütlerine göre karşılaştırılması

Algoritma	Knime Paket Programı				Python			
	Doğru	Yanlış	DO (%)	$\kappa$	Doğru	Yanlış	DO (%)	$\kappa$
Rastgele Orman	364	100	%78,40	0,45	357	107	%76,88	0,40
Naive Bayes	320	144	%69,05	0,28	310	154	%66,82	0,13
Karar Ağacı	345	119	%74,47	0,37	333	131	%71,79	0,30
Destek Vektör Makineleri	331	133	%71,42	0,00	330	134	%71,14	0,00
K-En Yakın Komşu	337	127	%72,71	0,24	344	120	%74,07	0,30

Doğru sınıflandırmada 364 veri ile en yüksek, yanlış sınıflandırmada 100 veri ile en düşük, doğruluk oranında %78,40 ile en yüksek, hata oranında %21,60 ile en düşük ve Cohen Kappa katsayısında 0,45 ile 1’e en yakın değerleri bulduğundan Rastgele Orman (Random Forest) algoritması beş farklı algoritma içerisinde en başarılısı şeklinde değerlendirilmiştir. Doğru sınıflandırmada 320 veri ile en düşük, yanlış sınıflandırmada 144 veri ile en yüksek, doğruluk oranında %69,05 ile en düşük, hata oranında %30,95 ile en yüksek ve Cohen Kappa katsayısında 0,28 ile 0’a yakın değerleri bulduğundan Naive Bayes algoritması beş farklı algoritma içerisinde en başarısızı şeklinde değerlendirilmiştir. Python programlama dilinde de doğruluk başarısına göre en yüksek algoritma Knime ile paralel olarak Rastgele Orman Algoritması ve en düşük doğruluk yüzdeliği ise Naive Bayes olmuştur. Knime ve Python’da aynı algoritmalarda farklı başarı yüzdeliklerinin elde edilmesinin nedeni veri setinin %80’i eğitim veri seti olarak elde

edilirken verilerin sistemler tarafından rastgele (random) olarak seçiliyor olmasından kaynaklanmaktadır. Veri seti aynı olmasına rağmen rastgelelik bulunduğundan dolayı farklı programlarda farklı başarı oranlarının elde edilmiştir.

#### 4.1.6. Tahminlemelerin gerçekleştirilmesi

Bu bölümde çalışmanın amacı olan, kurum içerisinde aktif olarak çalışmakta olan personellerin işten ayrılma ihtimali olup olmadığını tespit edebilmek ya da işe girmek üzere başvuruda bulunan adayların ilerleyen zamanlarda işten ayrılma olasılığını inceleyebilmek adına makine öğreniminde en yüksek doğru tahmin başarısı sağlayan algoritma olan Rastgele Orman Algoritması üzerinde yeni veri test edilmiştir.

Knime programında test ve eğitim seti olarak kullanılan Excel dosyasındaki satırların en altına yeni bir satır eklenerek sorgu yapılmak istenen olası aday ya da çalışanın her bir nitelik için değerleri girilmiştir. İlk olarak Tablo 4.11’de verildiği gibi, vardiya amiri, 3 yıllık kıdeme sahip, 27 yaşında, doğum yeri Hatay, medeni durumu evli, çocuk sahibi olan, engellilik durumu bulunmayan, emekli olmayan, çok tehlikeli sınıfta çalışan, eğitim düzeyi lise, maaş düzeyi yüksek, beyaz yaka, bir tane avans talebinde bulunmuş ve icrası bulunmayan bir çalışan ele alınmış ve istifa etme durumu hayır olarak varsayımında bulunulmuştur.

**Tablo 4.12** Tahminleme örneği

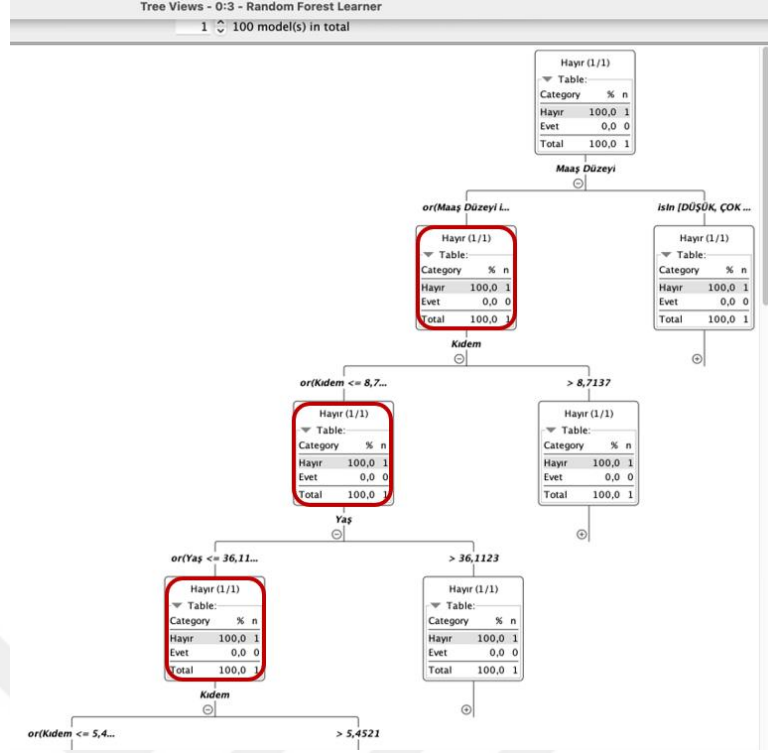
Pozisyon	Kıdem	Yaş	Doğum Yeri	Medeni Durum	Çocuk Sahibi	Engellilik	EMEKLİLİK	TEHLİKE DURUMU	Eğitim Düzeyi	Maaş Düzeyi	Yaka Türü	Avans	İcra	İstifa Mı
Vardiya Amiri	3,00	27,00	HATAY	Evli	Evet	Yok	Normal	Çok Tehlikeli	Lise	YÜKSEK	Beyaz Yaka	1	Yok	Hayır

Tablo 4.12’de 2318. Satırda gösterilmektedir. Veri girişinde de varsayılan şekilde istifa etme durumunu %89’luk doğru tahmin başarısı ile “Hayır” olarak tahminlemiştir.

**Tablo 4.13** Tahminleme örneği çıktısı

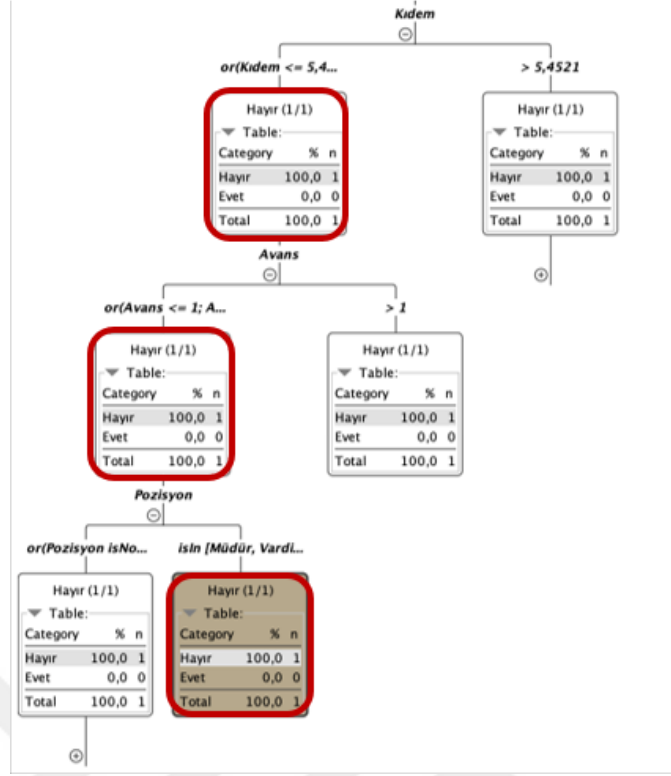
Row2318	Vardiya Amiri	3	27	HATAY	Evli	Evet	Yok	Normal	Çok Tehli...	Lise	YÜKSEK	Beyaz Yaka	1	Yok	Hayır	Hayır	0.89
---------	---------------	---	----	-------	------	------	-----	--------	--------------	------	--------	------------	---	-----	-------	-------	------

Tahminlerin değerlendirilmesi aşamasında verilen örnek Knime üzerinden “Random Forest Learner” modülünün Karar Ağacı görüntülemesi ile elde edilen görsel ile aynı sonuca ulaşılabilirliği incelenmiştir.



Şekil 4.22 Knime rastgele orman algoritması karar ağacı gösterimi

Şekil 4.22’de Rastgele Orman Algoritması Karar Ağacının kök düğüm, iç düğüm ve yaprak düğümleri görülmektedir. İlk dallanma “Maaş Düzeyi” kriteri ile başlamaktadır. Ele alınan örnekteki çalışanın maaş düzeyi “Yüksek” sınıfında olduğundan kırmızı çerçeve içerisine alınan iç düğüm ile ilerlemektedir. İlgili seçimin ardından “Kıdem” niteliği kontrol edilmiş, dallanma kıdem 8,71’den büyük olması ya da olmaması şeklinde olmuştur. Çalışanın kıdemi 3 olduğundan küçük eşittir alternatifi ile ilerlenmiştir. Bir sonraki aşamada “Yaş” kriteri incelenerek, yaşın 36,11’den büyük olması ya da olmaması halinde dallanma görülmektedir. Örnekteki çalışanın yaşı 27 olduğundan küçük eşittir düğümünden devam edilmiştir.



Şekil 4.23 Knime rastgele orman algoritması karar ağacı gösterimi-2

Şekil 4.23'te "Kıdem" niteliği için 5,45'ten büyük olması ya da olmaması olarak incelenmiştir. Örnek çalışanın kıdemi 5,45'ten küçük olduğundan ilgili düğüm kırmızı çerçeve ile işaretlenerek bir sonraki kırılıma ilerlenmiştir. Bu aşamada "Avans Talep" kriteri incelenmiştir. İlgili çalışanın avans talep sayısı 1 olduğundan " $\leq 1$ " düğümü seçilmiştir. Son aşamada ise "Pozisyon" kriteri kontrol edilmiştir. Pozisyonu; Müdür, Vardiya amiri, Uzman, Uzman yardımcısı, Kıdemli mühendis, Müdür yardımcısı, Kıdemli uzman ve Genel müdür olması ya da olmaması olarak ayrı düğümlerde sınıflanmıştır. Ele alınan çalışan Vardiya Amiri olduğundan bu pozisyonlara dahil şeklindeki yaprak seçilmiştir. Bu seçimin ardından herhangi bir kırılımının olmaması nedeniyle sonuca ulaşıldığı yorumu yapılır. Bu niteliklere sahip çalışanın istifa etme olasılığının Rastgele Orman Algoritması'nın Karar Ağacı görünümü ile yapılan değerlendirmelerde "Hayır" olarak ulaşılmıştır.

Örnek sayıları farklı nitelikler ile çoğaltılabilir. Bu örnekler ile işe alım esnasında değerlendirilen adayların niteliklerinin Knime programında girişi ile gelecekte işten ayrılma ihtimalinin olup olmayacağını tahminlemek ya da işten ayrılma potansiyeli olduğu fark edilen çalışanlar için bu olasılığın varlığının kontrolü sağlanabilecektir.

İstifa etme durumu için 14 farklı niteliğin önem sıralaması yapılmış ve buna göre istifa etme durumunda en önemli nitelik 0,30 oranla yaş, en önemsiz nitelik avans talep

sayısı olmuştur. Önem sıralaması; yaş, kıdem, doğum yeri, maaş düzeyi, eğitim düzeyi, pozisyon, çocuk sahibi olma durumu, tehlike durumu ve yaka türü şeklinde sıralanmıştır. Önem sıralamasında en önemli faktörlerden olan yaş ve kıdem kriterlerinin istifa durumuna göre ilişkisi Şekil 4.5 ve Şekil 4.6’da incelenerek değerlendirilmiştir.

Rastgele Orman Algoritması ile elde edilen Karar Ağacındaki ayrıştırılmalar, bu ayrıştırma kriterlerine ait açıklama ve öneriler Tablo 4.13’te açıklanmıştır.

**Tablo 4.14** Karar ağacı ayrıştırma kriteri ve önerileri

Ayrıştırma Kriteri	Açıklama	Öneri
Maaş Düzeyi	Çalışanın istifa etme kararında maaş düzeyi ile ilgili bir memnuniyetsizlik durumunda ücret artışı önerisi sunulabilmektedir ancak çalışmanın yapıldığı kuruluşa ait ücret skalasının bulunması kişilere özel ücret uygulamasını mümkün kılmamaktadır. İşten ayrılan çalışana, ücrette değişiklik önerilmesi ücret dağılımının bozulmasına ve ücrette adaletin sağlanamamasına neden olacaktır. İstifa düşüncesi olmayan ancak ücret tatmini sağlayamayan çalışanların ücret değişikliği amacıyla gerçekçi olmayan istifa başvurularına da sebebiyet verebilecektir.	Bağlayıcılık kapsamında önemli rol oynayan bayram harçlığı, prim, yakacak, kırtasiye yardımları, özel/tamamlayıcı sağlık sigortası, doğum, evlilik, vefat yardımı gibi yan haklar arttırılacaktır.
		Ödül yönetimi ve takdir tanıma sistemi oluşturulacaktır.
		Öneri sistemi ile maddi, zaman, verimlilik ya da iş sağlığı ve güvenliği gibi kazanım sağlayan fikirler toplanarak öneri sistemi ile değerlendirilerek yıl sonunda en iyi öneri veren çalışanlara ödül verilecektir.
Kıdem	Kıdemın yükselmesi kuruma aidiyeti arttırdığından çalışanın mevcut pozisyonunda devam etmesi beklenmektedir.	İşten ayrılma adına başvuran çalışana, potansiyel kariyer yol haritası, eğitim ve gelişim planları konularında yönlendirme yapılması ile yetkinlik iyileştirmeleri sağlanacaktır.
		Şirketteki maaş, kıdem vb. niteliklerin sürekliliğinin sağlanmasının öneminden bahsedilerek istifanın önüne geçmeye çalışılacaktır.
Yaş	Kıdem kriteri ile yaş kriterinin birlikte değerlendirilmesi mümkündür. Yaş kriteri istifada önemli bir rol oynamakta ve yaşı genç olan çalışanların istifa oranının daha yüksek olduğu görülmüştür.	Yaşam kalitesini arttırmaya yönelik boş zamanlarında gönüllü faaliyetlerden olan, spor müsabakaları gibi sportif aktiviteler, doğa yürüyüşleri, piknik organizasyonu, boya, çizim, seramik, tatlı atölyesi vb. etkinlikler planlanacaktır. Takım çalışmasını destekleyecek aktivitelerin planlanması, ekip içi iletişimi güçlendirerek iş kapsamı haricinde de sosyalleşmeyi sağlayabilecektir.
		Genç, beyaz yaka çalışanların esnek çalışma koşulları, iş koşullarının mümkün olduğu pozisyonlarda uzaktan, hibrit çalışma yöntemleri ile iş-yaşam arasındaki dengeyi sağlayarak kuruma bağlılığı arttırması beklenebilmektedir.
		Genç çalışanların gelişen teknolojiye hızlı adapte olabildiğinden üretim ve yönetimin her kolunda teknolojiye ayak uydurarak verimli çalışmayı ve çalışırken tatmin olmayı sağlayacaktır.
		En başarılı toplam kalite yönetimi uygulaması yapan çalışanlar “Aydın Çalışanı” olarak seçilerek motivasyon sağlanır ve çalışanlar arası pozitif rekabet ortamı ile teşvik edilmiş olunacaktır.
Avans Talep Sayısı	Çalışanın sağlık sorunlarını gidermek üzere yapması gereken ödemeler var olması durumlarında maaş ödemelerinden eşit taksitlerle kesilmek üzere peşinen yapılan ödemeler avans talebi başlığı altında incelenmiştir.	Sağlık sorunlarının iş kazası ya da meslek hastalığı ile ilgili olması durumunda ödemelerin işyeri tarafından karşılanması önerilebilir.
		Esnek geri ödeme seçenekleri ya da rapor vb. durumların beyanı ile taksit ötelemesi sunulabilir.
		Finansal planlama konusunda çalışanın bilgilendirilmesi ve borç sürecinden olumsuz etkilenmemesi adına finansal ve psikolojik açıdan çalışan destek programı oluşturulabilir.

**Tablo 4.13** Karar ağacı ayrıştırma kriteri ve önerileri (Devamı)

Ayrıştırma Kriteri	Açıklama	Öneri
<b>Pozisyon</b>	Pozisyon kriteri beyaz ya da mavi yaka farketmeksizin incelenmiştir. Pozisyona bağlı istifa durumlarında ilk plan açık iletişimin kurulması gerekliliğidir. Kişilik envanterleri ile çalışanlara kariyer yönetimi konusunda destek sağlanabilecektir.	Adil görev dağılımının yapılıp yapılmadığının kontrolü sağlanmalıdır. İş yükünün hesaplanması için iş dengeleme gerçekleştirilmelidir. Norm kadro açığı nedeniyle oluşan fazla iş yükü ise norm kadro analizi ile tespit edilmelidir.
		Çok tehlikeli sınıfta yer alan görevlerde, ilgili pozisyon için çalışma ortamında iyileştirme ya da görev değişikliği imkanı sunulabilir.
		Kariyer hedefleri ile ilgili plan doğrultusunda eğitimler organize ederek gelişim imkanı sunulabilir bu sayede pozisyona aidiyet duygusu oluşabilir.

## 5. TARTIŞMA, SONUÇ VE ÖNERİLER

Demir çelik sektörünün çok tehlikeli olması, ağır sanayi koşullarının da beraberinde getirdiği çalışma koşullarının zorluğu nedeniyle işten ayrılışlara sıklıkla sebebiyet verebilmektedir. Sektör fark etmeksizin nesil değişimi de işten ayrılışların artmasında etkisi göz ardı edilememektedir. İnsan kaynakları yönetiminin fonksiyonları ve amaçlarından olan çalışan tutundurma adına alınacak önlem ve iyileştirmelerin insan kaynakları profesyonelleri tarafından gerçekleştirilmesi gerekmektedir. İşletmeler tarafından mevcut çalışanın tutundurulmasının maliyet ve zaman açısından yeni çalışan istihdam edilmesine göre çok daha avantajlı olduğu bilinmektedir, bu nedenle işten ayrılmanın tahminlenmesi işletmelere zaman ve maliyet açısından fayda sağlayacaktır.

Bu araştırma ile insan kaynakları ve yapay zeka alanında, ham veriler ve birden fazla program kullanılarak ulusal literatüre katkı sağlanmıştır. İnsan kaynakları profesyonellerinin odaklanması gereken temel alanlardan biri olan çalışan tutundurma konusunda, günlük faaliyetlerin yanı sıra yapay zeka gibi ileri teknoloji yöntemlerinden faydalanılması hedeflenmiştir. Bu sayede, değerlendirme ve tahmin süreçlerinde adaletsiz yargılar, öznel değerlendirmeler ve benzeri sorunların önüne geçilmesi amaçlanmıştır.

Çalışmada, demir çelik sektöründeki bir işletmeden alınan ham veriler ile çalışanların işten ayrılma durumu yapay zekanın alt dallarından olan makine öğrenme algoritmaları ile tahminlenmiştir. Makine öğrenmesi algoritmaları Knime ve Python üzerinden uygulanmış ve başarı kriterlerine göre en yüksek başarılı tahminleme gerçekleştiren algoritma belirlenmiştir. İki programda da en başarılı tahminlemeyi sağlayan algoritma Rastgele Orman Algoritması, en başarısız tahminleme gerçekleştiren algoritma ise Knime programında Naive Bayes algoritması, Python programlama dilinde ise Destek Vektör Makineleri Algoritması olduğu belirlenmiştir. Bölüm 5.7’de Knime uygulaması üzerinden belirlenmiş kriterlerde rastgele nitelikler saptanarak örnek uygulama olarak işten ayrılma tahminlenmiştir.

Çalışma kapsamında, araştırmanın yapıldığı işletmenin kullanmış olduğu SAP sistemine geçiş itibarıyla veriler elde edilebilmiştir. Geçmişteki verilerin eksik olması, güncel olmaması vb. nedenler ile temin sağlanamamıştır. Veri gizliliği nedeniyle elde edilen verilerden bazı sayısal nitelikler gruptandırılmıştır. Mesai süresi, işe geç gelme sıklığı gibi eklenmesi planlanan nitelikler büyük boyutlarda olduğundan SAP sisteminden çekilmesi mümkün olamamıştır.

Gelecekteki arařtırmalarda, bu alıřmada yer alan veri sayısı eřitlendirilebilir ve bu nitelikler; gemiř iřyeri ıkıř nedeni, bir nceki iřyerinde alıřma suresi, ka iřyeri deėiřikliėi yaptıėı, izin kota kullanım durumu; devamsızlık gunleri, rapor gunleri, iře ge gelme sıklıėı, iř kazası sayısı, İSG sarı kart / ihlal – uyarı cezası alma durumu, bir nceki dnem performans puanı, bir nceki dnem potansiyel puanı, alıřanın grev aldıėı birim, ikametgah adresi, bir nceki terfiden geen sure, bir nceki dnem yapılan fazla mesai suresi vb. olarak rneklendirilebilir. Yine gelecekteki alıřmalarda, verilerin sayısı arttırılabilir, farklı aėır sanayi sektrlerinde aynı problem ele alınabilir. alıřan memnuniyet, alıřan tutum ve ıkıř anketi vb. anket verileri arařtırmaya dahil edilebilir. ıkıř anketinde;

- alıřma deneyimi
- Oryantasyon, sosyal imkanlar vb.
- Kiřisel geliřim ve eėitim
- Ayrılma kararı

İle ilgili deėerlendirmelerin yer alması nerilebilir. ıkıř anketi ile alıřanların istifa dřncesinde etkin rol oynayan faktrler gzlemlenebilecektir.

İřten ayrılan alıřanlara ıkıř mlakatı yapılarak ilgili sorular zerinden deėerlendirmeye alınmak zere yeni bir veri seti elde edilebilir. Makine ėrenmesi algoritmalarından, Lojistik Regresyon, Doėrusal regresyon, Doėrusal Diskriminant Analizi vb. algoritmalar alıřmaya dahil edilerek performansı deėerlendirilebilir. Gelecekteki alıřmalarda nesne ynelimli programlama dillerinde kullanıcı tarafından kullanımı kolay olacak řekilde arayz tasarlanması nerilebilir. Bu sayede insan kaynakları yneticilerinin yapay zeka ya da ileri bilgisayar becerileri gerekmez niteliklere ilgili deėerleri girerek tahmin et komutu ile alıřanın iřten ayrılma tahminini gerekleřtirebilir. Knime Karar Aėacı Algoritması ıktısı olan karar vermede grselleřtirmeyi kolaylařtıran ıktı sonucu programlama dillerinden yararlanılarak dıřarıya aktarılması saėlanarak ara yz tasarımı ile, İK profesyonellerinin herhangi bir programa gerek duymadan kořulları sırasıyla ilerleterek iřten ayrılma olasılıėı var ya da yok sonucuna ulařması saėlanabilir.

## 6. KAYNAKLAR

- Abdulrahman, S. O. (2023). *Stratejik İnsan Kaynakları Yönetiminde Performans Değerlendirme: Banka Çalışanları Üzerine Bir Araştırma*. Çankırı.
- Ak, B. (2021). Nehirlerdeki Akış Miktarının Destek Vektör Makineleri Ve Bulanık Mantık Yöntemleri İle Modellenmesi. Hatay: İskenderun Teknik Üniversitesi/Mühendislik Ve Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Akyol, H. (2023). Makine Öğrenme Ve Pekiştirmeli Öğrenme Algoritmaları İle Denizaltı Savunma Harbinin Modellenmesi. Ankara.
- Alamsyah, A., & Salma, N. (2018). A Comparative Study Of Employee Churn Prediction Model. *2018 4th International Conference On Science And Technology (Icst)*, 1-4.
- Al-Darraji, S., Honi, D. G., Francesca, F., Abdulsada, A., Giuliano, R., & Abdulmalik, H. (2021). Employee Attrition Prediction Using Deep Neural Networks. *Computers*, 10(11), 141. Doi:10.3390/Computers10110141
- Aldulaimi, S., Mowafak, B., Abdeldayem, M. M., & Abdulaziz, M. (2021). Experimental Perspective Of Artificial Intelligence Technology In Human Resources Management. *Applications Of Artificial Intelligence In Business, Education And Healthcare*, 487-511. Doi:10.1007/978-3-030-72080-3\_26
- Armağan, Y. (2019). Mobilya Tasarımında Yapay Zeka: Tasarım Ve Ar-Ge Merkezleri Üzerinden Bir Değerlendirme. Ankara: Güzel Sanatlar Enstitüsü, Yüksek Lisans Tezi.
- Arromrit, T., Srisakaew, K., Roswhan, N., & Mahikul, W. (2023). A Supervised Machine Learning Method For Predicting The Employees Turnover Decisions. *IEEE 8th International Conference On Software Engineering And Computer Systems (Icsecs)*, 122-127.
- Arslan, B. (2021). İnsan Kaynakları Yönetimi Uygulamaları Ve Algısı; Elazığ Örneği. Elazığ.
- Atalay, M., & Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* (9(22)), 155-172.
- Aydoğan, Ş., Pura, T., & Bingül, F. (2024). Predicting Students' Academic Performances Using Machine Learning Algorithms In Educational Data Mining. *Malaysian Online Journal Of Educational Technology* (12(4)), 131-153.
- Bahadır, M., Bayrak, A., Yüçetürk, G., & Ergün, P. (2021). Kayıp Çalışan Tahminleme Yöntemlerinin Karşılaştırılması. İstanbul.
- Bıkmaz Bilgen, Ö., & Doğan, N. (2017). Puanlayıcılar Arası Güvenirlik Belirleme Tekniklerinin Karşılaştırılması. *Eğitimde Ve Psikolojide Ölçme Ve Değerlendirme Dergisi*, 63-78.
- Bilekdemir, G. (2010). Veri Madenciliği Tekniklerini Kullanarak Üretim Süresi Tahmini Ve Bir Uygulama. İzmir: Dokuz Eylül Üniversitesi, Yüksek Lisans Tezi.
- Bujold, A., Maltais, I. R., Rocheleau, X. P., Boasen, J., Sénécal, S., & Léger, P. (2024). Responsible Artificial Intelligence In Human Resources Management: A Review Of The Empirical Literature. *AI And Ethics*, 1185-1200. Doi 10.1007/S43681-023-00325-1

- Ceylan, E. (2023). İnsan Kaynakları Yönetiminde Kavramlar, İlkeler, Örgütlenme Ve Planlama. İstanbul.
- Chowdhury, S., Dey, P., Edgar, S., Bhattacharya, S., & Rodriguez, E. (2023). Unlocking The Value Of Artificial Intelligence In Human Resource Management Through A1 Capability Framework. *Human Resource Management Review*.
- Cingöz, A. (2011). Stratejik İnsan Kaynakları Yönetimi Ve Stratejik İnsan Kaynakları Yönetiminin Örgütsel Performans Ve İç Girişimcilik (Girişimsel Performans) Üzerindeki Etkileri: Kayseri İmalat Sanayinde Bir Araştırma. Kayseri: Erciyes Üniversitesi Sosyal Bilimler Enstitüsü Doktora Tezi.
- Demir, K., & Çalık, E. (2020). İşgören Seçiminde İnsan Kaynakları Analitiği Yaklaşımının Kullanılması. Yalova: İşletme Araştırmaları Dergisi.
- Doğan, İ., & Doğan, N. (2022). İki Sonuçlu Nitel Veriler İçin Cohen Kappa Katsayısı Ve Ayırt Edilebilirliğin Değerlendirilmesi: Bir Sümülasyon Çalışması. *Türkiye Klinikleri Biyoistatistik Dergisi*.
- Eteman, V. (2024). Makine Öğrenmesinde Açıklanabilirlik Kavramına Derin Pekiştirmeli Öğrenme Ve Sembolik Regresyon İle Hibrit Yaklaşım: Algoritmik Ticaret Örneği. Bursa: Bursa Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi.
- Eyüp Çalık, K. D. (2020). Modelleme Ve Örnek Uygulamalarıyla İnsan Kaynakları Analitiği. Ankara: 1.Basım, *Nobel Akademik Yayınları*.
- Fallucchi, F., & Coladangelo, M. (2020). Predicting Employee Attrition Using Machine Learning Techniques. *Computers*, 9(4), 86.
- Gélinas, D., Sadreddin, A., & Vahidov, R. (2022). Artificial Intelligence In Human Resources Management: A Review And Research Agenda. *Pacific Asia Journal Of The Association For Information Systems*, 1-42. Doi:10.17705/1pais.14601
- Guerranti, F., & Dimitri, G. (2022). A Comparison Of Machine Learning Approaches For Predicting Employee Attrition. *Applied Sciences*, 13,267. Doi:10.3390/13010267
- Hatice Ümit Aksoy Uğurlu, A. D. (2023). İnsan Kaynakları Yönetiminde Dijital Dönüşüm Ve Dijitalleşen İşe Alım İşlevi. İstanbul: Kosbed.
- Hmoud, B. (2021). The Adoption Of Artificial Intelligence In Human Resource Management And The Role Of Human Resources. *In Forum Scientiae Oeconomia*, 105-118. <https://www.researchgate.net/publication/350517240> Adresinden Alındı
- İbiş, M. F. (2022). Teknoloji Ve Yapay Zekanın İnsan Kaynakları Yönetimindeki Rolü. Yozgat.
- İtü. <https://web.itu.edu.tr/~sonmez/lisans/ai/>. İstanbul Teknik Üniversitesi: <https://web.itu.edu.tr/> Adresinden Alındı (Erişim Tarihi:23.11.2023)
- Jatoba, M., Santos, J., Gutierrez, I., Moscon, D., Fernandes, P. O., & Teixeira, J. P. (2019). Evolution Of Artificial Intelligence Research In Human Resources. *Procedia Computer Science*, 137-142. Doi:<https://doi.org/10.1016/j.procs.2019.12.165>
- Kahraman, G. E. (2023). İnsan Kaynakları Yönetimi Uygulamalarından Eğitim Ve Geliştirmenin İşten Ayrılma Niyeti Üzerindeki Etkisinde Örgütsel Bağlılığın Aracı Rolü. Ankara.

- Kambur, E. (2021). Yapay Zeka Çağında İnsan Kaynakları Yönetimi Konusunda Yazılmış Türkçe Makaleler Üzerine Bir Araştırma. Denizli: *Sosyal Bilimler Enstitüsü Dergisi*.
- Karaahmetoğlu, E. (2023). Yapay Zeka Yaklaşımı İle Son Yıllarda Ve Geleceğe Yönelik Mesleki Değişimler Ve Eğilimlerin Analizi. Kırıkkale.
- Kartal, C. (2020). Destek Vektör Makineleri İle Borsa Endekslerinin Tahmini. *İnsan Ve Toplum Bilimleri Araştırmaları Dergisi* (9(2)), 1394-1418.
- Kırılmaz, S. K. (2020). Digital Transformation In Human Resources Management: *Investigation Of Digital Hrm Practices Of Businesses*. Sakarya: Pressacademia.
- Kızılkaya, Y. M., & Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi* (37), 90-98.
- Korytkowski, M., Nowak, J., Scherer, R., Zbieg, A., Zak, B., Relikowska, G., & Mader, P. (2022). Employee Turnover Prediction From Email Communication Analysis. *International Conference On Artificial Intelligence And Soft Computing*, 252-263.
- Köklü, R. (2010, Temmuz). Melen Nehri Su Kalitesinin İstatistiksel Analiz Yöntemleri Ve Yapay Zeka Teknikleri Kullanılarak Değerlendirilmesi. Sakarya.
- Kurtboğan, H. (2023). Yeni Dünyada Yapay Zeka Metaforu Ve Yapay Zekanın Çalışan Performansına Etkisi. Karaman: Karamanoğlu Mehmetbey Üniversitesi, Yüksek Lisans Tezi.
- Kutlugün, M. A. (2017, Aralık). Gözetimli Makine Öğrenmesi Yoluyla Türe Göre Metinden Ses Sentezleme. 30-33. İstanbul: İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Makaritou, P. (2019). The Socioeconomic Disruption Of Artificial Intelligence In The Fourth Industrial Revolution. İstanbul: Bahçeşehir Üniversitesi, Yüksek Lisans Tezi.
- Marvin, G., Jackson, M., & Alam, M. (2021). A Machine Learning Approach For Employee Retention Prediction. *2021 IEEE Region 10 Symposium (Tensymp)*, 1-8.
- Mhatre, A., Mahalingam, A., Narayanan, M., Nair, A., & Jaju, S. (2020). Predicting employee attrition along with identifying high risk employees using big data and machine learning. In *2020 2nd International conference on advances in computing, communication control and networking (icaccn)* (269-276). IEEE.
- Midem, G. (2016). İnsan Kaynakları Yönetiminde İnovasyon (2000'li Yıllardan Günümüze İnsan Kaynakları Yönetimi Gelişim Süreci). Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi. İstanbul.
- Mohbey, K. K. (2020). Employee's Attrition Prediction Using Machine Learning Approaches. *Machine Learning And Deep Learning In Real-Time Applications*, 121-128.
- Nawaz, N., Arunachalam, H., Pathi, B. K., & Gajenderan, V. (2024). The Adoption Of Artificial Intelligence In Human Resources Management Practices. *International Journal Of Information Management Data Insight*, 4(1), 100208.
- Niray, N. (1999). İnsan Kaynakları Yönetiminde Yeni Yönelimler Ve Çanakkale'de İnsan Kaynakları Yönetimi Üzerine Bir Araştırma. Çanakkale: Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi.
- Oruçoğlu, O. (2022). Endüstri 4.0'ın İnsan Kaynakları Yönetimi Fonksiyonlarından İşe Alım'a Etkileri. *İzmir: Ege Stratejik Araştırmalar Dergisi*.

- Öcal, N. (2023). Bağımsız Denetim Firmalarında Yapay Zeka Uygulamaları Ve Denetim Riski. İstanbul.
- Öğündür, G. (2019). Doğruluk (Accuracy) , Kesinlik(Precision) , Duyarlılık(Recall) Ya Da F1 Score. Medium.Com: Medium.Com Adresinden Alındı(Erişim Tarihi: 18.12.2023)
- Ömer Faruk Ereken, Ç. T. (2021). İş Başvurularının Makine Öğrenmesi Yöntemleriyle Değerlendirilmesi. *İzmir: Yönetim Bilişim Sistemleri Dergisi*.
- Özakça, N., Bulus, A., & Çetin, A. (2024). Artificial Intelligence Based Employee Attrition Analysis And Prediction. *In 2024 6th International Conference On Computing And Informatics*, 512-517.
- Palos-Sánchez, P., Badicu, A., & Infante-Moro, J. (2022). Artificial Intelligence And Human Resources Management: A Bibliometric Analysis. *Applied Artificial Intelligence*, 3628-3655. Doi:10.1080/08839514.2022.2145631
- Rohit, P., & Ajit, P. (2016). Prediction Of Employee Turnover İn Organizations Using Machine Learning Algorithms. (İjarai) *International Journal Of Advanced Research İn Artificial Intelligence*, Vol. 5, No. 9, 22-26.
- Seyitoğlu, Z. (2019, Mayıs). Türkiye’de Dijital Halkla İlişkilerde Değişen Müşteri Deneyimi: Chatbot Uygulamaları. İstanbul: İstanbul Kültür Üniversitesi/Lisansüstü Eğitim Enstitüsü/İletişim Sanatları Anabilim Dalı/İletişim Sanatları Bilim Dalı/Doktora Tezi.
- Şahin, S. (2023). Makine Öğrenmesi Algoritmalarını Kullanarak Web Günlük Kayıtlarından Zararlı İsteklerin Tespiti Ve Bulut Tabanlı Bir Sistem Gerçeklenmesi. İstanbul.
- Şahin, T. (2022). İnsan Kaynakları Yönetimine Teknoloji Etkisi: Dijital Yıkıcılık Üzerine. İstanbul.
- Şahinarslan, F. V. (2019). Makine Öğrenmesi Algoritmaları İle Nüfus Tahmini: Türkiye Örneği. İstanbul: İstanbul Teknik Üniversitesi, İşletme Anabilim Dalı, Yüksek Lisans Tezi.
- Şaşmaz, E. C. (2023). Stratejik İnsan Kaynakları Yönetiminde Kurumsallaşma Ve Örgütsel Bağlılık: Gıda Sektöründe Bir Araştırma. Konya: Necmettin Erbakan Üniversitesi, Doktora Tezi.
- Şeker, Ş., & Erdoğan, D. (2018). Knime İle Uçtan Uca Veri Bilimi.
- Şekerli, E. B. (2019). Ticari Havayolu Taşımacılığı Sektöründe Makine Öğrenmesi Uygulamalarının İncelenmesi. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi* (22(2)), 405-419.
- Şengül, Z. (2022). Makine Öğrenmesi Algoritmalarını Kullanarak Bitcoin Fiyat Tahmini. Edirne: Trakya Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi.
- Tiftik, C. (2021). İnsan Kaynakları Yönetiminde Yapay Zekâ Teknolojileri Ve Uygulamaları. *Ibad Sosyal Bilimler Dergisi*, 374-390. Doi:10.21733/İbad.833256
- Uçacak, K. (2020). İnsan Kaynakları Yönetimindeki Yapay Zekâ Tekniklerinin Kamu Sektöründe Uygulanabilirliğinin Değerlendirilmesi. Ankara: *Kamu Görevlileri S. Kongresi Bildirgeler Kitabı 2*. Cilt.
- Uzak, B. (2022). Telekomünikasyon Sektöründe Çalışan Kaybı Tahmini İçin Makine Öğrenmesi Modeli Seçimi. Bursa.

- Ülker, E. (2007). Yapay Zeka Teknikleri Kullanılarak Yüzey Modelleme. Konya.
- Widiyawati, L. M. (2023). Prediction Of Company Employee Resignation Using Naïve Bayes Algorithm, *International Journal Of Scientific Engineering And Science*. *International Journal Of Scientific Engineering And Science*, 29-33.
- Yaldız, Y. (2020). Seyahat Sigortalarında Tazminat Talep Tahmini. İstanbul.
- Yang, J., Awan, A., & Vall-Llosera, G. (2019). Support Vector Machines On Noisy Intermediate Scale Quantum Computers. *Arxiv Preprint Arxiv*, 1909.11988. Doi:10.48550/1909.11988
- Yazıcı, M. B. (2023). Yapay Zeka Ve Makine Öğrenmesi Yöntemleri İle Yazılım Kalite Tahmini. Ankara.
- Yıldırım, M. (2021). Yelken Balığı Eniyileme Yaklaşımı İle Güçlendirilmiş Karar Ağacı Algoritması Kullanarak Kalp Rahatsızlıklarının Teşhisi. Isparta.
- Yılmaz, Ö. İ. (2022). Yapay Zekâ Bağlamında İnsan Kaynakları Yönetimi. Kahramanmaraş.
- Yüksel, Z. K. (2023). İnsan Kaynakları Yönetiminde Yapay Zeka Ve Türkiye Uygulaması. İstanbul.
- Zilyas, D., & Yılmaz, A. (2023). Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* (14(3)), 437-447.

## ÖZGEÇMİŞ

Adı-Soyadı : Nurselin SÜLLÜ

### Eğitim ve Mesleki Geçmişi:

- 2022 - 2024, Alanya Alaaddin Keykubat Üniversitesi, Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Anabilim Dalı
- 2016 - 2020, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Endüstri Mühendisliği
- 2022 - , Anadolu Üniversitesi, Açıköğretim Fakültesi, İnsan Kaynakları Yönetimi