



Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

İş Analitiği Bilim Dalı

**PANDEMİ DÖNEMİNİN TÜRK SAVUNMA SEKTÖRÜNDE
GÖNÜLLÜ İŞTEN AYRILMA NEDENLERİNE ETKİSİ VE
AYRILMA NİYETİNİN TAHMİNLENMESİ**

Aysu ERÖZEL

Yüksek Lisans Tezi

Ankara, 2024

PANDEMİ DÖNEMİNİN TÜRK SAVUNMA SEKTÖRÜNDE
GÖNÜLLÜ İŞTEN AYRILMA NEDENLERİNE ETKİSİ VE
AYRILMA NİYETİNİN TAHMİNLENMESİ

Aysu ERÖZEL

Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

İş Analitiği Bilim Dalı

Yüksek Lisans Tezi

Ankara, 2024

KABUL VE ONAY

Aysu Erözel tarafından hazırlanan "Pandemi Döneminin Türk Savunma Sektöründe Gönüllü İşten Ayrılma Nedenlerine Etkisi ve Ayrılma Niyetinin Tahminlenmesi" başlıklı bu çalışma, 06.09.2024 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Prof. Dr. Fazıl GÖKGÖZ (Başkan)

Prof. Dr. Kazım Barış ATICI (Danışman)

Prof. Dr. Mehmet SOYSAL (Üye)

Doç. Dr. Mustafa ÇİMEN (Üye)

Dr. Öğr. Üyesi Bülent ÇEKİÇ (Üye)

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylıyorum.

Prof.Dr. Uğur ÖMÜRGÖNÜLŞEN

Enstitü Müdürü

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinleri yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H.Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. ⁽¹⁾
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir. ⁽²⁾
- Tezimle ilgili gizlilik kararı verilmiştir. ⁽³⁾

...../...../2024

Aysu ERÖZEL

“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

- (1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir *. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.
Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

* Tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu tarafından karar verilir.**

ETİK BEYAN

Bu çalışmadaki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi, görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduğumu, tezimin kaynak gösterilen durumlar dışında özgün olduğunu, **Prof. Dr. Kazım Barış ATICI** danışmanlığında tarafımdan üretildiğini ve Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü Tez Yazım Yönergesine göre yazıldığını beyan ederim.

Aysu ERÖZEL

TEŞEKKÜR

Hayatımın her alanında beni yüreklendiren ve hep yanımda olan canım aileme, ilk öğretmenim ve babam Prof. Dr. Ahmet Zeki Erözel'e, çalışkanlığıyla ve sabrıyla örnek aldığım annem Nuran Erözel'e, hiçbir zorlukta yılmayan en büyük desteğim ablam Güzen Erözel Muslu'ya, enişteden çok öte olan abim Çağlar Muslu'ya ve gözbebeğim, biricik yeğenim Peri Muslu'ya, bu yoğun süreçte bana sevgisiyle destek olan oğlum ve köpeğim Pumpkin'e; güvenlerini hep hissettiğim yakın arkadaşlarım ve canım dostlarım Damla Özgül, Melda Gürel ve Hikmet Özge Bacak'a; bu programa başlarken beni yapabileceğim konusunda motive etmiş ve her anlamda bana yardımcı olmuş eski yöneticim Ongun Can Özkaya'ya ve iş arkadaşım Oğuzhan Efe Şakrak'a; kariyer yolculuğumda desteklerini esirgemeyen Direktörüm Ali Işık'a; iş hayatı, okul hayatı ve sosyal hayat dengesini kurarken anlayışla yanımda olan dostum ve yöneticim Seval Dönmez'e; birlikte çalışma fırsatı bulduğum ve bu dönemde destekleriyle çalışmaya zaman bulup motive olmamı sağlamış olan ekip arkadaşlarım Erkut Kaan Gökdemir, Serkan Şahal, İrem Ateş, Meryem Erdal Demirci, Ali Emre Polat ve Muhammed Fevzi Koç'a; program boyunca öğrettikleri bilgiler sayesinde yeni bakış açılarıyla yepyeni şeyler öğrenmemi sağlamış olan ve bu program vasıtasıyla tanıdığım tüm değerli hocalarıma, özellikle en çıkmazda hissettiğim dönemlerde yapıcı yaklaşımı, bilgi ve yönlendirmeleriyle bu çalışmayı gerçekleştirebilmemi ve bitirebilmemi sağlamış olan tez danışmanım ve değerli hocam Prof. Dr. Kazım Barış Atıcı'ya, tez komisyonumda beni değerlendiren ve gelişim odaklı yaklaşımlarıyla bana örnek olan yine çok değerli hocalarım Prof. Dr. Fazıl Gökgez, Prof. Dr. Mehmet Soysal, Dr. Öğr. Üyesi Bülent Çekiç ile bu programa vizyoner bir bakış açısıyla yaklaşmamda aktardığı bilgilerle destek olan Doç. Dr. Mustafa Çimen'e destekleri için çok teşekkür ederim.

ÖZET

ERÖZEL, Aysu. *Pandemi Döneminin Türk Savunma Sektöründe Gönüllü İşten Ayrılma Nedenlerine Etkisi ve Ayrılma Niyetinin Tahminlenmesi*, Yüksek Lisans Tezi, Ankara, 2024

Günümüz rekabet koşullarında işten ayrılma durumları örgütlere maliyet getirmektedir. Bu maliyetlerin önüne geçebilmek amacıyla özellikle son dönemde yapılan araştırmalar artmış; analitik yöntemlerin insan kaynakları alanında da kullanılmasıyla birlikte işten ayrılma nedenleri ve işten ayrılma niyetinin tahminlenmesi üzerine birçok çalışma yapılmıştır. Bu çalışmada, özellikle Covid-19 ile yaşanan pandemi döneminde değişen koşulların, çalışanların işten ayrılma niyetlerine etkisi ile pandemi öncesi ve sonrası dönemde işten ayrılma niyetinin tahminlenmesine yönelik gerçek veriler üzerinden örnek bir uygulama gerçekleştirilmesi amaçlanmıştır. Çalışma kapsamında, Türkiye’de savunma sektöründe faaliyet gösteren bir şirketin 2017-2023 yılları arasında şirkette bulunmuş çalışanlarına ait demografik, organizasyonel ve istihdam durumu verileri kullanılmıştır. Analizlerde, denetimli makine öğrenmesi sınıflandırma yöntemlerinden ikili lojistik regresyon, k en yakın komşuluk algoritması, destek vektör makinesi, karar ağacı ve rassal orman yöntemleri uygulanmış; modeller arası tahmin başarılarını karşılaştırabilmek için farklı örneklem büyüklüklerini içeren yaklaşımlar tasarlanmıştır. Uygulamada *Orange* Veri Madenciliği ve *International Business Machines Corporation (IBM) SPSS* İstatistik programlarından faydalanılmıştır. Yapılan analizler sonucunda, çalışanların organizasyonel bilgilerinin pandemi sonrası dönemde ayrılma kararı alma ihtimallerinde etkili hale geldiği görülmüştür. Buna ek olarak, ayrılma niyetini tahminlemek için elde edilen model performansları doğruluk (CA) ve eğri altındaki alan (AUC) göstergelerine göre yaklaşık yüzde 50 ve yüzde 80 arasında olmuştur. Çalışma sonucunda model başarılarının, verilerin ait olduğu dönem, örneklem büyüklüğü, hiperparametre değerleri, özniteliklerin sayısı gibi birçok özellikten etkilendiği gözlemlenmiştir.

Anahtar Sözcükler

İşten ayrılma, ayrılma niyeti, işten ayrılma niyetini tahminleme, makine öğrenmesi, denetimli öğrenme, sınıflandırma yöntemleri, karışıklık matrisi.

ABSTRACT

ERÖZEL, Aysu. *The Effect of Pandemic on Voluntary Turnover and Prediction of Turnover Intention in Turkish Defence Sector*, Master's Thesis, Ankara, 2024.

In today's competitive environment employee turnover creates extra costs for organizations. In order to prevent this cost, the number of academic research has increased recently. Besides, with the growing use of analytical methods in the field of human resources, more studies have been conducted on employee turnover and prediction of employee turnover intention recently. This study is an exemplary application based on real data to predict the impact of the changing conditions during the pandemic period with Covid-19 on employees' turnover and turnover intention before and after the pandemic. Within the scope of the study, demographic, organizational and employment status data between 2017 and 2023 of the people working in the company which is operating in the defense sector in Turkey is used. In the analysis, supervised machine learning methods such as binary logistic regression, k nearest neighbors, support vector machine, decision tree and random forest are applied. In order to compare the models' performances different approaches with different sample sizes are designed. Orange Data Mining and International Business Machines Corporation (IBM) IBM SPSS Statistics programs are used for modeling. As a result of the analysis, it was revealed that in the post-pandemic period organizational factors become effective in deciding whether to leave the job. In addition, it is found that the accuracy and AUC scores of the prediction models are approximately between 50 percent and 80 percent. Moreover, it was observed that model prediction performance is affected by many aspects such as the period to which the data belongs, the sample size, hyperparameter values and the number of features included in the model.

Keywords

Employee turnover, turnover intention, prediction of turnover intention, machine learning, supervised learning, classification methods, confusion matrix

İÇİNDEKİLER

KABUL VE ONAY.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI.....	ii
ETİK BEYAN.....	iii
TEŞEKKÜR	iv
ÖZET	v
ABSTRACT	vi
İÇİNDEKİLER.....	vii
KISALTMALAR DİZİNİ.....	x
TABLolar DİZİNİ.....	xii
ŞEKİLLER DİZİNİ.....	xiii
GİRİŞ.....	1
1. BÖLÜM: İŞTEN AYRILMA KAVRAMI VE ANALİZ YÖNTEMLERİ.....	4
1.1. İŞTEN AYRILMA KAVRAMI	4
1.1.1. Çalışan Devir Oranı	5
1.2. İŞTEN AYRILMA NİYETİ	6
1.2.1. İşten Ayrılma Niyetini Etkileyen Faktörler	7
1.2.2. İşten Ayrılma Niyetinin Tahminlenmesi	9
1.3. PANDEMİ DÖNEMİNİN İŞTEN AYRILMA NİYETİ ÜZERİNE ETKİSİ	9
1.4. İŞTEN AYRILMA NİYETİ SAYISAL ANALİZ YÖNTEMLERİ	11
1.4.1. Ayrılma Nedenleri ve Niyetine Yönelik Sayısal Analiz Yöntemleri	11
1.4.2. İşten Ayrılma Niyeti Tahmini Analiz Yöntemleri	12
2. BÖLÜM: VERİ	19
2.1. VERİ TOPLAMA VE VERİ AYIKLAMA SÜRECİ.....	19
2.1.1. Veri Toplama Süreci	19

2.1.2. Veri Ayıklama Süreci	20
2.2. KULLANILAN VERİLER	22
2.2.1. Anahtar Veri.....	22
2.2.2 İstihdam Verileri	22
2.2.3. Demografik Veriler	23
2.2.4. Organizasyonel Veriler	24
3. BÖLÜM: BETİMSEL ANALİZLER	27
3.1. AYRILIŞLAR VE İSTİHDAM ÖZELLİKLERİ.....	27
3.2. AYRILIŞLAR VE DEMOGRAFİK ÖZELLİKLER.....	29
3.3. AYRILIŞLAR VE ORGANİZASYONEL ÖZELLİKLER	32
3.4. BETİMSEL ANALİZ BULGULARI	37
4. BÖLÜM: YÖNTEM	38
4.1. ANALİZ TASARIMI	38
4.1.1. Popülasyondan Örneklem Oluşturma ve Kullanılan Yaklaşımlar	38
4.2. MODEL KURULUMU	41
4.2.1. Ayrılış Niyetine Etki Eden Faktörlerin Analizi	41
4.2.2. İkili Lojistik Regresyon	43
4.2.3. Ayrılış Niyeti Tahminleme Model Senaryosunun Oluşturulması	44
4.2.4. K En Yakın Komşuluk	48
4.2.5. Destek Vektör Makinesi	49
4.2.6. Karar Ağacı.....	50
4.2.7. Rassal Orman.....	51
4.2.8. Model Başarı Ölçütleri	52
5. BÖLÜM: BULGULAR	54
5.1. AYRILMA NİYETİNE ETKİ EDEN FAKTÖRLER	54
5.2. AYRILMA NİYETİNİN TAHMİNLENMESİ	58
5.3. GENEL BULGULAR	62
SONUÇ.....	65
KAYNAKÇA	68

EK 1. ORİJİNALLİK RAPORU	78
EK 2. ETİK KURUL / KOMİSYON İZİNİ YA DA MUAFİYET FORMU	80
EK 3. SPSS VE ORANGE ANALİZ SONUÇLARI ÖRNEK (ÖRNEKLEM-1) EKRAN GÖRÜNTÜLERİ.....	82

KISALTMALAR DİZİNİ

AIHR	Yenilikçi İK Akademisi
ANN	Yapay sinir ağları
AUC	Eğri altındaki alan
CA	Doğruluk
DN	Doğru negatif
DP	Doğru pozitif
DT	Karar ağacı
EYT	Emeklilik Yaşa Takılanlar
GBDT	Gradyan Arttırıcı Karar Ağacı
IBM	<i>International Business Machines Corporation</i>
İK	İnsan kaynakları
KNN	K en yakın komşuluk
LDA	Doğrusal diskriminant analizi
LR	İkili lojistik regresyon
MLP	Çok katmanlı algılayıcı
NB	<i>Naive Bayes</i> sınıflandırıcı
NN	Sinir ağları
RBF	Radyal tabanlı fonksiyon
RF	Rassal orman
SPSS	<i>IBM SPSS</i> İstatistik programı
SVM	Destek vektör makinesi
Orange	<i>Orange</i> Veri Madenciliği programı

YN Yanlış negatif

YP Yanlış pozitif

TABLOLAR DİZİNİ

Tablo 1. Ayrılma niyetinin tahminlenmesi üzerine yapılmış örnek araştırmalar.	15
Tablo 2. Modelde kullanılan değişkenler / öznelilikler	25
Tablo 3. Popülasyon verisi	26
Tablo 4. Çalışanların işe başlama ve son işten ayrılma tarihlerine göre dağılımı	27
Tablo 5. Deneyim süreleri ve ayrılış tarihine göre ayrılan çalışan dağılımı	28
Tablo 6. Deneyim dağılım tablosu	28
Tablo 7. Ana iş gruplarının pandemi öncesi ve sonrası ayrılışlardaki dağılımı..	33
Tablo 8. Pandemi öncesi ve sonrası ayrılan çalışanların organizasyon bölümlerine göre dağılımı	34
Tablo 9. Pandemi öncesi ve sonrası dönemde ayrılan çalışanların performanslarına göre yüzdesel dağılımı	36
Tablo 10. Yüksek performanslı ve işten ayrılan çalışanların yaş ve dönemsel dağılımı	37
Tablo 11. Çalışmada kullanılan yaklaşımlar.....	40
Tablo 12. Yaklaşım 4. Pandemi sonrası performansı yüksek çalışanlar	41
Tablo 13. SPSS istatistik programı ikili lojistik regresyon model ölçüm değerleri	54
Tablo 14. İkili lojistik regresyon değişken tablosu	56
Tablo 15. Öznelilik etkileri	57
Tablo 16. <i>Orange</i> ayrılış tahminleme modeli hiperparametre ayarları	59
Tablo 17. Model test başarı göstergeleri	60
Tablo 18. Model tahmin başarı ölçütleri	62
Tablo A.1. Model özeti	80
Tablo A.2 Hosmer ve Lemeshow testi	80
Tablo A.3. SPSS Karışıklık Matrisi	80
Tablo A.4. Değişken tablosu	81
Tablo A.5. Hiperparametre ayarları yapılmadan önce test başarı ölçütleri.....	82
Tablo A.6. Örnek hiperparametre ayar ekranı	82
Tablo A.7. <i>Orange</i> karışıklık matrisi.....	83

ŞEKİLLER DİZİNİ

Şekil 1. Çalışan ayrılış niyetini etkileyen temel faktörler (AIHR).....	8
Şekil 2. Kullanılan veri grupları	23
Şekil 3. Cinsiyete göre işten ayrılma durumu.....	29
Şekil 4. Çalışanların yaşlarına göre istihdam durumları	30
Şekil 5. Pandemi öncesi ve sonrası ayrılan çalışanların yaşlarına göre dağılımı	31
Şekil 6. Çalışanların ayrılışlardaki yüzde dağılımı ile çocuk sayısı ilişkisi	31
Şekil 7. Eğitim durumuna göre dağılım	31
Şekil 8. Ana iş grubuna göre dağılım	32
Şekil 9. Halen çalışmakta olan ve işten ayrılmış olan çalışanların yerleşkelere göre dağılımı.....	33
Şekil 10. Bağlı oldukları bölüme göre pandemi öncesi ve sonrası çalışan sayıları	34
Şekil 11. İşten ayrılış durumlarına göre çalışanların performans bazlı dağılımı	35
Şekil 12. Performanslarına göre çalışanların işten ayrılma ya da halen şirkette çalışıyor olma yüzdeleri	36
Şekil 13. <i>Orange</i> programı örneklem oluşturma senaryosu	39
Şekil 14. Model tahmininde öznitelik etkileri <i>Orange</i> programı senaryosu	42
Şekil 15. Makine öğrenmesi yöntemleri	46
Şekil 16. Ayrılış niyeti tahmin modeli oluşturma <i>Orange</i> programı senaryosu ..	47
Şekil 17. K en yakın komşuluk örneği	48
Şekil 18. Destek vektör makinesi örneği	49
Şekil 19. Karar ağacı yapısı	51
Şekil 20. Karışıklık matrisi	52
Şekil A.1.ROC eğrisi.....	83
Şekil A.2.Karar ağacı.....	84
Şekil A.3.Öznitelik etkinliği.....	84

GİRİŞ

Günümüzde rekabet koşullarının artmasıyla birlikte örgütler için başarının sürdürülebilirliği ve düşük maliyetlerle hizmet vermek ya da üretim yapabilmek en önemli hedefler haline gelmiştir. Bu anlamda hem sürdürülebilirlik hem de maliyet açısından çalışanların işten ayrılmaları örgütler için oldukça olumsuz bir durum oluşturmaktadır (Çağlar, 2018). Bir çalışan işten ayrıldığında, çalışana yapılan yatırımlar, kaybedilen deneyim ve bu deneyimin yerini doldurmak için yapılacak yeni yatırımların hepsi örgütler için ayrılış maliyeti oluşturmaktadır (Gazi, 2024). Hem yetenek rekabetlerinde öne geçebilmek hem de bu maliyetlerin azaltılabilmesi için son dönemde insan kaynakları (İK) başta olmak üzere çalışanların gönüllü işten ayrılmaları birçok davranışsal ve sayısal farklı alanın araştırma konusu olmuştur. Bu çalışmaların temel amacı, çalışanın işten ayrılma nedenlerinin araştırılması ve çalışanların ayrılma niyetlerinin önceden tahminlenmesi üzerine olmaktadır. Böylece, bulgular ışığında işten ayrılmaların önüne geçecek ya da işten ayrılmaları azaltacak yönde politikalar yöneticiler tarafından uygulanabilecektir (Najafi-Zangeneh, 2021).

Bu çalışma kapsamında yapılan literatür araştırmasında, işten ayrılma nedenlerinin analizi ve çalışan işten ayrılma niyetinin tahminlenmesi için yapılan araştırmaların birçoğunda denetimli makine öğrenmesi sınıflandırma yöntemlerinden yararlanıldığı gözlemlenmiştir. Son dönemde, veri madenciliği ve teknoloji alanındaki ilerlemeler makine öğrenmesi algoritmalarının İK gibi sosyal alanlar dahil birçok alanda kullanılmasına neden olmuştur. Makine öğrenmesi, mevcut verileri çeşitli yöntemler üzerinden öğrenen makinenin bu bilgiyle yeni gelen veri için tahminleme modelleri oluşturmasıdır. Makine öğrenmesi yöntemleri genel olarak denetimli (*supervised*), denetimsiz (*unsupervised*) ve pekiştirmeli öğrenme olarak gruplandırılmaktadır. Bu yöntemlerden, denetimli öğrenme yönteminde, veriler belli bir etikete sahiptir ve bu şekilde öğrenme süreci denetimli olarak gerçekleştirilmektedir. Herhangi yeni bir verinin ait olduğu sınıfı ya da etiketi tahminlemek üzere uygulanan denetimli makine öğrenmesi yöntemleri ise sınıflandırma yöntemleridir. Bu çalışmada, sınıflandırma yöntemleri kullanılarak gerçek bir tahminleme uygulaması yapılması; sonuçların yorumlanması ve bu yöntemlerin model tahmin başarılarının farklı yaklaşımlar üzerinden karşılaştırması hedeflenmiştir.

Özellikle, 2020 yılı Mart ayında Covid-19 ile yaşanan pandeminin de etkisiyle, başta iş hayatı koşulları olmak üzere birçok konuda değişimler yaşanmış; çalışanların işten ayrılma niyetlerinde ve sayılarında pandemi öncesi ve sonrasındaki dönemlerde farklılaşmalar olduğu gözlemlenmiştir. Buna paralel olarak, çalışmada çalışanların ayrılma niyetinin Türkiye’de faaliyet gösteren bir savunma sanayii şirketi özelinde özellikle Covid-19 ile yaşanan pandemi dönemi ve sonrasında nasıl bir değişim gösterdiğinin analiz edilmesi ve ayrılma niyeti ihtimallerini her iki dönem için önceden tahmin edebilecek bir model geliştirilmesi, özellikle İK uzmanları için örnek teşkil edebilecek bir tahminleme çalışması yapılması amaçlanmıştır. Bu amaçla, şirketin 2017-2023 yılları arasında şirkette çalışmış olan çalışanlarının İK verileri kullanılmıştır. Denetimli sınıflandırma makine öğrenmesi yöntemlerinden ikili lojistik regresyon (*binary logistic regression – LR*), k en yakın komşuluk algoritması (*k nearest neighbour – KNN*), destek vektör makinesi (*support vector machine-SVM*), karar ağacı (*decision tree-DT*) ve rassal orman (*random forest -RF*) yöntemleri uygulanarak tahmin modelleri oluşturulmuş ve analiz bulguları yorumlanarak, model başarıları çeşitli performans ölçümlerine göre farklı yaklaşımlar üzerinden karşılaştırılmıştır.

Çalışmanın ilk bölümünde, işten ayrılma ile ilgili analizlere geçmeden önce, bu konunun önemi, yapılan araştırmalar ışığında tespit edilen çalışanın işten ayrılma nedenleri ve pandemi ile değişen iş hayatı koşullarının yeni düzende çalışan beklentilerine etkileri aktarılmıştır. Buna ek olarak bu bölümde, işten ayrılma ve işten ayrılma niyeti kavramlarına değinilmiş ve bu alanda yapılmış sayısal analiz yöntemleri, yapılan araştırmalar ışığında özetlenmiştir.

İkinci bölümde, yapılan analizde kullanılan ve Türkiye’de savunma sektöründe faaliyet gösteren bir şirkete ait 2017-2023 yılları arasındaki gerçek çalışan verileri ve öznitelikler ayrıntılı olarak sunulmuştur. Popülasyon verilerinin anlatıldığı bu bölümde, verilerin kaynağı, veri ayıklama süreci, veri kategorizasyonu ve veri özniteliklerinin açıklamaları detaylı olarak aktarılmıştır.

Üçüncü bölümde, popülasyon verileri kullanılarak işten ayrılma ve pandemi dönemi odağında yapılan betimsel analizlere yer verilmiştir. Özniteliklerdeki değişimler ile veri incelendiğinde ortaya çıkan betimsel bulgular bu bölümde özetlenmiş; çıkan sonuçlar şirketin yapısı da göz önüne alınarak değerlendirilmiştir.

Uygulama yönteminin aktarıldığı dördüncü bölümde, analizlerde karşılaştırma yapabilmek amacıyla kullanılan dört ayrı örneklem alma yaklaşımı anlatılmıştır. Yine bu bölümde *Orange* Veri Madenciliği (*Orange*) programı ile örneklem alma yöntemi ve analiz tasarımlarına yer verilmiştir. Yapılan analizlerin daha net anlaşılabilmesi için nedensellik ve tahminleme analizleriyle bu analizlerde kullanılan makine öğrenmesi sınıflandırma yöntemlerinden LR, KNN, SVM, DT ve RF yöntemlerine değinilmiştir. Buna ek olarak, ayrılma niyeti nedenlerinin tespit edilmesinde kullanılan *International Business Machines Corporation (IBM) SPSS İstatistik (SPSS)* programında ikili lojistik regresyon analizi sonuçları ile ayrılma niyeti tahminlemede kullanılan *Orange* programında ortaya çıkan model başarı göstergelerinin açıklamaları bu bölümde detaylı olarak anlatılmıştır.

Çalışmanın son ama en önemli bölümünde ise öncelikle, işten ayrılma nedenlerini araştırmak için yapılan LR analizinin sonuçlarına dair bulgulara değinilmiştir. Ardından, dört farklı yaklaşım ve bu yaklaşımların içerdikleri örneklemeler özelinde, ayrılma niyetini tahminlemek için yapılan analiz sonuçları sunulmuş, analiz sonuçlarında elde edilen model performanslarına dair çıktılar yorumlanarak, çalışma ve kullanılan yöntemler hakkında genel değerlendirilmeler ve çıkarımlar yapılmıştır.

Bu çalışmada, işten ayrılma nedenlerinin araştırılması ve çalışanların işten ayrılma niyetlerinin farklı yaklaşım ve yöntemlerle modellenmesi, bu alanda örnek bir uygulama gerçekleştirilmesi hedeflenmiştir. Bu konuda yapılan çalışmalardan farklı olarak bu çalışmada pandemi dönemi ile gelen değişimlerin gözlemlenmesi amaçlanırken yine birçok çalışmada olduğundan farklı şekilde gerçek çalışan verileri kullanılarak uygulama gerçekleştirilmiştir. Çalışmada aktarılan bilgilerin ve sonuçların her akademik araştırmada olduğu gibi bu alanda yapılan diğer çalışmalara örnek teşkil etmesi ve geliştirilmesi esas hedeflenen çıktıdır.

1.BÖLÜM

İŞTEN AYRILMA KAVRAMI VE ANALİZ YÖNTEMLERİ

1.1.İŞTEN AYRILMA KAVRAMI

Frederick W. Taylor tarafından 20. Yüzyılda ortaya çıkarılan bilimsel yönetimin ilkeleri, iş yerinde verimliliği sağlamak üzerine odaklanarak insan sermayesinin etkin kullanımı ve bağlantılı olarak işle ilgili analizleri gündeme getirmiştir (Alanlı, 2022). Ardından yaşanan teknolojik gelişmeler ve üretimde meydana gelen rekabetçi ortam ise örgütlerin sermayesinde insan kaynağının önemli bir rol oynadığını ortaya çıkarmış; çalışanların örgüt içerisindeki rolü ve örgüt sermayesine katkıları daha görünür hale gelmiştir (Obedgiu, 2017). Bu gelişmeler sonucunda, çalışanın yönetilmesi kavramı yerini çalışan motivasyonunun (*motivation*) ve çalışanın organizasyona bağlılığının (*engagement*), çalışan yaşam döngüsündeki (*employee life-cycle*) tüm adımların stratejik olarak yönetilmesi gibi kavramlara bırakmıştır (Greer, 2021). Çalışanlar yani örgütün insan kaynağı, stratejik bir öneme sahip olmuştur. Bununla bağlantılı olarak, insan kaynakları alanında yapılan çalışmalar ve ortaya çıkan kavramlar çeşitlenmiş ve bu kavramlardan biri de “işten ayrılma (*employee turnover*)” kavramı olmuştur. “İşten ayrılma (*employee turnover*)” çalışanın bağlı olduğu örgütle ilişkisinin kesilmesi olarak tanımlanabilir ve gerçekleşmiş olan olayı tanımlayan bir terimdir (Lazzari vd., 2022). Aslında işten ayrılma, ayrılan çalışanın yerine bir başkasının gelmesiyle oluşan bir devir daim durumunu da tanımlamaktadır (Ongori, 2007).

İşverenler için rekabet ortamında başarıyı sürdürebilmekte çalışanlarının örgütteki sürekliliğini sağlamak önemlidir. Bu nedenle, işten ayrılma durumu, aslında işverenlerin yakından takip ettikleri ve stratejik öneme sahip bir konudur. Bu konuda Hom vd. (2019) tarafından da aktarıldığı gibi işten ayrılmaların örgütlerin ve araştırmacıların önemsendiği konular içerisinde yer almaya başlaması oldukça eski zamanlara dayanmaktadır çünkü işten ayrılmalar aslında örgüte çeşitli maliyetler de getirmektedir. İşten ayrılma maliyetleri (*turnover costs*), olarak geçen bu maliyetler sadece çalışana yapılan eğitim ve diğer gelişim maliyetleri değil, çalışanın deneyiminden ötürü kaybedilen sermaye, ayrılan çalışanın yerine yapılan yeni işe alım maliyetleri ve yeni işe alınan çalışanın eğitim maliyetlerini de içermektedir (O’Connell ve Kung, 2007) (Yiğit ve Shourabizadeh, 2017).

Hatta bunların yanında, ayrılan çalışanın diğer çalışanlar üzerinde sebep olduğu olumsuz etmenler de hesaplanamayan maliyetler olarak gösterilmektedir (Bhartiya vd., 2019). İşten ayrılma kavramı üzerine yapılan ve ilerleyen bölümlerde aktarılacak olan birçok araştırma ve analizin temel amacı bu maliyetlerin azaltılması olmaktadır.

1.1.1. Çalışan Devir Oranı

İşten ayrılma maliyetlerinin azaltılması üzerine yapılan analizlerin tümünde işten ayrılma gerçekleştirmelerini içeren geçmiş verilerden yararlanılmaktadır. Bu analizlerde en temel gösterge olarak kullanılan veri ise işten ayrılmalarla ilgili mevcut durumu yansıtmak üzere hesaplanan “çalışan devir oranı (*employee turnover rate*)” ‘dır. Çalışan devir oranı, bir örgütün belli bir dönemde işten ayrılan çalışan sayısının aynı dönem içindeki ortalama mevcut çalışan sayısına bölümünün 100 ile çarpılmasıyla hesaplanır (Acar vd.,2017). Bu oran, örgütün hem zaman içinde hem de kendi sektöründeki rakiplerine oranla çalışanlarını ne kadar elinde tutabildiğinin bir göstergesi olarak değerlendirilmektedir. Bu göstergenin yorumlanması, sektör dinamikleri ve iş türüne göre değişkenlik göstermektedir (Richardson, 1999).

Çalışan devir oranının yüksek olması ya da artan bir trend izlemesi, örgütler tarafından işten ayrılma maliyetlerinin artışına işaret ettiğinden istenmeyen bir durum olarak görülmektedir. Bu bakış açısıyla, çalışan devir oranının örgüt ve çalışan performansını etkileyen diğer metriklerle ilişkisi de araştırmacıların merak ettiği konular arasında yer almıştır. Bu araştırmalar genel olarak bu göstergenin örgüt performansı ve insan kaynakları ile ilgili konuları açıklamakta ne kadar etkin olduğunu tartışan çalışmalar olmaktadır. Örnek olarak, Acar vd. (2017) çalışan devir oranı ile yetenek yönetimi arasındaki ilişkiyi, Akduman vd. (2013) çalışan devir oranı ile ciro arasındaki ilişkiyi, Deery ve Shaw (1999) organizasyonel kültür ile çalışan devir oranı arasındaki ilişkiyi, Warrad ve Al Omari (2015) sektör performansı ile çalışan devir oranı arasındaki ilişkiyi ve Richardson vd. (1999) çalışan devir oranı ile satışlar arasındaki ilişkiyi farklı sektörlerden örneklemeler üzerinde farklı zaman aralıklarında analiz etmişlerdir. Çalışmalarda, konu özelinde farklı sonuçlara ulaşılmış olsa da ortak olarak görülen ve dikkat çekilen nokta çalışan devir oranının yüksek olmasının işten ayrılışları azaltmaya yönelik aksiyon alınırken yanıtıcı bir gösterge olabildiğidir.

Çalışan devir oranının sadece çalışanların ayrılma trendini gösteren bir veri olabileceği, devir oranının yüksek olmasının arkasında yatan ve ileride ayrılışa sebep olabilecek temel etkenlerin tespitinin mevcut durumdan daha önemli olduğu ve aksiyon planları oluşturulurken öncelikli olarak ayrılmaya etken olan nedenlerin tespit edilerek bu nedenlerin dikkate alınması gerektiği belirtilmektedir (Cohen vd., 2016). Bu çıkarımdan yola çıkarak, işten ayrılma konusunda ortaya çıkan diğer bir önemli kavram olan “işten ayrılma niyeti (*turnover intention*)” kavramı gündeme gelmiştir.

1.2. İŞTEN AYRILMA NİYETİ

İşten ayrılmalar, “gönüllü ayrılış (*voluntary turnover*)” ve “zorunlu ayrılış (*involuntary turnover*)” olarak ikiye ayrılmaktadır (Lazzari vd., 2022). Gönüllü ayrılışlar, çalışanların kendi istekleriyle işten ayrılmalarını tanımlarken; zorunlu ayrılışlar çalışanlar tarafından değil örgütün isteğiyle gerçekleşen işten ayrılmalarıdır (Alhashmi, 2019). Bu konuda, ek bir görüş olarak Hom vd. (2019) tarafından araştırmacılar arasında hangi ayrılışların gönüllü sayılacağı yönünde net olarak yapılamayan ayrımlar olduğu da belirtilmektedir. Örneğin, emeklilik kavramı hem gönüllü bir ayrılış şekli olabilmekte hem de yaş sebebiyle kanuni olarak zorunlu bir ayrılış haline gelebilmektedir. Burada, hangi ayrılışların gönüllü hangi ayrılışların zorunlu sayılacağı, örgütler tarafından yürütülen analizlerin amaçları ve insan kaynakları uygulamalarına göre şekillenmektedir.

Zorunlu ayrılış maliyetleri örgütün çoğunlukla öngörerek karar verdiği maliyetler olurken gönüllü ayrılış maliyetleri örgütün önceden tahmin edemediği çalışan davranışlarıyla meydana gelen maliyetler olmaktadır. Bu nedenle, işten ayrılmalar üzerine yapılan araştırmaların birçoğunda gönüllü ayrılışlar üzerine analizler yapılmaktadır (Dayal ve Verma, 2021). Bu analizlerde, gerçekleşmiş gönüllü işten ayrılma verilerine bakılarak aslında gerçekleşmemiş olan ayrılışları yani çalışanın “işten ayrılma niyeti”ni engellemek amaçlanmaktadır.

“İşten ayrılma niyeti” henüz gerçekleşmemiş ancak var olan gönüllü işten ayrılma potansiyeli olarak ifade edilebilir (Lazzari vd., 2022). Bu potansiyelin elimine edilmesi için hem potansiyele neden olan faktörlerin tespit edilmesi hem de bu potansiyelin varlığının araştırılması gerekmektedir. Bu amaçla, bu çalışmada da olduğu gibi “işten ayrılma

niyetine etki eden faktörlerin analiz” edilmesi ve “işten ayrılma niyetinin tahminlemesi” üzerine iki ayrı uygulama yürütülmektedir.

1.2.1. İşten Ayrılma Niyetini Etkileyen Faktörler

İşten ayrılma niyetini engelleyebilmek adına yapılan analizlerden biri işten ayrılma niyetine sebep olacak faktörlerin tespit edilmesine yöneliktir. Bu şekilde, işverenler gönüllü ayrılışlara engel olmak için bu faktörleri elimine edecek işveren politikaları uygulayarak çalışan devir oranının düşürülmesini yani işten ayrılma maliyetlerinin azaltılmasını sağlayabileceklerdir. Farklı şekilde ifade edilirse, bu analizlerde mevcut işten ayrılma nedenleri tespit edilmekte ve aynı nedenler sebepli oluşabilecek işten ayrılma niyetinin ortadan kaldırılması hedeflenmektedir (Lazzari vd., 2022).

Ayrılma niyeti üzerine yapılan nedensellik çalışmaları incelendiğinde bu çalışmaların daha çok sözel alanlarda yapılmış olduğu görülmüştür. Bu araştırmaların sonucunda çıkan bulguların ise aslında sayısal alanlarda yapılan çalışmalara taban oluşturduğu gözlemlenmiştir. Analitik yöntemler kullanılarak yapılan araştırmalarda, hangi etkenlerin sayısallaştırılarak analizlerde girdi olarak kullanılabilceği konusunda sözel çalışmalar yol gösterici olmaktadır. Bunun karşılığında sayısal yöntemler ise belli faktörlerin ayrılma niyetinde ne kadar etkin olup olmadığını tespit edebilmektedir. Sözel yöntemler ve sayısal yöntemler, diğer tüm alanlarda olduğu gibi burada da birbirini beslemektedir.

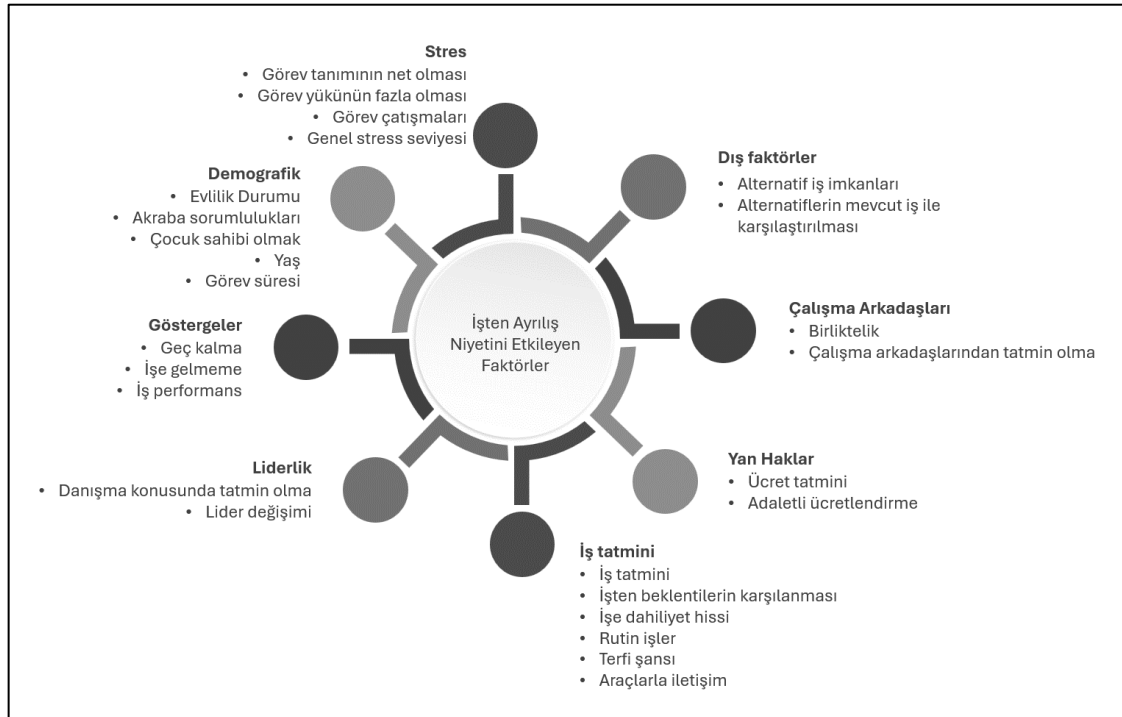
Bolt vd. (2022) işten ayrılma niyetine etki eden faktörlerle ilgili yayınlanmış 1371 araştırmayı taramış, işten ayrılma niyetinin anlaşılmasının “*İK yönetiminin yanında, endüstriyel ilişkiler, örgütsel davranış, bireysel ve örgütsel psikoloji, ekonomi ve sağlık bilimleri*” dahil birçok farklı alanda uzmanın farklı bakış açılarından yaklaştığı bir konu haline geldiğini belirtmişlerdir. Bunun sebebi, ayrılışların hem örgütsel hem psikolojik hem de bireysel nitelikler ile dış faktörlere bağlı olabileceğinin insan hayatında ve iş hayatında yaşanan değişimler boyunca fark edilmesi ve araştırılmasıdır.

Eren ve Saraçoğlu (2011) tarafından yapılan araştırmada ise ayrılış nedenleriyle ilgili daha önce yapılan araştırmalar taranmış ve başlarda iş tatmini ve örgütsel bağlılık üzerine kurgulanmış modellerin yerini çalışan tutum ve algısına yönelik modellere bıraktığına değinilmiştir. Yine aynı araştırmada, “*çalışanların daha çok bireysel*

özelliklerinin ve içinde buldukları koşulların” ayrılışlardaki etkisine yönelik çalışmalardan ve bunu destekleyici yönde bulgulardan bahsedilmiştir.

Ayrılma nedenleri veya ayrılma niyetine neden olan faktörler üzerine yapılan en güncel çalışmalardan biri de İK analitiği alanında çalışmalar ve araştırmalar yapan ve ayrıca bu alanda eğitimler sunan AIHR (*Academy to Innovate HR – Yenilikçi İK Akademisi*) sayfasında Vulpen (t.y.) tarafından özetlenmektedir. Vulpen (t.y), genel olarak araştırmalarda bahsedilen ve konu alınan tüm ayrılma nedenlerini Şekil 1’de gösterildiği gibi gruplayarak özetlemiş ve bu etmenler arasında en büyük etki yüzdesine sahip olan etmenin, stres ve demografik etkenler olduğunu belirtmiştir.

Son dönemde, İK alanında ortaya çıkan yeni yaklaşımlar da benzer bir bakış açısıyla, insan odaklı ve insan sermayesini kaybetmemek için yapılan uygulamalar üzerine olmaktadır (İlhan, 2020). Bu durumda, 2020 yılı başında yaşanan Pandemi döneminin de etkisi oldukça fazla olmuştur.



Şekil 1. Çalışan ayrılış niyetini etkileyen temel faktörler (AIHR)

<https://www.aihr.com/blog/what-drives-employee-turnover/>

1.2.2. İşten Ayrılma Niyetinin Tahminlenmesi

İşten ayrılma niyetinin nedenlerine yönelik analizler, yukarıda da açıklandığı gibi ayrılmaya etki eden faktörlerin incelenmesi ve işverenler tarafından gerçekleştirilmemiş ancak gerçekleştirilecek ayrılmaları engelleyebilmek üzerine “bu faktörler özelinde” önlem alınması amacıyla kurgulanmıştır. Ancak, burada bir başka olguya daha dikkat çekilmektedir. Düşük performanslı ve işten çıkarılamayan çalışanların gönüllü ayrılışlarının örgüt açısından olumlu hatta maliyet azaltıcı etkisinin olabileceği belirtilmektedir. Bunun aksine, yüksek performanslı ya da yaptığı iş ve deneyim sebepli kritik konumda olan çalışanların ise örgütte yüksek ayrılış maliyetlerine sebep olduğu ve bu çalışanların işten ayrılmasının önüne geçilmesinin gerektiği vurgulanmaktadır (Hom vd., 2019).

Bu çerçevede, özellikle örgüte ayrılışları maliyetli olan çalışanları elde tutabilmek amacıyla “işten ayrılma niyetinin tahmini (*employee turnover/ churn/ intention prediction*)” üzerine analitik modeller oluşturulmaya başlanmıştır. Bu alandaki çalışmalar incelendiğinde görülmektedir ki, işten ayrılma tahminlemesi için kullanılan yöntemler işten ayrılma niyetine etki eden nedenlerin tespiti için kullanılan yöntemlerle çakışabilmekte ve tek bir yöntemde her iki konuda da çıktı üretilmektedir. Bu konuda yapılan çalışmalar tahminleme amaçlı olduğundan, görülmüştür ki ayrılma nedenleri kapsamında yürütülen araştırmalardan farklı olarak çoğunlukla sözel değil analitik yöntemlere dayanarak yapılan araştırmalardır.

1.3. PANDEMİ DÖNEMİNİN İŞTEN AYRILMA NİYETİ ÜZERİNE ETKİSİ

Küresel salgın haline dönüşen 2020 yılı Mart ayında ülkemizde de görülen Covid-19 ile birlikte gelen Pandemi süreci, hem sosyal hem aile hem de iş yaşamının evlere sığdırılmasını mecbur kılmış ve insan sağlığını tehdit etme noktasında birçok insanın kaygı ile mücadele ederek yaşamaya devam etmesine sebebiyet vermiştir (Özkanan, 2022). Dışarı çıkma yasaklarının uygulanmak zorunda kalındığı bu dönemde, iş hayatının devam edebilmesi için örgütler vardiyalı çalışma, evden çalışma ve hibrit çalışma gibi farklı çalışma şekillerine geçiş yapmak durumunda kalmış; dijital iletişim araçlarının kullanımında uzmanlaşmaya başlayan ofis çalışanları yüz yüze paylaşımdan dijital paylaşıma geçerek işlerini yürütmeye başlamışlardır.

Bu yeni çalışma ve hayat düzeninin, insan kaynakları alanına her sektör özelinde yansımaları ise oldukça çeşitli ve rekabet ortamında stratejik olarak değişimi gerektirecek şekilde zorlayıcı olmuştur. Örneğin, sağlık sektöründe çalışanların pandemi döneminde riskli koşullarda çok yoğun çalışmaları gerekmiş; bunun aksine turizm sektöründe çalışanların ise seyahat kısıtlamaları nedeniyle çalışmamaları durumu oluşmuştur (Lee vd., 2021) (Shen vd., 2024). Her sektör özelinde sektörün gerekliliklerine göre farklılaşan durumlar bu alanda yapılan çalışmalara konu olmuştur. Bunlara ek olarak, ofislerin dijital ofislere dönüşmesi ve uzaktan çalışma şeklinin yaygınlaşmasıyla birlikte kıtalar arası iş değişikliği yapma imkânı çoğalmış; bunun sonucunda çeşitli çalışan profillerine sahip olan birçok iş yeri ortaya çıkmış, yetenek kazanımı konusu örgütler arasında bir rekabet konusu haline gelmiştir. Bu ve benzeri durumların yanında, özellikle motivasyon teorileri üzerinden incelenen pandeminin çalışan performansına ve bağlılığına olan etkisi de bu dönem yaşanan travmatik kaygılar ve her örgüt tarafından aynı çalışma imkanlarının sağlanamaması gibi sebeplerle yine insan kaynakları yönetiminin ön plana çıkmasına sebep olmuştur (KPMG, 2020).

Deloitte (2021, p.12)'un yayınladığı "2021 Deloitte Global İnsan Kaynakları Trendleri Raporu"nda Covid-19 ile yaşanan pandemi dönemiyle birlikte iş hayatında yaşanan değişim şu şekilde aktarılmaktadır:

"Bugüne kadar göz ardı edilmiş olan iş, özel yaşam, sağlık, güvenlik ve zindelik arasındaki ilişki sonunda değerlendirmeye alınmıştır."

Tüm bu olgular ışığında, insan kaynaklarında "esenlik (*well-being*)", "çeşitlilik/kapsayıcılık (*diversity*)", "İK analitiği (*hr analytics*)", "iş özel hayat dengesi (*work-life balance*)", "çalışan deneyimi (*employee experience*)", "liderlik (*leadership*)", vb. kavramlar en çok konuşulan kavramlar haline gelmiştir. Bu kavramların ortak yanı ise pandemi sonucunda, insan odaklı bir çalışma hayatına geçmenin, performansı yüksek çalışanlara sahip olmak, bu çalışanları elde tutarken onları gelişen ve motivasyonu yüksek çalışanlara dönüştürmek için şart olması ve iş hayatında en iyi iş veren markası olabilmek için bu kavramlara eğilimin gerekliliğe dönüşmesi olarak aktarılmaktadır (Kundu ve Nag, 2021).

Pandemi sonrasında “yeni normal” ile motivasyon ve insani değerler ön plana çıkmış; çalışanların kariyer hedeflerine, iş ortamından ve iş tanımından beklentilerine, yöneticileriyle ve ekipleriyle ilişkilerine kadar tüm çevresel etmenlere bakış açılarında değişimler görülmüştür (İsmail, 2021) (Nilasari vd., 2021). Bu değişime ayak uyduramayan sektörlerde ve organizasyonlarda ise kaçınılmaz şekilde çok fazla çalışan işten ayrılmış; pandemi sonrasında işten ayrılma nedenlerinde farklılıklar olabileceği yönünde bir öngörü oluşmuştur.

Bu çalışmada amaçlanan çıkarımlardan biri de benzer şekilde, verilerin gizliliği sebebiyle uzaktan çalışma imkânı sağlayamamış olan bir savunma sanayi şirketi örneklemini üzerinden, pandeminin gönüllü ayrılış nedenlerine herhangi bir etkisi olup olmadığının çalışanların sayısallaştırılabilmiş ve kaydedilmiş öznelikleri üzerinden araştırılmasıdır.

1.4. İŞTEN AYRILMA NİYETİ SAYISAL ANALİZ YÖNTEMLERİ

Önceki bölümlerde açıklandığı gibi işten ayrılma kavramı ile ilgili analizlerin en temeli çalışan devir oranına bakılarak yapılan durum analizleridir. Ayrılış maliyetlerini azaltmak adına, yukarıda aktarılan ve ayrılma niyetini konu alan yayınlanmış araştırmalar ve bu araştırmalarda kullanılan yöntemler ise bu çalışmanın uygulama konusu olup bu bölümde özetlenmiştir.

1.4.1. Ayrılma Nedenleri ve Niyetine Yönelik Sayısal Analiz Yöntemleri

Ayrılma niyetini konu alan sayısal analizlerde kullanılan veriler mevcutta işten ayrılmış ve mevcutta halen çalışmakta olan çalışanlara ait veriler olmaktadır. Bu nedenle, “işten ayrılma niyeti”ne neden olan faktörler ve “işten ayrılma” nedenleri genellikle literatürde birbirinin yerine kullanılmaktadır. Nadiren, bazı araştırmalarda bu kavramların farklı olması varsayımıyla analizler gerçekleştirilmektedir. Örneğin Lambert vd. (2001) tarafından yapılan araştırmada, çalışanın demografik özelliklerinin, çalışma ortamlarının, iş tatmininin, beyan ettikleri ayrılış niyetinin ve sahip olduğu alternatif iş imkânı olanaklarının arasındaki ilişki ve bunların ayrılış kararlarındaki etkisi istatistiksel yöntemler kullanılarak iki ayrı kavramı da içerecek şekilde incelenmiştir.

Ayrılma niyetine etki eden faktörler ile ilgili birçok yayınlanmış yerel ve yabancı nitel ve nicel araştırma bulunmaktadır (Krishna ve Sidharth, 2022) (Yadav vd., 2018). “İşten ayrılma”lar üzerinden “ayrılma niyeti”ne yönelik yapılan sayısal analizlerde genellikle belli faktörlerin istatistiksel yöntemler kullanılarak farklı sektörlerde ya da organizasyonlar üzerindeki ayrılışlarda ne kadar anlamlı bir etken olduğu araştırılmıştır (Ayodele vd., 2020) (Lee vd., 2012) (Jeswani ve Dave, 2012) (Rombaut ve Guerry, 2018) (Setiawan vd., 2020). Örneğin, Shukla ve Sinha (2013) araştırmalarında başlıca istatistik verileri ve hipotez testlerinden yararlanarak bankacılık sektöründeki ayrılışları incelemiştir. Falch ve Strøm (2005) öğretmenlerin mobiliteleriyle işten ayrılmaları arasındaki ilişkiyi ekonometrik model kullanarak araştırmıştır. Lee vd. (2012) ise kariyer adaptasyonunun ayrılışlar üzerine etkisini hipotez testleri yaparak incelemiştir. Analitik yöntemler geliştikçe bu çalışmalarda kullanılan analiz yöntemleri ve çalışmaların yöneldiği odak da farklılaşmaya ve derinleşmeye başlamıştır. Artık birçok çalışmada işten ayrılma niyetinin nedenlerine ve tahminlenmesine odaklanıldığı, dolayısıyla bu çalışmalarda klasik yöntemlerden ziyade makine öğrenmesi tekniklerinin kullanıldığı görülmüştür (Alshiddy ve Aljaber, 2023).

1.4.2. İşten Ayrılma Niyeti Tahmini Analiz Yöntemleri

Ayrılma niyetini tahminleme çalışmalarıyla ilgili yazılmış çok fazla araştırma olmakla birlikte, birçok kaynakta bu tahminlemelerin yapılabilmesi için makine öğrenmesi temelli algoritmalar kullanıldığı bu alandaki araştırmaları derleyen yayınlarda da aktarılan bir bilgidir (Bhartiya vd., 2019). Berhil vd. (2020) tarafından yapılan bir araştırmada, 2008-2018 yılları arasında yayınlanan araştırmalar taranmış, İK konularına bilgi teknolojilerini kullanarak çözüm arayan yöntemlerden yüzde 41'inin “makine öğrenmesi” ve “veri madenciliği”ne dayandığı belirtilmiştir. Özellikle, daha önce de belirtildiği gibi kritik çalışanların ayrılışlarının önceden bilinmesi ve bu yönde aksiyonlar alınması ile örgütün ayrılış maliyetlerinin azaltılmasının önemli bir iş stratejisi haline gelmesiyle, tahminleme araçlarının kullanımı ve hatta ticarileşmesi de kaçınılmaz bir hale gelmiştir (Jain vd., 2020).

İşten ayrılmaların tahminlenmesi konusunda yazılmış birçok araştırmanın ortak noktası kullanılan çeşitli yöntem ve algoritmalarından türetilen makine öğrenmesi modellerinin

geçerlilik ve tahminleme becerilerinin seviyeleri üzerine karşılaştırmalara yer verilmesidir.

Tahminlemede kullanılan algoritmalarda, girdi olarak kullanılan veriler ayrılma niyeti nedenleri bölümünde aktarılan ayrılma sebeplerini yansıtan sayısallaştırılmış çalışan verileridir (Jain ve Nayyar, 2018). Al Akasheh vd. (2023) tarafından son yıllarda ayrılış niyeti üzerine yapılmış analiz çalışmaları derlenmiş ve bu çalışmalarda ele alınan, girdi olarak kullanılan ve ayrılmaya neden olabilecek çalışan verilerinin cinsiyet, yaş, kıdem, medeni durum, ücret, prim, deneyim, çevresel tatmin, iş tatmini, mevcut yöneticiyle geçirilmiş olan süre, toplam çalışma yılı, görev tanımı, organizasyon bölümü, memnuniyet oranı, şimdiye kadar çalıştığı iş yeri sayısı, iş seyahati sıklığı, firma aracı / telefonu kullanıp kullanmadığı, uyuşuğu, iş ve evi arasındaki mesafe, yan haklar, örgüt kültürü, yönetici performansı, sorumlu olduğu proje sayısı, toplam mesai süresi, son performans değerlendirme puanı, çalışma koşulları, son terfiden sonra geçen süre, mevcut görev tanımında geçen süre, çocuk yardımı alıp almadığı, eğitim seviyesi, yönetici değişiklik sıklığı, iş ilişkilerinde tatmin, iş güvencesi, işe gelme sürekliliği, işte eşitlik algısı, vb. çok çeşitli veriler olduğu belirtilmiştir. Benzer şekilde, bu alanda yapılan ve taranan diğer çalışmalarda da yine burada belirtilen özniteliklerin kullanıldığı görülmüştür. Bu verilerin bir kısmı çalışanın demografik özellikleriyle, bir kısmı çalışanın bağlı olduğu organizasyonla, bir kısmı da mevcut kariyer ve iş durumuyla ilgili verilerdir.

Bu verilerde, ayrılan ve ayrılmayan çalışanların verileri bir arada yer almaktadır. Makine öğrenmesi yöntemlerinde, veri setlerindeki gerçekleştirmeler üzerinden öğrenen makine; bu veriler içerisinde ayırdığı test verileri üzerinden kurduğu modelin gerçekleştirmelere göre tahminleme başarısını çeşitli göstergeler üzerinden test etmektedir. Oluşturulan makine öğrenmesi tahminleme modeli sayesinde ise benzer özellikleri verilen bir çalışanın örgütten ayrılma durumu modelin geçerliliği göz önüne alınacak şekilde tahmin edilebilmektedir (Bahadır vd., 2021).

Çalışanların ayrılış tahminleme analizlerinde genel olarak, çalışan istihdam durumu etiket olarak kullanılmakta ve ayrılış gerçekleştirmelerine göre ayrılan ve ayrılmayan çalışanlar özelinde bir sınıflandırma analizi yapılmaktadır. Bu sebeple, bu analizlerde klasik analizler yerine daha çok denetimli/ gözetimli makine öğrenmesi algoritmaları kullanıldığı görülmektedir (Atef vd., 2022).

Çalışan ayrılışlarının tahminlemesi üzerine yapılmış çalışmalarda farklı birçok yöntem kullanılmakla beraber denetimli makine öğrenmesi sınıflandırma yöntemlerinden *LR*, *KNN*, *RF*, *SVM* ve *DT* yöntemlerinin ağırlıklı olarak kullanıldığı görülmektedir. Bu çalışmalarda genel olarak amaçlanan, hangi sınıflandırma yönteminin çalışan ayrılışlarını tahmin eden modeli oluşturmakta daha yüksek tahmin başarısına sahip olduğunun, belli göstergeler üzerinden karşılaştırılması olmaktadır. Bu alanda yazılmış olan araştırmalar ve kullanılan yöntemler aşağıdaki Tablo 1’de örnek olarak sunulmuştur.

Tablo 1’de yer alan çalışmaların bir kısmında birden çok yöntem harmanlanarak yeni yöntem önerileri getirilirken, örneklem üzerinde değişimler yaparak uygulamalar da yapılmaktadır. Hem ayrılma niyetine etki eden faktörlerin araştırılmasında hem de ayrılma niyetinin tahminlenmesinde özellikle makine öğrenmesi yöntemlerinin kullanılmakta olduğu net bir şekilde görülmektedir. Bu yöntemler içinde ağırlıklı olarak denetimli makine öğrenmesi sınıflandırma yöntemlerinden özellikle *LR*, *KNN*, *RF*, *DT* ve *SVM* problem tanımının bu yöntemlere uygun olması nedeniyle daha yaygın olarak denenmiştir.

Çalışan öznelikleri genellikle gizli bilgiler olduğu için birçok araştırma IBM veri seti gibi sentetik veriler üzerinden yapılmış; çalışmalarda kullanılan model başarı ölçütleri de genel olarak ilerleyen bölümlerde daha detaylı anlatılacak olan doğruluk (*accuracy-CA*), eğri altındaki alan (*area under curve-AUC*) ve hassasiyet ölçütleri olmuştur. Çalışmaların çoğunluğunda, herhangi bir yöntem en geçerli yöntem olarak belirtilememiş, verinin özelliklerine, geçerlilik analizi için kullanılan ölçüt değerine ve yöntemin kullanım amacına göre hangi yöntemin daha iyi olduğunun farklılaşabildiği belirtilmiştir.

Özetle, Tablo 1’de yer alan çalışmalarda genel olarak belli bir dönemdeki sentetik çalışan verileri kullanılarak ayrılma niyetinin tahminlenmesi için tahmin modelleri oluşturulmuş; bu modellerin tahmin performansları karşılaştırılmıştır. Bu çalışmada da benzer şekilde en çok kullanılan yöntemlerden *LR*, *KNN*, *RF*, *DT* ve *SVM* modelleri kullanılarak çalışan ayrılma niyetini tahminleyen modeller oluşturulması amaçlanmış ve yine benzer şekilde yaygın olarak kullanılan model performans ölçütlerinden *CA* ve *AUC* skorları ile model başarıları karşılaştırılmıştır. Bunun yanında, bu çalışmada gerçek çalışan verileri kullanılırken, tüm bu çalışmalardan farklı olarak pandemi dönemindeki dönemsel değişiklikleri baz alan bir araştırma ve tahminleme çalışması yürütülmüştür.

Kaynak	Kullanılan yöntem	Kullanılan veri seti	Performans ölçütleri ve sonuçları
Sexton vd., (2005)	Yapay Sinir Ağları	Özel bir işletmenin verileri	Belirtilmemiş
Saradhi ve Palshikar (2011)	Naïve Bayes (NB), SVM, DT, RF, LR	Gerçek çalışan verileri	CA, hassasiyet, doğru negative ölçütleri: değişken
Fan vd. (2012)	Clustering	Anket cevapları	CA ölçütü: SOM+ANN 92%
Bao vd. (2017)	NB, SVM, DT, KNN, ve RF	İki farklı firmaya ait ik verileri	F1 Skoru: RF: 86% en yüksek
Dolatabadi ve Keynia (2017)	DT, SVM, NB, Sinir Ağları (NN)	Organizasyonlara ait çalışan verileri	CA ölçütü: DT, NN, NB 100%
Sisodia vd. (2017)	L-SVM, C 5.0, RF, KNN, NB	Kaggle Verisi	CA ölçütü: RF en iyi
Yiğit vd. (2017)	DT, LR, SVM, KNN, RF, NN	IBM veri seti	CA ölçütü: SVM 90%; Kesinlik: SVM 98%; Hassasiyet: 38% NB; F1 skoru: RF 31%

Tablo 1. Ayrılma niyetinin tahminlenmesi üzerine yapılmış örnek araştırmalar

Kaynak	Kullanılan yöntem	Kullanılan veri seti	Performans ölçütleri ve sonuçları
Alamsyah ve Salma (2018)	<i>NB, DT, RF</i>	Endonezya'da bir firmanın ik verileri	CA ölçütü: RF en yüksek: 97,50% NB ikinci yüksek: 96,60% DT en düşük: 88,70%
Alduayj ve Rajpoot (2018)	<i>SVM, RF, KNN</i>	<i>IBM</i> veri seti	F1 Skoru: KNN(K=3): 93% (29 öznelilik) RF: 91% (12 öznelilik)
Frye vd. (2018)	KNN, RF, LR	IBM veri seti	CA ölçütü: LR 74%
Jain ve Nayyar (2018)	XGBoost	IBM veri seti	CA ölçütü :89%
Rombaut and Guerry (2018)	LR	Belçika'da özel bir firmanın ik verileri	AUC ölçütü: 74%
Shankar vd. (2018)	DT, LR, SVM, KNN, RF, NB	IBM veriseti	Belirtilmemiş
Yadav vd. (2018)	LR, SVM, RF, DT, AdaBoost, NN	Gerçek veri seti	CA, Kesinlik, Hassasiyet, F1 skoru: RF, AdaBoost :99%
Alhashmi (2019)	DT	IBM veri seti	Belirtilmemiş
Bhartiya vd. (2019)	SVM, DT, KNN, RF, NB	IBM veri seti	CA ve AUC ölçütleri CA ölçütü: 83,30% RF en yüksek NB ve SVM en yüksek AUC.

Tablo 1. (Devam)

Kaynak	Kullanılan yöntem	Kullanılan veri seti	Performans ölçütleri ve sonuçları
Zhao vd. (2019)	DT, RF, GBDT, XGBoost, LR, SVM, NN, Doğrusal Diskriminant Analizi (LDA), NB, KNN	IBM veri seti ve ABD'de bir bankanın verileri	CA, F1 skoru, kesinlik, AUC, hassasiyet: değişken
Cai vd. (2020)	RF, XGBoost, LR, NB, DT ve Gradyan Arttırıcı Karar Ağacı (GBDT)	Çin sosyal ağ internet sayfası verileri	AUC ölçütü: RF DBGE algoriması: 86%
El-Rayes vd. (2020)	LR, DT, RF, GBDT	Glassdoor internet sayfası verileri	AUC: RF 73%
Fallucchi vd. (2020)	GNB, LR, KNN, DT, RF, SVM	IBM veri seti	Hassasiyet: GNB 54%
Jain vd. (2020)	SVM, DT, RF	Kaggle Verisi	Kesinlik, Hassasiyet, F1 skoru: RF en iyi
Setiawan vd. (2020)	LR	4410 çalışan verisi	CA: 75%; Hassasiyet: 73%, Kesinlik:75%
Al-Darraji vd. (2021)	NN	IBM veri seti	CA'ya göre: KNN (K=1) en yüksek: 97% DNN: 94%
Bahadır vd. (2021)	DT, KNN, RF, LR, Yapay Sinir Ağları (ANN), SVM, Ensembled Model	Kaggle Verisi	Kesinlik: ENS 99%; DT 98% CA: ENS 99%; ANN 99% F1 Skoru: ENS 99%, SVC 97%
Kaya ve Korkmaz (2021)	SVM, ANN, Gaussian Radyal Tabanlı Fonksiyon (RBF), RF, Bayes, kNN, JRip	IBM veri seti	CA: veriye göre değişken
Najafi-Zangeneh vd. (2021)	LR	IBM veri seti	F1 Skor: LR en yüksek

Tablo 1. (Devam)

Kaynak	Kullanılan yöntem	Kullanılan veri seti	Performans ölçütleri ve sonuçları
Yahia vd. (2021)	DT, LR, SVM, RF, XGBoost, VC, NN, LSTM	Kaggle verisi, IBM veri seti, İK verileri	CA, F1 skoru: Değişken
Alsheref vd. (2022)	RF, GB, Çok Katmanlı Algılayıcı (MLP)	Gerçek veri seti	Belirtilmemiş
Avrahami vd. (2022)	Kümeleme (Clustering)	Anket cevapları	Belirtilmemiş
Chowdhury vd. (2022)	LR, DT, SVM, NB, RF, GB	IBM veri seti	Belirtilmemiş
Krishna ve Sidhart (2022)	RF, AdaBoost	Kaggle Verisi	AUC ve F1 Skoru
Lazzari vd. (2022)	KNN, DT, LR, RF, XGBoost, LGBM, TabNet	Uluslararası Çalışan Bağlılık Endeksi anketi	AUC: LGBM ve LR 64%
Naz vd. (2022)	SVM, DT, NN LR	IBM veri seti	CA: DT 98%
Thompson vd. (2022)	NB	Hemşirelere ait veriler	RF: 98
Alshiddy ve Aljaber (2023)	NB, SVM, RF, Ensembled Model	IBM veri seti	RF CA: 94,20%; RF F1: 94,20%; RF AUC:98,40%
Chung vd. (2023)	LR, RF, XGBoost, SVM, ANN, and stacking ensemble learning	IBM veri seti	RF ve ANN Ensemble Model: CA: 98%, F1-skor: 97%, AUC: 98%, Kesinlik: 100%, Hassasiyet: 95%
Mozaffari vd. (2023)	GB	Bir farmasi firmasının İK verileri	CA: 89%

Tablo 1. (Devam)

2.BÖLÜM

VERİ

Bu çalışmada savunma sektöründe faaliyet gösteren bir şirketin 2017-2023 yıllarında insan kaynakları veri tabanında kayıtlı olan çalışan verileri kullanılarak ayrılma niyetini etkileyen faktörlerin pandemi öncesi ve sonrası dönemde değişiklik gösterip göstermediğini tespit etmek ve aynı veriler kullanılarak ayrılış niyetini tahmin eden bir model oluşturmak amaçlanmıştır. Şirket gizlilik politikaları gereği kullanımına izin verilen kısıtlı öznitelik üzerinden analizler yapılırken veriler makyajlanmıştır. Çalışmada kullanılan verilerin temini, ayıklanması ve temel özellikleri ile betimsel analizler bu bölümde detaylı olarak aktarılmıştır.

2.1.VERİ TOPLAMA VE VERİ AYIKLAMA SÜRECİ

2.1.1. Veri Toplama Süreci

Çalışmada, Türkiye’de bulunan bir savunma sanayi şirketinin kurumsal raporlama platformunda yer alan insan kaynakları raporlarından yararlanılmıştır.

Veriler, 2017 ve 2023 yılları arasında şirkette çalışmış olan çalışanlara ait verilerdir. Bu bilgilerin yer aldığı raporlar aşağıda listelenmiştir:

1. Ayrılış ve işe alım raporları: 2017 ve 2023 tarihleri arasında işe alınan ve işten ayrılan çalışanların, işe alım tarihi, işten ayrılış tarihi, bu tarihlerdeki organizasyon bilgilerini içeren raporlardır.
2. 2016 ve 2023 yılları sene sonu organizasyonel raporları: 2017 ve 2023 tarihleri arasında organizasyonda çalışmakta olan çalışanların iş tanımı, bölüm ve yerleşke bilgilerini içeren raporlardır.

3. Eđitim raporu: alıřan numarası verilen alıřanların řimdiye kadar sisteme giriři yapılmıř olan ilkokuldan itibaren okul, mezuniyet durumu, iře giriř tarihlerini ieren rapordur.
4. alıřan performans puanı raporu: alıřanların yıl bazında aldıkları performans puanlarının yer aldıđı rapordur.
5. alıřan esnek raporu: Seilen bilgi tiplerine gre alıřanların kayıtlı olan son demografik bilgilerini ieren rapordur. alıřanın cinsiyeti, dođum tarihi, ocuk sayısı gibi bilgilerinin alınabildiđi rapordur.

Yukarıda belirtilen farklı İK raporları ierisinde, aynı kategorideki bilgilerin (iřten ayrılıř ve iře alım tarihleri, organizasyon bilgileri) raporlar arasında tutarlı olup olmadıđı kontrol edilmiřtir. Raporlar ierisindeki bilgiler birleřtirilerek, analizde kullanılacak bilgilerin toplu olarak yer aldıđı bir rapor oluřturulmuřtur.

2.1.2. Veri Ayıklama Sreci

Raporlarda yer alan verilerin tutarlılıđını kontrol etmenin yanı sıra, yapılacak analiz iin veriler sadeleřtirilmiř ve ihtiyacı karřılayacak veri kategorilerinin alıřmaya dahil edilebilmesi iin veriler ayıklanarak dzenlenmiřtir:

- řirkette birden fazla defa iře girmiř ve iřten ayrılmıř alıřanlar bulunmaktadır. Bunun iin rapordaki iře giriř ve iřten ayrılıř tarihlerinin tutarlılıđı kontrol edilmiřtir. Kontrol sonrasında alıřanın son iře giriř ve 2023 yılı sonunda řirkette alıřmıyor durumdaysa sadece son iřten ıkıř tarihi rapora dahil edilmiřtir.
- Temel iř grubu, ynetici olan alıřanların verileri hem gizlilik hem de bu iř kolunda rotasyonun ve deđiřimin ok olması nedenleriyle analize dahil edilmemiřtir.
- Henz tam zamanlı alıřan kadrosunda olmayan niversite đrencileri ile belirli sreli szleřmeli alıřanlar ve geici uzmanlar da analize dahil edilmemiřtir. Bu

çalışanların sözleşmelerinin yenilenme durumuna ya da tam zamanlı kadroya geçme durumlarına göre devamlı çalışan olmaları daha sonra netleşmektedir.

- Şirket bir tasarım ve üretim şirketi olduğu için şirkette sayıca fazla olan ve şirkete sermaye getirisi yüksek olan kritik çalışanlar, mühendis çalışan grubudur. Bu sebeple, analize sadece mühendis çalışanların verileri dahil edilmiştir. Mavi yaka çalışanlar ile beyaz yaka idari çalışanların verileri analize dahil edilmemiştir.
- Şirketten zorunlu olarak ayrılan çalışanlar, çalışmanın önceki bölümlerinde de aktarıldığı gibi analizin amacının ayrılış niyetine odaklanması gereği çalışmaya dahil edilmemiştir.
- Şirkette performans sistemi 2019 ve hatta 2020 yılında değişikliğe uğramıştır. Bir önceki sistemde ve 2019 sonrası sistemde performans puanlamasına dahil olmayan çalışanların performans puanları 0 kabul edilmiş, bu nedenle bu çalışanlar analize dahil edilmemiştir.
- Çalışanların şirket deneyimleri hesaplanarak bulunmuştur. 2023 yıl sonu itibarıyla halen şirkette çalışmakta olan çalışanların deneyim süreleri son işe girdikleri yıldan 2023'e kadar geçen süreye göre hesaplanırken; 2023 yıl sonunda şirketten ayrılmış durumda olan çalışanların deneyim süreleri son işe girdikleri yıldan işten ayrıldıkları son tarihe kadar geçen süre baz alınarak yıl olarak hesaplanmıştır.
- Veri setine şirkette 2023 yıl sonu itibarıyla çalışmakta olan çalışanların 2023 yıl sonu bilgileri; 2023 yıl sonu itibarıyla şirketten ayrılmış durumda olan çalışanların ise ayrıldığı tarih itibarıyla var olan bilgileri eklenmiştir.

Ayrılış analizlerinde sıklıkla öznitelik olarak kullanılan özellikle, ücret, prim, terfi, unvan gibi birçok öznitelik daha önce bu verilerle ilgili kayıt tutulmamış olması, İK sistemlerinde ve şirket yapısında yapılan değişikliklerin verilerde tutarsızlık yaratabilmesi ve gizlilik nedeniyle paylaşılmasının uygun olmaması gibi gerekçelerle veri setine öznitelik olarak eklenememiştir.

2.2. KULLANILAN VERİLER

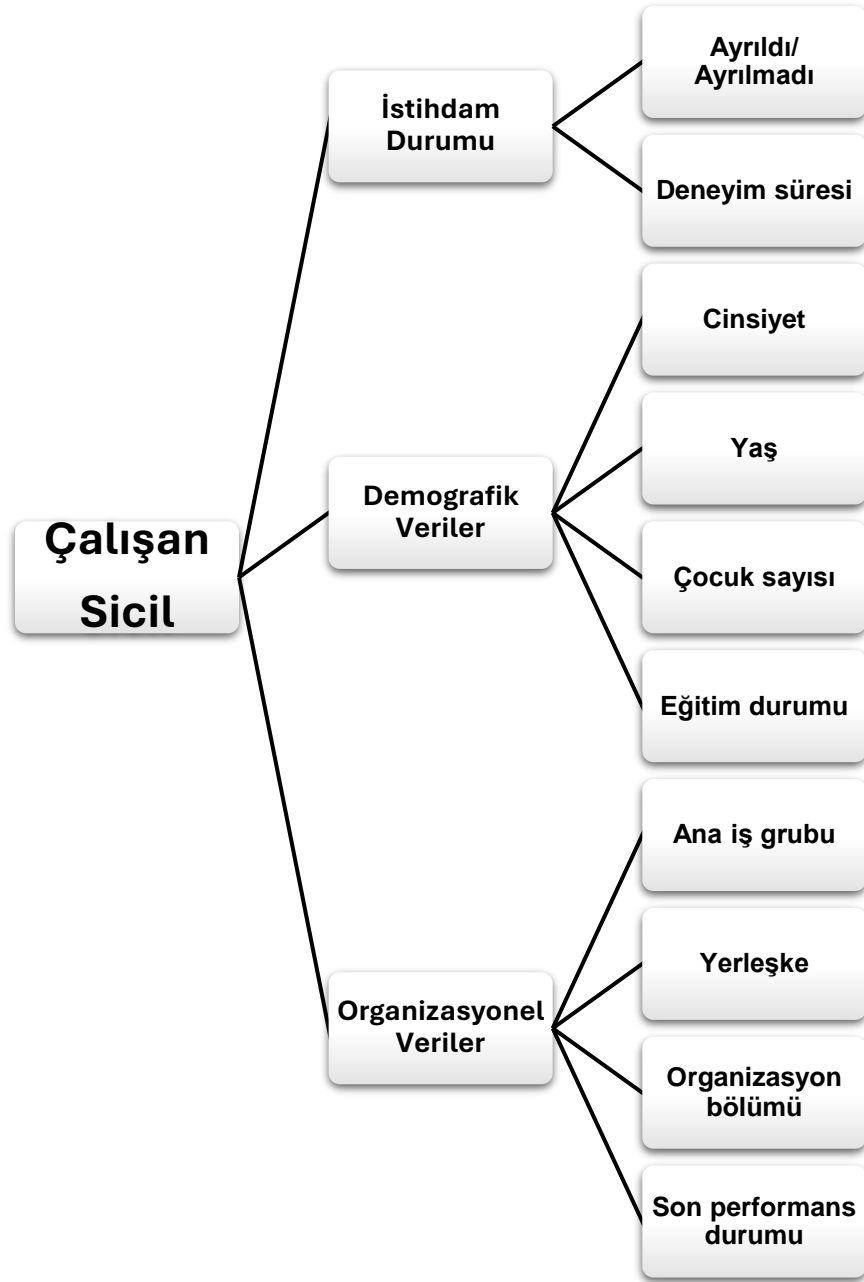
Çalışmada kullanılan verilerin sınıflandırılması Şekil 2’de verilmiştir.

2.2.1. Anahtar Veri

- Çalışanın Sicili: Her çalışanın farklı bir sicil numarası vardır. Veri kesikli sayı verisidir.

2.2.2. İstihdam Verileri

- Çalışanın İşten Ayrılma Durumu: Çalışanın 2023 yıl sonu itibarıyla şirkette çalışır durumda olup olmadığını gösteren veridir. Şirkette işten ayrılma durumu istenmeyen bir durum olduğundan çalışır durumda olan çalışanlar “1”; çalışır durumda olmayan çalışanlar “0” olarak numaralandırılmıştır.
- İşe Girdiği Son Tarih: Çalışan birden fazla defa şirkette işe girmiş ise son işe girdiği tarihtir.
- İşten Ayrıldığı Son Tarih: Çalışan 2023 yıl sonu itibarıyla işten ayrılmış durumdaysa işten ayrıldığı son tarihtir.
- Deneyim Süresi: Yukarıda aktarıldığı gibi hesaplamayla bulunan veridir. Bu veri çalışanın şirkette çalıştığı süreyi yıl olarak vermektedir.



Şekil 2. Kullanılan veri grupları

2.2.3. Demografik Veriler

- Cinsiyet: Çalışanın cinsiyetini gösteren kategorik veridir. Sayısal veriye çevrilerek 1 ve 2 değerleri kullanılmıştır.

- Yaş: Çalışanın 2023 yıl sonunda çalışır durumdaysa 2023 yıl sonundaki yaşını; ayrılmış durumda olan bir çalışansa ayrıldığı yıla göre yaşını gösteren kesikli sayısal veridir. Çalışanın doğum tarihi ve ayrıldığı tarih verileri kullanılarak hesaplanmıştır.
- Çocuk Sayısı: Çalışanın çocuk sayısını gösteren kesikli sayı verisidir.
- Eğitim Durumu: Şirketin akademik olarak eğitim durumu yüksek seviyede olan ve yine akademik eğitim odaklı bir çalışan yapısı vardır. Veri kategorik ve sıralanmış bir veridir. Doktora üstü çalışma yapan, doktora mezunu, doktora eğitime devam eden, yüksek lisans mezunu, yüksek lisans eğitime devam eden ve lisans mezunu olmak üzere altı kategori bu sırayla 1'den 6'ya kadar sıralanmıştır.

2.2.4. Organizasyonel Veriler

- Ana iş grubu: Çalışanın hangi mühendislik alanında çalıştığını gösteren veridir. Şirket içerisinde üretim, kalite, tasarım, proje, vb. olmak üzere toplam 11 farklı mühendislik çalışma alanı bulunmaktadır. Kategorik olan bu veriler 1'den 11'e kadar rastgele numaralandırılmıştır.
- Yerleşke: Şirketin şehrin farklı yerlerinde ve şehir dışında yerleşkeleri vardır. Tüm yerleşkeler birbirlerine olan yakınlıklarına göre toplam 6 ana grupta toplanmış; bu kategorik veri gruplaması rastgele bir eşleşme ile 1'den 6'ya kadar numaralandırılmıştır.
- Bölüm: Şirkette toplam 7 ana organizasyon bölümü bulunmaktadır. 2023 yıl sonu itibarıyla halen çalışmakta olan çalışanların, 2023 yıl sonu organizasyon raporunda bağlı buldukları organizasyon bölümü; 2023 yıl sonu itibarıyla ayrılmış olan çalışanların ise ayrılış raporunda yer alan ayrıldıkları tarih itibarıyla son kayıtlardaki bağlı oldukları organizasyon bölümü veri olarak kullanılmıştır. Bu kategorik veri yine rastgele bir eşleşme ile 1'den 7'ye kadar numaralandırılmıştır.

- Son Performans Puanı: Şirkette her yıl bir önceki yılın performans değerlendirmesi yapılmaktadır. Yapılan performans değerlendirmelerinde çalışanların aldıkları puanlara göre girdikleri düşük, orta, yüksek performans bilgileri 2016 ve 2022 yılları arasında yıllar bazında raporlanmıştır. 2023 yıl sonu itibarıyla halen çalışmakta olan çalışanların 2022 yılı performans kategorisi; 2023 yıl sonu itibarıyla ayrılmış olan çalışanların ise var olan son performans verileri kullanılmıştır. Kategoriler yüksekten düşüğe doğru 1'den 3'e sıralanarak numaralandırılmıştır.

Çalışmada kullanılan ve aktarılmış olan öznitelikler Tablo 2'de özetlenmiştir.

Öznitelik	Kategori sayısı/ Türü	Modeldeki yeri
Ayrıldı (0) / Ayrılmadı (1)	0 1 (Kategorik)	Hedef Değişken
Şirketteki Deneyim Süresi (Yıl)	Kesikli sayı değişken	Bağımsız Değişken
Cinsiyet	1 2 (Kategorik)	Bağımsız Değişken
Yaş	Kesikli sayı değişken	Bağımsız Değişken
Çocuk Sayısı	Kesikli sayı değişken	Bağımsız Değişken
Eğitim Durumu	1 2 3 4 5 6 (Kategorik)	Bağımsız Değişken
Ana İş Grubu	1 2 3 4 5 6 7 8 9 10 11 (Kategorik)	Bağımsız Değişken
Yerleşke	1 2 3 4 5 (Kategorik)	Bağımsız Değişken
Bölüm	1 2 3 4 5 6 7 (Kategorik)	Bağımsız Değişken
Son Performans Puanı	1 2 3 (Kategorik- Sıralı)	Bağımsız Değişken

Tablo 2. Modelde kullanılan değişkenler / öznitelikler

Kullanılacak olan veriler pandemi öncesi ve pandemi sonrası dönemler için ayrı analizler yapılabilecek şekilde ayrıştırılmıştır. Bunun için:

- Pandemi öncesi dönemi (2017-2019) yansıtacak analizler için işe başladığı ilk tarih 2019 ve öncesi olan çalışanlar analize dahil edilmiş; bu çalışanlardan işten ayrıldığı son tarih 2020, 2021, 2022 ve 2023 olan çalışanlar bu dönem için halen çalışmakta olan çalışanlar olarak sınıflandırılmıştır.
- Pandemi sonrası dönem (2020-2023) analizleri için ise son işten ayrıldığı tarih 2020 ve sonrası olan ve 2023 yıl sonu itibarıyla halen çalışmakta olan

alıřanlar analize dahil edilmiřtir. 2023 yıl sonu itibarıyla mevcut alıřma durumlarına gre sınıflandırılmıřlardır.

Tm bu bilgiler ışığında son durumda veriler ařağıda Tablo 3'te gsterildiğı řekilde dzenlenmiř ve sınıflandırılmıřtır.

Veriler modellerde tanımlanırken iki sınıfa sahip hedef deęiřken olan alıřanın istihdam durumu, alıřan iřten ayrıldıysa 0, iřten ayrılmadıysa 1 olacak řekilde numaralandırılmıřtır. Veride, eksik veri bulunmadığı iin veri tamamlama adımına gerek olmamıřtır.

	Ayrılan alıřan sayısı	Halen alıřmakta olan alıřan sayısı	Toplam alıřan sayısı
2017-2019	299	3928	4227
2020-2023	1045	5034	6079

Tablo 3. Poplasyon verisi

3.BÖLÜM

BETİMSEL ANALİZLER

3.1.AYRILIŞLAR VE İSTİHDAM ÖZELLİKLERİ

Analizlerde kullanılan popülasyon verisinde 6378 çalışana ait bilgiler bulunmaktadır. Bu çalışanlardan 5034 çalışan 2023 yıl sonu itibarıyla halen şirkette çalışmakta olup, 1344 çalışan ise işten ayrılmıştır.

İşe giriş ve işten çıkış tarihlerine göre işten ayrılma durumu değerlendirildiğinde, pandemi dönemi öncesi (2017-2019) ve sonrasındaki (2020-2023) değişim işe giriş ve işten ayrılma tarihleri göz önüne alınarak Tablo 4'te gösterilmiştir.

2023 sonu çalışan durumu	Son işe giriş tarihi				Son ayrılış tarihi			Toplam
	Öncesi	2017- 2019	2020- 2023	Öncesi	2017- 2019	2020- 2022	2023	
Halen çalışmakta olan	1819	1338	1877	-	-	-	-	5034
İşten ayrılan	779	291	274	-	299	738	307	1344
Toplam	2598	1629	2151					6378

Tablo 4. Çalışanların işe başlama ve son işten ayrılma tarihlerine göre dağılımı

Tablo 4 incelendiğinde, 2019 yılından sonra yani pandemi dönemi sonrasında işten ayrılışlarda yaklaşık yüzde 147 oranında bir artış gözlemlenmiştir. 2023 yılında özellikle de Emeklilik Yaşa Takılanlar (EYT) etkisiyle ayrılışlar fazlasıyla devam etmiştir. Ayrılışların etkisini azaltmak amacıyla aynı yıllarda işe alım oranları da yüzde 32 civarında artış göstermiştir.

Ayrılan çalışanların deneyimli çalışanlar arasından ayrılıp ayrılmadığı ise şirketin ayrılış maliyetini etkileyen durumlardan biridir. Deneyimli çalışana yapılan yatırımın yüksek olması ve iş konusunda bu çalışanların bilgisinin sermayeye katkısının daha fazla olması sebepleriyle, işe alımla yerlerinin doldurulması daha zor olan çalışanlardır.

Bu bakış açısıyla, veriler incelendiğinde, Tablo 5'te görüldüğü gibi pandemi öncesi dönemde ayrılan çalışanların büyük çoğunluğu 5-14 yıl arasında deneyimli çalışanlar arasından olurken, pandemi sonrasında 0-4 yıl arasında deneyimi olan çalışanlar arasından ayrılanlar daha fazla olmuştur. Bu da şirketin yeni işe alınan çalışanları tutundurma anlamında zayıf kaldığını göstermektedir. Tablo 6'da yer aldığı gibi ayrılan çalışanların ortalama deneyim süresi 7 yıl iken en fazla 2 yıl deneyime sahip çalışanların şirketten ayrıldığı görülmektedir. Dağılım sağa yatık ve sivridir.

Ayrıldığı tarih/ deneyim süresi	0-4	5-14	15-19	20-39	Toplam
2017-2019	25%	65%	5%	5%	100%
2020-2022	47%	43%	5%	5%	100%
2023	54%	33%	5%	8%	100%
Toplam	44%	45%	5%	6%	100%

Tablo 5. Deneyim süreleri ve ayrılış tarihine göre ayrılan çalışan dağılımı


Deneyim süresi – ayrılan çalışanlar	
Ortalama	7,24
Medyan	5
Mod	2
Standart sapma	6,22
Aralık	37
Minimum	1
Maksimum	38

Tablo 6. Deneyim dağılım tablosu

Bunun ötesinde, çalışanların şirketteki kritiklik seviyesini şirketteki unvanları da belirlemektedir. Bu veri de yaş verisiyle genelde paralel olduğu için gizlilik ve unvan sistemindeki geçmiş değişikliklerin veriye yansıtılmıyor olması nedenleriyle, analizlerde çalışanların unvanları yerine yaşları kullanılmıştır.

3.2. AYRILIŞLAR VE DEMOGRAFİK ÖZELLİKLER

Çalışanların demografik bilgilerine göre ayrılışlardaki dağılımlarına bakıldığında, cinsiyete göre dağılım Şekil 3'te verilmiştir. Cinsiyetlerden 1 numaralı cinsiyetin şirkette sayıca fazla olması hem ayrılışlarda hem de halen çalışmakta olan çalışanlar içerisindeki yüzdesini beklendiği gibi arttırmıştır.




Şekil 3. Cinsiyete göre işten ayrılma durumu

Çalışanların yaşına göre ayrılışlardaki dağılıma baktığımızda, Şekil 4 ve Şekil 5'te görüldüğü gibi 28-32 yaş arası çalışanların ağırlıkta olduğu, 33-37 yaş arası çalışanların bu grubu takip ettiği görülmüştür. Şirketin mevcut kariyer yollarına bakıldığında, 28-32 yaş arası artık deneyimlerin kazanıldığı ve yardım almadan işlerin yapılabilirdiği yetkinliğe sahip olunması beklenen hatta yönetici olunabilen yaşlar olurken; 33-37 yaş aralığı bu bilgilerin diğer çalışanlara aktarılmaya başlandığı, özellikle ekip yönetimi rollerinin yoğun olarak üstlenildiği yaşlar olmaktadır. Bu bilgiler doğrultusunda, 28-32 ve 33-37 yaş gruplarında ayrılışların yüksek olması şirket açısından ayrılışları daha maliyetli hale getirmiştir.


Pandemi döneminin, ayrılışlarda ayrılan çalışanın yaşına bir etkisi olup olmadığı incelendiğinde ise Şekil 5'te görüldüğü gibi özellikle işi birebir olarak yapması beklenen 28 yaş öncesi ve 28-32 yaş arası işten ayrılmalarda oldukça fazla bir artış görülmüştür.

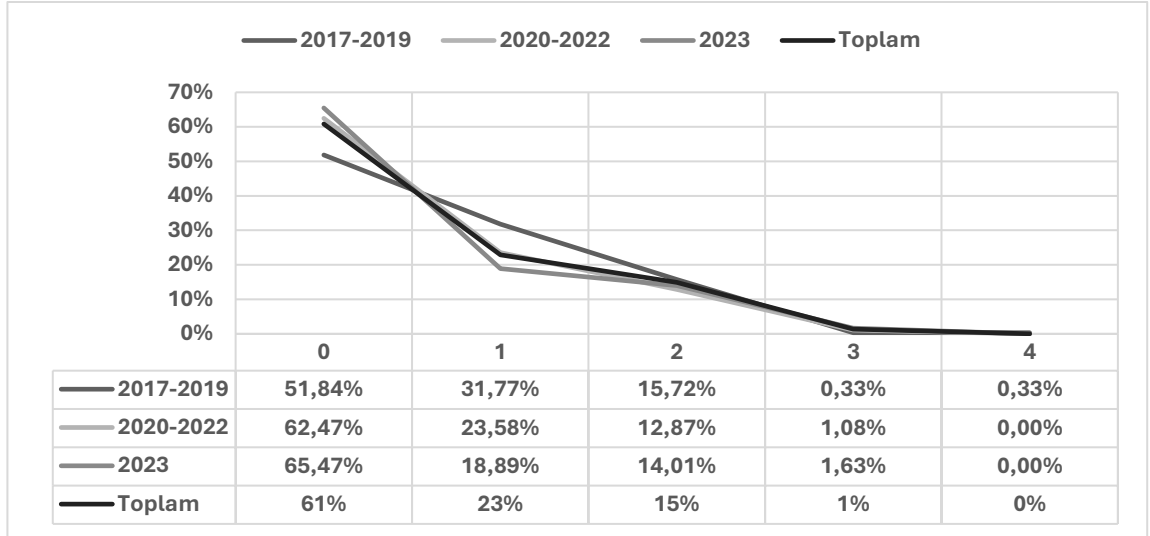
Bu sonuç, pandemi döneminde savunma sektöründe uzaktan çalışma imkanının olmamasının, özellikle şirketteki yeni jenerasyonun ve kariyerinde değişiklik yapma imkanı daha yüksek olan yetkin çalışanların uzaktan çalışma imkanı sunan diğer iş imkanlarına yönelmelerini tetiklemesinin sonucu olarak yorumlanabilir.




Şekil 4. Çalışanların yaşlarına göre istihdam durumları

Çalışanların çocuk sayısı arttıkça çalışanın iş değiştirmek için manevra alanı ekonomik kaygılar sebebiyle azalmaktadır. Verilere bakıldığında bunu destekleyecek şekilde, dönemden bağımsız olarak çocuk sayısı ve ayrılan çalışanların yüzdesinin Şekil 6'da negatif yönlü bir ilişkiye sahip olduğu gösterilmiştir.



Şekil 5. Pandemi öncesi ve sonrası ayrılan çalışanların yaşlarına göre dağılımı**Şekil 6.** Çalışanların ayrılışlardaki yüzde dağılımı ile çocuk sayısı ilişkisi


Demografik verilerde son olarak çalışanın eğitim durumuna göre işten ayrılma eğilimlerine bakıldığında, Şekil 7’de görüldüğü gibi yüksek lisans mezunu çalışanların diğer çalışanlara göre ayrılan çalışanlar içerisinde ağırlıklı olduğu görülmüştür. Genel olarak şirkette çalışanların çoğunluğu yüksek lisans mezunudur. Bu durum ayrılan çalışanlar içerisinde en fazla yüzde dağılımına sahip çalışanların yüksek lisans mezunu olmasına katkı sağlamıştır.

**Şekil 7.** Eğitim durumuna göre dağılım

Bunun yanında, şirket çalışan profiline bakıldığında akademik geçmiş anlamında şirketin başarılı bir profile sahip çalışanlardan oluşması, ayrılan çalışanların akademik hayata devam etme eğiliminde olabildiğine de işaret etmektedir. Şirket akademik çalışmalar için çalışanlara belli koşullar karşılığında izin vermektedir. Bu sebeple, şirkette işe başlamayı tercih edip okul mezuniyeti sonrası başka iş alanlarına yönelen çalışanlar olduğu da görülmüştür. Çalışanlar işten ayrılma anketlerinde işten ayrılma nedeni olarak bunu net olarak belirtmedikleri için bu bilgi net bir bilgi değildir.

3.3. AYRILIŞLAR VE ORGANİZASYONEL ÖZELLİKLER

Çalışanların şirket içerisindeki görevleri ve bağlı oldukları organizasyon birimlerinin ayrılışlarında etkili olabildiği yapılan araştırmalarda aktarılmaktadır (Shankar vd., 2018). Çalışan ana iş gruplarının ayrılan ve etkin olarak çalışmakta olan çalışanlar içerisindeki yüzdesi Şekil 8'de verilmiştir.



Şekil 8. Ana iş grubuna göre dağılım

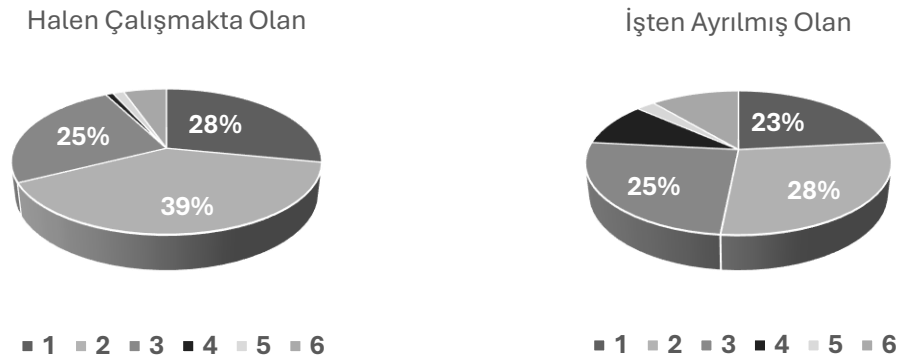
Şekil 8 incelendiğinde şirkette çalışanlar arasında 1. ve 2. grubun yüzdesinin diğer çalışanlara göre daha fazla olduğu ve ayrılan çalışanlar arasında 2. grubun yüzdesinin halen çalışmakta olan çalışanlar içindeki yüzdeye göre fazla olduğu görülmektedir. 1. ve 2. grupta çalışan mühendislerin şirketin ana faaliyet alanlarında etkin olan gruplar olduğu rakamlara bakılarak tahmin edilebilmektedir. Bu anlamda, özellikle aynı sektör içerisinde mobilite imkânı yüksek olan iş gruplarında çalışıyor olmaları varsayımı da yapılabilir.

İş gruplarının pandemi dönemi öncesinde ve sonrasında ayrılışlardaki oranları çok fazla değişmiyor olsa da ayrılan çalışan sayılarına bakıldığında pandemi sonrasında sayıca artışın fazla olduğu Tablo 7’de görülmektedir. 2023 yılında bu artış 2017-2019 yılları arasındaki 3 yıllık döneme göre tek bir yıla bakıldığında hala sayıca yüksek olarak değerlendirilebilir. Emeklilik Yaşa Takılanlar (EYT) kapsamında 2023 yılında erken emekli olan çalışanların da şirkette gönüllü ayrılanlar içerisinde sayılması, bu sayının yüksekliğinde az da olsa etkili olmuştur. Erken emeklilik gerekçesiyle 2023 yılında ayrılan çalışan sayısı ile 2020-2022 yılları arasında aynı gerekçeyle gönüllü ayrılan çalışan sayısı birbirine eşit ve 25 çalışandır.

İş grubu	2017-2019 (pandemi öncesi)	2020-2022 (pandemi sonrası)	2023 (son yıl)	Toplam
1	38	79	41	158
2	229	576	218	1023
3 - 11	32	83	48	163
Toplam	299	738	307	1344

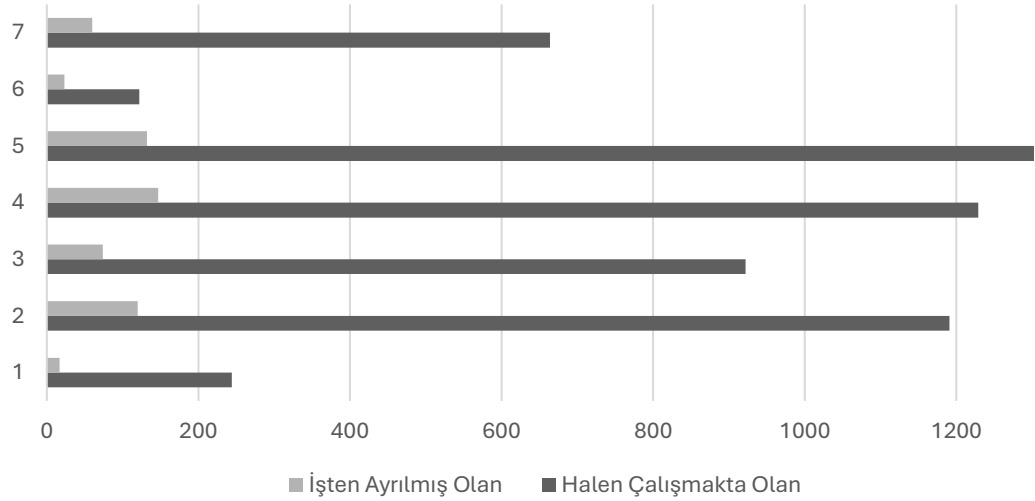
Tablo 7. Ana iş gruplarının pandemi öncesi ve sonrası ayrılışlardaki dağılımı

Çalışanların çalıştıkları yerleşkelere göre ayrılan ve mevcut durumda çalışanlar arasındaki dağılımı Şekil 9’da gösterilmiştir. Şirkette 2 ve 3 numaralı yerleşkeler merkezden uzak yerleşkeler olup, 4 numaralı yerleşke merkezden, merkeze uzak bir yere yer değiştirmiş olan bir bölümdür. Pandemi öncesi ve sonrası için dönemsel değişime bakıldığında farklı bir dağılım yerine Şekil 9’da gösterilen dağılım ile paralel bir dağılım görülmektedir.



Şekil 9. Halen çalışmakta olan ve işten ayrılmış olan çalışanların yerleşkelere göre dağılımı

Şirkette bağlı oldukları ana organizasyonel bölüme bakıldığında, çalışanların pandemi öncesi ve sonrası dönemsel istihdam durumu gerçekleştirmeleri Şekil 10'da yer almaktadır. Şekil incelendiğinde ayrılan çalışanların çoğunlukla bölüm 4 ve 5'te çalıştığı görülmüştür.



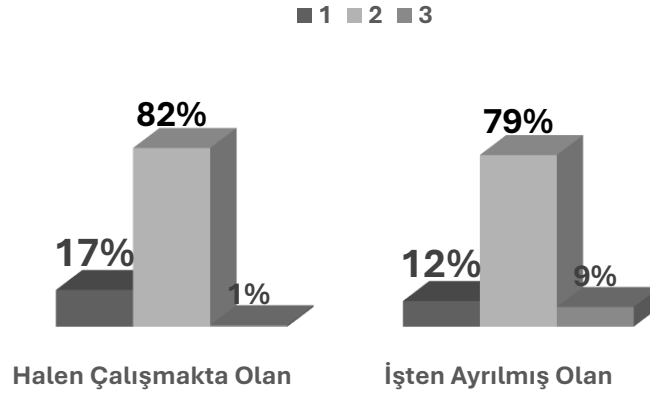
Şekil 10. Bağlı oldukları bölüme göre pandemi öncesi ve sonrası çalışan sayıları

Benzer şekilde, Tablo 8 incelendiğinde pandemi sonrasında ayrılışlarda 2, 4 ve 5 numaralı organizasyonel bölümden ayrılanların fazla olduğu, diğer bölümlerin ayrılan çalışanlar içindeki dağılımlarının çok değişmediği görülmektedir. Diğer bölümlere göre 6 numaralı bölüm yeni kurulan ve farklı işlerle ilgilenen bir bölümdür. Bu bölümden ayrılışların pandemi sonrasında yoğunlaşmasında bu durumun etkisi olabilir.

	2017-2019	2020-2022	2023	Toplam
1	2%	3%	5%	3%
2	18%	22%	28%	21%
3	15%	11%	9%	13%
4	29%	22%	22%	26%
5	25%	19%	22%	23%
6	4%	3%	5%	4%
7	6%	20%	9%	10%
Toplam	100%	100%	100%	100%

Tablo 8. Pandemi öncesi ve sonrası ayrılan çalışanların organizasyon bölümlerine göre dağılımı


Çalışanların performans verileri incelendiğinde, Şekil 11’de gösterildiği gibi çalışanların çoğunluğu orta seviye performansa sahiptir. Ayrılan çalışanlar içerisinde düşük performans grubundaki çalışanların yüzdesinin artmış olması şirket açısından olumlu bir durumdur.



Şekil 11. İşten ayrılış durumlarına göre çalışanların performans bazlı dağılımı

Çalışmanın ilk bölümünde de aktarıldığı gibi örgütler için işten ayrılma analizlerinde önemli olan ayrılan çalışanların yüksek performanslı ya da yaptığı iş sebebiyle kritik çalışanlar arasında yer almıyor olmasıdır. Bu çalışanların ayrılış durumlarının şirkete maliyeti yüksek olmaktadır. Şekil 12, performanslarına göre çalışanların işten ayrılma ya da halen şirkette çalışıyor olma yüzdelerini vermektedir. Performansı yüksek ve orta seviyede olan çalışanların büyük çoğunluğu halen şirkette çalışırken, aksine performansı düşük olan çalışanların birçoğu ise şirketten ayrılmıştır. Bu da gerçekleşmesi istenen senaryo ile tutarlıdır.

Tablo 9’da Pandemi öncesi ve sonrası dönemde ayrılan çalışanların performanslarına göre yüzdesel dağılımı gösterilmektedir. Tabloda görüldüğü gibi Pandemi dönemi sonrasında ayrılan çalışanların çoğunluğu yüksek performanslı çalışanlar arasından olmuş; aksine bir durum olarak düşük performanslı çalışanların ayrılanlar arasındaki yüzdesi oldukça düşüktür. Bu da şirket için ayrılış maliyetlerinin pandemi sonrasında artmış olabileceğinin büyük bir göstergesidir.



Şekil 12. Performanslarına göre çalışanların işten ayrılma ya da halen şirkette çalışıyor olma yüzdeleri

	2017-2019	2020-2022	2023
1	8%	14%	11%
2	70%	81%	83%
3	22%	5%	6%
Toplam	100%	100%	100%

Tablo 9. Pandemi öncesi ve sonrası dönemde ayrılan çalışanların performanslarına göre yüzdesel dağılımı

Bu analize çalışanların yaşları da eklendiğinde, yüksek performanslı ve 28-32 yaş aralığındaki çalışanlardan pandemi öncesi ayrılan çalışanların yüzdesi, pandemi sonrasında iki katına çıkmıştır. Bu durum, ayrılışların pandemi sonrasında şirkete maliyetini daha da arttıran bir durumdur. Bu durum Tablo 10'da görülmektedir.

Yaş	2017-2019	2020-2022	2023
<28	0%	8%	3%
28-32	17%	34%	35%
33-37	50%	29%	21%
38-42	25%	19%	24%
43-47	8%	6%	15%
48-52	0%	2%	0%
53-57	0%	2%	3%
58-62	0%	1%	0%
Yüksek performanslı çalışanlar	8%	14%	11%

Tablo 10. Yüksek performanslı ve işten ayrılan çalışanların yaş ve dönemsel dağılımı

3.4. BETİMSSEL ANALİZ BULGULARI

Bu bölümde aktarılan bulgular kısaca özetlenecek olursa, toplam 6378 çalışandan 5034 çalışan 2023 yıl sonu itibarıyla halen çalışmakta iken 1344 çalışan işten ayrılmış durumdadır. Pandemi dönemi sonrasında işten ayrılmaların genel olarak şirkette arttığı, bunu telafi etmek adına işe alımların da arttırıldığı görülmüştür. Pandemi öncesinde 5-14 yıl deneyimli çalışan ayrılışları daha çok iken Pandemi sonrasında 0-4 yıl deneyimli çalışan ayrılışları daha çok olmuştur. Bu da şirketin çalışan tutundurma yeteneğinin zayıfladığını göstermektedir. Ayrılan çalışanlar şirkete deneyimi ile daha çok getiri sağlayan ve yatırım yapılmış olan 28-32 ve 33-37 yaş arasındaki çalışanlar olmuştur. Demografik verilere bakıldığında ise, beklendiği şekilde çocuk sayısı arttıkça ayrılışların azaldığı görülmüştür. Eğitim seviyesine bakıldığında, yüksek lisans mezunu çalışanların ayrılış yüzdesi diğer eğitim seviyelerindeki çalışanlardan daha fazla olmuştur. Son olarak, Pandemi sonrasında yüksek performanslı çalışanların ayrılışlardaki oranı artarken, düşük performanslı çalışanların ayrılışlardaki oranı ise azalmıştır.

4.BÖLÜM

YÖNTEM

Bu çalışmada, hem işten ayrılmalara sebep olan nedenlerin pandemi öncesi ve pandemi sonrasında nasıl farklılaştığını gösteren örnek bir uygulama yapılmış hem de aynı veriler kullanılarak işten ayrılma niyetinin önceden tahmin edilebilmesi için bir model geliştirilmesi amaçlanmıştır. Bu amaçla, denetimli makine öğrenmesi yöntemlerinden sınıflandırma için kullanılan ikili lojistik regresyon, k en yakın komşuluk, destek vektör makineleri, karar ağacı ve rassal orman makine öğrenmesi yöntemleri kullanılmıştır.

Çalışmanın bu bölümünde daha önceki bölümlerde aktarılan bilgiler çerçevesinde, uygulama için tasarlanmış farklı yaklaşımlar ile analizlerin tasarımı ve kullanılan yöntemler detaylı olarak aktarılmıştır.

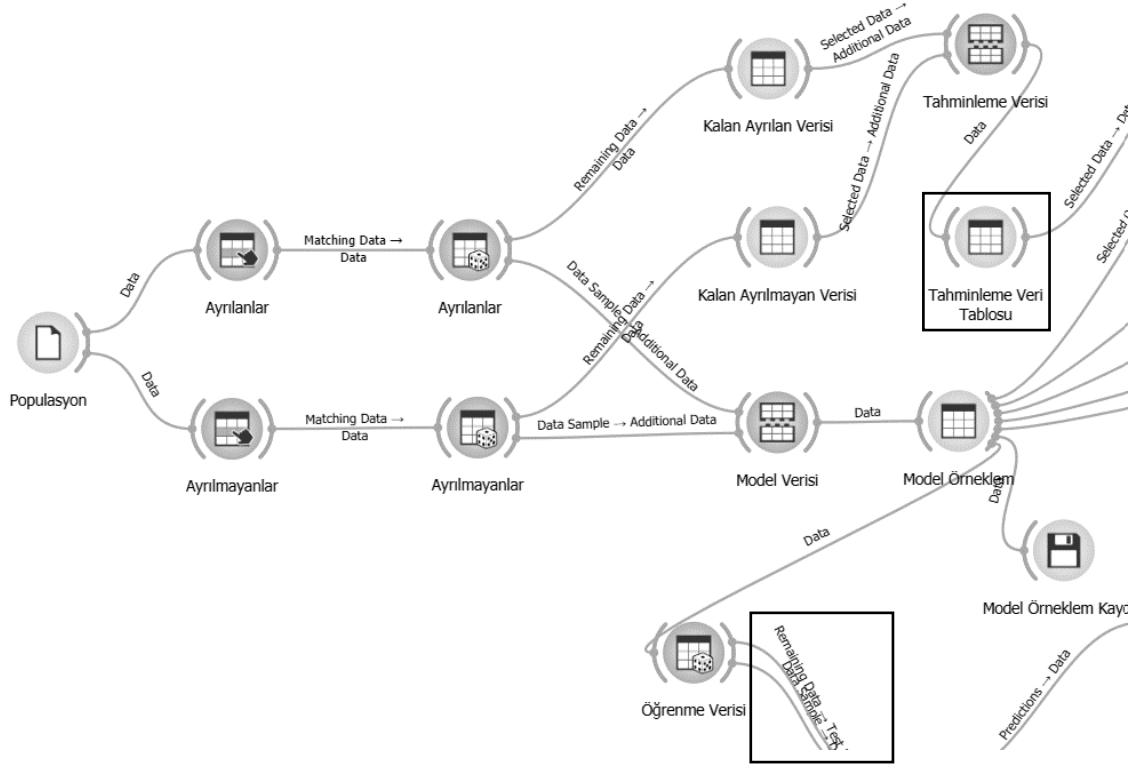
4.1.ANALİZ TASARIMI

4.1.1. Popülasyondan Örneklem Oluşturma ve Kullanılan Yaklaşımlar

Önceki bölümlerde çalışmada kullanılan veriler detaylı olarak açıklanmıştır. Bu bölümde ise bu verilerin nasıl ayrıştırıldığından bahsedilmektedir. Öncelikle, analizler için her iki dönemi temsil eden örneklem oluşturulmuştur. Çalışmada popülasyondan örneklem oluşturma aşamaları *Orange* programında hazırlanan senaryo üzerinden gerçekleştirilmiştir. Hem ayrılış niyetine etki eden faktörlerin analizinde hem de ayrılış niyetini tahminleme analizlerinde aynı örneklem yaklaşımları ve verileri kullanılmıştır.

Popülasyonda her iki dönem için ayrılan çalışan sayıları, halen çalışmakta olan çalışanlardan çok daha az olduğu için çoğaltıcı değil (*oversampling*) azaltıcı örneklem (*undersampling*) yöntemine gidilmiştir. Her iki dönemde oluşturulan örneklem için seçimler Şekil 13'te gösterildiği gibi *Orange* yardımıyla rastgele yapılmıştır. Popülasyonda örneklem alınan veriden geriye kalan veriler ise ayrılış tahmin analizinde modelin tahmin (*prediction*) verisi olarak kullanılmıştır.

Modelin öğrenmesi (*train*) ve test (*test*) için kullanılacak olan veriler sırasıyla örneklem grubunun yüzde 80'i ve yüzde 20'si olacak şekilde yine Şekil 13'te gösterildiği gibi *Orange* programı örneklem oluşturma özelliği üzerinden ayrıştırılmıştır.



Şekil 13. *Orange* programı örneklem oluşturma senaryosu

Çalışmada kullanılan yöntemlerin örneklem çeşitlerine göre geçerliliklerini gözlemleyebilmek için farklı yaklaşımlar kullanılmıştır. Bu yaklaşımların ortak özelliği ayrılan ve ayrılmayan çalışan sayılarının örnekleme eşit sayıda olmasıdır. Bu şekilde, örnekleme sınıfların dengeli dağılımı sağlanmıştır. Ancak, örnekleme dağılım eşit olsa da yüzde 80 oranındaki öğrenme verisinde bu dağılım verilerin seçimine göre eşit olmayabilir.

Seçilen ve model oluşturmada kullanılan yaklaşımlara ait örneklemeler aşağıda Tablo 11'de özetlenmiştir.

Yaklaşım-1. Tüm ayrılan çalışanlar: Bu yaklaşımda, popülasyondaki ayrılan tüm çalışanlar örnekleme yer almaktadır. Bu şekilde tahmin verisinde tamamen halen

çalışan sınıfında yer alan örnekler yer alacaktır. Her iki dönem için de aynı yaklaşım uygulanarak örneklem 1 ve örneklem 2 oluşturulmuştur.

Yaklaşım-1	Tüm ayrılan çalışanlar						
	Ayrılan çalışan sayısı	Halen çalışmakta olan çalışan sayısı	Toplam çalışan sayısı (N)	Öğrenme verisi	Test verisi	Tahmin verisi	Toplam
2017-2019 (1)	299	299	598	478	120	3629	4227
2020-2023 (2)	1045	1045	2090	1672	418	3989	6079

Yaklaşım-2	Dönemler arası eşit dağılım						
	Ayrılan çalışan sayısı	Halen çalışmakta olan çalışan sayısı	Toplam çalışan sayısı (N)	Öğrenme verisi	Test verisi	Tahmin verisi	Toplam
2017-2019 (1)	299	299	598	478	120	3629	4227
2020-2023 (3)	299	299	598	478	120	5481	6079

Yaklaşım-3	Küçük örneklem						
	Ayrılan çalışan sayısı	Halen çalışmakta olan çalışan sayısı	Toplam çalışan sayısı (N)	Öğrenme verisi	Test verisi	Tahmin verisi	Toplam
2017-2019 (4)	200	200	400	320	80	3827	4227
2020-2023 (5)	800	800	1600	1280	320	4479	6079

Tablo 11. Çalışmada kullanılan yaklaşımlar

Yaklaşım-2. Dönemler arası eşit dağılım: Bu yaklaşımda her iki döneme ait örneklem sayıları birbirine eşit olacak şekilde örneklem 1 baz alınarak örneklem 3 oluşturulmuştur. 2017-2019 dönemi için örneklem 1 kullanılmış; dolayısıyla aynı sayıda örneklem 2020-2023 dönemi için de kullanıldığında bu dönem için ayrılan tahmin verisinde yaklaşım 1'den farklı olarak işten ayrılan çalışanlar da yer almıştır.

Yaklaşım 1 ve 2 arasında bir kıyaslandığında, aynı dönemi temsil eden örneklem 2 ve 3'ün büyüklüğünün değişiminin etkisi ile farklı sınıflardan veri olduğunda modellerin tahminleme becerisi karşılaştırılmıştır.

Yaklaşım-3. Küçük örneklem: Bu grupta her iki dönem için tahmin verisinde her iki sınıftan da veri olması amaçlanmıştır. Dolayısıyla 2017-2019 dönemi için yaklaşım 1 ve

2'den daha küçük olan örneklem 4 ve 2020-2023 dönemi için de örneklem 5 oluşturulmuştur.

Yaklaşım 1, 2 ve 3 kıyaslandığında, örneklem büyüklüğünün modellerin tahminleme başarısındaki etkisi ve her iki dönemde de farklı iki sınıftan veri olduğunda tahminleme becerisi daha net gözlemlenmiştir.

Yaklaşım-4. Performansı yüksek olan çalışanlar: Yukarıda bahsedilen yaklaşımlara ek olarak, 2020-2023 döneminde performansı yüksek olan çalışanlardan örneklem 6 oluşturulmuştur. Bu örnekleme performansı puanı özneliği yer almamaktadır. Tablo 12'de yaklaşım 4 ile ilgili bilgiler verilmiştir.

Yaklaşım 4	Performansı yüksek olan çalışanlar						
	Ayrılan Çalışan Sayısı	Halen Çalışmakta Olan Çalışan Sayısı	Toplam Çalışan Sayısı (N)	Öğrenme Verisi	Test Verisi	Tahmin Verisi	Toplam
2020-2023 (6)	135	135	270	216	54	718	988

Tablo 12. Yaklaşım 4. Pandemi sonrası performansı yüksek çalışanlar

Yaklaşım 4 ile yaklaşım 1, 2, 3 kıyaslandığında öznelik sayısı azaltıldığında oluşan durumla ilgili karşılaştırma yapılmış; hem de yüksek performanslı çalışanlar üzerinde de işten ayrılma neden analizi ve tahminleme çalışması yapılmıştır.

İşten ayrılma nedenleri araştırılırken yaklaşım 1 ve yaklaşım 4 uygulanırken, işten ayrılma niyeti tahmin modeli oluşturmak için tüm yaklaşımlardan faydalanılmıştır.

4.2. MODEL KURULUMU

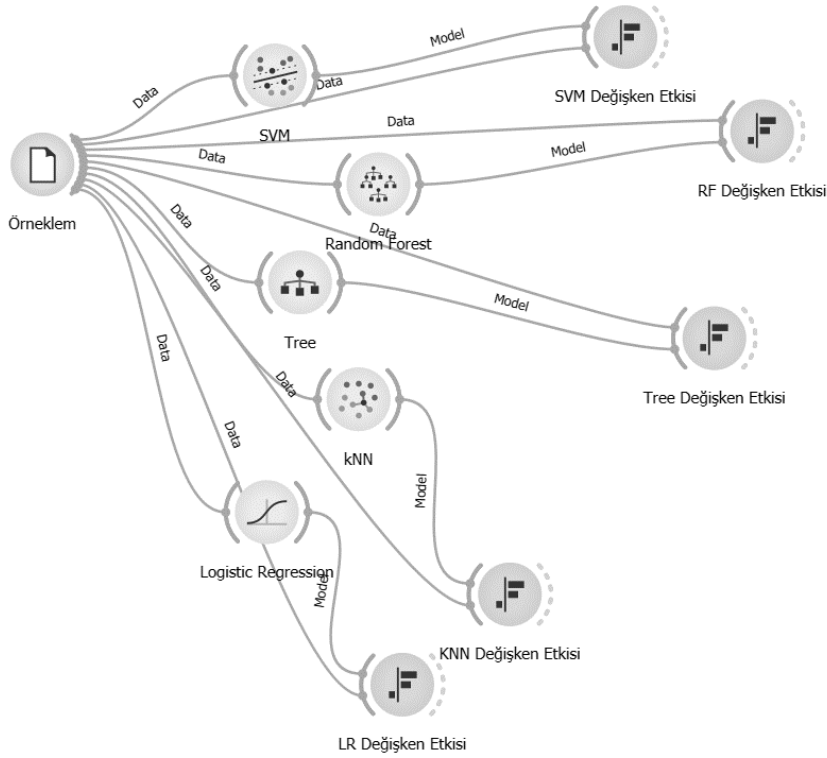
4.2.1. Ayrılış Niyetine Etki Eden Faktörlerin Analizi

Bu çalışmada pandemi öncesi ve sonrası dönemde ayrılma nedenlerindeki değişimlerin karşılaştırılması ulaşılmak istenen çıktılardan biridir. Bu konuyla ilgili yapılmış çalışmalarda daha önceki bölümlerde de ayrıntılı bir şekilde aktarıldığı gibi özellikle ikili

lojistik regresyon analizinden yararlanılmaktadır. Pandemi dönemi özelinde analitik olarak bu nedenleri analiz eden bir çalışmaya ise rastlanmamıştır.

Özniteliklerin hedef değişken yani ayrılma durumu üzerinde ne kadar etkili ya da etkisiz olduğuna dair analizler, her iki dönem için ikili lojistik regresyon yöntemi kullanılarak SPSS programında yapılmıştır. Analizlerde en kapsayıcı örneklem olduğu için yaklaşım 1'de yer alan ve her iki dönemde tüm ayrılan örnekleri içeren yaklaşım 1 (örneklem 1 ve 2)'den yararlanılmıştır. Bu analize ek olarak, yaklaşım 4 (örneklem 6)'te pandemi sonrası dönemde performansı yüksek çalışanların öznitelikleri kullanılarak bu çalışanların ayrılma niyeti nedenleri ayrıca incelenmiştir.

Çalışanların özniteliklerinin ayrılma kararları üzerindeki etkisi incelenirken SPSS programında yapılan analizlere ek olarak, *Orange* programı ile yapılan öznitelik etki analizleri de destekleyici veri olarak kullanılmıştır. Bunun için Şekil 14'te kullanılan senaryo örneklem 1, 2 ve 6 için uygulanmış, elde edilen AUC başarı ölçütüne göre sonuçlar bir sonraki bölümde sunulmuştur.



Şekil 14. Model tahmininde öznitelik etkileri *Orange* programı senaryosu

4.2.2. İkili Lojistik Regresyon

Lojistik regresyon analizi, denetimli makine öğrenmesinde sınıflandırma yöntemlerinden biridir. Lineer regresyondan farklı olarak sürekli sayılar yerine kategorik bağımlı değişkenlerin bağımsız değişkenlerle açıklanabilmesinde kullanılan bir regresyon analizidir (Yedida, 2018). Bağımlı değişkenin kategori sayısı iki olduğunda ikili lojistik regresyon; ikiden fazla olduğunda ise çoklu lojistik regresyon analizi yapılır. Bu analiz yöntemini daha detaylı olarak aktaracak olursak, lojistik regresyon, bağımlı değişkenin 1'e eşit olma olasılığının, eşit olmama olasılığına oranının (*odds*) doğal logaritmasıdır (*lojit*) (Abiad ve Ionescu, 2020). *Odds* değeri $0 \leq \theta(x) \leq 1$ olacak şekilde tanımlanır.

Bu durumda, *odds* denklemi (2) numaralı denklem ile lojit denklemi ise (3) numaralı lineer denklem ile hesaplanır.

$$\theta(x) = \frac{1}{1+e^{-Y}} \quad (2)$$

$$\text{lojit}(\theta(x)) = \log\left(\frac{\theta(x)}{1-\theta(x)}\right) = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n \quad (3)$$

Lineer regresyondan farklı olarak, lojistik regresyon maksimum olabilirlik (*maximum likelihood*) yöntemi ile verilerin iyi uyduğu çizgiyi tahmin eder. Chi-square test ile bağımsız değişkenlerin bağımlı değişkenleri açıklamasında lojistik regresyonun kullanılabilirliği ölçülürken; Wald test istatistiği ile her bir bağımsız değişkenin bağımlı değişkeni ne kadar iyi açıklayabildiği test edilir (Wulandari, 2022).

Bu analiz yönteminde, kategorik bağımlı değişken ikili kategorizasyona sahip ise 0 ve 1 değerlerini alır. Lojistik regresyonda bağımsız değişkenlerin kategorik, sürekli veya kesik veriler olmasının bir önemi yoktur (Wulandari, 2022). Bu anlamda, esnek ve oldukça tercih edilen bir yöntemdir.

Bu çalışmada hem ayrılma niyetine etki eden faktörlerin araştırılmasında hem de ayrılma niyetinin tahminlenmesinde ikili lojistik regresyon analizinden faydalanılmıştır.

Analiz sonuçlarını sunmadan önce, SPSS programında ortaya çıkan sonuçların nasıl yorumlanması gerektiği ile ilgili özet bilgiler, Wulandari (2022) tarafından yazılan bildiriden de yararlanarak aşağıda açıklanmıştır. Modelin uyumuna (*goodness of fit*) bakan testler incelendiğinde:

- Nagelkerke R kare test sonucu, toplu halde bakıldığında bağımsız değişkenlerin bağımlı değişkeni hangi oranda açıklayabildiğini gösteren değerdir.
- Hosmer ve Lemeshow testinde p değerinin 0,05'ten büyük olması ikili lojistik regresyon yönteminin veriye uygun bir modelleme yöntemi olduğunu göstermektedir.
- Sınıflandırma tablosu (*classification table*)nda karmaşıklık matrisi (*confusion matrix*) görülmektedir. Matris modelin tahminleme başarısını göstermektedir.

Özniteliklerin, hedef değişkenin yer aldığı grubu tariflediği sonuçlar ise:

- Değişken tablosunda analize konu olan bağımsız değişkenlerin (özniteliklerin) model içerisinde hedef değişkeni tek tek ele alındığında ne ölçüde açıkladıkları ve etkiledikleri yani yapılan *Wald* testinin sonuçları yer almaktadır. Eğer bir değişkenin açıklayıcılık (*significance-Sig.*) kolonundaki değeri 0,05'ten küçük veya eşit ise bu değişkenin B kolonundaki değer yönünde hedef değişkenin birinci sınıfta yer almasında etkisi olduğu söylenebilir. Eğer açıklayıcılık değeri 0,05'ten büyük ise bu değişkenin hedef değişkenin birinci grupta yer alması üzerinde bir etkisi yoktur.

4.2.3. Ayrılış Niyeti Tahminleme Model Senaryosunun Oluşturulması

Çalışan ayrılma niyetinin tahminlenmesi bir sınıflandırma problemi olarak tanımlanabilir. Bu nedenle, araştırmalarda yoğunluklu olarak makine öğrenmesi denetimli öğrenme sınıflandırma yöntemleri kullanılmaktadır.

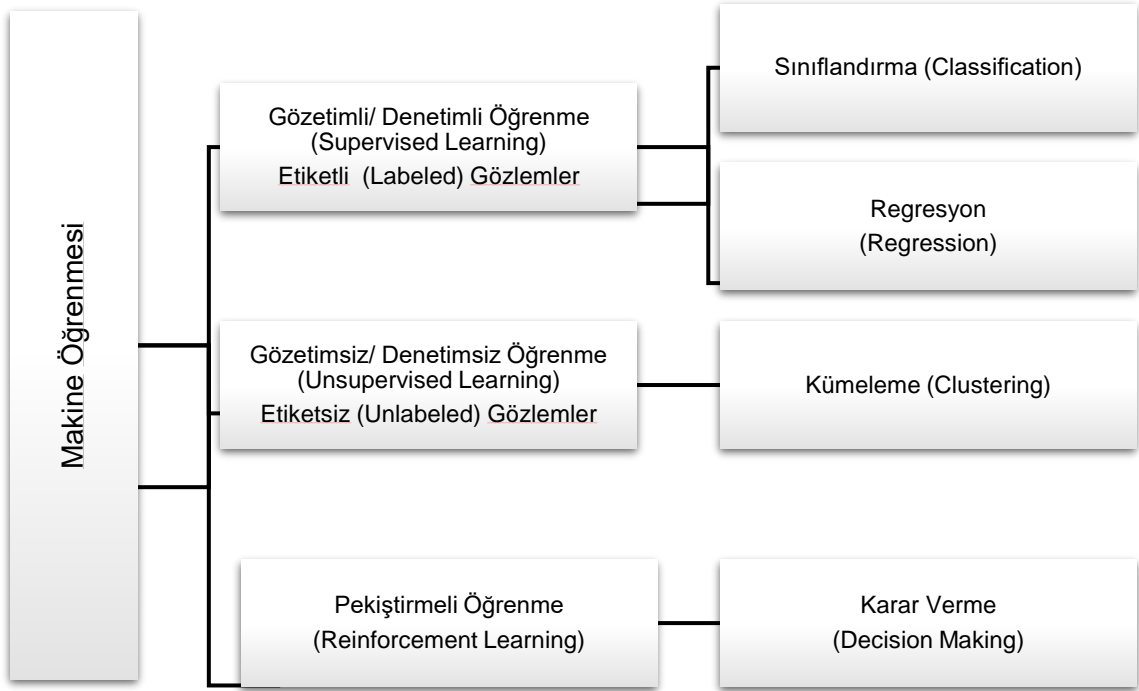
Makine öğrenmesi (*machine learning*) en basit şekilde, veriler üzerinden makinenin çeşitli yöntemlerle ilişki kurarak modeller üretmesi; çıkarım ve/veya tahminlerde

bulunmasıdır ve makinenin öğrenme şekline göre yöntemler Şekil 15'te gösterildiği gibi gruplanmaktadır (Sarker, 2021) (Krishna ve Sidharth, 2022).

- Gözetimli / denetimli öğrenmede, makineye öznitelik verileri ile sınıflandırılmış/ etiketlendirilmiş hedef veriler tanıtılır. Makine kullandığı algoritma ya da yönteme göre yaptığı denemelerle, özniteliklerin hedefi en iyi şekilde tariflediği modeli oluşturur. Bu yöntem sayesinde öznitelik değerlerine göre yeni verinin hangi sınıfta yer aldığına dair tahminlemeler yapılmaktadır. (Örn. lojistik regresyon, k en yakın komşuluk algoritması, karar ağacı, rassal orman, destek vektör makinesi, vb.)
- Gözetimsiz / denetimsiz öğrenmede, makineye sadece girdi verileri verilirken herhangi bir etiketlenmiş hedef verisi tanıtılmaz. Makine eldeki girdi verilerinin paternlerinden hedef veriye ulaşan modeli oluşturmaya çalışır. Bu şekilde girdi verilerini kümeleyecek çıktılara ulaşır. (Örn. k ortalama kümeleme, vb.)
- Karar verme algoritmalarında ise önemli olan doğru sırada gerçekleşen aksiyonların oluşturduğu politikayı, geçmiş aksiyonlara bakarak bulmak ve hedefe ulaşmaktır (örn. *Monte Carlo metotları*, vb.) (Alpaydin, 2020).

Ayrılma niyetine etki eden faktörler ve ayrılma niyeti tahminlemeleri birer sınıflandırma problemi kategorisine girdiği için bu çalışmada gerçekleştirilen uygulamada gözetimli makine öğrenmesi yöntemlerinden faydalanılmıştır. Makine öğrenmesinde, makineye girdi olarak verilen veriler aşağıdaki veri setlerine bölünerek makine tarafından işlenmektedir.

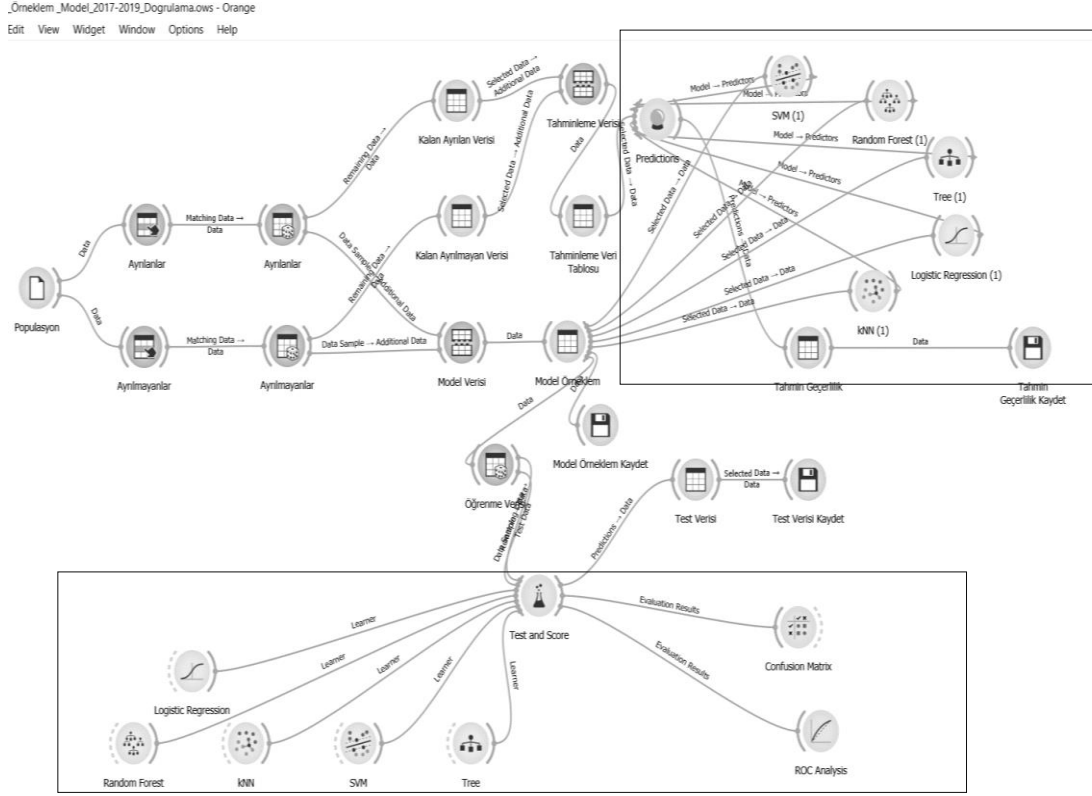
- Eğitim verileri (*train set*), makinenin modeli öğrenmesini sağlayan verilerdir.
- Doğrulama verileri (*validation set*), modeli doğrulamak için kullanılan ve gerektiğinde makineyi yeniden öğrenmeye yönlendiren verilerdir,
- Test verileri (*test set*), oluşturulan modelin test edildiği ve performansının ölçüldüğü verilerdir.



Şekil 15. Makine öğrenmesi yöntemleri

Makine öğrenmesinde esas hedef makinenin en iyi şekilde tahminleme yapacağı modeli bulabilmektir. Verinin dağılımından kaynaklı olarak modelin tahminleme performansını etkileyen aşırı öğrenme (*overfitting*) ya da eksik öğrenme (*underfitting*) gibi durumlar oluşabilir. Bu gibi durumları ortadan kaldırmak ya da model performansını arttırmak üzere modeli veriye daha uygun hale getirebilecek dışarıdan müdahaleler yapılması gerekebilir. Bu müdahaleler aslında hiperparametre olarak tanımlanan model parametrelerini değiştirerek modelde dışarıdan yapılan ayarlardır.

Bu çalışmada, *Orange* programından yararlanılarak aşağıda Şekil 16'da yer alan senaryo üzerinden LR, KNN, SVM, DT ve RF ile ayrılış tahmin modelleri oluşturulmuş; yöntemlere göre modellerin hiperparametreleri ayarlanarak performanslarıyla ilgili ilerleyen bölümde daha ayrıntılı aktarılan model test başarı göstergeleri elde edilmiştir. Aynı senaryoya modellerin öğrenme verisinden geriye kalan tahminleme verisi üzerindeki aynı hiperparametreler ile tahminleme başarısı da eklenmiştir.



Şekil 16. Ayrılış niyeti tahmin modeli oluşturma *Orange* programı senaryosu

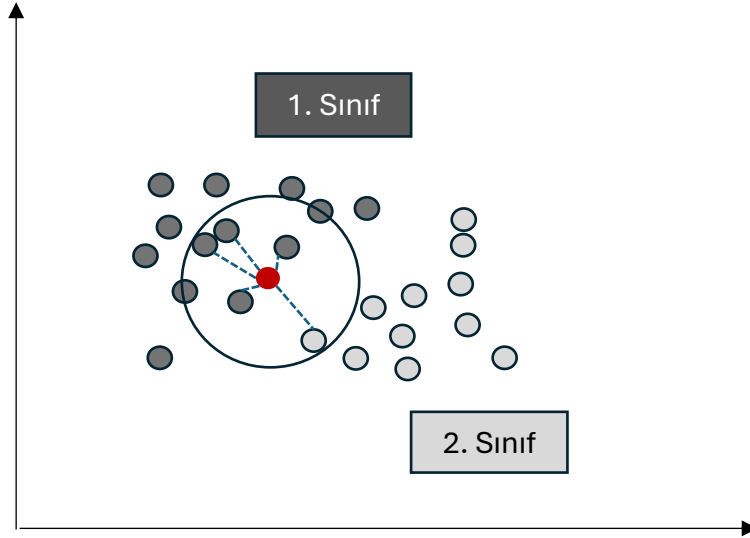
Bu çalışmada amaçlanan en iyi tahmin yapabilen modeli elde edebilmektir. Bu amaç doğrultusunda oluşturulan senaryo ile:

- Öncelikle yaklaşımlarda belirtilen örneklem büyüklüklerine göre her dönem ve yaklaşım için örneklem ayrı ayrı oluşturulmuş,
- Alınan örneklem verilerinin yüzde 80'i eğitim verisi, yüzde 20'si test verisi olarak ayrılmış,
- Ardından en iyi test başarısını verecek şekilde model hiperparametreleri ayarlanmış,
- Aynı hiperparametre değerleri kullanılarak model tahmin başarılarına bakılmıştır.

Elde edilen veriler ışığında, uygulanan tahmin modellerinin, yapılan hiperparametre ayarları sonrasında gösterdikleri test ve tahminleme başarıları bir sonraki bölümde aktarılan performans ölçütleri üzerinden karşılaştırılmıştır.

Bu çalışmada ve benzer diğer çalışmalarda kullanılan LR, KNN, SVM, DT ve RF denetimli makine öğrenmesi yöntemleri ile bu yöntemlerde kullanılan ve değişiklik yapılabilen hiperparametreler aşağıda detaylı olarak anlatılmıştır. LR yöntemi bir önceki bölümde aktarıldığı için bu bölümde tekrar edilmemiştir.

4.2.4. K En Yakın Komşuluk




Şekil 17. K en yakın komşuluk örneği

Bu algoritmada, yeni eklenen gözlemin sınıfı, verilen komşuluk miktarına yani K hiperparametresine göre kendisine en yakında olan K miktardaki komşularının mevcut sınıflarına bakarak bulunur. Şekil 17’de basit olarak iki öznitelikli bir veri setinde verilerin öznitelik değerlerine göre yerleri ve sınıflarına göre renklendirmeleri görülmektedir. Örneğin, k en yakın komşuluk algoritmasına göre, şekilde sınıfı belli olmayan ancak öznitelik değerlerine göre yeri belli olan kırmızı nokta K hiperparametresinin 5 olduğu durumda, kendisine en yakın 5 komşusunun çoğunluğu 1. sınıfta yer aldığı için 1. sınıfta gruplanacaktır (Salunkhe, 2018) (Akyel & Seçkin, 2012).

K en yakın komşuluk algoritmasında dışarıdan ayarlanabilen en önemli hiperparametre K komşuluk değeridir. Bunun yanında mesafe hesaplaması için de farklı denklemler kullanılabilir (Sisodia vd., 2017).

4.2.5. Destek Vektör Makinesi



Şekil 18. Destek vektör makinesi örneği

Destek vektör makinesi ikili sınıflandırmalar için kullanılan bir yöntemdir. İki veya daha fazla etikete sahip olan verileri sınıflarına göre ayıran bir hiperdüzlemin doğrusal denklemini gösteren modeldir. Yeni eklenen verinin öznelik değerlerine göre hangi sınıfa dahil olduğu bu doğrusal denklemin neresinde bulunduğuna göre tahmin edilir (Saradhi ve Palshikar, 2011). Doğrusal denklemin sınırlarını oluşturan vektörlere destek vektörleri denilmektedir (Shankar vd., 2018).

Destek vektörleri sınıfların sınırlarına ne kadar yakın geçebilirse yani destek vektörleri arasındaki mesafe (marjin) ne kadar maksimize edilirse yeni verinin sınıfını tahminleme başarısı o kadar yüksek olabilir. Aşağıda Şekil 18'de iki özneliğe sahip veriler üzerinde destek vektör makinesi çalışma prensibi gösterilmektedir. Şekilde, w ağırlık vektörü, x girdi vektörü, b ise sapmadır. Eğer doğrusal olarak ayrılamayan bir dağılıma sahip veri mevcutsa ya da bazı veriler düzlemin içerisinde kalıyorsa, bu veriler için bir C hata parametresi, optimizasyon denklemine eklenir. C 'nin büyüklüğü ile marjinin genişliği arasında negatif yönlü bir ilişki mevcuttur. C büyüdükçe destek vektörleri birbirine yaklaşır (Kaya ve Korkmaz, 2021).

Bu yöntemin uygulanabilmesinde zorlaştırıcı olan birden fazla özneliğin olduğu veri setlerinde ayırıcı düzlemin bulunmasının karmaşıklaşmasıdır. Bunun çözümü olarak destek vektör makinesi yönteminde verileri farklı bir düzlemde doğrusal fonksiyon ile tanımlamaya yarayan *Kernel* tekniği (*Kernel trick*) kullanılmakta ve veriler bir *Kernel* fonksiyonuna dönüştürülmektedir. Bunun için polinom *Kernel* ve *Gaussian* radyal temel işlev çekirdeği gibi teknikler kullanılmaktadır (Farquad vd., 2014).

Burada önemli olan aşırı tahmin ya da eksik öğrenme problemlerine sebep olmayacak parametreleri kullanmaktır. Aşırı tahmin durumunda C ve/ veya *Kernel* hiperparametrelerinin düşürülmesi gerekir.

4.2.6. Karar Ağacı

Karar ağacı algoritması öznelik değerlerini kullanarak verilerin buldukları yeri bir ağaç şeklinde tanımlamaktadır. Bu şekilde yeni verinin hangi sınıfta yer alacağını da bu ağaç üzerinden tahminlemektedir (Yıldız, 2023). Ağaç, başlangıç düğümü yani “kök”ten başlayarak en son yapraklara doğru veri özneliğinin değerine göre Şekil 19’da gösterildiği gibi dallara ayrılır.

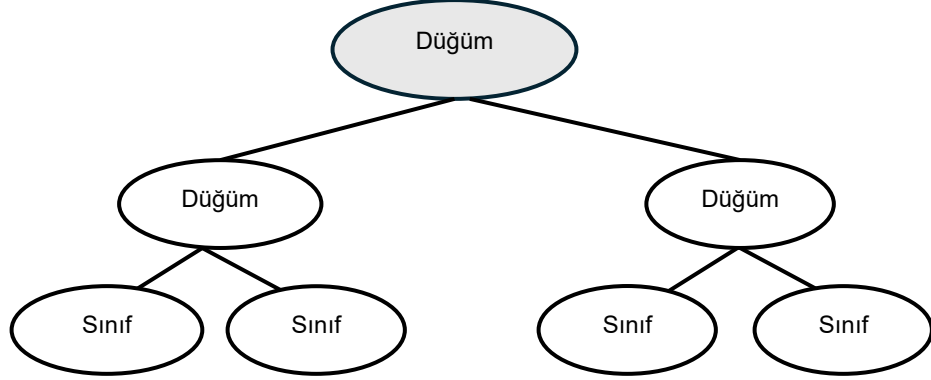
Ağaç oluşturulurken her dallanmada hangi düğümün kullanılacağına daha dengeli bir ağaç yapısı oluşturabilmek için entropi veya *Gini* performans değerlendirmeleri uygulanarak başlanır (Louak, 2021). *Gini* yöntemi hesaplamasında denklem (4) kullanılır. Burada, m düğümü, k m düğümündeki gözlem sayısını ve p_{mk} değeri bu bölgedeki gerçekleşme olasılık sayısını gösterir.

$$H(Q_m) = \sum_k p_{mk} * (1 - p_{mk}) \quad (4)$$

Entropi kullanıldığında da benzer olarak bu olasılığın logaritması alınır ve hesaplamada denklem (5) kullanılır (Louak, 2021).

$$H(Q_m) = - \sum_k p_{mk} * \log(p_{mk}) \quad (5)$$

Entropi kullanılarak da bilgi kazanımı hesaplamalarıyla ağaç mevcut verilerden ve mevcut sınıflamalardan öğrenerek oluşturulur (Alhashmi, 2019).



Şekil 19. Karar ağacı yapısı

Bu algorithmada ağaç yapısını ve modeli etkileyen hiperparametre değerleri aşağıda verilmiştir (Yıldız, 2023):

- Maksimum ağaç derinliği (*depth*),
- Düğümün minimum örnek sayısı,
- Minimum ve maksimum yaprak sayısı,
- Her kırılımdaki (dallanmadaki) minimum ve maksimum öznitelik sayısı

Algoritmanın tüm verilerin üzerinden geçerek fazlasıyla öğrenmesini engellemek için aşırı öğrenme durumunda ağaç derinliği küçültülmelidir. Bir düğümde az sayıda örnek yer alması aşırı öğrenmeye sebep olabilir.

4.2.7. Rassal Orman

Rassal orman, karar ağacı algoritmasından türetilmiş bir yöntemdir. Tek bir ağaç yerine rastgele bir öznitelikten başlayarak birkaç karar ağacının oluşturulması ve bulunan sonuçlarda en yüksek sonucun kullanılmasıyla tahmin yapılan bir yöntemdir (Alamsyah vd., 2018). Bu şekilde karar ağacında karşılaşılabilecek olan fazla tahminleme hatasını da ortadan kaldırmış olur (Krishna ve Sidharth, 2022). Bu algoritma karar ağacı

algoritmasının genişletilmiş hali olduğu için aynı hiperparametreler bu algoritma için de geçerlidir.

4.2.8. Model Başarı Ölçütleri

		Modele Göre Tahmin Edilen	
		Ayrıldı (0)	Ayrılmadı(1)
Gerçekleşen	Ayrıldı (0)	<p>Gerçekten ayrılan çalışanların ne kadarını ayrıldı olarak tahmin etti</p> <p>Doğru Pozitif (DP) (<i>True Positive</i>)</p>	<p>Gerçekten ayrılan çalışanların ne kadarını ayrılmadı olarak tahmin etti</p> <p>Yanlış Negatif (YN) (<i>False Negative</i>)</p>
	Ayrılmadı (1)	<p>Gerçekten halen çalışanların ne kadarını ayrıldı olarak tahmin etti</p> <p>Yanlış Pozitif (YP) (<i>False Positive</i>)</p>	<p>Gerçekten halen çalışanların ne kadarını halen çalışan olarak tahmin etti</p> <p>Doğru Negatif (DN) (<i>True Negative</i>)</p>

Şekil 20. Karışıklık matrisi

Farklı yöntemlerle elde edilen tahminleme modellerinin tahmin başarılarını karşılaştırabilmek amacıyla model başarı ölçütleri kullanılmaktadır. Bu ölçütlerin hesaplanması Şekil 20’de verilen “karışıklık matrisi (*confusion matrix*)” çıktılarına dayanmaktadır (Alamsyah ve Salma, 2018).

Bu matrise bakarak elde edilen model tahmin başarı ölçütleri aşağıdaki gibidir. Bu ölçütlerin oranları ne kadar yüksek olursa, modelin tahminleme başarısı ve veriyi sınıflandırma başarısı da o kadar yüksek demektir. Aşağıda bu ölçütler ve formülleri özetlenmiştir (Alamsyah ve Salma, 2018).

- Doğruluk (*Accuracy-CA*) =
$$\frac{DP+DN}{DP+DN+YN+YP}$$

Tüm verilerin ne kadarının doğru tahminlendiğini gösterir.

- Hata Oranı (*error rate/ misclassification Rate*) = $\frac{YP+YN}{DP+DN+YN+YP}$

Doğruluk ölçütünün tam tersi olarak tüm verilerin ne kadarının hatalı tahmin edildiğini gösterir.

- Kesinlik (*precision*) = $\frac{DP}{DP+YP}$
- F1 Skor (*F1 score*) = $2 * \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}}$
- Doğru negatif oranı (seçicilik/ özgüllük) (*TN rate/ specificity*) = $\frac{DN}{DP+YP}$
- Yanlış pozitif oranı (*FP rate*) = $\frac{YP}{DP+YP}$
- Doğru pozitif oranı (hassasiyet/ duyarlılık) (*TP rate/ sensitivity rate/ recall*) = $\frac{DP}{DP+YN}$

Model pozitif tahminlerinden ne kadarı doğru pozitif tahminlenmiştir.

- *ROC eğrisi (receiver operating characteristic)*: YP ölçütünün x ekseninde, DP ölçütünün y ekseninde yer aldığı durumda model için çizilen eğridir. Model eğrisi ne kadar DP oranının 1 olduğu konuma yaklaşırsa, model de o kadar başarılıdır.
- *AUC (area under curve)*: ROC eğrisinin altındaki alandır. Bu değer arttıkça model başarısı artar.

Orange tarafından yapılan ölçümlerde AUC, CA, F1 skoru, kesinlik, DP oranı ve hata oranı verilmektedir. Çalışmada gerçekleştirilen uygulamada benzer araştırmalarda yaygın olarak kullanılan tüm modelin toplam doğru tahmin etme oranını gösteren CA ve destekleyici şekilde AUC başarı ölçütleri model performanslarını karşılaştırmak için kullanılmıştır.

5.BÖLÜM

BULGULAR

5.1. AYRILMA NİYETİNE ETKİ EDEN FAKTÖRLER

Pandemi öncesi ve sonrası ayrılma nedenlerindeki değişimin karşılaştırılması amacıyla yaklaşım 1 (tüm ayrılan çalışanlar) örneklem 1 ve 2 ile yaklaşım 4 (pandemi sonrası kritik çalışanlar) örneklem 6 için SPSS istatistik programından yararlanılarak ikili lojistik regresyon analizi gerçekleştirilmiştir. LR analizinde özniteliklerin işten ayrılmama yani 1. sınıfta olma ihtimali üzerine etkisi araştırılmıştır. İkili lojistik regresyon model uyumluluğu ile ilgili ölçümler her iki dönem için Tablo 13'te gösterilmektedir. Bu sonuçlara ait SPSS programı ekran görüntüleri örneklem 1 özelinde Ek 3'te (Tablo A.1., Tablo A.2. ve Tablo A.3) verilmiştir.

Model uyumluluk test sonuçları	2017-2019 (N=598)	2020-2023 (N=2090)	2020-2023
			Yüksek performanslı çalışan (N=270)
Nagelkerke R kare	0,32	0,11	0,38
Hosmer ve Lemeshow p değeri	0,49	0,68	0,22
Model Doğruluk Ölçütü	0,71	0,62	0,70

Tablo 13. SPSS istatistik programı ikili lojistik regresyon model ölçüm değerleri

- Nagelkerke R kare test sonucuna göre bağımsız değişkenler hedef değişkeni açıklayabilmektedir. Ancak, pandemi öncesi dönemde değerler daha yüksek olması, pandemi sonrası döneme göre özniteliklerin ayrılma durumunu çok daha iyi açıklayabildiğini göstermiştir. Pandemi sonrası öznitelikler ile ayrılma niyeti arasındaki ilişki zayıflamıştır. Bunun nedeni, pandemide meydana gelen değişimlerle mevcut özniteliklerin ayrılma niyetini açıklamada yetersiz kalmaya başladığı şeklinde yorumlanabilir. Şirket tarafından gerçekleştirilen ayrılış anketleri ve memnuniyet anketi sonuçları da bu bulguyu desteklemektedir. Bu anketlerde en yüksek etkiye sahip olarak çıkan öznitelik, gizlilik nedeniyle modele dahil edilememiştir.

- Hosmer and Lemeshow p değerinin tüm dönemler için 0,05'ten büyük olması ikili lojistik regresyon yönteminin veriye uygun bir modelleme yöntemi olduğunu ve sonuçların değerlendirmeye alınabileceğini göstermektedir.
- Model doğruluk ölçütü ise ikili lojistik regresyonun pandemi öncesi dönemde, pandemi sonrası dönemden daha başarılı tahminleme yapabildiğini göstermektedir.

Benzer şekilde, kritik çalışanların ayrılma nedenlerinin incelenmesinde tüm göstergeler ikili lojistik regresyon modelinin uygulanabilirliğini kanıtlamaktadır.

Ayrılma niyeti nedenlerini verilen öznitelikler üzerinden açıklamak için yapılan LR analiz sonuçları, her iki dönem ve pandemi sonrası kritik çalışanlar için Tablo 14'te özniteliklerin anlamlılık durumları ile özetlenmiştir. Bu analiz için örneklem 1 özelinde ekran görüntüleri Ek 3'te (Tablo A.4.) gösterilmiştir.

İkili lojistik regresyon sonuçlarına göre pandemi öncesi ve sonrası dönemde dikkat çeken bulgular şu şekildedir:

- Genel olarak bakıldığında, şirketteki deneyim süresi pandemi öncesi ayrılmama kararında etkili iken; iş grubu, yerleşke ve bölüm pandemi sonrası dönemde alınan ayrılmama kararlarında etkili hale gelmiştir. Bunun yanında eğitim ve son performans tüm dönemler için karara etki ederken, cinsiyet, yaş ve çocuk sayısı gibi demografik bilgiler her iki dönemde de ayrılmama kararında etkili değildir.
- Performansı yüksek çalışanlar için diğer çalışanlardan farklı olarak pandemi sonrası dönemde, deneyim süresi ayrılmama kararında etkiliyken, bölüm etkisi olan bir öznitelik olmamaktadır.

Bu bilgiler ışığında özniteliklerin ne yönde ayrılmama kararına etki ettiğine dair bulgular şu şekildedir:

- Şirketteki deneyim süresi arttıkça pandemi öncesi dönemde ayrılmama ihtimali artmaktadır, ancak pandemi sonrası dönemde ayrılmama kararında etkisi olmamaktadır.

Öznitelikler/ Değişkenler	Ayrılmama kararını açıklayıcılık (etki yönü)		
	2017-2019 (N=598)	2020-2023 (N=2090)	2020-2023 Yüksek performanslı çalışan (N=270)
Şirketteki deneyim süresi	0,00* (+)	0,13 (+)	0,04* (+)
Cinsiyet = 1	0,32 (-)	0,79 (-)	0,26 (+)
Yaş	0,60 (+)	0,73 (-)	0,06 (-)
Çocuk sayısı	0,15 (-)	0,11 (+)	0,15 (+)
Eğitim	0,00* (-)	0,00* (-)	0,20 (+)
Ana İş Grubu	0,83 (-)	0,00* (+: 5, 6, 8, 9, 10) (-: 1-4, 7)	0,01* (+: 4,6,7,8, 9) (-: 1, 2, 3, 5)
Yerleşke	0,30 (+: 2, 3) (-: 1, 4)	0,00* (+)	0,03* (+)
Bölüm	0,51 (-)	0,00* (+: 3, 6) (-: 2, 4, 5)	0,22 (-: 3) (+: kalanlar)
Son performans puanı	0,00* (+)	0,00*(+)	veride yok

Tablo 14. İkili lojistik regresyon değişken tablosu

* Modelde işten ayrılmayan grubunda yer alma ihtimalini açıklayıcı olan ($p < 0.05$) değişkenlerdir.

- Eğitim seviyesi arttıkça pandemi öncesi ve sonrası çalışanın ayrılmama ihtimali de artmaktadır.
- İş grubu, pandemi sonrası dönemde çalışanın ayrılmama kararında etkili olmaya başlamıştır. Özellikle dış piyasada iş bulma imkânı diğer gruplara göre daha az olan iş grubu 6, 8, 9 ve 10'da çalışıyor olmak, çalışanların ayrılmama ihtimalini arttıran bir faktöre dönüşmüştür.
- Merkeze daha yakın yerleşkede çalışmak pandemi sonrasında ayrılmama ihtimalini arttırmaktadır.

- Pandemi sonrasında şirketin en kalabalık bölümleri olan bölüm 3 ve 6'da çalışmak ayrılmama durumunu olumlu etkilemektedir.
- Her iki dönem için de performans puanı iyileştikçe çalışanın ayrılmama ihtimali artmaktadır.

	1	2	6
	2017-2019 (N=598)	2020-2023 (N=2090)	2020-2023 (-1 öznitelik)
	AUC	AUC	AUC
LR	Son Performans Puanı Şirketteki Deneyim Süresi Eğitim Durumu ----- Yaş Çocuk Sayısı Ana İş Grubu	Yerleşke Bölüm Eğitim Durumu ----- Cinsiyet Çocuk Sayısı Şirkette Deneyim Süresi	Yerleşke Ana İş Grubu Yaş ----- Cinsiyet Çocuk Sayısı Eğitim Durumu
DT	Şirketteki Deneyim Süresi Yaş Eğitim Durumu ----- Cinsiyet Yerleşke Bölüm	Şirketteki Deneyim Süresi Yaş Eğitim Durumu ----- Son Performans Puanı Yerleşke Çocuk Sayısı	Yerleşke Ana İş Grubu Şirketteki Deneyim Süresi ----- Cinsiyet Çocuk Sayısı Eğitim Durumu
SVM	Şirketteki Deneyim Süresi Yaş Eğitim Durumu ----- Yerleşke Yaş Bölüm	Yerleşke Eğitim Durumu Şirketteki Deneyim Süresi ----- Yaş Cinsiyet Çocuk Sayısı	Ana İş Grubu Yerleşke Eğitim Durumu ----- Yaş Şirketteki Deneyim Süresi Çocuk Sayısı
KNN	Eğitim Durumu Son Performans Puanı Şirketteki Deneyim Süresi ----- Ana İş Grubu Yerleşke Çocuk Sayısı	Yaş Şirketteki Deneyim Süresi Eğitim Durumu ----- Yerleşke Son Performans Puanı Bölüm	Şirketteki Deneyim Süresi Yaş Yerleşke ----- Eğitim Durumu Çocuk Sayısı Bölüm
RF	Şirketteki Deneyim Süresi Son Performans Puanı Eğitim Durumu ----- Ana İş Grubu Yerleşke Bölüm	Eğitim Durumu Şirketteki Deneyim Süresi Yaş ----- Cinsiyet Son Performans Puanı Ana İş Grubu	Yerleşke Ana İş Grubu Bölüm ----- Cinsiyet Çocuk Sayısı Yaş

Tablo 15. Öznitelik etkileri

Bunlara ek olarak, ayrılma niyeti tahminleme modellerinde bir sonraki bölümde verilen model hiperparametrelerine göre özniteliklerin modele etkileri AUC değerleri üzerinden incelenmiştir. Modele etkisi en büyük ve en düşük olan ilk üç öznitelik Tablo 15'te verilmiştir. Tablo 14'te açıklayıcı ve açıklayıcı olmayan değişkenler ile Tablo 15'te çıkan etkili ve etkisiz öznitelikler benzer çıkmıştır. Örneklem 1'e ait etki analizlerinin SPSS analizlerine yönelik ekran görüntüleri çalışmada Ek 3'te (Tablo A.4.) sunulmuştur.

Özetle, bu analizde pandemi döneminin çalışan ayrılma nedenlerinde değişimlere sebep olduğu gözlemlenebilmiştir. Pandemi öncesinde şirketteki deneyim süresi çalışanların işten ayrılma kararlarında etkiliyken pandemi sonrasında çalışılan ana iş grubu, organizasyon bölümü ve yerleşke gibi organizasyonel faktörler ön plana çıkmaya başlamıştır. Pandemiyle birlikte gelen ve yukarıda da aktarılan iş piyasasında mobilitenin artması ve uzaktan çalışma imkanının belirtilen şirkette olmaması gibi etkenlerin çalışanların daha çok organizasyon ve iş odaklı düşünerek kararlar almalarında etkili olabileceği değerlendirilebilir. Bu sonuçlar ışığında, yöneticilerin pandemi sonrası dönemde şirket içerisinde iş grupları arasında rotasyonu teşvik etmeleri, çalışanların organizasyonel olarak iş grubu, bölüm ve yerleşkelerinde değişiklik yapmalarını sağlayarak işten ayrılma niyetlerinin önüne geçebileceği öngörülebilir.

5.2. AYRILMA NİYETİNİN TAHMİNLENMESİ

Ayrılma niyeti tahminlemesinde *Orange* programından yararlanılmıştır. Öncelikle, verilerden yaklaşımlarda belirtildiği şekilde örneklem alınmış, bu örneklemelerin yüzde 80'i öğrenme verisi yüzde 20'si de test verisi olarak rastgele ayrıştırılmıştır.

Test verilerinde çıkan, CA ve AUC başarı göstergelerine göre model hiperparametreleri, yaklaşımlar özelinde Tablo 16'da gösterildiği şekilde ayarlanmıştır. Bu sonuçların Örneklem 1 özelinde görülebildiği *Orange* sonuçlarına ait ekran görüntüleri, bu bölümde anlatılan diğer analiz sonuçları örnek teşkil edecek şekilde Ek 3'te (Tablo A.5., Tablo A.6., Tablo A.7., Şekil A.1., Şekil A.2., Şekil A.3.) sunulmuştur.

Tablo 11'de numaralandırılan altı farklı örneklem için elde edilen CA ve AUC performans ölçütleri yukarıdaki hiperparametre ayarlarından sonra aşağıda Tablo 17'de gösterildiği gibi olmuştur.

Hiperparametre	Orijinal Parametre	Yaklaşım-1-2	Yaklaşım-1	Yaklaşım-2	Yaklaşım-3	Yaklaşım-3
		(1)	(2)	(3)	(4)	(5)
		2017-2019 (N=598)	2020-2023 (N=2090)	2020-2023 (N=598)	2017-2019 (N=400)	2020-2023 (N=1600)
SVM-C	1,10	1,10	1,20	1,10	1,20	1,20
SVM-Epsilon (ϵ)	0,10	0,10	0,30	0,10	0,10	0,10
RF-Ağaç sayısı	10	10	10	10	10	11
RF-Her kırılımdaki öznelik sayısı	5	8	5	5	6	5
RF-Kırılımdaki minimum alt küme sayısı	5	5	5	5	5	5
DT-Yapraktaki minimum öznelik sayısı	6	2	5	6	2	6
DT- Kırılımdaki minimum alt küme sayısı	5	8	5	5	5	5
kNN-K	6	8	7	6	5	11

Tablo 16. Orange ayrılış tahminleme modeli hiperparametre ayarları

	1		2		3		4		5		6	
	2017-2019 (N=598)		2020-2023 (N=2090)		2020-2023 (N=598)		2017-2019 (N=400)		2020-2023 (N=1600)		2020-2023 (-1 öznitelik) (N=270)	
	AUC	CA	AUC	CA	AUC	CA	AUC	CA	AUC	CA	AUC	CA
LR	0,75	0,70	0,58	0,53	0,58	0,61	0,76	0,69	0,65	0,60	0,74	0,65
DT	0,69	0,69	0,55	0,53	0,58	0,56	0,67	0,64	0,66	0,62	0,71	0,56
SVM	0,68	0,66	0,48	0,46	0,44	0,53	0,74	0,69	0,49	0,53	0,69	0,67
KNN	0,76	0,72	0,56	0,55	0,58	0,58	0,68	0,65	0,61	0,59	0,66	0,59
RF	0,78	0,71	0,57	0,55	0,58	0,55	0,86	0,75	0,67	0,64	0,64	0,61

Tablo 17. Model test başarı göstergeleri

Tablo 17 incelendiğinde:

- Örneklem 1 ve 4, örneklem 3 ve 5, örneklem 2 ve 3, örneklem 2 ve 5 karşılaştırıldığında, veri sayısına bağlı olarak tahmin başarısının hiçbir modelde tüm karşılaştırmalar için aynı değişimi göstermediği görülmüştür. Ancak, bu dört karşılaştırmada, örneklem büyüklüğü azaldıkça genel olarak rassal orman modelinin başarısının arttığı söylenebilir.
- Yaklaşım 2 (örneklem 1 ve 3)'de farklı dönemler için model test başarıları örneklem sayıları aynı olsa da farklılaşmaktadır. Pandemi sonrası dönemde model başarıları düşmüştür. Bu da dönemsel etkilerin ve farklı özniteliklerin nedensellik kazanmasının model tahmin başarısında etki edebileceği şeklinde yorumlanabilir.
- Pandemi öncesi dönemde test tahmin başarıları pandemi sonrası dönemden Yaklaşım 4 (örneklem 6) dışında daha iyi olmuştur. Bu bulgu bir önceki bölümde özniteliklerin modeli açıklamada pandemi sonrası dönemde daha zayıf olması sonucuyla örtüşmektedir.
- Yaklaşım 4 (örneklem 6)'te öznitelik ve örneklem sayısı azaldığında genel olarak pandemi sonrası diğer örneklemelere göre modellerin test başarıları yükselmiştir.

Yaklaşımların modeller özelinde başarılarının karşılaştırılmasında aşağıdaki Tablo 18'de yer alan tahmin başarı göstergelerinden de yararlanılmıştır. Bu tahminler yapılırken tutarlılık olması için Tablo 16'da yer alan hiperparametre değerleri kullanılmıştır.

Tablo 18 incelendiğinde:

- Yaklaşım 1 (örneklem 1 ve 2) ve yaklaşım 4 (örneklem 6)'da tek bir sınıf üzerinden tahmin yürütülürken diğer örneklemelerde her iki sınıfın da yer aldığı veriler üzerinden tahminleme yapılmaktadır. Bu nedenle bu yaklaşımlarda AUC değeri bulunmamaktadır. Yaklaşım 1'de en geçerli model KNN olurken; daha az verinin tahminlendiği yaklaşım 4'te SVM en başarılı model olmaktadır.

- Yaklaşım 1 (örneklem 1 ve 2) ve yaklaşım 2 (örneklem 1 ve 3) karşılaştırıldığında, tahmin verisi arttığında her iki sınıf eklendiği durumda (örneklem 3) SVM modelinin başarısının oldukça arttığı gözlemlenmektedir. Yaklaşım 3 (örneklem 5) ile yaklaşım 2 (örneklem 3) karşılaştırıldığında ise her iki tahmin verisinde iki ayrı grup olsa SVM değeri tahmin verisi az olan yaklaşım 2 (örneklem 3)'te, yaklaşım 1 (örneklem 2)'ye benzer şekilde en düşük tahmin başarısını göstermektedir.

	1	2	3	4	5	6
	2017-2019 (N=598) (T=3629)	2020-2023 (N=2090) (T=3989)	2020-2023 (N=598) (T=5481)	2017-2019 (N=400) (T=3827)	2020-2023 (N=1600) (T=4479)	2020-2023 (-1 öznitelik) (T=718)
	CA	CA	AUC	CA	AUC	CA
LR	0,70	0,54	0,58	0,58	0,66	0,69
DT	0,61	0,52	0,53	0,59	0,63	0,61
SVM	0,59	0,35	0,54	0,54	0,61	0,61
KNN	0,72	0,64	0,51	0,47	0,63	0,74
RF	0,70	0,58	0,56	0,53	0,69	0,67

Tablo 18. Model tahmin başarı ölçütleri

- Tüm modellerde, doğruluğu en yüksek tahminleme her iki sınıfın da tahminde yer aldığı ve özniteliklerin modeli daha iyi açıkladığı pandemi öncesi döneme ait örneklem 4 ile sağlanmıştır. Tablo 18'de en yüksek tahmin başarısı SVM modeliyle tahminlenen örneklem 4'te olmaktadır. Örneklem 1 ile hemen hemen benzer sayıda öğrenme ve tahmin verisine sahip olmasına rağmen, iki grup üzerinden tahminleme yapılması CA değerini arttırmıştır.
- SVM modelinin doğruluğunun değişken ve özellik sayısı azaldığında arttığı gözlemlenmektedir.
- Test model başarılarında olduğu gibi pandemi sonrası tahmin başarılarının da genel olarak pandemi öncesi dönemden daha iyi olduğu görülmüştür.

5.3. GENEL BULGULAR

İlk olarak, işten ayrılma niyetine etki eden nedenlerin analizine bakıldığında, yapılan ikili lojistik regresyon analizinde pandemi öncesi ve pandemi sonrası dönemde çalışanların ayrılma niyetine etki eden faktörlerde farklılaşmalar olduğu görülmüştür. Model test ölçütlerine bakıldığında, pandemi sonrası dönemde aynı özniteliklerin ayrılma nedenini pandemi öncesi döneme göre daha az açıklayabildikleri ortaya çıkmıştır. Pandemi sonrasında modele dahil edilmemiş daha farklı öznitelikler işten ayrılma niyetinde etkili hale gelmiş olabilir. Bu nedenle, araştırmada daha fazla öznitelik kullanarak özniteliklerin modeli açıklayıcılığına bakılması nedenler üzerine politikalar geliştirilmesinde daha da etkili olabilir.

Çalışanın ayrılmama ihtimaline etki eden özniteliklere bakıldığında *Orange* ve *SPSS* programlarından alınan sonuçların tutarlı olduğu görülmüştür. Şirketteki deneyim süresi pandemi öncesinde ayrılmama kararında etkili iken; iş grubu, yerleşke ve bölüm gibi organizasyonel öznitelikler pandemi sonrası dönemde ayrılmama ihtimalinde etkin hale gelmiştir. Bunun yanında eğitim ve son performans puanı tüm dönemler için karara etki etmekte ancak, cinsiyet, yaş ve çocuk sayısı gibi demografik bilgiler her iki dönemde de ayrılmama ihtimalinde etkili değildir.

Pandemi döneminin çalışma hayatına ve çalışanlara etkisi üzerine yapılan araştırmalarda önceki bölümlerde aktarıldığı gibi yetenek kazanımı savaşları sebebiyle çalışanlar daha çok yöneticileriyle ilişkileri, yaptıkları iş ve mobilite imkanları gibi faktörlere odaklanmaya başlamıştır. Bu çalışmada çıkan sonuçlar da diğer araştırmalarda belirtilen durumu destekleyecek yönde olmuştur. Bu bulgular ışığında pandemi sonrası dönemde şirket içi rotasyonun artırılmasının işten ayrılma niyetini engelleyebilecek bir politika olabileceği değerlendirilebilir.

İşten ayrılma niyetini tahminleme analizlerinde ise yaklaşık yüzde 50 ve yüzde 80 aralığında modeller ve örneklemeler arasında değişkenlik gösteren bir tahminleme başarısı elde edilmiştir. Test başarısı ve tahminleme başarısı arasında çok büyük farklılıklar olmadığı için fazla tahminleme ya da az tahminleme durumları oluşmadığı değerlendirilmiştir. Buna ek olarak, pandemi öncesi dönemde modellerin tahmin başarılarının pandemi sonrası döneme göre genel olarak daha iyi olduğu söylenebilir. Bu da işten ayrılma neden analizinde ortaya çıkan durum ile uyumludur.

Benzer şekilde birden çok model üzerinde yapılan ve önceki bölümlerde aktarılan arařtırmalarda bu çalışmadan daha yüksek model başarılarına ulařılabildiđi görölmüş ancak herhangi bir modelin her koşulda ve veride daha iyi tahmin yapabildiđine dair bir bulguya rastlanmamıştır. Bu uygulamada da yapılan modelleme çalışmasıyla, en iyi tahminleme başarısını gösteren modelin yöntem, örneklem sayısı, dönemsel faktörler, öznitelik sayısı, vb. birçok etkene göre farklılıklar gösterdiđi ve bu konuda net çıkarımlar yapılamadıđı, her durum özelinde farklı bir modelin tercih edilmesinin uygun olacađı görölmüştür. Bunun yanında, diđer arařtırmalarda yer almayan ancak bu çalışmada incelenen bir konu olarak, büyük deđişimler getiren dönemlere ait modellerin dönemler özelinde ayrı olarak ele alınmasının modelin tahmin başarısını etkileyebildiđi gözlemlenmiştir.

Özetle, bu çalışmada, diđer benzer arařtırmalardan farklı olarak işten ayrılma analizleri pandemi dönemindeki deđişiklikleri de göz önüne alarak yapılmıştır. Çalışmada hem nedenlerin arařtırılması hem de ayrılma durumlarının tahmin edilmesi için iki ayrı analiz gerçekleştirilmiştir. Tüm bunların sonucunda ise pandeminin gerçekten işten ayrılma nedenlerinde ve ayrılma niyetlerinin tahminleme başarısında farklılıklara yol açtıđı gözlemlenmiştir. Bunun yanında, yapılan analizlerde yine diđer birçok çalışmadan farklı olarak sentetik veriler deđil gerçek İK çalışan verileri kullanılmış, hatta çalışan ayrılma niyetinin tahminlenmesi için farklı hazır bilgisayar programları kullanılarak İK uzmanları için örnek bir çalışma sunulmuştur. Bu çalışmanın daha ileriye taşınabilmesi için model tahminlerinin arttırılması, daha farklı çalışan özniteliđinin modele eklenmesi ve makinenin öğrenmesinin dönemsel dinamikleri de göz önüne alarak yeni verilerle modellerin periyodik olarak yenilenmesi önerilmektedir.

SONUÇ

Özellikle günümüzde pandemi dönemiyle birlikte gelen uzaktan çalışma ve farklı iş modelleriyle, rekabet halinde olan iş piyasasında çalışan ayrılmaları örgütlerde maddi ve manevi kayıplara neden olmaktadır. Örgütler çalışanlara yaptıkları yatırımları ve bu çalışanlara göre yapmış oldukları sermaye planlamalarını, çalışanların işten ayrılmalarıyla birlikte kaybetmekte ve yeni alınan çalışanların maliyetleri de bu maliyetlere eklenmektedir. Bu gerekçelerle, işten ayrılmalar örgütlerin uzun zamandır birçok farklı alandan bakış açısıyla incelediği ve çözüm ya da önlem arayışına girdiği bir konu haline gelmiştir.

Bu çalışmada, çalışanların kendileriyle ilgili demografik, sosyal ve performans bilgileri hem ayrılma nedeni olarak hem de ayrılma niyetini tahmin edebilecek bir model oluşturabilmek için analiz edilmiştir. Bu konudaki araştırmalar incelendiğinde, neredeyse tüm çalışmaların çoğunlukla mühendislik alanlarında çalışan uzmanlar tarafından sentetik veriler kullanılarak ve bilgisayarda programlama yapılarak tek bir dönem üzerinde ele alındığı görülmüştür. Bu çalışmada ise bu çalışmalardan farklı olarak Türkiye’de savunma sektöründe faaliyet gösteren bir şirketin gerçek insan kaynakları verileri kullanılmış, pandemi öncesi ve pandemi sonrası dönem için analizler ayrıştırılarak karşılaştırılmış ve SPSS ile *Orange* bilgisayar programlarından yararlanılmıştır.

Çalışan verilerine bakıldığında, betimsel analizler pandemi sonrasında çalışan ayrılışlarının artış eğiliminde olduğunu göstermiştir. Bunu telafi etmek için yapılan işe alımların sayısı da benzer şekilde artmıştır. Şirkete yeni girmiş 0-4 yıl deneyimli çalışanların pandemi sonrasında daha deneyimli çalışanlara göre daha fazla işten ayrıldığı görülmüştür. Bunun yanında betimsel analizlerde, ayrılan çalışanların daha çok 28-32 ve 33-37 yaş arasındaki çalışanlar olduğu, ancak bir yandan çocuk sayısı arttıkça ayrılışların azaldığı görülmüştür. Eğitim olarak yüksek lisans mezunu çalışanların ayrılış yüzdesinin daha fazla olduğu ve pandemi sonrasında düşük performanslı çalışanların ayrılışlardaki oranının azaldığı gözlemlenmiştir.

Çalışmanın sınırlılıkları, ayrılış analizlerinde sıklıkla öznitelik olarak kullanılan özellikle, ücret, prim, terfi, ünvan gibi birçok özneliğin bu verilerle ilgili kayıt tutulmamış olması,

İK sistemlerinde ve şirket yapısında yapılan değişikliklerin verilerde tutarsızlık yaratabilmesi ve özellikle de şirketin gizlilik politikası paylaşılmaması sebebiyle veri setine öznitelik olarak eklenememiş olması; benzer şekilde şirket tarafından yapılan ayrılış anketi ve çalışan memnuniyet anketlerinin sonuçlarının gizlilik nedeniyle çalışmada yer alamamasıdır.

Çalışmada, 2017-2023 yıllarını kapsayan toplam 6378 çalışan verisi kullanılmıştır. Bu veriler, öncelikle kullanılabilir veriler ve analizde yer alması gereken öznitelikler ve çalışanlar özelinde ayıklanmıştır. Ardından, pandemi öncesi dönem (2017-2019) ve pandemi sonrası dönem (2020-2023) için çalışanlar ilgili dönemdeki durumlarına göre işten ayrılmış ve ayrılmamış çalışan olarak sınıflandırılmıştır. Bu şekilde, iki ayrı dönem için iki ayrı sınıfı ve 9 özniteliği (şirketteki deneyim süresi, cinsiyet, yaş, çocuk sayısı, eğitim durumu, ana iş grubu, yerleşke, bölüm, son performans puanı) içeren iki ayrı popülasyon verisi oluşturulmuştur.

Analizler yapılırken temelde dört farklı yaklaşıma göre farklı büyüklükte örneklemeler oluşturulmuştur. Denetimli makine öğrenmesi sınıflandırma yöntemlerinden ikili lojistik regresyon, k en yakın komşuluk algoritması, destek vektör makinesi, karar ağacı ve rassal orman yöntemleri ile hem pandemi öncesi hem pandemi sonrası, her iki dönem için de ayrılma niyetlerine yönelik analizler gerçekleştirilmiştir.

İlk olarak gerçekleştirilen çalışan ayrılmalarında özniteliklerin neden analizinde, ikili lojistik regresyon yöntemi kullanılmıştır. Burada test sonuçlarına bakıldığında, pandemi öncesi dönemde özniteliklerin ayrılma niyetini pandemi sonrası döneme göre daha iyi açıklayabildiği sonucu çıkmıştır. Bu değişimde, bu alanda yapılan ve çalışmada da aktarılan araştırmaları destekleyecek şekilde, özellikle mühendislik alanında artan iş imkanlarının, insan odaklı eğilimlerin ve veride gizlilik nedeniyle yer özniteliklerin etkisinin olduğu değerlendirilmektedir. Ayrılma niyetine etki eden faktörler incelendiğinde ise pandemi öncesi ve sonrası dönemde özniteliklerin ayrılma kararını açıklamada farklılaştığı gözlemlenmiştir. Pandemi sonrası dönemde organizasyonel niteliklerin ayrılmama kararına etki ettiği görülmüştür. Öte yandan analizlerde, demografik verilerin her iki dönemde de ayrılma niyetinde etkin olmadığı, eğitim ve performans puanının ise dönemden bağımsız ayrılmalara her zaman etki ettiği yönünde sonuçlar çıkmıştır. Bu bulgunun, İK tarafından yapılan pandemi odaklı araştırmalarda da belirtildiği gibi

organizasyon sebepli imkanlar ve koşulların çalışanlar için ön plana çıkmasıyla uyumlu bir sonuç olduğu değerlendirilebilir. Bu sonuçlar ışığında yöneticilerin şirket içi rotasyonu özendirilen sistemler uygulamasının ayrılma niyetini engelleyici bir politika olabileceği de değerlendirilebilir.

Çalışmada gerçekleştirilen diğer analizlerde, yukarıda belirtilen makine öğrenmesi yöntemleri kullanılarak bir çalışanın belli özniteliklerine göre işten ayrılma ihtimalinin tahmin edilmesi yönünde modelleme çalışması gerçekleştirilmiştir. Bu uygulamada da öncelikle model hiperparametreleri her yaklaşım yani örneklem için model performans ölçütünü en yüksek hale getirecek şekilde ayarlanmıştır. Ardından, bu hiperparametre değerleri hem tahminleme hem etki analizlerinde kullanılmış ve model test ve tahmin başarıları incelenirken ve karşılaştırılırken CA ve AUC değerlerine bakılmıştır. Sonuçlara bakıldığında genel olarak yaklaşık yüzde 50 ile yüzde 80 arasında tahmin başarıları elde edilmiştir. Bulunan model başarıları benzer konuda gerçekleştirilen benzer diğer çalışmalarda bulunan başarı ölçütlerinden daha düşüktür ancak, bu çalışmada sınırlılıklar nedeniyle az sayıda öznitelik kullanılabilmiş, dönemsel farklılıklar göz önüne alınarak gerçek İK verileri üzerinden analizler gerçekleştirilmiştir. Bir diğer vurgulanması gereken ve bu araştırmalarla örtüşen temel bulgu ise model performanslarının kullanılan veri, örneklem büyüklüğü, öznitelik sayısı, dönemsel etkenler dahil tüm etmenlere göre her defasında farklılık gösterebildiğidir. Bu çalışmalarda herhangi bir model için her zaman en başarılı model olacağı çıkarımı yapılamamakta ve bu nedenle tahminleme modeli oluştururken yeni verilerle ve özniteliklerle modellemenin sürekli olarak yapılmasının daha doğru tahminler yapılmasını sağlayabileceği söylenebilir.

Sonuç olarak, bu çalışmada gerçek veriler kullanılarak pandeminin ayrılma niyetine etkileri veri analitiği yöntemleriyle açıklanmış ve ayrılma niyeti tahminlemesi için pandemi dönemini de içerecek şekilde bu alandaki diğer uygulamalardan farklı örnek bir uygulama gerçekleştirilmiştir. Aktarılan uygulama yöntemleri ile özellikle İK alanında çalışan birçok uzman, daha çok çalışan özneliğini içerecek benzer araştırmaları bilgisayar programlarını kullanarak yapabilir. Bu analiz ve tahmin çalışmaları ile örgütlerdeki kritik çalışanların işten ayrılma ihtimalleri önceden tahmin edilebilecek ve neden analizlerinden yola çıkarak geliştirilen insan kaynakları politikaları ile işten ayrılma maliyetleri azaltılabilecektir.

KAYNAKÇA

- Abiad, M., & Ionescu, S. (2020). Customer churn analysis using binary logistic regression model. *BAU Journal-Science and Technology*, 1(2), 7.
- Acar, O. K., Efe M. H., & Çelik, İ. (2017). İnsan Kaynakları Yönetiminde Yetenek Yönetimi ve İşgücü Devir Hızı İlişkisi: Isparta Örneği. *Yeni Fikir Dergisi*, 9(18), 20-32.
- Akduman, G., Erdoğan, O., & Yüksekbilgili, Z. (2013). Ciro ve Personel Devir Hızı İlişkisi. *Elektronik Sosyal Bilimler Dergisi*, 12(47), 203-211.
- Akyel, N., & Seçkin, K. (2012). K-En Yakın Komşuluk Algoritmasının Hile Denetiminde Kullanımı. *Journal of Accounting and Taxation Studies*, 5(1), 21-40.
- Al Akasheh, M., Malik, E. F., Hujran, O., & Zaki, N. (2023). A Decade of Research on Data Mining Techniques for Predicting Employee Turnover: A Systematic Literature Review. *Expert Systems with Applications*, 121794.
- Alamsyah, A., & Salma, N. (2018, August). A comparative study of employee churn prediction model. In 2018 4th international conference on science and technology (ICST) (pp. 1-4). IEEE.
- Alanlı, A. (2022). İnsan Kaynakları Yönetiminin Tarihsel Gelişimi. *Süleyman Demirel Üniversitesi İnsan Kaynakları Yönetimi Dergisi*, 1(1), 53-72.
- Al-Darraj, S., Honi, D. G., Fallucchi, F., Abdulsada, A. I., Giuliano, R., & Abdulmalik, H. A. (2021). Employee attrition prediction using deep neural networks. *Computers*, 10(11), 141.
- Alduayj, S. S., & Rajpoot, K. (2018, November). Predicting employee attrition using machine learning. In 2018 international conference on innovations in information technology (iit) (pp. 93-98). IEEE.

- Alhashmi, S. M. (2019, November). Towards understanding employee attrition using a decision tree approach. In 2019 International Conference on Digitization (ICD) (pp. 44-47). IEEE.
- Alpaydin, E. (2020). Introduction to machine learning. MIT press.13.
- Alsheref, F. K., Fattoh, I. E., & M. Ead, W. (2022). Automated prediction of employee attrition using ensemble model based on machine learning algorithms. *Computational Intelligence and Neuroscience*, 2022(1), 7728668.
- Alshiddy, M. S., & Aljaber, B. N. (2023). Employee Attrition Prediction using Nested Ensemble Learning Techniques. *International Journal of Advanced Computer Science and Applications*, 14(7).
- Atef, M., S Elzanfaly, D., & Ouf, S. (2022). Early prediction of employee turnover using machine learning algorithms. *International journal of electrical and computer engineering systems*, 13(2), 135-144.
- Avrahami, D., Pessach, D., Singer, G., & Chalutz Ben-Gal, H. (2022). A human resources analytics and machine-learning examination of turnover: implications for theory and practice. *International Journal of Manpower*, 43(6), 1405-1424.
- Ayodele, O. A., Chang-Richards, A., & González, V. (2020). Factors affecting workforce turnover in the construction sector: A systematic review. *Journal of construction engineering and management*, 146(2), 03119010.
- Bahadır, M. B., Bayrak, A. T., Ergun, P., & Yüçetürk, G. (2021). Kayıp Çalışan Tahminleme Yöntemlerinin Karşılaştırılması A Comparative Study for Employee Churn Prediction.
- Bao, L., Xing, Z., Xia, X., Lo, D., & Li, S. (2017, May). Who will leave the company?: a large-scale industry study of developer turnover by mining monthly work report. In

2017 IEEE/ACM 14th International Conference on Mining Software Repositories (MSR) (pp. 170-181). IEEE.

Berhil, S., Benlahmar, H., & Labani, N. (2020). A review paper on artificial intelligence at the service of human resources management. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(1), 32-40.

Bhartiya, N., Jannu, S., Shukla, P., & Chapaneri, R. (2019, March). Employee attrition prediction using classification models. In *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)* (pp. 1-6). IEEE.

Bolt, E. E. T., Winterton, J., & Cafferkey, K. (2022). A century of labour turnover research: A systematic literature review. *International Journal of Management Reviews*, 24(4), 555-576.

Çağlar, A. (2018). İş güçlüğü'nün işten ayrılma niyetine etkisi üzerine bir araştırma: Ankaradaki dört ve beş yıldızlı oteller örneği (Master's thesis, Sosyal Bilimler Enstitüsü).

Cai, X., Shang, J., Jin, Z., Liu, F., Qiang, B., Xie, W., & Zhao, L. (2020). DBGE: employee turnover prediction based on dynamic bipartite graph embedding. *IEEE Access*, 8, 10390-10402.

Chowdhury, S., Joel-Edgar, S., Dey, P. K., Bhattacharya, S., & Kharlamov, A. (2023). Embedding transparency in artificial intelligence machine learning models: managerial implications on predicting and explaining employee turnover. *The International Journal of Human Resource Management*, 34(14), 2732-2764.

Chung, D., Yun, J., Lee, J., & Jeon, Y. (2023). Predictive model of employee attrition based on stacking ensemble learning. *Expert Systems with Applications*, 215, 119364.

- Cohen, G., Blake, R. S., & Goodman, D. (2016). Does turnover intention matter? Evaluating the usefulness of turnover intention rate as a predictor of actual turnover rate. *Review of Public Personnel Administration*, 36(3), 240-263.
- Dayal, G., & Verma, P. (2021). Employee Satisfaction And Organization Commitment: Factors Affecting Turnover Intentions And Organization Performance. *Ilkogretim Online*, 20(5).
- Deery, M. A., & Shaw, R. N. (1999). An investigation of the relationship between employee turnover and organizational culture. *Journal of hospitality & tourism research*, 23(4), 387-400.
- Deloitte 2021 Global İnsan Kaynakları Trendleri Raporu. (2021). Yıkıma uğramış bir dünyada sosyal şirket. <https://www2.deloitte.com/tr/tr/pages/human-capital/articles/2021-global-insan-kaynaklari-trendleri-raporu.html>
- Dolatabadi, S. H., & Keynia, F. (2017, July). Designing of customer and employee churn prediction model based on data mining method and neural predictor. In 2017 2nd international conference on computer and communication systems (ICCCS) (pp. 74-77). IEEE.
- El-Rayes, N., Fang, M., Smith, M., & Taylor, S. M. (2020). Predicting employee attrition using tree-based models. *International Journal of Organizational Analysis*, 28(6), 1273-1291.
- Eren, A., & Saraçoğlu, B. (2011). GÖNÜLLÜ İŞTEN AYRILMALAR ÜZERİNE EKONOMETRİK BİR YAKLAŞIM. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 26(1), 1-15.
- Falch, T., & Strøm, B. (2005). Teacher turnover and non-pecuniary factors. *Economics of Education Review*, 24(6), 611-631.

- Fallucchi, F., Coladangelo, M., Giuliano, R., & William De Luca, E. (2020). Predicting employee attrition using machine learning techniques. *Computers*, 9(4), 86.
- Fan, C. Y., Fan, P. S., Chan, T. Y., & Chang, S. H. (2012). Using hybrid data mining and machine learning clustering analysis to predict the turnover rate for technology professionals. *Expert Systems with Applications*, 39(10), 8844-8851.
- Farquad, M. A. H., Ravi, V., & Raju, S. B. (2014). Churn prediction using comprehensible support vector machine: An analytical CRM application. *Applied Soft Computing*, 19, 31-40.
- Frye, A., Boomhower, C., Smith, M., Vitovsky, L., & Fabricant, S. (2018). Employee attrition: what makes an employee quit?. *SMU Data Science Review*, 1(1), 9.
- Gazi, M. S., Nasiruddin, M., Dutta, S., Sikder, R., Huda, C. B., & Islam, M. Z. (2024). Employee Attrition Prediction in the USA: A Machine Learning Approach for HR Analytics and Talent Retention Strategies. *Journal of Business and Management Studies*, 6(3), 47-59.
- Greer, C. R. (2021). *Strategic human resource management*. Pearson Custom Publishing. (pp. 94-216)
- Hom, P. W., Allen, D. G., & Griffeth, R. W. (2019). *Employee retention and turnover: Why employees stay or leave*. Routledge
- İlhan, Ü. D. (2020). Covid-19 ile mücadelede insan kaynakları yönetimi uygulamalarında ihtiyaç duyulan aksiyonların belirlenmesine yönelik örgütsel müdahale yöntemi önerisi. *Gaziantep University Journal of Social Sciences*, 19(COVID-19 Special Issue), 288-307.
- İsmail, F. (2021). Impact of pandemic COVID-19 on human resources management. *Advances in Humanities and Contemporary Studies*, 2(1), 1-7.

- Jain, P. K., Jain, M., & Pamula, R. (2020). Explaining and predicting employees' attrition: a machine learning approach. *SN Applied Sciences*, 2(4), 757.
- Jain, R., & Nayyar, A. (2018, November). Predicting employee attrition using xgboost machine learning approach. In *2018 international conference on system modeling & advancement in research trends (smart)* (pp. 113-120). IEEE.
- Jeswani, S., & Dave, S. (2012). Impact of individual personality on turnover intention: A study on faculty members. *Management and Labour Studies*, 37(3), 253-265.
- Kaya İ.E., Korkmaz, O., (2021). Machine Learning Approach for Predicting Employee Attrition and Factors Leading to Attrition. *Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi*, 36(4), 913-928.
- KPMG Report. (Nisan 2020). Workforce, Work place and HR reshaping During Covid-19 Pandemic. <https://assets.kpmg.com/content/dam/kpmg/in/pdf/2020/04/workforce-worplace-and-hr-reshaping-during-19-pandemic.pdf>
- Krishna, S., & Sidharth, S. (2022, April). Analyzing employee attrition using machine learning: the new AI approach. In *2022 IEEE 7th International conference for Convergence in Technology (I2CT)* (pp. 1-14). IEEE.
- Kundu, S., & Nag, S. (2021). Employee engagement: Factors and recommendations for enhancing employee engagement during COVID-19 pandemic. *Journal of Strategic Human Resource Management*.
- Lambert, E. G., Hogan, N. L., & Barton, S. M. (2001). The impact of job satisfaction on turnover intent: a test of a structural measurement model using a national sample of workers. *The Social Science Journal*, 38(2), 233-250.

- Lazzari, M., Alvarez, J. M., & Ruggieri, S. (2022). Predicting and explaining employee turnover intention. *International Journal of Data Science and Analytics*, 14(3), 279-292.
- Lee, C. C., Huang, S. H., & Zhao, C. Y. (2012). A study on factors affecting turnover intention of hotel employees. *Asian Economic and Financial Review*, 2(7), 866.
- Lee, P. C., Xu, S. T., & Yang, W. (2021). Is career adaptability a double-edged sword? The impact of work social support and career adaptability on turnover intentions during the COVID-19 pandemic. *International Journal of Hospitality Management*, 94, 102875.
- Louak, M. (2021). *Employee Turnover Prediction with Machine Learning Algorithms* (Doctoral dissertation).
- Mozaffari, F., Rahimi, M., Yazdani, H., & Sohrabi, B. (2023). Employee attrition prediction in a pharmaceutical company using both machine learning approach and qualitative data. *Benchmarking: An International Journal*, 30(10), 4140-4173.
- Najafi-Zangeneh, S., Shams-Gharneh, N., Arjomandi-Nezhad, A., & Hashemkhani Zolfani, S. (2021). An improved machine learning-based employees attrition prediction framework with emphasis on feature selection. *Mathematics*, 9(11), 1226.
- Naz, K., Siddiqui, I. F., Koo, J., Khan, M. A., & Qureshi, N. M. F. (2022). Predictive modeling of employee churn analysis for IoT-enabled software industry. *Applied Sciences*, 12(20), 10495.
- Nilasari, B. M., Nisfiannoor, M., & Devinta, F. R. M. (2021). Changes in motivation that affect employee performance during the covid 19 pandemic. *Jurnal Aplikasi Manajemen*, 19(2), 435-447.

- Obedgiu, V. (2017). Human resource management, historical perspectives, evolution and professional development. *Journal of Management Development*, 36(8), 986-990.
- O'Connell, M., & Kung, M. C. (2007). The cost of employee turnover. *Industrial management*, 49(1).
- Ongori, H. (2007). A review of the literature on employee turnover.
- Özkanan, A. (2022). Pandemi Döneminde Temel İhtiyaçların Artan Önemi: Maslow'un İhtiyaçlar Hiyerarşisi Bağlamında Bir Değerlendirme. *Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(1), 51-70.
- Richardson, R. (1999). Measuring the impact of turnover on sales. *The Journal of Personal Selling and Sales Management*, 53-66.
- Rombaut, E., & Guerry, M. A. (2018). Predicting voluntary turnover through human resources database analysis. *Management Research Review*, 41(1), 96-112.
- Salunkhe, T. P. (2018). Improving employee retention by predicting employee attrition using machine learning techniques (Doctoral dissertation, Dublin Business School).
- Saradhi, V. V., & Palshikar, G. K. (2011). Employee churn prediction. *Expert Systems with Applications*, 38(3), 1999-2006.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 160.
- Setiawan, I. A., Suprihanto, S., Nugraha, A. C., & Hutahaeen, J. (2020, April). HR analytics: Employee attrition analysis using logistic regression. In *iop conference series: materials science and engineering* (Vol. 830, No. 3, p. 032001). IOP Publishing.

- Sexton, R. S., McMurtrey, S., Michalopoulos, J. O., & Smith, A. M. (2005). Employee turnover: a neural network solution. *Computers & Operations Research*, 32(10), 2635-2651.
- Shankar, R. S., Rajanikanth, J., Sivaramaraju, V. V., & Murthy, K. V. S. S. R. (2018, July). Prediction of employee attrition using datamining. In 2018 IEEE International Conference on System, Computation, Automation and Networking (ICSCAN) (pp. 1-8). IEEE.
- Shen, K., Eddelbuettel, J. C., & Eisenberg, M. D. (2024, January). Job flows into and out of health care before and after the COVID-19 Pandemic. In *JAMA Health Forum* (Vol. 5, No. 1, pp. e234964-e234964). American Medical Association.
- Shukla, S., & Sinha, A. (2013). Employee Turnover in banking sector: Empirical evidence. *IOSR Journal of Humanities and Social Science*, 11(5), 57-61.
- Sisodia, D. S., Vishwakarma, S., & Pujahari, A. (2017, November). Evaluation of machine learning models for employee churn prediction. In 2017 International Conference on Inventive Computing and Informatics (ICICI) (pp. 1016-1020). IEEE.
- Thompson, S. C., Holmgren, A. J., & Ford, E. W. (2022). Information system use antecedents of nursing employee turnover in a hospital setting. *Health Care Management Review*, 47(1), 78-85.
- Vulpen, E. V. (t.y.). What Drives Employee Turnover? Part 2. AIHR Academy to Innvate. <https://www.aihr.com/blog/what-drives-employee-turnover/>
- Warrad, L., & Al Omari, R. (2015). The impact of turnover ratios on Jordanian services sectors' performance. *Journal of modern accounting and auditing*, 11(2), 77-85.
- Wulandari, D. Y. (2022, November). Application of Binary Logistic Regression Analysis Method with SPSS Statistics 22.0 in Predicting Factors Affecting the Long of

Study. In Proceedings of the International Conference on Technology, Education, and Science (Vol. 4, No. 1, pp. 47-57).

Yadav, S., Jain, A., & Singh, D. (2018, December). Early prediction of employee attrition using data mining techniques. In 2018 IEEE 8th international advance computing conference (IACC) (pp. 349-354). IEEE.

Yahia, N. B., Hlel, J., & Colomo-Palacios, R. (2021). From big data to deep data to support people analytics for employee attrition prediction. *IEEE Access*, 9, 60447-60458.

Yedida, R., Reddy, R., Vahi, R., Jana, R., GV, A., & Kulkarni, D. (2018). Employee attrition prediction. arXiv preprint arXiv:1806.10480.

Yıldız, K. (2023). İstatistiksel yöntemler ile çalışanın işten ayrılmasının tahminlenmesi ve ücret belirlenmesi ile işten ayrılmanın optimizasyonu.

Yiğit, İ. O., & Shourabizadeh, H. (2017, September). An approach for predicting employee churn by using data mining. In 2017 international artificial intelligence and data processing symposium (IDAP) (pp. 1-4). IEEE.

Zhao, Y., Hryniewicki, M. K., Cheng, F., Fu, B., & Zhu, X. (2019). Employee turnover prediction with machine learning: A reliable approach. In *Intelligent Systems and Applications: Proceedings of the 2018 Intelligent Systems Conference (IntelliSys) Volume 2* (pp. 737-758). Springer International Publishing.

EK 1. ORİJİNALLİK RAPORU

EK 2. ETİK KURUL MUAFİYET FORMU

EK 3. SPSS VE ORANGE ANALİZ SONUÇLARI ÖRNEK (ÖRNEKLEM-1) EKLAN GÖRÜNTÜLERİ

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	662.920 ^a	.243	.323

a. Estimation terminated at iteration number 20 because maximum iterations has been reached. Final solution cannot be found.

Tablo A.1. Model özeti

Hosmer and Lemeshow Test

Step	Chi-square	df	Sig.
1	7.469	8	.487

Tablo A.2. Hosmer ve Lemeshow testi

Classification Table^a

Observed		Predicted			
		Ayrıldı (0)/ Ayrılmadı (1)		Percentage Correct	
		0	1		
Step 1	Ayrıldı (0)/ Ayrılmadı (1)	0	200	99	66.9
		1	76	223	74.6
Overall Percentage					70.7

a. The cut value is .500

Tablo A.3. Karışıklık matrisi

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
Step 1 ^a								
ŞirketdekiDeneyimSüresiYılKategorik	.092	.027	11.379	1	.001	1.096	1.039	1.156
Cinsiyet(1)	-.236	.238	.984	1	.321	.790	.495	1.259
YaşKategorik	.014	.026	.280	1	.597	1.014	.964	1.066
ÇocukSayısı	-.212	.146	2.102	1	.147	.809	.607	1.077
EğitimDurumuRank			17.552	4	.002			
EğitimDurumuRank(1)	-1.181	.436	7.326	1	.007	.307	.131	.722
EğitimDurumuRank(2)	-1.136	.360	9.982	1	.002	.321	.159	.650
EğitimDurumuRank(3)	-.917	.264	12.056	1	.001	.400	.238	.671
EğitimDurumuRank(4)	-.234	.353	.441	1	.507	.791	.396	1.581
AnaışGrubu			5.830	10	.829			
AnaışGrubu(1)	-21.444	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(2)	-21.047	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(3)	-40.451	31019.144	.000	1	.999	.000	.000	.
AnaışGrubu(4)	-20.758	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(5)	-20.611	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(6)	-20.496	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(7)	-21.936	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(8)	-19.488	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(9)	-22.520	28131.979	.000	1	.999	.000	.000	.
AnaışGrubu(10)	-20.558	28131.979	.000	1	.999	.000	.000	.
Yerleşke			4.865	4	.301			
Yerleşke(1)	-.227	.469	.234	1	.629	.797	.318	1.999
Yerleşke(2)	.478	.866	.305	1	.581	1.613	.295	8.808
Yerleşke(3)	18.455	40192.933	.000	1	1.000	103486367.8	.000	.
Yerleşke(4)	-1.791	1.353	1.751	1	.186	.167	.012	2.367
Bölüm			5.300	6	.506			
Bölüm(1)	-.593	1.538	.148	1	.700	.553	.027	11.264
Bölüm(2)	-.932	.791	1.388	1	.239	.394	.084	1.856
Bölüm(3)	-.653	.435	2.253	1	.133	.520	.222	1.221
Bölüm(4)	-1.349	.851	2.517	1	.113	.259	.049	1.374
Bölüm(5)	-19.189	40192.933	.000	1	1.000	.000	.000	.
Bölüm(6)	-1.232	1.059	1.353	1	.245	.292	.037	2.325
SonPerformansPuanı			41.747	2	.000			
SonPerformansPuanı(1)	3.984	.618	41.507	1	.000	53.705	15.985	180.436
SonPerformansPuanı(2)	3.179	.573	30.743	1	.000	24.032	7.811	73.941
Constant	18.426	28131.979	.000	1	.999	100499240.2		

a. Variable(s) entered on step 1: ŞirketdekiDeneyimSüresiYılKategorik, Cinsiyet, YaşKategorik, ÇocukSayısı, EğitimDurumuRank, AnaışGrubu, Yerleşke, Bölüm, SonPerformansPuanı.

Tablo A.4. Değişken tablosu

Model	AUC	CA	F1	Prec	Recall	MCC
Logistic Regression	0.754	0.697	0.696	0.705	0.697	0.404
Tree	0.661	0.681	0.681	0.684	0.681	0.365
SVM	0.627	0.580	0.576	0.589	0.580	0.171
kNN	0.707	0.681	0.675	0.703	0.681	0.386
Random Forest	0.771	0.647	0.641	0.666	0.647	0.316

Tablo A.5. Hiperparametre ayarları yapılmadan önce test başarı ölçütleri

The screenshot shows the Orange3 software interface. On the left, a workflow is visible with nodes for 'Ayrılanlar' (Separated) and 'Ayrılmayanlar' (Not Separated). The main window displays the 'Test and Score' results for various models. A 'Random Forest - Orange' configuration window is open, showing the following settings:

- Name: Random Forest
- Basic Properties:
 - Number of trees: 10
 - Number of attributes considered at each split: 8
 - Replicable training
 - Balance class distribution
- Growth Control:
 - Limit depth of individual trees: 3
 - Do not split subsets smaller than: 5
 - Apply Automatically

The 'Test and Score' window shows the following evaluation results for target (None, show average over classes):

Model	AUC	CA	F1	Prec	Recall	MCC
Logistic Regression	0.754	0.697	0.696	0.705	0.697	0.404
Tree	0.661	0.681	0.681	0.684	0.681	0.365
SVM	0.627	0.580	0.576	0.589	0.580	0.171
kNN	0.707	0.681	0.675	0.703	0.681	0.386
Random Forest	0.776	0.706	0.705	0.713	0.706	0.419

The 'Compare models by' section is set to 'Area under ROC curve'.

Tablo A.6. Örnek hiperparametre ayar ekranı

Confusion Matrix			Fri Aug 16 24, 19:01:04		
Confusion matrix for Logistic Regression (showing number of instances)					
	Predicted		0	1	Σ
Actual	0	39	23	62	
	1	13	44	57	
	Σ	52	67	119	


Confusion Matrix			Fri Aug 16 24, 19:02:04		
Confusion matrix for Random Forest (showing number of instances)					
	Predicted		0	1	Σ
Actual	0	40	22	62	
	1	13	44	57	
	Σ	53	66	119	

Confusion Matrix			Fri Aug 16 24, 19:01:20		
Confusion matrix for Tree (showing number of instances)					
	Predicted		0	1	Σ
Actual	0	37	25	62	
	1	12	45	57	
	Σ	49	70	119	

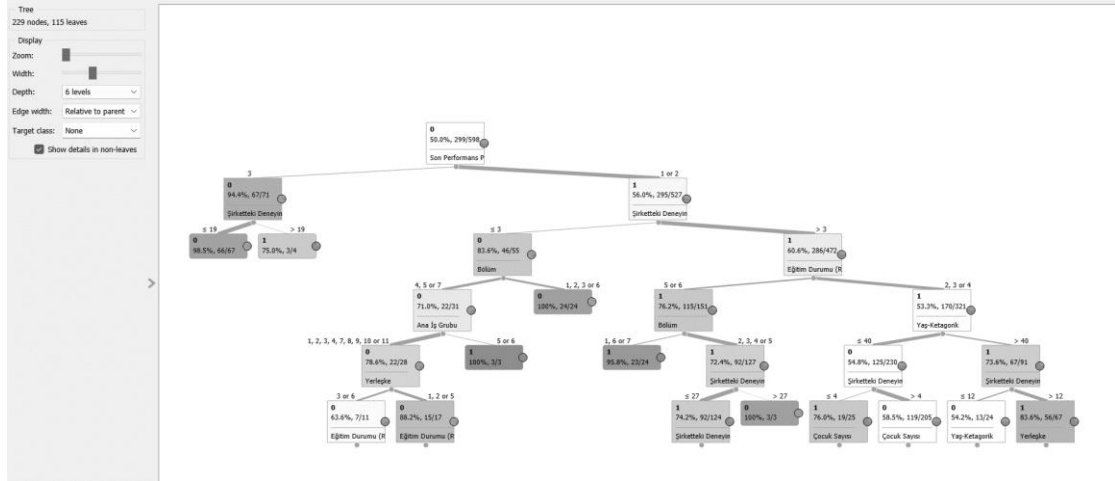
Confusion Matrix			Fri Aug 16 24, 19:01:29		
Confusion matrix for SVM (showing number of instances)					
	Predicted		0	1	Σ
Actual	0	39	23	62	
	1	17	40	57	
	Σ	56	63	119	

Confusion Matrix			Fri Aug 16 24, 19:01:56		
Confusion matrix for kNN (showing number of instances)					
	Predicted		0	1	Σ
Actual	0	40	22	62	
	1	11	46	57	
	Σ	51	68	119	

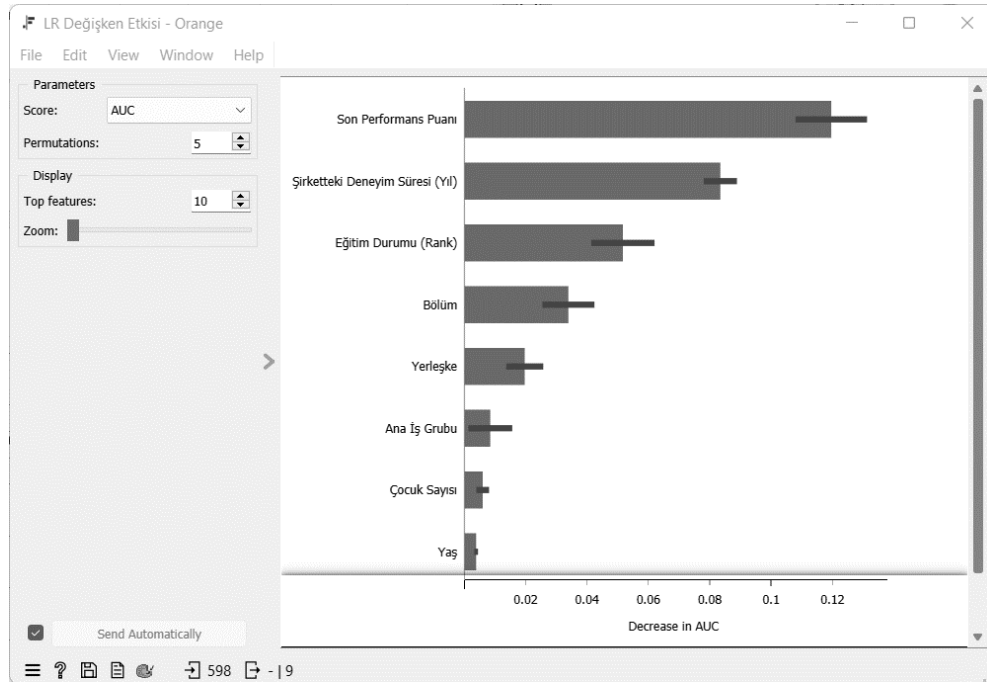
Tablo A.7. Karışıklık matris raporu



Şekil A.1. ROC eğrisi



Şekil A.2. Karar ağacı



Şekil A.3. Öznitelik etkinliği