



T.C.

HİTİT ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ADLİ BİLİMLER ANABİLİM DALI

**KULLANICILARIN MOBİL UYGULAMA GÜVENLİK
FARKINDALIKLARININ MAKİNE ÖĞRENMESİ
TEKNİKLERİYLE İNCELENMESİ**

Yüksek Lisans Tezi

Esmâ ERDOĞAN

Çorum - 2024

**KULLANICILARIN MOBİL UYGULAMA GÜVENLİK
FARKINDALIKLARININ MAKİNE ÖĞRENMESİ TEKNİKLERİYLE
İNCELENMESİ**

Esmâ ERDOĞAN

**Lisansüstü Eğitim Enstitüsü
Adli Bilimler Anabilim Dalı**

Yüksek Lisans Tezi

TEZ DANIŞMANI

Dr. Öğretim Üyesi Mustafa COŞAR

Çorum 2024

Esma ERDOĞAN tarafından hazırlanan “Kullanıcıların Mobil Uygulama Güvenlik Farkındalıklarının Makine Öğrenmesi Teknikleriyle İncelenmesi” adlı tez çalışması 26/06/2024 tarihinde aşağıdaki jüri üyeleri tarafından oy birliği/oy çokluğu ile Hitit Üniversitesi Lisansüstü Eğitim Enstitüsü Adli Bilimler Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Dr. Öğretim Üyesi Mustafa COŞAR

.....

Dr. Öğretim Üyesi İbrahim KÖK

.....

Dr. Öğretim Üyesi Emre DENİZ

.....

Hitit Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun .../...../2024 tarih ve sayılı kararı ile Esma ERDOĞAN' ın Adli Bilimler Anabilim Dalında Yüksek Lisans derecesi alması onanmıştır.

(İmza)

Prof. Dr. Osman Çubuk

Lisansüstü Eğitim Enstitüsü Müdürü

* Jüri Başkanının adı yazılmalıdır.

** Tez danışmanının adı yazılmalıdır.

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan ederim.

(İmza)

Esmâ ERDOĞAN



**KULLANICILARIN MOBİL UYGULAMA GÜVENLİK FARKINDALIKLARININ
MAKİNE ÖĞRENMESİ TEKNİKLERİYLE İNCELENMESİ**

Esmâ ERDOĞAN

ORCID: 0009-0001-4595-0179

HİTİT ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Yüksek Lisans Tezi

Haziran 2024

ÖZET

Cep telefonlarının her yerde bulunabilme, anında bağlantı kolaylığı, uygulama çeşitliliği, kişiselleştirme, esneklik, dağıtım ve konuma dayalı hizmetler gibi zenginleştirilmiş işlevsellik ve etkileşim özellikleri, onları dünyanın birinci iletişim aracı haline getirmiştir. Çoğu insan için cep telefonları artık vazgeçilmez bir unsur haline gelmiştir. Bu cihazlara yüklenen uygulamalarla kullanıcılar internet dünyasında etkileşimde bulunmaktadır. Mobil uygulama mağazaları, kullanıcılara çeşitli kategorilerde binlerce uygulamayı keşfetme ve indirme imkânı sunmaktadır. Her gün milyonlarca insan, ihtiyaçlarına veya ilgi alanlarına uygun uygulamaları bulmak için bu mağazalardan faydalanmaktadır. Kullanıcılar bu mağazalardan uygulama indirerek, iletişim kurma, eğlenme, bilgi edinme, alışveriş yapma, finansal işlemler yapma, seyahat planlama ve daha pek çok işlemi gerçekleştirme imkânına sahip olmaktadır. Bu çalışmada Harvard Üniversitesi'ne ait olan Dataverse platformunun bir araştırma anketin veri seti kullanılmıştır. Anket, 15'ten fazla ülkede 10.208 kişiyle yapılmıştır. Veri setinde ankete katılanların demografik özellikleri, eğitim bilgileri ve mobil uygulama kullanım davranışları gibi bilgiler bulunmaktadır. Bu çalışmanın temel hedefi mobil cihaz kullanıcılarının profillerini ve uygulama kullanım amaçlarını ve ihtiyaçlarını analiz ederek kullanıcıların bir uygulamayı tercih etme, kullanma ve bırakma kararlarına etki eden faktörleri makine öğrenmesi teknikleriyle belirlemektir. Araştırmada, veri seti üzerinde Logistik Regresyon (LR) , Random Forest (RF), Support vector machine (SVM), K-Nearest Neighbors(KNN) makine öğrenme algoritmaları ile yapılan analizde uygulamanın bulunması, seçilmesi ve bırakılması aşamaları test edilmiştir. Test etme aşamalarında Doğruluk (Accuracy), Hassasiyet (Precision), Duyarlılık (Recall), F1-Score (F-Measure) değerlerine bakılmıştır. Araştırmanın " Kullanıcı demografik özellikleri uygulamayı bulma davranışını etkilemektedir." Şeklinde kurulan 1. Hipotezin doğrulanmasında SVM makine öğrenmesi algoritması doğruluk oranı 0,930 F1-

Score deęeri ise 0,950 ile en başarılı algoritma olmuştur. Araştırmanın “Kullanıcının demografik özellikleri uygulamayı seçme davranışını etkilemektedir” şeklinde kurulan 2. Hipotezinin doğrulanmasında SVM makine öğrenmesi algoritması doğruluk oranı 0,920 ve F1-Score deęeri ise 0,950 ile en başarılı algoritma olmuştur. Araştırmanın “Kullanıcı demografik özellikleri uygulamayı bırakma davranışını etkilemektedir.” 3. Hipotezinde SVM makine öğrenmesi algoritmasına göre doğruluk oranı 0,940 F1-Score deęeri ise 0,970 olarak en başarılı algoritma olmuştur. Elde edilen analiz sonuçlarına göre mobil uygulama kullanıcıları demografik özelliklerinin uygulamayı bulma, seçme ve bırakma davranışları üzerinde etkili olduęu makine öğrenme yöntemleri ile doğru tahmin edilebileceęi görülmüştür. Araştırmanın “ Mobil uygulama kullanıcılarının uygulamayı bulma ve seçme davranışları arasında anlamlı bir ilişki vardır.” 4. Hipotezini test etmek için Pearson Korelasyon modeli kullanılmıştır. Bu model sonuçlarına göre Ortalama Pearson Korelasyon Katsayısı: 0.215 çıkmıştır. Araştırmanın “Mobil uygulama kullanıcılarının uygulamayı seçme ve bırakma davranışları arasında anlamlı bir ilişki vardır.” 5. Hipotezini test etmek için Pearson Korelasyon modeli kullanılmıştır. Bu model sonuçlarına göre Ortalama Pearson Korelasyon Katsayısı: 0.230 çıkmıştır. Elde edilen bu deęerlere göre kullanıcının mobil uygulamayı bulma, seçme ve bırakma davranışları arasında pozitif yönde zayıf bir ilişki olduęu görülmüştür.

Bu araştırma, kullanıcıların mobil uygulama güvenlięi ve gizlilik konusundaki bilinç düzeyini artırmak ve bilinçli seçimler yapmasına yardımcı olacaęı düşünülmektedir. Aynı zamanda mobil uygulama geliřtiricilerine, kullanıcıların gereksinimlerini daha iyi anlama ve uygulama deneyimini iyileřtirme konusunda deęerli veriler sunmaktadır.

Anahtar Kavramlar: Mobil Uygulama, Makine Öğrenimi, Mobil Kullanıcı

Bilim Kodu: 92414

INVESTIGATION OF USERS' MOBILE APPLICATION SECURITY AWARENESS USING MACHINE LEARNING TECHNIQUES

Esma ERDOĞAN

ORCID: 0009-0001-4595-0179

HITIT UNIVERSITY

GRADUATE SCHOOL

Master of Science Thesis

June 2024

ABSTRACT

The enriched functionality and interaction features of mobile phones, such as ubiquity, ease of instant connection, application diversity, personalization, flexibility, distribution and location-based services, have made them the world's first means of communication. Mobile phones have now become an indispensable element for most people. Users interact in the internet world with the applications installed on these devices. Mobile application stores offer users the opportunity to discover and download thousands of applications in various categories. Every day, millions of people use these stores to find applications that suit their needs or interests. By downloading applications from these stores, users have the opportunity to communicate, have fun, obtain information, shop, make financial transactions, travel planning and many other transactions. In this study, a research survey data set of the Dataverse platform belonging to Harvard University was used. The survey was conducted with 10,208 people in more than 15 countries. The data set includes information such as demographic characteristics, educational information and mobile application usage behavior of the survey participants. The main goal of this study is to analyze the profiles of mobile device users and their application usage purposes and needs, and to determine the factors that affect users' decisions to choose, use and abandon an application, using machine learning techniques. In the research, the stages of finding, selecting and abandoning the application were tested in the analysis performed on the data set with Logistic Regression (LR), Random Forest (RF), Support vector machine (SVM), K-Nearest Neighbors (KNN) machine learning algorithms. During the testing stages, Accuracy, Precision, Recall and F1-Score (F-Measure) values were examined. "User demographic characteristics affect the behavior of finding the application." In verifying the 1st Hypothesis established as follows, the SVM machine learning algorithm was the most successful algorithm with an accuracy rate of 0.930 and an F1-Score value of 0.950. In confirming the 2nd Hypothesis of the research, which was established as "The demographic characteristics of the user affect the application selection behavior", the SVM machine learning algorithm was the

most successful algorithm with an accuracy rate of 0.920 and an F1-Score value of 0.950. "User demographic characteristics affect application abandonment behavior." In the 3rd Hypothesis, according to the SVM machine learning algorithm, the accuracy rate was 0.940 and the F1-Score value was 0.970, making it the most successful algorithm. According to the analysis results obtained, it has been seen that the demographic characteristics of mobile application users have an impact on the behavior of finding, choosing and leaving the application and can be accurately predicted by machine learning methods. "There is a significant relationship between mobile application users' behavior in finding and choosing the application." Pearson Correlation model was used to test Hypothesis 4. According to the results of this model, the Average Pearson Correlation Coefficient was 0.215. "There is a significant relationship between the application selection and abandonment behavior of mobile application users." Pearson Correlation model was used to test Hypothesis 5. According to the results of this model, the Average Pearson Correlation Coefficient was 0.230. According to these obtained values, it was seen that there was a weak positive relationship between the user's behavior of finding, selecting and leaving the mobile application.

It is thought that this research will help users increase their awareness of mobile application security and privacy and make informed choices. It also provides valuable data to mobile app developers to better understand users' needs and improve the app experience.

Key Terms: Mobile Application, Machine Learning, Mobile User

Science Code: 92414

TEŐEKKÜR

Bu tez alıřmasının gerekleřmesi sũresince bana sabırla yol gũsteren, bana her konuda yardımlarını ve desteklerini esirgemeyen, bilgisini paylařan saygıdeęer danıřmanım ve hocam Dr. Őęr. Őyesi Mustafa COŐAR'a, tez savunması'nda yer alan ve kıymetli gũrũřleriyle arařtırmama katkıda bulunan deęerli jũri ũyesi hocalarım Dr. Őęr. Őyesi İbrahim KŐK ve Dr. Őęr. Őyesi Emre DENİZ'e ok teőekkũr ederim.

Her zaman yanımda olan aileme ayrıca hayatımın her alanında fikirlerini, maddi manevi desteklerini ve yardımlarını esirgemeyen bana her anlamda yol gũsterici olan eřim Murat ERDOęAN'a teőekkũrlerimi ve sevgilerimi sunarım.

Esmā ERDOęAN

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
TABLolar DİZİNİ	xi
ŞEKİLLER DİZİNİ	xii
SİMGELER VE KISALTMALAR	xiii
GİRİŞ	1

1. BÖLÜM

KAVRAMSAL ÇERÇEVE

1.1. Mobil Uygulama.....	9
1.1.1. Mobil uygulama kullanım oranları.....	10
1.1.2. Mobil uygulamalarda kullanıcı güvenlik farkındalığı.....	16
1.2. Makine Öğrenmesi.....	17
1.2.1. Makine öğrenmesi çeşitleri.....	18
1.2.1.1 Denetimli makine öğrenmesi.....	18
1.2.1.1.1 Logistik Regresyon (LR) Modeli.....	19
1.2.1.1.2 Random forest(RF) modeli.....	20
1.2.1.1.3 Support vector machine(SVM) modeli	21
1.2.1.1.4 K-Nearest Neighbors (KNN) Modeli	21
1.2.1.2 Denetimsiz Makine Öğrenmesi	22
1.2.1.3 Yarı denetimli makine öğrenmesi.....	23
1.2.1.4 Pekıştirmeli makine öğrenmesi.....	23
1.3. Değerlendirme Ölçütleri	24
1.4. Python Dili Kütüphaneleri	25

2. BÖLÜM

YÖNTEM

2.1. Araştırmanın Amacı.....	27
2.2. Araştırmanın Modeli	27
2.3. Veri Seti.....	28
2.4. Veri Ön İşleme Adımları.....	29
2.4.1. Veri setinin incelenmesi ve temizlenmesi.....	29
2.4.2. Veri setinde eksik değerlerin incelenmesi ve doldurulması	32
2.5. Araştırmanın Sınırlılıkları	32

2.6. Modellerin Eğitilmesi Ve Test Edilmesi.....	33
--	----

3. BÖLÜM

BULGULAR VE TARTIŞMA

3.1 Hipotez 1 İçin Makine Öğrenmesi Sonuçları	34
3.2. Hipotez 2 İçin Makine Öğrenmesi Sonuçları	36
3.3. Hipotez 3 İçin Makine Öğrenmesi Sonuçları	40
3.4. Hipotez 4 İçin Modellerin Eğitilmesi ve Test Edilmesi.....	43
3.5. Hipotez 5 İçin Modellerin Eğitilmesi ve Test Edilmesi.....	43
SONUÇ VE ÖNERİLER.....	45
KAYNAKÇA.....	47



TABLolar DİZİNİ

Tablo	Sayfa
Tablo 1.1. H2 - SVM Modeline Göre H2 Hipotezinin Uygulanması	15
Tablo 2.1. Veri Setine Ait Kullanıcıya Yöneltilen Sorular	29
Tablo 2.1. Çalışma Katılımcılarının Demografik Özellikleri ve Sayıları	30
Tablo 2.2. Veri Setinde Yer Alan Kullanıcıların Uygulama Bulma-Seçme-Bırakma Kararlarını Etkileyen Nedenler	31
Tablo 3.1. LR Modeline Göre H1 Hipotezinin Uygulanması	34
Tablo 3.2. RF Modeline Göre H1 Hipotezinin Uygulanması	34
Tablo 3.3. SVM Modeline Göre H1 Hipotezinin Uygulanması.....	35
Tablo 3.4. KNN Modeline Göre H1 Hipotezinin Uygulanması	35
Tablo 3.5. H1 - Model Karşılaştırma Ölçütleri.....	36
Tablo 3.6. H2 - LR Modeline Göre H2 Hipotezinin Uygulanması.....	37
Tablo 3.7. H2 - RF Modeline Göre H2 Hipotezinin Uygulanması.....	37
Tablo 3.8. H2 - SVM Modeline Göre H2 Hipotezinin Uygulanması	38
Tablo 3.9. H2 - KNN Modeline Göre H2 Hipotezinin Uygulanması.....	38
Tablo 3.10. H2 - Model Karşılaştırma Ölçütleri	39
Tablo 3.11. H3 - LR Modeline Göre H3 Hipotezinin Uygulanması.....	40
Tablo 3.12. H3 - RF Modeline Göre H3 Hipotezinin Uygulanması.....	41
Tablo 3.13. H3 - SVM Modeline Göre H3 Hipotezinin Uygulanması	41
Tablo 3.14. H3 - KNN Modeline Göre H3 Hipotezinin Uygulanması.....	42
Tablo 3.15. H3 - Model Karşılaştırma Ölçütleri	42

ŞEKİLLER DİZİNİ

Şekiller	Sayfa
Şekil 1.1. 2016-2023 Dünya Çapında Akıllı Telefon Mobil Ağ Abonelikleri Sayısı ve 2028 Yılına Kadarki Tahmini Mobil Ağ Abonelikleri Sayısı Grafiği	11
Şekil 1.2. Yaşa Göre Mobil Uygulama Kullanım Süreleri	12
Şekil 1.3. 2016'dan 2023'e kadar dünya çapında mobil uygulama indirme sayısı	13
Şekil 1.4. İndirme Sayısına Göre Mart 2024'te Dünya Çapında Lider Mobil Uygulamalar	14
Şekil 1.5. Kullanıcıların haftalık olarak en çok kullandığı mobil uygulama kategorileri	15
Şekil 1.6. Makine Öğrenimi Çeşitleri.....	18
Şekil 1.7. Denetimli Makine Öğrenmesi	19
Şekil 1.8. Random Forest Modeli Algoritması	20
Şekil 1.9. Support Vector Machine Modeli Algoritması	21
Şekil 1.10. Denetimsiz Makine Öğrenmesi.....	22
Şekil 1.11. Yarı Denetimli Makine Öğrenmesi.....	23
Şekil 1.12. Pekiştirmeli Makine Öğrenmesi.....	24
Şekil 2.1. Veri Seti Gözleme, Eksik Değerleri Kontrol Etme ve Doldurmaya İlişkin Kod Parçacığı	32
Şekil 2.2. Kategorik Değerlerin Sayısal Değerlere Dönüştürülmesine İlişkin Kod Parçacığı ...	32
Şekil 2.3. Bağımlı-Bağımsız Değişkenlerin Tanımlanmasına İlişkin Kod Parçacığı.....	33
Şekil 2.4. Veri Setini Test ve Eğitim Veri Kümesine Ayırmaya İlişkin Kod Parçacığı	33
Şekil 3.1. H1 - Model Karşılaştırma Ölçütleri Grafiği	36
Şekil 3.2. H2 Model Karşılaştırma Ölçütleri Grafiği.....	39
Şekil 3.3. H3 Model Karşılaştırma Ölçütleri Grafiği.....	43

SİMGELER VE KISALTMALAR

Simgeler

E	Euler sayısı
z	Modelin tahmin ettiği olasılık

Kısaltmalar

SVM	Support Vector Machine
RF	Random Forest
LR	Logistik Regresyon
PCA	Temel Bileşen Analizi
KA	Küme Analizi
H1	Hipotez 1
H2	Hipotez 2
H3	Hipotez 3
H4	Hipotez 4
H5	Hipotez 5
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative

GİRİŞ

Dijital ağların yaygınlaşması ve küresel bağlantının artmasıyla birlikte teknoloji hayatımızın hemen her alanında daha baskın bir rol oynamaya devam etmektedir. Sanayiden sağlığa, kamu ve özel sektörde birçok kurum ve kuruluş, hizmetlerini ve ürünlerini internet aracılığıyla sunmaktadırlar. Sosyal ağlar, bulut bilişim ve mobil cihazların kullanımındaki artış, bilgilere hızlı ve kolay erişimi sağlamakta ve bu teknolojiler giderek vazgeçilmez hale gelmektedir. Bu durum, bilişim hizmetlerinin hızla mobil cihazlara doğru kaydığını göstermektedir. Son birkaç yılda, kişisel bilgisayarlar (dizüstü, masaüstü) üzerinden internete erişimdeki eğilim azalırken, mobil cihazların (telefon, tablet, giyilebilir tekn.) kullanımı artmış durumdadır (Bal, 2017). Bu eğilim, mobil cihazların kullanımının giderek yaygınlaştığını ve geleneksel bilgisayarların yerini alabileceğini göstermektedir. Bu durum, bilişim dünyasında mobil odaklı bir dönüşümün yaşandığını göstermektedir.

Mobil cihazların yaygınlaşması, insanların günlük yaşamlarında vazgeçilmez bir araç haline gelmesine ve hatta bağımlılık noktasına ulaşmasına neden olmuştur (Chen ve diğerleri., 2017). Artık mobil cihazlar sadece telefon görüşmeleri için değil, e-posta gönderme/alma, sosyal medyada çevrimiçi kalmak ve elektronik finansal işlemler gibi birçok farklı amaç için de kullanılmaktadır. Bu cihazların esnek yapısı, tasarımcılara ve geliştiricilere yeni ve yenilikçi uygulamalar geliştirme imkanı sunmaktadır. Sonuç olarak, mobil cihaz kullanıcıları, geniş bir uygulama portföyünden faydalanabilmektedir.

Mobil işletim sistemleri cep telefonları, tabletler ve diğer taşınabilir el cihazları gibi mobil cihazların çalışması için özel olarak tasarlanmış işletim sistemleridir(Uslu ve diğerleri., 2020). Bu işletim sistemleri mobil cihazların donanımlarını yönetir ve kullanıcıların uygulamaları yüklemesine ve kullanmasına olanak tanır. İşletim sistemleri arasında Windows mobile, Symbian OS, Blackberry OS, Palm OS, Bada, IOS ve Android gibi birçok mobil işletim sistemleri mevcuttur. Ancak mobil uygulamaların büyük çoğunluğu Android ve IOS işletim sistemini kullanmaktadır. Android işletim sistemi Google tabanlı katman yazılımı kullanan mobil cihazlar için önemli uygulamalar içeren ücretsiz bir yazılımdır. IOS işletim sistemi iphone, iPad ve iPad Tocuh gibi apple cihazlarının kullanımı için yapılmış bir yazılımdır.

Mobil uygulamaları indirebilmek için kullanıcılar genellikle cihazlarına önceden yüklenmiş olan veya sonradan indirebilecekleri uygulama mağazalarını kullanmaktadırlar. Bu uygulama mağazaları, genellikle cihazın işletim sistemine bağlı olarak belirlenmekte ve kullanıcılara geniş bir uygulama yelpazesi sunmaktadır. Örneğin, Android işletim sistemine sahip cihazlar için Google Play Store, iOS işletim sistemine sahip cihazlar için App Store, Windows Phone işletim sistemine sahip cihazlar için Microsoft Store gibi mağazalar bulunmaktadır. 2024 yılı itibarıyla Apple Store'da yaklaşık iki milyon, Google Play ise yaklaşık üç milyon uygulama vardır (Buildfire, 2024). Yine 2023 yılına ait indirilen mobil uygulama sayısı 257 milyardır

(Statista, 2023). Bu uygulama mağazaları, kullanıcıların milyonlarca uygulama arasından istediklerini bulmalarını ve indirmelerini sağlamaktadır. Kullanıcılar genellikle mağaza arama özelliğini kullanarak istedikleri uygulamayı bulabilmekte veya popüler uygulama listelerini, kategorileri veya editörün seçimlerini gözden geçirebilmektedirler. Bir uygulama bulunduğunda, kullanıcılar genellikle birkaç tıklama ile indirme ve yükleme işlemi gerçekleştirirler. Uygulama mağazaları ayrıca kullanıcı yorumları, derecelendirmeler ve ek bilgiler gibi uygulamalar hakkında daha fazla bilgi sağlamaktadırlar. Böylece kullanıcılar kararlarını bilinçli bir şekilde verebilirler.

Mobil cihazların yaygınlaşması, insanların kişisel ve kritik verilerini bu cihazlarda saklama eğilimini artırmıştır. Android işletim sisteminin ücretsiz ve açık kaynak kodlu olması, onu en geniş kullanım ağına sahip yaparken, aynı zamanda kötü niyetli yazılım geliştiricileri için bir hedef haline getirmiştir. Google Play gibi büyük uygulama dağıtım platformları, kullanıcılara istedikleri türde uygulamaları indirip kullanma imkanı sunmaktadır. Ancak, bu platformlardaki uygulamaların tam güvenliği sağlanamaz.

Android ve iOS'un güvenlik modelleri arasındaki farklar gerçekten de önemli ve belirgin bir şekilde ayrılmaktadır (Büyükgöze, 2019). iOS'un güvenlik modeli, geliştiricilere uygulama oluşturma ve uygulama mağazalarına katkıda bulunma konusunda büyük bir fırsat sunarken, aynı zamanda uygulama güvenliğini ön planda tutmaktadır. Herhangi bir üçüncü taraf geliştirici tarafından sunulan her uygulama başvurusu, bir revizyon sürecinden geçmektedir. Bu süreçte uygulama kodu, uygulama mağazasına girmeden önce güvenliğin sağlanmasını garanti eden profesyonel geliştiriciler tarafından incelenir. Bu sayede, kullanıcılar uygulama indirdiklerinde tüm izinlerin güvenli bir şekilde alındığından emin olabilirler. Örneğin, bir uygulamanın kamera, internet bağlantısı veya konum gibi hassas bileşenlere erişimi olmadan kullanıcının izni alınmaz. Android ise kullanıcılara daha fazla özgürlük ve esneklik sunarken, aynı zamanda kullanıcıların kendi güvenliklerini sağlamalarını da bekler. Android'de, her uygulama indirildiğinde izinler kullanıcı tarafından onaylanır, ancak bu onaylar genellikle genel bir kabulü içerir ve uygulama, gerektiğinde bu izinlere erişebilir. Bu farklar, iOS'un geliştiricilerini güvenlik konusunda daha sıkı standartlarla uyumlu olmaya zorlamasını sağlar. Bu şekilde, zararlı uygulamaların App Store'a girmesi engellenir. Android ise kullanıcıların daha fazla kontrole sahip olmasını sağlar, ancak aynı zamanda kullanıcıların daha dikkatli olmalarını gerektirebilir. Her iki platformun da kendine özgü avantajları ve dezavantajları bulunmaktadır ve kullanıcılar güvenliklerini sağlamak için en uygun platformu seçmelidirler.

Mobil cihazların taşınabilirlik ve erişilebilirlik özellikleri, kullanım kolaylığı sağlarken aynı zamanda güvenlik risklerini de artırmaktadır. Akıllı telefonları hedef alan kötü amaçlı yazılımlar genellikle kullanıcıların kişisel verilerini çalmayı veya kullanıcının kredisini kötüye kullanmayı hedeflemektedir (La Polla ve diğerleri., 2013). Yanlış kullanıldığında veya kötü

niyetli kişilerin eline geçtiğinde, mobil cihazlar önemli güvenlik zaafiyetlerine neden olabilmektedirler. Siber tehditler, artan mobil cihaz kullanımıyla birlikte bilgisayarlardan daha fazla etkilenmekte ve daha fazla zarara yol açmaktadır. Ancak, tüm bu bilinen güvenlik açıklarına rağmen, bireyler ve kurumlar mobil cihazların sunduğu avantajlardan vazgeçememektedirler (Gökce ve diğerleri., 2021). Bu durum, mobil cihazların güvenliğine daha fazla önem verilmesi gerektiğini ortaya çıkarmaktadır. Artan siber saldırılar, kullanıcıların güvenlik konusundaki farkındalığını artırmıştır. Mobil cihazların güvenli bir şekilde kullanılabilmesi için, tüm güvenlik riskleri, iç ve dış tehditler ile kullanıcı dikkatsizlikleri belirlenmeli ve her bir risk için ayrı bir aksiyon ve önlem planı oluşturulmalıdır. Bu, güçlü parolaların kullanılması, güvenlik yazılımlarının düzenli olarak güncellenmesi, güvenilir uygulamaların yüklenmesi ve düzenli yedekleme yapılması gibi önlemleri içerebilir. Ayrıca, çalışanlara güvenlik eğitimleri verilerek bilinçli bir kullanıcı kitlesi oluşturulması da önemlidir. Bu şekilde, mobil cihazlar hayatımızın vazgeçilmez bir parçası olarak kalırken, güvenlik riskleri minimize edilebilir. Güvenlik zafiyetlerinin tespit edilmesinde yeni nesil teknolojilerin kullanımı önemlidir. Yeni nesil teknolojiler arasında yapay zeka, makine öğrenimi önemli bir yer tutmaktadır.

Makine öğrenmesi yöntemi günümüzde pek çok farklı disiplinde uygulanmaktadır. Bu disiplinler arasında teknoloji, eğitim, sağlık, finans, mühendislik gibi geniş bir yelpaze bulunmaktadır. Her disiplin kendi alanında benzersiz veri türlerine ve problemlere sahip olduğu için, makine öğrenimi bu alanlarda farklı yaklaşımlar getirmektedir. Örneğin, sağlık sektöründe makine öğrenimi, hastalık teşhisi, tedavi planlaması, hasta takibi gibi birçok alanda kullanılmaktadır. Eğitimde ise öğrenci performansının değerlendirilmesi, öğrenciye özgü öğrenme yollarının belirlenmesi gibi alanlarda makine öğrenimi teknikleri kullanılmaktadır. Edebiyat ve kültür alanında ise, metin analizi, duygu analizi, tematik analiz gibi tekniklerle metinlerin içeriği hakkında bilgi edinmek ve kültürel trendleri anlamak için makine öğrenimi kullanılmaktadır. Bu sayede, edebiyat eserlerinin, tarihsel dönemlerin veya belirli kültürlerin incelenmesi daha kolay hale gelmektedir. Her alandaki uygulamalar, o alandaki uzmanların bilgi ve deneyimlerini makine öğrenimi algoritmalarına entegre etmeyi gerektirir. Bu şekilde, makine öğrenimi teknikleri, farklı disiplinlerdeki karmaşık sorunlara çözüm bulmak için güçlü bir araç olabilir.

Araştırma kapsamında literatürler incelendiğinde mobil cihaz kullanımı, mobil uygulama güvenliği, mobilde kullanıcı güvenliği ve farkındalığı ile yapılmış bir çok çalışma ve araştırmanın olduğu görülmüştür. Bu araştırmalar mobil cihazlar ve uygulamalarıyla ilgili farklı araştırma alanlarına ve çalışma türlerine yönelik örnekler sunmaktadır. Araştırmacılar, mobil teknolojinin güvenliği, kullanımı ve etkileri gibi konuları ele alarak bu alandaki bilgi birikimini artırmaya devam etmektedirler.

(Zhu ve diğeri., 2014), "Mobile app recommendations with security and privacy awareness" adlı makalelerinde akıllı mobil cihazların hızla yaygınlaşmasıyla mobil uygulama sayısı patladığı ve mevcut öneri sistemleri genellikle popüler uygulamaları önerdiği belirtilmiştir. Ancak gizlilik ve güvenlik açısından yetersiz olduğu vurgulanmıştır. Bu makalede, güvenlik farkındalığına sahip bir mobil uygulama öneri sistemi geliştirilmiştir. Sistemin, uygulamaların güvenlik riskini otomatik olarak algıladığı ve değerlendirdiği, popülerlik ve güvenlik tercihlerini dikkate alarak önerilerde bulunduğu anlatılmıştır. Öneri sisteminin, uygulamaların talep ettiği izinlerle potansiyel güvenlik riskini algıladığı vurgulanmıştır. Kullanıcılara önerilerde bulunmak için modern portföy teorisine dayalı esnek bir yaklaşım ve uygulama karma ağacı kullanılmıştır. Google ait Play Store mağazasından toplanan veri kümesi üzerinde yapılan deneyler, bu öneri sisteminin etkinliğini doğruladığı anlatılmıştır.

(Unal, 2015), "Mobil uygulama tavsiyelerinde kullanıcı profilleri ve kullanım tercihlerinin analizi" adlı doktora tezinde mobil uygulama öneri sistemlerinin en çok indirilen, en popüler, tüketici beğenisi ve bunlar arasındaki benzerlik veya en çok tüketilen ürünler gibi stratejileri dikkate aldığı vurgulanmaktadır. Çalışmada mobil uygulama pazarının hızla büyüdüğü bu ortamda uygulama önerilerinin kullanıcı deneyimlerini etkilediği ve, öneri sistemlerinin kullanıcıların ihtiyaçlarını anlamak ve bireysel farklılıkları dikkate alması gerektiği vurgulanmaktadır. Öneri sistemlerinin kullanıcıların kişilik özelliklerini dikkate alması ve daha uygun kişiselleştirilmiş öneriler sunmasının kullanıcı memnuniyeti ve uygulama kullanımının artacağı belirtilmiştir. Çalışmada 44 sorudan oluşan bir anket yapılmış ve kullanıcıların özelliklerinin cep telefonu, mobil uygulama ve iletişim uygulamalarında etkili olup olmadığının cevapları aranmıştır. Cinsiyet, eğitim, yaş gibi faktörlerin mobil uygulama seçiminde ve kullanımında etkili olduğu yönler anlatılmıştır.

(Lim ve diğeri., 2015), "Mobilde Ülke Farklılıklarının Araştırılması Uygulama Kullanıcı Davranışı ve Yazılım Mühendisliğinde Zorluklar" adlı çalışmalarında 15'ten fazla ülkede 10.208 katılımcıyla bir anket gerçekleştirmişlerdir. Çalışmada yapılan anket, kullanıcıların uygulama ihtiyaçlarını, bir uygulamayı seçme veya bırakma gerekçelerini ve ülkeler arasındaki davranış farklılıklarını araştırmak üzere yapılmıştır. Bu anketten elde edilen veriler Pearson korelasyon katsayısı, doğrusal regresyon, Pearson ki-kare testi ve olasılık oranı gibi istatistiksel ölçümler kullanılarak analiz edilmiştir. Araştırma da mobil uygulamalar açısından kültürel ve ülkeler arası farklılıkları belirlemek amaçlanmıştır. Bu açıdan bu araştırmanın dünya genelindeki en büyük anketlerden birini uyguladığı ve ülkeler arasındaki davranış farklılıklarını gösterdiği vurgulanmıştır.

(UĞUR, 2015), "Üniversite Öğrencilerinin Mobil Uygulamaları Kabulünü Etkileyen Faktörlerin Belirlenmesine Yönelik Bir Araştırma:Sakarya Üniversitesi Örneği" adlı tezinde 1654 üniversite öğrencisinde elde edilen veriler neticesinde mobil uygulama teknolojilerinin toplu

üzerindeki etkisini, yayılımını, benimsenmesini ve kabulüne etki eden faktörlerinin belirlenmesini amaçlamaktadır. Araştırmanın mobil uygulamaların toplumların yaşamındaki etkilerini ve iletişim alışkanlıklarını daha iyi anlamamıza yardımcı olacağı düşünülmektedir. Bu çalışmada üniversite öğrencilerinin seçilme nedeni, teknolojik yeniliklerin ve ürünlerin hedef kitlesinin gençler olması ve mobil uygulamaların kullanım amacını şekillendiren faktörlerin bu genç kitleden gelmesi olarak belirlenmiştir. Çünkü gençler teknolojik açıklık ve yeniliklere yatkın olmalarıyla bilinmektedirler. Bu nedenle, üniversite öğrencileri, mobil uygulamaların benimsenme sürecini ve bu süreci etkileyen faktörleri daha iyi anlamak için ideal bir örneklem oluşturmaktadır. Verilerin ışığında, gençlerin mobil uygulamaları nasıl kullandıkları, hangi faktörlerin bu kullanımı etkilediği ve bu uygulamaların toplumdaki rolü gibi konuları incelemeye çalışılmıştır.. Bu araştırma da, teknolojinin toplumsal etkisini daha iyi anlamamıza ve gelecekteki teknoloji kullanımının şekillenmesine yardımcı olacağı düşünülmüştür.

(Arslan ve diğerleri., 2017)'deki, "Android Mobil Uygulamalar için İzin Karşılaştırma Tabanlı Kötücül Yazılım Tespiti" adlı makalelerinde mobil uygulamaların izin tabanlı modellerini kullanarak güvenlik ve gizlilik modellerini oluşturmak ve uygulamaların risk değerlerini belirlemek için önemli bir yaklaşım sunmaktadır. Çalışma da, istatistiksel analiz ve kod analizi gibi teknikleri bir araya getirilerek uygulamaların gereksiz izin taleplerini belirlemek ve şüpheli kaynak erişimlerini tespit etmek amaçlanmıştır. Bu yöntem, uygulamaların istedikleri ve kullandıkları izinleri analiz ederek fazladan izin talep eden uygulamaları tespit etmekte ve bu sayede kullanıcıların gizliliğini korumaya yardımcı olmaktadır. Ayrıca, her bir uygulama için belirlenen şüphe değeri sayesinde uygulamalar kötücül veya zararsız olarak sınıflandırılmaktadır. Android işletim sistemi için geliştirilen bu yöntem, kötücül yazılımların tespit edilmesi ve kullanıcıların daha güvenli bir Android ortamında dolaşmaları için önemlidir. Yöntemin etkinliğini ve güvenilirliğini değerlendirmek için mevcut veri setleri üzerinde doğruluk seviyesinin belirlenmesi yapılmıştır. Uygulanan yöntem kötücül uygulamaların tespitinde %97'lik bir oran yakalamıştır. Bu çalışma, mobil güvenlik alanında yeni bir yaklaşım sunması ve kullanıcıların güvenliği için değerli bir katkı sağlaması açısından önemlidir. Özellikle, mobil uygulama mağazalarında güvenlik risklerini azaltmaya yönelik çabaların arttığı bir dönemde, bu tür yöntemlerin önemi giderek artmaktadır.

(Çelik, 2018), "Mobil Uygulamalarda Kullanıcı Sürekliliği İçin Yaşam Döngüsü Yönetiminde Büyük Veri Analiz Yöntemlerinin Geliştirilmesi" adlı çalışmasında mobil uygulamalardaki kullanıcı sürekliliğini artırmak için büyük veri analizi yöntemi ile A/B testlerinin uygulanması yapılmıştır. Çalışmada büyük veri kullanılarak kullanıcıları tanınması ve davranışlarının analiz edilmesi de büyük önem taşıdığı vurgulanmıştır.. Bu yöntem ile, mobil uygulama yaşam döngüsünü daha iyi anlamak ve kullanıcıların uygulamayı ne zaman ve nasıl kullandıklarını belirlemek için etkili olabileceği düşünülmüştür. Araştırmada A/B testlerinin, farklı kullanıcı deneyimlerini karşılaştırarak, uygulamanın kullanıcılar üzerindeki etkisini değerlendirmek

için yaygın olarak kullanılan bir yöntem olduğu belirtilmiştir. Bu şekilde elde edilen veriler, uygulamanın geliştirilmesi ve kullanıcıların memnuniyetinin artırılması için değerli bir rehberlik sağlayabileceği anlatılmıştır.

(Büyüköze, 2019), “Mobil Uygulama Marketlerinin Güvenlik Modeli İncelemeleri” adlı araştırmasında akıllı telefon işletim sistemlerinin uygulama güvenliğini sağlama yöntemlerini karşılaştırarak aralarındaki farkı ortaya koymaktadır. Apple, App Store'da yayınlanacak uygulamaları kendi belirlediği güvenlik kriterlerine göre değerlendirmekte ve bu kriterleri yerine getirmeyen uygulamaları App Store'a yüklememektedir. Bu sebeple iOS kullanıcıları, App Store'dan indirdikleri uygulamaların güvenli olduğunu bilmektedirler . Öte yandan, diğer işletim sistemleri genellikle uygulama güvenliğini kullanıcılara bırakmıştır. Bu, kullanıcıların uygulama indirirken dikkatli olmalarını ve güvenilir kaynaklardan uygulama indirmelerini gerektirmektedir. Ancak, bu yaklaşım kullanıcıların güvenlik konusunda bilinçli olmadığı durumlarda güvenlik risklerine yol açabilmektedir. Bu çalışma, iOS'un uygulama güvenliği konusunda daha katı bir denetim politikasına sahip olduğunu ve diğer işletim sistemlerinin bu konuda daha esnek bir yaklaşım benimsediğini göstermektedir. Bu durum, kullanıcıların güvenliğini sağlamak için alınan önlemlerin ve denetim politikalarının önemini vurgular.

(Koyuncu & Pusatlı, 2019), “Akıllı Telefon Kullanıcılarının Güvenlik Farkındalığı Düzeyi: Keşifsel Bir Vaka Çalışması” adlı çalışmalarında akıllı telefon teknolojisinin yaygınlaşmasıyla birlikte, kişisel ve hassas bilgilerin bu cihazlarda saklanması kötü niyetli kişilerin ve siber suçluların bu alanı hedef haline getirmesine neden olmuştur. Bu da güvenlik konusu daha kritik hale getirmiştir. Ancak, birçok kullanıcı bu konuda yeterince bilinçli değil ve bu da kişisel veri ihlallerine ve güvenlik açıklarına yol açmaktadır. Bu çalışma farklı yaş, eğitim düzeyi ve bilgi teknolojileri güvenliğini uzmanlığına sahip bir grup kişi üzerinde yürütülen anket çalışmasına dayanmaktadır. Çalışmada elde edilen sonuçlara göre katılımcıların farkındalık düzeyi düşük çıkmış ve bu durumun iyileştirilmesi gerektiğini sonucuna varılmıştır. Eğitim düzeyinin ve bilgi teknolojileri konusunda bilgi sahibi olmanın kullanıcıların güvenlik farkındalığına olumlu yönde etki eden bir faktör olduğu sonucuna varılmıştır. Yaş açısından en yaşlı grubun farkındalık düzeyi oldukça düşük çıkmıştır.

(Karakethüdaoğlu, 2019), “Sistemlerin geliştirilmesinde mobil uygulamalarda kullanıcı geri bildirimlerinin önemi Türkiye e-nabız örneği” isimli çalışmasında Google Play Store ve AppleStore uygulama mağazalarında T.C. sağlık bakanlığına ait Mobil e-Nabız uygulamasına yapılan 3965 adet kullanıcı yorumlarının veri mandenciliği yazılımlarından olan QDA Miner ve Wordstat programlarında analizlerini yapmıştır. Araştırmada Mobil E-Nabız uygulamasının kullanım düzeyini belirlemek için kullanıcı yorumlarından alınan 220 kişilik bir örnek kesiti IBM SPSS yazılımında çeşitli testlerden geçirmiştir. Bu testlerin amacını farklı platformlarda kullanıcıların uygulamaya verdiği yıldız derecelendirmeleri, beğenilen yönler ve hatalar ve

yorumlar arasındaki ilişki tutarlıklarını belirlenmesi olarak açıklanmıştır. Yapılan bu testlerden yola çıkarak kullanıcılardan aldıkları geri bildirimler sayesinde uygulamanın gelişim analizleri ve yazılım geliştirmesine yönelik katkıları gibi çeşitli analizler yapılmıştır. Araştırmanın amacının sağlık alanındaki bir mobil uygulamanın hızlı, kusursuz ve düzenli çalışmasını sağlamak olduğu vurgulanmıştır. Bu sebeple bunu sağlamanın yöntemi uygulamayı kullanan kullanıcıların geri bildirimlerinin analizlerini yapmak olduğu belirtilmiştir.

(Balapour ve diğerleri., 2020)“Mobile application security: Role of Perceived Privacy as the Predictor of Security Perceptions” adlı çalışmalarında mobil kullanıcıların güvenlik ve gizlilik endişelerinin mobil uygulamalara ilişkin güvenlik algılarını etkileyip etkilemediğinin araştırması yapılmıştır. Çalışma da mobil uygulamaların kullanımıdaki artışın kullanıcıların güvenlik endişelerini de beraberinde getirdiği anlatılmıştır. Güvenlik endişelerinin, kullanıcıların mobil uygulamaları yükleme ve kullanma niyetlerini büyük ölçüde etkilediği belirtilmiştir. Araştırmada mobil kullanıcıların en az yarısının gizlilik endişeleri nedeniyle mobil uygulamaları silmekte ve kullanmayı bırakmakta olduğu vurgulanmıştır. Bu çalışmada mevcut güvenlik ve gizlilik çalışmalarını incelenmiş ve bir araştırma modeli ile iki anket kullanılarak test edilmiştir. Bir ankette az hassas bilgiler kullanan uygulamalar diğer ankette ise daha hassas bilgilere erişen uygulamalar kullanılmıştır. Araştırmadaki sonuçlar, algılanan gizlilik riskinin mobil uygulamaların algılanan güvenliğini olumsuz etkilediğini; gizlilik politikasının algılanan etkinliğinin, kullanıcıların mobil uygulama güvenliği algılarını olumlu etkilediğini; ve algılanan gizlilik farkındalığının, algılanan gizlilik riskinin mobil uygulamaların algılanan güvenliği üzerindeki etkisini azalttığını göstermiştir.

(Gökce ve diğerleri., 2021), “Mobil Yaşamda Siber Güvenlik Yaklaşımı” adlı makalelerinde Mobil cihazların yaygınlaşmasıyla birlikte, siber güvenlik konusundaki farkındalık arttığı ve kullanıcıların ve kurumların bu cihazları güvenli bir şekilde kullanabilmek için çeşitli önlemler almaya başladığı anlatılmıştır. Özellikle mobil cihazların kolay taşınabilme, erişilebilme ve internet erişimi için kullanımının artması, bu cihazlara yönelik siber saldırıları da arttırdığı belirtilmiştir. Çalışma da bu saldırılardan korunmak için kişi ve kurumların alabileceği güvenlik önlemleri ve güvenlikle ilgili yapması gerekenler açıklanmıştır. Mobil iletişim operatörlerinin iletişim altyapısı ve hizmetleri üzerindeki riskleri belirleyerek gerekli güvenlik önlemlerini alması gerektiği anlatılmıştır.

Literatürün genel çerçevesine bakıldığında araştırmaların mobil teknolojilerin güvenliği ve kullanıcı deneyimi üzerine odaklandığı görülmüştür. Bu araştırmalar, mobil cihazların yaygınlaşmasıyla birlikte ortaya çıkan güvenlik tehditlerini anlamak, kullanıcıların güvenlik farkındalığını değerlendirmek ve mobil uygulamaların güvenliğini artırmak için çeşitli yöntemler geliştirme gibi konuları ele almaktadır. Bu çalışmada ise veri seti üzerinde mobil cihaz kullanıcısının mobil uygulamalar üzerinde uygulamayı bulma, seçme ve bırakma

davranışlarını demografik özelliklerin etkileme durumları Logistik Regresyon, Random Forest ve Support Vector Machine makine öğrenme modelleri kullanılarak analiz edilmiştir.

Bu tez çalışması üç bölümden oluşmaktadır. Birinci bölümde mobil uygulama kavramı açıklandıktan sonra mobil uygulama kullanım oranları ve istatistikleri incelenmiştir. Bu konulardan sonra mobil uygulama kullanıcı güvenlik farkındalığı açıklanmış ve makine öğrenmesi yöntem ve teknikleri detaylandırılarak anlatılmıştır. İkinci bölümde ise araştırmanın yöntemi ve modeli anlatılmıştır. Araştırmada kullanılan veri seti ön işleme adımları uygulanarak veri setinin incelenmesi, temizlenmesi ve eksik değerlerin doldurulması işlemi yapılmıştır. Daha sonra veri setinin makine öğrenmesi modelleri ile eğitilmesi ve test edilmesi başlıkları açıklanmıştır. Üçüncü bölümde bulgular ve tartışma başlığı altında makine öğrenmesi yöntemleri ile kurulan hipotezler test edilerek analizleri yapılmıştır. Sonuç ve öneriler bölümünde kullanıcı davranışlarının etkilenme durumlarını makine öğrenme teknikleri ile analiz edilmesinin sonuçları anlatılmıştır.

1. BÖLÜM

KAVRAMSAL ÇERÇEVE

1.1. Mobil Uygulama

Akıllı telefonlar ve mobil uygulamalar hayatımızın her alanında giderek daha fazla yer almaktadırlar. Bu uygulamalar, kullanıcıların çeşitli işlevleri yerine getirmesine olanak tanımaktadır. Mobil uygulama, akıllı telefonlar, tabletler veya diğer taşınabilir cihazlar için özel olarak geliştirilen yazılım programlarıdır. Her gün yüzlerce yeni uygulama geliştirilmektedir. Bu uygulamalar yaşamımızın pek çok yönünü kolaylaştırmakta ve zenginleştirmektedir. Mobil uygulamalardaki bu çeşitlilik yazılımcıların mobil uygulama sektörüne ilgi duymasına ve bu alanda yazılım geliştirmesine katkıda bulunmuştur (Bilgili, 2014). Mobil uygulamalar geniş bir yelpazede kullanım alanlarına sahiptir. Bunlar oyunlar, eğitim uygulamaları, sosyal medya platformları, haber uygulamaları, alışveriş uygulamaları, sağlık ve fitness takip uygulamaları gibi çeşitli kategorilerde olabilmektedir. Oyunlar, sosyal medya uygulamaları, müzik ve video akış hizmetleri gibi uygulamalar ile boş zamanlarımız eğlenceli bir hale gelmektedir. Öğrenme platformları, haber uygulamaları ve e-kitap uygulamaları sayesinde kullanıcılar istedikleri konularda bilgi edinmeleri sağlanmaktadır. Finansal yönetim uygulamaları, takvim uygulamaları ve iş verimliliği uygulamaları gibi uygulamalar işlerimizi düzenlememize, planlamamıza ve izlememize yardımcı olmaktadır. Seyahat ve Navigasyon uygulamaları ile otel bulma, rezervasyon yapma ve seyahat ederken yön bulma gibi işlerimizi yapmamıza ve yeni yerler keşfetmemizi sağlamaktadır. Genellikle belirli bir platformda (Android, iOS, Windows Phone gibi) çalışacak şekilde tasarlanmıştır.

Kullanıcılar, mobil uygulamaları cihazlarının uygulama mağazalarından indirmekte ve uygulamayı yükleyerek kullanabilmektedirler. Akıllı telefon işletim sistemleri, kullanıcıların bu uygulamalara erişimini sağlar. Mobil uygulamalar, çoğu zaman platforma özgü olarak geliştirilmektedir. IOS için App Store ve Android için Google Play Store gibi özel uygulama mağazaları, kullanıcıların uygulamaları keşfetmelerini, indirmelerini ve güncellemelerini yapmalarını sağlamaktadır. Mobil uygulama mağazaları akıllı telefonların işletim sistemine göre çeşitlenmekle beraber marka ve model ayrımı gözetmeksizin kullanıcıların ihtiyaçlarına uygun milyonlarca mobil uygulama seçeneğini sunmaktadır (Namlı, 2010). Bu mağazalarda, farklı kategorilerde binlerce uygulama bulunur. İhtiyaca yönelik uygulamalar, oyunlar, eğitim uygulamaları, sosyal medya platformları, haber uygulamaları ve daha fazlası gibi geniş bir yelpazede uygulamalar mevcuttur. Bu çeşitlilik, her türlü kullanıcı ihtiyacını karşılamak için tasarlanmıştır.

Mobil uygulamaların popülerliği, kullanıcıların taşınabilir cihazlarını günlük yaşamlarında giderek daha fazla kullanmalarıyla birlikte artmıştır. Bu uygulamalar, iletişimden alışverişe, eğlenceden iş üretkenliğine kadar çeşitli alanlarda kullanılabilir. Hangi sektör olduğu fark etmeksizin bütün firmalar ve şirketler piyasada güçlü bir pazara ulaşabilmek için ve

kullanıcılara daha kolay ulaşmak adına mobil uygulamaların kullanılması gerektiğine karar vermişlerdir (Koçak ve diğerleri., 2013). Kullanıcıların mobil uygulama seçiminde dil, fiyat, performans, hafıza kullanımı, kullanıcı yorumları ve hız gibi kriterler etkili olmaktadır (Uslu ve diğerleri., 2020).

1.1.1. Mobil uygulama kullanım oranları


Mobil uygulamaların çeşitlenmesi ve artması, akıllı telefonların kullanıcı gereksinimlerine göre özelleştirilmesini ve kullanıcıların beklentilerini artırmasını sağlamıştır (Inukollu ve diğerleri., 2014). Kullanıcılar, kendi ihtiyaçlarına ve tercihlerine uygun milyonlarca mobil uygulama seçeneği arasından seçim yapabilmektedirler. Bu durum, mobil uygulama mağazalarının, kullanıcıların farklı ihtiyaçlarını karşılayacak çeşitli uygulamalar sunarak akıllı telefon kullanımını artırmaya ve çeşitlendirmeye yönelik olduğunu göstermektedir.

Akıllı telefonlarda çalışan mobil uygulamaların sunduğu özellikler, kullanıcıların hayatlarını kolaylaştırmak için tasarlanmıştır. Bu özellikler, iletişimden eğlenceye, işten finansa kadar geniş bir yelpazede sunularak kullanıcıların günlük aktivitelerini daha etkin ve verimli bir şekilde yönetmelerine yardımcı olmaktadır (Khalid ve diğerleri., 2015).

Mobil uygulamaların akıllı telefon kullanımına etkisi büyüktür. Kullanıcıların hayatlarını daha kolay ve pratik hale getirmesi, mobil cihazlara olan ilgiyi artırmıştır. WhatsApp, Instagram, Twitter tarzı sosyal mesajlaşma uygulamalarının kullanımının artması akıllı telefon kullanımının artmasını beraberinde getirmiştir. Bu da mobil cihazların yaygınlaşmasını ve teknolojiye olan erişimin artmasını sağlamıştır.


Bu bilgiler ışığında mobil uygulamaların çeşitlenmesi ve kullanıcı ihtiyaçlarına uygun özellikler sunması, akıllı telefon kullanımını artırmış ve mobil iletişim cihazları sektöründe büyük bir etki yaratmıştır. Bu durum, mobil teknolojinin gelişimi ve kullanıcı deneyiminin sürekli olarak iyileştirilmesi açısından olumlu bir gelişmedir.

2024 yılı itibarıyla önemli mobil uygulama istatistikleri şunlardır (Buildfire, 2024). Mobil uygulama pazarında Google Play Store ve Apple App Store piyasaya hakim olan en önemli uygulama mağazalarındandır. 2024 yılında yaklaşık 7 milyara yakın mobil ağ kullanıcısı vardır. Mobil uygulamaların 2024 yılında 935 milyar doların üzerinde gelir elde etmesi beklenmektedir. Dünya çapındaki mobil uygulamaların %98'i ücretsiz uygulamalardan oluşmaktadır. Apple App Store'da indirilebilecek 1,96 milyon uygulama vardır. Google Play Store'da indirilebilecek 2,87 milyon uygulama vardır. 2023 yılında indirilen mobil uygulamalar sayısı 257 milyardır. Ortalama bir kullanıcı her gün yaklaşık 3 saatini akıllı telefonu üzerinde harcamaktadır. Y kuşağının (1983-1995) %21'i bir uygulamayı günde 50'den fazla kez açmaktadır. İnsanların %49'u bir uygulamayı her gün 11'den fazla kez açmaktadır. ABD'deki dijital medya zamanının %70'i mobil uygulamalardan gelmektedir. Ortalama bir akıllı telefon sahibi günde 10, ayda 30 uygulama kullanmaktadır.




Şekil 1.1. 2016-2023 Dünya Çapında Akıllı Telefon Mobil Ağ Abonelikleri Sayısı ve 2028 Yılına Kadarki Tahmini Mobil Ağ Abonelikleri Sayısı Grafiği (Statista, 2024).

Şekil 1.1'deki grafiğe bakıldığında yatay sütun yıllar, dikey sütun ise ağ abonelikleri sayısı olmak üzere dünya çapında akıllı telefon mobil ağ aboneliklerinin sayısı 2022'de neredeyse 6,7 milyara ulaşmıştır. 2028 yılında ise bu sayının 7,7 milyarı aşacağı tahmin edilmektedir. Statista'nın hazırladığı rapora göre en fazla akıllı telefon mobil ağ aboneliğine sahip ülkeler Çin, Hindistan ve ABD'dir. Akıllı telefon pazarı hâlâ yüksek büyüme potansiyeline sahip olmakla, akıllı telefon sayısının başta Çin ve Hindistan olmak üzere yüksek nüfuslu birçok pazarda ülke nüfuslarının yüzde 70'nin altında kalmaktadır.




Şekil 1.2. Yaşa Göre Mobil Uygulama Kullanım Süreleri (Buildfire, 2024).

Şekil 1.2’de Yaşa göre mobil uygulama kullanım süreleri grafiği incelendiğinde 18-24 yaş aralığındaki genç insanların mobil uygulama kullanım süreleri ayda yaklaşık 113 saat ile diğer yaş grubundaki insanlara göre daha fazla çıkmıştır. Şekil 1.’deki grafikte de görüldüğü gibi 25-34 yaş arasındaki insanlar ayda yaklaşık 103 saatini mobil uygulamaları kullanarak geçirmektedir. Bu süre 35-44 yaş aralığındaki insanlarda 93.6 saat, 45-54 yaş aralığındaki insanlarda 75.6 saat, 55-64 yaş aralığındaki insanlarda 69.3 saat olarak bulunmuştur. 65 yaş üzeri mobil kullanıcıların aylık 51.4 saate yakın vakitlerini mobil uygulamalarda harcadıkları görülmüştür.




Şekil 1.3. 2016'dan 2023'e kadar dünya çapında mobil uygulama indirme sayısı (Statista, 2024).

Şekil 1.3'deki 2016'dan 2023'e kadar dünya çapında mobil uygulama indirme sayısı grafiği incelendiğinde 2016 yılında indirilen mobil uygulama sayısı 140 milyar iken bu sayı 2023 yılında 257 milyara çıkmıştır. Mobil uygulama indirme sayısındaki bu artış bize Mobil uygulama pazarının gelişmekte ve hızla büyüdüğünü göstermektedir. Mobil uygulama indirme sayısı 2016-2022 yılları arasında artmaya devam ederken, 2023 yılında küresel uygulama indirmeleri durağanlaşarak 257 milyar indirmeye ulaşmıştır. Statista'nın hazırladığı rapora göre mobil uygulama pazarının 2025 yılında 613 milyar ABD dolarından fazla gelir elde etmesi öngörülmektedir. Tüm uygulama kategorileri arasında en büyük gelir payını mobil oyunlar almaktadır (Swiftspeed, 2024). En çok gelir elde eden mobil oyun uygulamaları sırasıyla sosyal ağlar, eğlence ve alışveriş uygulamaları takip etmektedir.



Şekil 1.4. İndirme Sayısına Göre Mart 2024'te Dünya Çapında Lider Mobil Uygulamalar (Statista, 2024)

Şekil 1.4'de İndirme sayısına göre 2024'te dünya çapında lider mobil uygulamalar grafiği incelendiğinde Facebook ve Instagram, sırasıyla 59 milyon ve 58 milyon indirmeye dünya çapında en çok indirilen mobil uygulamalar olmuştur. Sosyal video uygulaması TikTok ise 46 milyon indirmeye 3. Sıradaki mobil uygulama olmuştur. TikTok uygulamasını sırasıyla 42 milyon indirmeye WhatsApp, 27 milyon indirmeye Telegram ve 24 milyon indirmeye Threads uygulaması olmuştur. Şekil3.'deki mobil uygulamalar en çok indirilen ve en popüler uygulamalardır.



Şekil 1.5. Kullanıcıların haftalık olarak en çok kullandığı mobil uygulama kategorileri (Truelist, 2024)

Şekil 1.5.'de Kullanıcıların haftalık olarak en çok kullandığı mobil uygulama kategorileri grafiğine bakıldığında en popüler uygulama kategorisinin haftalık 131 dakika ile instagram, facebook, twitter gibi sosyal ağlar olduğu görülmektedir. İkinci sıradaki en popüler uygulama kategorisi ise kullanıcıların haftalık 116 dakika harcadığı oyun uygulamalarıdır. Oyun uygulamalarını sırasıyla iletişim uygulamaları 102 dakika, müzik uygulamaları 80 dakika ve eğlence uygulamaları 67 dakika ile takip etmektedir.

Tablo 1.1. Mobil uygulama kategorilerinin ortalama 30 ve 90 günlük uygulama tutma tablosu(Swifspeed, 2024).

Mobil Uygulama Sektörü	Ortalama 30 Günden Fazla Tutma Oranı	Ortalama 90 Günden Fazla Tutma Oranı
Medya ve Eğlence	43%	24%
E-Ticaret/Perakende	37%	18%
Seyahat/Yaşam Tarzı	36%	18%
Teknoloji	33%	19%
Oyun	27%	10%

Tablo 1.6'da 2024 yılı mobil uygulama istatistikleri raporuna göre mobil kullanıcılar bir uygulamayı indirdikten sonra, kullanıcıların %71'i 90 günlük bir süre içerisinde uygulamayı bırakmaktadır (Swiftspeed, 2024). Mobil uygulama kategorileri arasında farklılıklar olsa da 30 günlük elde tutma oranı %42, 90 günlük elde tutma oranı ise %25'dir. Eğlence ve medya mobil uygulamaları %43 oranla en fazla 30 günlük elde tutma oranına ve %24 oranla en fazla 90 günlük elde tutma oranına sahiptir. Burada dikkati çeken nokta Şekil 4.'de oyunlar en fazla indirilen 2. mobil uygulama kategorisi içerisindeyken mobil uygulama elde tutma kategorilerinde en düşük 30 ve 90 günlük elde tutma oranlarına sahip olmasıdır. Bir araştırmaya göre kullanıcıların % 21 'i bir uygulamayı tek kullanımdan sonra bırakmakta, % 38'i ise uygulamayı en az 10 kere veya daha fazla başlatmaktadır (Uplandsoftware, 2024). Uygulama kullanıcılarının %71 ise 90 günlük sürenin içerisinde uygulamayı bırakmaktadır.

1.1.2. Mobil uygulamalarda kullanıcı güvenlik farkındalığı

Akıllı mobil cihazların popülerliği giderek artmakta ve bu da mobil uygulamaların sayısında önemli bir artışa neden olmaktadır (Zhu ve diğerleri., 2014). Her geçen gün yeni uygulamalar geliştirilmekte ve kullanıcılar için çeşitli ihtiyaçları karşılamak üzere piyasaya sürülmektedir. Kullanıcıların mobil cihazlarına uygulama yükleme esnasında verdikleri izinler hassas bilgilerin güvenliğini riske atma ve veri sızıntılarına neden olma gibi güvenlik tehditlerine sebebiyet vermektedirler (Zargham ve diğerleri., 2019). Diğer bir yandan uygulama izinleri genellikle ilgili bir bilgileri içermekte ve kullanıcılar bu izinlerin sonuçlarını anlamada bilgi eksikliği ve farkındalıktan kaynaklı ekstra bir çaba göstermemektedirler (Bahrini ve diğerleri., 2019). Kötü amaçlı mobil uygulamalar aldıkları izinler sayesinde kullanıcıların özel verilerini arka planda sessiz bir şekilde başka bir yere gönderebilmektedirler. Araştırmalar çoğu kullanıcının mobil güvenlik farkındalığı konusunda oldukça zayıf bir anlayışa sahip olduğu ve telefonunda yüklü uygulamaların erişebildiği hassas bilgilerden haberinin olmadığı ortaya çıkarmıştır (Wu ve diğerleri., 2020). Mobil kullanıcıların uygulamalara verdikleri izinler konusundaki ilgi ve farkındalığını artırmak için eğitimler verilebilir ve verilen izinlerin sonuçlarını gösteren uygulamalar geliştirilebilir. Mobil uygulama güvenliği önemli bir konudur ve bu konuda bazı önemli anahtar kelimeler şu şekilde sıralanmıştır (Gökce ve diğerleri., 2021).

- **Güvenilir Kaynaklar:** Uygulamaları indirirken resmi uygulama mağazalarını tercih edilmelidir. Güvenilmeyen kaynaklardan uygulama indirmek zararlı yazılımlara maruz kalma riskini artırmaktadır.
- **İzinler:** Uygulamaların hangi izinlere ihtiyaç duyduğunu kontrol edilmelidir. Bazı uygulamalar gereksiz izinler isteyebilmekte, bu da gizlilik ve güvenlik riskleri oluşturabilmektedir.
- **Güncel Yazılım:** Mobil cihazınızın işletim sistemini ve uygulamalarınızı düzenli olarak güncellenmelidir. Güncellemeler genellikle güvenlik açıklarını gidermekte ve sizi potansiyel saldırılardan korumaktadır.

- Güçlü Parolalar ve Kimlik Doğrulama: Mobil cihazınıza güçlü bir parola veya biyometrik kimlik doğrulama eklenmelidir. Bu, cihazınızın fiziksel güvenliğini artırmaktadır.
- Ağ Güvenliği: Açık Wi-Fi ağlarından kaçınmalı ve mümkünse VPN kullanılmalıdır. Açık ağlar üzerinden yapılan bağlantılar gizlilik riskleri taşımaktadır.
- Bilinçli Kullanım: Hassas verilerinizi paylaşırken dikkatli olunmalıdır. Uygulamalara gereksiz erişim vermek kişisel ve hassas bilgilerinizi tehlikeye atabilmektedir.
- Yetkisiz Uygulamaların Kullanımı: Jailbreak veya root gibi işlemlerle cihazınızın güvenliğini tehlikeye atmamalıyız. Bu tür işlemler cihazınızı potansiyel saldırılara daha açık hale getirebilmektedir.
- Bilgi Koruma ve Yedekleme: Önemli bilgilerinizi düzenli olarak yedeklemeli ve cihazınızı uzaktan silme veya bulma gibi özelliklere karşı korunmaya almalıyız.

Mobil uygulama indirirken kullanıcıların genellikle tercih ettiği ve yüksek indirme sayısına sahip olan uygulamalar, genellikle güvenilir ve kullanıcı dostu olduğu düşünülmektedir (Btnet, 2024). Ancak, sadece yüksek indirme sayısına ve sıralamasına bakmak yeterli olmamaktadır. Uygulamanın Google Play Store veya App Store gibi platformlardaki kullanıcı yorumlarını ve derecelendirmelerini okumak gerekmektedir. Güncellenmeyen uygulamalar, performans sorunlarına veya güvenlik açıklarına neden olabilmektedir. Dolayısıyla, uygulamanın son güncelleme tarihine ve geliştiricinin güncelleme sıklığına dikkat etmek önemlidir. Uygulamanın istediği izinleri kontrol etmek önemlidir. Uygulamayı geliştiren şirket veya geliştirici hakkında bilgi edinmek de dikkat edilmesi gerekenlerdendir. Çünkü daha önce güvenilir uygulamalar yayınlamış, iyi bir itibara sahip geliştiriciler genellikle güvenilir bir uygulama sunmaktadırlar. Yukarıda sıralanan bu önlemler, mobil uygulama güvenliği konusunda farkındalığınızı artırmanıza yardımcı olmakla birlikte cihazınızın güvenliğini sağlamak için önemli bir temel oluşturmaktadır.

1.2.Makine Öğrenmesi

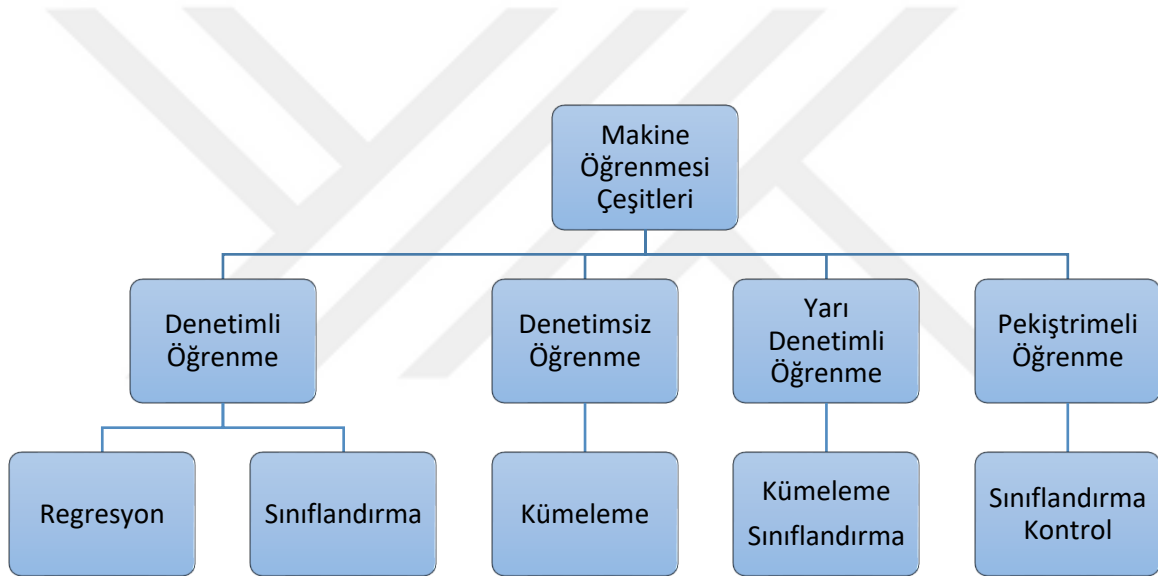
Gelişen teknoloji ile birlikte kullanılan teknolojik cihazlar çeşitlilik kazanmıştır. Bilgisayar, tablet, akıllı telefon ve giyilebilir teknolojiler gibi çeşitli teknolojik ürünler kullanıcının günlük hayattaki ihtiyaçlarını karşılamaya ve kolaylaştırmaya yönelik olarak sürekli güncellenmektedir. Güncellenen bu cihazların pek çoğunda verileri kayıt altına alma özellikleri bulunmaktadır. Her gelişen yeni teknoloji ile birlikte kayıt altına alınan veri büyüklüğünde artmaktadır. Oluşturulan veri tabanından doğru bilgiye erişebilmek için bilginin ayrıştırılması, analiz edilmesi, temizlenmesi gibi işlemler gerekmektedir. Bu işlemler içinde makine öğrenmesi kullanılmaktadır (Akbulut, 2022).

Makine öğrenmesi, bilgisayarların insanlar gibi öğrenme yeteneği kazanabilmesi için çeşitli algoritmalar, modeller ve teknikler geliştiren bir bilim dalıdır. Bu sayede bilgisayarlar, programlanmadan verilerden ve deneyimlerden öğrenebilir ve performanslarını zamanla iyileştirebilir (Alpaydın, 2010).

Makine öğrenimi, kullanılan veriden anlamlı bilgiler çıkararak, bu bilgiler üzerinden tahminler yapabilir. Sunulan karmaşık problemleri çözmek için algoritmalar geliştirip, modellemeler yapabilir(Akbulut, 2022). Makine öğrenimi, yapay zekanın temel bir alt dalıdır. Yapay zeka, insan zekasını taklit eden ve problem çözmek için kullanılan sistemler geliştirmeye odaklanır (Dündar ve diğerleri., 2021). Makine öğrenmesi, bu sistemlerin verilerden otomatik olarak öğrenmesini ve zamanla performanslarını geliştirmelerini sağlar. Makine öğrenimi programlama yapmadan verilerden ve deneyimlerden öğrenebilir ve performanslarını zamanla iyileştirebilir.

1.2.1. Makine öğrenmesi çeşitleri

Makine öğrenimi dört grupta incelenmektedir(Mahesh, 2019). Şekil 1.7' de makine öğrenme algoritma çeşitleri verilmiştir.

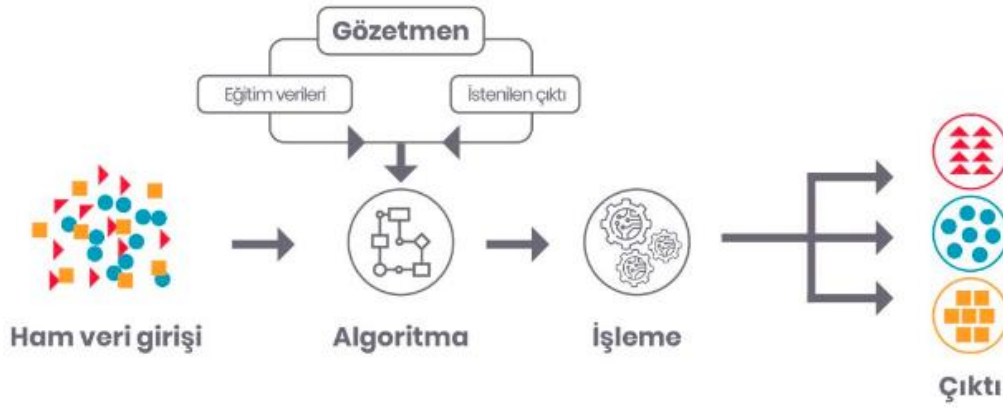


Şekil 1.6. Makine Öğrenimi Çeşitleri(Mahesh, 2019)

Makine öğrenme çeşitleri dört gruba ayrılmaktadır. Bunlar denetimli, denetimsiz, yarı denetimli ve pekiştirmeli makine öğrenimidir.

1.2.1.1 Denetimli makine öğrenmesi

Denetimli öğrenme, bir makine öğrenmesi modelinin önceden etiketlenmiş verilerden öğrenmesini sağlayan bir tekniktir. Bu verilerde, giriş ve çıktı açıkça belirtilmiştir. Model, bu verileri kullanarak giriş ile çıktı arasındaki ilişkiyi öğrenir ve yeni veriler için tahminler yapabilir.



Şekil 1.7. Denetimli Makine Öğrenmesi (Eker ve diğerleri., 2023)

Şekil 1.7’ de denetimli makine öğrenimi çalışma prensibi görsel olarak verilmiştir. Denetimli öğrenmede, veri test ve eğitim verisi olarak ayrılır. Eğitim verisi ve test verisi sisteme yüklenerek eğitilen eğitim verisi test verisi üzerinde kontrol edilir. Amaç sonuçları bilinen eğitim veri seti üzerinden sonuçları bilinmeyen veriler üzerinde tahmin yapabilmektir (KIZILKAYA and OĞUZLAR 2018). Denetimli makine öğrenimi sınıflandırma ve regresyon teknikleri olarak iki grupta incelenir. Sınıflandırma teknikleri kullanılan veriler etiketlenebilir, kategorilere ayrılabilir veya belirli gruplara sınıflara ayrılabiliriyorsa kullanılabilir (YILDIRIM and ÜSTÜNDAĞ 2022). Genel olarak kullanılan sınıflandırma algoritmaları, destek vektör makinesi, karar ağaçları, k-en yakın komşu, Naive Bayes, diskriminant analizi, lojistik regresyon ve sinir ağlarını içerir. Regresyon teknikleri ise sürekli olan bir değeri tahmin etmek için kullanılır. Genel olarak kullanılan regresyon algoritmalarına doğrusal model, doğrusal olmayan model, regülasyon, kademeli regresyon, karar ağaçları, sinir ağları örnek olarak verilebilir.

1.2.1.1.1 Logistik Regresyon (LR) Modeli


Logistik regresyon modeli, bağımlı değişkenin kategorik olduğu durumlarda kullanılan bir regresyon modelidir. Bağımlı değişken genellikle binary (iki sınıflı) olur, yani iki farklı kategoriye ait olabilir. LR modeli, bağımsız değişkenlerin verildiğinde bağımlı değişkenin belirli bir sınıfa ait olma olasılığını tahmin etmek için kullanılır (COŞAR & DENİZ, 2021). Bu tahmin, 0 ile 1 arasında bir olasılık değeri olarak verilir. Eğer bu olasılık değeri belirlenen bir eşik değerinden büyükse, örneğin 0.5, o zaman örnek o sınıfa atanır, değilse diğer sınıfa atanır. LR modeli genellikle maksimum olabilirlik yöntemi kullanılarak tahmin edilir. Model, bağımsız değişkenlerin katsayıları ile bir doğrusal kombinasyonunu kullanır ve bu kombinasyonu bir logit (log-olasılık oranı) fonksiyonuna sokarak sonuç elde eder.

$$LR = f(x) = 1/(1 + e^{(-z)}) \quad (1)$$

Bu fonksiyon, girdi olan z değerini 0 ile 1 arasında bir değere dönüştürmek için kullanılır. Formülde kullanılan " e " matematiksel bir sabittir ve Euler sayısı olarak bilinir. Değeri yaklaşık olarak 2.71828'dir. Euler sayısı, doğal logaritmanın tabanı olarak da kullanılır ve matematikte birçok alanda önemli bir role sahiptir. z değeri genellikle bağımsız değişkenlerin katsayıları ile bir doğrusal kombinasyonunu temsil eder ve modelin tahmin ettiği olasılığı ifade eder(Kuyucu, 2012). Bu fonksiyon sayesinde, logistik regresyon modeli 0 ile 1 arasındaki olasılıkları tahmin edebilir ve sınıflandırma yapabilir. LR modeli, bu formül kullanılarak eğitilir ve belirli bir eşik değerine göre sınıflandırma yapar. Eğitim sürecinde, modelin katsayıları veriye uygun olarak tahmin edilir.

1.2.1.1.2 Random forest(RF) modeli

Rastgele Orman yöntemi, eğitim veri setinin rastgele örnekler üzerinde büyüyen ve ağaç yapım sürecinde rastgele özellik seçimi yaparak karar ağaçları topluluğu oluşturan bir algoritmadır. Tahminler, tüm ağaçların tahminlerinin bir araya getirilmesiyle yapılır. Rastgele Orman, karar ağaçlarının toplulukları olduğu için, tek ağaca dayalı sınıflandırıcılara göre önemli bir performans artışı sağlar. Rastgele Orman, büyük veri kümeleri için iyi bir seçenek olmasına rağmen, dengesiz eğitim veri kümeleri durumunda dezavantajlar gösterebilir(Doğan & Büyükkör, 2022). Rastgele Orman, genel hata oranını en aza indirir ve bu nedenle dengesiz veri kümeleri durumunda daha yüksek bir toplam doğruluk elde ederken, azınlık sınıfının gerçek tahminini zayıflatabilir.




Şekil 1.8. Random Forest Modeli Algoritması (Akdeniz, 2022)

Şekil 1.8'de RF modelinin çalışma prensibi şekil olarak gösterilmiştir. RF algoritmaları, tek bir ağaç yerine bir orman oluşturarak işlem yapar. Bu ormanda her bir ağaç, veri setinin rastgele örnekleriyle eğitilir. Her bir ağaç, rastgele özellikler üzerinden bölünmeler yaparak kararlar alır (Akdeniz, 2022). Test aşamasında, RF, her bir ağacın verdiği sınıf tahminlerini toplayarak çoğunluk oylaması yapar ve bu şekilde final sınıf tahminini belirler. Bu yöntem, tek bir ağacın genellemesinden daha güçlü ve daha kararlı bir tahmin yapılmasını sağlar.

1.2.1.1.3 Support vector machine(SVM) modeli

Destek Vektör Makineleri (SVM), sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenimi modelidir(Akdeniz, 2022). Temel amacı, veri noktalarını sınıflar arasında en iyi şekilde ayıran veya bir regresyon çizgisi oluşturan bir hiperdüzlem bulmaktır. SVM, özellikle düşük boyutlu veri setlerinde etkilidir ve aşırı uydurma (overfitting) eğilimine karşı dirençlidir(Elmas, 2019).



Şekil 1.9. Support Vector Machine Modeli Algoritması (Akdeniz, 2022)

Şekil 1.9’da iki sınıflı problem üzerinde SVM modelinin çalışma prensibi gösterilmiştir. Bu şekle göre yorum yapıldığında, verilen iki sınıfı A,B,C isimli üç farklı düzlem ayırmaktadır. Bu düzlemlerden A, sınıfı başarılı ayırmadığı, B düzleminin ise en yüksek marjini ayıramadığı, C düzleminde ise başarılı bir sınıf ayrımı yaptığı görülmektedir (AKDENİZ 2022;(Elmas, 2019)). SVM’nin çalışma prensibi, veri noktalarını en iyi şekilde ayıran hiperdüzlemi bulmaya dayanır. Bu hiperdüzlem, veri noktalarının en yakın olduğu destek vektörler arasında yer alır. SVM, bu destek vektörler arasındaki marjı maksimize etmeye çalışarak modelin genelleme performansını artırmayı hedefler.

1.2.1.1.4 K-Nearest Neighbors (KNN) Modeli

K-Nearest Neighbors (KNN) modeli, sınıflandırma ve regresyon analizlerinde kullanılan basit ama etkili bir makine öğrenmesi algoritmasıdır(Xiong & Yao, 2021). KNN, eğitim verilerini kullanarak bir tahmin yaparken yeni bir veri noktasının yakınındaki en yakın k komşusunu dikkate almaktadır. KNN modelinin temel özellikleri aşağıda verilmiştir(IBM, 2023).

Sınıflandırma ve Regresyon: KNN, hem sınıflandırma hem de regresyon problemleri için kullanılabilir.

Eğitim Süreci: KNN, eğitim aşamasında veri noktalarının etiketlerini veya değerlerini saklar; bu nedenle eğitim süreci hızlıdır.

Tahmin Süreci: Tahmin aşamasında, yeni bir veri noktası için en yakın kk komşuyu bulur ve bu komşuların etiketleri veya değerleri üzerinden karar verir. Sınıflandırma için, en yaygın sınıf etiketi seçilir; regresyon için, komşuların değerlerinin ortalaması alınır.

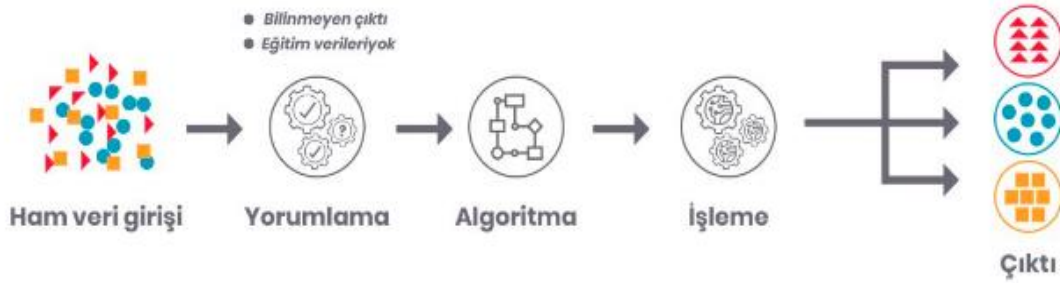
Uzaklık Metrikleri: Genellikle Öklidyen uzaklık kullanılır, ancak Manhattan, Minkowski gibi farklı uzaklık metrikleri de kullanılabilir.

K Parametresi: kk değeri, komşu sayısını belirler ve modelin performansını etkileyebilir. Küçük kk değerleri modelin daha esnek olmasını sağlarken, büyük kk değerleri modelin daha genel olmasını sağlar.

KNN modeli, veri ön işleme ve uygun k değerinin seçimiyle etkili sonuçlar verebilir, ancak büyük veri setlerinde hesaplama maliyetleri artabilir.

1.2.1.2 Denetimsiz Makine Öğrenmesi

Denetimsiz makine öğrenmelerinde etiketlenmiş veri kullanılmaz. Bunun yerine girdi verilerini kullanarak veri kümeleri aracılığıyla anlamlı bilgiler çıkarmayı amaçlar (Dündar ve diğerleri., 2021). Denetimsiz öğrenmenin temel prensibi, verilerin kendi içindeki yapı ve organizasyonu keşfetmesine izin vermektir (Dilki & Deniz Başar, 2020). Bu, verilerdeki benzerlikleri ve farklılıkları analiz ederek ve veri noktalarını gruplara ayırarak yapılır (Aksaç & Dikmen, 2023).



Şekil 1.10. Denetimsiz Makine Öğrenmesi (Eker ve diğerleri., 2023)

Şekil 1.10'da denetimsiz makine öğrenimi çalışma prensibi görsel olarak verilmiştir.

Denetimsiz öğrenmenin en yaygın kullanılan iki tekniği şunlardır:

Temel Bileşen Analizi (PCA): PCA, verilerdeki varyansın büyük bir kısmını açıklayan daha az sayıda yeni özellik (bileşen) oluşturmak için kullanılır. Bu, veri kümesini boyutlandırmayı ve daha az sayıda önemli değişkene indirgemeyi sağlar (Çoğun ve diğerleri., 2016).

Küme Analizi (KA): KA, benzer özelliklere sahip veri noktalarını kümelere ayırmak için kullanılır. Bu, verilerdeki doğal grupları keşfetmek için kullanılır (Çoğun ve diğerleri., 2016).

1.2.1.3 Yarı denetimli makine öğrenmesi

Yarı denetimli öğrenme, hem denetimli hem de denetimsiz öğrenme sistemlerinin bir sentezidir. Bu yöntemde, bir kısmı etiketlenmiş, bir kısmı ise etiketlenmemiş veriler birlikte kullanılır. Etiketlenmiş veriler, modele bir temel oluştururken, etiketlenmemiş veriler ise modelin daha karmaşık örüntüleri öğrenmesini ve genelleme yeteneğini geliştirmesini sağlar(Eker ve diğerleri., 2023).

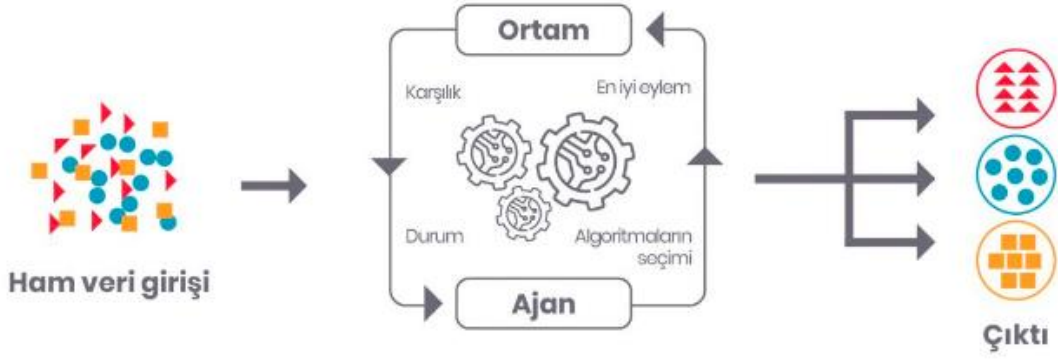


Şekil 1.11. Yarı Denetimli Makine Öğrenmesi (Eker ve diğerleri., 2023)

Şekil 1.11 'de yarı denetimli makine öğrenimi çalışma prensibi görsel olarak verilmiştir. Bu yaklaşımın temel amacı, az miktarda etiketlenmiş veri kullanarak, büyük miktarda etiketlenmemiş veriden de faydalanarak öğrenme sürecini optimize etmektir(Gökalp, 2022). Gözlemler, etiketlenmemiş verilerin bilinçli bir şekilde kullanımıyla, modelin performansında önemli bir artış elde edilebileceğini göstermektedir.

1.2.1.4 Pekiştirmeli makine öğrenmesi

Pekiştirmeli Makine Öğrenmesi, bir yapay zeka modelinin, deneme yanılma yoluyla ve bir ödül sistemi aracılığıyla etkili davranışları öğrenmesini sağlayan bir tekniktir. Bu teknikte, model bir çevreyle etkileşime girer, aldığı eylemlere göre ödül veya ceza alır ve zamanla en fazla ödülü alacak şekilde davranmayı öğrenir (Aksaç & Dikmen, 2023).



Şekil 1.12. Pekiştirmeli Makine Öğrenmesi (Eker ve diğerleri., 2023)

Şekil 1.12 de pekiştirmeli makine öğrenimi çalışma prensibi görsel olarak verilmiştir. Pekiştirmeli öğrenmede Ajan, çevre, eylem, durum, ödül ve ceza unsurları bulunmaktadır. Çalışma prensibinde ajan çevredeki durumu gözlemler, gözlemlediği duruma uygun bir eylem seçer. Seçtiği eylemi gerçekleştirir ve bulunduğu çevreden geri bildirim (ödül-ceza) alır (Çoğun ve diğerleri., 2016). Aldığı geri bildirim göre de gerçekleştirilen eylemin doğru ya da yanlış davranış olduğunu öğrenir (Bölük ve diğerleri., 2019). Zamanla da en fazla ödül aldığı davranışı sergilemeyi öğrenir (İmamoğlu ve diğerleri., 2009).

Pekiştirmeli öğrenmede, modelin önceden programlanmasına gerek yoktur. Deneme -yanılma yolu ile en etkili davranışı öğrenir aynı zamanda değişen ortamlara kolaylıkla uyum sağlayabilir.

1.3. Değerlendirme Ölçütleri

Bir sınıflandırma modelinin başarısı, kullanılan eğitim ve test veri setlerinin özelliklerine ve bu setlerdeki sınıf dağılımlarına bağlıdır. Farklı örnekleme yöntemleri, veri setinin nasıl oluşturulacağını ve modelin performansını nasıl etkileyebileceğini gösterir (Kıraç, 2021). Çalışmamızda kullandığımız sınıflandırma modellerinin performanslarını değerlendirmek için aşağıda belirtilen ölçütler kullanılmıştır.

Doğruluk (Accuracy): Doğruluk oranı bir modelin başarısını değerlendirmek için kullanılan ölçütlerden en sık görülendir. Doğruluk, kullanılan sınıflandırma modelinin ne kadar iyi eğitildiğini ve genel performansını gösterir. Doğru sınıflandırılmış örnek sayısı, toplam örnek sayısına bölünerek doğruluk ölçütü bulunur (DEMİREL 2023). Doğruluk ölçütünün formülü aşağıdaki şekildedir.

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2)$$

Hassasiyet (Precision): Sınıflandırma modelinin pozitif olarak tahmin ettiği verilerin ne kadarının gerçekten pozitif olduğunu gösteren bir ölçüttür. Başka bir deyişle, modelin ne kadar isabetli bir şekilde "evet" dediğini gösterir(UYANIK & KASAPBAŞI, 2021). Hassasiyet ölçütünün formülü aşağıda verilmiştir.

$$\text{Hassasiyet} = \text{TP} / (\text{TP} + \text{FP}) \quad (3)$$

Duyarlılık (Recall): Duyarlılık, kullanılan modelin gerçekten pozitif olan verilerin ne kadarını pozitif olarak tahmin ettiğini gösteren bir ölçüttür. Modelin ne kadar kapsamlı bir şekilde "evet" dediğini gösterir. Formülü aşağıda verilmiştir(Kılıç ve diğerleri., 2022).

$$\text{Duyarlılık} = \text{TP} / (\text{TP} + \text{FN}) \quad (4)$$

F1 Skoru (F1 Score): Kullanılan modelin gerçekten pozitif olan verileri ne kadar başarılı bir şekilde tahmin ettiğini gösteren bir ölçüttür. Hassasiyet (precision) ve duyarlılık (recall) değerlerinin harmonik ortalaması alınarak hesaplanır(UYANIK & KASAPBAŞI, 2021). Formülü aşağıda verilmiştir.

$$\text{F1 Skoru} = 2 * (\text{Hassasiyet} * \text{Geri Çağırma}) / (\text{Hassasiyet} + \text{Geri Çağırma}) \quad (5)$$

1.4. Python Dili Kütüphaneleri

Python, makine öğrenmesi, veri analizi, web geliştirme, veri tabanı işlemleri ve daha birçok alanda kullanılabilen geniş bir standart kütüphaneye sahiptir. Bu kütüphaneler bulunan çeşitli algoritmalar makine öğrenmesi ile ilgili geliştirilen uygulamalarda veri analiz ve sınıflandırılmalarını oldukça kolaylaştırmaktadır. Gerçekleştirilen çalışmada kullanılan farklı kütüphaneler hakkında bilgi verilmiştir.

Pandas kütüphanesi, veri okuma ve yazma, veri temizleme ve dönüştürme, veri indeksleme ve seçme, veri gruplama ve toplulaştırma, zaman serisi analizi ve daha pek çok veri işleme işlevselliği sağlar. Özellikle veri bilimi ve veri analizi gibi alanlarda sıklıkla kullanılır(akademi40, 2023).

Numpy kütüphanesi, çok boyutlu diziler ve matrisler üzerinde çalışmak için kullanılır. Bilimsel hesaplama için temel bir araçtır ve genellikle veri işleme ve analizi, lineer cebir gibi matematiksel işlemler için kullanılır(coderspace, 2023).

Seaborn kütüphanesi, veri analizi sırasında verileri daha çekici ve etkili bir şekilde görselleştirmek için kullanılır. Çeşitli istatistiksel grafikler oluşturmak için kullanılan yüksek seviyeli bir arayüz sağlar. Örneğin, çizgi grafikleri, scatterplotlar, bar grafikleri, histogramlar, kutu grafikleri gibi grafik türlerini oluşturmak için kullanılabilir(akademi40, 2023).

Matplotlib kütüphanesi, verileri görselleştirmek için kullanılan güçlü bir kütüphanedir. Grafiklerin görünümünü özelleştirmek için de geniş olanaklar sunar. Bunlar arasında renkler, çizgi stilleri, etiketler, eksenlerin konumu ve ölçekleri gibi özellikler bulunur. Genellikle veri analizi, makine öğrenmesi ve bilimsel arařtırmalarda kullanılan temel bir araçtır(akademi40, 2023).

Scipy kütüphanesi, bilimsel ve teknik hesaplamalar için kullanılan bir kütüphanedir. Scipy.stats modülü istatistiksel testler, regresyon analizleri, frekans dağılımları, çeşitli test istatistikleri ve diğeri istatistiksel hesaplamalarda kullanılır(akademi40, 2023).

Scikit-learn kütüphanesi, kullanımı kolay ve verimli bir şekilde çeşitli makine öğrenimi algoritmalarını kullanma imkanı sunar. Sınıflandırma, regresyon, kümeleme, boyut indirgeme, model seçimi ve veri ön işleme gibi çeşitli makine öğrenimi işlevlerini destekler. sklearn.linear_model, sklearn.ensemble, sklearn.metrics, sklearn.model_selection, sklearn.impute gibi alt modülleri çalışmada kullanılmıştır(coderspace, 2023).

2. BÖLÜM

YÖNTEM

2.1. Araştırmanın Amacı

Bu araştırmanın temel hedefi, mobil uygulama güvenliği konusundaki kullanıcı farkındalığını ve uygulama ihtiyaçlarını derinlemesine anlayarak, kullanıcıların bir uygulamayı seçme, kullanma veya bırakma kararlarını etkileyen faktörleri makine öğrenimi modelleriyle analiz edip belirlemektir. Bu amaç doğrultusunda çalışmada beş tane hipotez kurulmuştur. Bunlar:

- Hipotez 1 (H1): Mobile uygulama kullanıcılarının uygulamayı bulma davranışını kullanıcının demografik özellikleri etkilemektedir.
- Hipotez 2 (H2): Mobile uygulama kullanıcılarının uygulamayı seçme davranışını kullanıcının demografik özellikleri etkilemektedir.
- Hipotez 3 (H3): Mobile uygulama kullanıcılarının uygulamayı bırakma davranışını kullanıcının demografik özellikleri etkilemektedir.
- Hipotez 4 (H4): Mobile uygulama kullanıcılarının uygulamayı bulma ve seçme davranışları arasında anlamlı bir ilişki vardır.
- Hipotez 5 (H5): Mobile uygulama kullanıcılarının uygulamayı seçme ve bırakma davranışları arasında anlamlı bir ilişki vardır.

2.2. Araştırmanın Modeli

Mobil uygulama kullanıcılarının güvenlik farkındalıklarının incelenmesine yönelik makine öğrenmesi modellerinin oluşturulabilmesi için, kullanıcıların uygulamayı bulma, seçme ve bırakma aşamalarındaki davranışları hakkında bilgiye ihtiyaç duyulmaktadır. Makine öğrenimi tekniklerinin kullanıldığı uygulamaların geliştirilmesi sürecinde karşılaşılan problemlere hızlı çözümler bulabilmek oldukça önemlidir. Bu çözümlerin bulunması, uygulamanın geliştirme sürecindeki verimliliği artırırken aynı zamanda zaman ve kaynak tasarrufu sağlar. Özellikle büyük veri kümeleriyle çalışıldığında veya karmaşık algoritmaların kullanıldığı durumlarda karşılaşılan hataların hızlı bir şekilde giderilmesi gerekebilir. Bu nedenle, uygulamanın geliştirileceği ortamın ve kullanılacak programlama dilinin, bu tür sorunlara hızlıca müdahale edebilmeyi kolaylaştıracak şekilde seçilmesi önemlidir. Bu durumlar göz önünde bulundurulduğunda açık kaynak kodlu Python programlama dili uygulama geliştirmede tercih edilmiştir. Python, basit ve okunabilir söz dizimine sahip yüksek seviyeli bir programlama dilidir. Genel amaçlı bir dil olmasının yanı sıra veri analizi, yapay zekâ, bilimsel hesaplama, web geliştirme ve otomasyon gibi çeşitli alanlarda kullanılır. Python'un bu özelliklerinden dolayı birçok alanda tercih edilen bir dil haline gelmiştir. Özellikle veri bilimi, yapay zekâ ve web geliştirme gibi alanlarda kullanımı oldukça yaygındır.

Uygulama geliştirilirken Python Programlama Dili Google Colab Platform üzerinden kullanılmıştır. Google Colab, Google tarafından sağlanan ücretsiz bir hizmettir ve Jupyter

Notebook ortamında Python programlama dili kullanarak kod yazmanıza ve çalıştırmanıza olanak tanır. Colab, bulut tabanlı bir hizmet olduğu için herhangi bir kurulum gerektirmez ve sadece internet bağlantısına ihtiyaç duyar. Colab, veri analizi, makine öğrenimi, yapay zeka ve daha birçok alanda kullanılan Python kütüphanelerinin kullanılmasına olanak tanır. Bu sebeplerden dolayı çalışmada geliştirme aracı olarak Google Colab kullanılmıştır. Kullanılan Python dilin de Pandas, Numpy, Seaborn, Matplotlib, Scipy ve Scikit-learn kütüphanesi kullanılmıştır.

Çalışmada veri seti olarak HARVARD Dataverse veritabanından faydalanılmıştır. Araştırmanın temel modeli, yarı deneysel desenle gerçekleştirilmiştir. Bu desen, deneysel ve gözlemsel verilerin birleştirilmesini sağlar. Bu sayede, deneysel gruplar oluşturulabilir ve araştırılan değişkenler arasındaki ilişkiler daha iyi anlaşılabilir. Yarı deneysel desen, araştırmacılara kontrol grupları oluşturma ve korelasyonlar üzerinde daha iyi bir kontrol sağlama imkanı sunar. Veri seti, analizlerin daha erişilebilir olması ve veri işleme sürecinin kolaylaştırılması amacıyla Excel programından faydalanılarak sadeleştirilmiştir. Veri seti analizleri makine öğrenimi yöntemleri kullanılarak yapılmıştır. Böylece veri setindeki örüntüler daha derinlemesine incelenmiş ve anlaşılabilir hale getirilmiştir.

2.3. Veri Seti

Araştırmada ihtiyaç duyulan bilgileri kapsayan veri seti HARVARD Dataverse veritabanından faydalanılmıştır(Lim ve diğerleri., 2015). Harvard Üniversitesi'ne ait olan Dataverse, araştırma verilerinin depolanması, paylaşılması, yayınlanması ve keşfedilmesini sağlayan bir platformdur. Araştırmacılar, veri setlerini yükleyebilir, verileri düzenleyebilir, açık erişim politikalarına uygun olarak paylaşabilir ve verilere erişmek için izin isteyebilirler. Dataverse, araştırma verilerinin kalıcı bir şekilde saklanmasını sağlayarak, veri yönetimi ve araştırma verilerinin paylaşımını kolaylaştırmayı amaçlar. Çalışmada kullanılan veri seti de açık erişime uygun bilgileri içermektedir. 15'ten fazla ülkeden 10.208 kişiyle mobil uygulama kullanım davranışları hakkında anket yapılmıştır. Bu ülkeler arasında ABD, Çin, Japonya, Almanya, Fransa, Brezilya, İngiltere, İtalya, Rusya, Hindistan, Kanada, İspanya, Avustralya, Meksika ve Güney Kore bulunmaktadır. Mobil Uygulama Kullanıcı Anketi'nde (Mobile App User Survey) katılımcılarına yöneltilen sorular: Kullandıkları uygulama mağazaları hangileridir, kullanıcıları mobil uygulama aramaya neyin yönelttiği, buldukları uygulamaları neden indirdikleri, kurulan uygulamayı neden terk ettikleri ve kullandıkları uygulama türleridir. Cinsiyet, yaş, medeni durum, uyruk, ikamet edilen ülke, ilk dil, etnik köken, eğitim düzeyi, meslek ve hane geliri dahil olmak üzere demografik özellikleri sorulmuştur. Kullanılan veri setinde bu sorulara ait cevap bilgileri bulunmaktadır. Veri Seti bilgilerini oluşturan mobile uygulama kullanıcılarına yöneltilen demografik özellikler ve uygulama davranış biçimlerini belirleyen sorular aşağıda Tablo 2.1' de sunulmuştur.

Tablo 2.1. Veri Setine Ait Kullanıcıya Yöneltilen Sorular

1	Bir mobil cihazınız var mı?
2	Hangi mobil cihazı kullanıyorsunuz?
3	Hangi uygulama mağazasını kullanıyorsunuz?
4	Uygulama aramak için uygulama mağazasını ne sıklıkla ziyaret ediyorsunuz?
5	Ayda ortalama kaç uygulama indiriyorsunuz?
6	Uygulamaları ne zaman arıyorsunuz?
7	Uygulamaları nasıl buluyorsunuz?
8	İndirilecek uygulamaları seçerken nelere dikkat ediyorsunuz?
9	Neden bir uygulama indiriyorsunuz?
10	Bir uygulamaya neden para harcarsınız?
11	Bir uygulamaya en çok ne kadar harcadınız?
12	Ortalama olarak her ay uygulamaya ne kadar harcıyorsunuz?
13	Uygulamaları neden derecelendiriyorsunuz?
14	Bir uygulamayı bırakmanıza neden olan nedir?
15	Hangi tür uygulamaları indiriyorsunuz?
16	Cinsiyetiniz nedir?
17	Yaşınız kaç?
18	Medeni durumunuz nedir?
19	Uyruğunuz nedir?
20	Yaşadığınız ülke neresidir?
21	Ana diliniz nedir?
22	Etnik kökeniniz nedir?
23	Tamamladığınız en yüksek eğitim seviyeniz nedir?
24	Kaç yıl eğitim aldınız?
25	Herhangi bir engeliniz var mı?
26	Şu anki çalışma durumunuz nedir?
27	Mesleğiniz nedir?
28	Hane geliriniz nedir?

2.4. Veri Ön İşleme Adımları

2.4.1. Veri setinin incelenmesi ve temizlenmesi

Bu bölümde veri setinin makine öğrenmesine hazır hale getirilmesi için bir takım işlemler uygulanmıştır. Makine öğrenmesi uygulamalarında kullanılan veri kümesinin anlaşılabilirliği uygulamalarda yapılan analizlerin başarı oranını etkilemektedir (Görmez & Bostancı, 2021). Veri kümesinin anlaşılabilirliğini artırmak için veri setinde yapılan ön işlem adımları ise analiz aşamasındaki iş yükünü azaltmaktadır (Feng ve diğerleri., 2020). Bir araştırmanın geçerliliğini ve başarı oranını etkilemesi için veri seti üzerinde temizleme gibi bazı işlemler yapılır. Makine öğrenmesi için hazır hale gelen veri seti analizler sürecinde algoritmaların daha kolay çalışması, kolay açıklanabilir olması ve aynı zamanda modellerin eğitim verilerinde aşırı

uyuma(overfitting) sorununun önüne geçilmesi için temizlenir. Çalışmada kullanılan veri setinde aşağıdaki işlemler yapılmıştır.

1. Veri setinde eksik veri içeren gözlemler uygulanan algoritmaların doğru bir şekilde çalışması için çıkarılmıştır.
2. Veri setinde bulunan verilerin biçimleri gözden geçirilerek uygun veri tiplerine, örneğin kategorik veriler sayısal değerlere dönüştürülmüştür.
3. Veri setinde bulunan ve analiz süreçlerine önem katmayacak olarak düşünülen bir takım kullanıcı demografik bilgileri veri setinden çıkarılmıştır.

Yukarıdaki maddelerin veri seti üzerine uygulanması sonucunda 10.208 kayıta sahip olan veri seti 5.317 kayıta indirilmiştir. Veri setinde kullanıcıya ait demografik özelliklerden, Cinsiyet, Yas, Eğitim durumu ve Mesleği olarak dört özellik yapılacak olan analizler için seçilmiştir. Kullanıcı davranışına yönelik sorulardan ise kullanıcıları mobil uygulama aramaya neyin yönelttiği, buldukları uygulamaları neden indirdikleri, kurulan uygulamayı neden terk ettikleri analizler için kullanılmak üzere seçilmiştir.

Tablo 2.1. Çalışma Katılımcılarının Demografik Özellikleri ve Sayıları

Demografik Özellikler		Katılımcı Sayısı
Cinsiyet	Kadın	2720
	Erkek	2644
Yaş Aralığı	15-25 yaş arası	1670
	26-35 yaş arası	1393
	36-50 yaş arası	1120
	50 üzeri yaş	1043
Eğitim Durumu	İlkokul	77
	Ortaokul	1477
	Lise	1100
	Mesleki Eğitim	399
	Lisans	1507
	Yüksek Lisans	586
Mesleği	Doktora	146
	Serbest Meslek	2940
	Öğrenci	1090
	Ev Hanımı	279
	İşsiz	515
	Emekli	455
	Diğer	36

Tablo 2.1 ve Tablo 2.2' de çalışmada kullanılacak veri seti üzerine yukarıda belirtilen işlemler uygulandıktan sonraki kullanıcı demografik özellikleri ve katılımcı sayıları ile mobil uygulama davranış nedenleri verilmiştir.

Tablo 2.2. Veri Setinde Yer Alan Kullanıcıların Uygulama Bulma-Seçme-Bırakma Kararlarını Etkileyen Nedenler

Uygulamaları nasıl buluyorsunuz?	
Bulma-1	En iyilerini seçmek için birkaç uygulamayı karşılaştırıyorum.
Bulma-2	Sunulan uygulamalar listesinde gördüğüm ilk uygulamayı indiriyorum.
Bulma-3	Uygulama mağazasının ön sayfasında yer alan uygulamaları arıyorum.
Bulma-4	En çok indirilenler tablosuna bakıyorum.
Bulma-5	İlğimi çekebilecek uygulamalar için rastgele göz atıyorum.
Bulma-6	Uygulama mağazasında anahtar kelimeler kullanarak arama yapıyorum.
Bulma-7	Uygulamaları inceleyen web sitelerini ziyaret ediyorum.
Bulma-8	Arama motorlarını (ör. Google) kullanıyorum.
İndirilecek uygulamaları seçerken nelere dikkat ediyorsunuz?	
Seçim-1	Diğer kullanıcıların yorumları
Seçim-2	Uygulamanın adı
Seçim-3	Uygulamayı indiren kullanıcı sayısı
Seçim-4	Simge (ör. Uygulamanın simgesi görsel olarak çekiciyse)
Seçim-5	Uygulamanın açıklaması
Seçim-6	Özellikler
Seçim-7	Uygulamayı derecelendiren kullanıcı sayısı
Seçim-8	Fiyat
Seçim-9	Yıldız derecelendirmesi
Seçim-10	Uygulamanın boyutu
Seçim-11	Ekran görüntüleri (ör. Çalışırken nasıl görüldüğünü görmek için)
Seçim-12	Uygulamayı kim geliştirdi
Bir uygulamayı kullanmayı bırakmanıza neden olan nedir?	
Bırakma-1	Çöküyor.
Bırakma-2	Daha iyi alternatifler buldum
Bırakma-3	Reklamlar can sıkıcı
Bırakma-4	Kullanımı zordur
Bırakma-5	Artık arkadaşlarım ve/veya ailem tarafından kullanılmıyor
Bırakma-6	İhtiyacım olan özellikler için fazladan ödeme yapmam gerekiyor
Bırakma-7	Uygulamayı unuttum
Bırakma-8	Sağladığı özelliklere ihtiyacım yok
Bırakma-9	Özel hayatıma giriyor
Bırakma-10	Çok yavaş
Bırakma-11	Bundan sıkıldım
Bırakma-12	İşe yaramıyor
Bırakma-13	Beklediğim özelliklere sahip değil
Bırakma-14	Artık ona ihtiyacım yok

2.4.2. Veri setinde eksik değerlerin incelenmesi ve doldurulması

Veri setinde eksik değerler için yapılabilecek farklı yöntemler bulunmaktadır. Bunlar eksik değerleri silme, doldurma, tahmine dayalı doldurma veya işaretleme gibi yöntemlerdir. Çalışmada kullanılan veri setinde modelleme sonuçlarını etkileyecek olan ve silinmesi durumunda veri kaybına yol açacak olan kullanıcı kayıtlarındaki eksik değerler doldurulmuştur. Eksik değerler, genellikle ortalama, medyan veya en yakın komşu değerler kullanılarak doldurulabilir. Bu yöntem, veri kaybını önlerken, modelin genel birleşimini artırabilir. Ancak, eksik değerlerin bakımı ve veri setinin doğasını korumak önemlidir çünkü yanlış aktarma verileri de hatalı bölünme yolu açılabilir. Kullanılan veri setinde yapılan modellemenin doğasına uygun olan (ortalama, medyan veya en yakın komşu değerler) seçilerek Şekil 2.1’ de görüldüğü gibi “0” değeri ile doldurulmuştur.

```
# Veri setini gözlemleyelim
print(data.head())

# Eksik değerleri kontrol edelim
print(data.isnull().sum())

# Eksik değerleri dolduralım (boş değerleri 0 ile doldurabiliriz)
data.fillna(0, inplace=True)
```

Şekil 2.1. Veri Seti Gözlemeleme, Eksik Değerleri Kontrol Etme ve Doldurmaya İlişkin Kod Parçası

2.4.3 Kategorik değerlerin dönüştürülmesi

Veri setinde bulunan bazı niteliklerin formatı kategorik olduğu görülmektedir. Makine öğrenmeleri algoritmalarında bu format da olan nitelikler kullanılamaz. Bundan dolayı kategorik formatta olan nitelikler sayısal formata dönüştürülmelidir.

```
label_encoder = LabelEncoder()
veri['birakma-1'] = label_encoder.fit_transform(veri['birakma-1'])
```

Şekil 2.2. Kategorik Değerlerin Sayısal Değerlere Dönüştürülmesine İlişkin Kod Parçası

Şekil 2.2’de kullanılan LabelEncoder sınıfı, her farklı kategorik değeri benzersiz bir sayıya atar. Bu sayede makine öğrenmesi modelleri gibi dijital değerlerle çalışan uygulamaların bu kategorik değerleri işlemesi daha kolay hale gelir. Bu durumda veri setinde kategorik değerler modelleme için hazır hale gelmiş bulunmaktadır.

2.5. Araştırmanın Sınırlılıkları

Araştırmanın sınırlılıkları aşağıda verilmiştir.

1. Araştırmada kullanılan veri seti düzenleme işlemi yapılmadan önce 10208 kullanıcı verisine sahipken veri seti temizleme işlemi yapıldıktan sonra bu sayı 5317 kullanıcı verisine düşmüştür.

2. Veri seti İngilizce dilindedir, anlaşılabilir olması için Türkçe diline çevrilmiştir.
3. Veri setinde kullanıcıya seçim için sunulan mobil uygulama marketlerinin sayıları ile sınırlıdır.

2.6. Modellerin Eğitilmesi Ve Test Edilmesi

Çalışmanın bu bölümüne kadar veri seti makine öğrenmesi modellemeleri için uygun hale getirilmiştir. Kullanılacak modellemelerde analizlerin anlamlı çıkabilmesi için veri setinde bulunan değişkenler özelliklerine göre bağımlı ve bağımsız değişken olarak tanımlanmıştır.

```
features = data[['cinsiyet', 'yas', 'egitim', 'meslek']]  
target = data['birakma-1']
```

Şekil 2.3. Bağımlı-Bağımsız Değişkenlerin Tanımlanmasına İlişkin Kod Parçasığı

Şekil 2.3’de görüldüğü gibi demografik öznitelik olan değişkenler bağımsız, kullanıcı davranışlarına ait olan ve değişebilen “bulma-seçme-bırakma” gibi değişkenlerde bağımlı değişken olarak tanımlanmıştır. Değişken tanımlamaları yapıldıktan sonra veri seti eğitim ve test kümelerine ayrılmıştır.

```
kf = KFold(n_splits=10, shuffle=True, random_state=42)
```

Şekil 2.4. Veri Setini Test ve Eğitim Veri Kümesine Ayırmaya İlişkin Kod Parçasığı

Yapılan çalışmada veri seti bölümlenmesinde Şekil 2.4 de verilen kod kullanılarak 10 katlı bir çapraz doğrulama yöntemi kullanılmıştır. Buna göre veri kümesi 10 alt küme (kat) halinde bölünmüştür. Yani, veri kümesi 10 eşit parçaya ayrılır ve her parça bir kez test verisi olarak kullanılırken, kalan 9 parça eğitim verisi olarak kullanılır. Bu işlem 10 kez tekrarlanır, her defasında farklı bir parça test verisi olarak seçilir. Çapraz doğrulama, modelin genelleme performansını daha iyi değerlendirmek için kullanılır ve veri kümesinin her bir parçasının hem eğitim hem de test için kullanılması sayesinde daha güvenilir sonuçlar elde edilir.

3. BÖLÜM

BULGULAR VE TARTIŞMA

3.1 Hipotez 1 İçin Makine Öğrenmesi Sonuçları

Veri seti eğitim için hazır hale geldikten sonra çalışmanın birinci hipotezi olan mobil uygulama kullanıcılarının demografik özelliklere göre uygulamayı bulma davranışlarının analizi yapılmıştır. Yapılan analizler için LR, RF ve SVM modeli kullanılmıştır.

Tablo 3.1. LR Modeline Göre H1 Hipotezinin Uygulanması

<i>Değişken</i>	<i>Doğruluk (Accuracy)</i>	<i>Hassasiyet (Precision)</i>	<i>Duyarlılık (Recall)</i>	<i>F1-Score (F-Measure)</i>
Bulma-1	0,750	0,720	1,000	0,830
Bulma-2	0,920	0,900	1,000	0,950
Bulma-3	0,790	0,780	1,000	0,880
Bulma-4	0,730	0,710	0,990	0,830
Bulma-5	0,700	0,640	1,000	0,780
Bulma-6	0,690	0,620	0,830	0,710
Bulma-7	0,790	0,760	1,000	0,860
Bulma-8	0,700	0,680	1,000	0,810

Tablo 3.1 de LR modeline göre mobil uygulama kullanıcılarının uygulama bulma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. Bulma 2 değişkeni olan “Sunulan uygulamalar listesinde gördüğüm ilk uygulamayı indiriyorum.” seçeneğinin demografik özellikler tarafından en çok etkilenen seçim olduğu görülmektedir. Yapılan analizde LR modelinde kullanıcıların demografik özelliklere göre Bulma-2 bağımlı değişkeninin etkinlenme doğruluk oranını 0,901 değerle tahmin ettiği görülmektedir.

Tablo 3.2. RF Modeline Göre H1 Hipotezinin Uygulanması

<i>Değişken</i>	<i>Doğruluk (Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(FMeasure)</i>
Bulma-1	0,750	0,720	0,850	0,780
Bulma-2	0,920	0,900	0,990	0,940
Bulma-3	0,790	0,710	0,890	0,840
Bulma-4	0,730	0,730	0,820	0,770
Bulma-5	0,700	0,680	0,790	0,780
Bulma-6	0,700	0,670	0,690	0,660
Bulma-7	0,790	0,770	0,900	0,830
Bulma-8	0,720	0,690	0,800	0,740

Tablo 3.2’de Random Forest modeline göre mobil uygulama kullanıcılarının uygulama bulma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları

görülmektedir. RF modeline göre en yüksek doğruluk oranı 0,895 değeri ile Bulma-2 değişkeninde elde edilmiştir.

Tablo 3.3. SVM Modeline Göre H1 Hipotezinin Uygulanması

Değişken	Doğruluk(Accuracy)	Hassasiyet(Precision)	Duyarlılık(Recall)	F1-Score(F-Measure)
Bulma-1	0,720	0,700	1,00	0,830
Bulma-2	0,930	0,910	1,00	0,950
Bulma-3	0,760	0,760	1,00	0,860
Bulma-4	0,700	0,690	1,00	0,810
Bulma-5	0,680	0,670	1,00	0,790
Bulma-6	0,670	0,650	1,00	0,750
Bulma-7	0,780	0,770	1,00	0,870
Bulma-8	0,700	0,690	1,00	0,810

Tablo 3.3'de SVM modeline göre mobil uygulama kullanıcılarının uygulama bulma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. SVM modeline göre en yüksek doğruluk oranı 0,930 değeri ile Bulma-2 değişkeninde elde edilmiştir.

Tablo 3.4. KNN Modeline Göre H1 Hipotezinin Uygulanması

Değişken	Doğruluk (Accuracy)	Hassasiyet (Precision)	Duyarlılık (Recall)	F1-Score (F-Measure)
Bulma-1	0,680	0,700	1,000	0,800
Bulma-2	0,910	0,900	1,000	0,950
Bulma-3	0,740	0,750	1,000	0,880
Bulma-4	0,660	0,690	0,990	0,830
Bulma-5	0,610	0,640	1,000	0,780
Bulma-6	0,570	0,620	0,830	0,710
Bulma-7	0,740	0,760	1,000	0,860
Bulma-8	0,620	0,680	1,000	0,810


Tablo 3.4'de KNN modeline göre mobil uygulama kullanıcılarının uygulama bulma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. KNN modeline göre en yüksek doğruluk oranı 0,910 değeri ile Bulma-2 değişkeninde elde edilmiştir.

Veri seti üzerinde kullanıcılar mobil uygulama araştırması sırasında 8 ayrı bulma davranışı sergilemektedir. Bu davranışları makine öğrenme algoritmaları ile tahmin sürecinde en iyi sonucu Bulma-2 "Sunulan uygulamalar listesinde gördüğüm ilk uygulamayı indiriyorum." değişkeninde elde etmiştir. Araştırmada, tüm bulma değişkenlerinin bir ortalaması alınarak yapılan son bir uygulama da ise Tablo 3.5'deki sonuçlar elde edilmiştir.

Tablo 3.5. H1 - Model Karşılaştırma Ölçütleri

<i>MAKİNE ÖĞRENME MODELLERİ</i>	<i>DOĞRULUK (ACCURACY)</i>	<i>HASSASİYET (PRECİSİON)</i>	<i>DUYARLILIK (RECALL)</i>	<i>F1-SCORE (F-MEASURE)</i>
<i>LR</i>	0,759	0,726	0,978	0,831
<i>RF</i>	0,763	0,734	0,841	0,793
<i>SVM</i>	0,743	0,730	1,000	0,834
<i>KNN</i>	0,691	0,718	0,978	0,828

Tablo 3.5’de H1 için dört farklı sınıflandırma algoritmasından LR, RF , SVM ve KNN modelinin eğitilen veri seti üzerinde yapılan analizlerin değerleri görülmektedir. Bu oranlara bakılarak mobil uygulama kullanıcılarının demografik özelliklerinin(yaş, cinsiyet, meslek, eğitim) uygulamayı bulma davranışları üzerinde etkisinin olduğu görülmektedir. Bu etkinin, RF’ de doğruluk değerinin 0,763 ile en yüksek değerde olduğu görülmüştür.



Şekil 3.1. H1 – Model Karşılaştırma Ölçütleri Grafiği

Şekil 3.1’ de H1 için kullanılan modellemelerin karşılaştırma ölçüt grafiği verilmiştir. Verilen grafikte SVM modelinde duyarlılık ölçütüne göre en yüksek değere 1,00 ulaşıldığı görülmektedir.

3.2. Hipotez 2 İçin Makine Öğrenmesi Sonuçları

Çalışmada kurulan ikinci hipotez kullanıcıların demografik özelliklere göre mobil uygulamayı seçme davranışlarının analiz edilmesidir.

Tablo 3.1. H2 - LR Modeline Göre H2 Hipotezinin Uygulanması

<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(FMeasure)</i>
Seçme-1	0,720	0,620	0,670	0,650
Seçme-2	0,860	0,860	1,000	0,920
Seçme-3	0,770	0,740	1,000	0,850
Seçme-4	0,890	0,880	1,000	0,940
Seçme-5	0,690	0,590	0,700	0,640
Seçme-6	0,680	0,560	0,790	0,660
Seçme-7	0,780	0,750	1,000	0,860
Seçme-8	0,650	0,540	0,400	0,460
Seçme-9	0,710	0,660	0,720	0,690
Seçme-10	0,770	0,770	1,000	0,870
Seçme-11	0,780	0,710	1,000	0,830
Seçme-12	0,900	0,890	1,000	0,940

Tablo 3.6' da LR modeline göre mobil uygulama kullanıcılarının uygulama seçme davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. Seçme-12 değişkeni olan "Uygulamayı kim geliştirdi?" seçeneğinin demografik özellikler tarafından en çok etkilenen seçim olduğu görülmektedir. Yapılan analizde LR modelinde kullanıcıların demografik özelliklere göre Seçme-12 bağımlı değişkeninin etkinlenme doğruluk oranını 0,900 değerle tahmin ettiği görülmektedir.

Tablo 3.2. H2 - RF Modeline Göre H2 Hipotezinin Uygulanması

<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Seçme-1	0,720	0,690	0,700	0,700
Seçme-2	0,860	0,860	0,960	0,900
Seçme-3	0,770	0,760	0,870	0,810
Seçme-4	0,890	0,880	0,970	0,920
Seçme-5	0,680	0,690	0,700	0,700
Seçme-6	0,670	0,650	0,700	0,700
Seçme-7	0,780	0,760	0,870	0,810
Seçme-8	0,670	0,670	0,700	0,700
Seçme-9	0,710	0,690	0,700	0,710
Seçme-10	0,770	0,770	0,920	0,830
Seçme-11	0,760	0,720	0,880	0,790
Seçme-12	0,910	0,890	0,970	0,930

Tablo 3.7'da RF modeline göre mobil uygulama kullanıcılarının uygulama seçme davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. RF modeline göre en yüksek doğruluk oranı 0,910 değeri ile Seçme-12 değişkeninde elde edilmiştir.

Tablo 3.3. H2 - SVM Modeline Göre H2 Hipotezinin Uygulanması

<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Seçme-1	0,620	0,710	0,700	0,700
Seçme-2	0,890	0,860	1,000	0,910
Seçme-3	0,800	0,740	1,000	0,840
Seçme-4	0,880	0,870	1,000	0,930
Seçme-5	0,610	0,600	1,000	0,710
Seçme-6	0,650	0,660	1,000	0,710
Seçme-7	0,750	0,750	1,000	0,860
Seçme-8	0,600	0,610	0,710	0,700
Seçme-9	0,680	0,670	0,700	0,710
Seçme-10	0,800	0,790	1,000	0,870
Seçme-11	0,790	0,780	1,000	0,840
Seçme-12	0,920	0,900	1,000	0,950

Tablo 3.8' de SVM modeline göre mobil uygulama kullanıcılarının uygulama seçme davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. SVM modeline göre en yüksek doğruluk oranı 0,920 değeri ile Secme-12 değişkeninde elde edilmiştir.

Tablo 3.4. H2 - KNN Modeline Göre H2 Hipotezinin Uygulanması

<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Seçme-1	0,560	0,650	0,700	0,700
Seçme-2	0,830	0,860	1,000	0,910
Seçme-3	0,710	0,730	1,000	0,840
Seçme-4	0,870	0,870	1,000	0,930
Seçme-5	0,540	0,600	1,000	0,710
Seçme-6	0,540	0,660	1,000	0,710
Seçme-7	0,720	0,730	1,000	0,860
Seçme-8	0,530	0,600	0,710	0,700
Seçme-9	0,560	0,610	0,700	0,710
Seçme-10	0,740	0,720	1,000	0,870
Seçme-11	0,680	0,710	1,000	0,840
Seçme-12	0,900	0,900	1,000	0,950

Tablo 3.9' da KNN modeline göre mobil uygulama kullanıcılarının uygulama seçme davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. KNN modeline göre en yüksek doğruluk oranı 0,900 değeri ile Secme-12 değişkeninde elde edilmiştir.

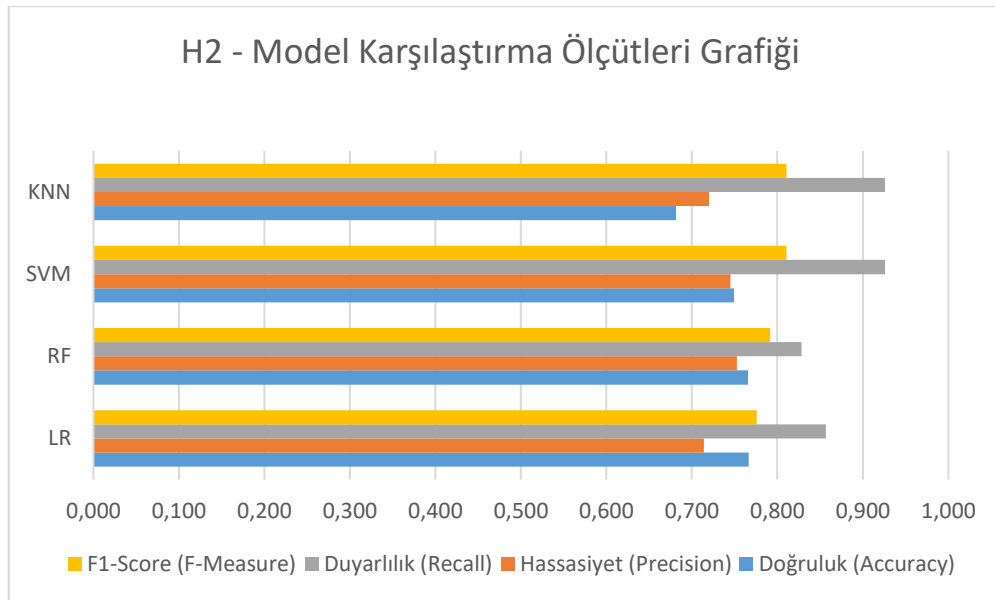
Veri seti üzerinde kullanıcılar mobil uygulama araştırması sırasında 12 ayrı seçme davranışı sergilemektedir. Bu davranışları makine öğrenme algoritmaları ile tahmin sürecinde en iyi sonucu Secme-12 “ Uygulamayı kim geliştirdi?” değişkeninde elde edilmiştir. Araştırmada, tüm

bulma deęişkenlerinin bir ortalaması alınarak yapılan son bir uygulamada ise Tablo 3.10' daki sonuçlar elde edilmiştir.

Tablo 3.5. H2 - Model Karşılaştırma Ölçütleri

<i>MAKİNE ÖĞRENME MODELLERİ</i>	<i>DOĞRULUK (ACCURACY)</i>	<i>HASSASİYET (PRECİSİON)</i>	<i>DUYARLILIK (RECALL)</i>	<i>F1-SCORE (F-MEASURE)</i>
<i>LR</i>	0,767	0,714	0,857	0,776
<i>RF</i>	0,766	0,753	0,828	0,792
<i>SVM</i>	0,749	0,745	0,927	0,811
<i>KNN</i>	0,682	0,720	0,926	0,811

Tablo 3.10' da ki deęerler incelendięinde kurulan hipotez için dört farklı sınıflandırma modeli kullanılmıştır. Kullanılan LR, RF, SVM ve KNN modelinin eęitilen veri seti üzerinde yapılan analizlerin doęruluk oranları görülmektedir. Kullanıcıların mobil uygulamayı seçme davranışını demografik özelliklerinin (yaş, cinsiyet, meslek, eęitim) etkisi açısından deęerlendirmek için tablo incelendięinde SVM modelinin duyarlılığı daha yüksek görülmektedir. Bu, demografik özelliklerin mobil uygulama seçimindeki etkisinin daha doęru bir şekilde tespit edilmesinde SVM modelinin tercih edilebileceęi anlamına gelmektedir. Bu oranlara bakılarak mobil uygulama kullanıcılarının demografik özelliklerinin uygulamayı seçme davranışları üzerinde etkisinin bulunduęu söylenebilmektedir.



Şekil 3.2. H2 Model Karşılaştırma Ölçütleri Grafięi

Şekil 3.2’de H2 için kullanılan modellemelerin karşılaştırma ölçüt grafiği verilmiştir. Verilen grafikte SVM modelinde duyarlılık ölçütüne göre en yüksek değere 0,927 ulaşıldığı görülmektedir.

3.3. Hipotez 3 İçin Makine Öğrenmesi Sonuçları

Çalışmada kurulan üçüncü hipotez kullanıcıların demografik özelliklere göre mobil uygulamayı bırakma davranışlarının analiz edilmesidir.

Tablo 3.1. H3 - LR Modeline Göre H3 Hipotezinin Uygulanması

<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Bırakma-1	0,780	0,670	0,990	0,790
Bırakma-2	0,730	0,660	0,980	0,780
Bırakma-3	0,800	0,780	1,000	0,880
Bırakma-4	0,780	0,750	1,000	0,850
Bırakma-5	0,930	0,920	1,000	0,960
Bırakma-6	0,790	0,780	1,000	0,870
Bırakma-7	0,860	0,870	1,000	0,930
Bırakma-8	0,780	0,790	1,000	0,880
Bırakma-9	0,850	0,830	1,000	0,910
Bırakma-10	0,770	0,720	1,000	0,810
Bırakma-11	0,720	0,700	0,890	0,770
Bırakma-12	0,780	0,730	1,000	0,820
Bırakma-13	0,750	0,720	1,000	0,810
Bırakma-14	0,670	0,620	0,950	0,720

Tablo 3.11’ de LR modeline göre mobil uygulama kullanıcılarının uygulama bırakma, kaldırma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. Bırakma-5 değişkeni olan “Artık arkadaşlarım ve/veya ailem tarafından kullanılmıyor.” Seçeneğinin demografik özellikler tarafından en çok etkilenen seçim olduğu görülmektedir. Yapılan analizde LR modelinde kullanıcıların demografik özelliklere göre Bırakma-5 bağımlı değişkeninin etkilenme doğruluk oranını 0,930 değerle tahmin ettiği görülmektedir.

Tablo 3.2. H3 - RF Modeline Göre H3 Hipotezinin Uygulanması

Değişkenler	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(FMeasure)</i>
Bırakma-1	0,780	0,710	0,790	0,730
Bırakma-2	0,740	0,690	0,780	0,730
Bırakma-3	0,800	0,780	0,890	0,830
Bırakma-4	0,770	0,760	0,870	0,800
Bırakma-5	0,920	0,920	0,980	0,950
Bırakma-6	0,790	0,780	0,910	0,840
Bırakma-7	0,860	0,870	0,960	0,910
Bırakma-8	0,780	0,800	0,910	0,850
Bırakma-9	0,860	0,860	0,940	0,890
Bırakma-10	0,770	0,720	0,810	0,740
Bırakma-11	0,720	0,720	0,710	0,710
Bırakma-12	0,780	0,750	0,830	0,760
Bırakma-13	0,740	0,720	0,820	0,740
Bırakma-14	0,670	0,630	0,680	0,700

Tablo 3.12’ de Random Forest modeline göre mobil uygulama kullanıcılarının uygulama bırakma, kaldırma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. RF modeline göre en yüksek doğruluk oranı 0,920 değeri ile Bırakma-5 değişkeninde elde edilmiştir.

Tablo 3.3. H3 - SVM Modeline Göre H3 Hipotezinin Uygulanması

Değişkenler	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Bırakma-1	0,700	0,690	1,00	0,810
Bırakma-2	0,690	0,670	1,00	0,790
Bırakma-3	0,800	0,770	1,00	0,870
Bırakma-4	0,780	0,740	1,00	0,850
Bırakma-5	0,940	0,940	1,00	0,970
Bırakma-6	0,800	0,780	1,00	0,870
Bırakma-7	0,900	0,860	1,00	0,920
Bırakma-8	0,790	0,760	1,00	0,870
Bırakma-9	0,870	0,840	1,00	0,920
Bırakma-10	0,710	0,690	1,00	0,820
Bırakma-11	0,690	0,680	1,00	0,880
Bırakma-12	0,780	0,760	1,00	0,840
Bırakma-13	0,750	0,740	1,00	0,810
Bırakma-14	0,690	0,680	1,00	0,750

Tablo 3.13’ de SVM modeline göre mobil uygulama kullanıcılarının uygulama bırakma, kaldırma davranışını oluşturan alt nedenlerinin demografik özelliklere göre etkilenme oranları görülmektedir. SVM modeline göre en yüksek doğruluk oranı 0,940 değeri ile Bırakma-5 değişkeninde elde edilmiştir.

Tablo 3.4. H3 - KNN Modeline Göre H3 Hipotezinin Uygulanması


<i>Değişkenler</i>	<i>Doğruluk(Accuracy)</i>	<i>Hassasiyet(Precision)</i>	<i>Duyarlılık(Recall)</i>	<i>F1-Score(F-Measure)</i>
Bırakma-1	0,650	0,680	1,00	0,810
Bırakma-2	0,610	0,650	1,00	0,790
Bırakma-3	0,740	0,760	1,00	0,870
Bırakma-4	0,730	0,740	1,00	0,850
Bırakma-5	0,930	0,940	1,00	0,970
Bırakma-6	0,740	0,760	1,00	0,870
Bırakma-7	0,860	0,860	1,00	0,920
Bırakma-8	0,750	0,720	1,00	0,870
Bırakma-9	0,830	0,830	1,00	0,920
Bırakma-10	0,650	0,650	1,00	0,820
Bırakma-11	0,620	0,640	1,00	0,880
Bırakma-12	0,640	0,720	1,00	0,840
Bırakma-13	0,630	0,700	1,00	0,810
Bırakma-14	0,540	0,650	1,00	0,750

Veri seti üzerinde kullanıcılar mobil uygulama araştırması sırasında 14 ayrı bırakma davranışı sergilemektedir. Bu davranışları makine öğrenme algoritmaları ile tahmin sürecinde en iyi sonucu bırakma-5 “ Artık arkadaşlarım ve/veya ailem tarafından kullanılmıyor.” değişkeninde elde edilmiştir. Araştırmada, tüm bırakma değişkenlerinin bir ortalaması alınarak yapılan son bir uygulamada ise Tablo 3.15’ deki sonuçlar elde edilmiştir.

Tablo 3.5. H3 - Model Karşılaştırma Ölçütleri

MAKİNE ÖĞRENME MODELLERİ	DOĞRULUK (ACCURACY)	HASSASİYET (PRECİSİON)	DUYARLILIK (RECALL)	F1-SCORE (F-MEASURE)
LR	0,785	0,753	0,986	0,841
RF	0,784	0,765	0,849	0,799
SVM	0,778	0,757	1,000	0,855
KNN	0,709	0,736	1,000	0,855

Tablo 3.15’ de ki değerler incelendiğinde kurulan hipotez için dört farklı sınıflandırma modeli kullanılmıştır. Kullanılan LR, RF, SVM ve KNN modelinin eğitilen veri seti üzerinde yapılan analizlerin doğruluk oranları görülmektedir. Kullanıcıların mobil uygulamayı seçme davranışını demografik özelliklerinin etkisi açısından değerlendirmek için tablo incelendiğinde LR modelinin doğruluk değerinin daha yüksek görülmektedir. Bu, demografik özelliklerin mobil uygulama seçimindeki etkisinin daha doğru bir şekilde tespit edilmesinde SVM modelinin tercih edilebileceği anlamına gelmektedir.



Şekil 3.3. H3 Model Karşılaştırma Ölçütleri Grafiği

Şekil 3.3’ de H3 için kullanılan modellemelerin karşılaştırma ölçüt grafiği verilmiştir. Verilen grafikte SVM ve KNN modelinde duyarlılık ölçütüne göre en yüksek değere 1,00 ulaşıldığı görülmektedir.

3.4. Hipotez 4 İçin Modellerin Eğitilmesi ve Test Edilmesi

Çalışmada kurulan dördüncü hipotez kullanıcıların mobil uygulamayı bulma-seçme davranışları arasında herhangi bir anlamlı ilişki olup olmadığıdır. Bu analizi yapmak için bağımlı değişkenlerin birbiri ile arasındaki ilişkiyi ve etkileme durumlarını test eden algoritma kullanılmıştır. “Bulma” ve “seçme” değişkenleri arasındaki ilişkiyi test etmek için Pearson Korelasyon modeli kullanılmıştır. Bu modelde “bulma” değişkeni ile “secim” değişkenleri arasında çapraz ilişkiye bakılmıştır. Bu model sonuçlarına göre Ortalama Pearson Korelasyon Katsayısı: 0.215 çıkmıştır. Bu sonuçlara göre mobil uygulamayı “bulma” ve “seçme” durumları arasında pozitif yönde zayıf bir ilişki olduğunu gösterir. Bu modele göre de kullanıcıların mobil uygulamayı seçmesinin bulma davranışı ile ilişkili olduğu görülmektedir.

3.5. Hipotez 5 İçin Modellerin Eğitilmesi ve Test Edilmesi

Çalışmada kurulan beşinci hipotez kullanıcıların mobil uygulamayı seçme-bırakma davranışları arasında herhangi bir anlamlı ilişki olup olmadığıdır. Bu analizi yapmak için bağımlı değişkenlerin birbiri ile arasındaki ilişkiyi ve etkileme durumlarını test eden algoritma kullanılmıştır. “seçme” ve “bırakma” değişkenleri arasındaki ilişkiyi test etmek için Pearson Korelasyon modeli kullanılmıştır. Bu modelde “seçme” değişkeni ile “bırakma” değişkenleri arasında çapraz ilişkiye bakılmıştır. Bu model sonuçlarına göre Ortalama Pearson Korelasyon

Katsayısı: 0.230 çıkmıştır. Bu sonuçlara göre mobil uygulamayı “seçme” ve “bırakma” değişkenleri arasında zayıf derecede bir pozitif ilişki olduğunu gösterir. Bu modele göre de kullanıcıların mobil uygulamayı bırakmasının seçme davranışı ile ilişkili olduğu görülmektedir.



SONUÇ VE ÖNERİLER

Farklı uygulama mağazalarında çok çeşitli ve sayıca fazla uygulamanın yer alması uygulamaların güvenlik takibinin yapılmasını zorlaştırmaktadır. Kullanıcıların bu uygulama kalabalığı içinde güvenli uygulamayı bulmaları ve kullanmaları zorlaşmaktadır. Bu durum karşısında kullanıcıların bir uygulamayı bulma-seçme ve bırakma davranışlarının neye göre şekillendiği önem arz etmektedir. Bu çalışmada mobil uygulama kullanıcılarının demografik özelliklerinin uygulamayı bulma-seçme ve bırakma davranışlarını ne yönde etkilediğine bakılmıştır. Ayrıca kullanıcı davranışlarına ait bağımlı değişkenler olan uygulamayı bulma-seçme ve bırakma davranışları arasındaki korelasyonlarına da incelenmiştir.

Çalışmada HARVARD Dataverse veri tabanından elde edilen veri seti kullanılmıştır. Veri seti üzerine eksik veri içeren gözlemlerin çıkarılması sonucunda 10.208 kayıta sahip olan veri seti 5.317 kayıta indirilmiştir. Veri setinde bulunan kategorik veriler makine öğrenimi modelleri yapılabilmesi için sayısal değerlere dönüştürülmüştür. Veri setinde analiz süreçlerine önem katmayacağı düşünülen bir takım kullanıcı demografik bilgileri çıkartılmıştır. Hazır hale getirilen veri seti, kullanıcı davranışlarının etkilenme durumları makine öğrenme teknikleri ile analiz edilerek yorumlanmıştır. Makine öğrenme modellerinden kullanılan veri seti yapısına uygun olan kullanıcı demografik özellikler ve davranışların analizi için LR, RF, SVM ve KNN modeli kullanılmıştır. Uygulanan dört farklı modelin doğruluk, hassasiyet, duyarlılık ve F1 Score değerleri karşılaştırılmış olup H1 için SVM modeli 0,930 doğruluk değeri ile en yüksek tahmini yapmıştır. LR modelinde doğruluk değeri 0,920 LF modelinde doğruluk değeri 0,920 KNN modelinde ise doğruluk değeri 0,910 olarak gözlemlenmiştir. H2 için SVM modeli 0,920 doğruluk değeri ile en yüksek tahmini yapmıştır. LR modelinde doğruluk değeri 0,900 LF ve KNN modelinde ise doğruluk değeri 0,910 olarak gözlemlenmiştir. H3 için SVM modeli 0,940 doğruluk değeri ile en yüksek tahmini yapmıştır. LR modelinde doğruluk değeri 0,930 LF modelinde doğruluk değeri 0,920 KNN modelinde ise doğruluk değeri 0,930 olarak gözlemlenmiştir.

Bu değerlere göre kullanıcıların demografik özelliklerinin mobil uygulamayı bulma, seçme ve bırakma davranışlarını yapay zeka algoritmalarının tahminlerinin yüksek olduğu tespit edilmiştir.

Ayrıca, kullanıcı davranışları olan mobil uygulamayı bulma, seçme ve bırakma durumlarının birbirleri ile aralarında bir ilişki olup olmadığına bakılmıştır. Bu ölçüm için Pearson Korelasyon modeli kullanılarak yapılan analizde kullanıcıların bir uygulamayı seçme davranışının uygulamayı bulma davranışı tarafından etkilenme oranının 0,215 olarak görülmüştür. Bu veri neticesinde de kullanıcıların uygulamayı seçme davranışının uygulama bulma davranışından pozitif yönde düşük düzeyde etkilendiği söylenebilir. Kullanıcıların uygulamayı bırakma davranışlarında uygulamayı seçme davranışlarının etkili olup olmadığını görmek için Pearson Korelasyon modeli ile analiz yapıldı doğruluk oranı 0,230 olarak hesaplanmıştır. Bu değerler

sonucunda ise kullanıcıların mobil uygulamayı bırakma davranışı uygulamayı seçme davranışı tarafından düşük düzeyde pozitif olarak etkilendiği görülmektedir.

Yapılan literatür taramaları sonrasında mobil uygulamalarında kullanıcı davranışlarını ölçen ve analiz eden çalışmaların az olduğu görülmektedir. Kullanıcı özellik ve davranışlarını makine öğrenmeleri ile analiz eden bir çalışmanın ise olmadığı görülmektedir. Bu sebeple yapılan çalışma bundan sonraki çalışmalara yeni bir bakış açısı sunarak, kullanıcıların mobil uygulamaları bulma, seçme ve terk etme davranışları üzerindeki demografik özelliklerin etkisini daha iyi anlaşılmasına yardımcı olacaktır. Bundan sonraki çalışmalarda, farklı sektörlerdeki uygulamalar ve farklı demografik gruplar üzerinde benzer analizlerin yapılması, bu alandaki bilgi ve anlayışı geliştirecektir. Ayrıca, kullanıcı davranışlarını etkileyen diğer faktörlerin (örneğin, uygulama tasarımı, kullanıcı deneyimi vb.) daha detaylı bir şekilde incelenmesi, mobil uygulama geliştiricilerine rehberlik edeceği düşünülmektedir.

Yapay zeka algoritmalarında bu çalışmada kullanılan LR, RF ve SVM modellerinin dışında farklı algoritmalar kullanılarak farklı sonuçlar elde edilebilir. Çalışmanın farklı algoritmalarla denenmesi, elde edilen sonuçların güvenilirliğini artırabilir ve bulguların daha genellenmesi sağlanabilir. Aynı zamanda farklı algoritmaların kullanılması ve sonuçların karşılaştırılması yapay zeka ve makine öğrenmesi alanındaki araştırmalara katkıda bulunabilir. Elde edilen sonuçlara bakılarak en iyi tahmin yapabilen algoritma bulunabilir ve çalışmalar genişletilebilir.

Yapılan tez çalışmasında kullanılan veri setini farklı ülkelerden kullanıcılar oluşturmaktadır. Bu çalışmanın bir sonraki adımı olarak veri setinin yeniden işlenerek ülke sınırları içerisinde farklı coğrafi bölgelerdeki kullanıcı gruplarına odaklanmak olabilir. Bu şekilde, demografik özelliklerin ve davranışların coğrafi faktörlerden nasıl etkilendiği daha ayrıntılı bir şekilde incelenebilir. Ayrıca, farklı kültürel ve sosyo-ekonomik yapıların mobil uygulama kullanımı üzerindeki etkilerini anlamak için de çalışma üzerinde farklı analizler yapılabilir. Bu çalışma, mobil uygulama geliştiricilerine ve pazarlamacılarına farklı coğrafi bölgelerdeki kullanıcıları daha iyi anlama ve hedefleme konusunda önemli bir yol gösterici olabilir.

Yapay zekanın her alanda kullanılmasının olumlu sonuçlarının yanı sıra bazı olumsuz taraflarının da unutulmaması gerekir. Özellikle kişisel verilerin korunması, etik sorunların ortaya çıkması, sonuçların küçük veri setleri ile denenmesi sonucunda yanlış sonuçların elde edilmesi gibi olumsuz etkileri olmaktadır.

KAYNAKÇA

- akademi40. (2023). *Sık Kullanılan Python Kütüphaneleri*. <https://www.akademi40.org/python-kutuphaneleri>
- Akbulut, S. (2022). *Makine Öğrenmesi ve Derin Öğrenme Yöntemleri Kullanılarak Bist100 Endeksi İle Emtia, Döviz Fiyatları ve Gelişmekte Olan Ülkelerin Borsa Endeksleri Arasındaki İlişkinin İncelenmesi*. 8.5.2017, 2003–2005.
- Akdeniz, A. C. (2022). Makine Öğrenmesi Yöntemleri Kullanılarak Uzaktan Eğitim Konulu Türkçe Tweetlerin Duygu Analizi. *Journal of Economic Perspectives*, 2(1), 1–4.
- Aksaç, C., & Dikmen, M. (2023). *Makine Öğrenimi Kullanarak Tweet Popülarite Tespiti için Karşılaştırmalı Bir Çalışma* (Vol. 4, Issue 1, pp. 88–100).
- Arslan, R. S., Doğru, İ. A., & Barışcı, N. (2017). Android Mobil Uygulamalar için İzin Karşılaştırma Tabanlı Kötücül Yazılım Tespiti. *Journal of Polytechnic*, 20(1), 175–189. <https://dergipark.org.tr/tr/download/article-file/467150>
- Bahrini, M., Meissner, M., Malaka, R., Wenig, N., & Sohr, K. (2019). Happypermi: Presenting Critical Data Flows in Mobile Application to Raise User Security Awareness. *Conference on Human Factors in Computing Systems - Proceedings*. <https://doi.org/10.1145/3290607.3312914>
- Bal, E. (2017). Teknoloji Çağında Cep Telefonu Kullanım Alışkanlıkları ve Motivasyonlar: Selçuk Üniversitesi Öğrencileri Üzerine Bir İnceleme. *Humanities Sciences*, 4(1), 9–15. <https://doi.org/10.12739/NWSA.2017.12.3.4C0220>
- Balapur, A., Nikkhah, H. R., & Sabherwal, R. (2020). Mobile application security: Role of perceived privacy as the predictor of security perceptions. *International Journal of Information Management*, 52, 102063. <https://doi.org/10.1016/j.IJINFOMGT.2019.102063>
- Bilgili, M. İ. (2014). *Adaptif bağlam bilinçli mobil uygulama geliştirme*. Yayımlanmamış Yüksek Lisans Tezi Gazi Üniversitesi, Bilişim Enstitüsü, Türkiye. <https://avesis.gazi.edu.tr/yonetilen-tez/2a1f0181-1409-4c04-ba2e-5fe53d24435d/adaptif-baglam-bilincli-mobil-uygulama-gelistirme>
- Bölük, N., Uçar, Ö., & Inner, A. B. (2019). Mobil Robotlarda Navigasyon Problemi için Pekiştirmeli Öğrenme. *Türkiye Robotbilim Konferansı, June*, 40–44.
- Btnet. (2024). *Android Uygulama Yüklerken Dikkat Etmeniz Gerekenler*. <https://www.btnet.com.tr/android-uygulama-yuklerken-dikkat-etmeniz-gerekenler-1020>
- Buildfire. (2024). *Mobile App Download Statistics & Usage Statistics (2024)*. <https://buildfire.com/app-statistics/>
- Büyükgöze, S. (2019). *Mobil Uygulama Marketlerinin Güvenlik Modeli İncelemeleri Security Model Investigations of Mobile Application Markets*. 9–18.
- Çelik, R. (2018). *Mobil Uygulamalarda Kullanıcı Sürekliliği İçin Yaşam Döngüsü Yönetiminde Büyük Veri Analiz Yöntemlerinin Geliştirilmesi*.
- Chen, C., Zhang, K. Z. K., Gong, X., Zhao, S. J., Lee, M. K. O., & Liang, L. (2017). Understanding compulsive smartphone use: An empirical test of a flow-based model. *International Journal of Information Management*, 37(5), 438–454. <https://doi.org/10.1016/j.IJINFOMGT.2017.04.009>
- coderspace. (2023). *En Popüler Python Kütüphaneleri | Coderspace Blog*. <https://coderspace.io/blog/en-populer-python-kutuphaneleri/>
- Çoğun, H., Parlar, İ., & Üzmuş, H. (2016). *International Congress of Engineering and Natural Sciences Studies* (Vol. 4, Issue 1).
- COŞAR, M., & DENİZ, E. (2021). Makine Öğrenimi Algoritmaları Kullanarak Kalp Hastalıklarının Tespit

- Edilmesi. *European Journal of Science and Technology*, 28, 1112–1116. <https://doi.org/10.31590/ejosat.1012986>
- DEMİREL, Y., & DEMİREL, G. (2023). Deep Learning Based Approach for Classification of Mushrooms. *Gazi University Journal of Science Part A: Engineering and Innovation*, 10(4), 487–498. <https://doi.org/10.54287/gujsa.1355751>
- Dilki, G., & Deniz Başar, Ö. (2020). İşletmelerin İflas Tahmininde K- En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 19(38), 224–233.
- Doğan, S., & Büyükkör, Y. (2022). Makine Öğrenmesi ile Finansal Zaman Serisi Tahminleme. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 24(3), 1205–1230. <https://doi.org/10.26745/ahbvuibfd.1191080>
- Dündar, D. R., Sarı Çiçek, İ., Çınar, E., & Yazıcı, A. (2021). Kestirimci Bakımda Makine Öğrenmesi: Literatür Araştırması. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29(2), 256–276. <https://doi.org/10.31796/ogummf.873963>
- Eker, R., Alkış, K. C., Uçar, Z., & Aydın, A. (2023). Ormancılıkta makine öğrenmesi kullanımı. *Türkiye Ormancılık Dergisi*, 24(2), 150–177. <https://doi.org/10.18182/tjf.1282768>
- Elmas, Ş. E. (2019). *Sosyal Medya Mesajlarının Veri Madenciliği Yöntemi ile Duygu Analizi (Sivas İli Örneği)*. Sivas Cumhuriyet Üniversitesi.
- Feng, Y., Wang, D., Yin, Y., Li, Z., & Hu, Z. (2020). An XGBoost-based casualty prediction method for terrorist attacks. *Complex and Intelligent Systems*, 6(3), 721–740. <https://doi.org/10.1007/s40747-020-00173-0>
- Gökalp, Ö. (2022). *Makine Öğrenmesi - Machine Learning*. January, 14.
- Gökce, K. G., Şahinaslan, E., & Dincel, S. (2021). Mobil Yaşamda Siber Güvenlik Yaklaşımı. *Uuslararası Bilgi Güvenliği ve Kriptoloji Konferansı, February*, 214–221.
- Görmez, B., & Bostancı, G. E. (2021). *Adli Bilişimde Makine Öğrenmesi : Makine Öğrenmesi Algoritmaları ile Terör*.
- IBM. (2023). *What is the k-nearest neighbors algorithm? | IBM*. <https://www.ibm.com/topics/knn>
- İmamoğlu, N., Aydın, E., & Efe, M. Ö. (2009). Döner Ters Sarkaç Sisteminin Pekiştirmeli Öğrenme Algoritmaları ile Kontrolü. *Otomatik Kontrol Türk Milli Komitesi, Otomatik Kontrol Ulusal Toplantısı TOK'09*.
- Inukollu, V. N., Keshamoni, D. D., Kang, T., & Inukollu, M. (2014). FACTORS INFLUENCING QUALITY OF MOBILE APPS: ROLE OF MOBILE APP DEVELOPMENT LIFE CYCLE. *International Journal of Software Engineering & Applications (IJSEA)*, 5(5). <https://doi.org/10.5121/ijsea.2014.5502>
- Karakethüdaoğlu, M. (2019). *Sistemlerin geliştirilmesinde mobil uygulamalarda kullanıcı geri bildirimlerinin önemi Türkiye e-nabız örneği*.
- Khalid, H., Shihab, E., Nagappan, M., & Hassan, A. E. (2015). What do mobile app users complain about? *IEEE Software*, 32(3), 70–77. <https://doi.org/10.1109/MS.2014.50>
- Kılıç, Ö. D., Aydemir, M. E., & Özdemir, P. Ö. (2022). Uçak Görüntülerinin Sınıflandırılmasında Farklı Yapay Zekâ Algoritmalarının Performansı. *6 Th International Symposium on Innovative Approaches in Smart Technologies*, 84–88.
- Kıraç, F. (2021). Arazi Örtüsü Sınıflandırması için Makine Öğrenmesi Yaklaşımı. *İstanbul Sabahattin Zaim Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Bilimi Mühendisliği Bilim Dalı*.
- Koçak, N., Şanlıöz, K., & Dilek, E. (2013). Değişen Dünya , Dönüşen Pazarlama : Türkiye Turizm Sektöründen Öncü Bir Mobil Uygulama Örneği. *Anatolia Turizm Araştırmaları Dergisi*, 4220, 250–

- Koyuncu, M., & Pusatlı, T. (2019). Security Awareness Level of Smartphone Users: An Exploratory Case Study. *Mobile Information Systems, 2019*. <https://doi.org/10.1155/2019/2786913>
- Kuyucu, Y. E. (2012). *Lojistik Regresyon Analizi (LRA), Yapay Sinir Ağları (YSA) Ve Sınıflandırma ve Regresyon Ağaçları(C&RT) Yöntemlerinin Karşılaştırılması Ve Tıp Alanında Bir Lojistik Regresyon Analizi(LRA), Yapay Sinir Ağları(YSA)*.
- La Polla, M., Martinelli, F., & Sgandurra, D. (2013). A survey on security for mobile devices. *IEEE Communications Surveys and Tutorials, 15*(1), 446–471. <https://doi.org/10.1109/SURV.2012.013012.00028>
- Lim, S. L., Bentley, P. J., Kanakam, N., Ishikawa, F., & Honiden, S. (2015). Investigating country differences in mobile app user behavior and challenges for software engineering. *IEEE Transactions on Software Engineering, 41*(1), 40–64. <https://doi.org/10.1109/TSE.2014.2360674>
- Mahesh, B. (2019). Machine Learning Algorithms-A Review. *Technical Report in International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
- Namlı, Ç. (2010). *Mobil Uygulamaların Kullanılabilirliğinin Değerlendirilmesi*. Yayımlanmamış Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- Statista. (2023). *Annual number of mobile app downloads worldwide 2023 | Statista*. <https://www.statista.com/statistics/271644/worldwide-free-and-paid-mobile-app-store-downloads/>
- Statista. (2024). *Mobile network subscriptions worldwide*. <https://www.statista.com/statistics/330695/number-of-smartphone-users-worldwide/>
- Swiftspeed. (2024). *2024 App Download Statistics, Usage Statistics, and Revenue Statistics - Swiftspeed App Builder*. <https://swiftspeed.app/app-statistics/>
- Truelist. (2024). *Apps Statistics 2024*. <https://truelist.co/blog/apps-statistics/>
- UĞUR, N. G. (2015). *Üniversite Öğrencilerinin Mobil Uygulamaları kabulünü etkileyen faktörlerin belirlenmesine yönelik bir araştırma: Sakarya Üniversitesi örneği*.
- Unal, P. (2015). *an Analysis on User Profiles and Usage Preferences for Mobile*. August.
- Uplandsoftware. (2024). *App Uninstall Statistics 2018: 21% App Abandonment | Localytics*. <https://uplandsoftware.com/localytics/resources/blog/21-percent-of-users-abandon-apps-after-one-use/>
- Uslu, B., Gür, Ş., Eren, T., & Özcan, E. (2020). Mobil Uygulama Seçiminde Etkili Olan Kriterlerin Belirlenmesi ve Örnek Uygulama. *İstanbul İktisat Dergisi, 70*(1), 113–139. <https://doi.org/10.26650/ISTJECON2019-0022>
- UYANIK, F., & KASAPBAŞI, M. C. (2021). Telekomünikasyon Sektörü için Veri Madenciliği ve Makine Öğrenmesi Teknikleri ile Ayrılan Müşteri Analizi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9*(3), 172–191. <https://doi.org/10.29130/dubited.807922>
- Wu, D., Moody, G. D., Zhang, J., & Lowry, P. B. (2020). Effects of the design of mobile security notifications and mobile app usability on users' security perceptions and continued use intention. *Information & Management, 57*(5), 103235. <https://doi.org/10.1016/J.IM.2019.103235>
- Xiong, L., & Yao, Y. (2021). Study on an adaptive thermal comfort model with K-nearest-neighbors (KNN) algorithm. *Building and Environment, 202*, 108026. <https://doi.org/10.1016/J.BUILDENV.2021.108026>
- Zargham, N., Bahrini, M., Volkmar, G., Sohr, K., Wenig, D., & Malaka, R. (2019). What could go wrong? Raising mobile privacy and security awareness through a decision-making game. *CHI PLAY 2019 - Extended Abstracts of the Annual Symposium on Computer-Human Interaction in Play, 805–812*.

<https://doi.org/10.1145/3341215.3356273>

Zhu, H., Xiong, H., Ge, Y., & Chen, E. (2014). Mobile app recommendations with security and privacy awareness. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 951–960. <https://doi.org/10.1145/2623330.2623705>

