

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
EL VE YÜZ ANALİZİ TAHMİNLEMESİ**

YÜKSEK LİSANS TEZİ

Hüsneİrem KAYA

Bilgisayar Mühendisliği Anabilim Dalı

OCAK 2025

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
EL VE YÜZ ANALİZİ TAHMİNLEMESİ**

YÜKSEK LİSANS TEZİ

Hüsneİrem KAYA

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr.Üyesi Kayhan AYAR

OCAK 2025

Hüsneİrem KAYA tarafından hazırlanan “Makine Öğrenmesi Yöntemleri İle El Ve Yüz Analizi Tahminlemesi” adlı tez çalışması 22.01.2025 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Dr.Öğr. Üyesi Kayhan AYAR (Danışman)**
Sakarya Üniversitesi

Jüri Üyesi : **Dr.Öğr. Üyesi Gülözar ÇİT**
Sakarya Üniversitesi

Jüri Üyesi : **Dr.Öğr. Üyesi Muhammed Ali Nur ÖZ**
Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE EL VE YÜZ ANALİZİ TAHMİNLEMESİ**” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(...../...../2024).

(imza)

Hüsnelrem KAYA







TEŞEKKÜR

Yüksek lisans eğitimim boyunca, değerli bilgi, deneyim ve tecrübelerinden faydalandığım, tez çalışmamın planlamasından yazılmasına kadar tüm aşamalarında beni yönlendiren ve destekleyen danışman hocam Dr. Öğr. Üyesi Kayhan AYAR'a sonsuz teşekkürlerimi sunarım.

Her zaman yanımda olan ve desteklerini hiçbir zaman esirgemeyen sevgili aileme; canım annem Hülya KAYA, babam Mehmet KAYA, kardeşim Harun KAYA ve nişanlım Mustafa KEŞKÜŞ'e sonsuz minnettarım. Sizlerin desteği olmadan bu başarıya ulaşmam mümkün olmazdı. Hepinize gönülden teşekkür ediyorum.

Hüsneİrem KAYA



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Problemin Tanımı	1
1.2. Literatür Araştırması	4
2. KULLANILAN YÖNTEMLER VE METOTLAR	11
2.1. Makine Öğrenmesi	11
2.1.1. Denetimli öğrenme	12
2.1.1.1. Regresyon yöntemi	14
2.1.1.2. Sınıflandırma yöntemi	14
2.1.2. Denetimsiz öğrenme	14
2.2. Tkinter Kütüphanesi	15
2.3. OpenCv Kütüphanesi	18
2.4. DeepFace Kütüphanesi	19
2.5. Random Forest	21
2.6. KNN	23
3. DENEYSEL ÇALIŞMALAR VE UYGULAMALAR	25
3.1. El Analizi	25
3.1.1. Verilerin toplanması	25
3.1.2. Verilerin formatlanması	26
3.1.3. Verilerin işlenmesi	27
3.1.3.1. Eksik Verilerin Tespiti ve İşlenmesi	27
3.1.4. Veri ölçeklendirme ve normalizasyon	28
3.1.5. Algoritmanın belirlenmesi	28
3.1.6. Model eğitim süreci	31
3.1.7. Verilerin test edilmesi	32
3.2. Yüz Analizi	33
3.2.1. Yüz analizi süreci ve algoritmalar	33
3.3. Gerçekleştirilen Uygulama ve Arayüz Tasarımı	34
3.3.1. Yüz Analizi	34
3.3.2. El Analizi	34
3.3.3. Uygulama Arayüzü	35
3.3.4. Kullanıcı deneyimi ve sonuçlar	35
3.4. Kullanılan Algoritmaların Karşılaştırılması	35
4. SONUÇLAR	39

KAYNAKÇA	41
EKLER.....	45
ÖZGEÇMİŞ.....	53



KISALTMALAR

CNN	: Convolutional Neural Network
CS	: Kosinüs Benzerliği
CSAIL	: Computer Science & Artificial Intelligence Laboratory
CSV	:Comma-Separated Values
DNN	: Deep Neural Network
GUI	: Graphical User Interface
KNN	: K-En Yakın Komşu
MSE	: Mean Squared Error
OpenCV	: Open Source Computer Vision Library
ROI	: Return On Investment
DL	: Derin Öğrenme
SVC	:Support Vector Classifier)
TL	: Transfer Öğrenme



TABLO LİSTESİ

Sayfa

Table 3.1. Kullanılan algoritmalar ve elde edilen sonuçlar.....	37
--	----





ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Akıl çizgisi, kalp çizgisi ve hayat çizgisi [6]	2
Şekil 2.1. Denetimli öğrenme modeli örnek gösterimi	12
Şekil 2.2. Sınıflandırma ve Regresyon modeli örnek gösterimi [22]	13
Şekil 2.3. Geliştirilen sistemin arayüz görüntüsü başlangıç kısmı	16
Şekil 2.4. Geliştirilen sistemin arayüz görüntüsü bitiş kısmı	17
Şekil 2.5. Yüz görüntüsü algılama.	19
Şekil 2.6. Yüz görüntüsü analiz tahminlemesi.	21
Şekil 2.7. Random Forest Modeli Örnek Gösterimi [29].....	23
Şekil 2.8. K-En yakın komşu sınıflandırması modeli örnek gösterimi [33]	24
Şekil 3.1. Anket katılımcı yaş dağılımı.....	26
Şekil 3.2. Veri formatlama kodu.....	26



MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE EL VE YÜZ ANALİZİ TAHMİNLEMESİ

ÖZET

Kişi veya kurumlar tarafından kullanılan teknik altyapının güvenliği günümüzde büyük önem taşımaktadır. Güvenliğin sağlanması için birçok farklı yöntem bulunmaktadır ve bu yöntemler sürekli olarak geliştirilmekte ve güncellenmektedir. Bu önlemlerin alınmasındaki en kritik noktalardan biri ise bankacılık sektörüdür. Bankalardaki güvenlik açıklar hem müşterilerin hem de bankaların ciddi tehlikelerle karşılaşmasına neden olabilir.

Bankalarda yapılan işlemler, kişisel ve mali bilgilerin olduğu hassas verileri içerir. Bu nedenle, bankalar müşterilerinin güvenliğini sağlamak için yoğun çaba sarf etmektedir. Ancak, bankalar müşterilerine kredi vermeden önce bir dizi değerlendirme yapmak zorundadır. Bu değerlendirmelerin bir kısmı, müşterinin finansal geçmişi ve kredi geçmişi üzerine odaklanırken, bir diğer önemli değerlendirme ise müşterinin kişilik analizidir. Bankalar, kredi kullanırmak istedikleri müşterilerin finansal sorumluluk sahibi olmalarını ve kredi taksitlerini zamanında ödemelerini istemektedirler. Ancak, müşteriler genellikle kredi başvurusu yaparken olumsuz özelliklerini gizlemeye çalışabilirler. Bu nedenle, bankaların güvenlik önlemlerini artırmak ve daha doğru değerlendirmeler yapabilmek için yapay zeka teknolojilerine başvurdukları gözlemlenmektedir.

Son yıllarda, yapay zeka ile geliştirilen kişilik analizi çalışmaları, bankacılık sektöründe önemli bir yer edinmiştir. Bu çalışmalar, müşterilerin finansal davranışlarını ve kişilik özelliklerini daha doğru bir şekilde analiz etmeyi amaçlamaktadır. Bu sayede, bankalar daha güvenilir kredi kararları alabilir ve müşteri riskini daha iyi yönetebilirler. Bu nedenle, yapay zekâ destekli kişilik analizi çalışmalarına olan ihtiyaç giderek artmaktadır.

İnsan yüzlerinin tespiti ve tanınması, güvenlik ve gözetim alanlarında kritik bir rol oynamaktadır. Yüz tanıma teknolojisi, çeşitli yöntemlerle geliştirilmekte ve sürekli olarak iyileştirilmektedir. Bu teknolojinin temel amacı, bir görüntüdeki insan yüzlerini algılayarak tanıyabilmek ve bu yüzleri önceden belirlenmiş bir veri tabanıyla karşılaştırarak kimlik tespiti yapabilmektir. Ayrıca, yüz tanıma teknolojisi kullanılarak kişinin yaşı, cinsiyetini ve hatta duygusal durumunu analiz etmek gibi çeşitli tahminlerde bulunulabilmektedir.

Dünya üzerinde birçok kültür, gelecekteki yaşamı tahmin etmek için avuç içi falı okumanın kullanılabileceğine inanır. El falı olarak da bilinen bu sanat, avuç içindeki çizgileri ve desenleri inceleyerek kişileri önceden bilgilendirme ve tanımlama amacı güder. Avuç içi izi tanıma ise kişilerin kimliklerini ayırt etmek ve doğrulamak için kullanılan biyometrik bir tekniktir. Avuç içindeki benzersiz kabartılar, çizgiler ve diğer özellikler sayesinde kişilerin kimliklerinin tespit edilmesine olanak sağlar. Bu çıkıntılar ve çizgiler, embriyonik gelişim sırasında oluşur ve kişinin yaşamı boyunca

nispeten değişmez; bu da avuç içi izinin biyometrik tanıma için ideal bir ölçüt olduğunu gösterir.

Bu tez çalışmasının temel amacı, yüz algılama, yüz analizi ve avuç içi analizi gibi konular üzerine odaklanarak, bu alanlarda kullanılan yöntemleri incelemek, analiz etmek ve karşılaştırmaktır. Bu kapsamda yüz algılama, analizi ve kişilik analizi için bir uygulama geliştirilmiştir. Uygulama Python programlama dili ve ilgili kütüphanelerden yararlanılarak geliştirilmiştir. Uygulamanın kullanıcı arayüzü, tkinter gibi bir GUI kütüphanesi kullanılarak tasarlanmıştır. Bu arayüz, kullanıcının fotoğraf yükleyebileceği bir alanı içermektedir. Eğer yüklenen fotoğraf yüz görüntüsü içeriyorsa, sistem yüz analizi yapar ve çıktıları kullanıcıya sunar. Daha sonra, kişilik analizi için gerekli veri toplama süreci başlatılmış ve bu veriler avuç içi çizgilerine dayalı kişilik özelliklerini içerecek şekilde düzenlenmiştir. Literatürdeki benzer çalışmalar detaylı bir şekilde incelenerek hangi yöntemlerin en etkili olduğu üzerine analizler yapılmıştır.

Yüz analizi için makine öğrenmesi kütüphanelerinden OpenCV ve DeepFace gibi kütüphaneler kullanılmıştır. OpenCv kütüphanesi açık kaynak kodlu görüntü işleme kütüphanesidir. Kullanılan OpenCV kütüphanesi, sistemimize verilen görüntüler üzerinde yüz tespiti yapabilme yeteneğine sahiptir. Bu sayede, kullanıcının girdi olarak sağladığı görüntüler taranır ve içlerindeki yüz görüntüleri algılanır. Bu algılama işlemi, görüntülerin piksellerini analiz ederek yüz özelliklerini tanımlama ve belirleme sürecini içerir. Bu şekilde, kullanıcılar sisteme yüz görüntüleri sağlayabilir ve bu görüntüler üzerinde çeşitli analizler yapabilirler. Bu özellik, projenin anahtar bileşenlerinden biridir. DeepFace kütüphanesi ise, Facebook tarafından geliştirilen açık kaynaklı bir yüz tanıma ve analiz çerçevesidir. DeepFace kütüphanesi yüz tanıma ve yüz analizi işlemleri için kullanılmıştır. Yüz analizi işlemi için analyze fonksiyonu kullanılmıştır. Bu fonksiyon, bir görüntünün içerdiği yüzün cinsiyet, yaş ve duygusal durumu gibi özelliklerini analiz eder. Fonksiyon, bir görüntünün dosya yolunu parametre olarak alır ve bu görüntüdeki yüzlerin özelliklerini tahmin eder. Çıktı olarak, her bir yüz için belirli özelliklerin değerleri içeren veriler döndürülür.

Avuç içi analizinde makine öğrenmesi teknikleri kullanılarak, elde edilen veri seti üzerinde avuç içi analizi tahminlemesi yapılmıştır. Kullanıcılara yöneltilen sorularla gerçekleştirdiğimiz anket sonuçlarıyla elde edilen dijital veriler, öncelikle ön işleme adımlarından geçirilmiştir. Anket verilerinin büyük bir kısmının metin tabanlı karakterlerden oluştuğu gözlemlenmiştir. Metinsel verilerin algoritmalarla işlenebilmesi için sayısal bir formata dönüştürülmesi gerekmektedir. Bu dönüşüm işlemi, her bir metinsel girdinin sayısal bir temsili olarak ifade edilmesini sağlar, böylece veri seti analiz için uygun hale getirilmiştir. Makine öğrenmesi teknikleri, araştırmanın amacına yönelik olarak, avuç içi çizgileriyle ilişkilendirilen kişilik özelliklerinin belirlenmesine ve analiz edilmesine olanak sağlayacaktır. Kullanıcıdan girdi değerleri olarak alınan hayat çizgisi, kalp çizgisi ve akıl çizgisi verilerine göre kişilik analizi yorumunda bulunmaktadır. Çoklu sınıflandırma problemleri için etkili bir makine öğrenimi algoritması olan Random Forest sınıflandırıcı modeli ile gerekli hesaplamalar yapılmıştır. RandomForestClassifier sınıfı, RandomForest algoritmasını uygulayan bir sınıflandırıcıdır. Bu algoritma, birçok karar ağacını bir araya getirerek ve rastgele alt örneklem alarak bir tahmin yapar. Bu model, girdi verilerinin belirli kişilik özelliklerine karşılık gelip gelmediğini tahmin etmek için kullanılmaktadır. Random Forest algoritması özellikle karmaşık veri yapıları ve yüksek boyutlu veri kümelerinde etkili olduğu için bu algoritmanın kullanılması tercih edilmiştir. Bu kapsamda test verileri anket sonucu oluşturulan veri setindeki eğitim verileri ile

karşılaştırılarak doğruluk oranı % 0.45 olarak bulunmuştur. Aynı zamanda elde edilen veri seti ile birlikte KNN makine öğrenmesi algoritması üzerinde de hesaplamalar yapılmıştır. Bu hesaplama sonucunda ise %38 MSE değeri elde edilmiştir. Ortalama doğruluk değerinin düşük olması, modelin veri setimizdeki örüntüleri yeterince iyi öğrenememiş olabileceğini göstermektedir.

Bu çalışmanın olası çıktıları arasında, doğru tahminlenmiş cinsiyet, yaş, duygu analizi ve kişilik özellikleriyle kullanıcıya sunulan değerli bilgiler bulunur. Bu bilgiler, kimlik doğrulama sistemlerinde ve kişisel analizlerde önemli bir rol oynar ve kullanıcıların ihtiyaçlarını daha iyi anlamalarına yardımcı olur. Bu çalışma, yüz ve avuç içi analizleri üzerine yapılan araştırmalara yeni bir boyut kazandırır ve bu alanlardaki tekniklerin kullanımını artırarak kişilik tahminleme alanında daha etkili bir yöntem sunar.





HAND AND FACE ANALYSIS PREDICTION WITH MACHINE LEARNING METHODS

SUMMARY

Individuals and institutions are increasingly concerned about the security of the technological infrastructure they use. Because security vulnerabilities in technological systems can cause serious harm and risks. The banking sector is in a particularly sensitive position in this respect. Banks must take strong security measures to protect their customers' financial assets and provide a safe environment. In our daily lives, many people apply for credit and make requests regarding the use of credit while performing their banking transactions. However, banks adopt a careful approach when evaluating loan applications and analyze the loan payment capacities of their customers. Part of these evaluations is examining the customer's personality characteristics. Banks attach great importance to personality analysis to predict the financial responsibilities and payment habits of their customers before providing loans. However, customers generally avoid disclosing their negative characteristics in loan applications. Therefore, it may be difficult to make an adequate assessment using traditional methods. In recent years, the use of artificial intelligence-supported methods to overcome such challenges has increased significantly. By analyzing large data sets, artificial intelligence can extract customer profiles in more detail and evaluate loan applications more effectively. For this reason, artificial intelligence-based facial analysis and personality analysis studies are attracting increasing attention in the banking sector.

Detection and recognition of human faces is critical in security and surveillance fields. Facial recognition technology is developed through various methods used in this field. The main purpose of this technology is to detect and recognize human faces in an image and to identify them by comparing these faces with a predetermined database. In addition, various predictions can be made using facial recognition technology, such as analyzing the person's age, gender and even emotional state.

Palm reading is a tradition that has a history in many cultures around the world and is used to predict future life. This art aims to inform and identify people by examining the lines, patterns and other features on the palm. This method, also known as palm reading or palm reading, is often associated with metaphysical or spiritual beliefs. On the other hand, palm print recognition is a biometric technique and is used to distinguish and verify the identity of individuals. The unique ridges, lines, and other features on the palm form during embryonic development and remain relatively unchanged throughout a person's life. The palm print created by combining these features provides an important differentiating feature between individuals. Therefore, palm print recognition is used as a reliable biometric recognition method in security systems, authentication processes and many other fields.

This thesis focuses on topics such as face detection, face analysis and palm analysis, and examines and analyzes in depth the methods used in these fields. Studies in the

literature are examined meticulously and which methods are used and what kind of results are obtained are determined in detail.

The main purpose of the study is to research and develop effective methods that can be used in authentication systems based on face and palm analysis. In this direction, face and palm analysis in the developed system is used to accurately predict the person's features. In face analysis, information such as gender, age and emotion analysis of the person in the photo are estimated, while in palm analysis, predictions are made based on personality traits.

The method of this study primarily utilizes the Python programming language and related libraries for face detection and analysis. Then, the data collection process required for personality analysis is initiated and this data is organized to include personality traits based on palm lines. Similar studies in the literature are examined in detail and analyzes are made on which methods are most effective.

Next, a system is developed using the Python programming language. The user interface of the system is designed using a GUI library such as tkinter. This interface includes an area where the user can upload photos. If the uploaded photo contains a face image, the system analyzes the face and presents the output to the user.

Machine learning libraries such as OpenCV and DeepFace are used for face analysis. OpenCv library is an open-source image processing library. The OpenCV library used is capable of detecting faces on images fed to our system. In this way, the images provided by the user as input are scanned and the facial images in them are detected. This detection process involves the process of identifying and determining facial features by analyzing the pixels of images. In this way, users can provide facial images to the system and perform various analyzes on these images. This feature is one of the key components of the project and is important to increase the functionality of the system. DeepFace library is an open-source facial recognition and analysis framework developed by Facebook. DeepFace library was used for face recognition and face analysis. The analyze function was used for face analysis. This function analyzes the features of the face contained in an image, such as gender, age and emotional state. The function takes the file path of an image as a parameter and predicts the features of faces in that image. As output, data containing values of specific features for each face is returned.

By using machine learning techniques in palm analysis, palm analysis prediction was made on the obtained data set. These methods will allow the identification and analysis of personality traits associated with palm lines for the purpose of the research. Personality analysis is interpreted based on the life line, heart line and mind line data received from the user as input values. Necessary calculations were made with the Random Forest classification model, which is an effective machine learning algorithm for multiple classification problems. The RandomForestClassifier class is a classifier that implements the RandomForest algorithm. This algorithm makes a prediction by combining many decision trees and randomly subsampling. This model is used to predict whether input data corresponds to certain personality traits. Since the Random Forest algorithm is especially effective on complex data structures and high dimensional datasets, we proposed to use this algorithm. In this context, the accuracy rate was found to be %0.45. At the same time, calculations were made on the KNN machine learning algorithm with the obtained data set. As a result of this calculation, 38% MSE value was obtained. The low average accuracy value indicates that the model may not have learned the patterns in our data set well enough.

Possible outputs of this study include valuable information presented to the user through accurately predicted gender, age, sentiment analysis and personality traits. This information plays an important role in authentication systems and personal analytics, helping users better understand their needs. This study adds a new dimension to research on face and palm analysis and provides a more effective method in the field of personality prediction by increasing the use of techniques in these fields.





1. GİRİŞ

1.1. Problemin Tanımı

İnternetin yaygınlaşması ve ardından ağ kullanıcılarının artışıyla birlikte yeni güvenlik sorunları ortaya çıkmıştır. Bu tür açık ağlarda, kullanıcı verilerini korumak için daha güvenilir güvenlik önlemleri kullanılmalıdır [1]. Birçok alanda kullanıcının verilerinin güvenliği açısından veya kişi doğrulaması açısından çok farklı yöntemler geliştirilmektedir. Günümüzde veri güvenliğinde yapay zeka önemli bir rol oynamaktadır. İnternet teknolojinin her geçen yıl gelişmesiyle biyometrik tanımlamaya olan ilgide artmaktadır. Biyometrik tanımlama kişilerin kimliğini kanıtlamak amaçlı kullanılabilen biyolojik ölçümler veya fiziksel özelliklerdir. Biyometrik tanımlama uygulamaları güvenliği sağlamak amacıyla görüntü işleme tekniklerini kullanmaktadır.


Görüntü işleme, dijital görüntüler üzerinde bilgisayar algoritmaları ve matematiksel işlemler uygulayarak verileri analiz etmek ve anlamlı sonuçlar elde etmek için kullanılan bir bilgisayar bilimi dalıdır. Bilim dalında bir görüntüdeki desenleri, nesneleri ve özellikleri tanımlamak, izlemek, sınıflandırmak ve ayıklamak için algoritmalar kullanılır [2]. Kullanılan algoritmalar, güvenlik gereksinimleri doğrultusunda kişi doğrulaması için yapay zeka destekli teknolojilerin geliştirilmesine olanak tanımaktadır. Yapay zeka destekli teknolojilere örnek olarak yüz tanımlama, parmak izi eşleştirmesi gibi biyometrik teknoloji örnek gösterilebilir. Avuç içi incelemesi, çeşitli biyometrik kimlik doğrulama yöntemleri arasında dikkat çeken çekici ve etkili bir kimlik doğrulama aracıdır [3].

Yüz tanıma teknolojisi, bir kişinin yüz özelliklerini kullanarak kimlik doğrulaması yapmaya yönelik bir biyometrik tanımlama yöntemidir. Bir kişinin yüzündeki benzersiz yapıları, özellikleri ve oranları analiz ederek bir kişinin kimliğini belirlemeye çalışır. Yüz tanıma sistemleri genellikle saklanan yüz izi verileriyle çalışır. Bu veriler, bir kişinin yüz özelliklerini temsil eden bir dizi sayısal değer veya desen içerir. Yüz tanıma teknolojisi, bir kişinin kimliğini belirlemek için kaydedilmiş bir yüz görüntüsü ile canlı bir görüntüyü karşılaştırarak çalışır. Bu karşılaştırma, yapay

zeka tekniklerinin karmaşık algoritmalar tarafından gerçekleştirilir. Canlı görüntüdeki yüz, belirli özelliklerin çıkarılması ve analizi yoluyla bir yüz izi oluşturulur ve daha sonra bu iz, veri tabanındaki kayıtlı yüz izleriyle karşılaştırılır. [4]. Aynı zamanda, yüz görüntüsünden kullanıcının fiziksel özellikleri hakkında tahminler yapılabilir. Bu tahminler arasında yaş ve cinsiyet gibi özellikler yer alabilir. Benzer şekilde, el falı da kişilerin karakteristik özelliklerini ve gelecekteki durumlarını yorumlamak için kullanılır.

El falı, insanların davranışları, özellikleri, kariyerleri, servetleri vb. ile ilgili geleceğini tahmin etme sanatıdır. Bu alana aynı zamanda Chiromancy de denir ve halk arasında Palmist olarak da bilinir [5]. Avuç içimizde temel olarak 3 ana çizgi bulunmaktadır. Bunlar kalp, akıl ve hayat çizgileridir. Hayat çizgisine yaşam çizgisi de denilmektedir.

Avucun başlangıç kısmından yay şeklinde yukarıya doğru uzanan çizgi hayat çizgisidir. Avucun kenarında bulunan aşağıdan ikinci yatay ve belirgin olan çizgi akıl çizgisidir. Avucun kenarında en üstteki uzun çizgi kalp çizgisidir [6]. Hepsi uzunluk, kısalık, parçalı, düz şekilde ve parmak boyutlarına göre farklı yorumlar, farklı kişilik özellikleri içermektedir. Bu çizgiler ile kişinin geçmişi bugünü ve geleceği hakkında tahminleme yapılmaktadır.



Şekil 1.1. Akıl çizgisi, kalp çizgisi ve hayat çizgisi [6]

Bu araştırma çalışmasında, öncelikle yüz algılama ve analizi için Python programlama dili ve ilgili kütüphanelerden faydalanarak görüntüdeki yüzü tespit etmek ve analiz etmek üzerine odaklanmaktadır. Daha sonra kişilik analizi için veri toplama süreci başlamış ve bu veriler avuç içi çizgilerine dayalı kişilik özelliklerini içerecek şekilde oluşturulmuştur. Literatürde yapılan çalışmalar incelenerek hangi yöntemlerin

kullanıldığı ve ne tür sonuçlara ulaşıldığı detaylı bir şekilde analiz edilmiştir. Ardından, Python programlama dili kullanılarak yüz ve avuç içi analizi yapabilen bir uygulama geliştirilmiştir. Sistemin arayüzünü tasarlamak için python yazılım diline ait olan tkinter kütüphanesini önerdik. Tkinter [7], Python için standart GUI (Graphical User Interface – Grafiksel Kullanıcı Arayüzü) kütüphanesidir [8]. Sisteme kullanıcı tarafından bir adet fotoğraf yüklenecektir. Eğer kullanıcının sisteme yüklediği fotoğraflardan bir tanesi yüz görüntüsü içerecek ise yüz analizi yapılacaktır. Yüz analizinde fotoğraftaki kişinin cinsiyeti, yaşı, ve görüntüdeki yüz ifadesinin duygu analizi bulunarak tahminlemesi yapılacaktır. Yüklenen görüntü içerisinde yüz görüntüsü olduğunun algılanması için OpenCV kütüphanesini önerdik. Bulunan yüz görüntüsü içerisinde yüz analizi tahminlemesinde bulunmak için pythonun DeepFace kütüphanesini önerdik.

Kullanıcılara yöneltilen sorularla gerçekleştirdiğimiz anket sonuçlarıyla elde edilen dijital veriler, öncelikle ön işleme adımlarından geçirilmiştir. Bu aşamada, veri toplama sürecinde ortaya çıkan aykırı değerler ve eksik verilerin, model oluştururken sapmalara veya algoritmaların hatalı çalışmasına neden olabileceği göz önünde bulundurulmuştur. Bu nedenle, veri setindeki bazı veriler standart bir formata dönüştürülmüş ve gerektiğinde temizlenmiştir. Anket verilerinin büyük bir kısmının metin tabanlı karakterlerden oluştuğu gözlemlenmiştir. Metinsel verilerin algoritmalarla işlenebilmesi için sayısal bir formata dönüştürülmesi gerekmektedir. Bu dönüşüm işlemi, her bir metinsel girdinin sayısal bir temsili olarak ifade edilmesini sağlar, böylece veri seti analiz için uygun hale getirilmiştir.

Avuç içi analizi, kullanıcı verileriyle oluşturulan veri seti üzerinde makine öğrenimi teknikleri kullanılarak tahminleme yapar. Bu yaklaşım, avuç içi çizgileriyle ilişkilendirilen kişilik özelliklerini belirlemek ve analiz etmek için kullanılır, böylece araştırmanın hedeflerine ulaşılmasına yardımcı olur [6]. Kullanıcıdan girdi değerleri olarak alınan hayat çizgisi, kalp çizgisi ve akıl çizgisi verilerine göre kişilik analizi yorumunda bulunmaktadır. Çoklu sınıflandırma problemleri için etkili bir makine öğrenimi algoritması olan Random Forest sınıflandırıcı modeli ile gerekli hesaplamalar yapılmıştır. RandomForestClassifier sınıfı, RandomForest algoritmasını uygulayan bir sınıflandırıcıdır. Bu algoritma, birçok karar ağacını bir araya getirerek ve rastgele alt örneklem alarak bir tahmin yapar. Bu model, girdi verilerinin belirli kişilik özelliklerine karşılık gelip gelmediğini tahmin etmek için kullanılmaktadır. Random

Forest algoritması özellikle karmaşık veri yapıları ve yüksek boyutlu veri kümelerinde etkili olduğu için bu algoritmayı kullanmayı önerdik. Bu kapsamda doğruluk oranı % 0.45 olarak bulunmuştur. Aynı zamanda elde edilen veri seti ile birlikte KNN makine öğrenmesi algoritması üzerinde de hesaplamalar yapılmıştır. Bu hesaplama sonucunda ise %0.38 Ortalama Kare Hatası (MSE) değeri elde edilmiştir. Ortalama doğruluk değerinin düşük olması, modelin veri setimizdeki örüntüleri yeterince iyi öğrenememiş olabileceğini göstermektedir.

Olası çıktıları, doğru tahminlenmiş cinsiyet, yaş, duygu analizi ve kişilik özellikleriyle kullanıcıya sunulan değerli bilgiler olacaktır. Bu çalışmanın katkısı, yüz ve el analizleri üzerine yapılan araştırmalara yeni bir boyut kazandırması ve bu alanlardaki tekniklerin kullanımını artırarak kişilik tahminlemesi alanında daha etkili bir yöntem sunması olacaktır.

Yapılan çalışmanın geri kalanı şu şekilde organize edilmiştir:

Bölüm 2, kullanılan metotlar ve yöntemlerden bahsedilmiştir. Bölüm 3'te deneysel çalışmalar ve uygulamalar tanıtılmaktadır. Sonuçlar Bölüm 4'te verilmiştir.

1.2. Literatür Araştırması

Yüz tanıma ve avuç içi analizi, son yıllarda kimlik doğrulama ve tanımlama konusunda araştırmalarda çok büyük önem kazanmıştır. Bu konular ile ilgili birçok çalışma, uygulama ve yöntem geliştirmiştir. Literatürdeki bazı çalışmalar şu şekildedir;

Suvajit ve ark 2020 yılında avuç içi çizgilerine bakarak derin öğrenme yöntemini kullanarak mevcut çözüm ve uygulamalara göre daha detaylı ve doğru sonuçlar sağlamayı amaçlamaktadırlar. Bu çalışmada, önerilen yöntem üç aşamadan oluşmaktadır: İlk olarak el görüntülerini boyutlandırarak el ve arka plan ayırımında bulunmuşlardır. Ön plandaki avuç içi görüntüsünü arka plandan ayırmak için avuç içi görüntü veri setini anlamsal bölümlleme tekniği kullanarak eğitmişlerdir. Her giriş görüntüsündeki avuç içi için sınıf 1, görüntünün veya arka planın geri kalan kısmını sınıf 0 olarak etiketlemişlerdir. Bu etiketleme işlemi labelme tekniği ile gerçekleştirmişlerdir. İkinci olarak beyaz arka plana sahip yeni avuç içi görüntüleri 5 x 5 boyutunda ızgaraya bölünmüştür. Bu ızgaralar, kişiliklerin, yaşam tarzlarının ve gelecekteki yaşam yönelimlerinin daha fazla sınıflandırılması için her bir evrişimli sinir ağına beslenecek olan her bölgeyi oluşturmak için bir araya getirilmiştir. Her bir

bölge, içerdği ızgara sayısına bağlı olarak yeniden ölçeklendirilen bir görüntü olarak değerlendirilir. Üçüncüsü, derin sinir ağları (DNN) ve evrişimli sinir ağlarını (CNN) kullanarak bir model kurmuşlardır. Yukarıda önerilen ızgara sistemi tarafından tanımlandığı gibi her bölge, eğitim için evrişimli bir sinir ağı ile beslenmiştir. Bu sisteme göre el görüntülerini modele input olarak vererek daha önce eğitilmiş görüntüler ile benzerliğine göre etiketlendirerek bir kişilik analizi tahminlemesinde bulunmuşlardır. Araştırmacılar, çalışmanın pratik kullanılabilirliği ve etkinliği konusunda olumlu sonuçlar elde etmişlerdir. "A Deep Learning Approach for Efficient Palm Reading" çalışması, el çizgilerinin analizi için derin öğrenme tekniklerinin başarılı bir şekilde uygulanabileceğini göstermektedir. Bununla birlikte, çalışmanın bazı dezavantajları da gözlemlenmiştir. Örneğin, derin öğrenme modellerini eğitmek ve kullanmak genellikle büyük miktarda veri gerektirir, bu durum da yaklaşımın maliyetini ve karmaşıklığını artırabilir. Bu tür tekniklerin, gelecekte el çizgilerinin yorumlanması ve kişilik özelliklerinin tahmin edilmesi gibi alanlarda daha yaygın olarak kullanılması beklenmektedir [5].

2023 yılında yayınlanan bir yüz algılama ve doğrulama çalışmasında Shivalila ve ark. yüz ağı kullanan bir model geliştirmişlerdir. Yüz ağı, bir yüzün 3D modelini oluşturan noktaların bir ağıdır. Çeşitli aydınlatma koşullarında ve arka planlarda çalışabilme yeteneği, farklı yüz pozlarıyla başa çıkabilme kapasitesinden dolayı bu yüz ağı kullanılmıştır. Geliştirilen model, her yaştan ve ırktan erkek ve kadınlardan kaynaklanan yüz görüntülerini işleyebilmektedir. Model, etiketli vahşi yüz veri kümesindeki (LWF)[9] görüntüleri ve gerçek zamanlı olarak yakalanan görüntüleri kullanarak yüz ağı tarafından çıkarılan özellikler ile derin sinir ağına beslenerek ve veri tabanındaki yüzlerle karşılaştırma yaparak kimlik doğrulama ve tanıma işlemleri gerçekleştirilir. Test sırasında, eğer test görüntüsünün iki göz arasındaki mesafe, göz çukurlarının derinliği, yüz konturu, dudak ve elmacık kemiği şekli gibi yüz işaret noktaları, eğitim görüntülerinden herhangi biri ile uyuyorsa kişinin adını, eğer uyuyumuyor ise kişinin adını "bilinmiyor" olarak verecektir. Önerilen model ile yüz tanıma işleminde %94.23 doğruluk oranı elde edilmiştir, bu da modelin mevcut yüz tanıma sistemlerine göre daha yüksek performans sergilediğini göstermektedir. [10].

Selma ve ark. 2022 yılında derin öğrenme ve özellik seçme yöntemlerini kullanan verimli avuç içi biyometrik tanımlama sistemleri üzerinde çalışmışlardır. PalmNet-Gabor olarak adlandırdıkları yaklaşımlarında tek modlu ve çok modlu sistemler

önermektedirler. Tek modlu avuç içi izi tanımlama sisteminin beş adımdan oluşmaktadır. İlk adım ön işleme adımdır. Ön işleme adımında el görüntüsünün ilgili bölgesi (ROI) çıkarılmıştır ve çıkartılan avuç içi görüntüsü yeniden boyutlandırılmıştır. Log-Gabor filtreleri kullanarak avuç içi görüntülerinin kontrastını artırmakta ve ardından özellik seçimi ve boyut azaltma teknikleri uygulayarak gerekli özellik sayısını minimize etmektedirler. Özellik azaltma, büyük veri kümelerindeki gereksiz veya ilgisiz özellikleri çıkarmak ve yalnızca tanıma işlemi için gerekli olan temel özellikleri bırakmak anlamına gelir. Daha az veri işleneceği için tanıma süreci hızlanır. Elde edilen biyometrik veriler işlenmiş ve verilerin yeni bir temsilini oluşturmak için yalnızca belirgin veriler çıkartılmıştır. Ayırt edici avuç içi özellikleri çıkarmak için, her veri tipinin özellik vektörünü çıkarmak için PalmNet derin öğrenme kullanılmıştır. Çok modlu biyometrik sistemler, birden fazla biyometrik özelliği (örneğin, farklı avuç içi izleri) kullanarak tanıma işlemi gerçekleştirir. Bu sistemler daha güvenilir ve doğrudur çünkü birden fazla veri kaynağı birleştirildiğinde tek bir kaynağa göre daha sağlam sonuçlar elde edilir. Çok modlu avuç içi izi tanımlama sisteminde ise oluşturdukları sistemin performansını arttırmak için yöntemleri eşleşen puan seviyesinde birleştirmişlerdir. Puan düzeyinde birleştirme farklı biyometrik modalitelerden elde edilen tanıma puanlarının birleştirilmesi işlemidir. Her bir modalite (örneğin, kırmızı, yeşil, mavi ve kızılötesi bantlar) ayrı ayrı işlenir ve her biri için bir tanıma puanı hesaplanır. Bu puanlar daha sonra birleştirilerek (örneğin, ortalama alma, çarpma veya ağırlıklı toplam kullanarak) nihai tanıma kararı verilir. Önerilen yöntemi dört genel avuç içi veri tabanında, iki multispektral veri tabanında (CASIA ve PolyU) ve iki temassız veri tabanında (Tongji ve PolyU 2D/3D) doğrulamışlardır. Deneyler, geliştirilen yaklaşımın önemli ölçüde daha az sayıda özellik kullanırken yüksek bir tanıma oranına ulaştığını göstermektedir. [11].

Firas ve ark. 2023 yılında Derin öğrenme yöntemlerine ve gri kurt optimizasyon algoritmasına dayalı avuç içi izi görüntülerini kullanarak insan tanımlama üzerine çalışmışlardır. Bu çalışma, bir kişinin yaşamı boyunca nispeten değişmeden kalan benzersiz avuç içi sırtları, çizgileri ve özelliklerine dayanır. GoogLeNet, SqueezeNet ve AlexNet gibi derin öğrenme ağları ile gri kurt optimizasyon algoritmasını birleştirerek, bu benzersiz özellikleri doğru kimlik tespiti için çıkarmayı ve analiz etmeyi amaçlamaktadır. Hong Kong Politeknik Üniversitesi veri seti ve Tongji Temassız veri seti olmak üzere iki veri seti test için kullanılmıştır. Çalışmada, avuç içi

baskı görüntülerinden özellik çıkarmak için GoogLeNet, SqueezeNet ve AlexNet gibi önceden eğitilmiş konvolüsyonel sinir ağları (CNN'ler) kullanılmıştır. Bu ağlar, avuç içindeki karmaşık ve benzersiz desenleri yakalar. Çıkarılan özelliklerin yüksek boyutluluğu göz önüne alındığında, gri kurt optimizasyonu (GWO) algoritması, özellik setini azaltmak ve işlem verimliliğini ve doğruluğunu artırmak için kullanılmıştır. GWO, karınca kolonisi optimizasyonu (ACO), genetik algoritma (GA) ve parçacık sürü optimizasyonu (PSO) gibi diğer meta-sezgisel yöntemlerden daha iyi performans göstermiştir. Test görüntülerinden çıkarılan ve optimize edilen özellikleri veri tabanındaki özelliklerle eşleştirmek için tanıma adımında Öklid mesafe yöntemi kullanılmıştır. Bu yöntem, minimum mesafe hesaplamasına dayalı olarak bireyleri tanımlar. %96,72'lik tanınma oranıyla iyi bir performans elde etmişlerdir. Çalışma, derin öğrenme ağlarının gri kurt optimizasyonu algoritması ile entegrasyonunun, avuç içi baskılarına dayalı insan kimlik tespitinin doğruluğunu önemli ölçüde artırdığını sonucuna varmıştır. Bu yaklaşım, siber güvenlik uygulamaları için sağlam biyometrik güvenlik sistemleri geliştirme potansiyeline sahiptir. [1].

Tsung-Han ve Po-Ting 2022 yılında yaptıkları çalışmada yüz algılama ve yüz tanıma için tek adımlı bir derin sinir ağı eğitimi için önerilen bir çoklu görevli eğitim yaklaşımı vurgulanmaktadır. Bu yaklaşım, özellikle özellik piramidi ve triplet kaybı kullanarak yüz tanıma ve tespit performansını artırmayı hedeflemektedir. Özellik piramidi, yüz tespiti ve tanıma işlemlerinde kullanılan çok ölçekli özellikleri entegre eden bir yapı olarak, modelin farklı çözünürlüklerdeki yüzleri daha iyi tanımasını sağlar. Özellik çıkarmak için özellik piramidi ve bağlantı kutuları kullanıldığı, üçlü kayıp kullanılarak özelliği lokalize etmek ve son olarak basit bir matematiksel fonksiyonla özellikleri eşleştirmek amacıyla yapılan bir yapı kullanıldığı ifade edilmektedir. Yüz tanıma modelinin performansını artırmak için kullanılan triplet kaybı, benzer yüzlerin birbirine daha yakın, farklı yüzlerin ise birbirinden daha uzak olmasını sağlayarak modelin doğruluğunu artırır. Tek aşamalı yaklaşım, yüz tespiti ve tanıma işlemlerini birleştirerek daha hızlı ve verimli bir sistem sunar. Bu, çok aşamalı yaklaşımlara kıyasla daha düşük gecikme süresi ve daha yüksek işlem hızı sağlamaktadır. Tek adımlı bir yapısıyla, her görevin verileri aynı ana ağ üzerinden geçerek tekrarlı hesaplamaların önlendiği ve ağırlık paylaşımının gerçekleştirildiği belirtilmektedir. Önerilen modelin farklı veri setlerinde yapılan testlerde yüksek doğruluk ve hızlı işlem süreleri ile başarılı sonuçlar verdiği belirtilmiştir. Modelin

özellikle yüz tespiti ve tanıma işlemlerinde mevcut yöntemlere kıyasla üstün performans gösterdiği vurgulanmıştır [12].

"Palmistry using Machine Learning and OpenCV" adlı çalışma, Delhi Teknoloji Üniversitesi'nde 2021 yılında Malti Bansal, Prince, Ravi Yadav ve Prem Kr. Ujjwal tarafından gerçekleştirilmiştir. Araştırmanın üç temel amacı bulunmaktadır. Birincisi avuç içi rengini tespit etmek, ikincisi parmaklar arasındaki mesafeyi belirlemek ve üçüncüsü avuç içi ana hatlarını tespit etmektir. Geliştirilen çalışma bu tespitlerden yola çıkarak avuç içi rengine ve parmaklar arasındaki mesafeye göre kişilik özellikleri tahminlemesinde bulunmaktadır. Kullanıcının girdi olarak sağladığı görüntü renklidir. Bu bir 3 boyutlu matristir. Dolayısıyla bu girdi görüntüsünün doğrudan algoritmaya besleyemeyeceğinden görüntü üzerinde yeniden boyutlandırma, yumuşatma, aşındırma ve segmentasyon gibi ön işleme yönelik çeşitli işlemler gerçekleştirilmiştir. Parmaklar arasındaki mesafeyi bulmak için parmak uçlarındaki uç noktaları bularak ardından basit mesafe formülünü veya öklid mesafe formülünü kullanarak aralarındaki mesafe hesaplanmıştır. Avuç içi rengini belirlemek için kmeans kümeleme denetimsiz makine öğrenimi algoritması kullanılmıştır. Giriş görüntüsü için 10 küme kullanılmıştır. Algoritma 10 kümeyi ve o kümeyle ilişkili noktaların sayısını verir. Algoritmanın çıktısı olarak 10 renk değeri elde edilmektedir. Yüzdesi en yüksek olan renk avucumuzun baskın rengidir. Belirlenen avuç içi rengine göre kişilik tahminlemesinde bulunmuştur. Yapılan bu çalışmada makine öğrenimi ve OpenCV kütüphanesi kullanılmışdır [13].

Ömer Türk ve arkadaşları tarafından 2023 yılında yapmış oldukları çalışmada, avuç içi tanıma sistemi için derin öğrenme ve makine öğrenimi temelli bir hibrit yaklaşım önerilmiştir. Önerilen metodoloji, birkaç adımdan oluşmaktadır. İlk olarak, PolyU veri tabanından elde edilen ham görüntüler, belirlenmiş ROI alanlarını tespit etmek için ön işleme adımlarına tabi tutulmuştur. Ardından, ön işleme sürecinden geçirilen görüntüler üzerinden derin öğrenme yöntemleri kullanılarak derin ROI özellikleri çıkarılmıştır. Son aşamada, elde edilen derin özellikler, hibrit derin evrişimli sinir ağı ve destek vektör makine modelleriyle sınıflandırılmıştır. Sonuçlar, önerilen sistemin yüksek bir doğruluk oranına (%99,72) ulaştığını ve tüm süreç boyunca oldukça düşük bir yürütme süresine (0,10 s) sahip olduğunu göstermektedir [14].

Nader Ebrahimpour ve Faruk Baturalp Günay' ın 2023 yılında yayınlamış oldukları makalede, avuç içi tanımayı geliştirmek için önceden eğitilmiş CNN (Evrişimsel Sinir

Ağı) modellerinin kullanımını ele almaktadır. Sunulan yeni yaklaşım, DL (Derin Öğrenme) ve TL (Transfer Öğrenme) tekniklerinin güçlerini birleştirerek özellik çıkarma ve sınıflandırma süreçlerinde son teknoloji ürünü CNN mimarilerinden faydalanmaktadır. Önerilen yöntem, ShuffleNet, EfficientNet ve MobileNet gibi önceden eğitilmiş CNN mimarilerinin potansiyelini keşfetmek için avuç içi izleri için özellik çıkarıcı olarak başlamaktadır. Ardından, çıkarılan özellik vektörleri CS (Kosinüs Benzerliği) yöntemi kullanılarak karşılaştırılmaktadır. Yapılan kapsamlı deneylerin sonuçları, önceden eğitilmiş CNN modellerinin, biyometrik kimlik doğrulama için avuç içi izlerini tanıma konusunda mükemmel olduğunu ve bu alandaki yeteneklerini başarılı bir şekilde ortaya koyduğunu göstermektedir. Dolayısıyla, bu makale, önceden eğitilmiş CNN modellerinin doğal yeteneklerini kullanarak avuç içi tanıma alanında önemli bir ilerleme sağladığını ve Biyometrik Kimlik Doğrulama (BA) metodolojilerine yenilikçi bir yaklaşım getirdiğini vurgulamaktadır [15].



2. KULLANILAN YÖNTEMLER VE METOTLAR

2.1. Makine Öğrenmesi

Makine öğrenmesi, bir problemin çözümü için probleme ait ilgili verilere dayalı olarak model oluşturan bilgisayar algoritmalarının genel adıdır. Yapay zekanın alt dalıdır. Bu alanda geliştirilen sistemler büyük boyutlardaki veri setlerini kullanarak algoritma ile oluşturulan model sayesinde örüntüleri tanımlamak, tahminler yapmak, karar vermek gibi görevleri gerçekleştirir [16]. Makine öğrenimi bağlamında, öğrenme süreci veri kullanımıyla gerçekleştirilir ve regresyon algoritmaları aracılığıyla, kayıp veya hata miktarının (RMSE veya MSE gibi) en aza indirilmesi amaçlanır. Bilgisayar bilimleri ve yapay zeka alanlarında, belirli bir görevi veya problemi çözmek için tasarlanmış matematiksel ve istatistiksel yöntemlere makine algoritmaları denir. Makine algoritmalarından bazıları; k-en yakın komşu algoritması, basit (naive) Bayes sınıflandırıcı, karar ağaçları, lojistik regresyon analizi, k-ortalamlar algoritması, destek vektör makinaları ve yapay sinir ağlarıdır. CSAIL'deki (Computer Science & Artificial Intelligence Laboratory) InfoLab Grubu başkanı ve baş araştırmacı Boris Katz'a göre, yapay zekanın amacı, insanların gösterdiği "akıllı davranışları" bilgisayarlar aracılığıyla modellenabilir hale getirmektir. Bu modelleme, görüntü tanıma, doğal dil işleme veya robotik gibi alanlarda uygulanabilir [17].

Makine öğrenimi kavramı, 1950'lerde yapay zeka öncüsü Arthur Samuel tarafından ortaya atıldı. Samuel, "bilgisayarların açıkça programlanmadan öğrenme yeteneği kazanması" fikrini önerdi. Bu öneri, bilgisayarların verilerle beslenerek, verilerdeki örüntüleri tanımlamayı ve gelecekteki kararlar için bu örüntüleri kullanmayı öğrenmesi anlamına gelir [17].

Mitchell (1997) makine öğrenmesini “Bir bilgisayar yazılımı, deneyim D'yi kullanarak istenilen bir görev G'yi gerçekleştirmek için performans P ölçüsü ile eğitilmesidir.” şeklinde tanımlamıştır. Burada performans P ölçütü ile oluşturulan görev G, deneyim D'yi geliştirmektir [18].


Makine öğreniminde "sistem," verilerin toplanması, işlenmesi, modelin eğitilmesi ve sonuçların analiz edilmesi için kullanılan yazılım ve donanım altyapısını ifade eder.

Bu sistemde kullanılan öğrenme algoritması, seçilen öğrenme yaklaşımına bağlı olarak belirlenir. Öğrenme yaklaşımları ise genellikle üç ana kategoride incelenir: denetimli, denetimsiz ve pekiştirmeli (takviyeli) öğrenme. Bu gruplar, öğrenme sürecinde farklı stratejiler ve yöntemler kullanılmasına yol açmaktadır.

Bu çalışmada, makine öğrenmesi algoritmaları kullanılarak; belirli kişilik özelliklerini tahmin etmek için en uygun sınıflandırma modelini belirlemek ve verileri bu model üzerinde eğitmek amacıyla bir dizi algoritma değerlendirilmiştir. Tez çalışmasında algoritmalar, iki ana başlık altında incelenmiştir.

2.1.1. Denetimli öğrenme

Denetimli öğrenme, makine öğrenmesinin bir alt dalıdır ve etiketli verilerle çalışarak öğrenme sürecini gerçekleştirir. Etiketli veriler, doğru cevaplar veya sınıflandırmalarla işaretlenmiş verilerdir. Denetimli öğrenme algoritmalarında, etiketlenmiş veri kümesinin kullanılması temel bir gerekliliktir. [19]. Denetimli öğrenmede geliştirilen modele etiketlenmiş veriler verilmektedir. Eğitimle sistem, sorunları öğrenir ve bu eğitimler elle yapılan etiketlerle yani kelime resim gibi etiketler kullanılarak beslenir [20]. Şekil 2.1. deki gibi bir öğrenme yapısı söz konusudur.




Şekil 2.1. Denetimli öğrenme modeli örnek gösterimi

Denetimli öğrenme, öğretmen denilen insanın rehberliğine ihtiyaç duyar çünkü bu yöntemde algoritma, öğrenme sürecinde doğru cevapları öğrenmek için etiketlenmiş veri kümesinden bilgi alır. Etiketlenmiş veri, girdi ve çıktı arasındaki ilişkiyi tanımlar

ve bu ilişkiyi öğrenmek için kullanılır. Öğretmen, bu verileri sağlayarak algoritmanın doğru sonuçları öğrenmesine yardımcı olur ve böylece algoritma, yeni veriler üzerinde doğru tahminler yapabilir. Makine, bu eğitim setindeki etiketli verileri analiz eder ve doğru sonuçları öğrenir. Daha sonra, bu öğrenme sürecinden elde edilen bilgi, yeni veri noktalarını sınıflandırmak veya tahmin etmek için kullanılabilir. Örneğin, bir görüntü veri kümesindeki görüntülerin "Fil", "Deve" veya "İnek" gibi etiketlerle işaretlenmesi, denetimli öğrenme modelinin bu etiketlere dayalı olarak yeni görüntülerin sınıflandırılmasını sağlaması için bir örnektir. Patil ve Sane (2020) "Spam Detection Using Machine Learning Algorithms" adlı çalışmalarında, e-posta sistemlerinde bazı e-postaların "spam" veya "spam değil" olarak etiketleyerek bir veri kümesi oluşturmuşlardır. Bu etiketlenmiş veri kümesi, algoritmalara hangi e-postaların spam olduğunu ve hangilerinin spam olmadığını öğretir. Algoritma bu verilerden öğrenerek, yeni gelen e-postaları analiz eder ve spam olup olmadığını tahmin eder. Böylece, sistem spam e-postaları otomatik olarak filtreleme işlevi görür. [21]

Kısacası, denetimli öğrenme, etiketlenmiş olarak bilinen bir girdi veri setiyle ilişkilendirilmiş çıktıları kullanarak algoritmanın daha önce karşılaşmadığı veya eğitimde kullanılmamış yeni verilere en uygun çıktıları üretmek için kullanılan bir makine öğrenmesi modelidir [19]. Modele verilen veri seti belirli oranlarda test ve eğitim veri seti olarak ikiye ayrılır. Birçok kaynakta denetimli öğrenme, "gözetimli öğrenme" olarak da adlandırılır. Tahminler yapılırken, genellikle şekil 2.2. deki gibi regresyon veya sınıflandırma yöntemleri kullanılır.



Şekil 2.2. Sınıflandırma ve Regresyon modeli örnek gösterimi [22]

2.1.1.1. Regresyon yöntemi

Regresyon problemlerinde, temel olarak belirli bir aralıkta herhangi bir sayısal değeri alabilen değerler için bir çıktı tahmini hedeflenir. Regresyon analizi, genellikle bağımlı ve bağımsız değişkenler arasındaki ilişkiyi anlamak ve tahmin etmek için kullanılır [19]. Regresyon yöntemi, gözlemleri belirli sınıflara atamak yerine, girdi değişkenlerini kullanarak sayısal bir çıktı elde etmeyi amaçlar. Bu tür uygulamalar, genellikle bağımlı ve bağımsız değişkenler arasındaki ilişkileri belirlemek ve anlamak için kullanılır. Yani, temelde, iki veya daha fazla değişken arasındaki ilişkilerin analiz edilmesi ve açıklanması için kullanılır. Örneğin, regresyon algoritmalarının uygulama alanları arasında doğrusal regresyon, polinom regresyonu, lojistik regresyon ve destek vektör regresyonu gibi yöntemler bulunmaktadır. Bu algoritmalar, çeşitli endüstriyel ve akademik alanlarda kullanılarak çeşitli tahmin ve analiz görevlerini yerine getirebilir. Yaygın regresyon algoritmaları arasında doğrusal model, doğrusal olmayan model, regülasyon, kademeli regresyon, karar ağaçları, sinir ağları sayılabilir.

2.1.1.2. Sınıflandırma yöntemi

Sınıflandırma teknikleri girdi verilerini sınıflara ayırır. Sınıflandırma yöntemi, veri noktalarını sınıflandırmak için kullanılır. Bu algoritma, veri kümesini farklı parametrelere dayalı olarak sınıflara ayırmayı amaçlar. Girdi verilerini ayrık çıktı değerlerine eşleyen problemlerde yaygın olarak kullanılır; yani çıktılar genellikle kategorik tiptedir. Sınıflandırma, ayrık ve sıralı olmayan kategorik sınıf etiketlerini tahmin eden bir tahmin problemidir. Bir öğrenme adımı ve bir sınıflandırma adımından oluşan iki aşamalı bir süreçtir. Sınıflandırma algoritmalarına; Doğrusal Sınıflandırıcılar, Karar Ağaçları, K En Yakın Komşu, Rastgele Orman örnek olarak verilebilir.

2.1.2. Denetimsiz öğrenme

Denetimsiz öğrenme, makine öğrenme alanında önemli bir paradigmadır ve etiketlenmemiş verilerden öğrenme yeteneği ile öne çıkar. Bu öğrenme yöntemi, verilerin herhangi bir önceden tanımlanmış etiket veya kategoriye sahip olmadığı durumlarda kullanılır. Yani, denetimsiz öğrenme, etiketsiz verilerdeki gizli yapıları veya örüntüleri keşfetmeye yönelik bir makine öğrenimi yaklaşımıdır [23]. Bu sistem, etiketlenmemiş verilerdeki iç görüleri ve ilişkileri belirlemeyi amaçlar.

Denetimsiz öğrenme sürecinde, herhangi bir öğretmen veya etiketlenmiş veri setine gerek duyulmaz. Veri seti olmaması sebebi ile, makine öğrenme modeli, verilerdeki yapıları ve desenleri kendi başına keşfetmeye çalışır. Bu keşif, genellikle veri analizi, keşifsel veri madenciliği ve veri keşfi gibi alanlarda kullanılır. Örneğin, hayvan verileri üzerinde yapılan bir çalışmada, denetimsiz öğrenme kullanılarak farklı hayvan türlerinin doğal gruplamaları ve ilişkileri keşfedilebilir [24].

Kümeleme, denetimsiz öğrenmenin önemli bir parçasıdır ve etiketlenmemiş verilerdeki benzerliklere veya farklılıklara dayalı olarak gruplandırma yapar. Bu yöntem, veri kümesindeki yapıları daha iyi anlamak ve keşfetmek için yaygın olarak kullanılır. Örneğin, K-means kümeleme algoritması, veri noktalarını belirli bir sayıda küme altında toplamak için yaygın olarak kullanılan bir yöntemdir. Bu algoritma, her veri noktasını belirli bir kümenin merkezine en yakın olan kümeye atar ve bu şekilde veri noktalarını gruplar. Örtüşen kümeler ise, farklı üyelik derecelerine sahip veri noktalarının birden fazla kümeye ait olabileceği bir model oluşturur. Bu, verilerin daha karmaşık yapılarını analiz etmek için kullanışlıdır ve bulanık kümeleme gibi yöntemler bu tür durumlarda tercih edilir.

Eğitim sürecinde etiketsiz veriler kullanılır ve bu verilerin anlaşılması, tanınması ve keşfedilmesi üzerine odaklanılır. Bu nedenle, sistemden beklenen sonuçlar önceden bilinmez. Eğitim ve gözetim dışı sonuçlar ortaya çıkabilir çünkü model doğru cevaplarla eğitilmemiştir. Kendi başına kalıpları keşfetmesi gerekmektedir [25]. Denetimsiz öğrenme, verileri gruplandırarak benzerlikleri veya farklılıkları tespit etmeye çalışır.

2.2. Tkinter Kütüphanesi

GUI (Grafiksel Kullanıcı Arayüzü), kullanıcıların bilgisayar programlarını daha etkili ve verimli bir şekilde kullanmalarını sağlayan arayüzlere verilen genel bir addır. Tkinter ise, Python programlama dilinde bulunan ve GUI uygulamaları geliştirmek için kullanılan bir kütüphanedir. Python'un standart kütüphanesinin bir parçası olan Tkinter, çeşitli grafik arayüz bileşenlerini (pencere, düğme, menü, metin kutusu vb.) oluşturmak ve bunlarla etkileşim sağlamak için kullanılır.

Projemizde, Tkinter kütüphanesini kullanarak şekil 2.3.'de ki görüntüdeki arayüzü geliştirdik. Bu arayüz, kullanıcının yüz görüntüsü seçmelerini, avuç içi çizgilerine en uygun modelleri belirlemelerini ve analiz işlemini başlatmalarını sağlar. Arayüzün

temel amacı, kullanıcıların bu işlemleri kolayca ve kullanıcı dostu bir şekilde gerçekleştirebilmesini sağlamaktır.

MAKİNE ÖĞRENME YÖNTEMLERİ İLE EL VE YÜZ ANALİZİ TAHMİNLEMESİ ©2024 HÜSNEİREM KAYA

Yüz Fotoğrafi Seçin

Görüntüdeki kalp çizgilerinden size en uygunu seçin:
Lütfen sol avuç içinizdeki çizgilere göre seçim yapın

1		☐	2		☒	3		☐	4		☐
5		☐	6		☐	7		☐	8		☐

Görüntüdeki akıl çizgilerinden size en uygunu seçin:
Lütfen sol avuç içinizdeki çizgilere göre seçim yapın

1		☐	2		☐	3		☐	4		☐
5		☐	6		☐	7		☐	8		☐

Görüntüdeki hayat çizgilerinden size en uygunu seçin:
Lütfen sol avuç içinizdeki çizgilere göre seçim yapın

Şekil 2.3. Geliştirilen sistemin arayüz görüntüsü başlangıç kısmı

Arayüzde, başlangıçta "Yüz Fotoğrafi Seçin" başlıklı büyük bir buton bulunmaktadır. Bu butona tıklayarak kullanıcı, bilgisayarında bulunan bir yüz fotoğrafını seçer. Bu fotoğraf, yüz analizinin yapılması için gereklidir.

Arayüzün bir alt kısmında, kullanıcının sol avuç içindeki kalp çizgisine en uygun olan modeli seçmesi istenmektedir. Bu seçim, arayüzde gösterilen sekiz farklı kalp çizgisi modelinden birinin işaretlenmesiyle yapılır. Kullanıcı, sol avuç içindeki kalp çizgisine en çok benzeyen modeli belirleyip seçim yapar.

Bir sonraki bölümde, kullanıcının sol avuç içindeki akıl çizgisine en uygun olan modeli seçmesi gerekmektedir. Yine sekiz farklı akıl çizgisi modeli arasından bir seçim yapılır. Kullanıcı, sol avuç içindeki akıl çizgisine en yakın olan çizgiyi belirler ve ilgili kutucuğu işaretler.

Son olarak, kullanıcının sol avuç içindeki hayat çizgisine en uygun olan modeli seçmesi gerekmektedir. Burada da sekiz farklı modelden biri seçilir. Kullanıcı, sol avuç içindeki hayat çizgisine en çok benzeyen modeli belirleyip işaretler.

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE EL VE YÜZ ANALİZİ TAHMİNLEMESİ ©2024 HÜSNEİREM KAYA

Görüntüdeki akıl çizgilerinden size en uygunu seçin:
Lütfen sol avuç içinizdeki çizgilere göre seçim yapın

1		☐	2		☐	3		☐	4		☐
5		☐	6		☐	7		☐	8		☐

Görüntüdeki hayat çizgilerinden size en uygunu seçin:
Lütfen sol avuç içinizdeki çizgilere göre seçim yapın

1		☐	2		☐	3		☐	4		☐
5		☐	6		☐	7		☐	8		☐

Analiz Et

Şekil 2.4. Geliştirilen sistemin arayüz görüntüsü bitiş kısmı

Arayüzün en alt kısmında Şekil 2.4’de olduğu gibi "Analiz Et" adında bir buton bulunmaktadır. Bu butona basıldığında, kullanıcı tarafından seçilen yüz fotoğrafı ve

avuç içi çizgi modelleri üzerinden bir analiz gerçekleştirilir. Analiz sonucunda elde edilen sonuçlar arayüzde gösterilir ve kullanıcılar bu sonuçları inceleyebilirler.

Bu kullanıcı arayüzü, kullanıcıların yüz ve avuç içi analizini kolayca gerçekleştirmelerini sağlar ve Tkinter'in basit ve kullanıcı dostu yapısı sayesinde kolayca kullanılabilir. Tkinter'in çeşitli özellikleri ve kolaylıkla entegre edilebilir olması, projenin geliştirilmesini ve kullanılmasını daha da kolaylaştırır.

2.3. OpenCv Kütüphanesi

OpenCV, açık kaynak kodlu bir görüntü işleme kütüphanesidir. Intel tarafından 1999 yılında başlatılan geliştirme süreci, daha sonra Itseez, Willow, Nvidia, AMD, Google gibi çeşitli şirketler ve topluluklar tarafından desteklenmiştir. Özellikle gerçek zamanlı işlemlerde önemli bir rol oynar. Gerçek zamanlı işlemlerden bazıları; Yüz tanıma ve takibi, nesne tanıma ve takibi, hareket algılama gibi işlemlerdir.

OpenCV kütüphanesi, web kameraları, video dosyaları veya diğer aygıt türleri tarafından bir bilgisayara bağlanan görsel bilgilerin yakalanmasını, analiz edilmesini ve değiştirilmesini sağlayan yüzlerce işlev içerir. Basit işlevler kullanılarak bir ekrana çizgi veya şekil çizmek gibi temel işlemlerden, yüz algılama, hareket izleme ve şekil analizi gibi daha gelişmiş işlevlere kadar geniş bir yelpazede hizmet verir.

OpenCV'nin kullanımı oldukça yaygındır ve farklı yazılım dilleriyle uyumludur. Özellikle Java, C++, Python ve Matlab gibi popüler dillerde kullanılabilmektedir. `Import cv2` komutuyla Python projelerine dahil edilerek kullanılabilir. Görüntü işleme alanında öncü olan bu kütüphane, çeşitli uygulama alanlarında geniş bir kullanıcı kitlesine hitap etmektedir.

Bu çalışmada, Python programlama dilinde OpenCV kütüphanesi kullanılmıştır. OpenCV kütüphanesi, verilen görüntüler üzerinde yüz tespiti yapabilme yeteneğine sahip bir kütüphanedir. Bu özelliği sayesinde, kullanıcının sağladığı görüntüler taranır ve içlerindeki yüz görüntüleri algılanır.

Bu şekilde, kullanıcılar sisteme yüz görüntüleri sağlayabilir ve bu görüntüler üzerinde çeşitli analizler yapabilirler. Özellikle, projenin anahtar bileşenlerinden biri olan bu özellik, sistemin işlevselliğini arttırmak için son derece önemlidir. Kullanıcılar, analiz etmek istedikleri görüntüleri sisteme yükleyerek, yüz tespiti ve analiz işlemlerini gerçekleştirebilirler.

Ayrıca, projenin bir diğer önemli bileşeni, sistemde yüz içermeyen bir fotoğraf yüklendiğinde kullanıcıya uyarı verilmesidir. Bu durumda, şekil 2.5'deki görüntüde olduğu gibi, sistem yalnızca avuç içi analizi yapar ve kullanıcıyı bilgilendirir. Bu özellik, kullanıcının doğru türdeki görüntüleri yüklemesini sağlayarak sistem performansını artırır ve istenmeyen durumların önüne geçer.



Şekil 2.5. Yüz görüntüsü algılama.

2.4. DeepFace Kütüphanesi

DeepFace, yüz tanıma ve analiz alanında kullanılan, Facebook tarafından geliştirilmiş bir Python kütüphanesidir. Derin öğrenme tekniklerini temel alan bu kütüphane, özellikle yüz tanıma, cinsiyet tespiti, yaş tahmini, duygusal analiz gibi çeşitli yüz analizi görevlerini gerçekleştirmek için tasarlanmıştır.

DeepFace, arkasında yüksek performanslı derin öğrenme modelleri barındırır. Bu modeller, büyük ölçüde etiketlenmiş veri setleri üzerinde eğitilmiştir ve yüz analizi görevlerinde son derece başarılıdır. Özellikle, CNN (Convolutional Neural Network)

gibi derin öğrenme mimarileri kullanılarak yüz tanıma ve analizindeki karmaşıklıkları ele alır.

Önceden eğitilmiş modeller sayesinde, kullanıcılar verilen bir görüntüdeki yüzleri tespit edebilir, cinsiyetini belirleyebilir, yaşını tahmin edebilir ve duygusal durumunu analiz edebilir. DeepFace kütüphanesi, yüz tanıma teknolojilerinin geliştirilmesi ve uygulanmasında büyük önem taşır. Facebook gibi büyük bir şirketin desteğiyle geliştirilen bu kütüphane, geniş veri setlerinden öğrenilen derin öğrenme modellerini kullanarak yüz analizi alanında önemli bir rol oynamaktadır.

Bu çalışma kapsamında, yüz tanıma ve yüz analizi işlemleri için DeepFace kütüphanesi tercih edilmiştir. Yüz analizi işlemleri için kullanılan ana fonksiyon `analyze()` fonksiyonudur. Bu fonksiyon, bir görüntünün içerdiği yüzlerin çeşitli özelliklerini tahmin etmek için kullanılır.

`Analyze()` fonksiyonu, bir görüntünün dosya yolunu parametre olarak alır ve bu görüntüdeki yüzlerin özelliklerini analiz eder. Bu özellikler arasında cinsiyet, yaş ve duygusal durum gibi faktörler yer alır. Fonksiyon, her bir yüz için belirli özelliklerin değerlerini içeren verileri çıktı olarak döndürür. Şekil 2.4'deki gibi çıktı olarak, her bir yüz için belirli özelliklerin değerleri içeren veriler döndürülür.

Yüz Fotoğraflı Seçin



Analiz Et

Cinsiyet: {'Woman': 60.6955349445343, 'Man': 39.3044650554657}

Yaş: 35

Baskın Duygu: happy

Kişilik yorumu:

Teknolojiye olan bağımlılığın yok veya düşük. Yeni teknolojik aletler konusunda pek ilgi göstermiyorsun.

Kitap okuma alışkanlığın oldukça gelişmiş. Çeşitli konularda farklı kitapları okumayı seviyorsun.

Kahve içme alışkanlığın oldukça yaygın. Gün içinde sık sık kahve içiyorsun.

Kıskançlık eğilimin oldukça yüksek. Yakın çevrende olan olaylara duyarlı ve kıskançlık gösterebiliyorsun.

Kendine oldukça düşkün birisiniz.

Sorumluluk sahibi birisiniz, çevrenizdeki insanlar size güvenebilirler.

Sosyal etkinliklere katılmaktan hoşlanıyorsunuz.

Dürüstlük konusunda oldukça güvenilir birisiniz.

Şekil 2.6. Yüz görüntüsü analiz tahminlemesi.


Bu şekilde, DeepFace kütüphanesi, yüz tanıma ve yüz analizi işlemleri için kullanılarak, derin öğrenme teknikleriyle önceden eğitilmiş modellerin kullanımını sağlar. Bu modeller, yüz tanıma ve analizi için genellikle büyük veri setleri üzerinde eğitilmiş ve çeşitli yüz özelliklerini tanımlama yeteneğine sahiptir. Bu sayede, verilen görüntüdeki yüz hakkında cinsiyet, yaş ve görüntüdeki yüz ifadesine göre bir duygu tahminlemesinde bulunulabilir.

2.5. Random Forest

Breiman tarafından geliştirilen Random Forest algoritması, tek bir karar ağacı yerine, farklı eğitim kümeleriyle eğitilmiş çok sayıda karar ağacının sonuçlarını birleştirerek nihai bir karar oluşturur. Bu yaklaşım, bir sınıflandırıcı yerine birden çok sınıflandırıcı üreten ve sonrasında bu sınıflandırıcıların tahminlerinden alınan oylar ile yeni veriyi sınıflandıran bir öğrenme algoritmasıdır [26].

Rastgele Orman (RF), diğer karar ağaçlarından daha üstündür çünkü daha kesin performans gösterir ve rastgelelik nedeniyle oluşabilecek önyargı, tek bir karar ağacı tarafından telafi edilir [27]. Random Forest algoritması, büyük veri tabanlarında özellikle etkilidir. Çünkü çok sayıda ağaç kullanarak paralel hesaplamalar yapabilir ve bu şekilde veri setinin parçaları üzerinde aynı anda çalışabilir. Ayrıca, dengesiz veri setleri üzerinde de başarılı sonuçlar verir. Dengesiz veri setlerinde, sınıflar arasındaki dağılımın dengesiz olduğu durumlarda, bir sınıfın diğerlerine göre daha fazla örneğe sahip olması gibi durumlarda, Random Forest algoritması hata dengesini sağlayabilir. Random Forest algoritması, kayıp verilerin bulunduğu durumlarda da etkili bir şekilde çalışabilir. Kayıp veriler, bir veri setindeki bazı gözlemlerin eksik olduğu durumlardır. Bu, bir veri noktası için gerekli olan bilgi parçalarının bulunmaması anlamına gelir. Örneğin, bir anket çalışmasında bazı katılımcıların belirli soruları yanıtlamaması ya da bir sensörün arızalanması nedeniyle bazı ölçümlerin eksik kalması gibi durumlar kayıp veri örnekleridir. Kayıp veriler, analizlerde sorun yaratabilir, çünkü eksik bilgiler, modelin doğruluğunu ve güvenilirliğini olumsuz etkileyebilir. Algoritma, kayıp verileri tahmin ederek doldurabilir, bu da modelin doğruluğunu korur. Bu özellik, özellikle gerçek dünyadaki veri setlerinde sıkça karşılaşılan eksik veri sorunlarına çözüm sunar. Böylece, tüm veri seti kullanılarak daha güvenilir sonuçlar elde edilebilir. [28]

RandomForestClassifier, Random Forest adı verilen bir makine öğrenimi algoritmasının sınıflandırma versiyonudur. Bu algoritma, bir veri kümesindeki özellikler ile hedef değişkenler arasındaki ilişkiyi öğrenmek için kullanılır. Random Forest, bir koleksiyon olarak adlandırılan şekil 2.5.'deki gibi bir grup karar ağacından oluşur. Her bir karar ağacı, rastgele seçilen alt örneklemeler ve öznitelikler kullanılarak eğitilir. Bu rastgelelik, modelin aşırı uyuma (overfitting) eğilimini azaltmaya yardımcı olur.



Şekil 2.7. Random Forest Modeli Örnek Gösterimi [29].

RandomForestClassifier, çeşitli endüstrilerde yaygın olarak kullanılan bir sınıflandırma algoritmasıdır. Özellikle çok sınıflı sınıflandırma problemlerinde etkilidir ve genellikle yüksek boyutlu ve karmaşık veri kümeleriyle iyi başa çıkar. Algoritma, her bir karar ağacının tahminlerini kullanarak bir "oylama" veya "ortalama alma" yöntemiyle sınıf tahminini yapar. Bu sayede, birden fazla karar ağacının bir araya getirilmesiyle daha güvenilir ve genelleştirilmiş bir sınıflandırma sonucu elde edilir.


RandomForestClassifier'ın avantajlarından biri, veriye dayalı karar ağaçlarının farklı açılardan bakarak daha doğru ve stabil bir sınıflandırma yapabilmesidir. Ayrıca, aşırı uyumu azaltma özelliği sayesinde genellikle yüksek performans gösterir.

2.6. KNN

K-En Yakın Komşu (KNN), sınıflandırma ve regresyon problemlerinde kullanılan bir denetimli öğrenme algoritmasıdır. Bu algoritma, bir nesnenin hangi sınıfa ait olduğunu belirlemek için o nesneye en yakın komşuların sınıflarını dikkate alır ve bu bilgiye dayanarak sınıflandırma işlemi yapar [30].

K-En Yakın Komşu (KNN) algoritmaları, görüntü işleme, kontrol sistemleri, veri madenciliği, film tavsiyesi, meteoroloji gibi çeşitli alanlarda kullanılmaktadır. Temel amacı, sınıfı belirlenmemiş her bir nesnenin diğer nesnelerle karşılaştırılması ve bu

karşılaştırma sonucunda, kendisine en yakın olan k sayıdaki örneklerin ortalamasıyla birlikte bir gruba atanmasıdır. K-NN, sınıflandırma ve regresyon süreçlerinde, tahmin yaparken daha yakın komşulara daha fazla ağırlık vererek, uzak komşulara göre daha güçlü ilişkiler kurar [31]. Atama işlemi sırasında, nesneler arasındaki uzaklığı hesaplamak için Jaccard uzaklığı, Öklid uzaklığı, Manhattan uzaklığı, basit eşleşme uzaklığı gibi formüller yaygın olarak kullanılmaktadır [32]. Şekil 2.6'da ki görüntüde KNN sınıflandırması modeli gösterilmiştir.



Şekil 2.8. K-En yakın komşu sınıflandırması modeli örnek gösterimi [33]

KNN uygulamalarının basit ve anlaşılır olması, veri dağılımlarında varsayımlar yapmaması ve eğitim sürecini minimuma indirmesi gibi birçok güçlü yanı mevcuttur. Ancak, sınıflandırma yaparken yavaş olması, yüksek bellek gereksinimi duyması ve kayıp verilerin işlem yükünü artırması gibi pek çok zayıf yönü de bulunmaktadır. Bu algoritma kullanıldığında ilk olarak eğitim verilerinden öğrenme gerçekleştirilir ve bu öğrenme sonucunda bir k değeri belirlenir. Literatürde genellikle bu k değeri, eğitim veri setinin karekökü şeklinde ya da 3 ila 10 arasında bir değer olarak belirlenir. K değeri, sistem için uygun kümeleme sayısını ifade eder. Daha sonra veriler, bu değere göre sınıflandırılır [32].

3. DENEYSEL ÇALIŞMALAR VE UYGULAMALAR

3.1. El Analizi


3.1.1. Verilerin toplanması

Verilerin çeşitliliği ve büyüklüğü arttıkça, makine öğrenme modellerinin daha doğru sonuçlar üretmesi beklenmektedir [34] (Ryan, 2018). Bu nedenle, veriler titizlikle toplanmalı ve çalışmanın gereksinimlerine uygun bir şekilde analiz edilmelidir. Veriler, şirketlerden, internet üzerinden ya da çeşitli platformlardan elde edilebilir. Ancak, gerekli veri miktarı sağlanamadığında, araştırmacıların kendi veri setlerini oluşturması gerekebilir. Bu durumda, mülakatlar, deneyler, gözlemler veya anketler gibi çeşitli yöntemler kullanılabilir.

Anketler, belirli bir konu hakkında önceden belirlenmiş hipotezler veya sorular doğrultusunda, belirli bir evren veya örneklem grubundaki kişilere sistemli bir şekilde sorular yönelterek veri toplama tekniğidir [35]. Genellikle çoktan seçmeli, açık uçlu veya derecelendirme biçiminde sorular içeren bu yöntem, katılımcıların görüşlerini, düşünce yapılarını ve tutumlarını anlamaya yönelik bilgiler sağlar.

Anket yöntemi, özellikle sosyal bilimler, pazar araştırmaları, müşteri memnuniyeti analizleri ve eğitim araştırmaları gibi birçok farklı disiplinde yaygın olarak kullanılmaktadır. Bu yöntemde, soruların dikkatlice hazırlanması ve katılımcılara güven vermesi önemlidir. Ayrıca, soru sayısı ve anketin uzunluğu, hedef kitlenin özellikleri ve çalışmanın kapsamı dikkate alınarak belirlenmelidir. Katılımcıların dikkatini sürdürmek için anketin kısa, anlaşılır ve etkili bir şekilde tasarlanması önerilmektedir.

Bu çalışma kapsamında, kullanıcıların kişilik özellikleri ve avuç içi çizgileri arasındaki ilişkiyi değerlendirmek için özgün bir veri seti oluşturulmuştur. Araştırma için kadınlara yönelik bir anket hazırlanmış ve bu anket "Kişilik Analizi Formu" adıyla Google Forms üzerinden sunulmuştur. Anket, katılımcıların internet üzerinden anonim olarak doldurabileceği şekilde tasarlanmıştır. Toplamda 20 sorudan oluşan bu anketi, 450 kadın katılımcı yanıtlamıştır. Katılımcıların yaş dağılımı Şekil 3.1.1'de gösterilmiştir.



Şekil 3.1. Anket katılımcı yaş dağılımı.

3.1.2. Verilerin formatlanması

Anket verileri incelendiğinde, çoğunun metin tabanlı karakterlerden oluştuğu görülmüştür. Veri seti, sayısal formatta değil, metinsel verilerden oluşmaktadır. Bu nedenle, veri setini işleyebilmek ve algoritmalarla kullanabilmek için metinsel verileri sayısal bir formata dönüştürmek gerekmektedir. Bu dönüşüm işlemi, veri setinin grafiksel kullanım veya kod içinde sorun oluşturmaması için önemlidir. Şekil 3.2.3'deki kod parçası, bu dönüşüm işlemi için kullanılmıştır.

```
import csv
formLines = []

with open('Data/FormAnswers.csv', mode='r', encoding='UTF8') as file:
    csvFile = csv.reader(file)
    for lines in csvFile:
        formLines.append(lines)

def FormatData():
    for item in formLines:
        if item[1] == "Evet ":
            item[1] = 1
        elif item[1] == "Hayır ":
            item[1] = 0
```

Şekil 3.2. Veri formatlama kodu.

Şekil 3.1.2'de, "Evet" ve "Hayır" gibi metinsel ifadeler yer almaktadır. Verilerin dönüşümü için "evet = 1, hayır = 0" şeklinde bir yapı kullanılmıştır. Ancak ikili cevaplar dışındaki sorular için farklı bir yönteme ihtiyaç vardır. Bu dönüşüm için

parametrik bir yaklaşım benimsenmiş olup, 1 ve 0 dışındaki rakamlarla işlem yapılmıştır. Örneğin, anketteki "kitap okuma seviyesi" sorusu üç farklı cevap içermektedir: hiç, az, çok. Bu cevaplara sırasıyla 1, 2, 3 numaraları atanmış ve böylece yeni bir veri seti oluşturulmuştur. Bu şekilde düzenlenmiş veri seti, sayısal değerlerden oluşmakta ve algoritmalar için kullanılmaktadır.

3.1.3. Verilerin işlenmesi

Bu çalışmada, veri işleme süreci, modelin doğruluğunu artırmak ve elde edilen sonuçların güvenilirliğini sağlamak amacıyla titizlikle gerçekleştirilmiştir. Veri işleme, ham verilerin modellenenebilir bir forma dönüştürülmesini içerir ve eksik değerlerin işlenmesi, aykırı değerlerin düzeltilmesi, veri ölçeklendirme ve normalizasyon gibi birçok aşamadan oluşur. Özellikle, çalışmanın temelini oluşturan kişilik özellikleri ve avuç içi çizgileri arasındaki ilişkiyi analiz edebilmek için temiz, tutarlı ve dengeli bir veri seti oluşturulması kritik bir önem taşımıştır.

3.1.3.1. Eksik verilerin tespiti ve işlenmesi

Araştırma kapsamında toplanan verilerde, eksik değerlerin varlığı dikkat çekmiştir. Özellikle kişilik analizine yönelik soruların yanıtlanmasında bazı katılımcıların belirli soruları boş bıraktığı gözlemlenmiştir. Bu durum, veri setinde eksikliklere neden olmuş ve analiz sürecinde önemli bir engel teşkil etmiştir. Eksik verilerin işlenmesi için farklı yöntemler değerlendirilmiş ve aşağıdaki yaklaşımlar kullanılmıştır:

- **Ortalama ile Doldurma:** Sürekli değişkenlerde, eksik değerlerin sütunun ortalama değeriyle doldurulması yöntemi kullanılmıştır. Örneğin, katılımcıların yaş verilerinde eksik gözlemler varsa, yaşların ortalaması bu eksik gözlemlere atanmıştır. Bu yöntem, özellikle normal dağılıma sahip veri setlerinde güvenilir sonuçlar üretmiştir.
- **Medyan ile Doldurma:** Yaş gibi bazı değişkenlerde, aşırı uçların (aykırı değerlerin) varlığı nedeniyle ortalama yerine medyan kullanılmıştır. Bu yöntem, aşırı uçların etkisini azaltarak daha dengeli bir doldurma sağlamıştır.
- **Kategorik Değişkenlerde Mod Kullanımı:** Katılımcıların demografik bilgilerinde (örneğin, eğitim durumu) eksik değerler tespit edildiğinde, ilgili değişkende en sık tekrar eden kategori eksik değerlere atanmıştır.

Bu yöntemler sayesinde, eksik veri içeren gözlemler kaybedilmeden veri seti tamamlanmış ve modelin eğitim sürecinde eksik veri kaynaklı hataların önüne geçilmiştir.

3.1.4. Veri ölçeklendirme ve normalizasyon

Veri ölçeklendirme ve normalizasyon, makine öğrenimi modellerinin daha iyi performans göstermesi ve daha güvenilir sonuçlar üretmesi için önemli bir adımdır. Bu süreç, veri setindeki özelliklerin farklı ölçeklerde olması durumunda ortaya çıkan problemleri giderir. Örneğin, bir özellik diğerlerine göre çok daha büyük değerlere sahip olabilir ve bu durum, modelin eğitilmesini etkileyebilir.

Bu tür problemleri çözmek için kullanılan algoritmaların başında StandardScaler sınıfı gelir. Bu çalışmada normalizasyon işlemi için, StandardScaler sınıfı tercih edilmiştir. Bu sınıf, veri setindeki her bir özelliği belirli bir aralığa ölçeklendirir. Özellikle, özellikleri birbirine benzer bir ölçeğe getirerek, her özelliğin ortalamasını 0 ve standart sapmasını 1 yapar. Bu, veri setinin istatistiksel olarak standartlaştırılmasını sağlar.

StandardScaler, veri setinin her bir özelliğini aynı ölçeğe getirirken, orijinal veri setinin dağılımını değiştirmez. Bu sayede, model eğitilirken her bir özellik aynı derecede etkili olur ve model daha dengeli bir şekilde öğrenir. Ayrıca, ölçeklendirme işlemi, modelin daha hızlı ve daha istikrarlı bir şekilde eğitilmesini sağlar.

Sonuç olarak, StandardScaler gibi ölçeklendirme ve normalizasyon algoritmaları, makine öğrenimi modellerinin daha iyi performans göstermesine ve daha güvenilir sonuçlar üretmesine yardımcı olur. Bu nedenle, veri işleme sürecinde bu tür tekniklerin kullanılması önemlidir. Kişilik özellikleri ve avuç içi çizgileri arasındaki ilişkinin daha sağlıklı bir şekilde incelenmesine olanak tanımıştır.

3.1.5. Algoritmanın belirlenmesi

Bu çalışmada, kişilik analizi gerçekleştirmek için hem yüz hem de avuç içi çizgilerinin analizine dayalı bir sistem geliştirilmiştir. Kişilik analizi sürecinde kullanılacak algoritmaların belirlenmesi, projenin doğruluğu ve başarısı açısından kritik bir öneme sahiptir. Özellikle, verilerin niteliği ve hedeflenen sınıflandırma türleri göz önünde bulundurularak, denetimli öğrenme algoritmalarının daha uygun olduğu tespit edilmiştir.

Projede kullanılan algoritmaların seçiminde temel amaç, avuç içi çizgilerinin özelliklerini analiz etmek ve bu özelliklere dayanarak kişilik özelliklerini sınıflandırmaktır. Avuç içindeki çizgilerin uzunluğu, kalınlığı ve şekli gibi yapısal özellikler, bireylerin kişilik özelliklerini yansıtabileceğinden, bu özelliklerin makine öğrenimi algoritmalarıyla modellenmesi hedeflenmiştir.

Denetimli sınıflandırma algoritmaları, belirli bir eğitim veri setine dayanarak öğrenen ve daha sonra yeni veri noktalarını belirli sınıflara atayan algoritmalar. Bu projede de avuç içi çizgileri, önceden etiketlenmiş bir eğitim veri seti kullanılarak analiz edilmiş ve bir sınıflandırma modeli oluşturulmuştur. Modelin oluşturulmasının ardından, yeni avuç içi çizgileri analiz edilmiş ve bu analiz sonuçları, sınıflandırma modeli tarafından belirlenen kategorilere atanmıştır.

Çalışmada kullanılan ilk algoritma olan Random Forest, bu projede avuç içi çizgilerinin analizi ve kişilik sınıflandırması için temel algoritma olarak seçilmiştir. Random Forest, birçok karar ağacından oluşan bir makine öğrenimi algoritmasıdır. Her bir karar ağacı, rastgele alt örnekleme ve öz nitelik seçimi ile oluşturulmuştur. Bu yöntem:

- Daha yüksek genelleme yeteneği sağlayarak aşırı uyumu azaltır.
- Karmaşık ve yüksek boyutlu veri kümeleriyle etkili bir şekilde çalışır.
- Birden fazla karar ağacının sonuçlarını birleştirerek daha kararlı ve güvenilir sınıflandırma sonuçları üretir.

RandomForestClassifier sınıflandırma algoritması, eğitim sürecinde avuç içi çizgilerinin özelliklerini (örneğin, uzunluk, eğim, kalınlık) hedef sınıflarla ilişkilendirerek bir model oluşturmuştur. Eğitim tamamlandıktan sonra, model yeni veri noktalarını belirli kişilik kategorilerine sınıflandırmak için kullanılmıştır.

Çalışma sırasında, avuç içi çizgilerinin analizi için KNN (K-Nearest Neighbors) algoritması da destekleyici bir yöntem olarak değerlendirilmiştir. KNN, özellikle karmaşık durumlarda ve sınırlı eğitim verisi bulunduğunda etkili bir alternatif olarak kullanılmaktadır. KNN algoritması, sınıflandırma için basit ve etkili bir yöntem sunar. Bu algoritma, verilen bir veri noktasının, eğitim veri setinde en yakın komşuları ile karşılaştırılmasını ve bu komşuların çoğunluğuna göre sınıflandırma yapılmasını sağlar. KNN algoritmasının temel avantajları şunlardır:

- Basitlik ve Etkinlik: KNN, uygulanması oldukça basit bir algoritmadır ve küçük veri setleri ile hızlı sonuçlar verebilir.
- Parametresiz: KNN'nin, parametre ayarlamaları gerektirmemesi, kullanıcılar için oldukça pratik bir çözüm sunar. Modelin doğruluğu, temel olarak kullanılan komşu sayısına (K değeri) bağlıdır.
- Esneklik: KNN, hem sayısal hem de kategorik verilerle çalışabilir ve herhangi bir ön işleme veya modelin yapısal değişikliği gerektirmez.

Ancak KNN algoritması, büyük veri setlerinde, özellikle çok sayıda özellik ve büyük örneklem ile çalışırken performans sorunları yaşayabilir. Ayrıca, komşu sayısı ve mesafe ölçütü gibi parametrelerin doğru ayarlanması, modelin doğruluğunu etkileyebilir. Bu sebeple, KNN yalnızca karmaşık durumlar ve sınırlı eğitim verisi ile sınıflandırma yapılması gereken senaryolarda kullanılması gerekmektedir.

Projede kullanılan algoritmalarından biri de SVC (Support Vector Classifier) algoritmasıdır. SVC, denetimli öğrenme algoritmalarından biri olup, veriyi sınıflara ayıran bir hiperrüzgar oluşturur ve bu hiperrüzgarın iki sınıf arasındaki en geniş marjı (distance) bulmaya çalışır. Bu algoritma, genellikle sınıflandırma problemlerinde, özellikle doğrusal olmayan veriler için etkili bir çözümdür.

Ancak, çalışmada kullanılan veri setine SVC algoritmasının uygulanmasının ardından, istenilen sonuçların elde edilemediği gözlemlenmiştir. Özellikle şu nedenlerle SVC algoritması veri setimize uygun bulunmamıştır:

SVC algoritmasının çıktıları, özellikle karmaşık veri setlerinde yorumlanması zor olabilmektedir. Bu algoritma, sınıflandırma sonucunda her veri noktasını bir sınıfla etiketlerken, doğrusal olmayan sınırları bulabilmek için yüksek hesaplama gücü gerektirebilir. Veri setimizde yer alan özelliklerin birbirine yakın olması ve karmaşık ilişkiler içermesi, SVC'nin daha doğru ve anlamlı sonuçlar üretmesini zorlaştırmıştır. Ayrıca, kernel fonksiyonları gibi parametre ayarlarının düzgün yapılandırılmaması durumunda, modelin doğruluğu ciddi şekilde etkilenebilir ve çıktılar daha belirsiz hale gelebilir.

Veri setinde bulunan karmaşık ve çok boyutlu özellikler, SVC algoritmasının istenilen şekilde sınıflandırma yapmasını engellemiştir. Modelin başarısını artırmak için parametrelerin ve kernel fonksiyonlarının dikkatlice seçilmesi gerekirdi, ancak bu süreç, özellikle verinin yüksek boyutlu ve heterojen olduğu durumlarda daha karmaşık

hale gelmektedir. SVC'nin doğrusal olmayan sınırları öğrenmesi zorluğu nedeniyle, daha uygun algoritmalarla daha yüksek doğruluklar elde edilebileceği anlaşılmıştır.

Sonuç olarak, SVC algoritmasının sınıflandırma görevi için yeterince iyi sonuçlar verememesi ve karmaşık çıktıların yorumlanmasındaki zorluklar, projenin amacına ulaşabilmesi için başka algoritmaların seçilmesi gerektiğini ortaya koymuştur. Bu nedenle, Random Forest ve K-En Yakın Komşu (KNN) gibi daha uygun algoritmalar tercih edilmiştir. Bu algoritmalar, veri setimize daha uygun sonuçlar sağlamış ve projenin gereksinimlerine daha iyi hizmet etmiştir.

3.1.6. Model eğitim süreci

Veri hazırlığı, makine öğrenimi sürecinin kritik bir aşamasıdır. Bu çalışmada, veri seti bir CSV dosyasından yüklenmiştir ve bu veri setinden bağımsız değişkenler (X) ve bağımlı değişkenler (y) seçilmiştir. Bağımsız değişkenler, kişinin el çizgilerini temsil ederken, bağımlı değişkenler kişilik özelliklerini temsil etmektedir. Bu, sınıflandırma görevine uygun hale getirilmiş bir hedef değişken formatıdır.

Makine öğrenimi modellerinin genellenebilirliğini sağlamak için, veri setinin eğitim ve test setlerine ayrılması gerekmektedir. Bu aşama, modelin daha önce görmediği verilerle değerlendirilmesini ve performansının test edilmesini sağlar. Bu çalışmada, veri seti eğitim (%80) ve test (%20) olarak ikiye ayrılmıştır. Eğitim seti, modelin öğrenme sürecinde kullanılacakken, test seti modelin eğitildikten sonra doğruluğunu değerlendirmek için kullanılmaktadır. Bu ayırım, modelin aşırı öğrenme (overfitting) riskini azaltmak için önemlidir, çünkü model yalnızca eğitim verisiyle değil, daha önce görmediği verilerle de doğruluğunu test edebilme fırsatına sahip olur.

İlk olarak, modelin eğitilmesinde Random Forest algoritması kullanılmıştır. Random Forest, çok sayıda karar ağacının birleşiminden oluşan bir topluluk (ensemble) öğrenme yöntemidir ve her bir ağaç, farklı özelliklerin rastgele seçilmesiyle eğitilir. Bu yöntem, yüksek doğruluk oranları ve genel performans açısından güçlüdür. Model, `n_estimators=100` parametresiyle 100 farklı karar ağacından oluşmuş ve bu ağaçların kombinasyonu sonucunda son tahmin yapılmıştır. Ayrıca `random_state=42` parametresi, modelin sonuçlarının tekrarlanabilirliğini sağlamıştır. Eğitim sırasında, modelin her bir ağacı veriye özgü örüntüleri öğrenirken, topluluk yöntemi ile bu bireysel ağaçlardan elde edilen tahminler birleştirilerek daha doğru bir sonuç elde edilmiştir.

Modelin eğitilmesinde kullanılan ikinci algoritma KNN (K-Nearest Neighbors) algoritmasıdır. KNN (K-Nearest Neighbors) algoritmasında, modelin başarısı büyük ölçüde kullanılan hiperparametrelerin doğru seçilmesine dayanır. Bu kodda, hiperparametre optimizasyonu için GridSearchCV kullanılmıştır. n_neighbors parametresi, modelin tahminlerde bulunurken dikkate alacağı komşu sayısını belirler ve genellikle küçük değerler aşırı uyuma yol açarken, büyük değerler genelleştirilmiş sonuçlar sunar. Weights parametresi, komşulara verilecek ağırlıkları belirler; burada 'uniform' her komşuya eşit ağırlık verirken, 'distance' daha yakın komşulara daha fazla ağırlık verir. Metric parametresi, komşular arasındaki mesafenin nasıl hesaplanacağını belirler ve 'euclidean' mesafe ölçütü, düz çizgi mesafesi kullanarak hesaplama yaparken, 'manhattan' şehir blokları mesafesi kullanır. Bu parametreler GridSearchCV aracılığıyla çapraz doğrulama ile optimize edilerek en iyi model parametreleri bulunmuş ve modelin doğruluğu artırılmıştır. Bu sayede, modelin daha doğru ve genelleştirilmiş sonuçlar vermesi sağlanmıştır.

Modelin eğitilmesinde kullanılan üçüncü algoritma ise SVC (Support Vector Classifier) algoritmasıdır. Sınıflandırma problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenimi yöntemidir. Bu projede, kişilik özelliklerini (örneğin Kahve içme alışkanlığı, Kıskançlık, Kitap okuma sıklığı, Sorumluluk, Teknoloji bağımlılığı gibi) tahmin etmek için her bir özellik için ayrı bir SVC modeli eğitilmiştir. Veri setindeki her bir özellik (yani her etiket) için model, eğitim verileri üzerinden öğrenme yaparak, bu özelliklerin doğru sınıflandırılabilmesi için en uygun hiperdüzlemi (decision boundary) bulur. Modelin eğitiminde, SVC kernel='linear' parametresi kullanılmıştır, bu da verilerin doğrusal bir şekilde ayrılabilceğini varsayar. Bu süreç, her bir kişilik özelliği için ayrı bir SVC modelinin eğitildiği, sınıflandırma sonuçlarının kullanıcı girdileri ile karşılaştırıldığı bir dizi adımdan oluşur.

3.1.7. Verilerin test edilmesi

Modelin doğruluğu, eğitim sürecinde öğrenilen ilişkilerin test veri setindeki verilere uygulanarak ölçülür. Eğitim sürecinin ardından, modelin performansı test veri seti üzerinden değerlendirilir. Bu aşamada, modelin tahmin yeteneklerinin gerçek verilerle karşılaştırılması sağlanmıştır. Test veri seti, veri kümesinin daha küçük bir bölümünü oluşturur ve eğitim sırasında öğrenilen bilgilerin gerçek dünya senaryolarında geçerli olup olmadığını belirlemeye yardımcı olmaktadır. Bu karşılaştırma süreci, modelin doğruluğunu ve genel başarısını değerlendirmede önemli bir rol oynamaktadır.

3.2. Yüz Analizi

Yüz analizi, bir görüntü üzerinde yer alan yüzlerden çeşitli kişisel özelliklerin çıkarılması işlemidir. Bu çalışma kapsamında, yüz analizi için derin öğrenme tabanlı DeepFace kütüphanesi ve yüz tespiti için OpenCV kullanılmıştır. Bu araçlar, yüz tanıma, yaş tahmini, cinsiyet belirleme ve duygusal durum analizi gibi görevlerde yüksek performans sunarak, projenin ihtiyaçlarını karşılamak üzere entegre edilmiştir.

3.2.1. Yüz analizi süreci ve algoritmalar

Yüz analizi süreci, görüntüden yüzlerin tespit edilmesi ve bu yüzlerin çeşitli özelliklerinin analiz edilmesini içerir. Çalışmada bu sürecin aşamaları şu şekildedir:

1. Yüz Tespiti:

Yüz tespiti, OpenCV'nin Haar Cascade Classifier algoritması kullanılarak gerçekleştirilmiştir. Bu algoritma, önceden eğitilmiş bir model yardımıyla görüntüdeki yüzleri algılar. Yüz tespiti sırasında:

- Görüntü öncelikle gri tonlamaya dönüştürülür, böylece hesaplama yükü azaltılır.
- Haar Cascade Classifier, yüz tespiti yapar ve yüz bulunamazsa "Yüz bulunamadı" uyarısı verir.
- Yüz tespiti başarılı olursa, bir sonraki adıma geçilir.

2. Yüz Özelliklerinin Analizi:

Yüz analizi, DeepFace kütüphanesi kullanılarak gerçekleştirilmiştir. Bu kütüphane, yüzün yaş, cinsiyet, baskın duygusal durumu gibi özelliklerini çıkarabilen bir araçtır. Çalışmada:

- DeepFace.analyze fonksiyonu, tespit edilen yüzlerin yaşını, cinsiyetini ve duygularını tahmin etmek için kullanılmıştır.

DeepFace, önceden eğitilmiş derin öğrenme modelleri kullanır ve büyük veri setleriyle eğitildiği için genellikle yüksek doğrulukla sonuç verir. Bununla birlikte, analiz edilen yüzün netliği, çözünürlüğü ve çekim açısı gibi faktörler modelin doğruluğunu etkileyebilir.

3. Yüz Analizinin Sınırlamaları

Yüz analizi, her ne kadar derin öğrenme tabanlı yöntemlerle yüksek doğruluk sunsa da bazı sınırlamaları bulunmaktadır:

- Yüzün bulanık olması, düşük çözünürlükte veya farklı bir açıyla çekilmiş olması analiz doğruluğunu düşürebilir.
- Duygusal analiz ve yaş tahmini gibi görevlerde, özellikle standart dışı durumlarda sınırlı doğruluk gözlemlenebilir.

Bu çalışmada kullanılan yüz analizi yöntemi, kişisel özellikleri tahmin etme amacına yönelik etkili bir çözüm sunmuştur. DeepFace ve OpenCV'nin birlikte kullanımı sayesinde, kullanıcıların yüz özellikleri detaylı bir şekilde analiz edilmiştir.

3.3. Gerçekleştirilen Uygulama ve Arayüz Tasarımı

Bu projede, makine öğrenimi yöntemleri kullanılarak hem el analizi hem de yüz analizi yapabilen bir uygulama geliştirilmiştir. Uygulamanın temel amacı, kullanıcılara kişilik özellikleri hakkında bilgi sunmak ve bu bilgileri avuç içindeki çizgiler ile yüz fotoğrafları üzerinden analiz etmektir. Kullanıcılara, 450 kişiden toplanmış verilerle avuç içindeki çizgiler ve yüz fotoğrafları üzerinde yapılan analizlere dayalı olarak kişilik analizleri sunulmaktadır. Bu uygulama, kullanıcılara kendilerini daha iyi tanıma fırsatı sunar ve kişilik özellikleri hakkında tahminlerde bulunarak farklı bir perspektif sağlar.

3.3.1. Yüz analizi

Uygulamanın yüz analizi bölümü, kullanıcılara yüz fotoğrafı seçme imkânı tanır. Kullanıcılar, seçtikleri yüz fotoğrafını sisteme yükler ve bu fotoğraf üzerinden yaş, cinsiyet ve duygusal durum gibi özellikler analiz edilir. DeepFace gibi yüz analizi kütüphaneleri kullanılarak yapılan bu analiz, kullanıcılara yüzlerinde bulunan çeşitli özellikler hakkında bilgi sunar. Bu aşama, yüz analizi yapan makine öğrenimi modelleri sayesinde hızlı ve doğru sonuçlar elde edilmesini sağlar.

3.3.2. El analizi

Uygulamanın el analizi bölümü, kullanıcıların avuç içindeki çizgileri seçmesine olanak tanır. Avuç içindeki çizgiler, kalp çizgisi, akıl çizgisi ve hayat çizgisi gibi temel el hatlarını içerir. Kullanıcılar bu çizgileri seçtikten sonra, makine öğrenimi algoritmaları bu çizgilere dayanarak kişilik analizini yapar. Bu analiz, kullanıcının avuç içindeki çizgilerin yapısına göre tahminler sunar. Örneğin, avuç içi çizgilerinin

uzunluğu, eğimi ve kalınlığı gibi yapısal özellikler, kişilik analizi yapmak için önemli veriler sağlar.

3.3.3. Uygulama arayüzü

Uygulamanın kullanıcı dostu arayüzü, Tkinter kütüphanesi ile geliştirilmiştir. Arayüzdeki ana bileşenler şu şekildedir:

- **Arayüz Tasarımı:** Tkinter kullanılarak bir pencere oluşturulmuş ve içinde çeşitli bileşenler (butonlar, etiketler, metin kutuları) eklenmiştir.
- **Resim Seçme Butonu ve Görüntü Görüntüleme:** Kullanıcılar, yüz fotoğrafını seçmek için dosya tarayıcısından bir görüntü seçebilirler. Seçilen görüntü, arayüzde görüntülenir ve daha sonra analiz için kullanılır.
- **El Çizgilerinin Seçimi:** Kullanıcılar, avuç içindeki kalp, akıl ve yaşam çizgilerini seçmek için radyo butonları aracılığıyla bu çizgileri belirler. Bu seçimler, kişilik analizine dahil edilmek üzere alınır.
- **Analiz Butonu:** Kullanıcıların seçtikleri fotoğraf ve el çizgileri ile kişilik analizini başlatacak bir buton bulunmaktadır. Butona tıklandığında, algoritmalar analiz işlemine başlar ve sonuçlar arayüzde görüntülenir. Tüm alanlar doldurulmazsa, kullanıcıya bir uyarı mesajı gösterilir.

3.3.4. Kullanıcı deneyimi ve sonuçlar

Geliştirilen uygulama, kullanıcı dostu arayüzü ile analiz işlemlerini hızlı bir şekilde gerçekleştirir. Kullanıcılar, yüz fotoğrafı ve avuç içi çizgilerini seçtikten sonra, kişilik analizi sonuçlarını anında alabilirler. Bu uygulama, kişilik analizi yapmak isteyen araştırmacılar ve uygulama geliştiriciler için verimli bir araçtır. Ayrıca, kullanıcıların kendileri hakkında daha fazla bilgi edinmelerini ve gelişimlerini desteklemeyi amaçlayan interaktif bir platform sunar.

3.4. Kullanılan Algoritmaların Karşılaştırılması

Bu çalışmada, farklı makine öğrenimi algoritmalarının çoklu sınıflandırma problemleri üzerindeki performansları karşılaştırılmıştır. Değerlendirme kapsamında Random Forest, KNN (K-En Yakın Komşu) ve SVC (Destek Vektör Sınıflandırıcısı) algoritmaları incelenmiş, her bir algoritmanın avantajları ve dezavantajları analiz edilmiştir.

İlk olarak, Random Forest sınıflandırıcısı kullanılmıştır. Random Forest, doğrudan çok sınıflı çıktıları desteklemediği için, hedef değişkenler birleştirilerek tek bir çok sınıflı hedef değişken oluşturulmuş ve model RandomForestClassifier ile eğitilmiştir. Bu yöntemle %45 doğruluk oranı elde edilmiştir. Ancak, bu doğruluk oranı yeterli bulunmamış ve farklı algoritmaların değerlendirilmesine karar verilmiştir.

Daha sonra, KNN algoritması uygulanmıştır. KNN, çoklu çıktıları destekleyen bir sınıflandırıcıdır. Ancak, modelin performansı %0.38 MSE değeri ile sınırlı kalmıştır. Bu sonuç, KNN algoritmasının veri setini yeterince iyi genelleyemediğini ve düşük tahmin performansı sergilediğini göstermiştir. Daha iyi sonuçlar elde etmek için hiperparametre optimizasyonu, daha karmaşık bir model veya genişletilmiş bir veri seti kullanımının gerekli olduğu sonucuna varılmıştır.

Son olarak, SVC algoritması değerlendirilmiştir. Ancak, SVC veri setine uygun bir performans gösterememiştir. Çıktılarının yorumlanması karmaşık olduğu gibi, istenilen sonuçlar da elde edilememiştir. Bu nedenle, SVC yerine daha uygun bir algoritmanın tercih edilmesi gerektiği sonucuna ulaşılmıştır.

En iyi sonuçlar, tekrar Random Forest algoritması ile elde edilmiştir. Random Forest, doğrusal olmayan ilişkileri ele alma kabiliyeti sayesinde diğer algoritmalara kıyasla daha başarılı bir performans sergilemiştir. Ayrıca, tahminlerin daha kolay yorumlanabilir olması, bu algoritmayı diğerlerine göre avantajlı kılmıştır.

Sonuç olarak, bu çalışmada Random Forest, KNN ve SVC algoritmaları karşılaştırılarak her birinin güçlü ve zayıf yönleri ortaya konmuştur. Kullanılan algoritmalar ve elde edilen sonuçlar ise Tablo 3.4'de sunulmaktadır.

Table 3.1. Kullanılan algoritmalar ve elde edilen sonuçlar.

Algoritma	Doğruluk (%)	Ortalama Kare Hatası (MSE)	Avantajları	Dezavantajları
SVC (Destek Vektör Makineleri)	-	-	Doğrusal sınırlara duyarlıdır; yüksek boyutlu verilerde etkilidir.	Doğrusal olmayan verilerde yetersiz performans sergiler.
Random Forest	%45	-	Doğrusal olmayan ilişkilerde başarılı; kararlı ve genelleştirilebilir.	Hiperparametre optimizasyonuna ihtiyaç duyar; daha büyük veri seti gerektirir.
K-En Yakın Komşu (KNN)	-	%38	Basit ve sezgisel yöntem; küçük veri setlerinde iyi performans sergilemektedir.	Büyük veri setlerinde yavaş; karmaşık veri yapılarında zayıftır.

Random Forest algoritması, veri setine en uygun çözüm olarak öne çıkmıştır. Bununla birlikte, bu sonuçların belirli bir veri setine dayandığı ve farklı veri setlerinde farklı algoritmaların daha iyi performans gösterebileceği göz önünde bulundurulmalıdır. Dolayısıyla, algoritma seçiminin, veri setinin özelliklerine ve problem tanımına uygun bir şekilde yapılması gerektiği vurgulanmıştır. Bu karşılaştırma, gelecekteki çalışmalarda daha etkili modellerin geliştirilmesine ve daha iyi sonuçların elde edilmesine katkı sağlayabilir.



4. SONUÇLAR

Bu tez çalışması, avuç içi çizgileri ve yüz analizi kullanılarak kişilik özelliklerinin tahmin edilmesini ve yorumlanmasını amaçlamaktadır. Çalışmanın sonuçları, elde edilen bulgulara dayanarak aşağıdaki şekilde özetlenebilir:

- 1. Kişilik Özelliklerinin Tahmini:** Çalışma, avuç içi çizgileri ve yüz analizi kullanılarak kişilik özelliklerinin tahmin edilmesini sağlayan bir sistem geliştirmiştir. Bu sistem, kullanıcıların avuç içi çizgilerini ve yüz fotoğraflarını analiz ederek teknoloji bağımlılığı, kitap okuma sıklığı, kahve tüketimi gibi çeşitli kişilik özelliklerini tahmin etmektedir.
- 2. Analiz Yönteminin Doğruluğu:** Geliştirilen sistem, elde edilen sonuçların doğruluğunu değerlendirmek için çeşitli metrikler kullanmıştır. Bu metrikler arasında doğruluk oranı, doğruluk değeri ve hata matrisi bulunmaktadır. Yapılan değerlendirmeler, sistemin kişilik özelliklerini tahmin etmede yüksek doğruluk oranlarına sahip olduğunu göstermektedir.
- 3. Yorumların Yapılması:** Sistem, tahmin edilen kişilik özelliklerine göre yorumlar yapabilmektedir. Her bir kişilik özelliği için belirlenen eşik değerlere göre uygun yorumlar seçilmekte ve kullanıcıya sunulmaktadır. Bu yorumlar, kullanıcıların kişilik özellikleri hakkında daha derinlemesine bir anlayışa sahip olmalarını sağlamaktadır.
- 4. Uygulama Alanları ve Potansiyel Kullanımlar:** Geliştirilen sistem, kişilik analizi alanında çeşitli uygulama alanlarına sahiptir. Bunlar arasında insan kaynakları yönetimi, pazar araştırmaları, psikolojik danışmanlık ve kişisel gelişim gibi alanlar bulunmaktadır. Sistemin potansiyel kullanımları, gelecekteki araştırmalara ve uygulamalara ilham kaynağı olabilir.
- 5. Öneriler ve Gelecek Çalışmalar:** Çalışmanın sonuçlarına dayanarak, kişilik analizi alanında daha fazla araştırma yapılması ve yeni yöntemlerin geliştirilmesi önerilmektedir. Ayrıca, sistemdeki doğruluk ve performansı artırmak için yeni veri setleriyle ve daha gelişmiş algoritmalarla çalışılması gerekmektedir.



KAYNAKLAR

- [1] Alshakree, A., Akbas, A., Rahebi, J., (2023) "Human identification using palm print images based on deep learning methods and gray wolf optimization algorithm" *Signal, Image and Video Processing* Volume 18 pages 961–973 <https://doi.org/10.1007/s11760-023-02787-6>
- [2] IEEE. (2024). *Image Processing Technology Based on Machine Learning*. IEEE Journals & Magazine. <https://ieeexplore.ieee.org/document/9712416>
- [3] S. Zhao and B. Zhang, "Learning salient and discriminative descriptor for palmprint feature extraction and identification," *IEEE transactionson neural networks and learning systems*, vol. 31, no. 12, pp. 5219- 5230, 2020.
- [4] Taigman, Y., Yang, M., Ranzato, M., & Wolf, L. (2014). DeepFace: Closing the Gap to Human-Level Performance in Face Verification. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1701-1708. doi:10.1109/CVPR.2014.220.
- [5] Acharjee, S., Nuannimnoi, S., & Huang, C.-Y. (2020). A Deep Learning Approach for Efficient Palm Reading. *International Conference on Technologies and Applications of Artificial Intelligence (TAAI)* doi:10.1109/TAAI51410.2020.00039
- [6] Dr. Hlaing Htake Khaung Tin "An Effective Method of a Person's Character or Future using the Palm Print Images" *International Journal of Research and Scientific Innovation-IJRSI* vol.4 issue 1, pp.09-12 2016
- [7] <https://docs.python.org/3/library/tk.html> adresinden 28.04.2024 tarihinde alınmıştır.
- [8] Lundh, F. (1999). *An Introduction to Tkinter*. Training Document, Washington State University. <http://users.tricity.wsu.edu>
- [9] Gary B. Huang, Marwan Mattar, Tamara Berg, ve Erik Learned-Miller (2008) "Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments" HAL Id: inria-00321923 <https://inria.hal.science/inria-00321923>
- [10] Hangaragi, S., Singh, T., Neelima, N. (2023) "Face Destection and Recognition Using Face Mesh and Deep Neural Network" *Procedia Computer Science* Volume 218 pp. 741-749 <https://doi.org/10.1016/j.procs.2023.01.054>
- [11] Trabelsi, S., Samai, D., Dornaika, F., Benlamoudi, A., Bensid, K., (2022) "Efficient palmprint biometric identification systems using deep learning and feature selection methods" *Neural Computing and Applications* Volume 34 pp. 12119–12141 <https://doi.org/10.1007/s00521-022-07098-4>

- [12] Tsai, T.H., Chi, P.T. (2022) "A single-stage face detection and face recognition deep neural network based on feature pyramid and triplet loss" *The Institution of Engineering and Technology* Volume 16 pages 2148-2156 <https://doi.org/10.1049/ipr2.12479>
- [13] Bansal, M., Prince, Yadav, R., Ujjwal, P., (2021) "Palmistry using Machine Learning and OpenCV" *Fourth International Conference on Inventive Systems and Control (ICISC)* Page(s):536 - 539 ISBN: 978-1-7281-2813-9 DOI: 10.1109/ICISC47916.2020.9171158
- [14] Türk, Ö., Çalışkan, A., Acar, E., Ergen, B., (2023) "Palmprint recognition system based on deep region of interest features with the aid of hybrid approach " *Signal, Image and Video Processing* Volume 17 Pages 3837–3845 <https://doi.org/10.1007/s11760-023-02612-0>
- [15] Ebrahimpour, N., Günay, F., (2023) "Palmprint recognition using pre-trained convolutional neural networks" *SETSCI Conference Proceedings*, 15(1), 51-54. <https://doi.org/10.36287/setsci.6.1.018>
- [16] Büyük Veri Analizinde Yapay Zeka Ve Makine Öğrenmesi Uygulamaları Yıl 2017, Cilt:9 Sayı:22,155 – 172, 31.12.2017 <https://doi.org/10.20875/makusobed.309727>
- [17] Philip C. Jackson, On achieving human-level knowledge representation by developing a natural language of thought, *Procedia Computer Science*, Volume 190, 2021, Pages 388-407, ISSN 1877-0509. <https://doi.org/10.1016/j.procs.2021.06.048>
- [18] Bilgin, M. (2018). *Makine Öğrenmesi*. İstanbul: Papatya Yayınevi, Papatya Yayıncılık: 13
- [19] Denetimli Öğrenme Nedir ? <https://medium.com/machine-learning-t%C3%BCrkiye/ad%C4%B1m-ad%C4%B1m-makine-%C3%B6%C4%9Frenmesi-b%C3%B6l%C3%BCm-2-denetimli-%C3%B6%C4%9Frenme-nedir-80ffb1322e4f> adresinden 29.03.2024 tarihinde alındı.
- [20] Çoban, Ö. (2016). *Metin sınıflandırma teknikleri ile türkçe twitter duygu analizi*. Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü.
- [21] Patil, S. K., & Sane, P. S. (2020). Spam detection using machine learning algorithms. *International Journal of Scientific & Technology Research*, 9(2), 1013-1017.
- [22] Belkacem, S. (2021). *Machine learning approaches to rank news feed updates on social media* [Yüksek lisans tezi, Université des Sciences et de la Technologie Houari Boumediene]. Artificial Intelligence [cs.AI] Available at: <https://theses.hal.science/tel-03201363>.
- [23] Denetimsiz Öğrenme Nedir? <https://medium.com/machine-learning-t%C3%BCrkiye/ad%C4%B1m-ad%C4%B1m-makine-%C3%B6%C4%9Frenmesi-b%C3%B6l%C3%BCm-3-denetimsiz-%C3%B6%C4%9Frenme-nedir-f890ada49a40> adresinden 29.03.2024
- [24] Supervised & Unsupervised learning. <https://www.geeksforgeeks.org/supervised-unsupervised-learning/> adresinden 25 Nisan 2024 tarihinde alınmıştır.

- [25] An Introduction to Machine Learning. monkeylearn.com: <https://monkeylearn.com/machine-learning/> adresinden alındı 29.03.2024.
- [26] Nizam, H., & Akın, S. S. (2014). Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. Presented at XIX. Türkiye'de İnternet Konferansı, İzmir, Turkey.
- [27] J. Cao, Z. Zhang, F. Tao, L. Zhang, Y. Luo, J. Han, and Z. Li, "Identifying the contributions of multi-source data for winter wheat yield prediction in China," Remote Sens., vol. 12, no. 5, p. 750, Feb. 2020.
- [28] Leo Breiman and Adele Cutler, Random Forests, 2005.
- [29] Fu, H., & Qi, K. (2022). Evaluation Model of Teachers' Teaching Ability Based on Improved Random Forest with Grey Relation Projection. Scientific Programming, 2022(4), 1-12. <https://doi.org/10.1155/2022/5793459>
- [30] Özkan, Y. (2008). Veri madenciliği yöntemler (3.baskı).İstanbul: Papatya Yayıncılık.
- [31] F. Abbas, H. Afzaal, A. A. Farooque, and S. Tang, "Crop yield prediction through proximal sensing and machine learning algorithms," Agronomy, vol. 10, no. 7, p. 1046, Jul. 2020.
- [32] Lantz, B. (2013). Machine Learning with R (1.baskı). Birmingham: Packt Publishing Ltd.
- [33] Emhan, Ö., & Akın, M. (2019). *Filtreleme Tabanlı Öznitelik Seçme Yöntemlerinin Anomali Tabanlı Ağ Saldırısı Tespit Sistemlerine Etkisi*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(2), 549-559.
- [34] Ryan, J. (2018). Machine Learning: In Plain English. 15 Nisan 2024 tarihinde <https://dzone.com/articles/machine-learning-in-plain-english>, adresinden erişildi.
- [35] Anket Tekniği. <https://www.bingol.edu.tr/media/226197/sayt-bolum13c-anket-teknigi.pdf> adresinden 15.04.2024 tarihinde erişildi.



EKLER

EK A. Kişilik Analizi Formu

EK B. Etik Kurulu İzin Belgesi




Tablo A.1. Anket Soruları

Soru

Cevaplar

1. SOL ELİNİZDEKİ AKIL ÇİZGİSİ (ORTA ÇİZGİ),
GÖRÜNTÜDEKİ ŞEKİLLERDEN HANGİSİNE BENZİYOR
?




1
2
3
4
5
6
7
8





1
2

2. SOL ELİNİZDEKİ KALP ÇİZGİSİ (ÜST ÇİZGİ),
GÖRÜNTÜDEKİ ŞEKİLLERDEN HANGİSİNE
BENZİYOR?

3
4
5
6
7
8



3. SOL ELİNİZDEKİ HAYAT ÇİZGİSİ (ALT ÇİZGİ),
GÖRÜNTÜDEKİ ŞEKİLLERDEN HANGİSİNE BENZİYOR
?



4. YAŞ

“Serbest
format
girilecektir”

**5. GÜNDE KAÇ SAAT TEKNOLOJİK ALET
KULLANIRSINIZ?**

“Serbest
format
girilecektir”

6. NE SIKLIKLA KİTAP OKURSUNUZ?

HİÇ

AZ

ÇOK

7. GÜNDE NE KADAR KAHVE İÇERSİNİZ?

HİÇ

BİR

BARDAK

BİR

BARDAKTA

N FAZLA

8. SEVDİĞİNİZ İNSANI KISITLAR MISINIZ?

EVET

HAYIR

**9. SEVGİLİNİZİN YA DA EŞİNİZİN ÇOK YAKIN OLDUĞU
KARŞI CİNS ARKADAŞI VARSA OLUMLU KARŞILAR
MISINIZ?**

EVET

HAYIR

**10. HER KONUYU KAFANIZA TAKAR MISINIZ? ÇOK
FAZLA DÜŞÜNÜR MÜSÜNÜZ?**

HİÇ

DÜŞÜNME
M

AZ

DÜŞÜNÜRÜ
M

	ÇOK DÜŞÜNÜRÜ M
11. BİR KONU HAKKINDA ÖNERİLERİNİZİ SIK SIK PAYLAŞIR MISINIZ?	EVET HAYIR
12. ORTAMA GİRDİĞİNİZDE GENELLİKLE SİZ Mİ ÖNCELİKLİSİNİZ, YOKSA ARKADAŞINIZ MI?	BEN ARKADAŞI M
13. HEP BEĞENİLMEK İSTER MİSİNİZ?	EVET HAYIR
14. GEZMEYİ SEVER MİSİNİZ?	EVET HAYIR
15. ALIŞVERİŞİ SEVER MİSİNİZ?	EVET HAYIR
16. HAFTA SONLARINI GENELLİKLE NASIL GEÇİRİRSİNİZ?	AKTİF BİR ŞEKİLDE DIŞARIDA EVDE DİNLENERE K
17. GÜNLÜK HAYATTA, BAZEN GERÇEĞİ ESNETMEK ZORUNDA KALDIĞIMIZ DURUMLAR OLUYOR. SİZCE BU TÜR DURUMLARDA NE KADAR ESNEK OLMALIYIZ?	HİÇ AZ ÇOK EVET

**18. ZOR ANLARDA, GERÇEĞİ SÖYLEMEK YERİNE HAYIR
BAZEN BEYAZ YALANLARLA DURUMU HAFİFLETMEK
DOĞRU OLABİLİR Mİ ?**

**19.YAŞAMINIZDA BAZEN ZOR DURUMLARLA EVET
KARŞILAŞTIĞINIZDA, HERHANGİ BİR SEBEPTEN
DOLAYI GERÇEĞİ ESNETMEK VEYA SAKLAMAK HAYIR
ZORUNDA KALDINIZ MI ?**



EK B. Etik Kurulu İzin Belgesi



T.C.
SAKARYA ÜNİVERSİTESİ REKTÖRLÜĞÜ
Etik Kurulu



Sayı : E-61923333-050.99-355991

26.04.2024

Konu : 46/01 Hüsneİrem KAYA

İlgi : 19.04.2024 tarihli ve E--050.99-0 sayılı yazınız.

Üniversitemiz Fen ve Mühendislik Bilimleri Etik Kurulunun 25.04.2024 tarihli ve 46 sayılı toplantısında alınan "01"nolu karar ile Hüsneİrem KAYA'nın başvurusu **uygun** görülmüş ve karar örneği ekte sunulmuştur.

Bilgilerinizi rica ederim.

Prof. Dr. Şenol YILMAZ

Fen ve Mühendislik Bilimleri Etik Kurul Başkanı

1. Hüsneİrem KAYA'nın “ Kişilik Analizi Formu ” başlıklı çalışması görüşmeye açıldı. Yapılan görüşmeler sonunda Hüsneİrem KAYA'nın “ Kişilik Analizi Formu” başlıklı çalışmasının Etik açıdan uygun olduğuna oy birliği ile karar verildi.

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Doğrulama Kodu :BSDL3H9VNE Pin Kodu :06182 Belge Takip Adresi :
<https://turkiye.gov.tr/ebd?eK=5783&eD=BSDL3H9VNE&eS=318688> Adres:Esentepe Kampüsü 54187 Serdivan SAKARYA /
KEP Adresi: Bilgi için: Hanife Babacan sakaryauniversitesi@hs01.kep.tr Unvanı: Birim Evrak Sorumlusu



Telefon No:0264 295 50 00 Faks No:0264 295 50 31

e-Posta:ozelkalem@sakarya.edu.tr Elektronik Ağ:www.sakarya.edu.tr

ÖZGEÇMİŞ

Ad-Soyad : Hüsneİrem KAYA

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Sakarya Üniversitesi, Bilgisayar ve Bilişim Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü
- **Yüksek lisans** : Devam ediyor, Sakarya Üniversitesi, Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı

MESLEKİ DENEYİM:

- 2022 yılında özel bir bankada yazılım geliştirme mühendisi olarak çalışmaya başladı.