



## Müşterini Tanı (Know Your Customer)

Yapay Zeka Arf Ödülleri



KOBİL Teknoloji A.Ş.

# İçindekiler



- Müşterini Tanı
- İş Planı
- Model Blok Diyagramları
- Akış Tasarımı
- Gerçekleştirilen Başarı Ölçütleri
- Belgelendirme



# Müşterini Tanı

Müşterini Tanı (KYC - Know Your Customer) sistemleri, bir bireyin kimliğini güvenilir ve doğrulanabilir şekilde tespit etmeyi amaçlayan süreçlerdir. Bu sistemler, kullanıcıların kimlik bilgilerini doğrulamak ve sahtecilik girişimlerini önlemek için çeşitli teknolojik modüllerden oluşur. KYC süreçlerinde sıklıkla kullanılan modüller şunlardır:

## 1. MRZ ve OCR Tabanlı Kimlik Bilgisi Çıkarımı

Kimlik belgelerinin (pasaport, kimlik kartı vb.) makine tarafından okunabilir bölgelerinden (MRZ - Machine Readable Zone) alanından optik karakter tanıma (OCR) teknolojisiyle bilgilerin alınması.

## 2. NFC ile Elektronik Kimlik Doğrulama

Elektronik kimliklerin (eID) NFC (Yakın Alan İletişimi) teknolojisi kullanılarak doğrulanması ve belgelerdeki güvenlik sertifikalarının kontrol edilmesi ve bilgilerin elde edilmesi.

## 3. Yüz Doğrulama (Face Recognition)

Kullanıcının yüz verilerinin doğrulanarak kimlik belgesindeki fotoğrafla eşleştirilmesi.

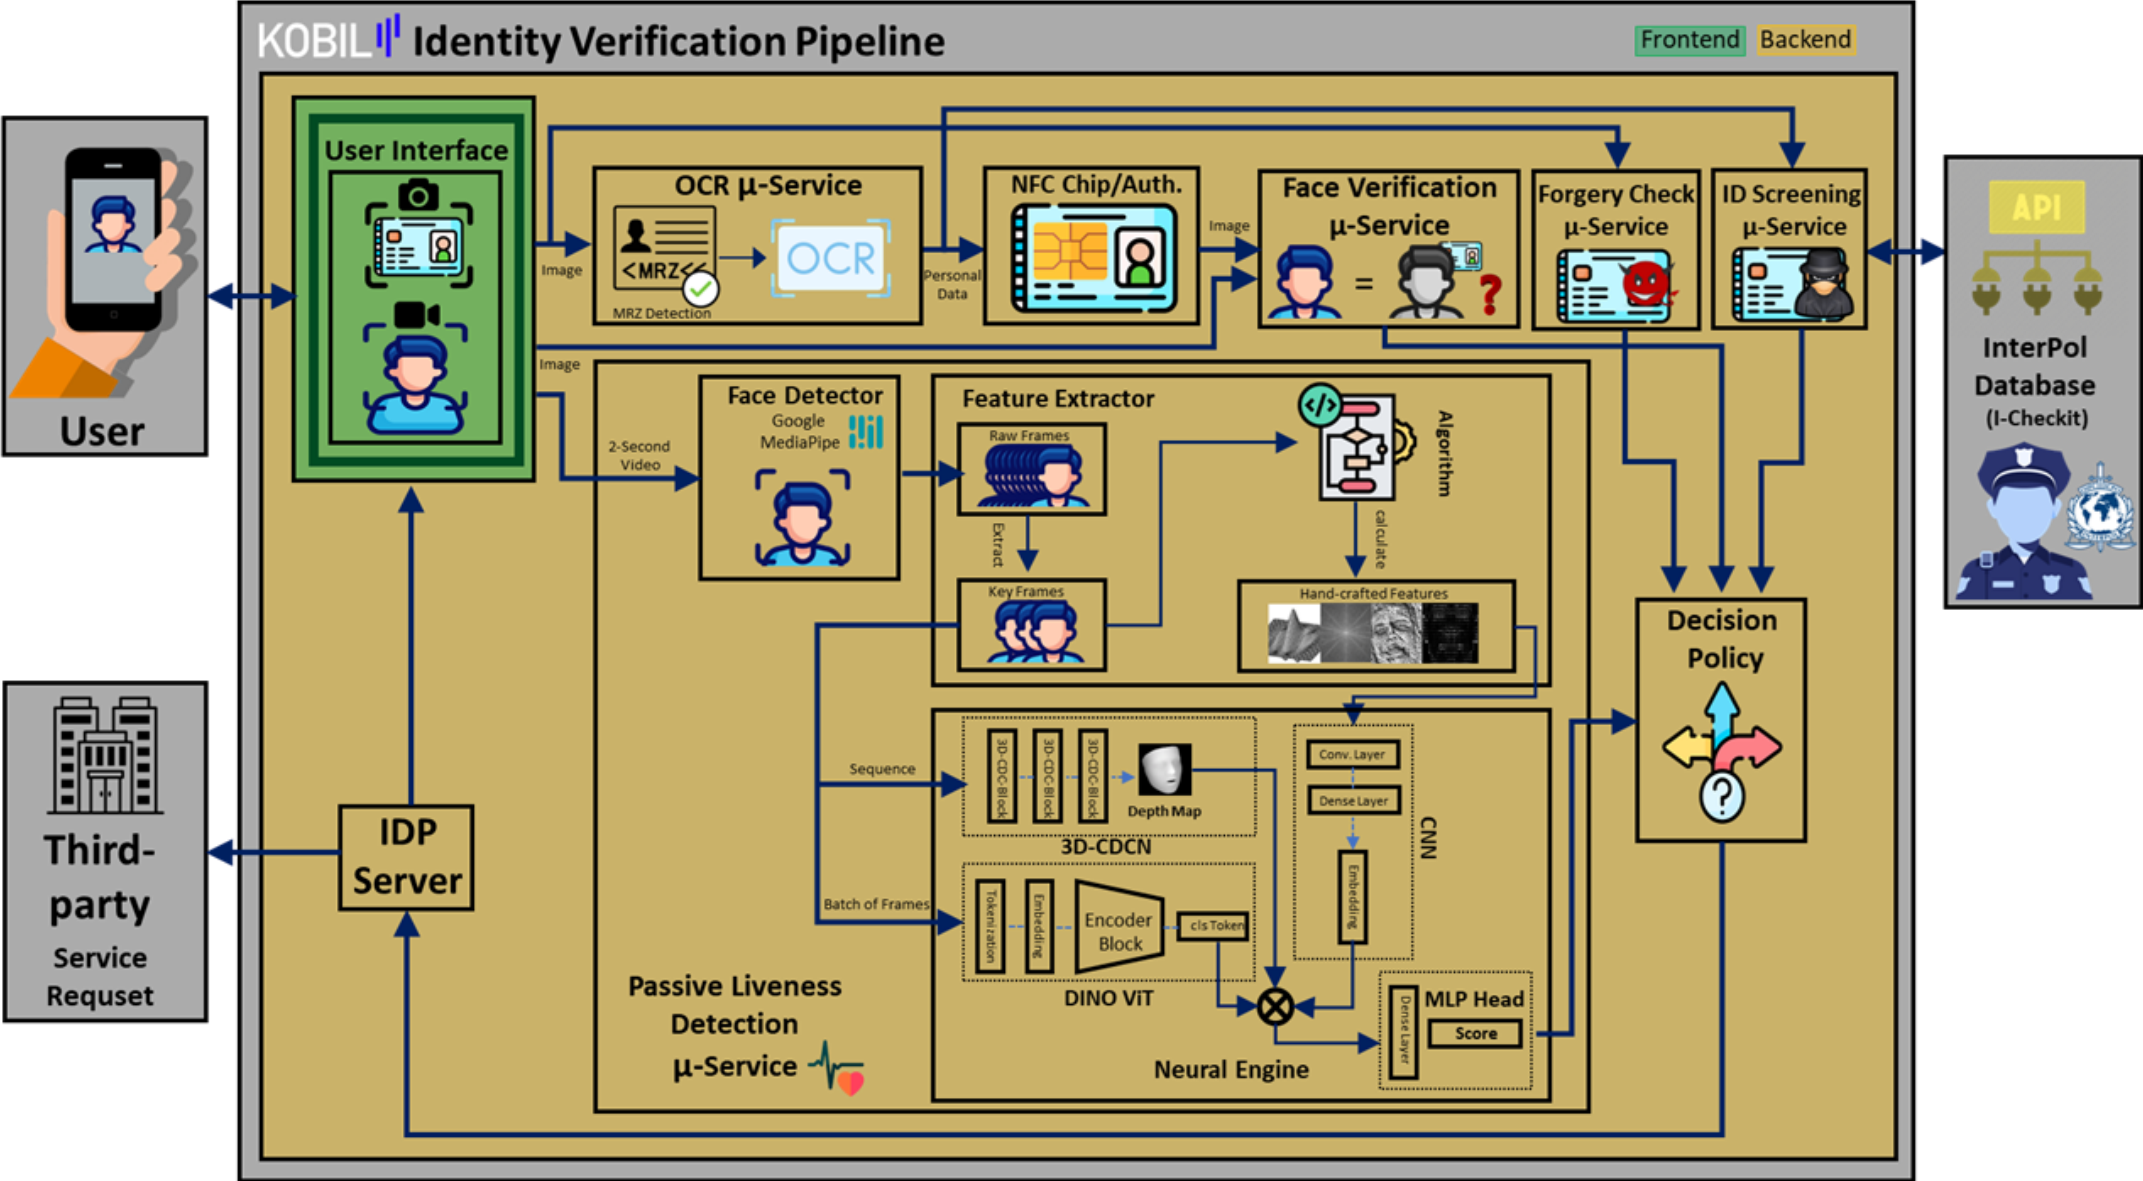
## 4. Canlılık Denetimi (Liveness Detection)

Kullanıcının gerçek bir kişi olduğunu ve statik bir görüntü ya da video kullanılmadığını doğrulamak için aktif ve pasif canlılık kontrol yöntemlerinin uygulanması.





# Model Blok Diyagramları



# KOBIL Deepfake Detection

Frontend Backend



User

**User Interface**

**OCR μ-Service**

Image → MRZ Detection → OCR

**NFC Chip/Auth.**

**Face Verification μ-Service**

**Forgery Check μ-Service**

**ID Screening μ-Service**

**API**

**InterPol Database (I-Checkit)**

**Face Detector**  
Google MediaPipe

**Frame Extractor**

Raw Frames → Extract → Key Frames

**Deepfake Detection μ-Service**

Neural Engine

**CLIP ViT w/ Spatiotemporal Adapter**

Attention → Attention → Downsample → Spatiotemporal Adapter → Upsample → Dense Layer → MLP Head → Score

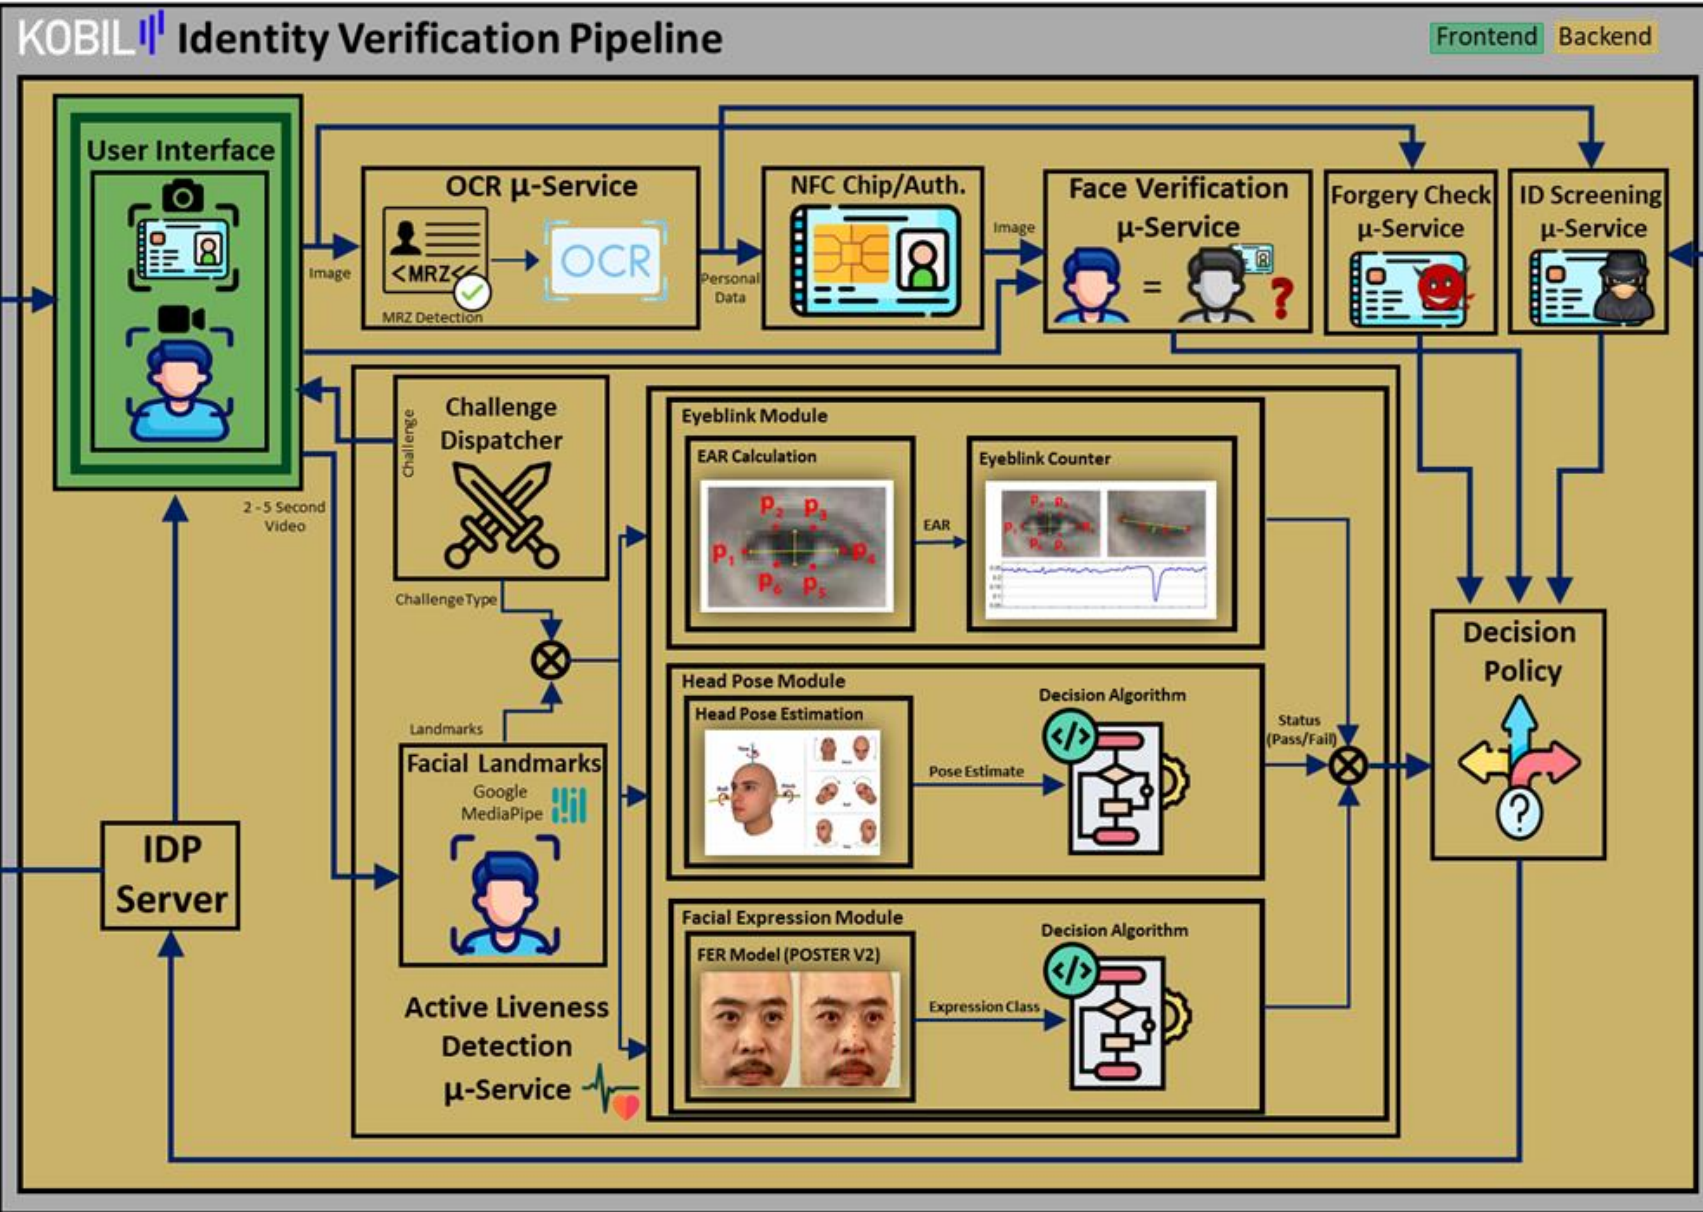
The Spatiotemporal Adapter consists of 3D Conv (spatial) and 3D Conv (temporal) layers.

**Decision Policy**

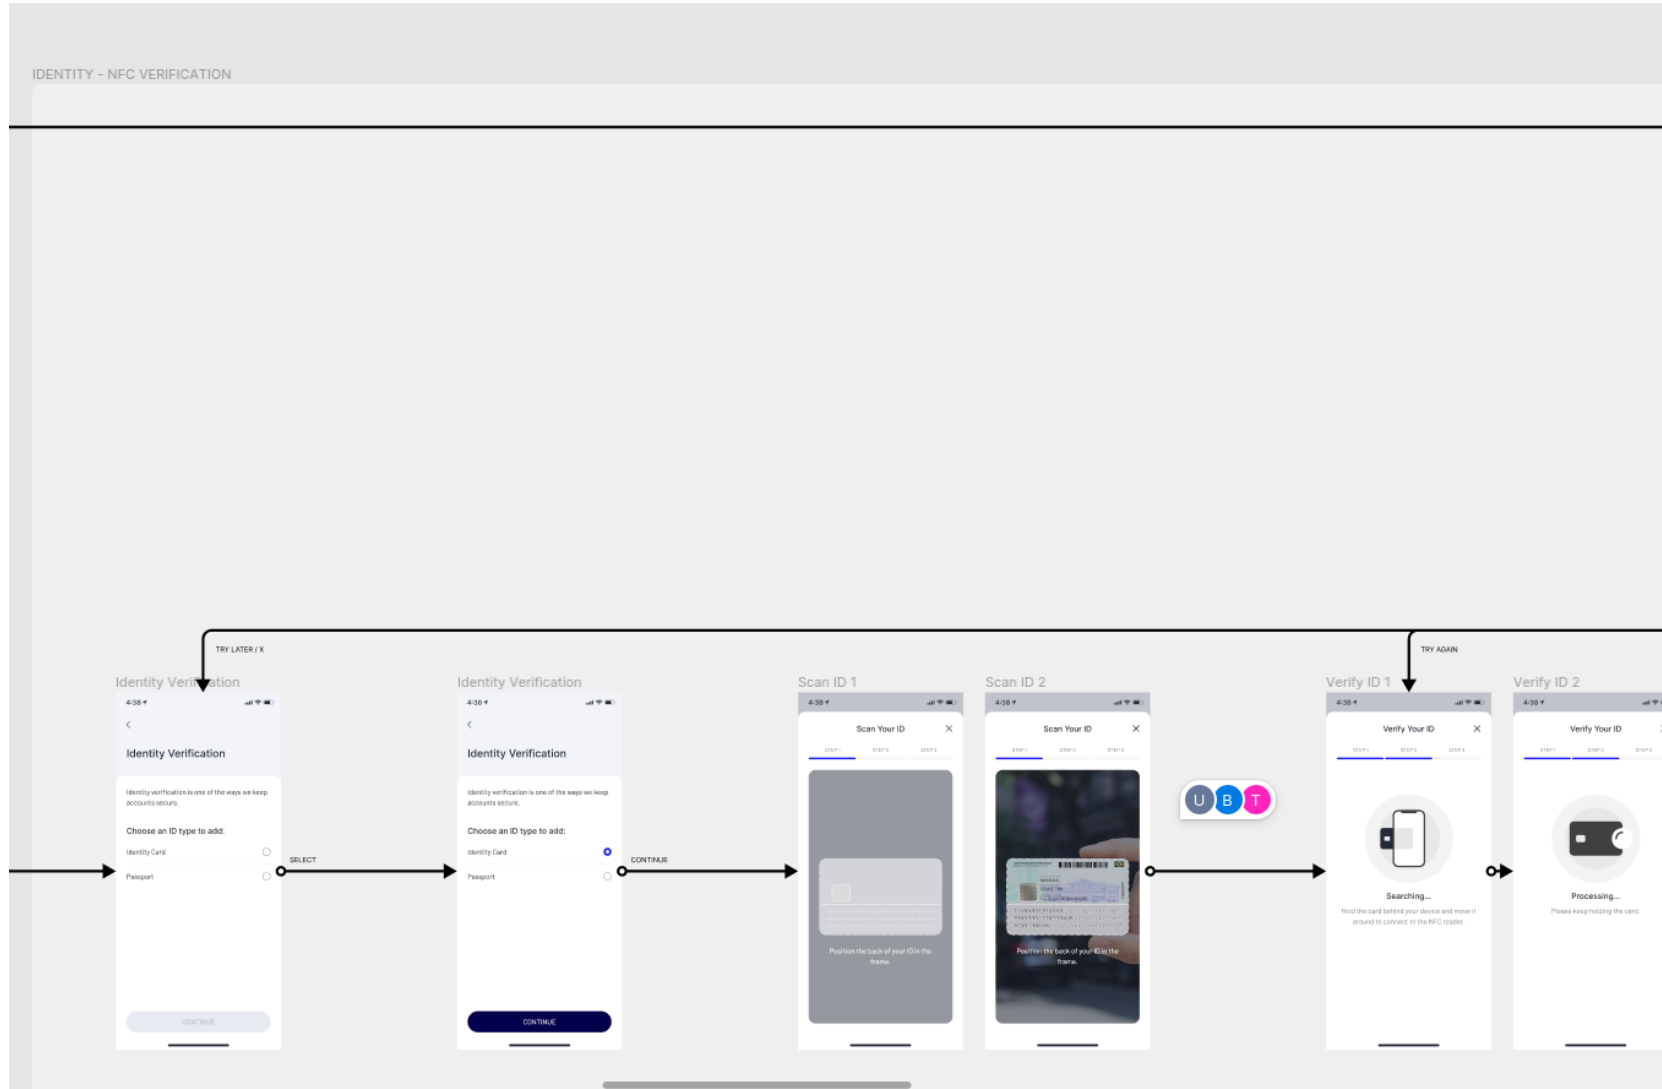
**IDP Server**

**Third-party Service Request**

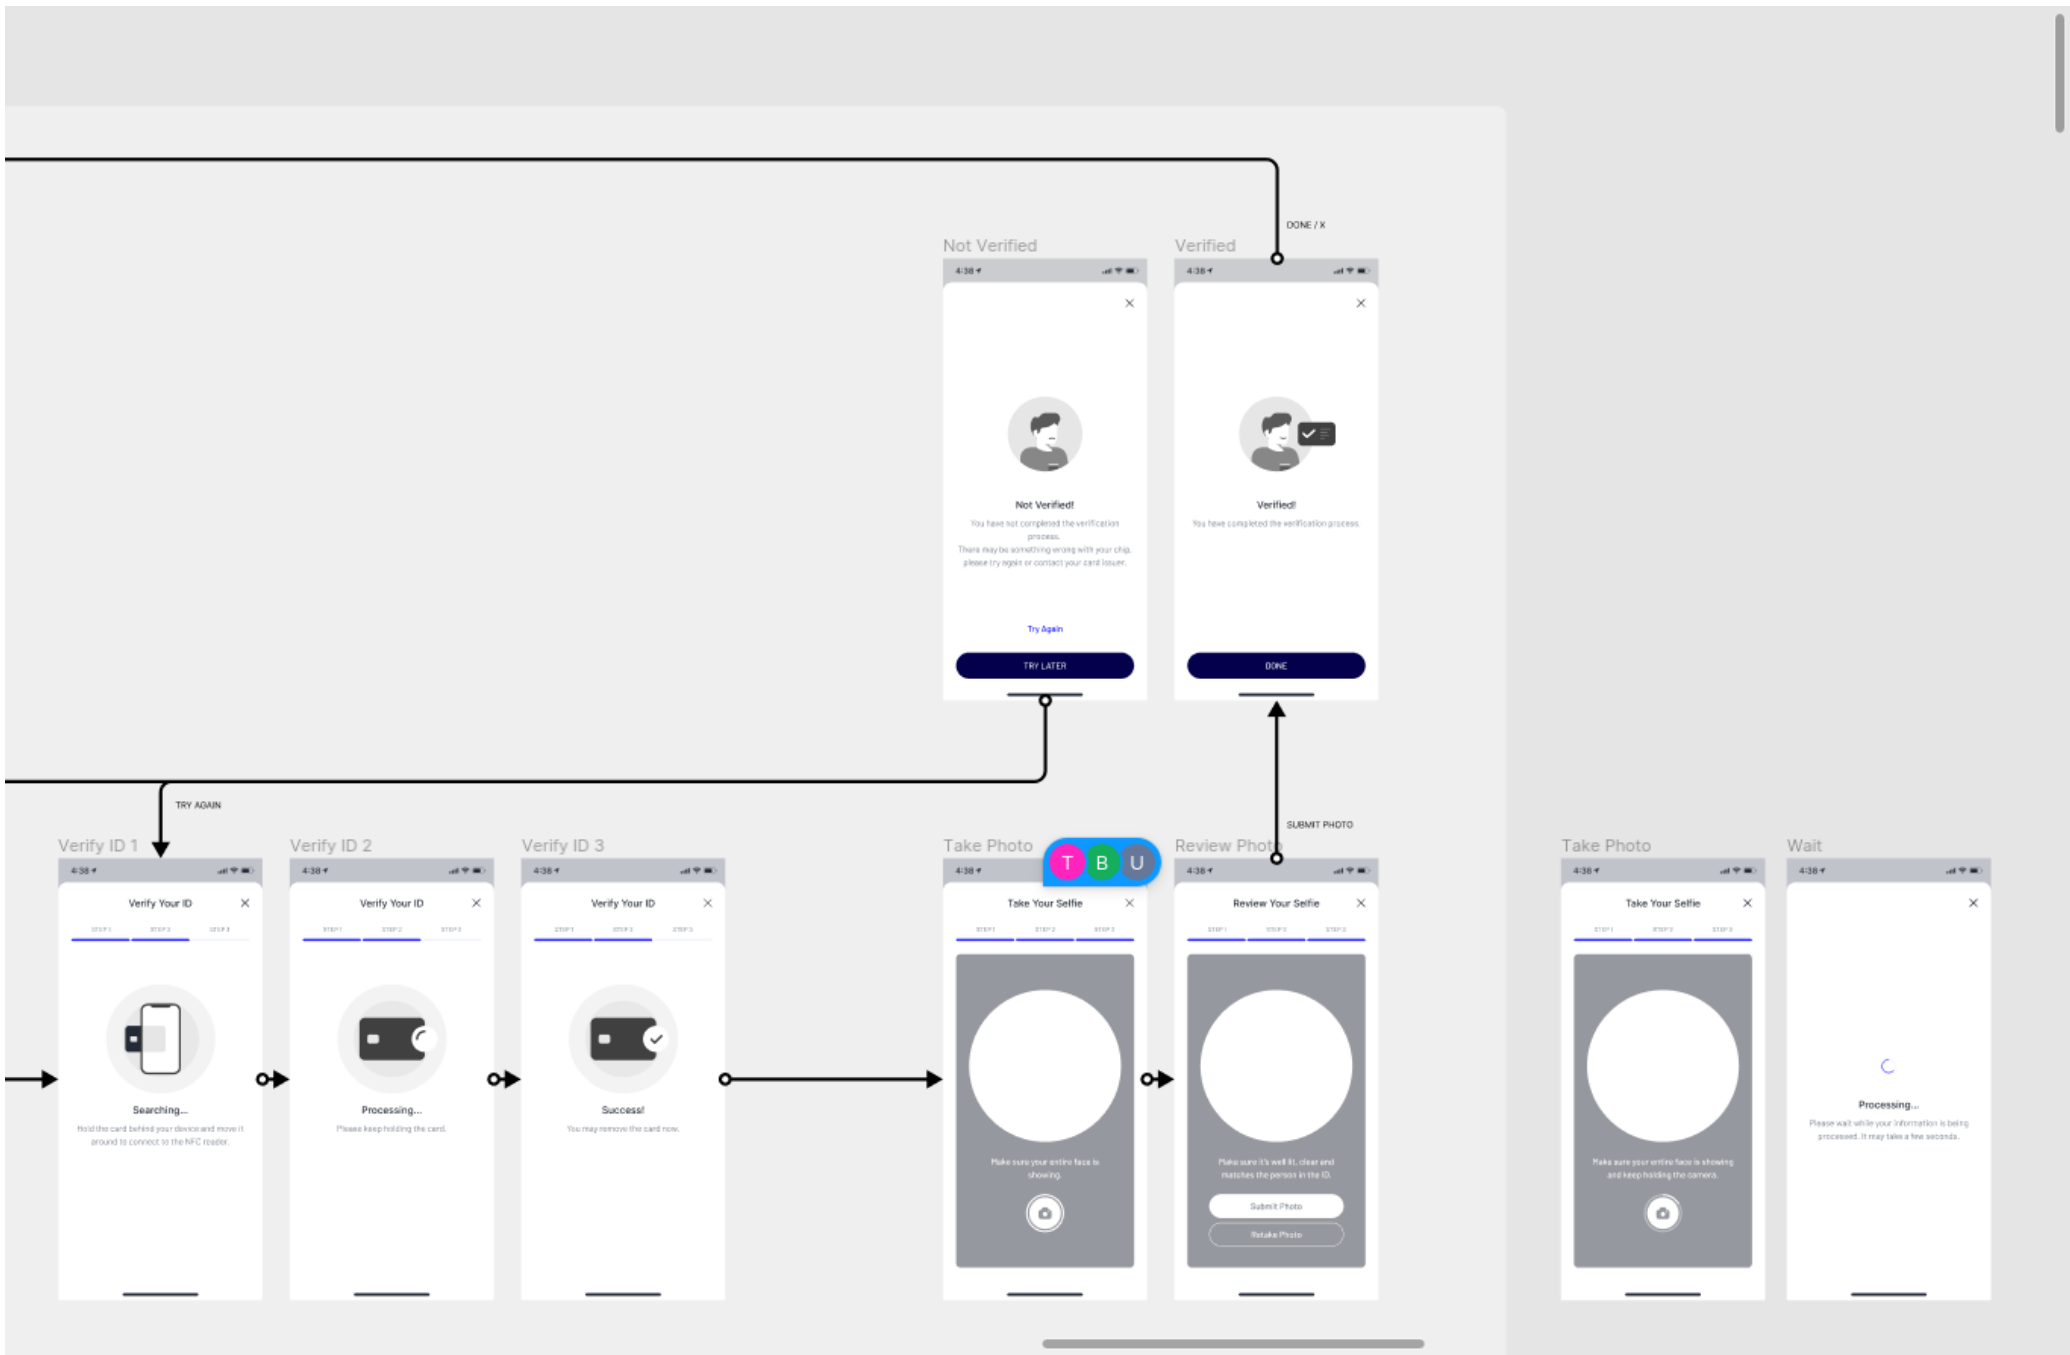


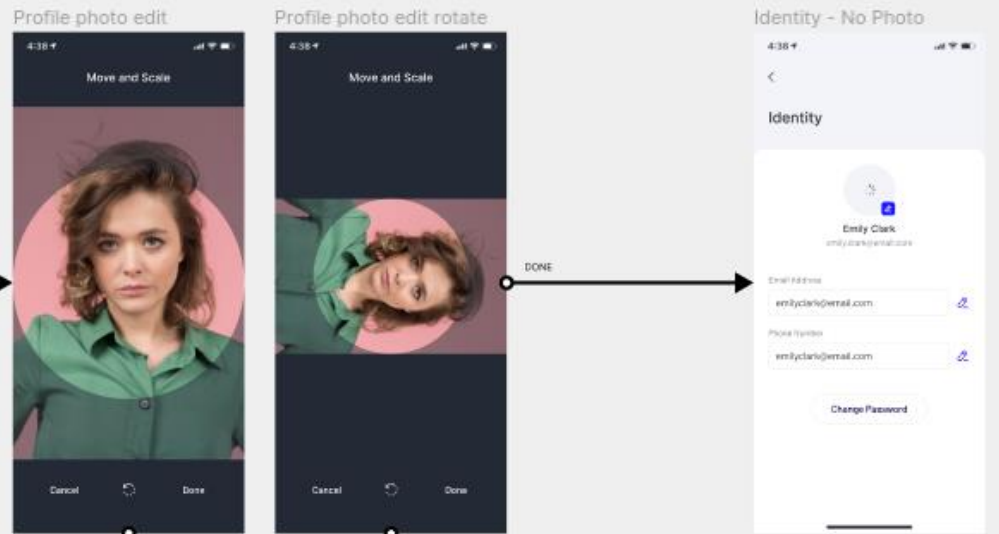
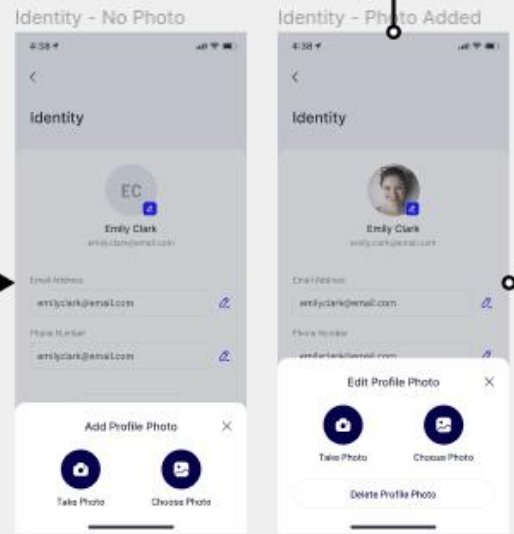
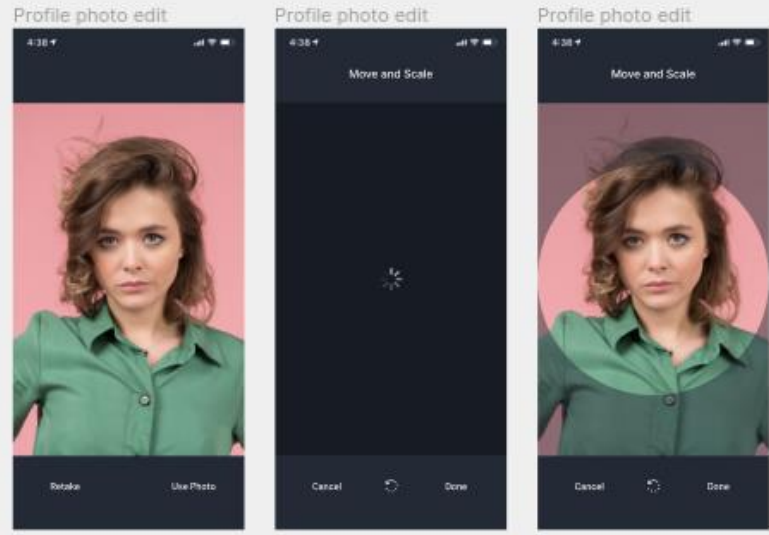
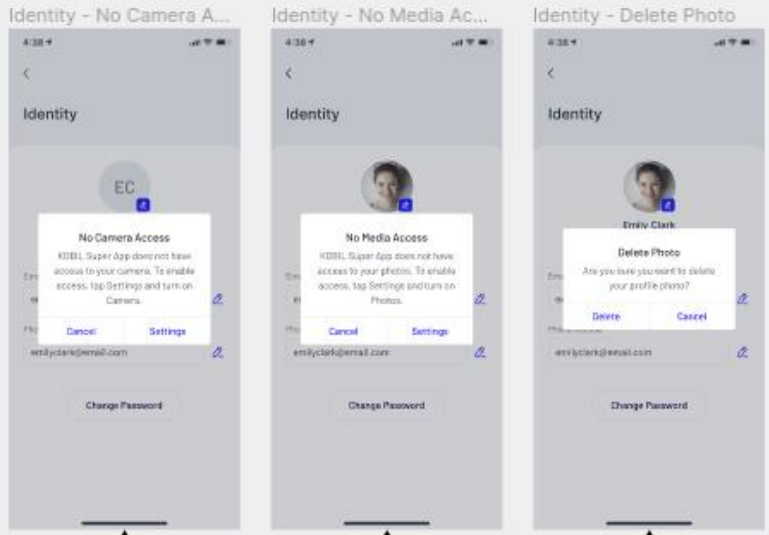
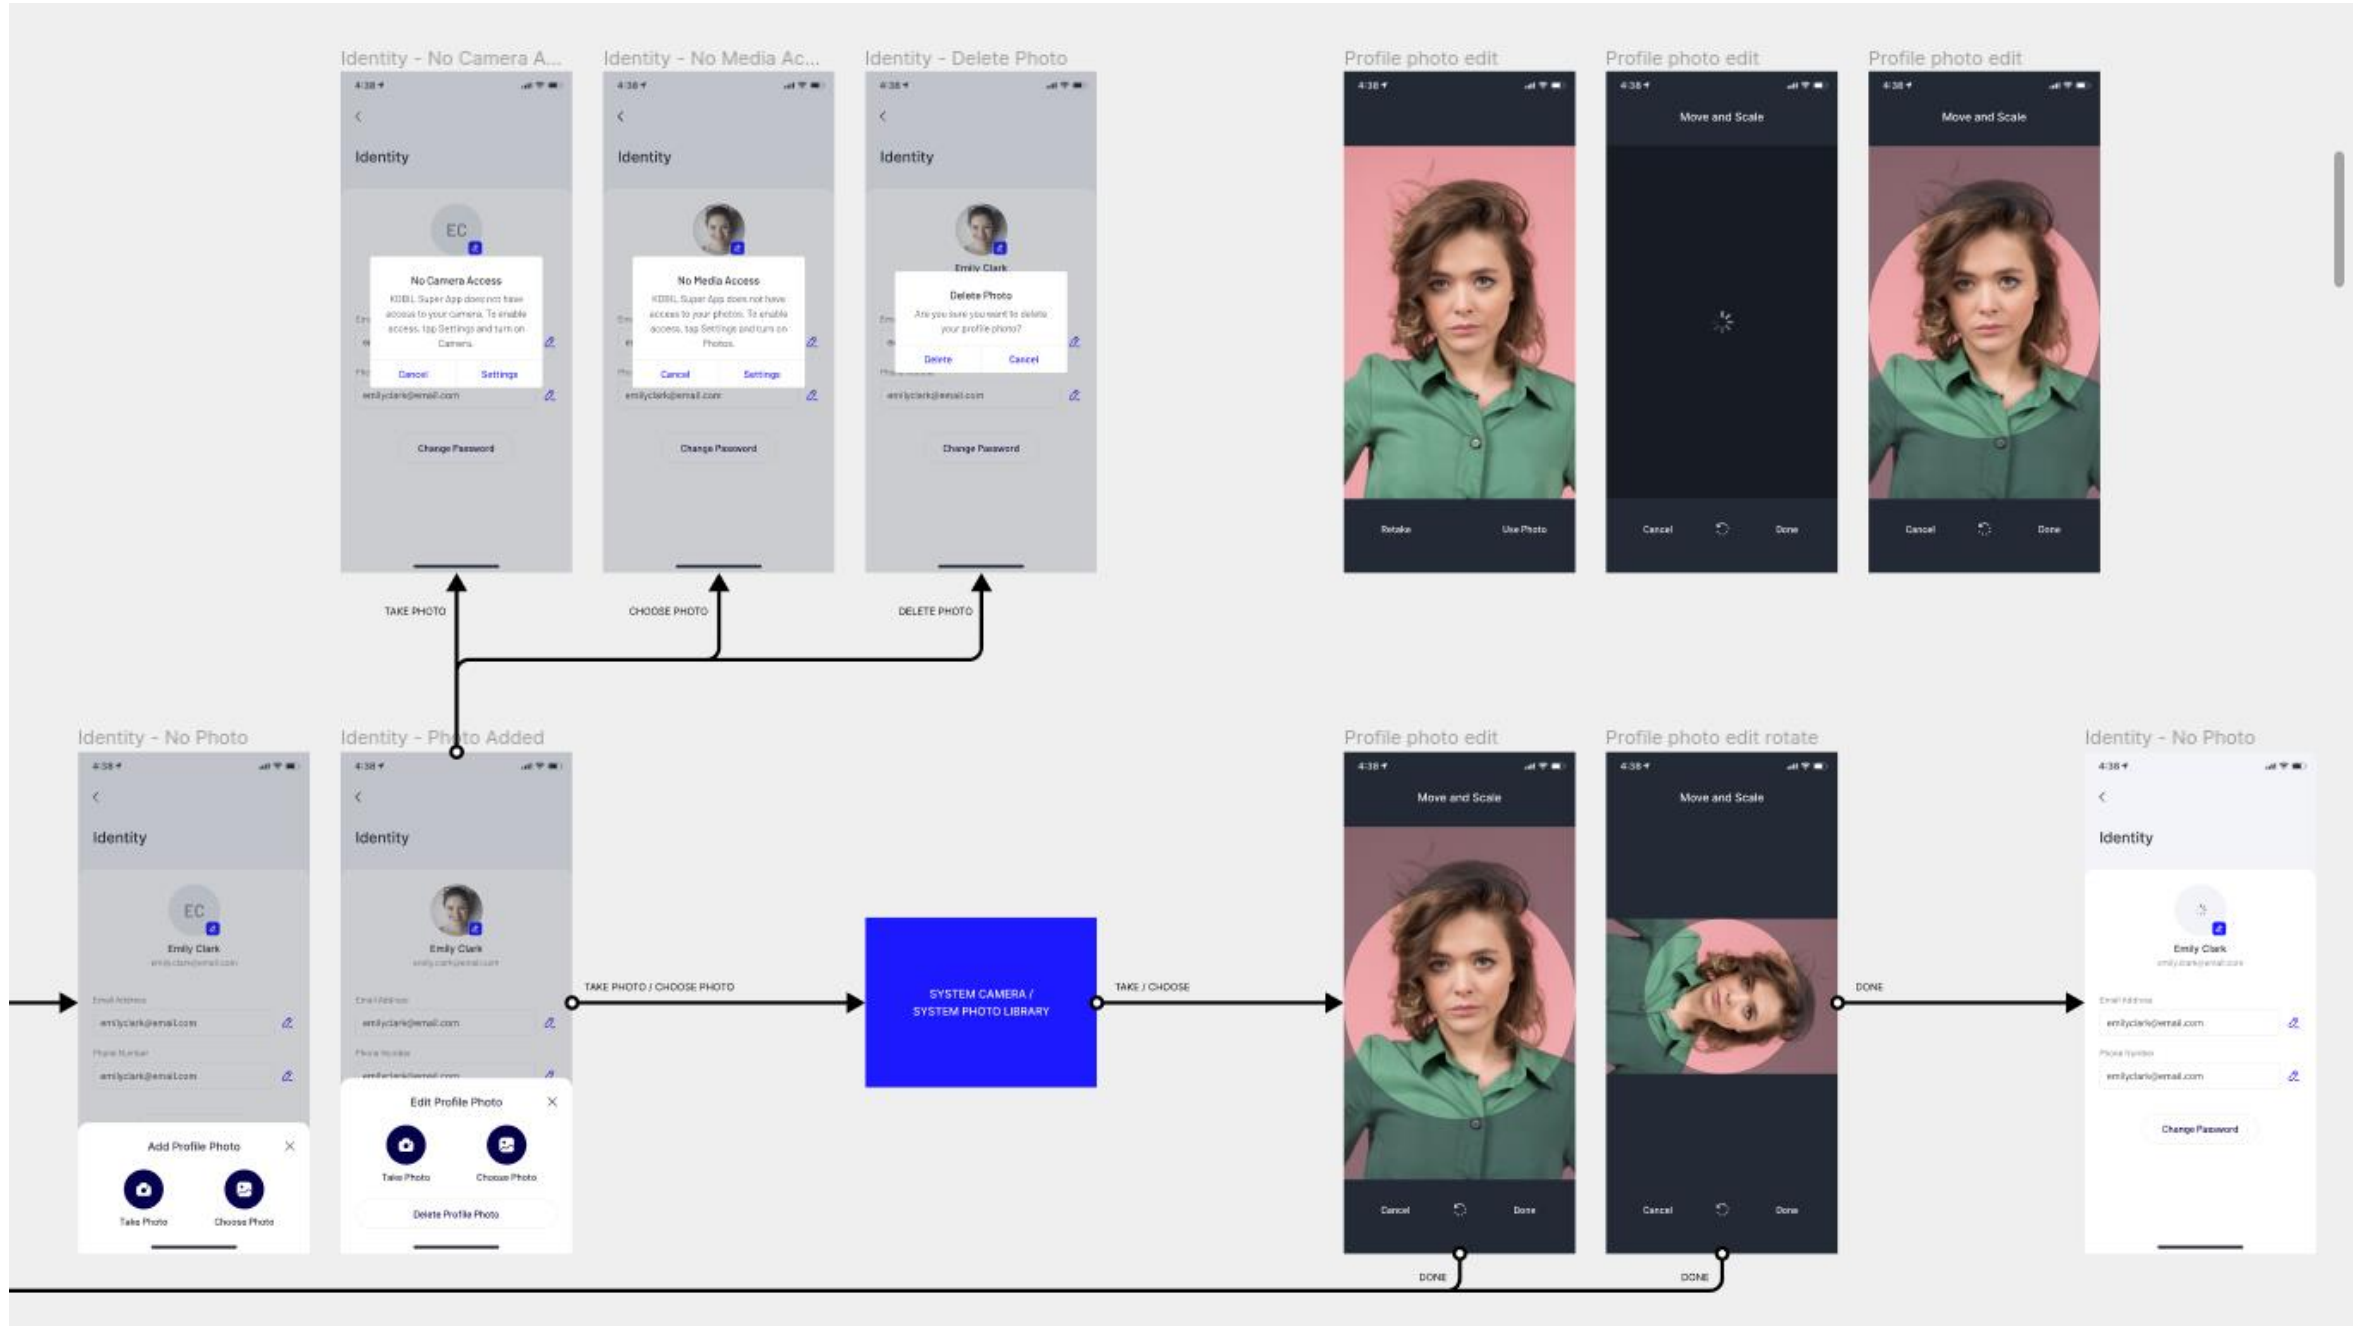


# Akış Tasarımı









SYSTEM CAMERA /  
SYSTEM PHOTO LIBRARY

TAKE PHOTO  
CHOOSE PHOTO  
DELETE PHOTO

TAKE PHOTO / CHOOSE PHOTO  
TAKE / CHOOSE

DONE

DONE  
DONE



# Gerçekleştirilen Başarı Ölçütleri

- Proje kapsamında hedeflenen başarı ölçütleri ve gerçekleşenler Tablo'da sunulmuştur. Her bir başarı ölçütü gelecek bölümlerde ayrıntılı olarak açıklanmıştır.

Başarı Ölçütü	Hedeflenen(%)	Gerçeklenen(%)
Yüz tanıma-sınıflama başarı metriği olarak Accuracy	$\geq 0.95$	<b>0.97</b>
Yüz tanıma-sınıflama başarı metriği olarak AUC*	$\geq 0.90$	<b>0.99</b>
Yüz tanıma canlılık testi - sınıflama metriği olarak Accuracy	$\geq 0.90$	<b>0.91</b>
Yüz tanıma canlılık testi - sınıflama metriği olarak AUC	$\geq 0.86$	<b>0.90</b>
Kullanıcı için özgünlük denetimi için maksimum süre	$\leq 45$ saniye	<b><math>\leq 20</math> saniye</b>

- Her bir modül için çalışma süresi ve boyutları.

Modül	MRZ	OCR	NFC	Yüz Tanıma	Yüz doğrulama	Canlılık testi
Süre	40 ms	250 ms	7-8 sn	40 ms	200 ms	500 ms
Boyut	700 KB	1.7 MB	1 MB	300 KB	3.7 MB	5 MB



# Belgelendirme

## ➤ Yazılım Tescilimiz:

Doğrulama Kodu : a37ab084-b283-4822-9c5b-2c1f8ea60202

**T.C.**  
**KÜLTÜR VE TURİZM BAKANLIĞI**  
TELİF HAKLARI GENEL MÜDÜRLÜĞÜ  
BİLGİSAYAR PROGRAMLARINA İLİŞKİN KAYIT-TESCİL BELGESİ

Kayıt-Tescil No: 2023/8070 Kayıt-Tescil Tarihi: 3.02.2023

**ESER BİLGİLERİ**  
Adı : Süper Uygulamalar İçin Konfigüre Edilebilir Çok Adımlı Doğrulama  
Türü : Bilgisayar Programı, Veritabanı  
Kullanıldığı Alanlar : Süper Uygulamalar, Mobil Uygulamalar  
Desteklenen İşletim Sistemleri : Android, IOS  
Dil Seçenekleri : Türkçe, İngilizce  
Üretim Tarihi : 1.08.2022  
İlk Aleniyet Tarihi : 1.11.2022

ESER SAHİPLERİ			
Sıra No	İsim / Unvan	T.C. Kimlik / Vergi No	Eser / Hak Sahipliği Türü
1	KOBİL TEKNOLOJİ LIMITED ŞİRKETİ	5640057447	Asıl Eser Sahibi

Bu belge başvuru sahibinin beyanı esas alınarak düzenlenmiştir.  
Hak kurucu niteliğe hâzır değildir, sadece eser sahibinin belirlenmesinde ispat kolaylığı sağlar.

Serhat DALGIÇ  
Bakan a.  
Daire Başkanı





## ➤ İSO Belgelerimiz:



## A Novel BlazeFace Based Pre-processing for MobileFaceNet in Face Verification

Necmettin Bayar\*, Kübra Güzel\*, and Deniz Kumlu\*  
 \*Artificial Intelligence Department, KOBIL Systems, Istanbul, Turkey  
 necmettin.bayar@kobil.com

**Abstract**—Face verification is an important security step on mobile devices and many other systems, thus it has to work with high accuracy. Besides the importance of the accuracy in the face verification model, its weight and computational complexity play crucial roles especially in mobile devices. In this study, we aimed to provide novel contribution as pre-processing step for MobileFaceNet without affecting its accuracy. With this contribution, overall pipeline has smaller weight and faster inference time by comparison to the available pre-processing models for MobileFaceNet such as multi task cascaded convolutional neural network (MTCNN) and RetinaFace. The face verification test results show the superiority of our proposed model compared to the state-of-the-art models in terms of weight and speed.

**Keywords**—BlazeFace; face verification; face alignment; facial landmarks; MobileFaceNet

### I. INTRODUCTION

Face verification (one-to-one process) and face recognition (one-to-many process) are popular in computer vision and image processing community. They are generally utilized for security purposes to identify or verify on-boarding (registration or login) people to certain application or system. In the last decade, there are huge increases in the number of mobile device users. Thus, many applications are developed which require face verification or recognition models for various purposes such as locking device screen, login to the secure application, mobile payment, banking application and many others can be given as examples of cases where face verification is required [1, 2].

Generally, face verification is mostly used by mobile devices, however it is also largely employed in embedded devices which are mostly used for security reasons in industrial application. Formerly, face verification was done by heavy deep convolutional neural networks (CNN) [3]. These networks have many parameters, which imply a huge number of model weights and higher computational times [1]. Since the mobile and embedded devices have limited storage capacity, and low computing power, these heavy CNN based approaches are not suitable for the mobile and embedded devices. On the other hand, using these heavy models in the mobile applications showed that the user experience reduces considerably.

To alleviate the size and computational time of the heavy models, lightweight and fast models are proposed. These models have fewer layers compared to older ones and using depth-wise separable convolution to achieve fast implementation on mobile devices [4]. MobileFaceNet is one of the common and frequently used face verification models on

mobile devices. By comparing the many other light weight models, MobileFaceNet achieves higher accuracy and its size is only around 4 MB. Besides, it has 99.5% accuracy on well known labeled faces in the wild (LFW) dataset [4].

Face verification process begins with face detection stage. In the conventional MobileFaceNet, Multi Task Cascaded Convolutional Neural Network (MTCNN) is used for detection purposes and MTCNN also provides 5 facial points on the detected human face [5]. These facial points are used to align face image with respect to reference facial points. MobileFaceNet has different model types which contain different input sizes and the best result are obtained by 112x112 input size. In the input of MobileFaceNet, it requires faces that are aligned and resized to 112x112. Then, MobileFaceNet extracts embedding vectors from pre-processed input images [4].

In the final step, similarity of 2 embedding vectors are checked by cosine similarity metric. If the similarity is over the predefined threshold value, face verification process is completed successfully, otherwise verification process has failed. In order to detect facial landmarks MobileFaceNet uses MTCNN as mentioned before. MTCNN has 3 different sub-models, each of them having different roles for detection. However, using three different networks increases the computational complexity of the model. Some of the MobileFaceNet implementation uses RetinaFace instead of MTCNN. In their work, it is shown that RetinaFace outperforms MTCNN on the LFW and other datasets. Retinaface is single stage face detection model which does not contain two different mechanisms such as proposal and refinement. Thus, it is faster and lighter compared to MTCNN [6].

Recently proposed BlazeFace model is specifically tailored for face detection with landmarks in mobile graphical processing unit (GPU) implementation [7]. In this paper, authors aim to replace pre-processing part of the MobileFaceNet by using BlazeFace instead of MTCNN model. BlazeFace can detect faces in less than milliseconds and inference time does not change by size of the input image. Thus, by using BlazeFace instead of MTCNN can achieve lightweight and faster verification by removing the dependency to input image size [7].

The paper is organized as follows; in section I, related works for face detection and alignment are presented. Section II is dedicated to pre-processing step with MTCNN and RetinaFace models. In Section III, proposed methods are explained in detail and in Section IV experimental results are presented.

## MobileMRZNet: Efficient and Lightweight MRZ Detection for Mobile Devices

Necmettin Bayar, Kubra Guzel and Deniz Kumlu

**Abstract**—The Machine Readable Zone (MRZ) is a standardized section found on identification documents (IDs) that adhere to the International Civil Aviation Association (ICAO) Document 9303. The MRZ region contains sensitive personal information about the document holder, and a portion of this information is utilized to establish communication between the passive chip within the ID and a mobile device via Near Field Communication (NFC) protocol. This communication is crucial as the data retrieved from the ID's chip is subsequently used in authentication steps such as face or fingerprint recognition. Thus, accurate detection of the personal information within the MRZ region is vital. In this research study, we propose a fast and lightweight approach for MRZ region detection called MobileMRZNet, which is based on the BlazeFace model. The MobileMRZNet architecture is specifically designed for mobile Graphical Processing Units (GPUs) and enables rapid and precise detection of MRZ regions. To train and evaluate the model, a dataset consisting of both simulated and real data was created using Turkish national IDs. The BlazeFace model was reconfigured and trained specifically for MRZ region detection. The detector, based on BlazeFace and trained on augmented real and simulated data, demonstrates excellent generalization capabilities for deployment with real IDs. Both qualitative and quantitative results confirm the superiority of our proposed method. The mean Intersection over Union (IoU) for the first frame, without utilizing any layout alignment for IDs, achieves an accuracy of approximately 81%. For character recognition, the method achieves 100% accuracy after three consecutive frames. The model operates in less than 10 milliseconds on a mobile device, and its size is around 400 KB, making it significantly fast, lightweight, and robust compared to any existing MRZ detection methods.

**Index Terms**—Biometric identification, BlazeFace model, ID Cards, MRZ Detection, Travel Documents.

### I. INTRODUCTION

IDENTITY DOCUMENTS (IDs) play a vital role in ensuring national security and enabling citizens to engage in

Necmettin Bayar, is with Artificial Intelligence Department, Kobil Technology, Istanbul, Turkey. (e-mail: [necmettin.bayar@kobil.com](mailto:necmettin.bayar@kobil.com)).  
<https://orcid.org/0000-0003-2367-828X>

Kubra Guzel, is with Artificial Intelligence Department, Kobil Technology, Istanbul, Turkey. (e-mail: [kubra.guzel@kobil.com](mailto:kubra.guzel@kobil.com)).  
<https://orcid.org/0009-0002-8401-6983>

Deniz Kumlu, is with Artificial Intelligence Department, Kobil Technology, Istanbul, Turkey. (e-mail: [deniz.kumlu@kobil.com](mailto:deniz.kumlu@kobil.com)).  
<https://orcid.org/0000-0002-7192-7466>

Manuscript received Jan 08, 2024; accepted Apr 15, 2024.  
 DOI: [10.17894/bajece.1416404](https://doi.org/10.17894/bajece.1416404)

various activities such as voting, traveling, and accessing government and private sector benefits. The accurate verification of IDs allows governments to effectively monitor their citizens, identify illegal immigrants, prevent identity theft, track criminals, monitor terrorism activities, and identify individuals who may pose a risk to national security. Moreover, governments provide services specifically tailored to their citizens, and IDs serve as a means to streamline service delivery by ensuring that only eligible citizens receive these services, minimizing any potential errors or misuse by non-citizens.

When the brief history of IDs are checked, it is evident that they first appeared around 1876. However, they did not become widely accessible until the early 20th century [1]. The introduction of photographic IDs occurred in 1915, following the well-known Lody-Spy scandal [2]. Prior to 1985, there was no global standardization for IDs. It was in 1985 that ISO/IEC 7810 established standardized guidelines for the shape, size, and content of IDs, which were further refined in 1988 through ISO/IEC 7816. As technology advanced, radio frequency identification (RFID) chips were integrated into IDs, enabling the storage of sensitive personal information alongside biometric data like photographs and fingerprints. The most recent standards for IDs are defined by the International Civil Aviation Association (ICAO), and the majority of countries worldwide have aligned their ID systems with these standards [3].

The International Civil Aviation Organization (ICAO) document 9303 establishes the standardized guidelines for machine-readable travel documents, including national IDs, passports, and more. Presently, over 190 countries have adopted these standards and incorporate machine-readable zones (MRZs) within their respective IDs.

The MRZ is a specific section on IDs that contains sensitive personal information about the document holder. It is designed to streamline and expedite the scanning process for government-issued documents such as IDs and passports. The information within the MRZ can be read using optical character recognition (OCR) methods, such as the Tesseract OCR engine, as the characters in the MRZ region have a unique font called OCR-B. To enhance the accuracy and performance of the OCR engine, it is crucial to accurately detect the exact MRZ region on IDs beforehand [4].

The MRZ region is commonly used as part of the authentication process, with some of its information utilized to access the chip within IDs via the Near Field Communication (NFC) module of mobile phones. NFC comprises a collection of short-range wireless technologies that establish a reliable



## Davranış Analizi

Yapay Zeka Arf Ödülleri



KOBİL Teknoloji A.Ş.



# İçindekiler



- Davranış Analizi
- İş Planı
- Veri Toplama
- Model Bilgisi ve Tasarım
- Gerçekleştirilen Başarı Ölçütleri



# Davranış Analizi

Mobil cihazlardan elde edilen biyometrik davranış verilerine dayalı olarak sürekli doğrulama sistemleri geliştirilmiştir. Bu sistem, kullanıcının uygulama üzerindeki güvenliğini artırmayı hedefleyen, gerçek zamanlı analiz gerçekleştiren yapay zeka tabanlı bir çözümdür. Sürekli doğrulama mekanizması, kullanıcının kimliğini her 5 saniyede bir güncelleyerek güvenlik tehditlerini proaktif bir şekilde önler. Proje kapsamında yapılan çalışmalar, uluslararası bir konferansta yayımlanarak akademik alanda da katkı sağlamıştır.

## Kullanılan Özellikler:

### 1. Klavye Vuruş Dinamikleri (Keystroke Dynamics)

Kullanıcının klavye üzerinde yazarken sergilediği ritim, hız ve basış süresi gibi benzersiz davranışların analizi.

### 2. Ekran Etkileşimleri (Screen Interactions):

Kullanıcının dokunmatik ekran üzerindeki kaydırma, dokunma ve tıklama gibi hareketlerinin izlenmesi ve değerlendirilmesi.

### 3. Sensör Verileri (Accelerometer, Magnetometer ve Gyroscope):

Cihazın hareket, yön ve manyetik alan verilerini ölçen sensörlerden toplanan verilerle kullanıcı davranışlarının tespiti.

- Bu özellikler, kullanıcı kimliğinin doğru ve güvenilir bir şekilde doğrulanması için güçlü bir temel oluşturur.



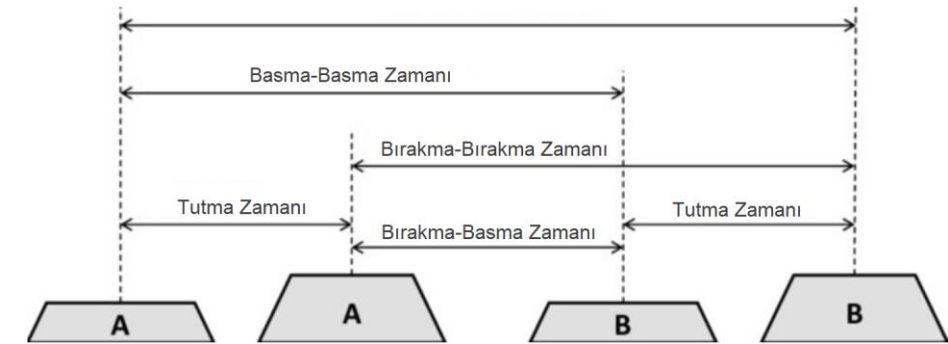
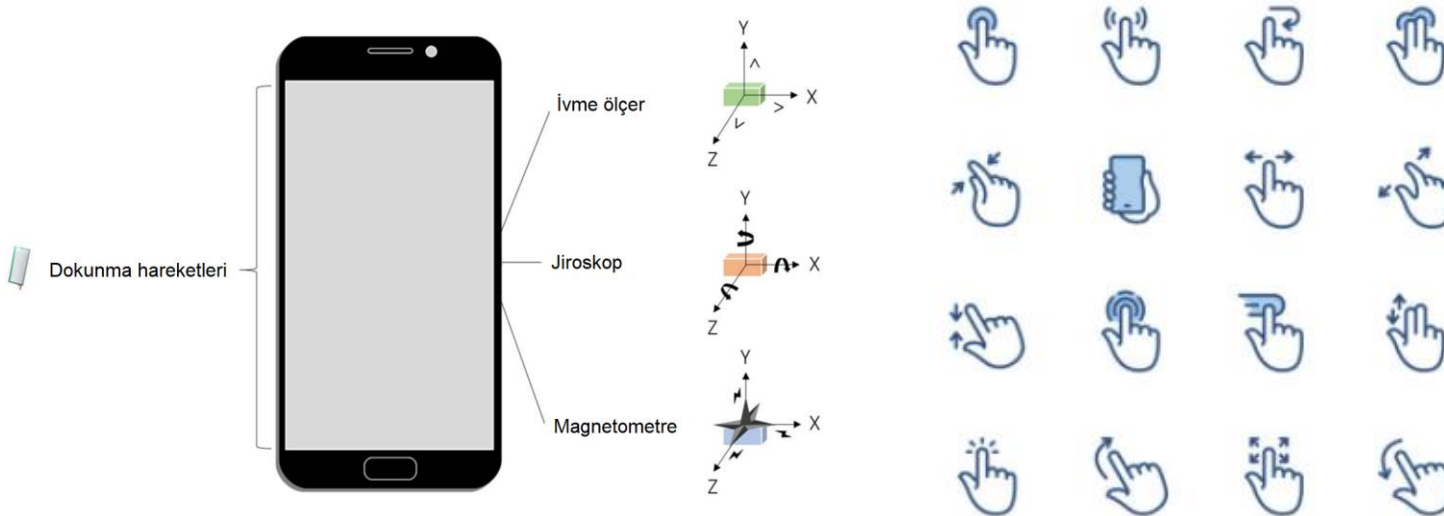


# Veri Toplama

➤ Literatür taramasında pek çok makale, kendi veri setlerini kullanmıştır.

Veri Seti	Yıl	Vuruş Dinamiği	Sensör	Parmak Hareketleri	Gönüllü Sayısı
HMOG	2016	Var	İvmeölçer, Jiroskop, Manyetometre	Var	100
BrainRun	2019	Yok	İvmeölçer, Jiroskop, Manyetometre	Var	2218
AALTO Mobile	2019	Var	Yok	Yok	37.370
DAKOTA	2021	Yok	İvmeölçer, Jiroskop, Manyetometre	Var	45
HuMldb*	2020	Var	İvmeölçer, Jiroskop, Manyetometre	Var	599

\* Bu veri seti için istekte bulunulmuş ve yakın zamanda elde edilecektir.



# ➤ Veri Toplama Uygulama



**Ensure your device is charged.**  
Keep the app active during data collection sessions.

**Device Handling:**  
Please hold your device in your hand for the duration of data collection to ensure accuracy.

**Data Types & Screens:**  
Current Activity Screen: Here, you'll be prompted to confirm your activity (e.g., walking, running) to match with sensor data.

**Keystroke Dynamics Screen:**  
Shows how we capture timing and pressure of key presses for analysis.

**Touch Activities Screen:**  
Demonstrates tracking of touch gestures (swipes, taps) on the screen.

**Sensor Data Screen:**  
Displays the collection of accelerometer, gyrometer, and magnetometer data while the device is in your hand.

**Technical Support:**  
For help or feedback, please reach out to AI Team.

Next ➤

### Activity Recognition

Which activity you're doing right now?

IN VEHICLE    ON BICYCLE

RUNNING    STILL

WALKING

Next ➤

### Zoom In and Zoom Out

Your name

Your surname

Your Age

Type this sentence in the below input field

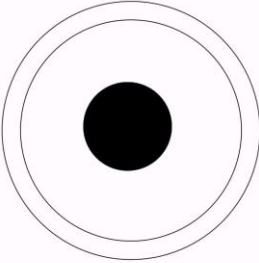
On the vibrant streets of a cultural festival, music and dance fuse, drawing together a mosaic of people, celebrating the richness of heritage and the joyous connections that transcend boundaries.

Sentence

Next ➤

### Zoom In and Zoom Out

Pick this black dot and try to zoom in and zoom out to match the outer circles.



Next ➤

### Swipe Left Gesture

0 => 1 => 2 => 3 => 4 => 5 => 6 => 7

←

Next ➤

### Swipe Right Gesture

= 6 <= 5 <= 4 <= 3 <= 2 <= 1 <= 0 <=

→

Next ➤

### Swipe Down Gesture

30  
29  
28  
27  
26  
25  
24  
23  
22  
21  
20  
19  
18  
17  
16  
15  
14  
13  
12  
11  
10  
9  
8  
7  
6  
5  
4  
3  
2  
1  
0

↓

Next ➤

### Swipe Up Gesture


1000  
999  
998  
997  
996  
995  
994  
993  
992  
991  
990  
989  
988  
987  
986  
985  
984  
983  
982  
981  
980  
979  
978  
977  
976  
975  
974  
973  
972  
971  
970  
...

↑

Next ➤

### Circle Sensor

Move you phone circular in clock and anti clock wise



Next ➤

### Cross Sensor

Move you phone like you're trying to draw a plus sign



Next ➤

### Click Gestures

Please press the button the number of times mentioned

Tap 1 time    Tap 2 times

Tap 3 times    Tap 4 times

Tap 5 times    Tap 6 times

Next ➤

### Drawing Screen

Draw the letter J

Clear ➤

Finish ➤

Hurray! 🎉🎉  
You have completed all the task

Restart ➤

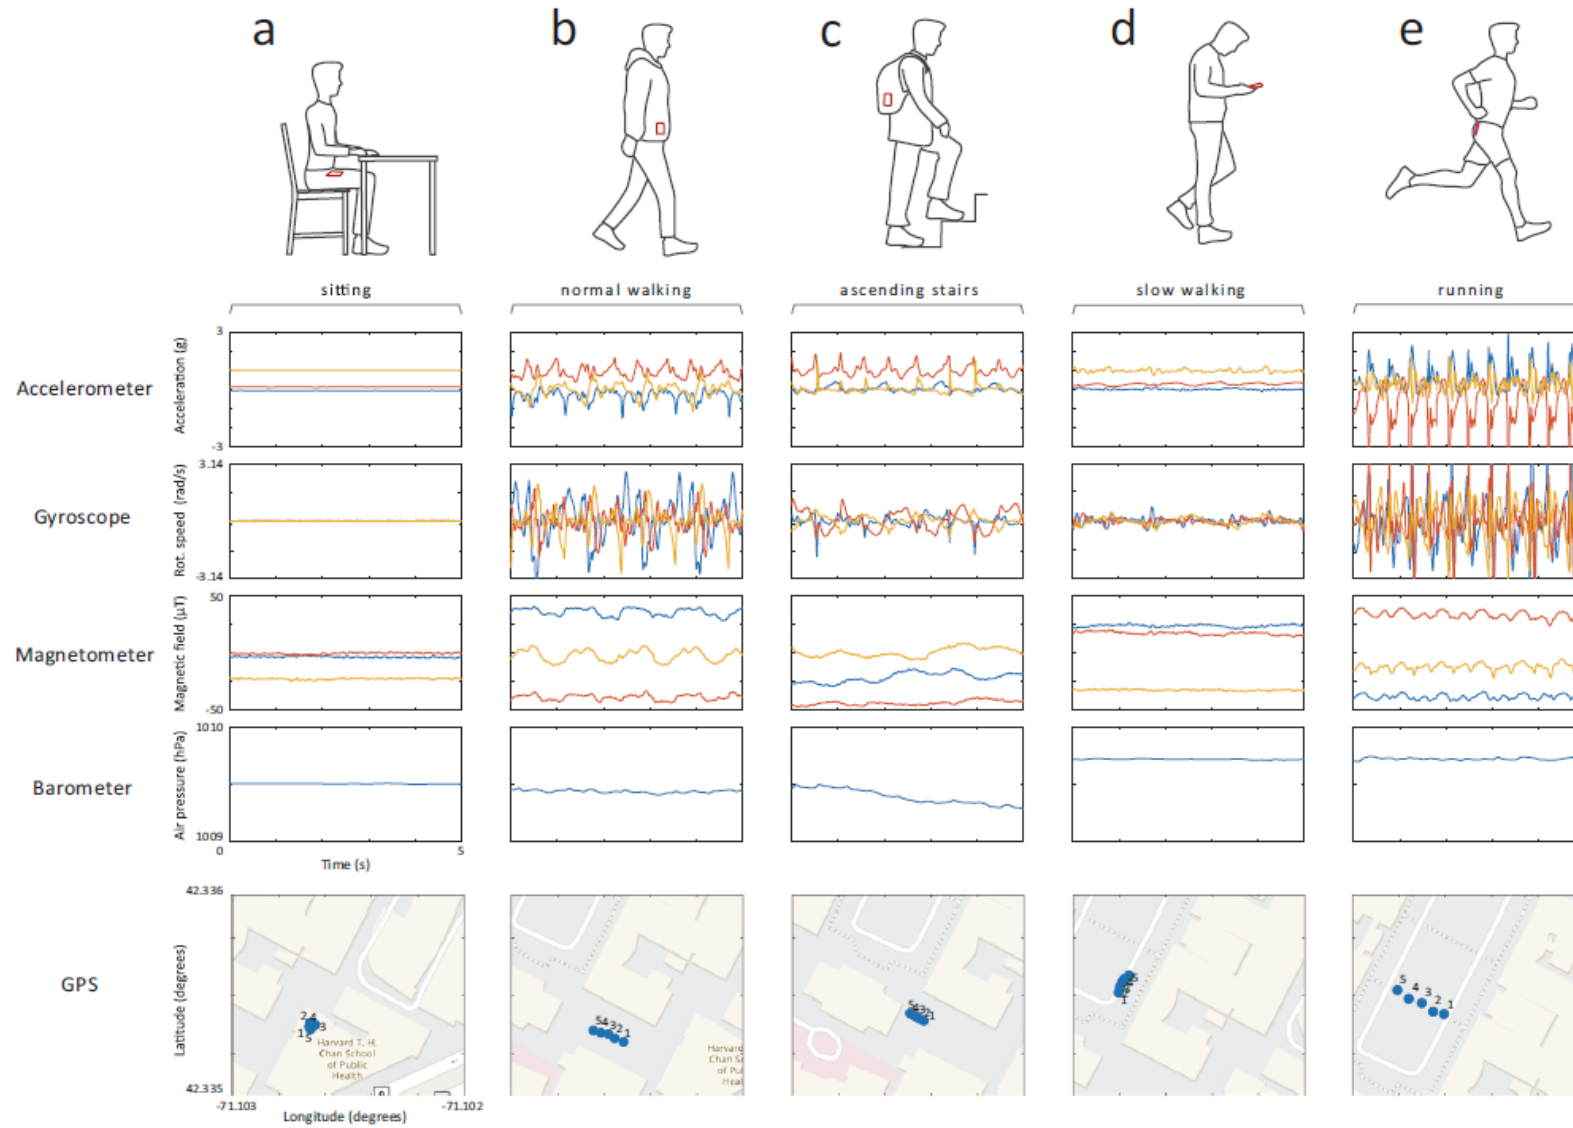
Not now ➤



# Model Bilgisi ve Tasarım

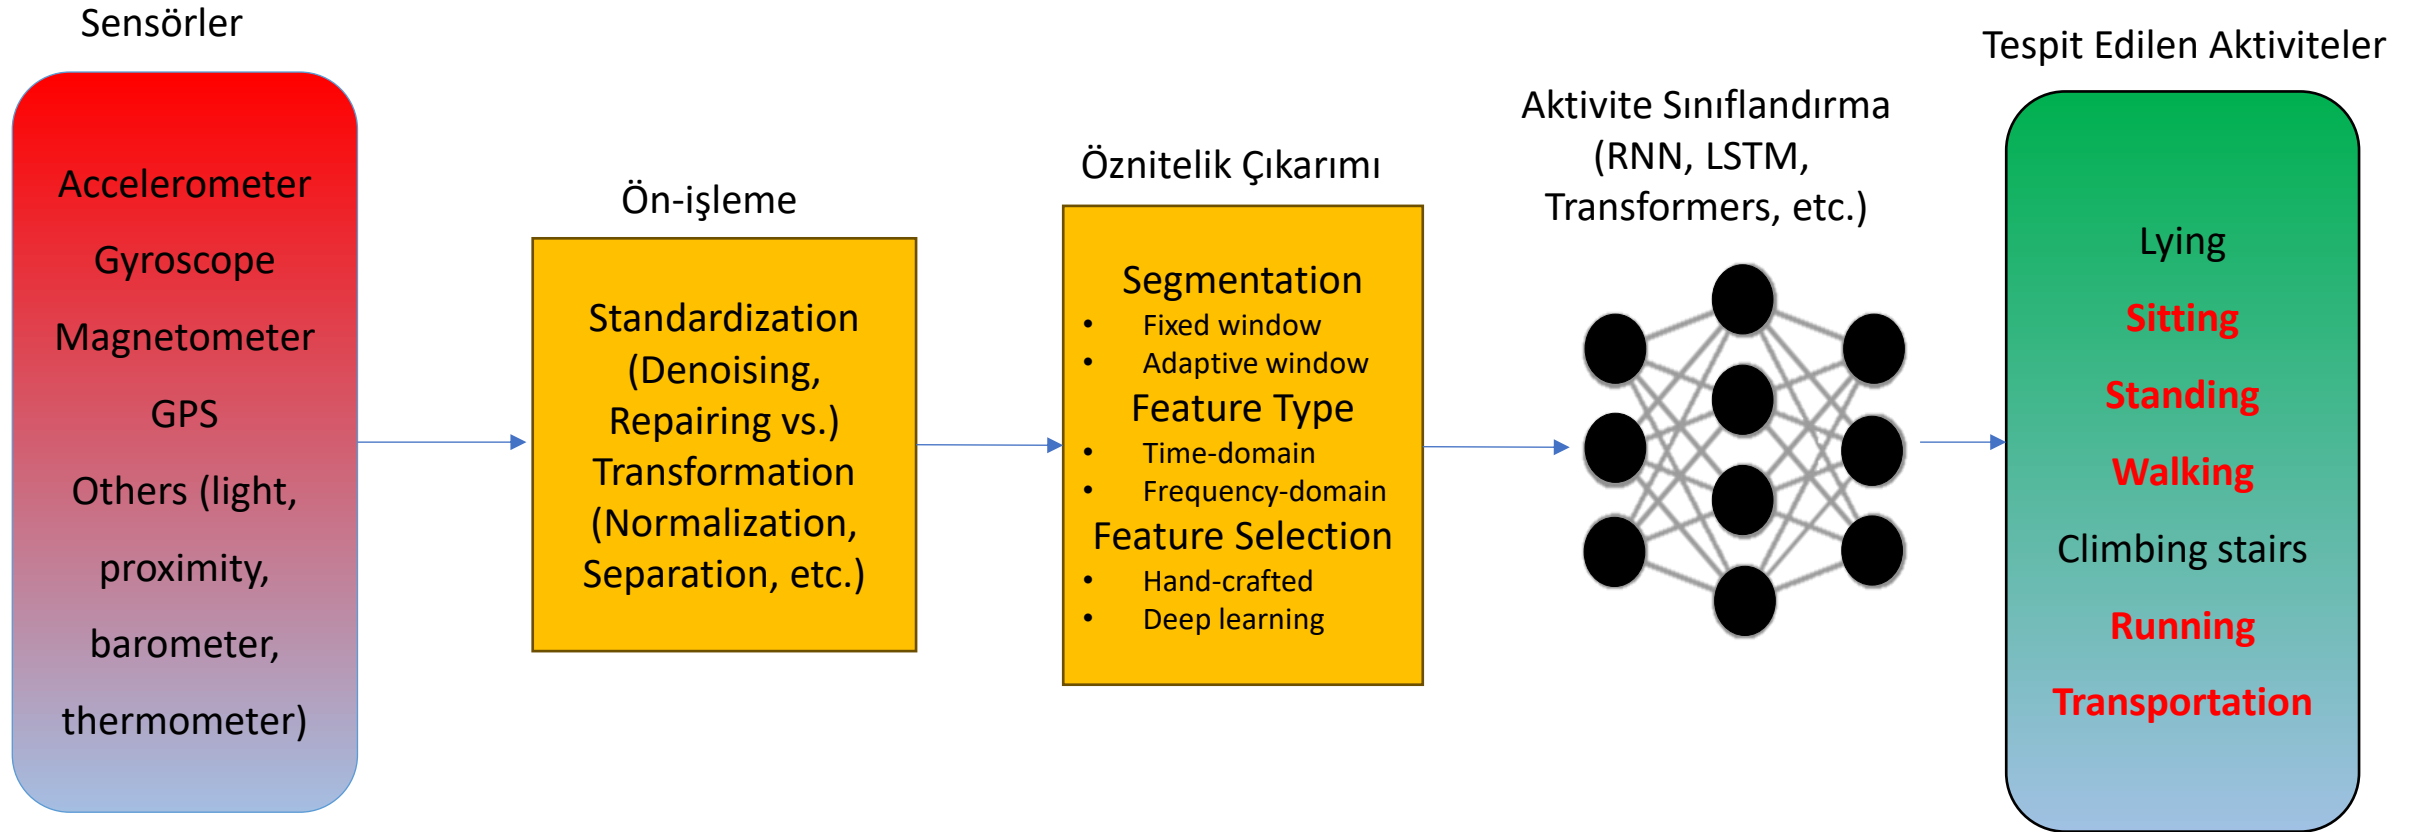
Fiziksel aktiviteler (hareket): ayakta durma, oturma, yatma, yürüme, merdiven çıkma, merdiven inme, koşma veya taşıma araçlarını kullanma (araba, otobüs, tren, gemi, bisiklet vb.).





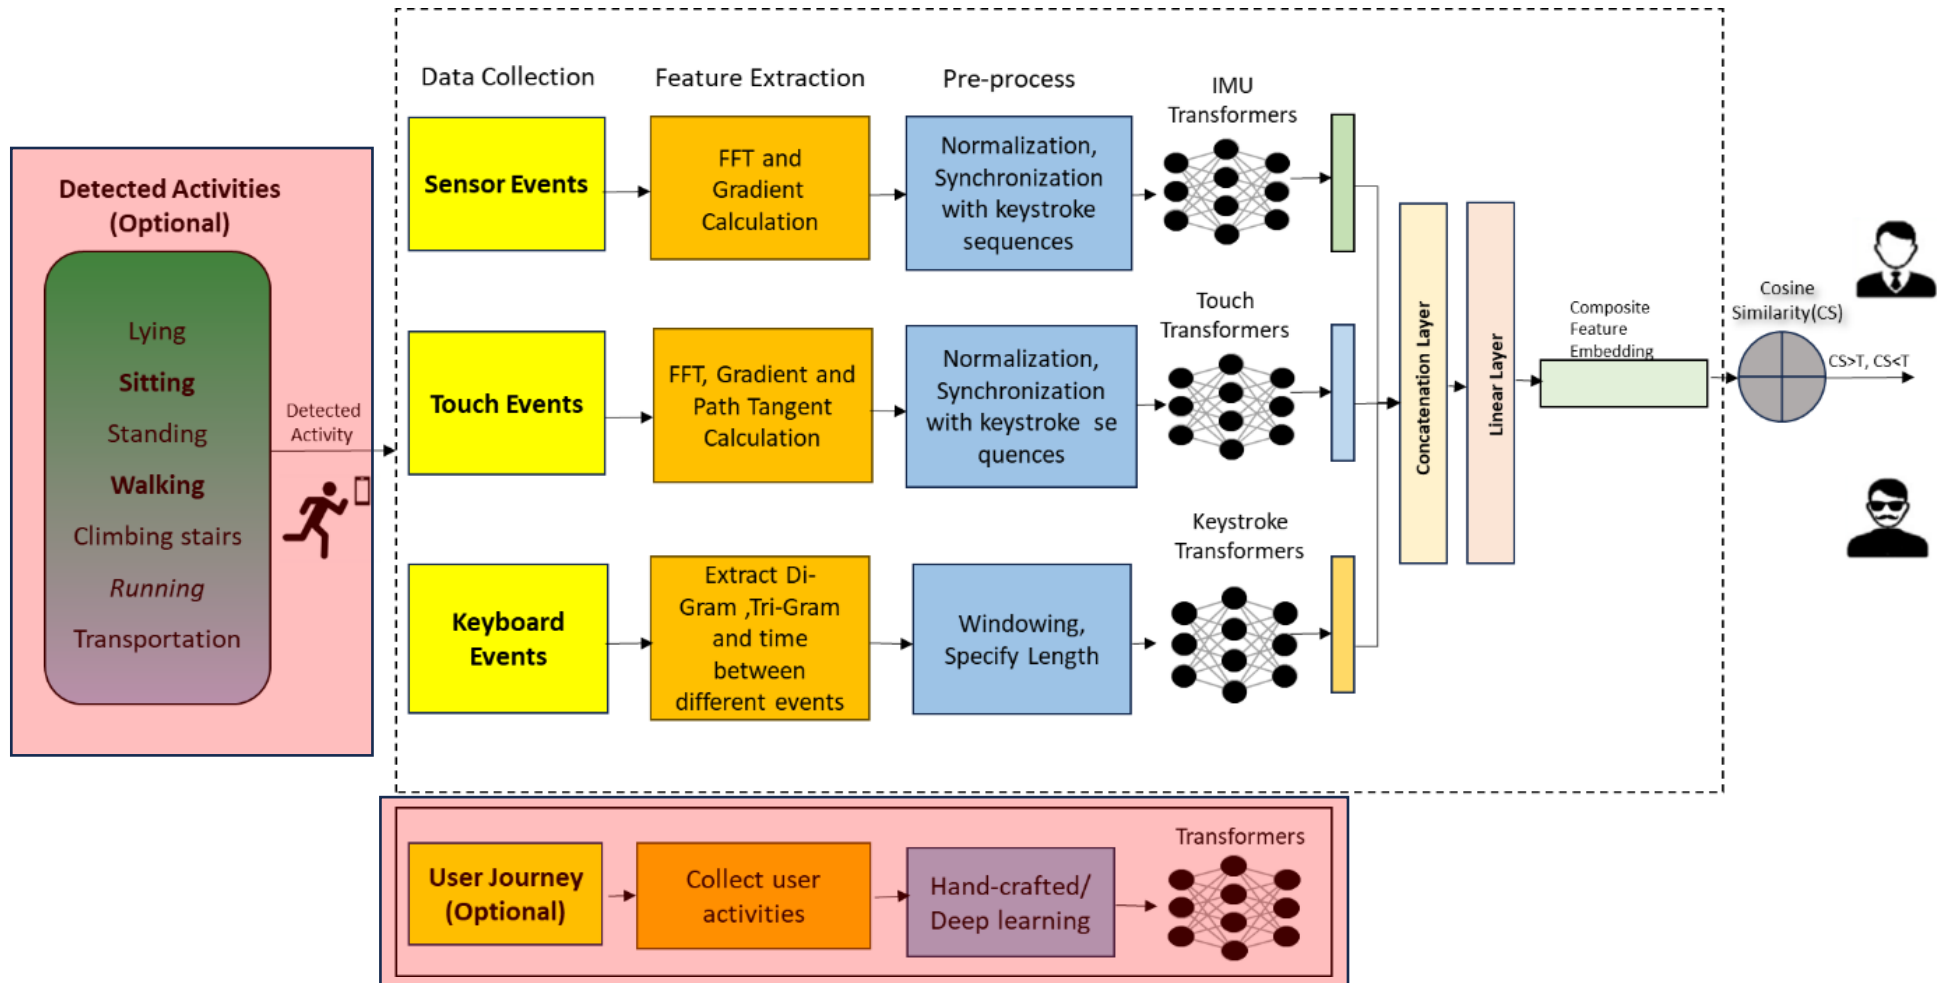
## ➤ Aktivite Tespiti

### Gerçek Zamanlı Aktivite Tespit Modeli



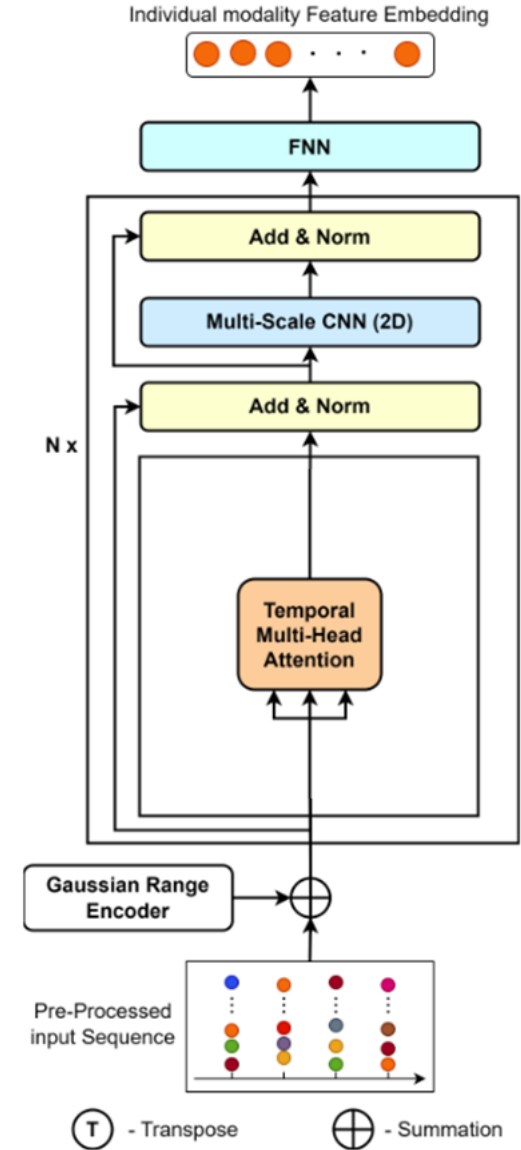


# Model Tasarım



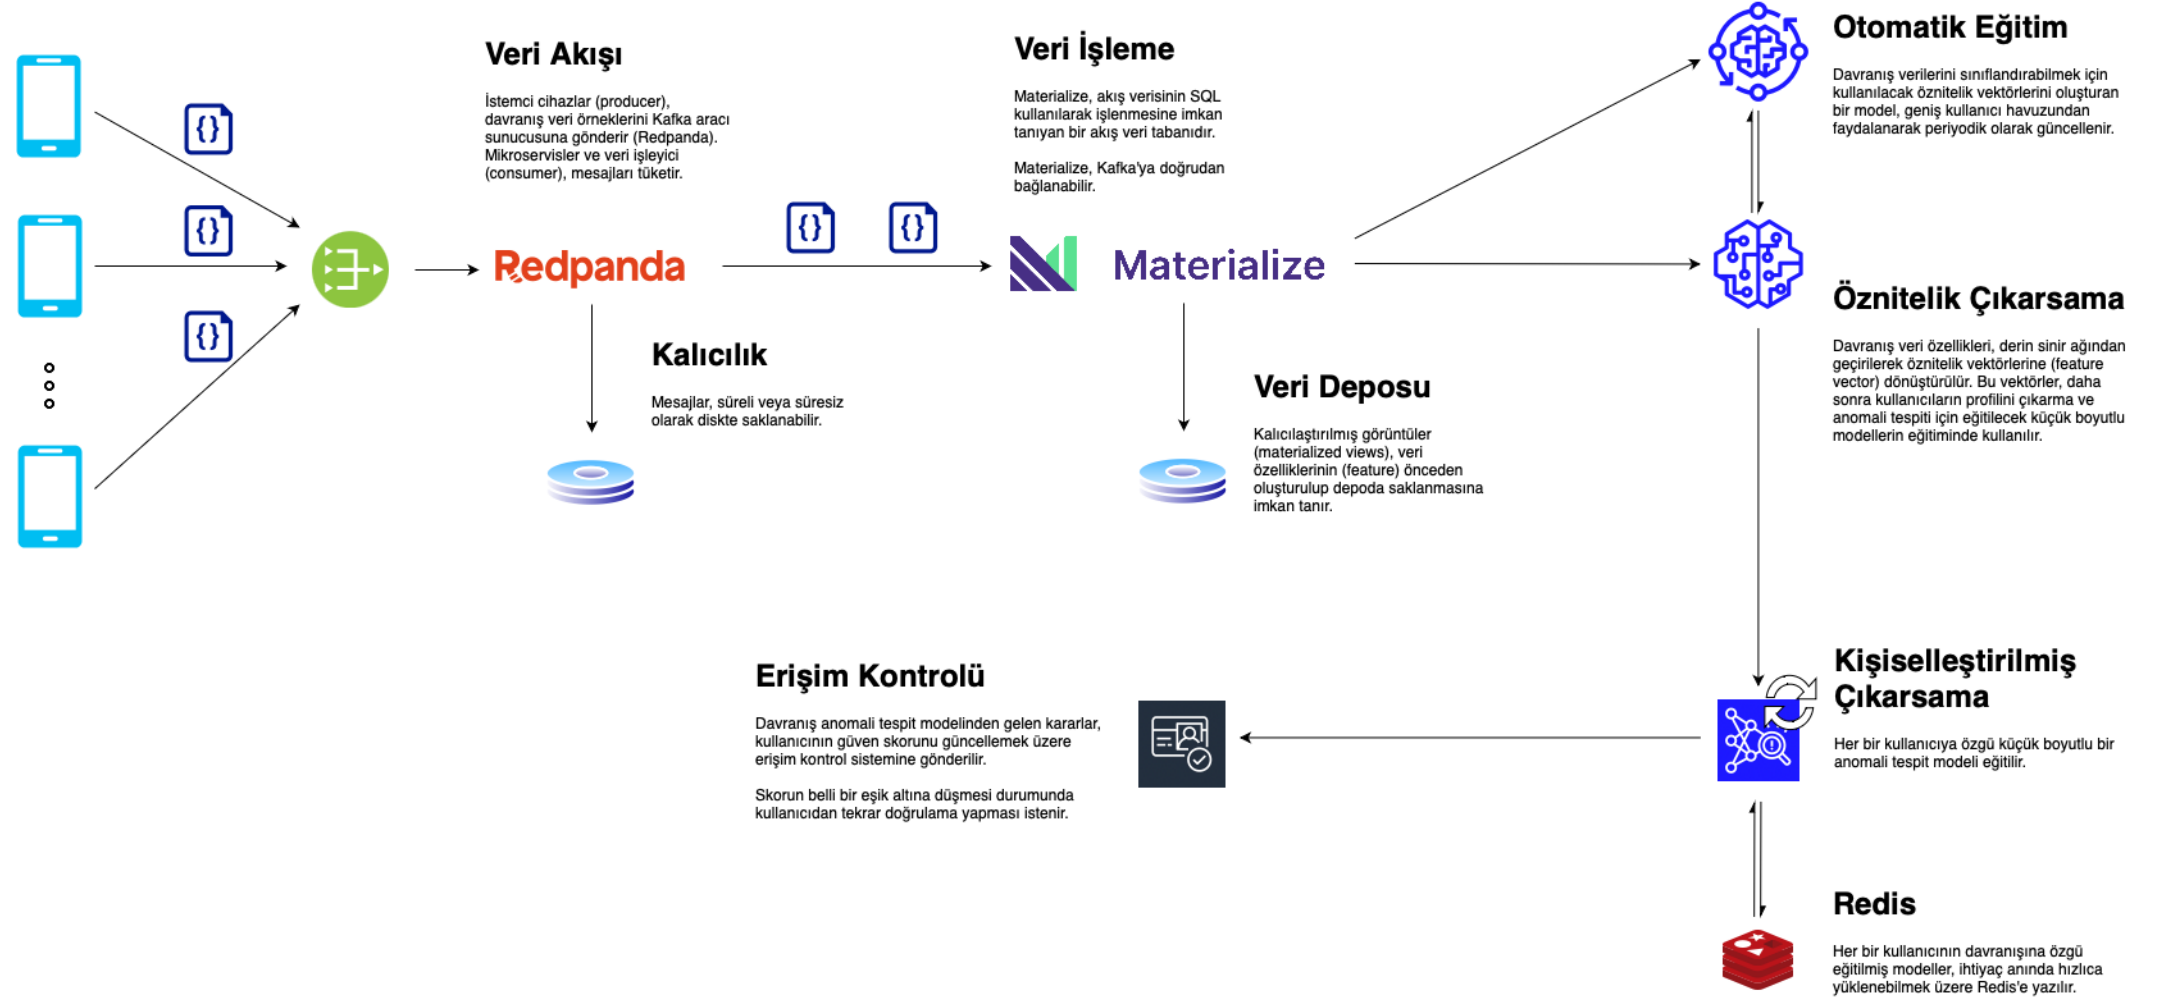
# Model Mimarisi

- Oluşturulan model tuş vuruşu dinamikleri, dokunma verileri ve sensör verileri için tasarlanmış üç adet Spatio-Temporal Dual Attention Transformer (STDAT) içerir. Bu, elde edilen verilerden daha ayırt edici özellikler çıkarmak için tanıtılan yeni bir transformerdir .
- STDAT modeli, gelen veri üzerinde zamansal boyutlara odaklanan çift dikkat mekanizması kullanır. Zamansal-MHA (multi-head attention), girdi verilerini zaman içinde analiz eder ve benzersiz davranışsal kalıpların çıkarılmasına olanak tanır. Model, pozisyonel ayrıntıların örneklemeler için ayrımcı bir özellik üretmede önemli olduğunu kabul ederek, girdiye Gaussian Range Encoder (GRE) kullanılarak pozisyonel kodlama ekler. GRE, pozisyonları tek bir nokta yerine pozisyon aralıkları olarak kodlayan öğrenilebilir bir aralık tabanlı pozisyonel kodlamadır. Model, ayrıca her iki dikkat modülünün çıktısını kullanarak, zamansal desenleri göz önünde bulundurularak ayrımcı özellikler içeren bir çıktı üretir .





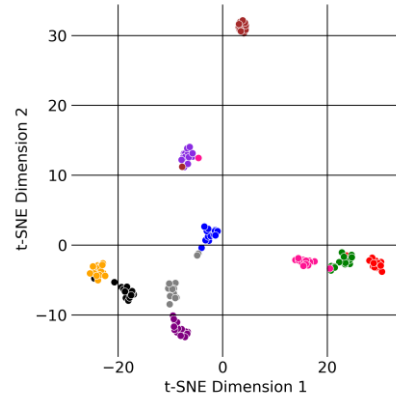
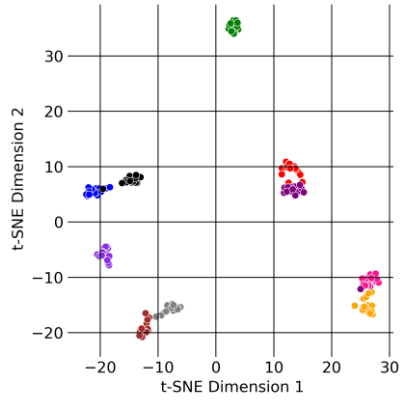
## ➤ Davranış Analizi Modeli Bulut Tarasımı

Yerinde çalıştırabilir davranış biyometriği ile sürekli doğrulama için makine öğrenmesi tasarım belgesi Şekil'de sunulmuştur.



# t-SNE plotları

t-SNE plotlarında farklı kullanıcılara ait özelliklerin kümenlendiğini gözlemleyebiliriz.



# Başarı Ölçütleri

Proje başvuru aşamasında yapılan kapsamlı değerlendirmeler sonucu, belirlenen başarı ölçütleri projenin hedeflerine ulaşma kapasitesini ve amacının gerçekleşme derecesini ölçmek için hayati önem taşımaktadır. Bu ölçütler, projenin genel performansının objektif bir şekilde değerlendirilmesini, ilerlemenin sürekli olarak izlenmesini ve elde edilen sonuçların kapsamlı bir şekilde analiz edilmesini sağlar. Model seçim sürecinde, bu başarı ölçütleri temel alınarak yapılan değerlendirmeler, projenin sonuçlarının güvenilirliğini ve uygulamadaki etkinliğini artırma yolunda kritik bir role sahiptir. Bu çerçevede, modellerin seçimi ve değerlendirilmesi sürecinde başarı ölçütleri, modelin performansını maksimize etme ve projenin genel başarısını optimize etme amacıyla kullanılmıştır.

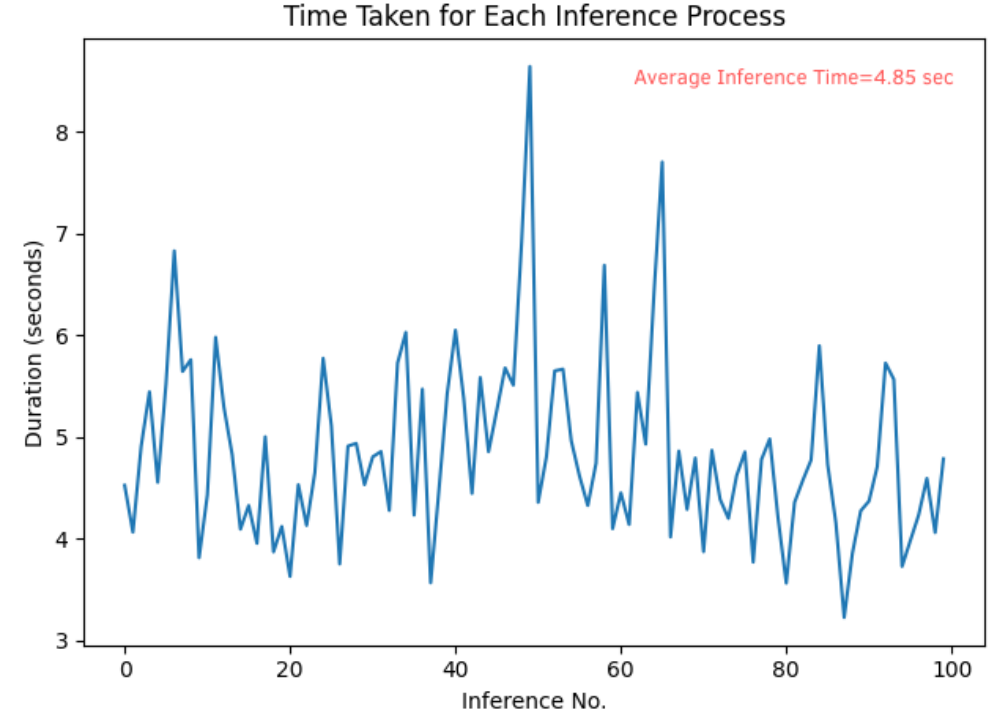
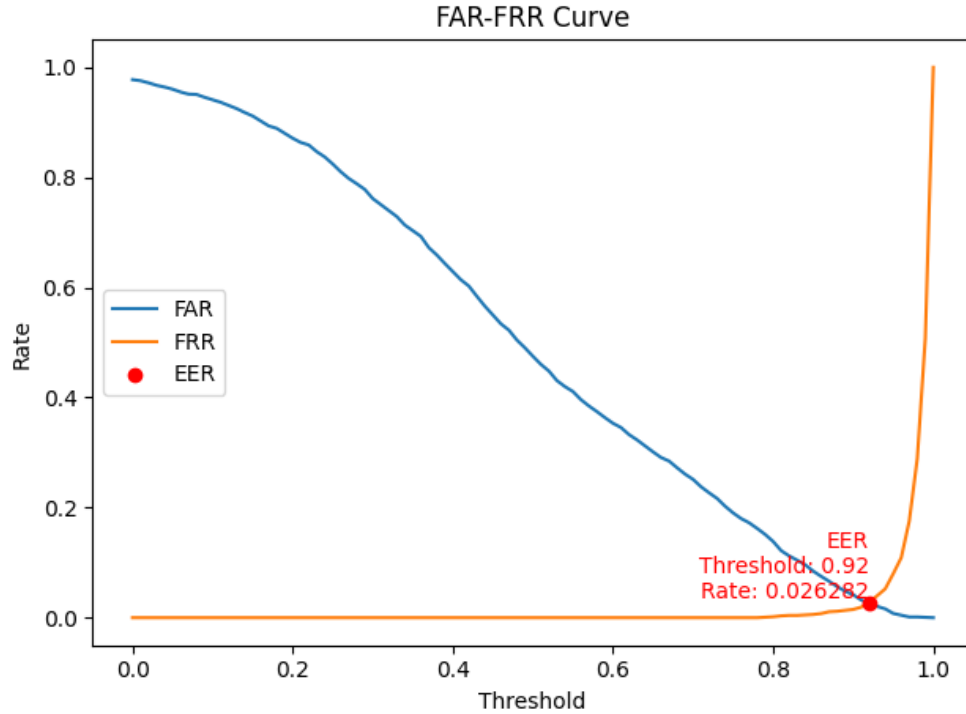
## Teknik Özellikler

Teknik Özellik	Proje Çıktısı (Planlanan)	Proje Çıktısı (Tamamlanan)
Jiroskop	Var	Mevcut
Sekans (bigram, trigram)	Var	Mevcut
İvmeölçer	Var	Mevcut
Manyetometre	Yok	Mevcut
Sürüklenme yönü	Var	Mevcut
Sürüklenme süresi	Var	Mevcut
Parmak basıncı	Var	Mevcut
Parmak hızı	Var	Mevcut

Başarı Ölçütü	Hedeflenen Değer	Gerçekleşen Değer
Davranış biyometriği- sınıflama başarı metriği olarak- FRR (False Rejection Rate)	$\leq 5\%$	<b>%2,8</b>
Davranış biyometriği- sınıflama başarı metriği olarak- FAR (False Acceptance Rate)	$\leq 3\%$	<b>%2,6</b>
Kullanıcı için özgünlük denetimi için denetim aralığı (saniye olarak)	$\leq 10$ sn	<b>4,85 sn</b>



# Model Performansı



Grafiğe ilişkin olarak farklı eşik seviyeleri için FRR ve FAR değerleri verilmiştir.

- ✓ 0,89 eşik => FRR = %1,3, FAR = %4,8
- ✓ 0,9 eşik=> FRR = %1,5, FAR = %4,1
- ✓ 0,91 eşik => FRR = %1,9, FAR = %3,2
- ✓ **0,92 eşik => FRR = %2,8, FAR = %2,6**
- ✓ 0,93 eşik => FRR = %4, FAR = %2





## Risk Verilerinin Analizi

Yapay Zeka Arf Ödülleri



KOBİL Teknoloji A.Ş.

# İçindekiler



- Risk Verilerinin Analizi
- İş Planı
- Veri İşleme
- Model Bilgisi ve Tasarım
- Gerçekleştirilen Başarı Ölçütleri





# Risk Verilerinin Analizi

Mobil cihazlardan gelen risk verilerini toplayarak, cihazlara **düşük, orta ve yüksek** olmak üzere **üç seviyeli bir risk** atayan bir değerlendirme sistemi geliştirdik. Bu sistem, kullanıcıların mobil cihazlarını güvenli bir şekilde kullanmalarını sağlamak amacıyla potansiyel tehditleri gerçek zamanlı olarak analiz ederek sınıflandırır. Risk değerlendirmesi, cihazın güvenlik durumu ve olası tehditlerin etkileri üzerine odaklanır. Kullanılan risk değerlendirme kriterleri aşağıda verilmiştir fakat model gelecekte olabilecek farklı kriterlere uyum sağlama özelliğine sahiptir.

## Değerlendirilen Risk Kriterleri:

1. Jailbreak/Kök Erişimi (Risk-ID [1])
2. Manipülasyon (Risk-ID [2])
3. Zararlı Uygulama (MaliciousApp) (Risk-ID [4])
4. Kod Enjeksiyonu (CodeInjection) (Risk-ID [6])
5. Emülatör Algılama (Emulator Detection) (Risk-ID [0x47])
6. Bellek Koruma (Memory Protection) (Risk-ID [8])






# Veri İşleme

- 5 milyon civarında bir veriyi KOBIL veri tabanından elde etmeyi hedefliyoruz. Burada bir düzenleme ve normalizasyon adımı yapacağız.
- Risk puanlama modelimizin temelinde denetimli öğrenme kullanacağız.

Denetimli öğrenme, bir modelin eğitim sürecinin, önceden etiketlenmiş veya doğru cevapları içeren verilere dayandığı bir öğrenme türüdür. Özetle, bu yaklaşım, bir modelin belirli bir görevi öğrenmesi ve daha sonra yeni verileri analiz etmek, tahmin etmek veya sınıflandırmak için kullanması amacıyla kullanılır. Örneğin, geometrik şekilleri üçgen, daire diktörtgen v.s. olarak sınıflandırmak veya görüntülerdeki nesnelere tanımlar vermek gibi birçok uygulama alanında denetimli öğrenme kullanılır. Bu süreç, veri toplama, model eğitimi ve performans değerlendirmesi adımlarını içerir ve makine öğrenme alanının temel taşlarından birini oluşturur.

## Supervised Learning



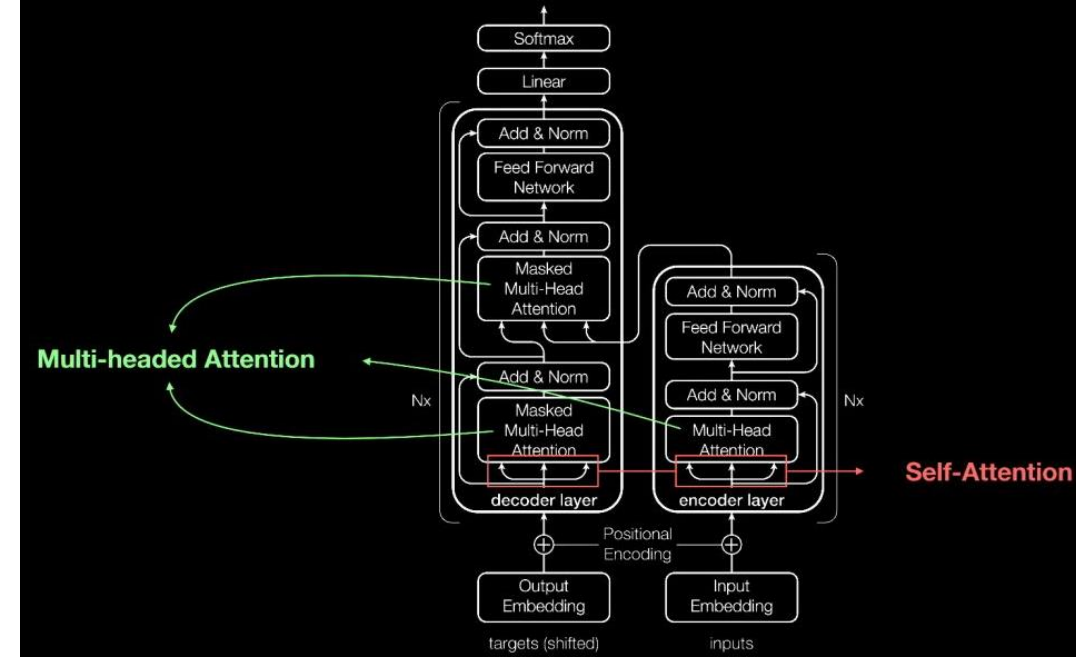
# Model Bilgisi ve Tasarım

Transformers mimarisi temelinde inşa edilmiş bir yapay zeka modelidir. Örneğin GPT, genellikle birçok tekrarlanan bloktan oluşur ve her blok, dikkat (attention) mekanizması ve besleme ileri (feedforward) katmanları içerir. GPT'nin temel bileşenlerine bakacak olursak:

Dikkat Mekanizması (Attention Mechanism): Her GPT bloğu, dikkat mekanizması içerir. Bu mekanizma, modelin giriş verilerinin farklı kısımlarına odaklanmasına olanak tanır. Dikkat mekanizması, metin verilerinin içindeki ilişkileri daha iyi anlamak için kullanılır.

Özyinelemesiz Dikkat (Self-Attention): GPT'deki dikkat mekanizması, özyinelemesizdir, yani veri sırasıyla işlenmez. Bu, paralel hesaplamaların yapılmasına ve eğitim sürecinin hızlanmasına olanak tanır.

Besleme İleri Katmanı (Feedforward Layer): Dikkat mekanizması sonuçları, besleme ileri katmanlarına iletilir. Bu katmanlar, özellikleri işler ve daha sonra sonuçları çıkarır.



Layer Normalizasyon: Her GPT bloğunda, katman normalizasyonu adı verilen bir teknik kullanılır. Bu, eğitim sürecini stabilize etmeye ve modelin daha hızlı yakınsamasına yardımcı olur.

Staked Blocks (Üst Üste Bloklar): GPT, genellikle birçok bloğun üst üste eklenmesiyle oluşturulur. Bu, modelin derinliğini artırır ve daha karmaşık görevleri çözmeye olanak tanır.

Kelime Gömme (Word Embeddings): GPT, kelime gömme katmanları ile başlar. Bu katmanlar, kelime dağılımını vektörlerle temsil ederler ve metin verilerini işlemeye başlamak için kullanılır.

Lineer Dönüşüm Katmanı (Linear Transformation Layer): GPT'nin çıkışı, genellikle bir lineer dönüşüm katmanı ile sonuçlanır. Bu katman, modelin sonuçlarını istenen çıktı biçimine dönüştürür.

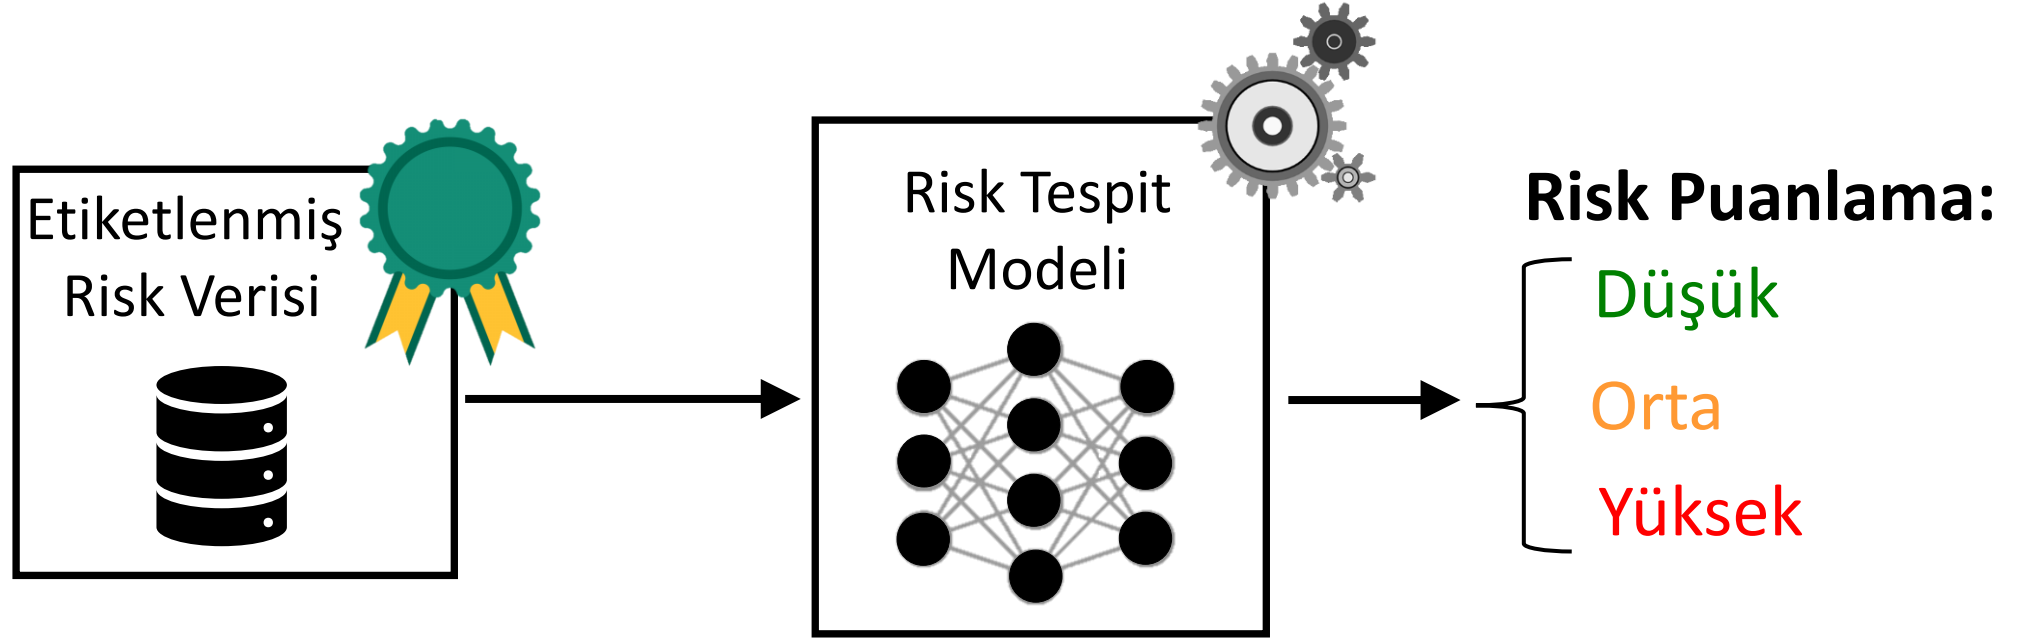
- ✓ **GPT modelleri, genellikle büyük veri setleri üzerinde ön eğitim ile başlatılır ve ardından belirli görevlere özelleştirilir. Bu yapının, doğal dil işleme görevleri gibi çeşitli uygulamalarda başarılı olduğu kanıtlanmıştır.**




# Risk Değerlendirme Sistemi



# Model Mimarisi



# Gerçekleştirilen Başarı Ölçütleri



	precision	recall	f1-score	support
0	1.00	0.99	0.99	82635
1	1.00	1.00	1.00	466452
2	0.99	1.00	0.99	125694
accuracy			1.00	674781
macro avg	0.99	0.99	0.99	674781
weighted avg	1.00	1.00	1.00	674781

