

# Makine öğrenme algoritmalarını kullanan duygu tahminine dayalı müzik öneri sistemi

Hasan ALİYEV<sup>1\*</sup>  
Peri GÜNEŞ<sup>2</sup>

## Özet

*Müzik, insanlık tarihi boyunca duygusal ifadenin araçlarından biri olmuştur. Farklı kültürlerde farklı zaman dilimlerinde müzik bireylerin deneyimlerini duygularını anlatmanın eşsiz bir yolunu sunmuştur. Teknolojik ilerlemelerle birlikte müzikle etkileşimimiz de büyük bir gelişme yaşamış dijital platformlar sayesinde müziğe erişimimiz kolaylaşmıştır. Geleneksel müzik öneri sistemleri kullanıcının müzik dinleme alışkanlıklarını baz alırken bu çalışma anlık duygu durumunu değerlendirerek müzik önerisi sunmayı hedeflemiştir. Kullandığımız model CNN temelli bir duygu tanıma sistemidir. Bu model yüz görüntülerini analiz ederek yedi duygudan birini tahmin eder. Modelin eğitim sürecinde Confusion Matrix (CM) sonuçları modelin duygu sınıflandırma konusunda iyi bir performans sergilediğini göstermektedir. ROC eğrisi analiz sonuçları modelin duyguyu tahmin etme kabiliyetinin yüksek olduğunu göstermektedir. Özellikle modelin genel doğruluk oranının %92,7 olması bu modelin ne kadar etkili olduğunu işaret etmektedir. Bu çalışmada duyguya göre müzik öneri sistemlerinin kullanıcı deneyimini daha etkili bir hale getirme potansiyeline sahip olduğu görülmektedir.*

**Anahtar Kelimeler:** *Evrişimli sinir ağları, duygu tanıma, müzik öneri sistemleri, derin öğrenme, yüz ifadesi analizi*

<sup>1</sup> İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, hasanaliev@stu.aydin.edu.tr ORCID: 0000-0003-1467-3284

<sup>2</sup> İstanbul Gelişim Üniversitesi, Elektrik Elektronik Mühendisliği, pgunes@gelisim.edu.tr ORCID:0009-0002-9080-3239

## **Music recommendation system based on emotion prediction using machine learning algorithms**

### ***Abstract***

*Music has been a means of emotional expression throughout human history. Different cultures and times have offered unique ways of expressing the emotions experienced by individuals through music. Technological advancements have greatly enhanced our interaction with music, making access easier thanks to digital platforms. While traditional music recommendation systems are based on the user's listening habits, this study aims to provide music recommendations by evaluating the user's immediate emotional state. We utilize a CNN-based emotion recognition system for this purpose. This model predicts one of seven emotions by analyzing facial images. The results of the Confusion Matrix (CM) in the training phase indicate that the model is proficient at classifying emotions. ROC curve analysis shows the model's high capability in emotion prediction. Notably, the model's overall accuracy stands at 92.7%, highlighting its effectiveness. This research demonstrates the potential of emotion-based music recommendation systems in enhancing the user experience.*

***Keywords: Convolutional Neural networks, emotion recognition, music recommendation systems, deep learning, facial expression analysis.***

## Giriş

Duygusal durumlar, bireylerin kararlarına, davranışlarına ve tercihlerine derinlemesine etki eden önemli faktörlerdir. Müzik ise tarih boyunca, bu duygusal durumları ifade etmek, pekiştirmek veya dönüştürmek için evrensel bir araç olarak kullanılmıştır. Teknolojinin ilerlemesiyle birlikte, duygusal durum ve müzik arasındaki bu etkileşim, kişiselleştirilmiş müzik öneri sistemleri ile yeni bir boyut kazanmıştır. Geleneksel müzik öneri sistemleri, genellikle kullanıcının geçmiş dinleme alışkanlıklarına veya genel popülerliğe dayalı önerilerde bulunurken, günümüzde duygusal durumu doğrudan analiz eden ve buna dayalı önerilerde bulunan sistemlerin önemi artmıştır.

Geleneksel müzik öneri sistemleri, kullanıcının geçmiş dinleme alışkanlıklarına ve genel popülerliğe dayanarak seçimler yapar. Ancak, günümüzde bu basit algoritmaların ötesine geçen, duygusal durumu doğrudan analiz eden ve buna dayalı önerilerde bulunan sistemlerin önemi artmaktadır. Bu çalışmada, yüz ifadesi analizi ile duygusal durumu tespit eden ve bu bilgiyi kullanarak müzik önerileri sunan bir yaklaşımı ele alınmaktadır (Qiu ve Jia, 2022).

Makine öğrenimi ve derin öğrenme teknolojileri, yüz ifadesi ve ses tonu gibi bireysel veri noktalarını kullanarak duygusal durum tahmininde bulunmak için kritik araçlar haline gelmiştir. Bu çalışma, teknolojik ilerlemelerin kişiselleştirilmiş müzik öneri sistemlerinin geliştirilmesinde nasıl bir rol oynayabileceği ve bu teknolojilerin etik ve gizlilik konularını nasıl ele alabileceği konularını da tartışmaktadır.

Teknolojik ilerlemeler, kişiselleştirilmiş deneyimler sunma potansiyelini artırırken, bu sürecin içerdiği etik ve gizlilik sorunları da göz ardı edilmemelidir. Kullanıcıların kişisel verilerinin, özellikle duygusal durumlarına ilişkin verilerinin, nasıl toplandığı, işlendiği ve saklandığı konuları, teknolojinin kullanımı kadar kritik bir öneme sahiptir. Bu, sadece kullanıcı mahremiyetini korumak adına değil, aynı zamanda algoritmalara olan güveni artırmak ve potansiyel yanıltıcı sonuçları en aza indirmek adına da gereklidir.

Teknolojinin ilerlemesiyle birlikte, duygusal ifade tanıma teknolojilerinde önemli gelişmeler kaydedilmiştir. Yüz ifadelerini tanıma ve analiz etme yeteneği, birçok uygulama için kritik bir öneme sahiptir. Bu yetenek, özellikle güvenlik ve yasa uygulama hizmetlerinde, şüpheli davranışları tespit etmek ve bireylerin niyetlerini anlamak adına büyük bir değer taşır. 'dlib' ve 'MediaPipe' gibi algoritmaların performans karşılaştırmaları, bu alandaki teknolojik gelişmelerin bir göstergesidir. 'MediaPipe', 'dlib' ve OpenCV'ye göre daha yüksek bir performans ve daha az başarısızlık oranı ile öne çıkmaktadır. Ancak, sadece performans değil, aynı zamanda tanıma doğruluğu da bu algoritmalarda kritik bir öneme sahiptir. Bu bağlamda, yüz ifadelerini tanıma konusunda hangi açıların en etkili olduğunu belirlemek amacıyla yapılan çalışmalar, daha doğru ve güvenilir sonuçlar elde etmek için kritik bir rol oynamaktadır (De Prisco ve Roberto, 2020). Bu, duygusal ifade tanıma teknolojisinin, özellikle güvenlik hizmetlerinde, daha geniş bir uygulama potansiyeline sahip olduğunu göstermektedir. Müzik, bireyler için sadece bir eğlence aracı olmanın ötesinde, duygusal halleri üzerinde derin bir etkiye sahip bir sanat formudur. Son yıllarda, teknolojinin gelişmesiyle birlikte, müzik önerme sistemleri büyük bir popülerlik kazanmıştır.

Bu sistemler, kullanıcının duygusal halini, müzik tercihlerini ve dinleme alışkanlıklarını dikkate alarak kişiye özel önerilerde bulunabilir. Özellikle Spotify gibi popüler müzik platformları, milyarlarca çalma listesi ile kullanıcıların kendi müzik tercihlerini yansıtan listeler oluşturmalarına olanak tanımaktadır (Martínez ve Vega, 2022). Finansal piyasalarda, özellikle hisse senedi piyasasında, duygusal analizin büyük bir potansiyele sahip olduğunu bilinmektedir. Bu bağlamda, sosyal medya verilerinden elde edilen duygusal analizlerin, hisse senedi piyasasındaki hareketleri tahmin etmede nasıl bir rol oynayabileceği konusunda birçok araştırma yapılmıştır (Jiao, 2022). Bir çalışma, 'StockTwits' ve 'Twitter' gibi popüler sosyal medya platformlarından toplanan veriler üzerinde duygusal analiz uygulayarak, bu analizlerin hisse senedi hareketlerini tahmin etmedeki etkinliğini incelemiştir. Bu analiz sürecinde, KNN, SVM, LR, NB, DT, RF ve MLP gibi çeşitli makine öğrenimi algoritmaları kullanılarak hangi modelin en iyi sonuçları verdiği değerlendirilmiştir (Ka ve ark., 2021). Makine öğrenimi algoritmaları sadece finansal analizlerde değil, aynı zamanda duygusal analizde de etkili bir şekilde kullanılmaktadır. Dijital çağın getirdiği ko-

laylıklardan biri, bireylerin duygusal durumlarının tespit edilip bu bilgilerin çeşitli uygulamalarda kullanılabilmesidir. Yüz ifadeleri, bu bağlamda, insanın duygusal durumunu ve genel ruh halini tahmin etmede kritik bir bileşen olarak ön plana çıkmaktadır (Koukaras ve ark., 2022).

Kameralar aracılığıyla yüz ifadelerini analiz ederek insan duygularını çıkarma yöntemleri konusunda yapılan çalışmalar, bu alandaki teknolojik gelişmeleri ve bu teknolojilerin potansiyelini gözler önüne sermektedir. Duygusal analizde kullanılan teknolojik araçlar arasında OpenCV öne çıkmaktadır. Bu araç, yüz ifadelerini tanıma ve analiz etme yeteneği sayesinde duygu tespiti ve müzik önerisi uygulamalarında sıkça kullanılmaktadır (Rosa ve ark., 2015). Bu teknolojik gelişmelerin yanı sıra, müzik de bireylerin duygusal halleri üzerinde derin bir etkiye sahiptir. Özellikle son yıllarda, müzik önerme sistemleri kullanıcılara duygusal durumlarına uygun müzik önerileri sunma potansiyeline sahip olmuştur. Müzik önerme sistemlerinin popülerleşmesinde, Spotify'nın kritik bir role sahip olduğunu gözlemleyebiliriz. Spotify, milyarlarca çalma listesi ile kullanıcıların kendi müzik tercihlerini yansıtan listeler oluşturmalarına olanak tanıyan devasa bir platformdur (Sashank ve ark., 2022). Bu alanda yapılan bir araştırmada, kullanıcıların oluşturduğu çalma listelerine dayalı bir öneri sistemi ele alınmaktadır. Bu sistem, TF-IDF vektörleştirilmesi kullanarak içerik tabanlı filtreleme yaparak, şarkıların veya parçaların adları üzerinde duygusal analiz gerçekleştirmektedir. Duygusal analiz, sadece müzik önerme sistemlerinde değil, aynı zamanda genel müzik analizinde de etkili bir araçtır (Chirasmayee ve Venkata Sai, 2022). Müzik, bireyler için duygusal ifadeleri ve ruh hallerini yansıtan güçlü bir sanat formudur. Bu bağlamda, duygusal analiz teknolojileri müziğin sunduğu duygusal zenginlikleri daha iyi anlamak ve bu bilgileri kullanmak için büyük bir potansiyele sahiptir. Müzikle ilgili duygu tanıma, belirli özelliklere dayanarak müzik parçalarının spesifik duygularla ilişkilendirilmesi sürecidir (Mehta ve Gupta, 2021). Duygusal bağlamda müziğin önemi, yalnızca bireylerin kişisel deneyimleriyle sınırlı değildir (Düzbastılar ve ark., 2019). Müzik, kültürel, toplumsal ve tarihsel bağlamlarda da derin bir etkiye sahiptir. Bu nedenle, müziğin duygusal analizinde, bu çeşitli bağlamları dikkate almak esastır. Böylece, bir müzik parçasının farklı kültürlerde veya topluluklarda farklı duygusal tepkilere neden olabileceği göz önünde bulundurularak daha kapsamlı ve doğru analizler yapılabilir (Aydoğan ve Şener., 2020). Müzik

ve duygusal analiz arasındaki bu derin bağ, teknolojinin de katkısıyla daha da karmaşık bir hale gelmiştir. Teknoloji, duygusal ifade tanıma teknolojilerinin gelişimine büyük katkıda bulunmuştur. Yüz ifadelerini tanıma ve analiz etme yeteneği, birçok uygulama için kritik bir öneme sahiptir (Gündüz ve Yılmaz., 2021). Bu, özellikle güvenlik ve yasa uygulama hizmetleri gibi alanlarda, duygusal ifade tanıma teknolojisinin büyük bir potansiyele sahip olduğunu göstermektedir. Güvenlik hizmetlerinde duygusal ifade tanıma teknolojisinin bu kadar kritik bir öneme sahip olması, teknolojinin hızla gelişen doğasından kaynaklanmaktadır (Yi ve Liu., 2020). Özellikle dlib ve MediaPipe gibi algoritmaların performans karşılaştırmaları, bu alandaki teknolojik ilerlemelerin ne kadar hızlı olduğunu göstermektedir. MediaPipe, dlib ve OpenCV'ye göre daha yüksek bir performans ve daha az başarısızlık oranı ile öne çıkmaktadır. Ancak, performans değil, aynı zamanda tanıma doğruluğu da bu algoritmalarda kritik bir öneme sahiptir. Tanıma doğruluğu, bu teknolojilerin gerçek dünya uygulamalarında ne kadar güvenilir olduğunu belirleyen bir faktördür (Siam Ve ark., 2022). Bu doğruluğun artırılması için, algoritmaların eğitim sürecinde kullanılan veri setlerinin çeşitliliği ve genişliği kritik bir öneme sahiptir. Bu bağlamda, algoritmaların farklı etnik kökenlere, yaş gruplarına ve cinsiyetlere sahip bireyler üzerinde eşit derecede iyi performans göstermesi esastır. Dolayısıyla, bu teknolojilerin geliştirilmesi ve uygulanmasında, çeşitlilik ve kapsayıcılığın önemi vurgulanmalıdır (Wang ve Perez, 2017).

Bu makale, duygusal analiz ve müzikle ilgili duygu tanımanın teknolojik araçlarla nasıl gerçekleştirildiğini incelemektedir. Ayrıca, bu teknolojilerin gelişimindeki en son trendleri ve bu alandaki gelecekteki potansiyelleri de bu çalışmada değerlendirilmektedir.

## **Materyal ve Metod**




Çalışmada kullanılan veri seti, anonim veri setleri ile popüler bir duygu tanıma veri seti olan FER (Facial Expression Recognition) Dataset'in birleştirilmesi ile oluşturulmuştur. Bu birleştirilmiş veri seti, farklı duygu durumlarını temsil eden yüz ifadelerini içermektedir. Duygusal tepkilerin tanınması için Convolutional Neural Network (CNN) tabanlı bir model kullanılmıştır. CNN, yüz ifadelerini analiz ederek belirli duygu durumlarına karşılık gelen sınıflandırmaları gerçekleştirmektedir.

Model, birleştirilmiş veri seti üzerinde eğitilmiş ve test edilmiştir. Modelin genel başarımı, doğruluk oranları ile değerlendirilmiştir. Kullanıcının duygusal durumuna en uygun müziği önermek için bir makine öğrenimi modeli geliştirilmiştir. Bu model, duygu analizi sonucunda elde edilen sınıflandırmaları temel alarak müzik önerileri sunmaktadır.

Kullanıcıların duygusal durumlarını anlık olarak paylaşabilmeleri için web tabanlı bir arayüz geliştirilmiştir. Bu arayüz, kullanıcının web kamerası aracılığıyla yüz ifadesini almakta ve bu veriyi duygu analizi sistemine iletmektedir. Kullanıcı, web arayüzü üzerinden kameraya duygusal durumunu paylaştığında, öncelikle CNN tabanlı model bu durumu analiz etmektedir. Ardından, analiz sonucu elde edilen duygu durumu, makine öğrenimi tabanlı müzik öneri modeline iletilir.

## Veri

Tüm veriler anonim olarak kullanılmıştır. Kullanılan veriler ve tipleri Tablo 1 Veri Özelliklerinde mevcuttur.


VERİ ADI	VERİ TİPİ	ÖRNEK VERİ
Sinirli	Fotoğraf	
Tiksinme	Fotoğraf	
Korku	Fotoğraf	
Mutlu	Fotoğraf	

Tablo 1 Veri Özellikleri (URL 1)

Normal	Fotoğraf	
Üzüntü	Fotoğraf	
Sürpriz	Fotoğraf	

Tablo-1, Resim-1 ve Resim-2’de de gözüktüğü üzere, bu çalışma duygusal tepkilere odaklanarak detaylı bir veri analizi sunmaktadır. Analiz edilen veri seti, farklı duygu durumlarını yüzdelik oranlarla şu şekilde yansıtmaktadır: ‘Öfhe=%12,3’, ‘Tiksinme=%9,5’, ‘Korku=%12,1’, ‘Mutlu=%19,3’, ‘Nötr=%19,6’, ‘Üzgün=%11,8’ ve ‘Şaşkın=%15,4’. Nötr ifadeler, analizdeki önemini vurgulayan en belirgin duygu durumunu temsil etmektedir. Mutlu ifadeler ise duygusal tepkilerin pozitif yönünü yansıtmaktadır.






**Resim 1. Duygu Sınıfı Dağılımı**

Duygularda veri dengesizliğini engellemek amacıyla olabildiğince çok sayıda veri toplanmış olup, olabildiğince eşit olmaya yakın bir veri dağılımı hedeflenmiştir. Bu hedef büyük ölçüde başarıyla gerçekleştirilmiştir. Üzgün ve şaşkın ifadeler, duygusal tepkilerin daha derin ve karmaşık yönlerini temsil ederken; öfke, korku ve tikslenme ifadeleri, duygusal tepkilerin daha az sıklıkla gözlemlenen yönlerini ortaya koymaktadır.

Bu detaylı dağılım, çalışma kapsamında hazırlanan iki grafikte görselleştirilmiştir. Modelin eğitim sürecinde hem renkli hem de renksiz verilerle çalışılmıştır, bu da modelin çeşitli veri tiplerine adaptasyonunu artırarak genel başarısını yükseltmiştir. Veri setini daha geniş ve çeşitli hale getirilmesi için fotoğrafların hafifçe kaydırılması, döndürülmesi, parlaklık ve kontrastın ayarlanması gibi temel yöntemler kullanılmıştır. Aynı zamanda, gürültü ekleme ve elastik dönüşümler gibi ileri seviye tekniklerle veri seti zenginleştirilmiştir. Bu teknikler, modelin genelleme yeteneğini geliştirerek, doğruluk oranını önemli ölçüde artırmıştır.



*Resim 2. Kullanılan Verilerin Duygu Sınıfı Dairesel Dağılımı*

Sonuç olarak, bu entegratif yaklaşım sayesinde, mevcut veri setinin kapsamı ve çeşitliliği önemli ölçüde genişletilmiştir. Modelin doğruluk oranı da ciddi bir artış göstermiştir, bu da duygusal analizlerde daha kesin ve güvenilir sonuçların elde edilmesine olanak tanımıştır.

## Model

### Evrişimli sinir ağları (CNN)

Evrişimli Sinir Ağları, derin öğrenme modellerinin bir alt kümesi olup, özellikle görsel görevlerde oldukça başarılıdır. CNN'lerin başarısının ardında, bir görüntüdeki yerel özellikleri öğrenme yeteneği yatmaktadır. Evrişim, bir giriş matrisi  $I$  (genellikle bir görüntü) üzerinde bir filtre matrisinin kaydırılmasıyla gerçekleşen bir matematiksel işlemidir. Filtre, belirli bir özelliği (örneğin bir kenar veya doku) tespit etmek için kullanılır.

Matematiksel olarak, evrişim işlemi şöyledir:

Eğer  $F$  bir filtre ve  $I$  bir görüntüyse, evrişim sonucu  $S$  şu şekilde hesaplanır:

$$S(i, j) = \sum_m^i \sum_n^i I(i - m, j - n) \times F(m, n)$$

Bu işlem, filtre boyutunda bir pencerenin her hareketi için giriş matrisi üzerinde tekrar tekrar yapılır. Bu, aktivasyon haritası olarak adlandırılan yeni bir matrisin oluşmasına neden olur. Evrişim işlemi sonrası, genellikle bir aktivasyon fonksiyonu (sıklıkla ReLU) uygulanır. Bu, modelin lineer olmayanlıkları öğrenmesine yardımcı olur.

ReLU fonksiyonu:

$$f(x) = \max(0, x)$$

Bu fonksiyon, negatif değerleri sıfıra ayarlar ve pozitif değerleri olduğu gibi bırakır.

Havuzlama, aktivasyon haritasının boyutunu azaltmak için kullanılır. Bu, hesaplamalı karmaşıklığı azaltırken modelin öğrendiği özelliklerin kolumnsal değişikliklere karşı dayanıklı olmasını sağlar.

Max-pooling, belirli bir pencere boyutu içindeki maksimum değeri alarak çalışır. Örneğin, 2x2 max-pooling uygulandığında, her 2x2 pencere için en büyük değer seçilir.

Bu katmanlar, evrişim ve havuzlama katmanlarının çıktılarını alır ve son sınıflandırma işlemi için kullanılır. Burada, tüm nöronlar önceki katmandaki nöronlara bağlıdır.

### Modelin Eğitim Süreci ve Yapısı Veri Hazırlığı

initDataGens() fonksiyonu, modelin başarılı bir setinin önceden işlenmesi ve hazırlanmasını ele alır. Eğitim süreci geçirebilmesi için ImageDataGenerator sınıfı, Keras kütüphanesinin sunduğu güçlü bir araç olup, gerçek zamanlı veri artırma işlemlerini desteklemektedir. Bu özellik, modelin ge-

nelleştirme kabiliyetini artırmak için hayati bir öneme sahip olup, potansiyel aşırı uyum problemlerini azaltmaktadır (Shorten ve ark., 2019).

Modelin aynı nesnenin farklı varyasyonlarını göstermesine izin vermek için eğitim setine özel bir veri artırma tekniği uygulanmıştır. Özellikle görüntü döndürme, yatay ve dikey kaydırma, düzenleme ve aydınlatma koşullarını değiştirme gibi yöntemlerle veri kümeleri iyileştirilir. Bu tekniklerin amacı, modelin aynı nesneyi farklı açılardan, aydınlatma koşullarından ve deformasyonlardan tanınmasını sağlamaktır.

`initDataSets ()` fonksiyonu, modelin gereksinim duyduğu veri setlerini dinamik bir şekilde hazırlar. Bu fonksiyon, `ImageDataGenerator` ile eşleştirilerek, verileri belirli bir dizinden alır ve bu veriyi model eğitimi sırasında kullanılmak üzere hazırlar. Bu dinamik yaklaşım, büyük veri setleriyle çalışırken belleği verimli bir şekilde kullanmayı ve disk I/O işlemlerini minimize etmeyi sağlar.

### **Modelin Özelleştirilmesi**

`getAllForTraining()`: Fonksiyonu, model eğitimi sırasında kullanılan geri çağırma fonksiyonlarını ve optimizasyon ayarlarını tanımlar. Bu fonksiyon, modelin eğitim sürecini daha verimli ve etkili hale getirmek için bir dizi strateji ve teknik tanımlar:

**ReduceLRonPlateau**: Bu geri çağırma fonksiyonu, eğitim süreci boyunca belirli bir metriğin (genellikle doğruluk) belirli bir süre boyunca iyileşmediğini gözlemlerse öğrenme hızını dinamik olarak azaltır. Bu yaklaşım, modelin yerel minimumlardan kaçınmasına ve global minimuma daha hızlı ulaşmasına yardımcı olabilir (Masud, 2022).

**EarlyStopping**: Bu fonksiyon, modelin eğitim süreci boyunca belirli bir metrikte (genellikle doğruluk) belirli bir süre boyunca iyileşme göstermediğinde eğitimi otomatik olarak durdurur. Bu, modelin aşırı uyuma karşı korunmasına yardımcı olur ve eğitim sürecinin verimliliğini artırır (Masud, 2022).

updateBaseModel (): Fonksiyonuyla MobileNet, belirli bir görev için uygun hale getirilir. MobileNet, hafif yapısı ve etkili performansı ile bilinen bir CNN modelidir. Bu fonksiyon, MobileNet'in çıktısına ek katmanlar ekleyerek, modeli belirtilen duyu sınıflarını tanıyabilecek şekilde özelleştirir.

MobileNet, özellikle hafif ve etkili bir CNN modelidir. Bu nedenle, modelin kaynak sınırlı ortamlarda, özellikle mobil cihazlarda, daha hızlı ve verimli bir şekilde çalışmasını sağlar. MobileNet'in bu özelliği, gerçek zamanlı uygulamalarda ve kenar hesaplamada (edge computing) oldukça kullanışlıdır (Nan ve ark., 2022).

Adam optimizasyon algoritması hem öğrenme hızınının adaptif ayarlamasını hem de momentum mekanizmasını birleştirir. Bu kombinasyon, modelin daha hızlı ve stabil bir şekilde yakınsamasını sağlar. Özellikle derin öğrenme modellerinde, Adam algoritması, öğrenme sürecinin daha hızlı yakınsamasını ve daha iyi bir genelleme performansı göstermesini sağlar. Bu algoritmanın kullanılma nedeni, çeşitli başlangıç koşulları ve veri dağılımları için etkili sonuçlar üretme kapasitesidir (Reyad ve ark. ,2023).

Günümüzün teknolojik gelişmeleri, bireysel deneyimleri zenginleştirmek ve kişiselleştirmek için insanın duygusal dünyasıyla daha yakından ilgilendirmektedir. Bu bağlamda, yüz ifadesi analizi ve müzikle insan psikolojisi arasındaki derin bağ, duygusal deneyimleri zenginleştirmek için benzersiz bir fırsat sunmaktadır.

## **Yüz İfadesi Analizi**

Yüzler, insanların duygularını ifade etmek için kullandıkları en güçlü araçlardan biridir. Parıldayan gözler, buruşuk dudaklar ve kaşların hareketi gibi ince yüz ifadeleri, kişinin içsel benliğini ortaya çıkarır.

Yüz ifadesi analizi, bu mikro ifadeleri tanıyabilen ve yorumlayabilen derin öğrenme algoritmaları kullanılarak gerçekleştirilir. Bu algoritmalar, binlerce yüz verisi üzerinde eğitildi ve bir kişinin yüzünün en küçük ayrıntılarını bile tanıyabilir.

Müzik, duygusal hallerimizi etkileyen, anıları tetikleyen ve genellikle ruh

hallerimize eşlik eden evrensel bir dil olarak kabul edilir. Örneğin; hüzünlü bir melodi, bizi geçmişteki bir anıya götürebilir veya enerjik bir ritim günümüzü aydınlatabilir.

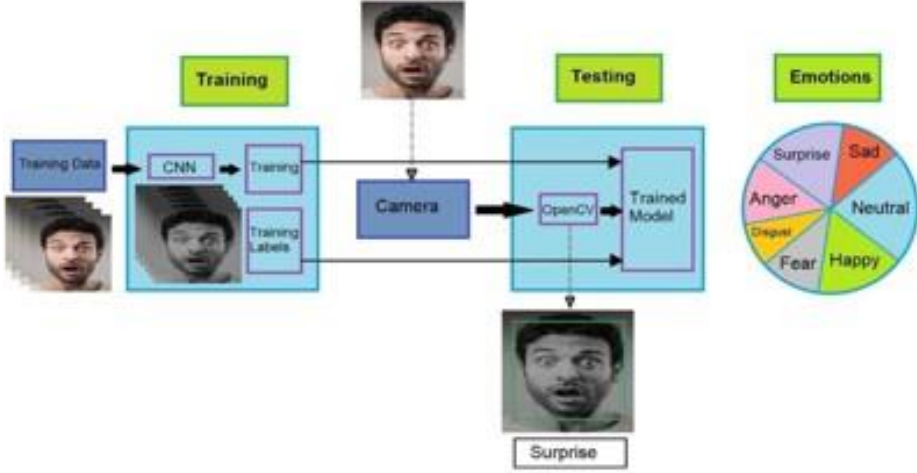
Bu projede, elde edilen duygusal duruma göre, belirli duygu durumlarına özel olarak hazırlanmış müzik listeleri kullanıcıya sunulmaktadır. Bu hem psikolojik hem de akustik bir uyum yaratmayı amaçlar.

Kullanıcının yüz fotoğrafı, ön yüz aracılığıyla arka yüze iletilir. Arka yüzde, derin öğrenme modeli bu fotoğrafı analiz eder ve bir duygu tahmini yapar. Bu tahmin, önceden eğitilmiş algoritmalar kullanılarak, fotoğrafın içerdiği mikro ifadelerden türetilir.

Bu duygusal analiz sonucu, önceden hazırlanmış müzik listeleri arasından bir seçim yapılır ve kullanıcıya, anlık duygusal durumuna uygun müzikler önerilir.

Bu sistem, kullanıcının duygusal durumunu anlama ve bu duruma uygun bir müzik deneyimi sunma yeteneğine sahiptir. Bu, kullanıcının duygusal ihtiyaçlarına daha duyarlı bir teknolojik yaklaşım sunarak, teknolojinin insani yönünü ön plana çıkarır.

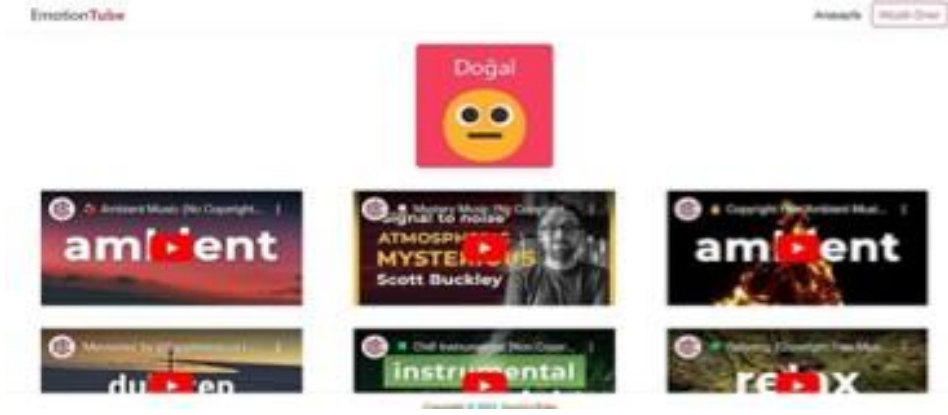
Özetle bu çalışma ile, teknoloji ve duygusal zekanın nasıl bütünleştirilebileceğinin etkileyici bir örneği ortaya konulmaya çalışılmıştır. Yüz ifadesi analizi ve duygu temelli müzik öneri sistemleri, teknolojik yeniliğin insan deneyimini nasıl zenginleştirebileceğinin mükemmel örnekleridir. Bu entegrasyon, duygusal deneyimlerin ve teknolojik ilerlemenin sınırsız potansiyelini gözler önüne serer.



**Resim 3.** Makine Öğrenimi Modelinin Çalışma Akışı

Resim-3'te, sunulan makine öğrenimi modelinin genel çalışma mantığı görsel olarak detaylandırılmıştır. İlk adımda, "Training Data" adlı veri seti kullanılarak model, Convolutional Neural Network (CNN) kullanılarak eğitilmektedir. Eğitim sürecini tamamladıktan sonra model test aşamasına geçer. Bu aşamada, atanan test verileri, modelin doğruluğunu test etmek için model üzerinde değerlendirilir. Eğitim ve test bölümleri arasında sürekli olarak veri alışverişi yapılır, bu da modelin başarı oranını artırır ve en iyi sonuçları üretir. Kullanıcı tarafından, kamera aracılığıyla alınan bir fotoğraf OpenCV teknolojisi ile işlenir. Bu işleme sırasında yüz tespiti gerçekleştirilir. Tespit edilen yüz, eğitilmiş olan modele gönderilir ve model, bu yüzün hangi duygusal durumu (emotion) yansıttığını belirler.

Modelin duygusal analiz sonuçları, Resim 3 de sağ tarafta yer alan pasta grafiği ile görselleştirilmiştir. Bu grafik, modelin hangi duyguları tanıyıp analiz edebileceğini detaylıca göstermektedir. Sonuç olarak kullanıcının fotoğrafındaki duygu durumu model tarafından analiz edilerek ilgili duygusal sonuçlar kullanıcıya sunulur.



**Resim 4.** Örnek Duygu İçin Müzik Önerisi

Resim-4'te, kullanıcılar için hazırlanan frontend'in ana sayfası gösterilmektedir. Bu ana sayfa, kullanıcının yüz ifadesine göre dinamik olarak şekillenen benzersiz bir yapıya sahiptir. Görüntüde de belirtildiği üzere, bu aşamada “Doğal (Neutral)” yüz ifadesiyle karşımıza çıkan bir ana sayfa oluşmaktadır. Bu sayfa, kullanıcının o anki yüz ifadesine en uygun şarkı önerilerini sunmaktadır.

Sağ üstteki “Müzik Öner” sekmesine tıklamak, kullanıcının yüz ifadelerini yeniden analiz edecek ve kullanıcı için en iyi müzik önerilerini içeren yeni bir sayfa yükleyecektir. Bu dinamik yapı, kullanıcının duygu durumuna göre kullanıcıya en iyi müziği anında önererek kullanıcı deneyimini zenginleştirmektedir. Kısacası platform, tamamen kullanıcının duygusal durumuna göre şekillenen kişiselleştirilmiş bir müzik deneyimi sunmaktadır.



**Resim 5.** Manuel Duygu Önerimi

Resim-5'te gösterilen ekranda, sitemizin otomatik yüz analizi ile müzik önerme özelliğinin yanı sıra manuel bir müzik öneri sistemi de bulunmaktadır. Bu manuel sistem sayesinde kullanıcılar, yüzlerini analiz ettirmeden doğrudan istedikleri duygu ikonuna (emojiye) tıklayarak o duyguya özgü müzik önerilerine yönlendirebilmektedir. Örneğin, mutlu bir anınızı kutla-



mak isterseniz, mutluluk emoji üzerine tıklamanız yeterli olacaktır. Bu, kullanıcılara hem otomatik hem de kişisel seçim imkanı tanıyarak kullanıcı deneyimini daha da zenginleştirmektedir. Amacımız, kullanıcılarımızın platformumuzda geçirdikleri her anın yüksek kaliteli, kişisel ve unutulmaz olmasını sağlamaktır.



*Resim 6. Duygu Analizi İçin Görüntü Alımı (URL 2)*


Resim-6, kullanıcılara kamerayla doğrudan bağlantı kurma olanağı sunan dinamik bir arayüze sahiptir. Bu arayüz, kullanıcıların manuel seçimlerinin ötesinde, gerçek zamanlı duygusal analizle müzik önerileri almasına olanak tanır. Kırmızı simgeye tıklanarak açılan pencere, kameranıza erişim talep eder. Erişim izni verildiğinde, yüzünüz derin öğrenme modeli tarafından analiz edilir ve bu analiz sonucunda belirlenen duygusal durumunuza uygun müzik önerileri sunulur. Bu interaktif özellik, kullanıcılara anında ve otomatik bir müzik öneri deneyimi sunarak, duygusal hallerine göre en uygun şarkıları keşfetmelerini sağlar. Amacımız, müzik dinleme deneyiminizi kişiselleştirmek ve her sesle duygusal bir bağ oluşturmaktır.




**Resim 7.** Duygu Analizi İçin Görüntü Analiz Etmesi (URL 2)

Resim-7, kullanıcıların kamerayla yüzlerini tanıtarak fotoğraf çekip analize gönderdikleri ana ekranı tasvir etmektedir. Bu adım, dinamik bir yüz tanıma sürecinin başlangıcıdır. Kullanıcının yüz ifadesi net ve anlaşılır olmalıdır; zira bu, analizin doğruluğu için kritik bir öneme sahiptir. Kaliteli ve net bir fotoğraf, modelin yüz ifadenizi daha doğru bir şekilde analiz etmesini sağlar, bu da doğru duygusal durumun tespitine olanak tanır.

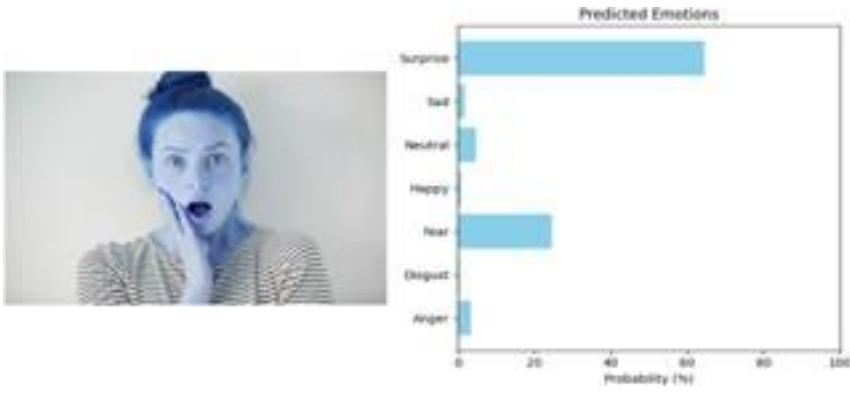
Yüz ifadesinin başarılı bir şekilde analiz edilmesi sonrasında, kullanıcı, anlık ruh haline en uygun müzik önerilerine yönlendirilir. Bu süreç, müzik seçiminde duygusal durumun ne kadar belirleyici olabileceğini vurgular. Dolayısıyla, Resim-7, kullanıcının ruh halini anlamak ve bu anlayışı kişiselleştirilmiş bir müzik deneyimine dönüştürmek için kritik bir adımdır. Örnek duygu analizleri Resim 8-14’de gösterilmiştir.



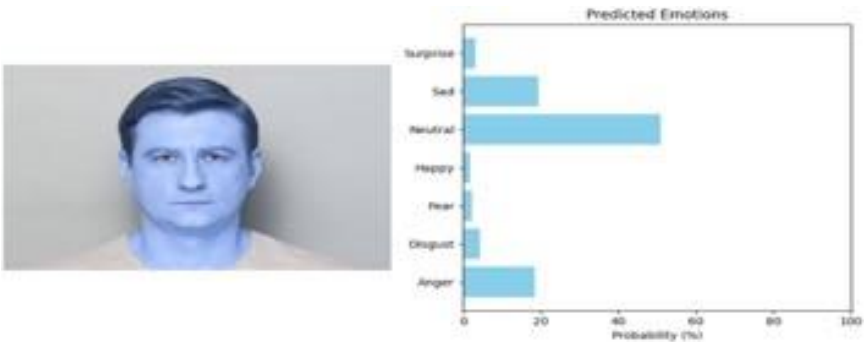
**Resim 8.** Örnek Sinirli Duygu Analizi (URL 3)



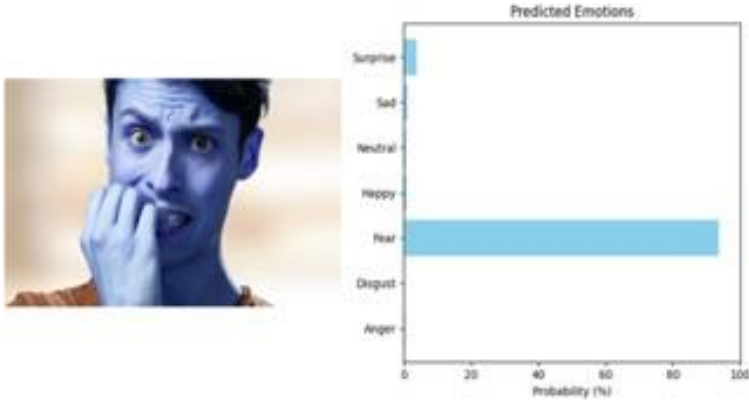
*Resim 9. Örnek Mutlu Duygu Analizi (URL 4)*



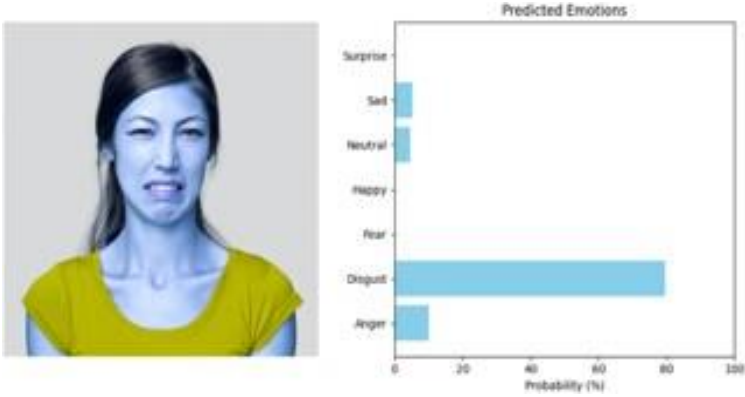
*Resim 10. Örnek Şaşkın Duygu Analizi (URL 5)*




*Resim 11. Örnek Notr Duygu Analizi (URL 6)*



*Resim 12. Örnek Korku Duygu Analizi (URL 7)*



*Resim 13. Örnek Tikslenme Duygu Analizi (URL 8)*



*Resim 14. Örnek Üzgün Duygu Analizi (Yık ve ark. 2013)*

Resim 8-14 de, modelimizin yüz ifadelerini analiz edip sonuçları görselleştirdiği örnekleri görebiliriz. Bu resimler, 7 farklı yüz ifadesi üzerinde modelimizin gerçekleştirdiği analizleri gözler önüne sermektedir. Bu yüz örnekleri, geniş bir duygusal ifade yelpazesini kapsamaktadır. Modelimizin bu yüzler üzerinde gerçekleştirdiği analizlerin sonuçları, onun karmaşık yüz ifadelerini ne derece başarılı bir şekilde sınıflandırabildiğini ortaya koymaktadır. İncelenen bu 7 örnekte, modelimiz her bir yüz ifadesini yüksek doğrulukla tanımlamıştır.

Bu görselleştirmeler, modelimizin sadece teorik testlerde değil, gerçek dünya örneklerinde de yüksek performans gösterebileceğini vurgulamaktadır. Bu örnekler, modelimizin çeşitli koşullar altında oldukça doğru sonuçlar verebileceğini göstermektedir. Bu başarılı sonuçlar, modelimizin duygu algılama uygulamaları için güçlü, etkili ve güvenilir bir araç olduğunu doğrulamaktadır. Bu uygulamada, verilen bir fotoğraftaki yüzü algılamak, işlemek ve modelle duygusal ifadeyi tahmin etmek için bir dizi adım gerçekleştirilir.

## **Veri Yükleme ve Ön İşleme**

Verilen bir fotoğraf ya bir dosya yolundan ya da doğrudan bir görüntü matrisi olarak alınır. Görüntü, RGB formatına dönüştürülerek renk kanallarına uyumlu hale getirilir.

OpenCV'nin Haar özellik tabanlı Face cascade sınıflandırıcısı kullanılarak fotoğraftaki yüz bölgesi tespit edilir. Bu algoritma, yüzün farklı boyutlarını ve pozisyonlarını hızlı bir şekilde tespit edebilir. Tespit edilen yüz bölgesi, modelin beklediği giriş boyutuna getirilmek üzere yeniden 48x48 piksel olarak boyutlandırılır.

Görüntü değerleri 0-1 arasına ölçeklenir, bu da modelin bu aralıkta veri beklediği anlamına gelir. Ön işlenmiş yüz görüntüsü, eğitilmiş modele gönderilir ve bu modele göre bir tahmin elde edilir. Bu tahmin, her bir duygu sınıfı için bir olasılık dağılımı olarak döner. Hem orijinal fotoğraf hem de modelin tahmin sonuçları, yan yana olacak şekilde görselleştirilir. Modelin tahminleri, yatay bir çubuk grafiğiyle gösterilir. Bu grafik, modelin her bir duygu sınıfı için ne kadar emin olduğunu yüzdelik değerlerle sunar.

Bu bölüm, yüz ifadelerinin değerlendirmelerine odaklanmaktadır. Burada, farklı yüz ifadelerinin başarılı tahmin oranları detaylı bir şekilde incelenmektedir. Ayrıca, hangi yüz ifadesinin daha stabil ve güvenilir sonuçlar verdiği konusunda kapsamlı bir değerlendirme yapılmıştır. ROC eğrisi (Receiver Operating Characteristic), özellikle ikili sınıflandırma modellerinin performansını değerlendirmede kritik bir öneme sahiptir. İkili sınıflandırmada, bir örneğin belirli bir sınıfa ait olup olmadığına karar verilme ye çalışılır. ROC eğrisi, bu kararın ne kadar doğru olduğunu gösteren bir metriktir (Parmigiani, 2020). Eğri, farklı sınıflandırma eşik değerlerinde gerçek pozitif oranını yanlış pozitif oranına karşı görselleştirir. Bu, modelin belirli bir eşik değerinde ne kadar hassas olduğunu gösterir. Özellikle modelin farklı eşik değerlerinde tepkisini öğrenmek için ROC eğrisi kullanılır. Eşik değeri, örneğin bir sınıfa ait olup olmadığına karar vermek için kullanılan değerdir. Bu görselleştirme modelin eşik değerlerinde performansını ölçmeye yardımcı olur. ROC eğrisi, aynı zamanda bir modelin eşik değerini değiştirerek ne kadar değişken olduğunu ve farklı durumlara ne kadar iyi adapte olabileceğini gösterir. Gerçek pozitif oran (true positive rate, tpr ya da duyarlılık)

$$TPR = \frac{TP}{TP + FN}$$

Bu, gerçekte pozitif olan örneklerin ne kadarının doğru bir şekilde pozitif olarak sınıflandırıldığını gösterir. Yanlış pozitif oran (false positive rate, fpr ya da 1- özgüllük)

$$FPR = \frac{FP}{(FP + TN)}$$

Bu, gerçekte negatif olan örneklerin ne kadarının yanlışlıkla pozitif olarak sınıflandırıldığını gösterir.

### ROC eğrisinin yorumlanması


Eğer ROC eğrisi sol üst köşeye yakınsa veya bu köşeyi geçiyorsa, modelin yüksek performans sergilediği kabul edilir. Eğri, 45 derecelik çizginin (rastgele tahmin çizgisi) altında ise modelin performansı rastgele tahmin yapmaktan daha kötüdür. Eğri sol üst köşeye yaklaştıkça model performansı artar. ROC eğrisinin altında kalan alan modelin performansını özetleyen bir değerdir. AUC değeri 1'e yaklaştıkça model gerçeğe yakın bir

performans sergilediği anlamına gelir.

Tablo-2 Değerlendirme

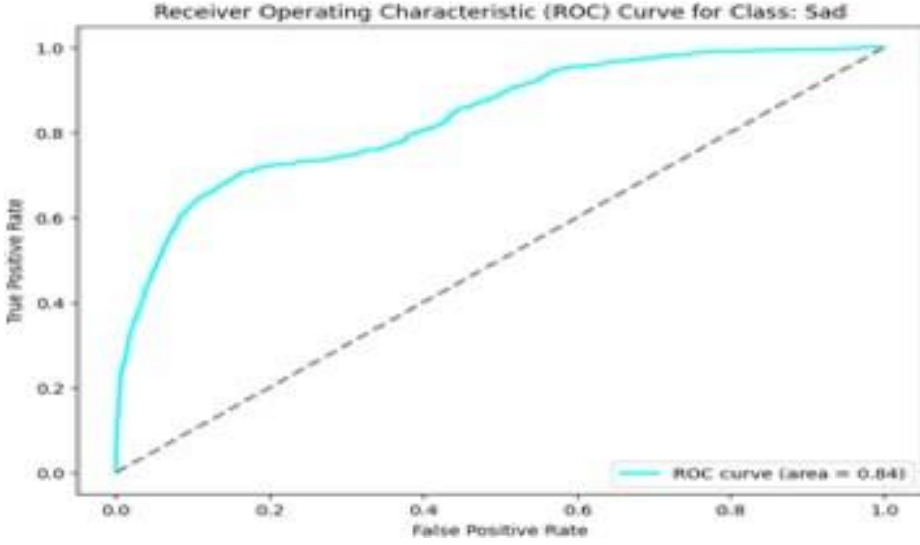
TP	Doğru Pozitif
TN	Doğru Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif

AUC, ROC eğrisinin altında kalan alandır. Sınıflandırma modelinin performansını özetleyen bir değer olarak kullanılabilir. AUC değeri 1'e yaklaştıkça, modelin performansı artar. Özellikle, AUC değeri 1'e eşitse model gerçeğe çok yakın bir sınıflandırma yapar. 0.5 ise, model gerçek olmayan tahminler yapar. ROC ve AUC modelin sınıflandırma yeteneğini değerlendirmek için oldukça kullanışlı bir yöntemdir. Özellikle dengesiz veri setlerinde, doğruluk yerine ROC ve AUC daha iyi bir performans ölçütü olabilir.



**Resim 15.** ROC Eğrisi Temelli Şaşkınlık Duygusu Performans Analizi

Resim 15'te, "Surprise" (Şaşkınlık) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin "Surprise" yüz ifadesini tanıma kabiliyetini değerlendirmek için kullanılmaktadır. ROC değerinin 0,96 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından son derece başarılı bir şekilde tanındığını göstermektedir.



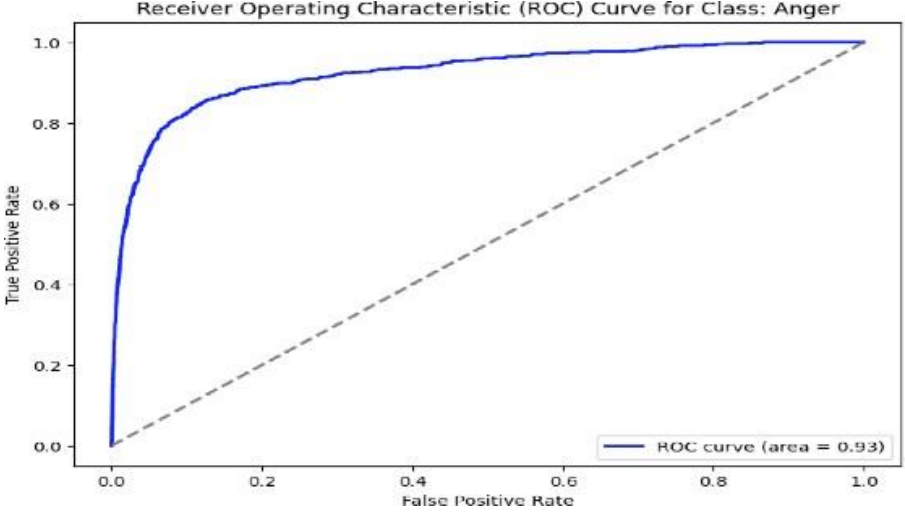
**Resim 16.** ROC Eğrisi Temelli Üzgün Duygu Performans Analizi

Resim 16’da ise “Sad” (Üzgün) yüz ifadesine ait ROC eğrisi sunulmaktadır. Bu eğri, modelin “Sad” yüz ifadesini ne kadar iyi tanıdığını değerlendirmek amacıyla hazırlanmıştır. ROC değerinin 0,84 olması, modelin “Sad” yüz ifadesini de oldukça başarılı bir şekilde tanıdığını belirtmektedir, fakat “Surprise” ifadesine göre biraz daha düşük bir başarıya sahiptir.

Genellikle, ROC değeri 1’e yakın olduğunda, sınıflandırma modelinin mükemmel bir performans sergilediği kabul edilir. Bu bağlamda, “Surprise” için 0,96 ve “Sad” için 0,84 değerleri, modelimizin her iki yüz ifadesini de oldukça hassas ve doğru bir şekilde tanıdığını belirtmektedir. Bu, modelin bu yüz ifadeleri için yüksek bir doğrulukla tahminlerde bulunduğunu ve bu ifadeler üzerindeki potansiyel yanıltıcı faktörlerin minimal olduğunu gösterir.

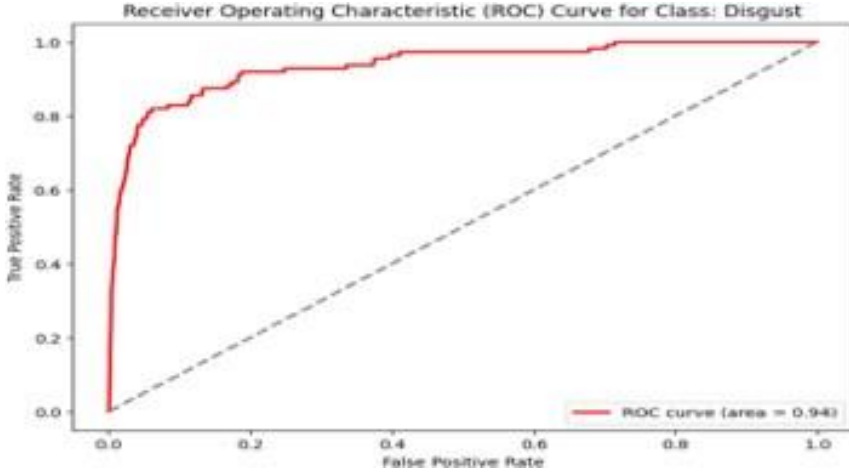
Her iki ROC eğrisinin şekline bakıldığında da modelde overfitting gibi problemlerin olmadığı gözlemlenmektedir. Bu, modelin genelizasyon yeteneğinin güçlü olduğunu ve farklı veri setleri üzerinde de benzer bir performans sergileyebileceğini gösterir.





**Resim 17. ROC Eğrisi Temelli Sınırlı Duygu Performans Analizi**

Resim 17’te, “Anger” (Öfhe) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin “Anger” yüz ifadesini tanıma kabiliyetini değerlendirmek için hazırlanmıştır. ROC değerinin 0,93 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından yüksek bir başarı ile tanındığını göstermektedir. “Anger” ifadesinin bu kadar yüksek bir ROC değerine sahip olması, modelin bu ifadeye karşı oldukça hassas ve doğru tahminlerde bulunduğunu belirtir. Bu da modelimizin öfhe gibi güçlü bir duygusal tepkiyi etkili bir şekilde tanıyabileceğini işaret eder.

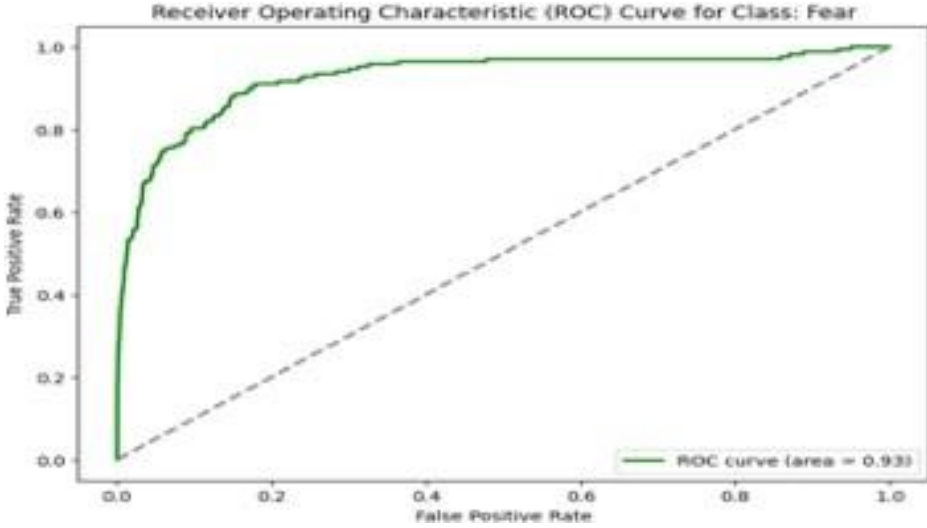


*Resim 18. ROC Eğrisi Temelli Tiksinti Duygusu Performans Analizi*

Resim 18’te ise, “Disgust” (Tiksinti) yüz ifadesine ait ROC eğrisi sunulmaktadır. Bu eğri, modelin “Disgust” yüz ifadesini tanıma yeteneğini derinlemesine değerlendirmek amacıyla oluşturulmuştur. ROC değerinin 0,94 olması, modelin “Disgust” yüz ifadesini neredeyse mükemmel bir başarıyla tanıdığını gösterir. Bu değer, modelin tiksinti gibi spesifik ve bazen diğer ifadelerle karıştırılabilen bir yüz ifadesini bile yüksek bir doğrulukla ayırt edebildiğini belirtir.


Her iki yüz ifadesi için de ROC değerlerinin 1’e yakın olması, sınıflandırma modelinin mükemmel bir performans sergilediğini gösterir. Bu bağlamda, “Anger” için 0,93 ve “Disgust” için 0,94 değerleri, modelimizin bu ifadeleri son derece hassas ve doğru bir şekilde tanıdığını belirtir. Ayrıca, bu yüksek ROC değerleri, modelin bu yüz ifadeleri üzerindeki potansiyel yanıltıcı etkenlerin etkisini minimumda tuttuğunu gösterir.

Her iki ROC eğrisinin şekillerine bakıldığında da, modelde aşırı uyum veya yetersiz uyum gibi olası problemlerin olmadığı görülmektedir. Bu, modelin genelleme yeteneğinin oldukça yüksek olduğunu ve farklı veri setleri üzerinde de benzer bir performans sergileyebileceğini gösterir.




**Resim 19.** ROC Eğrisi Temelli Korku Duygusu Performans Analizi

Resim 19’da “Fear” (Korku) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin “Fear” yüz ifadesini tanıma kabiliyetini değerlendirmek için kullanılmaktadır. ROC değerinin 0,93 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından yüksek bir başarı ile tanındığını göstermektedir. Korku gibi belirgin bir duygusal tepkinin bu kadar yüksek bir ROC değerine sahip olması, modelin bu ifadeyi etkili bir şekilde ayırt edebildiğini belirtir.



*Resim 20. ROC Eğrisi Temelli Mutluluk Duygusu Performans Analizi*

Resim 20’de, “Happy” (Mutlu) yüz ifadesine ait ROC eğrisi yer almaktadır. Bu eğri, modelin “Happy” yüz ifadesini tanıma kabiliyetini gösterir. ROC değerinin 0,97 olarak belirlenmiş olması, modelin bu yüz ifadesini son derece başarılı bir şekilde tanıdığını belirtmektedir. Mutlu bir ifadenin bu kadar yüksek bir ROC değerine sahip olması, modelin bu ifadeye karşı oldukça hassas ve doğru tahminlerde bulunduğunu belirtir.



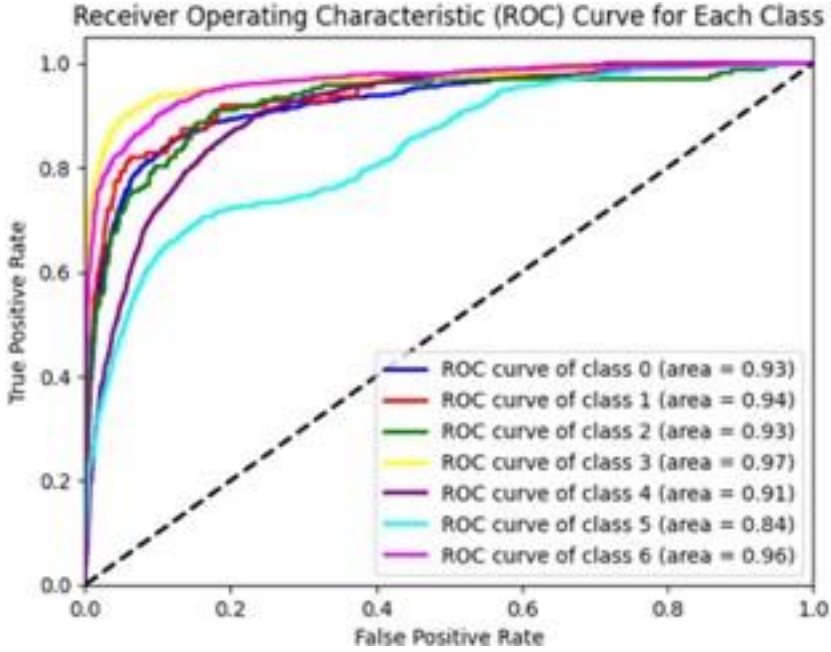
**Resim 21.** ROC Eğrisi Temelli Nötr Duygu Performans Analizi

Resim 21’de ise, “Neutral” (Nötr) yüz ifadesine ait ROC eğrisi sunulmaktadır. Bu eğri, modelin “Neutral” yüz ifadesini tanıma yeteneğini derinlemesine değerlendirmek amacıyla oluşturulmuştur. ROC değerinin 0,91 olması, modelin “Neutral” yüz ifadesini oldukça başarılı bir şekilde tanıdığını gösterir. Nötr bir ifadenin bazen diğer ifadelerle karıştırılabilen bir yüz ifadesi olmasına rağmen, modelin bu ifadeyi yüksek bir doğrulukla ayırt edebildiğini göstermektedir. Bu üç yüz ifadesi için belirlenen ROC değerlerinin 1’e yakın olması, sınıflandırma modelinin son derece başarılı bir performans sergilediğini gösterir. Bu bağlamda, modelimizin bu ifadeleri oldukça hassas ve doğru bir şekilde tanıdığı sonucuna varabiliriz. Ayrıca, bu yüksek ROC değerleri, modelin bu yüz ifadeleri üzerindeki potansiyel yanıltıcı etkenlerin etkisini minimumda tuttuğunu gösterir.

Resim 22’deki grafik aslında, sınıflandırma modelimizin yüz ifadelerini ne kadar iyi anladığını gösteren bir araç. Bu grafik, modelin farklı duygusal durumları ne kadar doğru bir şekilde tanıdığını yansıtıyor, yani insanların ifadelerinden ne kadar iyi anladığını. Aynı zamanda, modelin doğru anlamadığı durumları da gösteriyor. Bu eğri, modelin, her bir yüz ifadesi için ne kadar hassas (doğru pozitif oran) ve ne kadar özgül (yanlış pozitif oran) olduğunu ayrı ayrı gösterir. ROC eğrisinin bu genel sunumu, modelin farklı duygusal tepkilere nasıl tepki verdiğini, hangi yüz ifadelerinde daha ba-

şarılı olduğunu ve hangi yüz ifadelerinde daha fazla iyileştirme gerektiğini anlamamıza yardımcı olur.

Aynı zamanda, bu eğri modelimizin genel doğruluğunu değerlendirmemiz konusunda yardım eder. Özellikle eğrinin yükseklikleri modelin belirli yüz ifadelerini tanıma konusundaki hassasiyetini gösterir.



**Resim 22.** Yüz ifadelerinin sınıflandırılması için ROC eğrisi analizi

ROC eğrisi, sadece modelin performansını değerlendirmekle kalmaz, aynı zamanda modelin eğitim aşamasında hangi duygusal durumların daha zorlandığını veya hangi durumların daha kolay öğrenildiğini de belirlememize yardımcı olabilir. Modeli optimize etme ve iyileştirme sürecinde kritik bir öneme sahiptir.

ROC eğrisi analizi ile modelimizin farklı yüz ifadelerini tanıma kabiliyeti değerlendirilmiştir. Bu değerlendirme modelimizin genel performansının yanı sıra belirli yüz ifadeleri üzerindeki başarısını göstermektedir. Yüksek ROC değerleri, modelimizin bu yüz ifadelerini doğru bir şekilde tanıdığı-

nı göstermektedir. Bu sonuçlar, modelimizin duygusal güvenilir bir araç olduğunu doğrulamaktadır. Bu analizin ardından, modelimizin performansını daha da derinlemesine incelemek için Confusion Matrix metodunu kullanılacaktır. Bu metod modelimizin sınıflandırma tahminlerinin doğruluğunu gösterecektir.

### **Karışıklık matrisi (CM) ve sınıflandırma performansının derinlemesine incelenmesi**

Karışıklık Matrisi, özellikle sınıflandırma görevlerinde, istatistiksel analizin ve makine öğreniminin kritik bir bileşenidir. Bu matris, bir sınıflandırma modelinin performansını nicel bir şekilde analiz etmek ve vizüalize etmek için hayati bir araçtır. Matris, model tarafından yapılan tahminler ile gerçekte olan sınıfların karşılaştırmasını sunarak, modelin doğru ve yanlış tahminlerini net bir şekilde ortaya koyar. (Wu ve MT , 2022)

Karışıklık Matrisi, temel olarak dört ana bileşenden oluşur:

**True Positive (TP):** Modelin doğru bir şekilde pozitif olarak sınıflandırdığı örnek sayısıdır. Bu, modelin doğru bir şekilde tespit ettiği ilgili sınıf örnekleridir.

**True Negative (TN):** Modelin doğru bir şekilde negatif olarak sınıflandırdığı örnek sayısıdır. Bu, modelin doğru bir şekilde reddettiği diğer sınıf örnekleridir.

**False positive (fp):** Gerçekte negatif olmasına rağmen modelin yanlışlıkla pozitif olarak sınıflandırdığı örnek sayısıdır. Bu, tip I hata olarak da adlandırılır.

**False negative (fn):** Gerçekte pozitif olmasına rağmen modelin yanlışlıkla negatif olarak sınıflandırdığı örnek sayısıdır. Bu, tip II hata olarak da adlandırılır.

Bu temel bileşenler kullanılarak, modelin performansını özetleyen bir dizi metrik hesaplanabilir (Görtler ve ark. ,2022):

Doğruluk (accuracy): Toplam tahminler arasında doğru yapılan tahminlerin oranıdır.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Hassasiyet (precision): Pozitif olarak tahmin edilen örnekler içerisinde gerçekten pozitif olanların oranıdır.

$$Precision = \frac{TP}{TP + FP}$$

Duyarlılık (recall ya da true positive rate): Gerçekte pozitif olan örnekler içerisinde doğru bir şekilde pozitif olarak tahmin edilenlerin oranıdır.

$$Recall = \frac{TP}{TP + FN}$$

F1 skoru: Hassasiyet ve Duyarlılığın harmonik ortalaması olarak tanımlanır ve dengesiz veri setlerinde modelin genel performansını değerlendirmede özellikle faydalıdır.

$$F1 = 2 \times \left( \frac{Precision \times Recall}{Precision + Recall} \right)$$

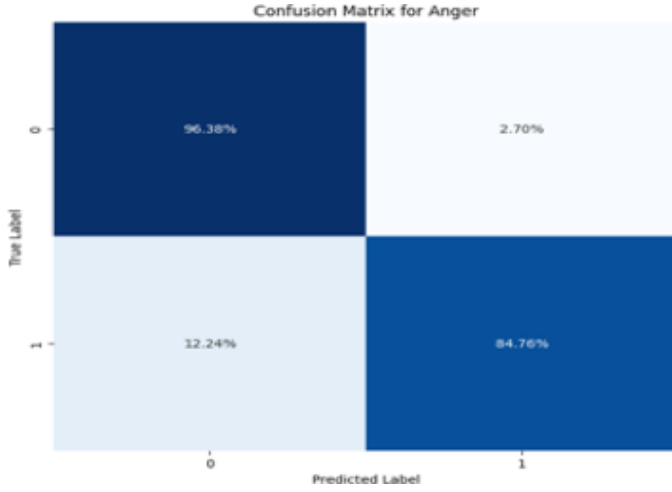
Karışıklık Matrisi'nin analizinde bu metriklerin tümünü dikkate almak, modelin gerçek dünya verileri üzerindeki performansını daha derinlemesine anlamamıza olanak tanır. Özellikle, dengesiz veri setlerinde, sadece doğruluğun yüksek olmasına aldanmamak için bu metriklerin kombinasyonunu kullanmak esastır. Bu, bir sınıflandırma modelinin performansının gerçekten ne kadar iyi olduğunu değerlendirmede kritik bir adımdır.

### **Karışıklık Matrisi Analizi: “Anger” ve “Disgust” Duyguları**

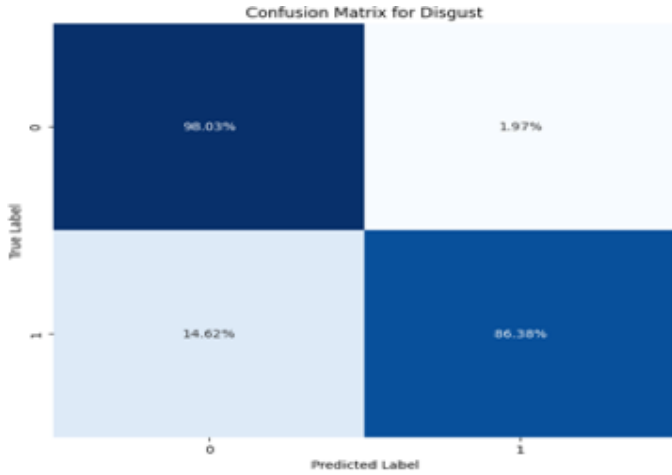
Karışıklık Matrisi, sınıflandırma modellerinin performansını derinlemesine incelemek için kullanılan kritik bir araçtır. Bu matris, modelin doğruluk ve duyarlılık gibi önemli metrikleri üzerinden ne kadar başarılı tahminlerde bulunduğunu gösterir. Bu bölümde, “Anger” (Öfke) ve “Disgust”



(Tiksinme) duyguları için modelin performansı incelenmektedir.



*Resim 23 Sinirli Duygu İçin CM Modeli*



*Resim 24 Tiksinme Duygusu İçin CM Modeli*

### Sinir Duygusu İçin Karışıklık Matrisi Değerlendirmesi

Tablo-3 Sinir duygusu Karışıklık Matrisi

True Positive (TP)	84.76%
True Negative (TN)	96.38%
False Positive (FP)	2.70%
False Negative (FN)	12.24%

### Tiksinti duygusu için karışıklık matrisi değerlendirme

Tablo-4 Tiksinti duygusu Karışıklık Matrisi

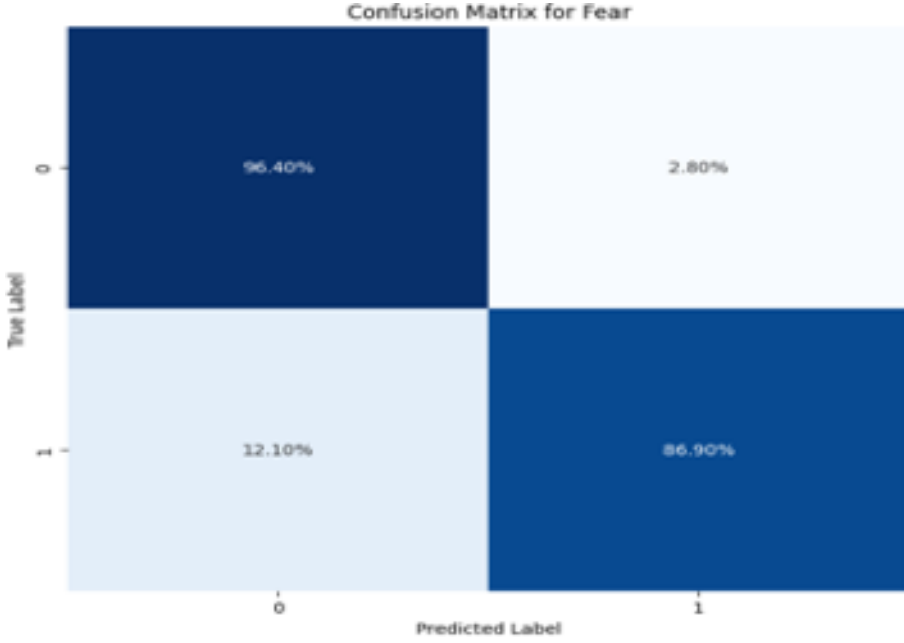
True Positive (TP)	86.38%
True Negative (TN)	98.03%
False Positive (FP)	1.97%
False Negative (FN)	14.62%

“Disgust” duygusu için modelin performansı, özellikle doğru negatif oranı (%98,03) ile dikkat çekicidir. Bu, modelin “Disgust” duygusu olmayan örnekleri mükemmel bir doğrulukla tespit edebildiğini gösterir. Bunun yanı sıra, doğru pozitif oranı (%86,38) da modelin “Disgust” duygusunu etkili bir şekilde tanıyabildiğini göstermektedir.

Her iki duygu için de modelin performansı oldukça etkileyicidir. Özellikle doğru negatif tahminlerdeki yüksek doğruluk oranları, modelin duyguları tespit edebilme kabiliyetini göstermektedir. Bu sonuçlar, modelin duygusal analizde yüksek bir güvenilirlikle çalışabileceğini ve gerçek dünya uygulamalarında etkili sonuçlar üretebileceğini ortaya koymaktadır. Modelin bu başarısı, doğru veri hazırlığı ve etkili bir model mimarisi ile birleşerek, duygu tanıma alanında etkileyici sonuçlara ulaşmasını sağlamıştır.

### Karışıklık Matrisi Analizi: “Fear” ve “Happy” Duyguları

Karışıklık Matrisi, bir sınıflandırma modelinin performansını değerlendirme konusunda oldukça önemli bir araçtır. Bu matris, sadece modelin doğruluk oranını değil, aynı zamanda modelin hangi sınıflarda ne kadar başarılı veya başarısız olduğunu da gösterir. Bu kısımda Fear (Korku) ve Happy (Mutlu) duyguları için modelin performansı incelenmektedir.




*Resim 25 Korku Duygusu İçin CM Modeli*

### Korku Duygusu için Karışıklık Matrisi Değerlendirmesi

Tablo-5 Korku duygusu Karışıklık Matrisi

True Positive (TP)	86.90%
True Negative (TN)	96.40%
False Positive (FP)	2.80%
False Negative (FN)	12.10%

Bu değerlere göre, modelin korku duygusunu tespit kabiliyeti oldukça yüksektir. Özellikle doğru negatif oranı (%96,40) ile modelin Fear duygusu olmayan örnekleri tespit edebilmesi etkileyicidir ve doğru pozitif oranı (%86,90) ile modelin Fear duygusunun iyi bir şekilde gördüğünü ifade edebiliriz.



Resim 26 Mutluluk Duygusu İçin CM Modeli

### Mutluluk Duygusu İçin Karışıklık Matrisi Değerlendirmesi

Tablo-6 Mutluluk duygusu Karışıklık Matrisi

True Positive (TP)	89.72%
True Negative (TN)	97.92%
False Positive (FP)	2.08%
False Negative (FN)	9.28%

“Mutluluk” duygusu için modelin performansı, özellikle doğru negatif oranı (%97,92) ile dikkat çekicidir. Bu, modelin “Mutluluk” duygusu olmayan örnekleri mükemmel bir doğrulukla tespit edebildiğini gösterir. Bunun yanı sıra, doğru pozitif oranı (%89,72) da modelin “Mutluluk” duygusunu etkili bir şekilde tanıyabildiğini göstermektedir.


### Değerlendirme

Hem “Korku” hem de “Mutluluk” duyguları için modelin performansı oldukça etkileyicidir. Özellikle doğru negatif tahminlerdeki yüksek doğru-

luk oranları, modelin duyguları tespit edebilme kabiliyetini gösterir. Bu sonuçlar, modelin duygu tanımda yüksek bir güvenilirlikle çalışabileceğini göstermektedir. Modelin bu başarısı, doğru veri hazırlığı, etkili bir model mimarisi ve optimize edilmiş hiper parametrelerin birleşimi ile elde edilmiştir. Sonuç olarak duygu tanıma konusunda derin öğrenmenin gücünü ve potansiyelini gözler önüne sermektedir.

### Karışıklık Matrisi Analizi: “Nötr”, “Üzgün” ve “Şaşkın” Duyguları

Karışıklık Matrisi, bir sınıflandırma modelinin ne kadar etkili olduğunu görsel ve sayısal bir temsilidir. Bu bölümde, “Neutral” (Nötr), “Sad” (Üzgün) ve “Surprise” (Şaşkın) duyguları için modelin performansını ayrıntılı olarak değerlendirilmiştir.




*Resim 27 Nötr Duygusu İçin CM Modeli*

## Nötr Duygusu için Karışıklık Matrisi Değerlendirmesi

**Tablo-7** Nötr duygusu Karışıklık Matrisi

True Positive (TP)	88.49%
True Negative (TN)	96.88%
False Positive (FP)	2.63%
False Negative (FN)	8.68%

Modelin “Nötr “ duygusu için performansı oldukça etkileyicidir. Özellikle doğru negatif oranı (%96,88) dikkat çekicidir. Ancak, yanlış pozitif oranı (%2,63) modelin bazı durumlarda nötr olmayan duyguları nötr olarak sınıflandırabileceğine işaret etmektedir. Bununla birlikte, doğru pozitif değeri (%88,49), modelin nötr duyguları oldukça başarılı bir şekilde tespit edebildiğini göstermektedir.



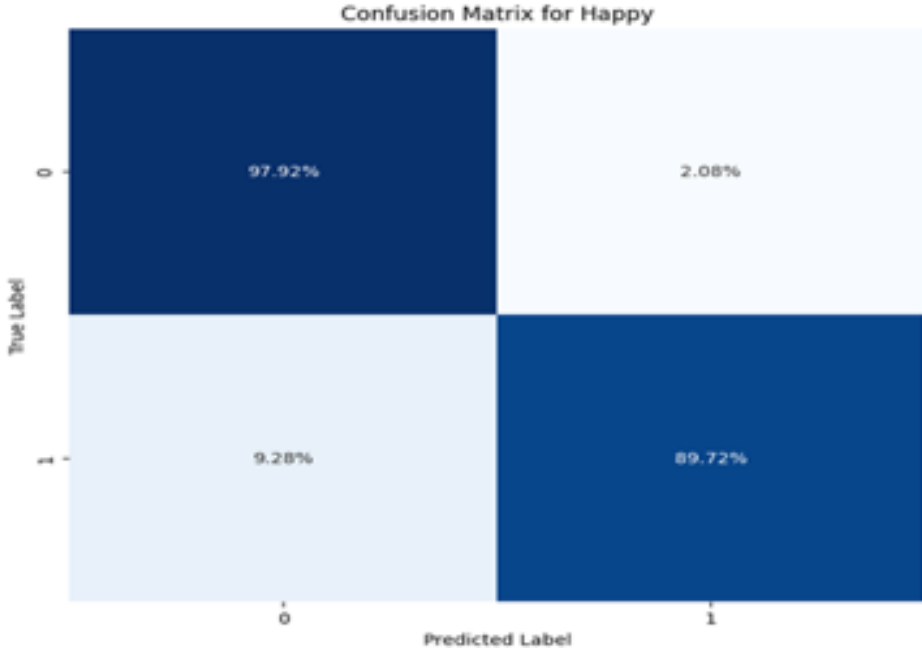
**Resim 28.** Üzgün Duygu İçin CM Modeli

## Üzgün Duygusu İçin Karışıklık Matrisi Değerlendirmesi

**Tablo-8** Üzgün duygusu Karışıklık Matrisi

True Positive (TP)	86.49%
True Negative (TN)	95.88%
False Positive (FP)	2.16%
False Negative (FN)	9.68%

“Üzgün” (Sad) duygusu için model, özellikle doğru negatif oranı (%95,88) ile mükemmel bir performans göstermektedir. Bu, modelin üzgün olmayan durumları tespit edebilmesi için oldukça güvenilir olduğunu gösterir. Doğru pozitif oranı (%86,49) da modelin “Üzgün” duygusunu yüksek bir doğrulukla tanıdığını göstermektedir.



**Resim 29.** Şaşkınlık Duygusu İçin CM Modeli

## Şaşkın Duygusu İçin Karışıklık Matrisi Değerlendirmesi

Tablo-9 Şaşkınlık duygusu Karışıklık Matrisi

True Positive (TP)	88.51%
True Negative (TN)	98.92%
False Positive (FP)	1.43%
False Negative (FN)	8.43%

“Surprise” (Şaşkın) duygusu için modelin performansı, doğru negatif oranıyla (%98,92) dikkat çekicidir. Bu, modelin şaşkın olmayan duyguları mükemmel bir doğrulukla tespit edebileceğini gösterir. Ayrıca, doğru pozitif oranı (%88,51) ile model, “Surprise” duygusunu etkili bir şekilde tanıyabilmektedir.

### Değerlendirme

Bu üç duygu için modelin genel performansı oldukça etkileyicidir. Özellikle doğru negatif tahminlerdeki yüksek doğruluk oranları, modelin duyguları tespit edebilme kabiliyetini göstermektedir. Modelin bu başarısı, doğru veri hazırlığı, etkili bir model mimarisi ve optimize edilmiş hiper parametrelerin birleşimiyle elde edilmiştir. Bu sonuçlar, duygu tanıma konusunda derin öğrenmenin gücünü ve potansiyelini bir kez daha gözler önüne sermektedir.

### Confusion Matrisi Sonuç

Karışıklık Matrisleri (Confusion Matrices) üzerinden yapılan analiz, sınıflandırma modellerinin performansını değerlendirmede kritik bir araçtır (Düntsche ve Gediga, 2019). Bu matrisler, bir modelin tahminlerinin gerçekte ne kadar doğru olduğunu görsel ve sayısal olarak ortaya koymaktadır. Ele aldığımız duygu sınıflarını karışıklık matrisleri üzerinden aşağıdaki genel çıkarımlar yapılabilir.

Genel Performans: Model, tüm duygu sınıfları için oldukça yüksek doğruluk oranlarına sahiptir. Bu, modelin veri setindeki duygusal ifadeleri etkili bir şekilde tanıdığını ve sınıflandırdığını göstermektedir.

Doğru Negatif (True Negative) Değerleri: Model, çoğu duygu sınıfı için



oldukça yüksek doğru negatif değerlere sahiptir. Bu, bir duygunun olmadığı durumları tespit edebilme kabiliyetinin yüksek olduğunu gösterir.

**Doğru Pozitif (True Positive) Değerleri:** Model, duygusal ifadeleri tanıma konusunda da başarılıdır. Özellikle “Happy”, “Sad” ve “Surprise” duyguları için yüksek doğruluk oranlarına sahip olması dikkat çekicidir.

**Yanlış Negatif (False Negative) ve Yanlış Pozitif (False Positive) Değerleri:** Bazı duygu sınıfları için yanlış negatif ve yanlış pozitif değerleri dikkate değerdir. Ancak, genel olarak bu değerler kabul edilebilir düzeydedir ve modelin genel performansını önemli ölçüde etkilememektedir.

**Denge:** Model, dengesiz veri setlerinde bile yüksek performans göstermektedir. Bu, modelin, çeşitli duygusal sınıflar arasında iyi bir denge kurabildiğini ve belirli bir duygu sınıfına önyargılı olmadığını göstermektedir. Sonuç olarak, bu karışıklık matrisleri, modelimizin duygu tanıma görevini başarıyla yerine getirdiğini ve yüksek doğruluk oranlarına sahip olduğunu göstermektedir. Model, çeşitli duygusal sınıflar arasında dengeyi sağlayarak etkili ve hassas tahminlerde bulunmaktadır. Bu başarılı sonuçlar, modelin gerçek dünya uygulamalarında da yüksek performanslı sonuçlar sunabileceğini işaret etmektedir. Bu nedenle modelimiz, duygu analizi uygulamaları için güçlü ve güvenilir bir araç olarak öne çıkmaktadır.

## **Tartışma**

Bu çalışma, Convolutional Neural Networks (CNN) tabanlı bir modelin yüz ifadeleri analizi aracılığıyla kullanıcıların duygusal durumlarını belirlemede ve bu bilgileri kullanarak kişiselleştirilmiş müzik önerileri sunmaktadır. Bu entegrasyon, teknoloji ve duygusal analizin birleşimine dair mevcut literatüre yeni bir boyut kazandırmaktadır.

## **Teknoloji ve Duygusal Analiz**

(De Prisco ve Roberto, 2020), (Ka ve ShanthaShalini, 2021) gibi çalışmalar, yüz ifadesi tanıma ve duygusal analiz teknolojisinin farklı alanlarda, özellikle güvenlik ve finansal piyasalar gibi, potansiyel taşıdığını göstermektedir. Fakat, bu çalışma literatüre, duygusal analizin kişiselleştirilmiş müzik öneri sistemlerinde nasıl bir rol oynayabileceğini eklemektedir.

## **Müzik Öneri Sistemleri ve Duygusal Analiz**

Çalışmalar, örneğin (Chirasmayee ve B. Venkata Sai ,2022), duygusal analizin müzikle birleştirilerek kullanıcı deneyimini nasıl iyileştirebileceğini incelemiştir. Ancak, bu çalışmada ele alınan model “Happy”, “Sad”, “Surprise” gibi çeşitli duygusal durumları etkili bir şekilde tanımakta ve bu bilgiyi kişiselleştirilmiş müzik önerileri sunmak için kullanmaktadır.

## **Algoritma Performansı ve Tanıma Doğruluğu**

Karışıklık Matrisi analizi ve literatüre göre, algoritmaların performansı ve doğruluğu her zaman eleştirel bir faktördür. Örneğin, (Siam ve ark., 2022) ve (Wang ve Perez, 2017) bu konuyu detaylı bir şekilde ele almışlardır. Ancak, kendi oluşturduğumuz model, dengesiz veri setlerinde bile yüksek performans göstererek ve önyargılı olmaksızın duygusal durumları tanıyarak, bu alandaki en iyi pratikleri yansıtmaktadır.

## **Kişiselleştirilmiş Müzik Öneri Sistemleri**

(Sashank ve ark., 2022) gibi çalışmalar, kişiselleştirilmiş müzik öneri sistemlerinin popülerleşmesinde kritik bir rol oynamaktadır. Ancak, kendi modelimiz bu potansiyeli en iyi şekilde kullanmaktadır; çünkü bu model, gerçek dünya uygulamalarında yüksek güvenilirlik ve doğruluk göstermektedir.

Yüz ifadesi ve duygusal analiz teknolojisinin, kişiselleştirilmiş müzik öneri sistemlerinin geliştirilmesinde nasıl kritik bir rol oynayabileceğini göstermektedir. Özellikle, kendi oluşturduğumuz modelin yüksek performansı ve güvenilirliği, bu alandaki gelecekteki araştırmalara ve uygulamalara yön veren bir temel oluşturmaktadır.

## **Sonuç**

Müzik, bireylerin duygusal, kültürel ve sosyal ifadesinin aracısı olmuştur. Müziğin insan psikolojisi üzerindeki derin etkisi onun küresel bir özellik olması haline gelmesini sağlamıştır. Her bir notada melodide veya ritimde yatan duygular, bizi farklı duygusal serüvenlere sürebilir. Bu çalışma, müziğin yapay zekâ ile nasıl daha da güçlü insanların duygularına göre nasıl daha iyi bir aracı olabileceği hakkındadır.

Derin öğrenme teknolojilerinin, özellikle CNN algoritmalarını fotoğrafları tanıma ve sınıflandırma konularında gösterdiği başarı duyguların tespiti için isabetli bir araç olmasını sağlamıştır. Ancak bu çalışmadaki yenilik bireylerin günlük yaşamlarına nasıl entegre edilebileceğidir. Yani bir kişinin yüzündeki birkaç çizgi veya ifadeyi tanımlamanın yanında bu bilgiyi kişisel bir müzik zevki oluşturmak için iyi bir araç olduğunu görmekteyiz.

Bunu gerçekleştirmek için büyük bir veri seti ile eğitim almış bir model oluşturuldu. Bu model duygusal durumu tahmin etmek için CNN kullanılmıştır. Kullanılan Modelin başarısını ölçerken sadece doğruluk oranıyla değil aynı zamanda gerçek insanların duygusal ifadelerini de doğru bir şekilde tespit edebildiğini bize göstermiştir.

Müzik öneri sistemimiz, duygusal durumu belirlenen kullanıcılar için akustik özellikleri ve semantik meta verileri temel alarak en uygun müzikal parçaları seçmektedir. Eğer bir kullanıcı pozitif bir duygusal durumda ise, sistem yüksek tempo ve majör tonalitesi gibi özelliklere sahip enerjik müzikler önerecektir. Öte yandan, eğer bir kullanıcı negatif bir duygusal durumda ise, daha düşük tempo ve minör tonalitesi gibi özelliklere sahip hüzünlü müzikler önerilmektedir.

Son olarak bu çalışma, teknolojinin insan deneyiminin daha kişisel bir yönüyle etkileşimde bulunma potansiyelini göstermektedir. Önümüzdeki yıllarda, duygusal durum tabanlı öneri sistemlerinin insanların günlük yaşamlarını daha da zenginleştirecek şekillere geleceğini görmek oldukça heyecan verici olacaktır.

## Kaynaklar

1. De Prisco, R., et al. (2022). Induced Emotion-Based Music Recommendation through Reinforcement Learning. *Applied Sciences*, 12(21), 11209.
2. Martínez, J., & Vega, J. (2022). ROS System Facial Emotion Detection Using Machine Learning for a Low-Cost Robot Based on Raspberry Pi. *Electronics*, 12(1), 90.
3. He, J. (2022). Algorithm Composition and Emotion Recognition Based on Machine Learning. *Computational Intelligence and Neuroscience*.

4. Ka, S., et al. (2021). Facial Emotion Based Music Recommendation System Using Computer Vision and Machine Learning Techniques. *Turkish Journal of Computer and Mathematics Education*, 12(1), 912-917.
5. Koukaras, P., Nousi, C., & Tjortjis, C. (2022). Stock Market Prediction Using Microblogging Sentiment Analysis and Machine Learning. *Telecom*, 3(2). MDPI.
6. Rosa, R. L., Rodriguez, D. Z., & Bressan, G. (2015). Music Recommendation System Based on User's Sentiments Extracted from Social Networks. *IEEE Transactions on Consumer Electronics*, 61(3), 359-367.
7. Sashank, M. S. K., et al. (2022). Mood-Based Music Recommendation System Using Facial Expression Recognition and Text Sentiment Analysis. *Journal of Theoretical and Applied Information Technology*, 100(19).
8. Chirasmayee, B. V. S., et al. (2022). Song Recommendation System Using TF-IDF Vectorization and Sentimental Analysis.
9. Mehta, R., & Gupta, S. (2021). Movie Recommendation Systems Using Sentiment Analysis and Cosine Similarity. *International Journal of Modern Trends in Science and Technology*, 7(01), 16-22.
10. Düzbastılar, M. E., & Eyüpoğlu, G. (2019). Müzik Öğretmenlerinin Özel Eğitime İhtiyacı Olan Öğrencilerin Müzik Öğretimine İlişkin Tutumlarının İncelenmesi. *International Journal of Social Sciences and Education Research*, 5(4), 384-404.
11. Aydoğan, M., & Şener, A. (2020). Duygu Analizi Tabanlı Yeni Bir Hibrit Tavsiyeci Sistem. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 7(13), 48-62.
12. Gündüz, İ., & YILMAZ, Ö. (2021). Yüz İfadesini Algılayarak Kullanıcının Ruh Haline Göre İçerik Öneren Mobil Uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, 28, 192-197.
13. Yi, S., & Liu, X. (2020). Machine Learning Based Customer Sentiment

- Analysis for Recommending Shoppers, Shops Based on Customers' Review. *Complex & Intelligent Systems*, 6(3), 621-634.
14. Siam, A. I., et al. (2022). Deploying Machine Learning Techniques for Human Emotion Detection. *Computational Intelligence and Neuroscience*.
15. Wang, J., & Perez, L. (2017). The Effectiveness of Data Augmentation in Image Classification Using Deep Learning.
16. Parmigiani, G. (2020). Receiver Operating Characteristic Curves with an Indeterminacy Zone. *Pattern Recognition Letters*, 136, 94-100.
17. Qiu, H., & Jia, X. (2022). Western Music History Recommendation System Based on Internet-of-Things Data Analysis Technology. *Mobile Information Systems*, 2022, 8920599.
18. Shorten, C., & Khoshgoftaar, T.M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60.
19. Masud, M. (2022). A light-weight convolutional Neural Network Architecture for classification of COVID-19 chest X-Ray images. *Multimedia Systems*, 28(4), 1165–1174.
20. Nan, Y., Ju, J., Hua, Q., Zhan[g, H., & Wang, B. (2022). A-MobileNet: An approach of facial expression recognition. *Alexandria Engineering Journal*, 61(6), 4435-4444.
21. Reyad, M., Sarhan, A., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing & Applications*, 35, 17095–17112.
22. Düntsch, I., & Gediga, G. (2019). Confusion matrices and rough set data analysis. In *Proceedings of the 2019 International Conference on Pattern Recognition and Intelligent Systems (PRIS 2019)*.
23. Wu, M.T. (2022). Confusion matrix and minimum cross-entropy metrics based motion recognition system in the classroom. *Scientific Reports*, 12, 3095.

24. Görtler, J., Hohman, F., Moritz, D., Wongsuphasawat, K., Ren, D., Nair, R., Kirchner, M., & Patel, K. (2022). Neo: Generalizing Confusion Matrix Visualization to Hierarchical and Multi-Output Labels. In CHI '22: Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems (Article No. 408, pp. 1-13).

25. Yik, M., Widen, S., & Russell, J. (2013). The within-subjects design in the study of facial expressions. *Cognition & Emotion*, 27.

### **İnternet Kaynakları**

1. URL 1 <https://paperswithcode.com/dataset/fer2013>
2. URL 2 <https://www.freepik.com/photos/man-video-call>
3. URL 3 <https://khoahoc.tv/phat-hien-loi-ich-khong-ngo-cua-su-tuc-gi-an-55770>
4. URL 4 <https://ar.europeanwriterstour.com/images-2023/happy-face-expression>
5. URL5 [https://www.freepik.com/free-photo/portrait-young-red-haired-woman\\_10323101.htm#query=10323101&position=0&from\\_view=search](https://www.freepik.com/free-photo/portrait-young-red-haired-woman_10323101.htm#query=10323101&position=0&from_view=search)
6. URL 6 <https://stock.adobe.com/tr/search/images?k=neutral+faces>
7. URL7 Anxious people are more successful in escaping from virtual predators, study finds
8. URL8 <https://www.istockphoto.com/tr/foto%C4%9Fraf/young-woman-making-a-frightened-face-expression-gm174756630-21662121>