

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



MAKİNE ÖĞRENME ALGORİTMALARINI KULLANAN
DUYGU TAHMİNİNE DAYALI MÜZİK ÖNERİ SİSTEMİ

YÜKSEK LİSANS TEZİ

Hasan ALIYEV

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

OCAK, 2024

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



MAKİNE ÖĞRENME ALGORİTMALARINI KULLANAN
DUYGU TAHMİNİNE DAYALI MÜZİK ÖNERİ SİSTEMİ

YÜKSEK LİSANS TEZİ

Hasan ALIYEV
(Y2213.010033)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ali GÜNEŞ

OCAK, 2024

ONAY FORMU

ONUR SÖZÜ

Yüksek lisans tezi olarak sunduğum " Makine öğrenme algoritmalarını kullanan duygu tahminine dayalı müzik öneri sistemi" adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça 'da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (.././2024)

Hasan ALIYEV

ÖNSÖZ

Bu tez çalışmasındaki rehberliği ve destekleri ile eğitimime olan katkılarından ötürü danışman hocam Prof. Dr. Ali GÜNEŞ 'e teşekkür etmek istiyorum. Bu tezin hazırlanması boyunca yaptıkları çok değerli yorum ve geri bildirimler için Dr. Öğr. Üyesi Peri GÜNEŞ'e ve Dr. Öğr. Üyesi Selcuk şener'e teşekkür etmek istiyorum. Tez çalışmamda yapmış olduğu değerli önerilerinden dolayı Dr. Öğr. Üyesi Âdem Özyavaş'a teşekkür etmek istiyorum. Ayrıca yaşamım boyunca ve özellikle yüksek lisans çalışmam süresince desteklerini hiçbir zaman esirgemeyen arkadaşlarıma, aileme çok teşekkür etmek istiyorum.

Ocak, 2024

Hasan ALIYEV

MAKİNE ÖĞRENME ALGORİTMALARINI KULLANAN DUYGU TAHMİNİNE DAYALI MÜZİK ÖNERİ SİSTEMİ

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 yaşanmış 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 göstermektedir. Bu çalışma, duyguya göre müzik öneri sistemlerinin kullanıcı deneyimini daha etkili bir hale getirme potansiyeline sahip olduğu görünmekte. Kullanıcının mevcut duygusunu analiz ederek, ona en uygun müzikleri önerme yeteneği müzik öneri sistemlerinin geleceğini şekillendirecek yenilikçi bir yaklaşım sunmaktadır.

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

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. The capacity to recommend the most fitting music by gauging the user's current emotional state presents an innovative approach that may shape the future of music recommendation systems.

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

İÇİNDEKİLER

	<u>Sayfa</u>
ONUR SÖZÜ	iii
ÖNSÖZ.....	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	vi
KISALTMALAR LİSTESİ.....	viii
ÇİZELGELER LİSTESİ.....	x
ŞEKİLLER LİSTESİ.....	xi
I. GİRİŞ	1
A. Temel Kavramlar	2
B. Tezin Önemi ve Amacı.....	3
II. LİTERATÜR TARAMASI.....	4
A. Yapılan Çalışmalar	4
III. MAKİNE ÖĞRENME (ML) MODELLERİ	10
A. Derin Öğrenme Modelleri.....	11
B. LSTM Modelleri	13
IV. EVRİŞİMLİ SINIR AĞLARI (CNN) MODELLERİ	15
A. Veri Setleri.....	16
V. YÖNTEM, SINIFLANDIRMA VE UYGULAMA.....	19
A. Yüz ifadesi analizi	19
B. Önerilen Yöntem	20

C. Veri yükleme ve ön işleme	26
D. Deneysel Sonuçlar	27
E. Deneysel Veri Seti	34
VI. MATERYAL VE METOT DEĞİŞİMİ	41
A. Karışıklık Matris	41
B. Karışıklık matrisin (CM) performans incelemesi	42
VII. SONUÇLAR VE DEĞERLENDİRİLMESİ	45
VIII. SONUÇLAR VE TARTIŞMALAR	47
IX. KAYNAKÇA	49
ÖZGEÇMİŞ	53

KISALTMALAR LİSTESİ

AI	: Artificial Intelligence
ANN	: Artificial Neural Networks
AUC	: Area Under the Curve
CM	: Confusion Matrix
CNN	: Convolutional Neural Networks
DT	: Decision Tree
FER	: Facial Expression Recognition
FN	: False Negative
FP	: False Positive
FPR	: False Positive Rate
GAN	: Generative Adversarial Networks
IOT	: Internet of Things
KNN	: K-Nearest Neighbors
LR	: Logistic Regression
LSTM	: Long Short-Term Memory
ML	: Machine Learning
MLP	: Multilayer Perceptron
NB	: Naive Bayes
ReLU	: Rectified Linear Unit
RF	: Random Forest
RNN	: Recurrent Neural Networks
ROC	: Rectified Linear Unit

SVM : Support Vector Machine
TF-IDF : Term Frequency- Inverse Document Frequency
TN : True Negative
TP : True Positive
TPR : True Positive Rate

ÇİZELGELER LİSTESİ

	<u>Sayfa</u>
Çizelge 1. Veri Özellikleri.....	16
Çizelge 2. Değerlendirme.....	27
Çizelge 3. Sinir duygusu Karışıklık Matrisi.....	35
Çizelge 4. Tiksinti duygusu Karışıklık Matrisi	35
Çizelge 5. Korku duygusu Karışıklık Matrisi	36
Çizelge 6. Mutluluk duygusu Karışıklık Matrisi.....	37
Çizelge 7. Nötr duygusu Karışıklık Matrisi	38
Çizelge 8. Üzgün duygusu Karışıklık Matrisi.....	39
Çizelge 9. Şaşkınlık duygusu Karışıklık Matrisi.....	40

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. Duygu Sınıfı Dağılımı.....	17
Şekil 2. Kullandığımız Verilerin Duygu Sınıfı Dairesel Dağılımı.....	18
Şekil 3. Makine Öğrenimi Modelinin Çalışma Akışı.....	20
Şekil 4. Örnek Duygu İçin Müzik Önerisi	21
Şekil 5. Manuel Duygu Önerimi	21
Şekil 6. Duygu Analizi İçin Görüntü Alımı (www.freepik.com , 2022)	22
Şekil 7. Duygu Analizi İçin Görüntü Analiz Etmesi (www.freepik.com , 2022).....	23
Şekil 8. Örnek Sınırlı Duygu Analizi (khoahoc.tv , 2023)	23
Şekil 9. Örnek Mutlu Duygu Analizi (ar.europeanwritersstour.com , 2023)	24
Şekil 10. Örnek Şaşkın Duygu Analizi (www.freepik.com , 2023).....	24
Şekil 11. Örnek Notru Duygu Analizi (stock.adobe.com/tr , 2023).....	24
Şekil 12. Örnek Korku Duygu Analizi (www.psypost.org , 2019).....	24
Şekil 13. Örnek Tiksiniye Duygu Analizi (www.istockphoto.com , 2012).....	25
Şekil 14. Örnek Üzgün Duygu Analizi (Yık ve ark. 2013).....	25
Şekil 15. ROC Eğrisi Temelli Şaşkınlık Duygusu Performans Analizi	28
Şekil 16. ROC Eğrisi Temelli Üzgün Duygu Performans Analizi.....	28
Şekil 17. ROC Eğrisi Temelli Sınırlı Duygu Performans Analizi.....	29
Şekil 18. ROC Eğrisi Temelli Tiksinti Duygusu Performans Analizi.....	30
Şekil 19. ROC Eğrisi Temelli Korku Duygusu Performans Analizi.....	31
Şekil 20. ROC Eğrisi Temelli Mutluluk Duygusu Performans Analizi	31

Şekil 21.	ROC Eğrisi Temelli Nötr Duygu Performans Analizi	32
Şekil 22.	Yüz ifadelerinin sınıflandırılması için ROC eğrisi analizi.....	33
Şekil 23.	Sinirli Duygu İçin CM Modeli	34
Şekil 24.	Tiksinme Duygusu İçin CM Modeli	35
Şekil 25.	Korku Duygusu İçin CM Modeli	36
Şekil 26.	Mutluluk Duygusu İçin CM Modeli	37
Şekil 27.	Nötr Duygusu İçin CM Modeli	38
Şekil 28.	Üzgün Duygu İçin CM Modeli	39
Şekil 29.	Şaşkınlık Duygusu İçin CM Modeli	40

I. GİRİŞ

Müzik, insan duygu ve deneyimlerini ifade etmenin güçlü bir aracı olarak, kültürel ve duygusal bağlamda derin etkileşimlere neden olmuştur. Günümüzde, dijital müzik platformlarının artan popülaritesiyle birlikte, kullanıcılar geniş bir müzik yelpazesi arasından seçim yapma imkanına sahiptirler. Ancak, bu geniş seçenek havuzu, kullanıcıların kişisel tercihlerini keşfetmelerini zorlaştırabilir. Bu bağlamda, makine öğrenmesi algoritmalarını kullanarak duygu tahminine dayalı müzik öneri sistemleri, kullanıcılara daha kişiselleştirilmiş ve duygusal olarak tatmin edici müzik deneyimleri sunma potansiyeli taşımaktadır. 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 major tonalitesi gibi özelliklere sahip enerjik müzikler önerecektir. Öte yandan, eğer bir kullanıcı negatif bir duygusal durumda ise, daha düşük tempo ve minor tonalitesi gibi özelliklere sahip hüzünlü müzikler önerilmektedir.

Bu tezin temel odak noktası, duygu tahmini üzerine kurulu bir müzik öneri sistemi geliştirmektir. Duygu analitiği, kullanıcıların müziği deneyimlerken hissettikleri duyguları anlamak için kullanılan bir yöntemdir. Makine öğrenmesi algoritmaları, büyük veri setleri üzerinde eğitilerek duygu özelliklerini çıkarmak ve müzik parçalarını duygusal olarak sınıflandırmak için kullanılabilir. Bu sınıflandırma, kullanıcıların geçmiş tercihleri ve duygusal tepkileri temel alınarak, onlara daha etkileyici ve özgün müzik önerileri sunmak için kullanılabilir.

Bu çalışma, müzik öneri sistemlerinin geliştirilmesinde duygu analitiğinin önemini vurgulayarak, kullanıcı deneyimini zenginleştirmeyi amaçlamaktadır. Makine öğrenmesi algoritmalarının entegrasyonu, kullanıcıların duygu durumlarına uygun müzik önerileriyle karşılaşmaları hedeflenmektedir. Bu bağlamda, tezin ilerleyen bölümlerinde kullanılacak olan makine öğrenmesi

algoritmalarının seçimi, veri seti hazırlığı, model eğitimi ve performans değerlendirmesi gibi adımlar detaylı bir şekilde ele alınacaktır.

A. Temel Kavramlar

Duygu Analitiği (Sentiment Analysis): Duygu analitiği, metin, ses veya görüntü verilerindeki duygusal içeriği tanımlamak ve anlamak için kullanılan bir tekniktir. Bu bağlamda, müzik öneri sistemimizde duygu analitiği, kullanıcıların müzik dinleme deneyimlerini temel alan duygu durumlarını belirlemek amacıyla kullanılacaktır.

Makine Öğrenimi (Machine Learning): Makine öğrenimi, bilgisayar sistemlerinin belirli bir görevi gerçekleştirmek için veri üzerinden öğrenmesini sağlayan bir alanı ifade eder. Müzik öneri sistemi için makine öğrenimi, büyük müzik veri setleri üzerinde model eğitimi yaparak, duygu durumlarına göre müzik parçalarını sınıflandırmak ve kullanıcı tercihlerini anlamak amacıyla kullanılacaktır.

Veri Madenciliği (Data Mining): Veri madenciliği, büyük veri setlerinden bilgi çıkarmak için kullanılan bir süreçtir. Müzik öneri sisteminde veri madenciliği, kullanıcıların müzik tercihleri, dinleme geçmişleri ve duygu durumları gibi verileri analiz ederek, anlamlı desenleri keşfetmeyi amaçlayacaktır. **Duygu Temelli Müzik Sınıflandırma:** Bu kavram, müzik parçalarını duygusal özelliklerine göre sınıflandırmayı ifade eder. Makine öğrenimi algoritmaları aracılığıyla, her müzik parçasının duygusal bir etiketleme sürecinden geçirilerek duygu temelli sınıflandırmalar elde edilecektir.

Müzik Öneri Sistemi: Bu sistem, kullanıcıların geçmiş müzik tercihlerini analiz ederek, onlara duygu durumlarına uygun yeni müzik önerileri sunan bir uygulamayı ifade eder. Bu öneriler, makine öğrenimi algoritmaları tarafından elde edilen duygu temelli sınıflandırmaları temel alacaktır.

Bu temel kavramlar, müzik öneri sistemimizin geliştirilmesi için kullanılacak olan ana bileşenleri ve bu bileşenler arasındaki ilişkileri anlamamıza yardımcı olacaktır. Bu tezin amacı, bu kavramları bir araya getirerek, duygu temelli müzik öneri sistemlerinin kullanıcı deneyimini zenginleştirmesini sağlamaktır.

B. Tezin Önemi ve Amacı

Bu tezin önemi, müzik dinleme deneyimlerini daha kişisel ve duygusal olarak tatmin edici hale getirmeyi amaçlayan duygu temelli müzik öneri sistemlerinin geliştirilmesindedir. Günümüzde, dijital müzik platformlarının geniş veri setleri üzerinde kullanıcı tercihleri ve duygu durumlarına dayalı olarak etkili önerilerde bulunabilen sistemlere olan ihtiyaç artmaktadır. Bu tür bir müzik öneri sistemi, kullanıcıların beklentilerini anlamak, müzik zevklerini öngörmek ve duygusal bağlamda tatmin edici bir müzik listesi oluşturmak için duygu analitiği ve makine öğrenimi tekniklerini kullanarak özelleştirilmiş öneriler sunabilir. Ayrıca, müzik öneri sistemleri, müzik endüstrisinde sanatçıları ve yapımcıları destekleyebilir. Bu sistemler, kullanıcı tercihleri üzerinden müzik trendlerini analiz etmeye ve yeni sanatçıları keşfetmeye yardımcı olabilir. Bu nedenle, duygu temelli müzik öneri sistemleri, hem kullanıcıların müzik keşif deneyimini iyileştirmek hem de müzik endüstrisine katkıda bulunmak açısından büyük bir öneme sahiptir.

Bu tezin temel amacı, duygu analitiği ve makine öğrenimi tekniklerini kullanarak duygu temelli bir müzik öneri sistemi geliştirmektir. Bu sistem, kullanıcıların geçmiş müzik tercihlerini ve duygu durumlarını analiz ederek, onlara duygusal bağlamda uygun müzik önerileri sunmayı hedefleyecektir. Amacımız, kullanıcıların müzik dinleme deneyimlerini daha özelleştirilmiş, tatmin edici ve duygusal olarak zengin kılmaktır. Bu bağlamda, tezde kullanılacak olan makine öğrenimi algoritmaları, veri seti hazırlığı, model eğitimi ve performans değerlendirmesi gibi adımlar detaylı bir şekilde ele alınacak ve geliştirilecek olan müzik öneri sisteminin etkinliği üzerine çeşitli testler yapılacaktır. Elde edilen sonuçlar, duygu temelli müzik öneri sistemlerinin gerçek dünya kullanımına yönelik potansiyelini anlamamıza ve bu alandaki gelecekteki çalışmaları yönlendirmemize katkıda bulunacaktır.

II. LİTERATÜR TARAMASI

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.

A. Yapılan Çalışmalar

Bu literatür taraması, Derin Öğrenme Modellerinin 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 almaktayız (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 toplandıđı, iřlendiđi ve saklandıđı konuları, teknolojinin kullanımı kadar kritik bir öneme sahiptir. Bu, sadece kullanıcı mahremiyetini korumak adına deđil, 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 yeteneđi, birçok uygulama için kritik bir öneme sahiptir; özellikle güvenlik ve yasa uygulama hizmetlerinde bu yetenek, şüpheli davranışları tespit etmek ve bireylerin niyetlerini anlamak adına büyük bir deđer 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 deđil, aynı zamanda tanıma dođruluđu da bu algoritmalarda kritik bir öneme sahiptir. Bu bağlamda, yüz ifadelerini tanıma konusunda hangi açılardan en etkili olduđunu belirlemek amacıyla yapılan çalışmalar, daha dođru 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 olduđunu 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 olduđunu biliyoruz. Bu bağlamda, sosyal medya verilerinden elde edilen duygusal analizlerin, hisse senedi piyasasındaki hareketleri tahmin etmede nasıl bir rol oynayabileceđi 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 etkinliđini

incelemiştir. Bu analiz sürecinde, KNN(K-Nearest Neighbors), SVM(Support Vector Machine), LR(Logistic Regression), NB(Naive Bayes), DT(Decision Tree), RF(Random Forest) ve MLP(Multilayer Perceptron) 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 kolaylıklardan 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, platformlar like 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 araştırma, kullanıcıların oluşturduğu çalma listelerine dayalı bir öneri sistemini inceliyor. Bu sistem, TF-IDF(Term Frequency- Inverse Document Frequency) vektörleştirilmesi kullanarak içerik tabanlı filtreleme yaparak, şarkıların veya parçaların adları üzerinde duygusal analiz gerçekleştiriyor. 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

potansiyeye 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 potansiyeye 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).

(Qiu ve Jia, 2022) tarafından geliştirilen Batı müziği tarihi öneri sistemi, Nesnelerin İnterneti (IoT) verilerini analiz ederek kullanıcılara Batı müziği tarihindeki farklı dönemlere ait şarkılar önermektedir. Sistem, kullanıcının IoT

cihazları aracılığıyla toplanan verileri, örneğin konum, aktivite ve kalp atış hızı verilerini kullanarak kullanıcının ruh halini ve müzik tercihlerini analiz etmektedir. Sistem, elde ettiği bilgiler ışığında kullanıcılara uygun şarkılar önermektedir. Sistemin çalışma prensibi aşağıdaki gibidir:

- a. IoT cihazları aracılığıyla kullanıcının verileri toplanır.
- b. Kullanıcının verileri analiz edilerek kullanıcının ruh hali ve müzik tercihleri belirlenir.
- c. Kullanıcının ruh hali ve müzik tercihlerine uygun Batı müziği tarihi şarkıları önerilir.

(Shorten ve Khoshgoftaar, 2019) tarafından yapılan araştırmada, derin öğrenmede görüntü verisi büyütme yöntemleri incelenmiştir. Araştırmacılar, görüntü verisi büyütmenin aşırı öğrenmeyi önlemeye yardımcı olduğunu ve böylece model performansını artırabileceğini göstermişlerdir. Görüntü verisi büyütme, mevcut eğitim verilerinden yeni eğitim verileri oluşturmak için çeşitli tekniklerin kullanılmasıdır. Örneğin, görüntüler döndürülerek, kırılarak veya gürültü eklenerek yeni görüntüler oluşturulabilir. Yazarlar, görüntü verisi büyütmenin derin öğrenme modellerinin performansını çeşitli veri kümeleri üzerinde değerlendirmişlerdir. Örneğin, CIFAR-10 veri kümesinde, görüntü verisi büyütme kullanılmadan eğitilen bir derin öğrenme modelinin doğruluk oranı %92,3 iken, görüntü verisi büyütme kullanılarak eğitilen bir derin öğrenme modelinin doğruluk oranı %94,5'e yükselmiştir. Yazarlar, görüntü verisi büyütmenin derin öğrenme modellerini aşırı öğrenmeye karşı daha dayanıklı hale getirdiğini ve bu nedenle model performansını artırdığını belirtmektedirler. Veri büyütmenin, özellikle sınırlı miktarda eğitim veriye sahip veri kümeleri için faydalı olabileceğini de vurgulamaktadırlar.

(Yik, Widen ve Russell, 2013) tarafından yapılan çalışma, yüz ifadelerinin incelenmesinde kullanılan deneysel tasarım olan özne içi tasarımın potansiyel artefaktlarını araştırmıştır. Çalışmada, katılımcılara önceki yüz ifadelerinin yeni bir yüz ifadesini algılayışlarını nasıl etkilediğini görmek için bir dizi farklı yüz ifadesi gösterilmiştir. Yazarlar, önceki yüz ifadelerinin yeni bir yüz ifadesinin algılanışını etkilediğini bulmuşlardır. Örneğin, katılımcılara önceki olarak kızgın yüz ifadeleri gösterildiğinde, yeni bir yüz ifadesini kızgın olarak algılama

olasılıkları daha yüksekti. Yazarlar, özne içi tasarımın potansiyel artefaktları olduğunu ve bu artefaktların yüz ifadelerinin incelenmesinde sonuçları etkileyebileceğini vurgulamıştır. Örneğin, özne içi tasarımda katılımcılar, önceki yüz ifadelerini ve yeni yüz ifadelerini aynı anda hatırlayabilirler. Bu, katılımcıların yeni yüz ifadelerini önceki yüz ifadelerine göre değerlendirmelerine neden olabilir. Yazarlar, özne içi tasarımın kullanıldığı yüz ifadesi çalışmalarında dikkatli olunması gerektiğini ve sonuçların yorumlanmasında bu artefaktların dikkate alınması gerektiğini belirtmişlerdir.

Bu makale, duygusal analiz ve müzikle ilgili duygu tanımanın teknolojik araçlarla nasıl gerçekleştirildiğini inceler. Ayrıca, bu teknolojilerin gelişimindeki en son trendleri ve bu alandaki gelecekteki potansiyellerini değerlendirir.

III. MAKİNE ÖĞRENME (ML) MODELLERİ

Makine öğrenimi (ML), bilgisayarların önceden programlanmamış olarak verilerden öğrenmesini sağlayan bir yapay zekâ (AI) alt alanıdır. ML modelleri, verilerden kalıplar ve ilişkiler öğrenerek yeni bilgiler üretebilir, kararlar verebilir ve eylemler gerçekleştirebilir. ML modelleri, çeşitli şekillerde sınıflandırılabilir. En yaygın sınıflandırma, denetimli ve denetimsiz eğitim olarak yapılır.

Denetimli eğitimde, model, bilinen etiketlere sahip bir veri kümesi üzerinde eğitilir. Model, bu verileri kullanarak etiketler ve özellikler arasındaki ilişkiyi öğrenir. Örneğin, bir görüntü tanıma modeli, kedi ve köpek görüntülerinin etiketli bir kümesi üzerinde eğitilebilir. Bu eğitim, modeli, yeni bir görüntünün kedi mi yoksa köpek mi olduğunu tahmin etmek için kullanır. Denetimli eğitimde, model, etiketsiz bir veri kümesi üzerinde eğitilir. Model, bu verileri kullanarak verilerdeki kalıpları ve ilişkileri öğrenir. Örneğin, bir grup müşterinin alışveriş alışkanlıklarını analiz eden bir model, bu verileri kullanarak müşterilerin gelecekteki alışverişlerini tahmin etmek için kullanılabilir (Congzheng Song, T. Ristenpart, Vitaly Shmatikov 2017).

Diğer bir yaygın sınıflandırma, sürekli ve sınıflandırma olarak yapılır. Sürekli modeller, sayısal verileri tahmin etmek için kullanılır. Örneğin, bir satış tahmin modeli, gelecekteki satışları tahmin etmek için kullanılabilir.

Sınıflandırma modelleri, verileri kategorilere ayırmak için kullanılır. Örneğin, bir e-posta spam filtresi, e-postaları spam veya ham olarak sınıflandırmak için kullanılabilir. ML modelleri, çok çeşitli uygulamalarda kullanılır. Bazı yaygın örnekler şunlardır:

- Görüntü tanıma: Fotoğrafları, videoları ve diğer görsel verileri analiz etmek için kullanılır. Örneğin, yüz tanıma, trafik işareti tanıma ve araç tanıma için kullanılabilir.
- Doğal dil işleme: Metin ve konuşmayı analiz etmek için kullanılır. Örneğin, çeviri, soru yanıtlama ve duygu analizi için kullanılabilir.

- Ses tanıma: Sesleri analiz etmek için kullanılır. Örneğin, sesli komutlar ve sesli asistanlar için kullanılabilir.
- Makine çevirisi: Bir dilden diğerine metin çevirmek için kullanılır.
- Yapay zeka destekli müşteri hizmetleri: Müşteri sorularına ve sorunlarıyla ilgilenmek için kullanılır.
- Büyük veri analizi: Büyük miktarda veriyi analiz etmek için kullanılır. Örneğin, müşteri davranışlarını analiz etmek, üretim hatlarını optimize etmek ve hastalıkları teşhis etmek için kullanılabilir.

ML modelleri, giderek daha karmaşık ve güçlü hale geliyor. Bu, onları birçok farklı uygulamada daha kullanışlı hale getiriyor. ML modellerinin avantajları şunlardır:

- Verilerden öğrenme yeteneğine sahiptirler. Bu, onları yeni durumlara uyum sağlamak ve yeni bilgiler üretmek için uygun hale getirir.
- İnsanların yapamayacağını veya yapmak istemediği görevleri otomatikleştirebilirler. Bu, verimliliği ve üretkenliği artırabilir.
- Kişiselleştirilmiş deneyimler sunmak için kullanılabilirler. Bu, müşteri memnuniyetini artırabilir. ML modellerinin dezavantajları şunlardır:
 - Büyük miktarda veriye ihtiyaç duyarlar.
 - Eğitimleri zaman alıcı ve karmaşık olabilir.
 - Yanlış yönlendirilmiş olabilirler. Bu, yanlış sonuçlara yol açabilir.

ML modelleri, yapay zekâ alanındaki en heyecan verici gelişmelerden biridir. Potansiyel uygulamaları çok çeşitlidir ve günlük hayatımızı önemli ölçüde iyileştirme potansiyeline sahiptir (Amira Sayed Gadallah, 2022).

A. Derin Öğrenme Modelleri

Derin öğrenme, yapay sinir ağları kullanarak karmaşık görevleri gerçekleştirmek üzere tasarlanan bir makine öğrenimi alt dalıdır. Bu modeller, genellikle çok katmanlı sinir ağlarından oluşur ve büyük miktarda veri üzerinde

karmaşık desenleri öğrenme yeteneğine sahiptir (Mosavi and Várkonyi-Kóczy, 2023). Aşağıda, derin öğrenme modellerinin temel tiplerini tanımlayan bazı önemli kavramlar bulunmaktadır:

Yapay Sinir Ağları (Artificial Neural Networks- ANN): Temel yapı taşları olan yapay sinir hücreleri, birbirine bağlı katmanlardan oluşan sinir ağlarını oluşturur. Bu ağlar, giriş verilerini işleyerek çıkışları üretirler. Yapay sinir ağları genellikle öğrenme sürecinde ağırlıkları ayarlayarak ve gerçek çıkış ile beklenen çıkış arasındaki hatayı minimize ederek eğitilirler.

Evrişimli Sinir Ağları (Convolutional Neural Networks- CNN): Özellikle görsel veri analizi için etkili olan CNN'ler, evrişim katmanlarından oluşan bir mimariye sahiptir. Bu katmanlar, özellik haritalarını çıkarmak ve önemli desenleri tanımak için özel bir evrişim işlemi kullanır. Bu nedenle, CNN'ler genellikle görüntü sınıflandırma, nesne tanıma ve görüntü segmentasyonu gibi görsel görevlerde kullanılır.

Rekürrens Ağları (Recurrent Neural Networks- RNN): Zaman serisi verileri veya ardışık girişlerle iyi çalışan RNN'ler, döngülü bağlantılara sahiptir. Bu sayede, önceki adımlardaki bilgileri hatırlayabilir ve ardışık veri analizi görevlerinde kullanılabilir. Ancak, geleneksel RNN'lerin zaman içindeki uzun vadeli bağımlılıkları ele almakta zorlanma sorunu "vanishing gradient problem" gibi zorluklarla karşılaşabilir.

Uzun Kısa Vadeli Bellek Ağları (Long Short-Term Memory- LSTM): LSTM'ler, önceki adımlardaki bilgileri daha iyi muhafaza etmek için tasarlanmış özel bir hücre yapısına sahip bir RNN türüdür. Bu sayede, zaman serisi verileri üzerinde daha uzun vadeli bağımlılıkları başarıyla modelleyebilirler ve "vanishing gradient problem" sorununu hafifletirler.

Üreteç ve Ayrımcı Ağlar (Generative Adversarial Networks- GAN): GAN'lar, bir üreteç ve bir ayrımcı olmak üzere iki ağdan oluşan bir modeldir. Üreteç, yeni veriler oluştururken, ayrımcı bu verilerin gerçek mi yoksa üretilmiş mi olduğunu ayırt etmeye çalışır. Bu sürekli rekabet, modelin gerçekçi veri üretme yeteneğini artırır (Gupta and Yamaguchi, S., 2021).

Bu derin öğrenme modelleri, müzik öneri sistemlerinin geliştirilmesinde duygu analitiği ve müzik sınıflandırma görevlerinde kullanılarak kullanıcılara

daha etkili ve kişiselleştirilmiş öneriler sunma potansiyeli taşır. Bu modellerin kullanılması, büyük veri setleri üzerinde duygu analizi yapma ve müzik parçalarını duygusal özelliklere göre sınıflandırma yeteneğini artırabilir, böylece daha tatmin edici müzik önerileri elde edilebilir.

B. LSTM Modelleri

Uzun Kısa Vadeli Bellek Ağları (LSTM), özellikle zaman serisi verilerinin işlenmesi ve ardışık veri analizi görevlerinde başarıyla kullanılan bir tür Rekürren Ağ (RNN) modelidir. LSTM'ler, RNN'lerin temel sorunlarından biri olan "vanishing gradient problem"i çözmek için özel bir hücre yapısına sahiptirler. Bu sayede, uzun vadeli bağımlılıkları daha etkili bir şekilde öğrenme yeteneğine sahiptirler. LSTM'lerin temel özellikleri şunlardır:

Hücre Yapısı: LSTM'ler, her bir hücre içinde bir hafıza hücresi (cell state) ve bu hafıza hücresini güncellemek ve kontrol etmek için giriş, çıkış ve unutma kapıları (input gate, output gate, forget gate) içerir.

Hafıza Hücresi (Cell State): LSTM'lerin belki de en önemli özelliği, her bir hücrenin içindeki hafıza hücresidir. Bu hafıza hücresi, ağın geçmiş adımlarda öğrendiği bilgileri muhafaza eder. Bu sayede, model zaman içindeki uzun vadeli bağımlılıkları daha iyi anlayabilir.

Giriş Kapısı (Input Gate): Giriş kapısı, hafıza hücresine yeni bilgi ekler. Bu kapı, giriş verisinin ne kadarının hafıza hücresine ekleneceğini kontrol eder.

Unutma Kapısı (Forget Gate): Unutma kapısı, hafıza hücresindeki eski bilgileri ne kadar unutacağını belirler. Bu, gereksiz bilgileri temizlemek ve modelin odaklanmasını sağlamak için önemlidir.

Çıkış Kapısı (Output Gate): Çıkış kapısı, hafıza hücresinden elde edilen bilgiyi modelin çıkışına iletmek için kullanılır. Bu kapı, hangi bilgilerin modelin çıkışına katkıda bulunacağını belirler.

LSTM'ler, dil modelleme, metin analizi, ses işleme ve zaman serisi tahmin gibi birçok görevde başarıyla kullanılmıştır. Müzik öneri sistemlerinde, özellikle zaman içindeki duygu değişimlerini ve müzikal yapıları modelleme yetenekleri nedeniyle tercih edilebilirler. LSTM'ler, zaman içindeki uzun vadeli

bağımlılıkları daha etkili bir şekilde ele alarak, müzik parçalarını daha duygusal bir bağlamda sınıflandırmak ve kullanıcılara kişiselleştirilmiş öneriler sunmak için kullanılabilir.

IV. EVRİŞİMLİ SİNİR AĞLARI (CNN) MODELLERİ

Evrışimli Sinir Ağları, derin öğrenme modellerinin bir alt kümesidir ve özellikle görsel görevlerde oldukça başarılıdırlar. CNN'lerin başarısının ardında, bir görüntüdeki yerel özellikleri öğrenme yeteneği yatar. Evrişim, bir giriş matrisi I (genellikle bir görüntü) üzerinde bir filtre matrisinin kaydırılmasıyla gerçekleşen bir matematiksel işlemdir. 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 konumsal 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.

A. Veri Setleri

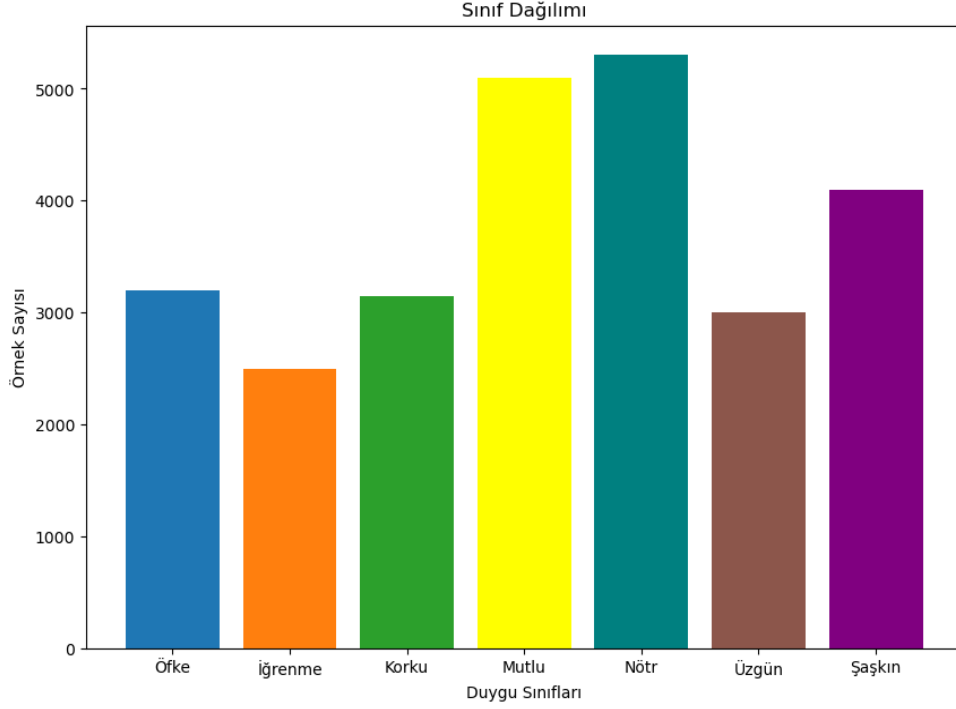
Tüm veriler anonim olarak kullanılmıştır. Kullanılan veriler ve tipleri Tablo 1 Veri Özelliklerinde mevcuttur (paperswithcode.com, 2013).

Çizelge 1. Veri Özellikleri

VERİ ADI	VERİ TİPİ	ÖRNEK VERİ
Sinirli	Fotoğraf	
Tiksinme	Fotoğraf	
Korku	Fotoğraf	
Mutlu	Fotoğraf	
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 yüzdelerle oranlarla şu şekilde yansıtmaktadır: 'Öfke=%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.

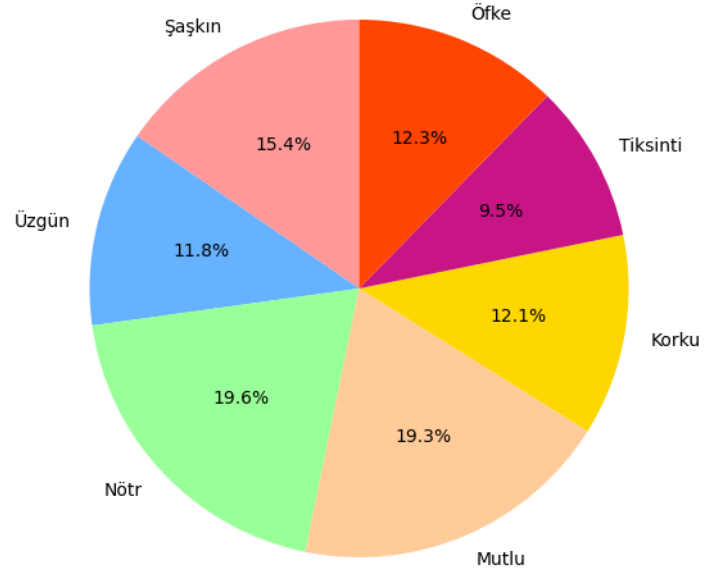


Şekil 1. Duygu Sınıfı Dağılımı

Duygularda veri dengesizliğini engellemek amacıyla olabildiğince çok sayıda veri toplandı ve eşit olmaya yakın bir veri dağılımı hedeflendi. Bu hedef büyük ölçüde başarıyla gerçekleştirildi. Üzgün ve şaşkın ifadeler, duygusal tepkilerin daha derin ve karmaşık yönlerini temsil ederken; öfke, korku ve tiksinme 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.



Şekil 2. Kullandığımız 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.

V. YÖNTEM, SINIFLANDIRMA VE UYGULAMA

A. Yüz ifadesi 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.

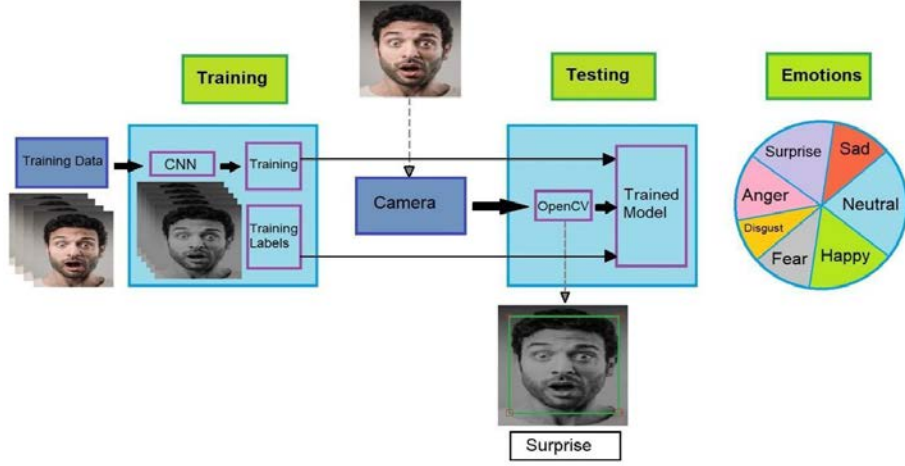
Kullanıcının yüz fotoğrafı, ön yüz aracılığıyla arka yüze iletilir. Arka yüzde, derin öğrenme modeli bu fotoğrafı analiz eder ve bir duygu tahmini yapar. Bu tahmin, önceden eğitilmiş algoritmalar kullanılarak, fotoğrafın içerdiği mikro ifadelerden türetilir.

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 proje, teknoloji ve duygusal zekanın nasıl bütünleştirilebileceğinin etkileyici bir örneği. 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.

B. Önerilen Yöntem

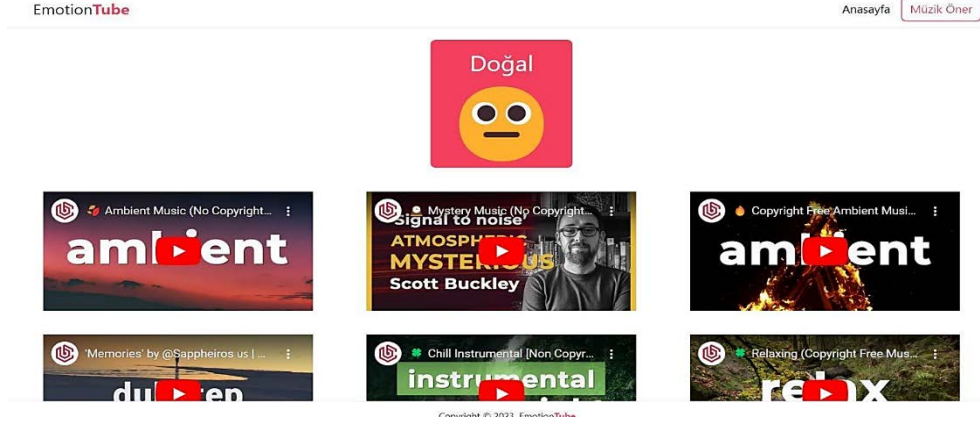


Şekil 3. Makine Öğrenimi Modelinin Çalışma Akışı

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.



Şekil 4. Örnek Duygu İçin Müzik Önerisi

Resim-4'te, kullanıcılar için hazırladığımız frontend'in ana sayfası gösterilmektedir. Bu ana sayfa, kullanıcının yüz ifadesine göre dinamik olarak şekillenen benzersiz bir yapıya sahiptir. Görüntüde de belirtildiği üzere, şu an "Doğal (Neutral)" yüz ifadesiyle karşımıza çıkan bir ana sayfa ile karşı karşıyayız. 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 zenginleştiriyor. Kısacası platform, tamamen kullanıcının duygusal durumuna göre şekillenen kişiselleştirilmiş bir müzik deneyimi sunuyor.

Manuel Öneri



Şekil 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

yönlendirilirler. Örneğin, mutlu bir anınızı kutlamak 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.



Şekil 6. Duygu Analizi İçin Görüntü Alımı (www.freepik.com, 2022)

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, kameraınıza 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.

Kaydedilen Görüntü

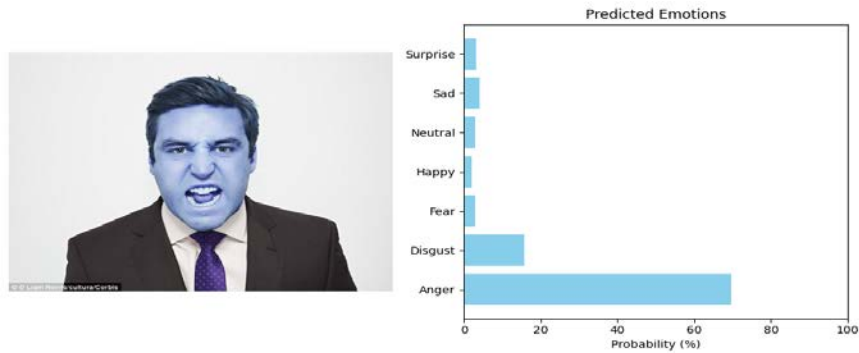


Resmi Gönder

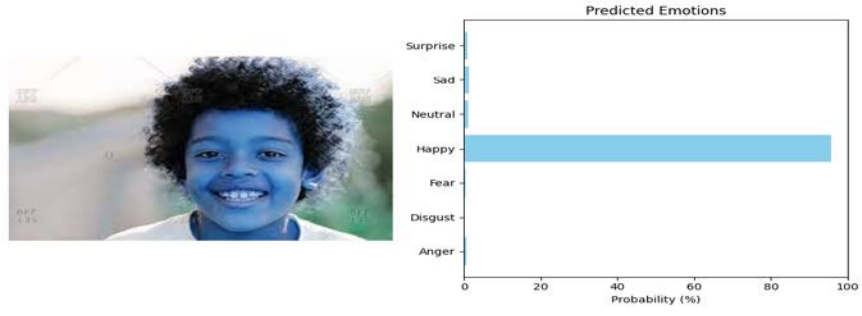
Şekil 7. Duygu Analizi İçin Görüntü Analiz Etmesi (www.freepik.com, 2022)

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.

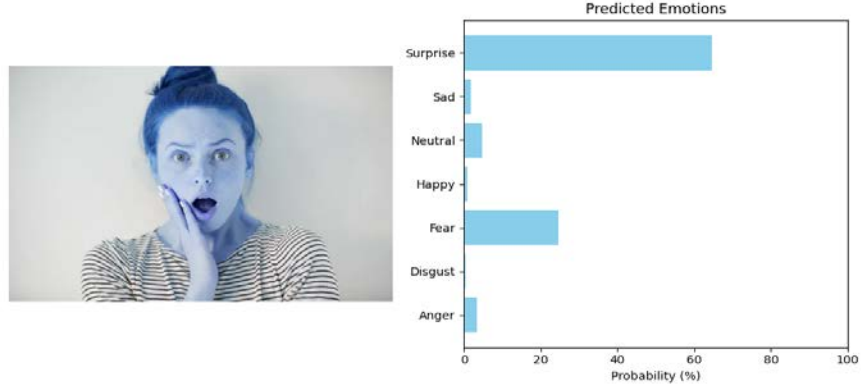
Yüz ifadesinin başarılı bir şekilde analiz edilmesi sonrasında, kullanıcı, anlık ruh haline en uygun müzik önerilerine yönlendirilir. Bu süreç, müzik seçiminde duygusal durumun ne kadar belirleyici olabileceğini vurgular. Dolayısıyla, Resim-7, kullanıcının ruh halini anlamak ve bu anlayışı kişiselleştirilmiş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




Şekil 8. Örnek Sınırlı Duygu Analizi (khoahoc.tv, 2023)



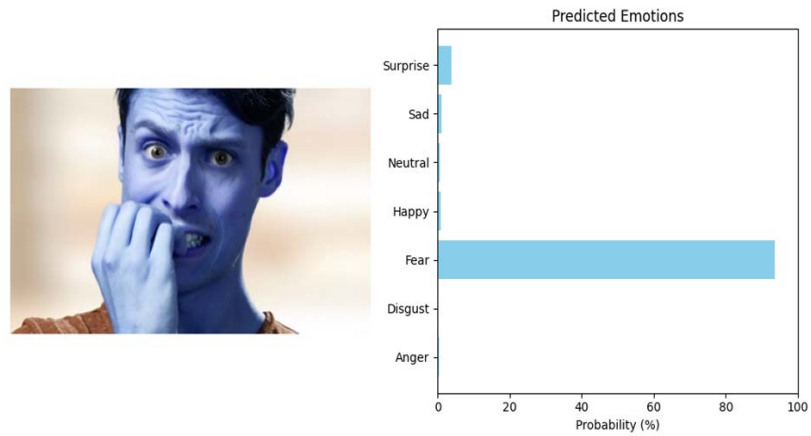
Şekil 9. Örnek Mutlu Duygu Analizi (ar.europeanwriterstour.com, 2023)



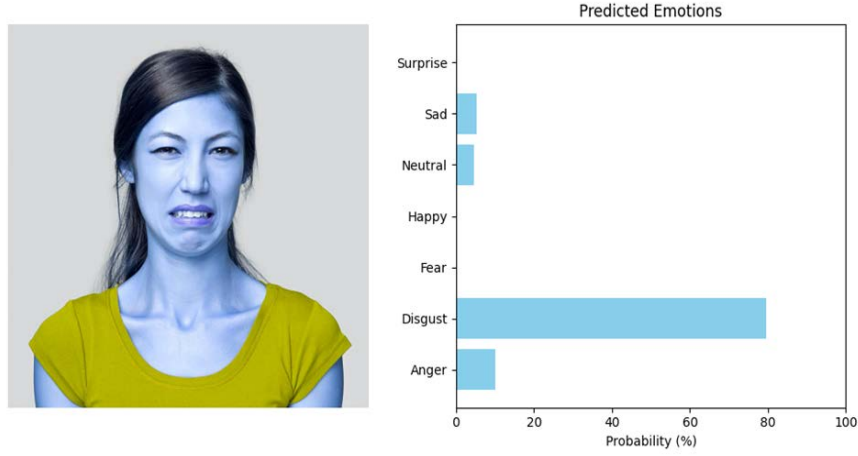
Şekil 10. Örnek Şaşkın Duygu Analizi (www.freepik.com, 2023)



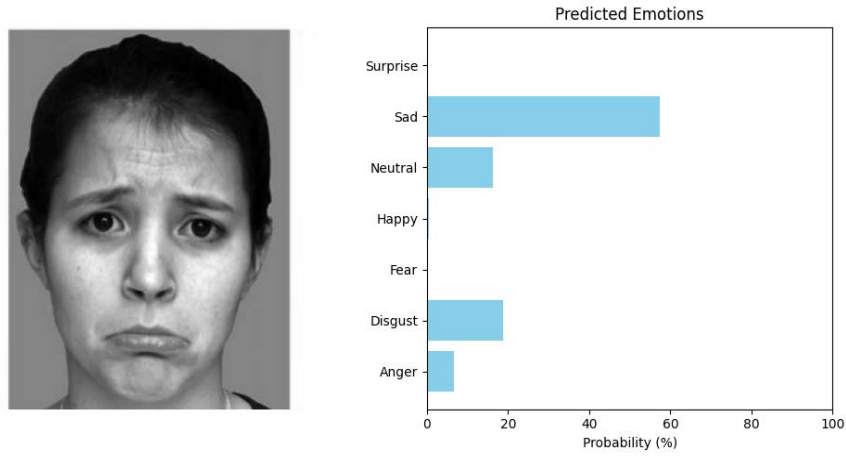
Şekil 11. Örnek Notru Duygu Analizi (stock.adobe.com/tr, 2023)



Şekil 12. Örnek Korku Duygu Analizi (www.psypost.org, 2019)



Şekil 13. Örnek Tikslenme Duygu Analizi (www.istockphoto.com, 2012)



Şekil 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.

C. Veri yükleme ve ön işleme

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 boyutlandırılır: 48x48 piksel. 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 yapıldı. 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. Burada kullanılan terimler


D. Deneysel Sonuçlar

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.

Çizelge 2. Değerlendirme

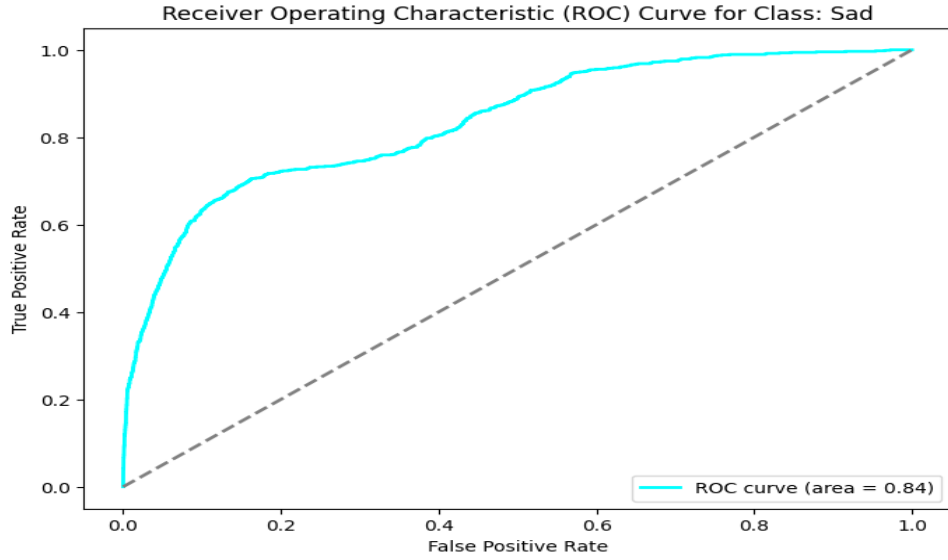
TP	Doğru Pozitif
TN	Doğru Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif

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.



Şekil 15. ROC Eğrisi Temelli Şaşkınlık Duygusu Performans Analizi

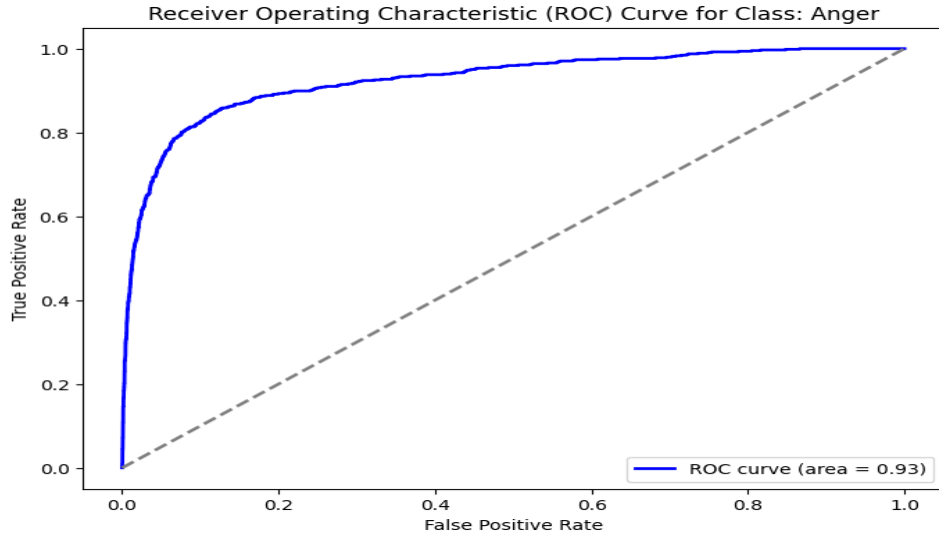
Resim 15'te, "Surprise" (Şaşkınlık) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin "Surprise" yüz ifadesini tanıma kabiliyetini değerlendirmek için kullanılmaktadır. ROC değerinin 0,96 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından son derece başarılı bir şekilde tanındığını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



Şekil 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.



Şekil 17. ROC Eğrisi Temelli Sınırlı Duygu Performans Analizi

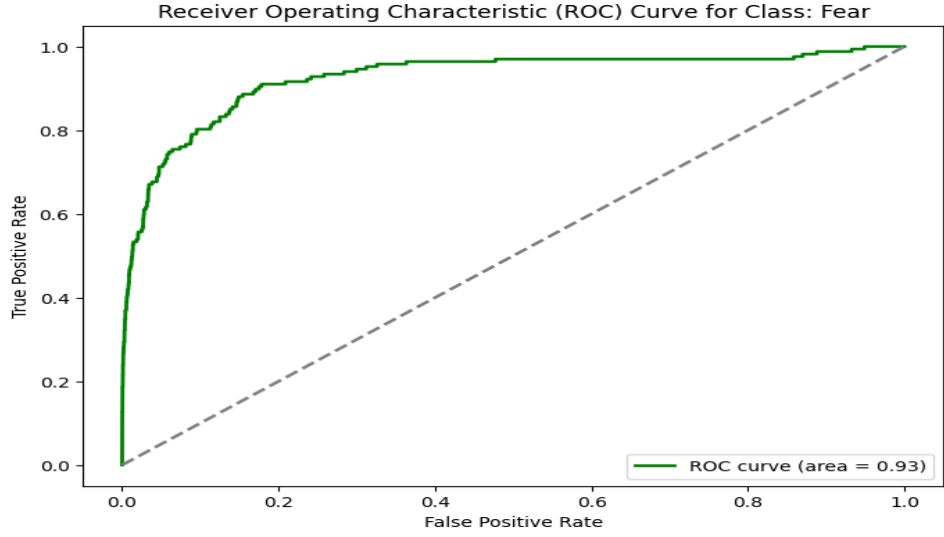
Resim 17'te, "Anger" (Öfke) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin "Anger" yüz ifadesini tanıma kabiliyetini değerlendirmek için hazırlanmıştır. ROC değerinin 0,93 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından yüksek bir başarı ile tanındığını göstermektedir.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



Şekil 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.



Şekil 19. ROC Eğrisi Temelli Korku Duygusu Performans Analizi

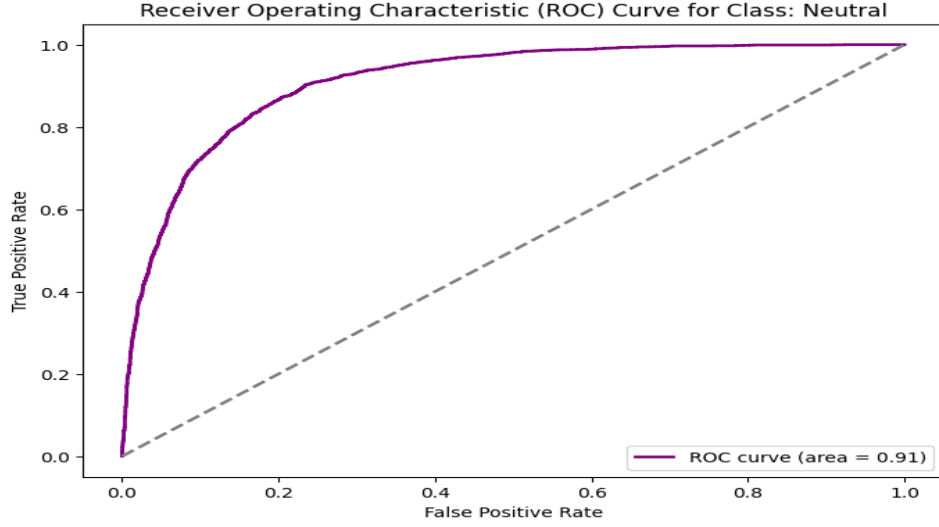
Resim 19'da "Fear" (Korku) yüz ifadesine ait ROC eğrisi gösterilmektedir. Bu eğri, modelin "Fear" yüz ifadesini tanıma kabiliyetini değerlendirmek için kullanılmaktadır. ROC değerinin 0,93 olarak belirlenmiş olması, bu yüz ifadesinin model tarafından yüksek bir başarı ile tanındığını göstermektedir.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



Şekil 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.



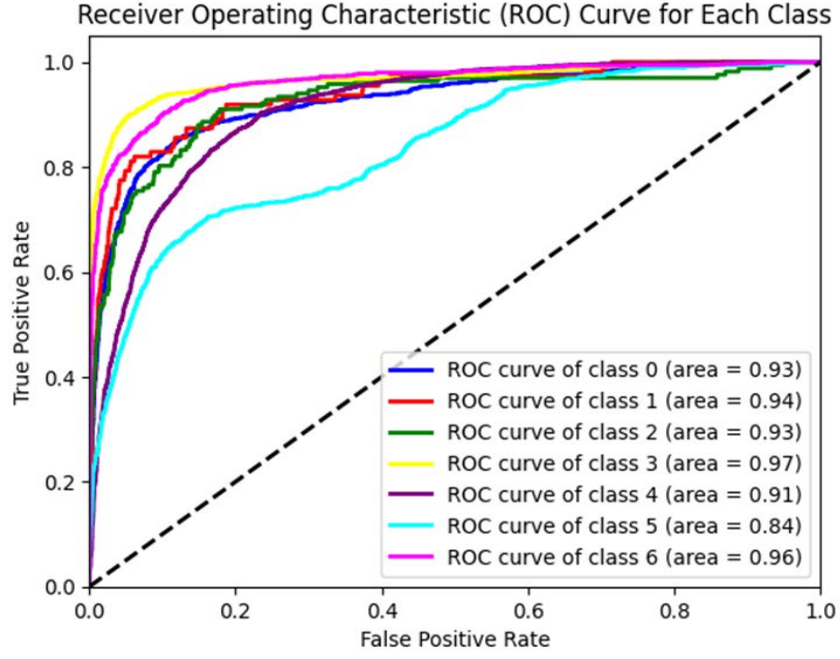
Şekil 21. ROC Eğrisi Temelli Nötr Duygu Performans Analizi

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 başarılı 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.



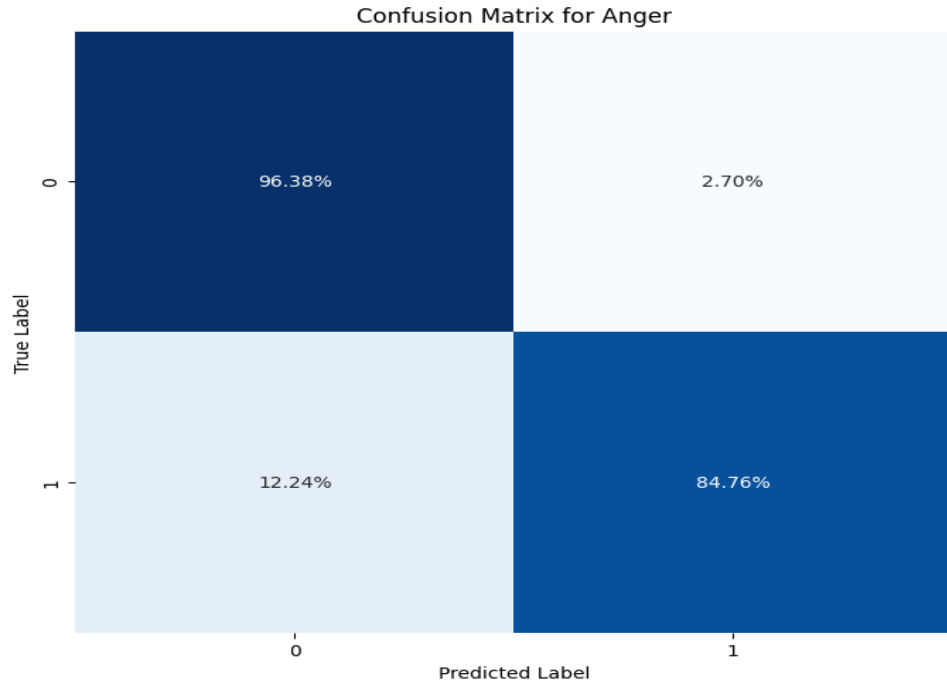
Şekil 22. Yüz ifadelerinin sınıflandırılması için ROC eğrisi analizi

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.

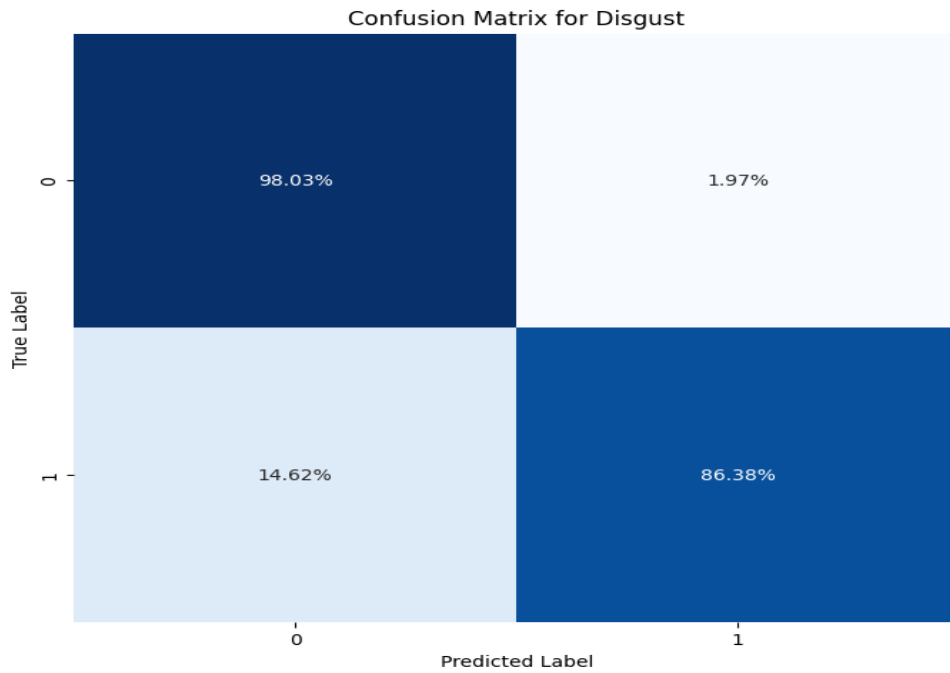
ROC eğrisi analizi ile modelimizin farklı yüz ifadelerini tanıma kabiliyeti değerlendirilmiştir. Bu değerlendirme modelimizin genel performansının yanı sıra belirli yüz ifadeleri üzerindeki başarısını göstermektedir. Yüksek ROC değerleri, modelimizin bu yüz ifadelerini doğru bir şekilde tanıdığını göstermektedir. Bu sonuçlar, modelimizin duygusal güvenilir bir araç olduğunu doğrulamaktadır. Bu analizin ardından, modelimizin performansını daha da derinlemesine incelemek için Confusion Matrix metodunu kullanacağız. Bu metod modelimizin sınıflandırma tahminlerinin doğruluğunu gösterecektir.

E. Deneysel Veri Seti

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 performansını inceliyoruz.



Şekil 23. Sinirli Duygu İçin CM Modeli



Şekil 24. Tiksınme Duygusu İçin CM Modeli

"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.

Çizelge 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%

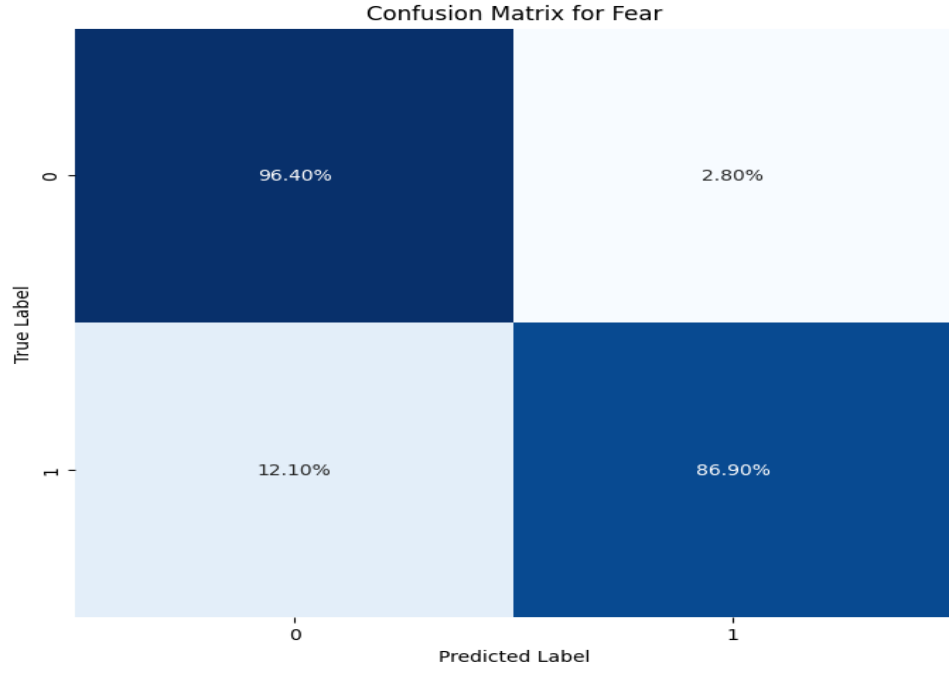
Her iki duygu için de modelin performansı oldukça etkileyicidir. Özellikle doğru negatif tahminlerdeki yüksek doğruluk oranları, modelin duyguları tespit edebilme kabiliyetini göstermektedir.

Çizelge 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%

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, 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 performansını incelendi.

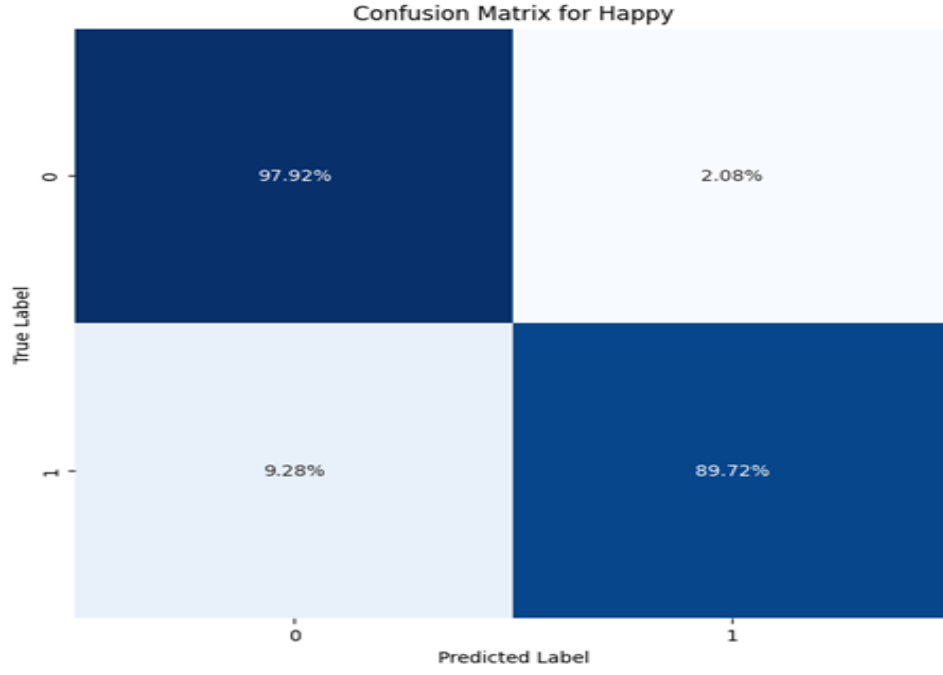


Şekil 25. Korku Duygusu İçin CM Modeli

Çizelge 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 görebiliriz.



Şekil 26. Mutluluk Duygusu İçin CM Modeli

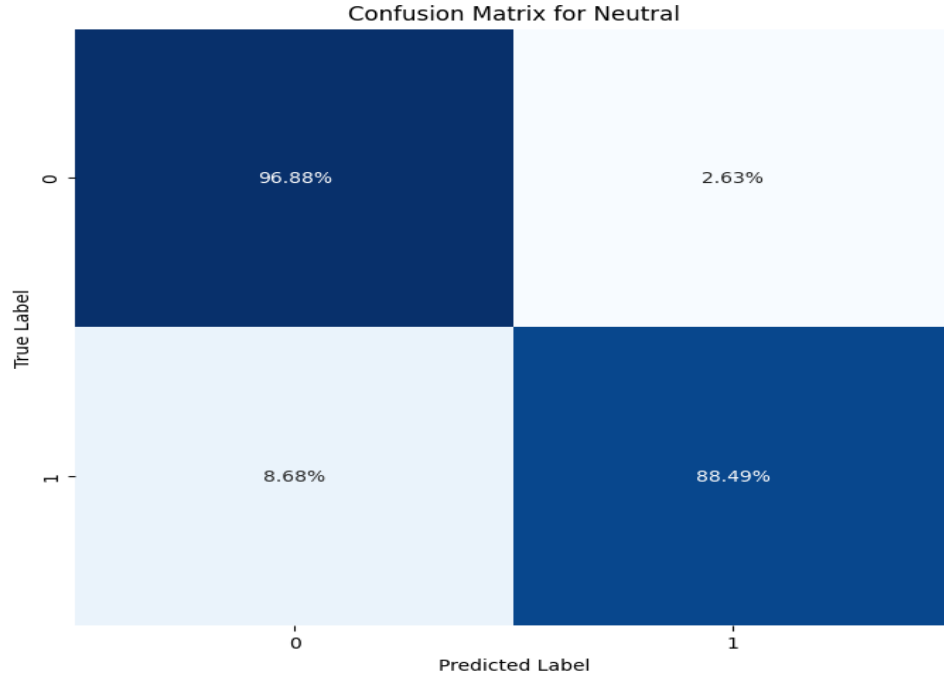
Çizelge 6. Mutluluk duygusu Karışıklık Matrisi

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.

Hem "Korku" hem de "Mutluluk" duyguları için modelin performansı oldukça etkileyicidir. Özellikle doğru negatif tahminlerdeki yüksek doğruluk oranları, modelin duyguları tespit edebilme kabiliyetini gösterir. Bu sonuçlar, modelin duygu tanıma konusunda yüksek bir güvenilirlikle çalışabileceğini gösteriyor. Modelin bu başarısı, doğru veri hazırlığı, etkili bir model mimarisi ve optimize edilmiş hiperparametrelerin birleşimi ile elde edilmiştir. Sonuç olarak duygu tanıma konusunda derin öğrenmenin gücünü ve potansiyelini gözler önüne sermektedir. Karışıklık Matrisi, bir sınıflandırma modelinin ne kadar etkili olduğunun görsel ve sayısal bir temsilidir. Bu bölümde, "Neutral" (Nötr), "Sad"

(Üzgün) ve "Surprise" (Şaşkın) duyguları için modelin performansını ayrıntılı olarak değerlendirildi.

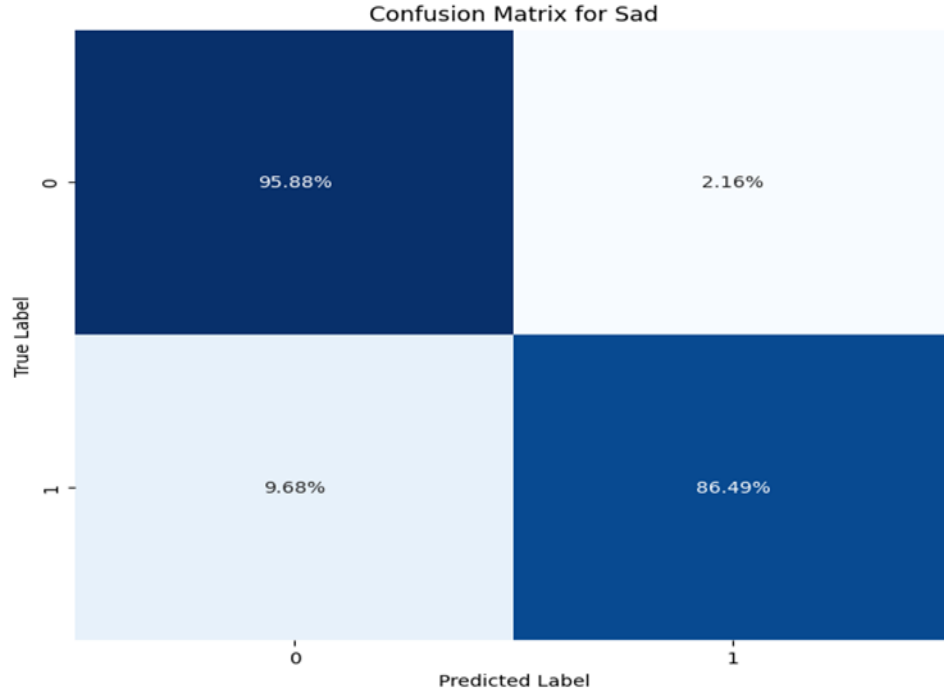


Şekil 27. Nötr Duygusu İçin CM Modeli

Çizelge 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 (%8,68) modelin bazı durumlarda nötr olmayan duyguları nötr olarak sınıflandırabileceğine işaret ediyor. Bununla birlikte, doğru pozitif değeri (%88,49), modelin nötr duyguları oldukça başarılı bir şekilde tespit edebildiğini gösterir.



Şekil 28. Üzgün Duygu İçin CM Modeli

Çizelge 8. Üzgün duygusu Karışıklık Matrisi

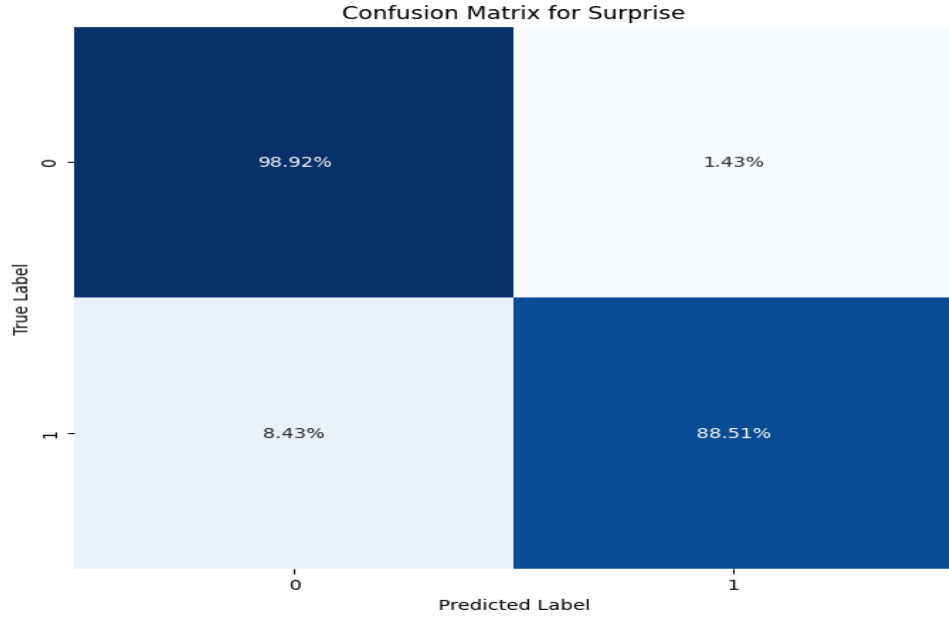
True Positive (TP)	86.49%
True Negative (TN)	95.88%
False Positive (FP)	2.16%
False Negative (FN)	9.68%

"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 gösterir.

"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.

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.



Şekil 29. Şaşkınlık Duygusu İçin CM Modeli

Çizelge 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%

VI. MATERYAL VE METOT DEĞİŞİMİ

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 Machine Learning 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 eder. Ardından, analiz sonucu elde edilen duygu durumu, Machine Learning tabanlı müzik öneri modeline iletilir.

A. Karışıklık Matris

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 çıkarımları yapabiliriz.

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.

B. Karışıklık matrisin (CM) performans incelemesi

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 sayısı. Bu, modelin doğru bir şekilde tespit ettiği ilgili sınıf örnekleridir.
- True Negative (TN): Modelin doğru bir şekilde negatif olarak sınıflandırdığı örnek sayısı. Bu, modelin doğru bir şekilde reddettiği diğer sınıf örnekleridir.
- False positive (FP): Gerçekte negatif olmasına rağmen modelin yanlışlıkla pozitif olarak sınıflandırdığı örnek sayısı. Bu, tip I hata olarak da adlandırılır.
- False negative (FN): Gerçekte pozitif olmasına rağmen modelin yanlışlıkla negatif olarak sınıflandırdığı örnek sayısı. 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.

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

Karıřıklık Matrisi'nin analizinde bu metriklerin tümünü dikkate almak, modelin gerek dnya verileri zerindeki performansını daha derinlemesine anlamamıza olanak tanır. zellikle, dengesiz veri setlerinde, sadece dođruluđun yksek olmasına aldanmamak iin bu metriklerin kombinasyonunu kullanmak esastır. Bu, bir sınıflandırma modelinin performansının gerekten ne kadar iyi olduđunu deđerlendirmede kritik bir adımdır.

VII. SONUÇLAR VE DEĞERLENDİRİLMESİ

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

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

güvenilirliđi, bu alandaki gelecekteki arařtırmalara ve uygulamalara yön veren bir temel oluřturmaktadır.

VIII. SONUÇLAR VE TARTIŞMALAR

Müzik, bireylerin duygusal, kültürel ve sosyal ifadesinin aracı 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 kullanıldı. 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 major tonalitesi gibi özelliklere sahip enerjik müzikler önerecektir. Öte yandan, eğer bir kullanıcı negatif bir duygusal durumda ise, daha düşük tempo ve minor 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.

IX. KAYNAKÇA

DERGİLER

- DE PRÍSCO, R., (2022). Induced Emotion-Based Music Recommendation through Reinforcement Learning. **Applied Sciences**, 12(21), 11209.(04.11.2022)
- 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.(26.12.2022)
- HE, J. (2022). Algorithm Composition and Emotion Recognition Based on Machine Learning. **Computational Intelligence and Neuroscience**.(06.06.2022)
- KA, S., (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.(05.04.2021)
- CONGZHENG S. (2017) Thomas Ristenpart, and Vitaly Shmatikov, "Machine Learning Models that Remember Too Much," in Proceedings of the 2017 **ACM SIGSAC Conference on Computer and Communications Security**, pp. 587-601, 2017.(30.10.2017)
- AMÍRA SAYED G, (2022) "A Review on Machine Learning Algorithms," in **International Journal of Computer Applications**, vol. 160, no. 12, pp. 1-11, 2022.(08.08.2022)
- A. MOSAVÍ, S. ARDABİLÍ, AND A. R. VÁRKONYI-KÓCZY,(2023) "List of Deep Learning Models," in **arXiv preprint arXiv:2311.13058**, 2023.(07.12.2023)

- GUPTA, B. B., AGRAWAL, D. P., AND YAMAGUCHI, S.(2021), "Deep learning models for human centered computing in fog and mobile edge networks," in **IEEE Wireless Communications**, vol. 28, no. 5, pp. 30-37, Oct. 2021.(15.10.2021)
- KOUKARAS, P., NOUSI, C., & TJORTJIS, C. (2022). Stock Market Prediction Using Microblogging Sentiment Analysis and Machine Learning. *Telecom*, 3(2). **MDPI**.(27.05.2022)
- ROSA, R. L., RODRÍGUEZ, 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.(13.10.2015)
- 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).(15.10.2022)
- CHIRASMAYEE, B. V. S., (2022). **Song Recommendation System Using TF-IDF Vectorization and Sentimental Analysis**.(16.06.2022)
- 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.(28.12.2020)
- DÜZBASTILAR, 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.(01.10.2019)
- 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.(04.01.2021)

- GÜNDÜZ, İ., & YILMAZ, Ö. (2021). Yüz İfadesini Algılayarak Kullanıcının Ruh Haline Göre İçerik Öneren Mobil Uygulama. **Avrupa Bilim ve Teknoloji Dergisi**, 28, 192-197.(30.11.2021)
- Yİ, S., & LİU, X. (2020). Machine Learning Based Customer Sentiment Analysis for Recommending Shoppers, Shops Based on Customers' **Review. Complex & Intelligent Systems**, 6(3), 621-634.(06.06.2020)
- SİAM, A. I.,. (2022). Deploying Machine Learning Techniques for Human Emotion Detection. **Computational Intelligence and Neuroscience**.(02.02.2022)
- WANG, J., & PEREZ, L. (2017). The Effectiveness of Data Augmentation in Image Classification **Using Deep Learning**.(13.12.2017)
- PARMİĞİANİ, G. (2020). Receiver Operating Characteristic Curves with an Indeterminacy Zone. **Pattern Recognition Letters**, 136, 94-100.(22.05.2020)
- QİU, H., & JİA, X. (2022). Western Music History Recommendation System Based on Internet-of-Things Data Analysis Technology. **Mobile Information Systems**, 2022, 8920599.(21.08.2022)
- SHORTEN, C., & KHOSHGOFTAAR, T.M. (2019). A survey on Image Data Augmentation for Deep Learning. **Journal of Big Data**, 6(1), 60.(06.07.2019)
- 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.(07.01.2022)
- 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. (06.06.2022)
- REYAD, M., SARHAN, A., & ARAFA, M. (2023). A modified Adam algorithm for deep neural network optimization. **Neural Computing & Applications**, 35, 17095–17112.(25.04.023)

- DÜNTSCH, I., & GEDİGA, G. (2019). Confusion matrices and rough set data analysis. In Proceedings of the 2019 **International Conference on Pattern Recognition and Intelligent Systems** (PRIS 2019).(04.02.2019)
- WU, M.T. (2022). Confusion matrix and minimum cross-entropy metrics based motion recognition system in the classroom. **Scientific Reports**, 12, 3095.(23.02.2022)
- GÖRTLER, J., HOHMAN, F., MORİTZ, D., WONGSUPHASAWAT, K., REN, D., NAİR, R., KİRCHNER, 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).(17.02.2022)
- YİK, M., WİDEN, S., & RUSSELL, J. (2013). The within-subjects design in the study of facial expressions. **Cognition & Emotion**, 27.(08.02.2013)

ELEKTRONİK KAYNAKLAR

- URL-1 <https://paperswithcode.com/dataset/fer2013>.
- URL-2 <https://www.freepik.com/photos/man-video-call>
- URL-3 <https://khoahoc.tv/phat-hien-loi-ich-khong-ngo-cua-su-tuc-gian-55770>
- URL-4 <https://ar.europeanwriterstour.com/images-2023/happy-face-expression>
- URL-5 [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)
- URL -6 <https://stock.adobe.com/tr/search/images?k=neutral+faces>
- URL-7 <https://www.psypost.org/2019/07/anxious-people-are-more-successful-in-escaping-from-virtual-predators-study-finds->
- URL-8 <https://www.istockphoto.com/tr/foto%C4%9Fraf/young-woman-making-a-frightened-face-expression-gm174756630-21662121>

ÖZGEÇMİŞ

ÖĞRENİM DURUMU:

Lisans: 2019, İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

**TEZDEN TÜRETİLEN YAYINLAR,
SUNUMLAR VE PATENTLER:**

ALİYEV H. , GÜNEŞ P. 2023 Makine öğrenme algoritmalarını kullanan
duygu tahminine dayalı müzik öneri sistemi

Applied in Istanbul Aydın University, Dergipark