



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**COVID-19 SERVİSLERİNDE GÖREV YAPAN
SAĞLIK ÇALIŞANLARININ SES
SİNYALLERİNDEN OLASI
ANKSİYETELERİNİN MAKİNE ÖĞRENMESİ
YÖNTEMİ
İLE BELİRLENMESİ**

Mehmet YİĞİT

YÜKSEK LİSANS TEZİ

Prof. Dr. Kemal TURHAN

TRABZON-2023

İthaf

Bu yüksek lisans tezimi, benim bu günlere gelmem için hiçbir fedakârlıktan kaçınmayan ve her zaman yanımda olan eşim Hilal Yiğit'e ve sevgili aileme ithaf ediyorum.



İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

ONAY

BEYAN

İthaf

TEŞEKKÜR

İÇİNDEKİLER

vi

TABLolar DİZİNİ

ix

ŞEKİLLER DİZİNİ

x

RESİMLER DİZİNİ

xi

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

xii

ÖZET

xiv

ABSTRACT

xv

1. GİRİŞ ve AMAÇ

1

2. GENEL BİLGİLER

4

2.1. COVID-19 Pandemisi

4

2.2. Anksiyete ve COVID-19 Pandemisi

5

2.2.1. Toplum Yönünden Anksiyete ve COVID-19 Pandemisi

6

2.2.2. Sağlık Çalışanları Yönünden Anksiyete ve COVID-19 Pandemisi

7

2.3. Makine Öğrenmesi ve Ses Verilerinin İlişkisi

7

2.3.1. Yapay Zekâ

7

2.3.2. Makine Öğrenmesi

8

2.4. Görüntü Verisi ve Duygu Çıkarımı

11

2.5. Derin Öğrenme (Deep Learning)

11

3. GEREÇ ve YÖNTEM

14

3.1. Veri Toplama Araçları

14

3.1.1. Durumluk- Sürekli Kaygı Ölçeği (DSKÖ)(State- Trait Anxiety Inventory- STAI) 14

3.1.2. Ses Analizi için Kullanılan Sorular	14
3.1.3. Anket Formu	15
3.2. Ses Verilerinin Düzenlenmesi	15
3.3. Ses Verilerinin Sınıflandırması	16
3.4. Ses Verilerini İşleme Yöntemleri	17
3.4.1. Fourier Dönüşümü	17
3.4.2. Spektogram	19
3.4.3. Mel Spectogram	19
3.4.4. Mel-Frekans Kepstral Katsayıları (MFCC)	20
3.5. Görüntü Verilerini Sınıflandırma Yöntemleri	21
3.5.1. CNN (Convolutional Neural Network)	21
3.5.2. AlexNet	23
3.5.3. VGG-19 ve VGG-16	23
3.5.4. ResNet	23
3.6. Ses ve Görüntü Verilerini İşleme Sırasında Kullanılan Uygulamalar	24
3.6.1. Pycharm	24
3.6.2. Jupyter Notebook	24
3.6.3. Google Colab	24
3.7. Verilerin Toplanması	24
3.8. Verilerin İşlenmesi	25
3.9. Çıktıları Sınıflandırmak için Tasarlanan CNN Yapısı	26
3.9.1. Veri Setinin Boyutu	26
3.9.2. Mini Batch Boyutu	26
3.9.3. Learning-rate	26
3.9.4. Epoch	26
3.9.5. Aktivasyon Fonksiyonları	27
3.9.6. CNN’de Kernel Boyutu	27

3.9.7. ResNet, AlexNet ve VGG-16 Yapısı	30
3.10. Verilerin Analizi	38
4. BULGULAR	40
4.1. Sağlık Çalışanlarının Anket Formuna Yönelik Bulguları	40
4.1.1. Sağlık Çalışanlarının Tanımlayıcı İstatistikleri	40
4.1.2. Sağlık Çalışanlarının DSKÖ'ye Yönelik Tanımlayıcı İstatistikleri	41
4.1.3. Sağlık Çalışanlarının Tanımlayıcı Özelliklerine Göre Karşılaştırmalar	42
4.2. Sağlık Çalışanlarının Ses Verilerine Yönelik Bulguları	47
4.3. Sağlık Çalışanlarının Makine Öğrenmesine Yönelik Bulguları	47
5. TARTIŞMA ve SONUÇ	57
6. KAYNAKLAR	62
EKLER	71
Ek-1: Veri toplama formu	72
Ek-2: Ses yanıtı soruları	75
Ek-3: Durumluk ve Sürekli Kaygı Ölçeği (DSKÖ)	77
Ek-4: Bilgilendirilmiş gönüllü olma formu	79
EK-5: Etik kurul onayı	80
Ek-6: Kurum izni	81
Ek-7: Ölçek izni	82
	83

TABLÖLAR DİZİNİ

Tablo No		Sayfa
Tablo 1.	1D CNN veri seti dağılımı	28
Tablo 2.	1D CNN veri seti dağılımı (Ham test verisi)	28
Tablo 3.	Eğitim ve test modelleri	30
Tablo 4.	Korelasyon katsayıları ve güç ilişkisi	39
Tablo 5.	Sağlık çalışanlarının demografik bilgileri	40
Tablo 6.	DSKÖ puanlarına ilişkin tanımlayıcı istatistik sonuçları	41
Tablo 7.	DSKÖ puanları arasındaki korelasyon sonuçları	42
Tablo 8.	Yaş ile DSKÖ puanları arasındaki korelasyon sonuçları	42
Tablo 9.	COVID-19 (+), tanısı alma ile DSKÖ puanlarının karşılaştırılması	43
Tablo 10.	Cinsiyete göre DSKÖ puanlarının karşılaştırılması	43
Tablo 11.	Çalışılan bölüme göre DSKÖ puanlarının karşılaştırılması	44
Tablo 12.	COVID-19 hastalarının bakımına katılım ile DSKÖ puanlarının karşılaştırılması	45
Tablo 13.	Formu doldurma yerine göre DSKÖ puanlarının karşılaştırılması	45
Tablo 14.	Mesleğe göre DSKÖ puanlarının karşılaştırılması	46
Tablo 15.	Duygu modelini eğitirken farklı hiper parametreler ve doğruluk oranları	47
Tablo 16.	Anksiyete modelini eğitirken farklı hiper parametreler ve doğruluk oranları	49
Tablo 17.	Duygu analizinde farklı CNN algoritmalarının doğruluk ve hata oranları	52
Tablo 18.	Anksiyete analizde farklı CNN algoritmalarının doğruluk ve hata oranları	53
Tablo 19.	Duygu model çıktıları (Ham test verisi)	53
Tablo 20.	Anksiyete model çıktıları (Ham test verisi)	54
Tablo 21.	Sınıflandırıcı model çıktıları (Duygu)	55
Tablo 22.	Sınıflandırıcı model çıktıları (Anksiyete)	55
Tablo 23.	En başarılı modellerin sınıflandırıcı model çıktıları (Duygu-Anksiyete)	56

ŞEKİLLER DİZİNİ

Şekil No		Sayfa
Şekil 1.	Yapay zekâ ve gelişimi	8
Şekil 2.	Modelin karmaşıklığı	9
Şekil 3.	K Katlamalı Çapraz Doğrulama	10
Şekil 4.	Eğitim modelinde Bias ve Varyans	10
Şekil 5.	Plutchik Duygu Çarkı	12
Şekil 6.	Russell'e göre 25 Türkçe duygu ifadesinin iki boyutlu modeli	13
Şekil 7.	Örnek ses verisi toplama formu	15
Şekil 8.	Ses verilerinin Audacity programındaki görüntüsü	16
Şekil 9.	Ses verilerinin kaydedilme biçimi	17
Şekil 10.	Zaman boyutunda Fourier Dönüşümü	17
Şekil 11.	Zaman boyutunda Fourier Dönüşümü	18
Şekil 12.	Sekiz noktalı DFT'nin zamanda desimasyon ile iki adet dört noktalı DFT'ye ayrıştırılması	19
Şekil 13.	Spektogram	19
Şekil 14.	Mel Spectogram	20
Şekil 15.	Mel-Frekans Kepstral Katsayıları ile insan sesinin gösterimi	20
Şekil 16.	Çalışma için tasarlanan duygu çıkarımı modeli	21
Şekil 17.	Softmax yöntemi ile duygu çıkarımı	23
Şekil 18.	Dönüşüm için geliştirilen Python uygulaması	25
Şekil 19.	Geliştirilen programın Melspectogram çıktıları	25
Şekil 20.	Bir sinir hücresi ile Aktivasyon Fonksiyonu arasındaki benzerlik	27
Şekil 21.	Bir boyutlu (1D CNN) modeli	29
Şekil 22.	Farklı CNN yapıları ve katmanları	37

RESİMLER DİZİNİ

Resim No	Sayfa
Resim 1. Matplotlib ile resimlerin etiketlerine göre gösterimi	31
Resim 2. Anksiyete sınıflandırma gruplarının gösterimi	31
Resim 3. Kategorilerine göre Melspectogramların görselleri	32
Resim 4. Spectogramlardaki kırmızı renk dağılımı	32
Resim 5. Spectogramlardaki mavi renk dağılımı	33
Resim 6. Beyaz Ölçekli Görüntü Kenar Algılama	33
Resim 7. Gri Ölçekli Görüntü Kenar Algılama	34
Resim 8. HOG algoritması ile özellik çıkarımı	34
Resim 9. SIFT uygulaması özellik çıkarımı	35
Resim 10. Gri Ölçekli SIFT uygulaması özellik çıkarımı	35
Resim 11. ResNet Datagen yapısı	36
Resim 12. VGG Datagen yapısı	36
Resim 13. AlexNet Datagen yapısı üzerinde rastgele verilerin görüntüleri	36
Resim 14. Modelin Doğruluğu epochs=50, batch_size=128'da %63.7'dir. Hata oranı 1.59'dur.	50
Resim 15. 1 boyutlu CNN yapısı ile oluşturulmuş duygu tanımlama modelinin karmaşıklık matrisi	50
Resim 16. Modelin Doğruluğu epochs=100, batch_size=128'da %73.5'dir. Hata oranı 1.59'dur.	51
Resim 17. 1 boyutlu CNN yapısı ile oluşturulmuş anksiyete tanımlama modelinin karmaşıklık matrisi	51
Resim 18. Anksiyete analizinde 100 Epoch değerinde ResNet50 modelinin doğruluk ve test grafiği	52

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

Kısaltmalar

AIDS	Acquired Immune Deficiency Syndrome
CNN	Konvolüsyonel Sinir Ağı (Evrışimli Sinir Ağı)
COVID-19	Coronavirus Disease 2019 (Koronavirüs hastalığı 2019)
CREMA-D	Crowd Sourced Emotional Multimodal Actors Dataset
DFT	Ayrık Fourier Dönüşümü (Discrete Fourier Transform)
DL	Derin Öğrenme (Deep Learning)
DSA	Derin Sinir Ağı
DSKÖ	Durumluk ve Sürekli Kaygı Ölçeği
DSM-IV	Diagnostic and Statistical Manual of Mental Disorders
DSÖ	Dünya Sağlık Örgütü
DVM	Destek Vektör Makinaları
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FN	Yanlış Negatifler
FP	Yanlış Pozitifler
FT	Fourier Transform (Fourier Dönüşümü)
HIV	Human Immunodeficiency Virus (İnsan Bağışıklık Yetmezliği Virüsü)
HOG	Yönlendirilmiş Degradelerin Histogramı (Histogram of Oriented Gradients)
IDE	Integrated Development Environment (Tümleşik Geliştirme Ortamı)
KA	Karar Ağaçları (Decision Tree)
KNN	En Yakın K Komşu Algoritması (K-Nearest-Neighbor)
LR	Lojistik Regresyon
MFCC	Mel-Frekans Cepstral Katsayıları (Mel-Frequency Cepstral Coefficients)
ML	Makine Öğrenmesi (Machine Learning)
MLP	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
NB	Naive Bayes Sınıflandırma Algoritması
NN	Sinir Ağı (Neural Network)
ReLU	Rectified Linear Unit

RF	Rastgele Orman (Randeom Forest)
RGB	Kırmızı-Yeşil-Mavi (Red-Green-Blue)
RNN	Tekrarlı Sinir Ağları (Recurrent Neural Networks)
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SIFT	Scale Invariant Feature Transform(Ölçek Değişmez Unsur Dönüşümü)
TN	Doğru Negatifler
TP	Doğru Pozitifler
VGG	Visual Geometry Group (Görsel Geometri Grubu)

Simgeler

β	Bağımsız değişken katsayı
ε	Hata değeri
n	Örneklem büyüklüğü
π	Olasılık
p	Olasılık değeri
R	Belirtme katsayısı
r	Korelasyon katsayısı
Y	Bağımlı değişken
X	Bağımsız değişken
$\mathbf{x}$	Bağımsız değişkenler vektörü
$\int$	İntegral
∞	Sonsuz
$\sim$	Yaklaşık

ÖZET

COVID-19 Servislerinde Görev Yapan Sağlık Çalışanlarının Ses Sinyallerinden Olası Anksiyetelerinin Makine Öğrenmesi Yöntemi ile Belirlenmesi

Ruh sağlığı alanında bireyler değerlendirilirken genellikle nitel yöntemlerden yararlanılmaktadır. Bu sorular ayrıntılı ve uzun olmakla birlikte nitel soru-cevap şeklinde ilerlediği için bazen yanlış yönlendirmelere neden olabilmektedir. Pandemide COVID-19 hastalığına doğrudan maruz kalan sağlık çalışanları da kendilerini tehdit altında hissetmeye başlamıştır. Anksiyete, kaygılı ve tehdit altında hissedildiğinde vücudun doğal bir tepkisidir. Anksiyete, duygu, düşünce ve fiziksel durumu etkilemektedir. Bu çalışma, ses verisiyle elde edilen çıktıların, anksiyetenin tanılanma sürecinin şekillendirilmesinde, sağlık profesyonellerine yardımcı olması amacıyla yürütülmüştür. Anksiyetenin tespiti için Durumluk-Sürekli Kaygı Ölçeği (DSKÖ) (State- Trait Anxiety Inventory- STAI) kullanılmıştır. Katılımcılar, Ordu ilinde COVID-19 pandemi kliniklerinde aktif olarak görev alan 30 sağlık çalışanı ile COVID-19 pandemi kliniklerinde aktif olarak görev almayan 30 sağlık çalışanından randomize olarak seçilmiştir. Phonic.ai aracılığı ile beş adet sözel soruya sesli yanıt ve ardından DSKÖ'ye yanıtlar alınmıştır. DSKÖ verilerinin analizinde SPSS paket programları kullanılmış olup analiz sonucunda Acil Servis'te çalışan sağlık çalışanlarında durumluk kaygı düzeyleri anlamlı olarak yüksek bulunmuştur. Sesli yanıtlardan makine öğrenmesi algoritmaları oluşturabilmek için Python yazılım dili kullanılmıştır. Tasarlanan algoritmalar ile çıktılar elde edilmiştir. DSKÖ'nün çıktıları ile makine öğrenmesi yönteminin çıktıları karşılaştırılmıştır. Modeller karşılaştırıldığında (VGG-19, ResNet50, AlexNet) en başarılısı 1D(boyutlu) CNN (konvolüsyonel sinir ağı) tabanlı model olmuştur. Modelin duygu analizinde; doğruluk %63.7 (%63 hassasiyet, %91 özgüllük) anksiyete analizinde ise doğruluk %73.5 (%73 hassasiyet, %94 özgüllük) saptanmıştır. Bu sonuçlar doğrultusunda geliştirilen modelin gelecek çalışmalarda görüntü ve video kaydı gibi yöntemlerle desteklendiğinde başarısının artacağı düşünülmektedir.

Anahtar Kelimeler: Anksiyete, COVID-19, Makine Öğrenmesi, Sağlık Bilişimi, Uzman Sistemler

ABSTRACT

The Determination of Possible Anxiety by Machine Learning Method From Sound Signals Healthcare Staff Members Who Work at COVID-19 Clinics

Qualitative methods are generally used when evaluating individuals in the field of mental health. Although these questions are detailed and long, they can sometimes lead to false guidance because they proceed in a qualitative question-answer form. Health workers directly exposed to the COVID-19 disease during the pandemic have also started to feel threatened. Anxiety is a natural response of the body when one feels anxious and threatened. Anxiety affects emotions and thoughts as well as physical state. This study was conducted to assist healthcare professionals in the process of identifying anxiety by using output obtained from voice data. The State-Trait Anxiety Inventory (STAI) was used to measure anxiety levels. The participants were randomly selected from 30 healthcare workers actively serving in COVID-19 pandemic clinics and 30 healthcare workers not actively serving in COVID-19 pandemic clinics, all located in Ordu province. five verbal questions were asked via Phonic.ai and answers were obtained through voice responses, followed by answers to the STAI. SPSS package programs were used for the analysis of STAI data, and the results showed that the state anxiety levels of healthcare workers working in the emergency department were significantly higher. To create machine learning algorithms from voice responses, Python programming language was used. The outputs of the State-Trait Anxiety Inventory (STAI) were compared with the outputs of the machine learning method. When the models were compared (VGG-19, ResNet50, AlexNet), the most successful one was found to be the 1D (dimensional) CNN (convolutional neural network) based model. In the emotion analysis of the model, an accuracy of 63.7% (63% sensitivity, 91% specificity) was achieved, while in the anxiety analysis, an accuracy of 73.5% (73% sensitivity, 94% specificity) was found. Based on these results, it is believed that the model developed will be more successful when supported by methods such as image and video recording in future studies.

Key Words: Anxiety, COVID-19, Expert Systems, Machine Learning, Medical Informatics

1. GİRİŞ ve AMAÇ

Ses, dilin işlevsel en küçük birimini oluşturur. Dil, insanlığın hislerini birbirine anlatmada kullanılan en önemli araçlardandır. İnsanlar doğuştan bu yetenekle dünyaya gelmektedir. Mesela bir ses duyarız, yüzünü bile görmeden anlamadığımız bir dilde konuşan bir kişinin nasıl bir ruh haline sahip olduğunu yaşını cinsiyetini hatta fiziksel özelliklerini tahmin edebiliriz (1-3). Her sesin kişiye veya o sesi çıkaran canlıya özgü bir frekans ve ağırlığı vardır. İnsan sesi, karakteri itibariyle duygu verisini de içermektedir. Ses içerisindeki duygu yüklü anlam insanlar tarafından algılanabilmektedir. Günümüzde popülerleşen makine öğrenmesi yöntemleri ise bu alanda yeni gelişim göstermektedir. Ses verileri, metinlerden elde edilen verilere göre daha etkilidir. İnsan-makine etkileşimi daha da kuvvetlenebilmesi için makinelerin, insan duygularını da öğrenmesi gerekmektedir (4, 5).

Son yıllarda yapılan birçok çalışmada ses verisi yaygın olarak kullanılmaktadır. Plutchik'e göre insani duygular 8 temel bölümde incelenmektedir; üzüntü, öfke, beklenti, şaşkınlık, tiksime, korku, güven ve sevinç. Daha sonra bu 8 temel duyguyu, 3'lü alt bölümlere ayırmıştır. Bunu da bir çarkıfelek (Duygu Çarkıfeleği) şeklinde görselleştirmiştir (6). Mevcut literatürde yer alan çalışmalarda ses verileri Mel spectrogram'a çevrilip görüntü verisi olarak işlenmektedir. Görüntü verileri mevcut kütüphanelerden (RAVDESS, SAVEE, CREMA-D, TESS, EMODB gibi) eğitilmiş bir yöntem kullanılarak yapay sinir ağına (YSA) yüklenilerek bu YSA' dan bir duygu çıkarımı yapılmaktadır (7-9).

SARS CoV-2 (Severe Acute Respiratory Syndrome Coronavirus 2) 'nin hayvanlardan insanlara geçiş yapmayı başardığı varsayılmaktadır. COVID-19 (Coronavirus Disease-19)'un fark edilmesini sağlayan ilk klinik belirti pnömonidir ve bağışıklık sistemi zayıf, yaşlı bireylerde daha sık gözlenmektedir. Özellikle küçük çocuklar arasında gastrointestinal semptomları yaygın görülürken, bazı vakalarda ise asemptomatik olarak enfeksiyon geçirildiği görülmüştür (10). Bu süreçte COVID-19 testi pozitif(+) çıkan sağlık profesyoneli sayısının 120 bini geçtiği, 216 sağlık profesyonelinin de COVID-19 sebebiyle yaşamını yitirdiği bildirilmiştir (11). COVID-19 pandemisi tüm dünya genelinde bireylerde genel bir endişe haline neden olmuştur. Özellikle COVID-19'un en karanlık yanıyla yüzleşen taraf sağlık çalışanlarıdır. Bu süreçte ön saflarda görev alıp tedavi ve bakımı gerçekleştirirken risk altında olan sağlık çalışanları için genel endişe durumu belirgin bir hal almıştır (12).

Ses verisinden duygu analizi yöntemiyle birçok çalışma literatürde yer almaktadır. Bunlar %65-90 oranında doğru tahminde bulunmaktadır. SVM (Support Vector Machine),

K-En Yakın Komşu Algoritması (KNN- K Nearest Neighbors Algorithm) gibi birçok yöntem ile değişik başarı oranları yakalanmıştır (13, 14). Bu geliştirilecek olan makine öğrenmesi sistemi ile anksiyetenin ses verisinden tanılanmasının başarı oranı değerlendirilecektir. Ayrıca anksiyetenin tanılanmasında kullanılan geleneksel yöntemlere ek olarak geliştirilen bu yöntemle tanılama sürecinin daha verimli olacağı öngörülmektedir. Duygular en iyi konuşma vasıtasıyla karşı tarafa iletilmektedir. Ruhsal hastalıkların oluşumunun temelinde duygu durum değişiklikleri ana etmenlerden birisidir. Zhao ve ark. (2019), 2D CNN-Long Short-Term Memory (LSTM) yapısının kullanıldığı çalışmada konuşan bir kişinin verilerine ait sınıflandırmada % 95.33, duyguya bağlı sınıflandırmada % 95.89 oranla doğruluk yakalanmıştır (15). Demircan ve Örnek (2020), MFCC (Mel-Frequency Cepstral Coefficients) aracılığı ile çıkarılan görüntüler SVM ve KNN sınıflandırma yöntemleri ile sınıflandırıldığında %92.86 doğruluk oranına ulaşılmıştır (16). Er (2020), tarafından yapılan çalışmada hazır veri seti ile nitelikleri belirlenmiş VGG-16 yöntemi ile sınıflandırıldığında %85.37 doğruluk performansı göstermiştir. Makine öğrenmesi yöntemlerinin duyguları sınıflandırmada başarılı olduğu kanıtlanmıştır (17). Ruhsal hastalıkları tanılama sürecinde, klinisyenler için geliştirilmiş el kitabı (The Diagnostic and Statistical Manual of Mental Disorders, Fourth Edition-DSM-IV) ve klinik hasta görüşmesi en sık kullanılan yöntemlerdir (18). Yapılan çalışmalar ikili görüşme veya nitel/nicel sorulardan oluşan formlar şeklindedir. Türkçapar (2004), anksiyete ve depresyon tanısının konulabilmesi için birinci basamak sağlık hizmetlerinde kullanılmak üzere geliştirilmiş olan Prime-MD formunu hastanın doldurması ve belirtilerin var olduğu gözlemlenen hastalar ile detaylı görüşme sonrasında tanı netleştirilmektedir (19). McGinnis ve ark. tarafından 2019’ da içselleştirme sorunları olan küçük çocukları belirlemek için yapılan çalışmada 3’er dakikalık ses kayıtlarından toplanan verilerle içselleştirme bozukluğunun tespiti için oluşturulan makine öğrenmesi modeliyle başarı oranları; %80 doğruluk ve %54 hassasiyet, %93 özgüllük şeklinde ortaya konmuştur. İçselleştirme sorunları olan çocukların ses özellikleri genellikle daha düşük ses tonu, tekrar eden cümle vurguları ve uyaranlara karşı yüksek tondan tepki verme ile karakterizedir (20). Tansim ve ark. (2022) konuşmadan depresyon-anksiyete tespiti için bir yapı oluşturmaya odaklanmışlar ve makine öğrenmesi sistemlerinin geliştirilebilmesi için veri setinin zengin, algoritmanın dengeli bir yapıda olması gerektiğini savunmuşlardır. Yapılan çalışmada, depresyon-anksiyete standart tarama araçlarında belirlenmiş standartlarına dayanarak etiketlenmiş mental rahatsızlık analizi, ses veri kümesi olarak tanıtılmaktadır. Bu veri kümesi, her birey

iin demografik bilgileri ve birden fazla konuřma grevini ierir. Ayrıca, insan konuřmasındaki zihinsel hastalık iřaretlerini belirlemeyi amalar. Son olarak, bu veri kmesi zerinde yapılan temel makine ğrenmesi modellerinin performansı diğeri iyi bilinen depresyon-anksiyete iin eğitilmiş temel modellerle, nerilen ses ve veri kmesinin kalitesi ve etkinliğı karřılařtırıldığında depresyon řiddetini tahmin etmede başarılı olduğı ne ıkmaktadır (21). Literatrdeki alıřmalarda grldğ zere makine ğrenmesi algoritmaları genellikle mental-ruhsal durum tespiti iin yardımcı olarak kullanılmaktadır.

Bu alıřmanın ana amacı; saėlık alıřanlarının, hasta ve hasta yakınlarının ortama baėlı deėiřen duygu durum deėiřikliklerinin gnlk yařamda doėal olarak kullanılan sesli iletiřim aracılığı ile tespit edilebilmesi halinde, oluřabilecek olumsuz duygu durum deėiřiklikleri ve gvenlik sorunlarını nleyebilecek uygulamaların geliřtirilebileceğini ortaya koymaktır.

2. GENEL BİLGİLER

2.1. COVID-19 Pandemisi

Bir bulaşıcı hastalık küresel bir hale dönüşürse bu pandemi olarak tanımlanır. 1918 yılında İspanyol Gribi dünya nüfusunun üçte birinden fazlasına bulaşan ve yaklaşık 50 milyon insanın ölümüne neden olan influenza türünün en ünlü örneğidir. Diğer örnekler arasında 14. yüzyılda Avrupa'da Hıyarcıklı Veba (Kara Veba), 2003 yılında Şiddetli Akut Solunum Sendromu (Severe Acute Respiratory Syndrome-SARS) virüsü ve HIV/AIDS (Human Immunodeficiency Virus-İnsan Bağışıklık Yetmezliği Virüsü/ Acquired İmmune Deficiency Syndrome- Edinsel Bağışıklık Yetmezliği Sendromu) bulunmaktadır. Bir hastalığın ne kadar yayılacağını etkileyen birçok faktör vardır. Bunlardan iki tanesi önemli olup birincisi hastalığın bir kişiden diğerine bulaşma hızı ve diğeri ise mortalitesidir (22).

Aralık 2019'da Çin'in Hubei Eyaleti'nin Wuhan kentinde kaynağı bilinmeyen bir zatürre salgını duyulmaya başlandı. Vakalar genellikle Huanan deniz ürünleri, toptan satış pazarı ile ilişkilendirildi. Yapılan çalışmalar sonucu genom analizi, SARS-CoV ile ilişkili yeni bir koronavirüs türü olan ve bu nedenle Şiddetli Akut Solunum Sendromu Koronavirüs 2 (Severe Acute Respiratory Syndrome Coronavirus 2-SARS-CoV-2) olarak isimlendirilen yeni bir solunum virüsünün varlığı ortaya çıktı. SARS-CoV-2, Sarbecovirus alt cinsine ait bir beta-koronavirüstür. SARS-CoV-2'nin küresel yayılımı ve COVID-19 hastalığının neden olduğu binlerce ölüm, Dünya Sağlık Örgütü (DSÖ) tarafından 12 Mart 2020'den itibaren bir pandemi olarak ilan edilmesine sebep olmuştur (23).

COVID-19 hastalığının vaka olarak fark edilmesini sağlayan ve insanları etkileyen ilk belirtisi pnömonidir. Daha sonrasında çıkan raporlarda ise çocuklarda özellikle gastrointestinal sisteme yönelik sendromlar olduğu ve birçoğunda semptom göstermeden hastalığı geçirdiği tanımlanmaktadır. Genellikle yapılan gözlemler sonucunda ortalama kuluçka süresinin 5-7 gün sürdüğü, medyan kuluçka süresinin 3 gün sürdüğü gözlemlenmiştir. Semptomatik olarak geçiren bireylerde semptomlar üst solunum yolları hastalığı ile benzerlik göstermektedir. Başlıca semptomlar ateş, burun tıkanıklığı, öksürük, yorgunluk gibi belirtilerdir. Enfeksiyon bazı bireylerde akciğer tutulmaları gösterir. Bu belirtiler ciddi nefes darlığı ve pnömoni ile doğrudan ilişkili olup hastalığın ikinci veya üçüncü haftasında gözlenmektedir. Bu belirtiler sonucunda hastaların kandaki oksijen seviyeleri düşer, kan değerlerinde bozulmalar gözlenebilir. Bu bozulmalar sonrasında

hastaların dışarıdan oksijen ihtiyacı artmaktadır. Bazı hastaların solunum cihazına bağlanması gereken durumlar da gözlemlenmiştir (10).

Bulaşıcı hastalıklar ve ortam değişikliği güvensizliğin önemli sebeplerindendir. Hastalığın nedeninin bilinmemesi, ilerlemesinin kötü olması ve sonuçlarının belirsiz olduğu durumlarda, söylentiler artar ve bireylerde içe kapanık tutumlar ortaya çıkar. SARS salgınının meydana geldiği dönemlerde, insanlarda kaygı düzeyi önemli ölçüde arttı. Hong Kong'da insanların yaklaşık %70'i hastaneye yatmaktan endişe duyduklarını ifade etmişlerdir. Bu durumun sebebi olarak SARS'a yakalanma ihtimalinin soğuk algınlığına yakalanma olasılığından daha fazla olmasıdır. Anksiyete ve korku ile ilgili enfeksiyonlar ayrımcılık eylemlerine yol açabilir. COVID-19 pandemisinde Wuhan'dan gelenler hedef alınmış ve Çinliler bu süreçte o zamandan beri uluslararası alanda damgalanmıştır. Çin virüsü, Wuhan virüsü ve Yeni Sarı Tehlike gibi terimlerin medya tarafından kullanılması Çinlilerin dışlanmış hissetmesine sebep olmuştur (24).

2.2. Anksiyete ve COVID-19 Pandemisi

Çin, 2019 yılında COVID-19 salgınından etkilenen ilk ülke oldu. SARS-CoV-2'nin neden olduğu salgın, Çin'in COVID-19 salgın modellerinin birkaç benzersiz özelliği ve yönetim politikası ile artan bir halk ruh sağlığı krizine yol açtı. Birincisi, pek çok Çinli hala 2003 yılının SARS salgınının Çin'in sosyal hayatı ve ekonomisi üzerindeki etkisini hatırlamaktadır. COVID-19, SARS'tan daha bulaşıcıdır ve vaka-ölüm oranı (%2.3) SARS virüsünden önemli ölçüde daha yüksektir. Bu oran mevsimsel grip için ise %2.0 olduğu varsayılmaktadır. Virüsün belirsiz kuluçka süresi ve olası asemptomatik bulaşması, ek korku ve endişeye neden olmaktadır. İkincisi, hükümetin salgını ilk başta küçümsemesi ve ciddiye almaması halkın hükümetin karar alma şeffaflığına ve yetkinliğine güvenini sarstı. Üçüncüsü, benzeri görülmemiş büyük ölçekli karantina önlemleri halkın büyük şehirlerde kendi evlerine hapsolmasına ve olumsuz bir psikososyal etkiye neden olmuştur. Dördüncüsü, tıbbi koruyucu malzeme, tıbbi ekipman ve sağlık hizmeti yetersizliği salgının yayılmasını hızlandırdığı ve halkın sağlık sistemine olan güvenini azalttığı söylenmektedir (25).

Özsoy ve Kutlu (2019) tarafından yapılan çalışmada sağlık çalışanı olmayan kişilerin COVID-19 sonrası sağlık anksiyetesi ve anksiyete düzeyleri incelenmiştir. Elde edilen sonuçlarda; çalışmaya katılan katılımcıların %50'den fazlasının yüksek düzeyde durumluk ve sürekli kaygı hissettiği ortaya konmuştur. Sağlıkları üzerindeki endişelerinin ise eskiden

olduđuna gre bir farklılık gstermediđi gzlemlenmiřtir. COVID-19 gibi bulařıcı hastalıkların olduđu dnemlerde psikiyatrik semptomların meydana gelmesi ngrlen bir durumdur. Literatrde bulařıcı hastalıkların insanların ruhsal sađlıkları zerine etkilerini inceleyen birok alıřma mevcuttur. Yapılan bir meta analiz alıřmasında depresyon ve anksiyete ile ilgili belirtilerin %16-28 arasında pandemi dneminde grldđ, aynı alıřmada strese bađlı uyku bozukluklarının da %8 oranında pandemi dneminde grldđ bildirilmiřtir. evrimii yapılan bir alıřmada ise sađlık alıřanı olmayan bir rneklem grubunda %28.8 oran ile orta seviye anksiyete, %16.5 oran ile depresif bulgular tespit edilmiřtir. Sađlık alıřanlarında yapılan alıřmada ise Beck Anksiyete leđi (BA) ve Beck Depresyon leđi (BD) kullanılmıřtır. BA iin %20.1 anksiyete, BD iin %12.7 depresyon tespit edilmiřtir. Sađlık alıřanı olmayan rneklem grubu iin yaygın anksiyete bozukluđu, uyku bozukluđu ve depresif belirtiler grldđ saptanmıřtır. Henz mesleđe bařlamamıř tıp fakltesi đrencileri iin yapılan alıřmada DSK kullanılmıř katılımcıların orta dzey bir anksiyete yařadıđı belirlenmiřtir. Aynı lek kullanılarak yapılan bir diđer alıřmada ise sađlık alıřanları ile sađlık alıřanı olmayan kiřiler kıyaslandıđında daha ncesinden bir psikiyatrik rahatsızlıđı olan bireylerin puanının yksek olduđu, erkeklerin ise daha dřk puan aldıđı fark edilmiřtir (26).

2.2.1. Toplum Ynnden Anksiyete ve COVID-19 Pandemisi

COVID-19 salgını sırasında yapılan alıřmaların, drt veri tabanından Nisan 2021-Temmuz 2021 tarihleri arasında kesitsel olarak incelendiđi bir arařtırmada 3537 alıřma bulunmuřtur. Bu alıřmalar detaylı olarak incelendiđinde 87 arařtırmanın rneklemine 755.180 kiři oluřturmuřtur. alıřma sonucunda %36 ile sađlık alıřanları endiře oranı en yksek grup tespit edilmiř ve bunları ikinci sırada niversitede rgn đrenim gren đrenciler, nc sırada genel toplum, đretmenler, hamileler ve polisler grubu takip etmiřtir. Kadın olması, nceden psikiyatrik hastalık gemiři olması, dřk sosyo-ekonomik dzeyde olunması, enfeksiyona maruz kalma durumunda artıř ve gen birey olması gibi risk durumları endiřenin artmasına sebep olmuřtur (27).

Bařka bir alıřmada ise yine kadınlar, řehir ierisinde yařayanlar ve daha ncesi ruhsal hastalık gemiři olanlar anksiyete ve depresyon seviyelerinin yksek olduđu bildirilmiřtir. Aynı alıřmada meydana gelebilecek bir pandemi iin daha nceden kronik ve psikiyatrik hastalık gemiři olan bireylerin ncelikli risk grubu olarak belirlenmesi gerektiđi sonucuna varılmıřtır. Ayrıca, duygu dzenleme zerine yapılan bir alıřmada anksiyetesi olan

bireylerde dikkat dağınıklığının yaygın olduğu ve genel olarak düşük vagal tonus gözlemlenmiştir (28, 29).

2.2.2. Sağlık Çalışanları Yönünden Anksiyete ve COVID-19 Pandemisi


COVID-19 döneminde;

- Sağlık çalışanları üzerine yapılan çalışmada yaygın anksiyete ve uykusuzluk düzeyleri karşılaştırılmıştır. Katılımcıların %52.3'ünde yaygın anksiyete bozukluğu ve %53.1'inin ise uykusuzluk yaşadığı belirlenmiştir. Ayrıca aynı çalışmada öğrenim durumu arttıkça anksiyete düzeylerinde artma olduğu gözlenmiştir (30).
- Bir üniversite hastanesinde çalışan sağlık personellerinde anksiyete, travma sonrası stres seviyesi incelenmiş katılımcıların %26.7'sinde yaygın anksiyete semptomları, %26.4'ü hafif ve daha şiddetli travmaya bağlı stres bozukluğu olduğu görülmüştür. Çalışmaya göre mesleki tecrübesi az olan bireyler ile psikiyatrik hastalık geçmişi olanların yaygın anksiyete belirtileri yaşadığı; ekip lideri ile ekip üyeleri arasındaki uyumsuzluk şiddetli yaygın anksiyete belirtileri ile ilişkilendirilmiştir (31).
- COVID-19 Korkusu Envanteri ile yapılan çalışmada; katılımcıların %73.6'sı devlet hastanesinde kadrolu ve %43.2'si doğrudan COVID-19 tanısı alan hastalarla çalışmıştır. Maslach Duyarsızlaşma, HSA Kaygı ve Depresyon, COVID-19 Korkusu Envanterlerine göre kadın bireylerin puan ortalaması, erkek bireylerin puan ortalamasından anlamlı bir şekilde farklı bulunmuştur. Ailesi ya da eşi ile yaşayanların puan ortalamaları yalnız yaşayanlara göre daha da yüksek bulunmuştur (32).
- Sağlık çalışanları arasında depresyon, kaygı ve uykusuzluk düzeylerinin incelendiği toplam 33.062 katılımcıyla gerçekleştirilmiş on üç araştırma analizinin dahil edildiği bir meta analiz çalışmasında kadın sağlık personellerinde daha yüksek anksiyete, depresyon ve uyku bozukluğu olduğu gözlemlenmiştir (33).

2.3. Makine Öğrenmesi ve Ses Verilerinin İlişkisi

2.3.1. Yapay Zekâ

İnsanlık tarihi boyunca düşünme eyleminin matematiği keşfedilmeye çalışılmaktadır. Bilge, zeki insan anlamına gelen Homo Sapiens, ilk modern insanı tanımlamaktadır. Yapay zekâ ise insanın düşünme eylemini keşfetme sürecinde makinelerinde bu dünyadaki problemleri anlama ve çözüm getirmesi amacına temellendirilmiştir. Yapay zekanın alanları algılama, anlamlandırma, öğrenme, kavrama gibi çok çeşitli alt dallara sahiptir (34).



Şekil 1. Yapay zekâ ve gelişimi (Xu'dan, 35)

2.3.2. Makine Öğrenmesi

Makine öğrenmesi yöntemleri biyolojik, biyomedikal ve davranış bilimlerinde son yıllarda giderek yaygınlaşan ve kabul gören yöntemlerdir. Bu yöntemler görüntü tanımda ve sınıflandırmada yüksek seviyede başarı oranına sahip olsa da az örneklem grubuyla elde edilen verileri işlemede başarı oranı düşük seyretmektedir (36). Makine öğrenmesi yöntemlerinin tıp ve görüntü işlemede güçlü ve zayıf yönleri tespit edilmiştir fakat gelecekte tanıya yönelik uygulamalarda daha başarılı olacaktır (37). Yöntemlerin Danışmanlı Öğrenme, Danışmansız Öğrenme, Yarı Denetimli Öğrenme ve Pekiştirmeli Öğrenme gibi türleri bulunmaktadır.


2.3.2.1. Danışmanlı Öğrenme

Derin öğrenme olsun ya da olmasın en çok tercih edilen makine öğrenmesi yöntemidir. Sınıflandırılmak istenen bir veri setinde sınıflandırılmak istenen nesnelerin bilgileri bulunur ve etiketleme yöntemi ile sınıflara bölünerek veri seti hazırlanır. Veri setini öğrenme sırasında makine bir görüntü ve bir puan vektörü biçiminde çıktı üretir. Her sınıflandırılan kategori için bu puanın en yüksek olması hedeflenir. Bu puanın öğrenmeden önce gerçekleşmesi pek de olası değildir. Ayrıca, çıktı puanları ile istenen bu puan modeli arasındaki mesafeyi ölçen bir aktivasyon fonksiyonu hesaplanmış olur (38).

2.3.2.2. Overfitting (Aşırı Öğrenme)

Yapay sinir ağlarının eğitilmesinde en büyük problemlerden birisi de eğitim verilerinin aşırı uyarlanmasıdır. Algoritma kendine verilen verilerden direk sonuç odaklı çalışır.

Kendine verilen verileri çok iyi çözümler ancak gerçek durumlara uyumunu kaybeder başka bir ifadeyle öğrenme ezber şeklinde gerçekleşir (39).




Şekil 2. Modelin karmaşıklığı (Hastie'den, 40)

2.3.2.3. Underfitting (Yetersiz Uyum)

Aşırı öğrenmenin tersidir. Bu model, değişkenliğin yakalanmadığı durumlarda ortaya çıkar. Verilerin, doğrusal eğitildiğini varsaydığımızda ($y = ax + b$ polinomu a ve b Sabit olmadığı) parabolik bir görünüm oluşturduğu durumda sınıflandırıcının yeterli öğrenmeyi gerçekleştirememektedir. Sınıflandırıcı program içerisindeki rastlantısallık durumları öğrenir (41). Bu durumlarda minimum hata artmaya başlar (Şekil 2).

2.3.2.4. Çapraz Doğrulama


Çapraz doğrulama, tahmine dayalı bir modelin genelleştirme yeteneğini değerlendirmek için oluşturulan bir modeldir. Bunun veri seti eğitim ve test verisi seçtiğimiz bir eğitim modeli oluşturulur. Her veri seti eğitim kısımlarının test verisi olarak kullanması yöntemidir. Küçük veri setleri için de uyum göstermektedir (42).



Şekil 3. K Katlamalı Çapraz Doğrulama (Amidi'den, 43)

2.3.2.5. Yanlılık (Bias) ve Varyans

Bias, önyargı anlamına gelmektedir. Oluşturulan modelin, ortalama tahmini ile tahmin etmeye çalıştığımız doğru değer arasındaki farkıdır. Yüksek bias değerine sahip model, eğitim verilerine çok az dikkat eder ve modeli aşırı basitleştirir. Eğitim ve test verilerinde her zaman yüksek hataya yol açar (44).



Şekil 4. Eğitim modelinde Bias ve Varyans (Cowan'dan, 45)

Eğitim verileri ağırlıklı çalışılan veriler türlerinde varyansın yüksek olduğu gözlemlenmiştir. Daha önce görmediği veriler üzerinde genelleme yapamazlar. Bu modeller eğitim verilerinde yüksek performans sergilerken test verilerinde ise yüksek hata oranları sergiler (46).

2.4. Görüntü Verisi ve Duygu Çıkarımı

Nabiyev (2012)'e göre yapay zekâ kavramı, bir bilgisayar veya bir makinenin, insana has özellikler kullanarak bir problemi çözme, bir anlam üretme, genelleme yapma ve geçmişten ders alarak çıkarım yapma gibi görevleri yerine getirme yeteneği olarak bilim dünyasında kabul görmektedir. Genel olarak yapay zekâ insanca düşünen makinelerin, insanların karşılaştığı problemlere çözüm ararken ürettiği yöntemlerdir. Yapay zekâyı anlamak için zekâ kavramını anlamak gerekmektedir. Zekâ, gerçekleri algılayarak yargı süzgecinden geçirerek bir sonuca varma yeteneklerinin tümüne denir. Kısacası zekâyı tanımlarken beynin bir bilgiyi alıp, hızlı ve doğru analiz etmesi olarak nitelendirebiliriz (47).


2.5. Derin Öğrenme (Deep Learning)

Yapay zekâyı sınıflandırırken en önemli sınıflama yöntemlerinden birisi de makine öğrenmesi kavramıdır. Makine öğrenmesi algoritmalarının içerisinde en popülerleri derin öğrenmedir. Derin öğrenme, katmanlar kullanarak çıktılar üretilmesidir. Her katman kendisinden, önceki katmanlardaki çıktıyı, girdi olarak kabul eder. Derin öğrenme genel olarak verinin temsiline dayalı olan bir öğrenme yöntemidir. Bir görüntü verisi için temsil kavramını açıklarsak kenar bulma, piksel yoğunluğu bulma, özel şekilleri bulma gibi çıkarımlar olarak düşünülebilir. Derin öğrenme yöntemlerini geliştirmek için birkaç yöntem kullanılabilir. Derin öğrenme; Çok Katmanlı Algılayıcı (Multi Layer Perceptron -MLP), girdi (input), gizli (hidden layer) ve çıktı (output) katmanlarından oluşur. Gizli katmanlar probleme göre değişir, çıkış katmanı ise gelen verileri işleyerek çıkış verisini oluşturur. Çıkış katmanı ağdaki bulunan eleman sayısına eşittir. Backpropagation yöntemi ile çıktı katmanlarından girdi katmanına doğru giden hata fonksiyonunun en az olduğu değer aranır (48).

Birçok araştırmacı duygusal ifadelerin neler olduğu ile çeşitli çalışmalar yapmışlardır. Çoğunlukla temel duyguları öfke, utanç, üzüntü, öğrenme, mutluluk, sevgi, şaşkınlık, korku şeklinde sınıflandırmak mümkündür. Bazı ifadeler bir arada görülebilirken tek tek olarak da ortaya çıkabilir. İnsanlar yazarken ya da konuşurken kategorize edilebilen söylemlerde

bulunurlar. Bu söylemler insanların duygularını, görüşlerini ve ruhsal durumunu içerir. Bu durum anlık ve değişebilen bir süreçtir (49).

Derin öğrenme sınıflandırmak için çok sayıda veri ve test kümesine ihtiyaç duyarken, makine öğrenmesi yöntemleri az sayıda veri ile başarılı olabilir. Derin öğrenmeyi makine öğrenmesinden ayıran bir diğer özellik ise derin öğrenme için güçlü makineler (çok sayıda matriste işlem yapma ihtiyacı) gereklidir. Makine öğrenmesi yöntemlerinde özelliklerin kullanıcıları tarafından tasarlanmaması gerekmektedir. Derin öğrenmede ağ kendi özellik çıkararak yeni özellikleri de öğrenebilir. Makine öğrenmesi uygulamalarında genellikle işlem süreleri azdır. Derin öğrenme yöntemlerinde ise fazla olabilmektedir. Çıkış verisi ses, metin ya da puan gibi özellikler derin öğrenme yöntemleri ile işlenebilirken, makine öğrenmesi algoritmaları sonucu sınıflandırma ya da bir puan gibi bir sonuç ortaya çıkar (50).



Şekil 5. Plutchik Duygu Çarkı (Hu'dan, 51)

UYARILMIŞLIK

. mutluluk . sevinç . heyecan . huzur . memnun . ferahlama HOŞ	. hayal kırıklığı(engellenmiş) . hüsrân . mutsuz . öfke . kızgınlık (sinirli) . üzüntü . hüzn . tedirgin HOŞ DEĞİL
. gayretli (uyarılmış) . hoşnutluk . sakinlik . kıvanç (tatmin olmuş) . uykulu	. şaşkınlık . can sıkıntısı . korku . stres (kaygı) . yorgun (ilgisiz)

UYKU HALİ

Şekil 6. Russell'e göre 25 Türkçe duygu ifadesinin iki boyutlu modeli (Çolakoğlu'dan, 52)

3. GEREÇ ve YÖNTEM

Bu tez çalışmasında ses verileri görüntü verilerine dönüştürülmüştür. Dönüştürülen veriler CNN (Convolutional Neural Network) Yöntemi ile karar destek sistemine öncü bir sistem geliştirilmesi için kullanılmıştır. Bu yöntemleri sırasıyla inceleyeceğiz.

3.1. Veri Toplama Araçları

3.1.1. Durumluk- Sürekli Kaygı Ölçeği (DSKÖ) (State- Trait Anxiety Inventory- STAI)

1964 yılında Spielberger ve ark. tarafından geliştirilmiştir. Türkçe geçerlik ve güvenirliği 1974-1977 yıllarında Öner ve Le Compte tarafından yapılmıştır. Durumluk kaygı bölümünde bireyin belirli zaman ve şartlarda kendisini nasıl hissettiği belirlenir. Sürekli kaygı bölümünde ise bireyin belirli zaman ve şartlara bağlı olmadan genellikle kendisini nasıl hissettiği belirlenir. Ölçekte, durumluk kaygı bölümünde 10 tane (1.,2.,5.,8.,10.,11.,15.,16.,19. ve 20. maddeler), sürekli kaygı bölümünde ise 7 tane (21.,26.,27.,30.,33.,36., ve 39. maddeler) tersine ifadeler bulunmaktadır. Değerlendirme yapılırken doğrudan ve tersine ifadeler için toplam ağırlık hesaplaması yapılır. Bunun için iki adet anahtar hazırlanır. Doğrudan ifadeler için elde edilen toplam puandan, ters ifadelerin toplam puanı çıkarılır ve bu sayıya değişmeyen bir değer eklenir. Bu değer durumluk kaygı bölümü için 50, sürekli kaygı bölümü için ise 35'tir. Her iki bölümden elde edilen toplam puan değeri 20 ile 80 arasında değişmektedir. Büyük puan yüksek kaygı seviyesini, küçük puan ise düşük kaygı seviyesini belirtmiş olur (53).

3.1.2. Ses Analizi için Kullanılan Sorular

Ses verilerine yönelik toplamda 6 adet soru bulunmaktadır. Bu sorulardan ilk dört soru duyguya ve son 2 soru ise anksiyete yöneliktir:

1.Soru: Şu an kendinizi nasıl hissediyorsunuz?

2.Soru: Bir sağlık çalışanı olarak çalışmak size nasıl hissettiriyor. Maksimum bir dakikalık ses kaydınızı yükleyebilir misiniz?

3.Soru: Pandemi sürecinde hastanede sağlık çalışanı olarak çalışmak sizi nasıl hissettiriyor?

4.Soru: Çalıştığınız klinikte çalışma ortamınız nasıldır? (Eğer stresli bir ortamda çalışıyorsanız. Stresle baş ederken ne gibi yöntemlere başvurursunuz?)

5.Soru: Aşağıda verilen metni sesli bir biçimde okuyunuz.

6.Soru: Aşağıda verilen metni sesli bir biçimde okuyunuz.

Anksiyete yönelik olan 5. ve 6.soruda katılımcıların gördükleri metni ses kaydı yapmaları istenmiştir.


3.1.3. Anket Formu

Phonic.ai, yüksek kalitede ses ve video görüntü verisi toplanması için tasarlanmış bir araştırma uygulamasıdır. Uygulama aracılığı ile oluşturulmuş çevrimiçi anket formunda demografik ve mesleğe bağlı bilgileri içeren 8 adet (yaş, cinsiyet, çalıştığı birim gibi), ses kaydı ile cevaplandırılan 6 adet ve DSKÖ ile yanıtlanan 4'lü likert tipte 40 adet soru bulunmaktadır. Oluşturulan anket formu ile veriler elde edildi.

Şekil 7. Örnek ses verisi toplama formu

3.2. Ses Verilerinin Düzenlenmesi

Audacity programı Windows, Mac OS X, Linux gibi birçok işletim sisteminde kullanılabilinen, özgür, ücretsiz bir ses kaydetme ve ses düzenleme yazılımıdır. Audacity aracılığı ile toplanılan ses verilerinin arka plan gürültüsü azaltıldı. Anket formunda bulunan sesli yanıt verilen 1., 2.,3. ve 4. soruların katılımcılar tarafından verilen cevapları ortalama iki saniyelik parçalara bölündü. 5. ve 6. soruların sadece gürültü verileri azaltıldı ve orijinal boyutu korunarak değerlendirmeye alındı.



Şekil 8. Ses verilerinin Audacity programındaki görüntüsü

3.3. Ses Verilerinin Sınıflandırması

Veri kümesi, literatürde sıkça kullanılan RAVDESS, EMODB, TESS, CREMA gibi kütüphanelerde kullanılan etiketleme yöntemlerine benzer şekilde etiketlendirildi. Bu veri setleri içerisinde duygular sakin, mutlu, üzgün, sinirli, korkmuş, yorgun ve endişeli şeklinde etiketlenmiş olarak bulunmaktadır (54).

Etiketleme şekline göre dosya adı sırasıyla;

1. Dosya Tipini (01 = Kontrol, 02 = Deney),
2. Cinsiyeti (01 = Erkek, 02 = Kadın),
3. Ses Kaydı Alınan Kişinin Numarasını,
4. Duygu Türünü (01 = Mutlu, 02 = Üzgün, 03 = Sakin, 04 = Sinirli, 05 = Endişeli, 06 = Sakin, 07 = Korkmuş),
5. Soru Numarasını (01 = "1. soru", 02 = "2. Soru" gibi) içerir (Şekil 9).

Ad	Değiştirme tarihi	Tür	Boyut
01-01-01-01-05	22.12.2022 15:45	WAV Dosyası	4.481 KB
01-01-07-01-05	22.12.2022 23:27	WAV Dosyası	6.129 KB
01-02-08-01-05	22.12.2022 15:28	WAV Dosyası	4.737 KB
01-02-19-01-05	Öğe türü: WAV Dosyası Boyut: 4.62 MB Uzunluk: 00:00:25	WAV Dosyası	4.321 KB
01-02-20-01-05		WAV Dosyası	5.010 KB
02-01-01-01-05	20.12.2022 11:05	WAV Dosyası	5.233 KB
02-01-05-01-05	20.12.2022 17:23	WAV Dosyası	4.676 KB
02-01-14-01-05	21.12.2022 00:49	WAV Dosyası	4.030 KB
02-02-21-01-05	21.12.2022 11:48	WAV Dosyası	4.641 KB
02-02-26-01-05	21.12.2022 12:30	WAV Dosyası	3.960 KB
02-02-27-01-05	21.12.2022 13:13	WAV Dosyası	4.830 KB
02-02-32-01-05	21.12.2022 22:28	WAV Dosyası	5.073 KB


Şekil 9. Ses verilerinin kaydedilme biçimi

3.4. Ses Verilerini İşleme Yöntemleri


3.4.1. Fourier Dönüşümü

Araştırmada ses verileri Fourier Dönüşümü yöntemi kullanılarak görüntüye dönüştürüldü. Fourier Dönüşümünü (Fourier Transform) hesaplamak için insanların veya tüm canlıların sadece sesleri dinlemesi yeterlidir. Kulak, doğal yapısı dolayısıyla bu dönüşümü hesaplar ve algıladığı ses perdesini dönüştürerek beyine iletir. Bir aklın bunu hesaplaması için yıllarca süren matematik eğitimi gerekmektedir (55).

Herhangi bir sinyal, içerisindeki farklı boyuttaki ve fazdaki sinüs(sinüzoid) dalgalarını hep birlikte gösterebileceği kuramının Fourier tarafından ortaya atılması Fourier Dönüşümünün temelini oluşturmuştur (56).




Şekil 10. Zaman boyutunda Fourier Dönüşümü (Kalhara'dan, 57)



Şekil 11. Zaman boyutunda Fourier Dönüşümü (Kalhara'dan, 57)

Şekil 10'da bulunan sinüs dalgalarının, zaman alanındaki karmaşıklığı Şekil 11'de temsil edilmiştir. Zaman bölümündeki üç dikey çizgi, frekans bölümündeki üç dikey çizgi ile temsil edilebildiği gözlenmektedir. Frekans bölümündeki bu basit gösterim, anahtar frekansların belirlenmesine yardımcı olmaktadır. Frekans alanındaki veriler zaman alanına geri taşınırsa kaybolma gözlenmez (56).


Fourier Dönüşümünü hesaplamanın en etkili yöntemi Hızlı Fourier Dönüşü (Fast Fourier Transform- FFT) algoritmasıdır. FFT, yeni bir teknik değil Ayrık Fourier Dönüşümü (Discrete Fourier Transform- DFT) hesaplamanın hızlı bir yöntemidir. Bilgisayarların işlem yetenekleri arttıkça ve programlama dilleri geliştikçe Fourier analizi için yeni yöntemlerin gelişmesi ile hesaplamalar daha da kolay yapılmaya başlandı. Cooley ve Tukey (1965) tarafından FFT diye bilinen program ortaya çıkarılmıştır (57).



Şekil 12. Sekiz noktalı DFT'nin zamanda desimasyon ile iki adet dört noktalı DFT'ye ayrıştırılması (Cochran'dan, 58)

3.4.2. Spektrogram

Spektrogram, bir sinyalin zamana göre değişiminin görselleştirilmesidir. Spektrogramlar dil bilim, sonar, radar, sismoloji ve müzikte sıklıkla kullanılmaktadır. Ses spektrogramları ise konuşulan kelimeleri görselleştirmek için kullanılmaktadır (59).




Şekil 13. Spektrogram (Kovitvongsa'dan, 60)

3.4.3. Mel Spectrogram

Birçok çalışmada insan sesi düz bir çizgi olarak değil dalgali olarak değerlendirilmiştir. İnsan sesi, genellikle düşük frekans ve yüksek frekansların birlikte olduğu şekilde görselleşmektedir. Yüksek frekans aralığını hem gözleyebilir hem de duyabiliriz ama ses aralığı daraldıkça gözlem ve duyma yetilerimiz azalacaktır. 1937 yılında


Stevens, Volkmann ve Newmann perdedeki eşit mesafelerin dinleyiciye eşit uzaklıkta duyulmasını sağlayacak bir perde birimi önermiştir. Buna mel skalası denir. Mel skalasına dönüştürmek için frekanslar üzerinde matematiksel birtakım işlemler sonucu Mel Spectogramlar oluşmaktadır (61).



Şekil 14. Mel Spectrogram (Thakur'dan, 62)

3.4.4. Mel-Frekans Kepstral Katsayıları (MFCC)

MFCC, insan kulağının çalışma prensibi gibi çalışan ve FFT tabanlı çalışan bir dönüşüm yöntemidir. MFCC'ler de ses dalga yapısından minimum oranda etkilenme avantajı vardır. MFCC katsayılarının elde edilmesi algoritmasının blok diyagramı görülmektedir (63).

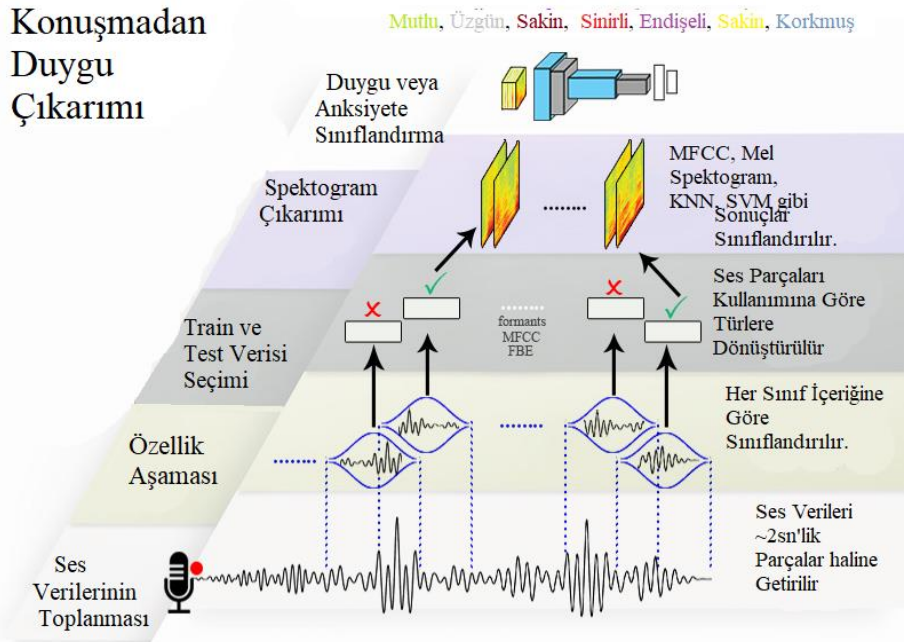


Şekil 15. Mel-Frekans Kepstral Katsayıları ile insan sesinin gösterimi (Aung'dan, 64)

3.5. Görüntü Verilerini Sınıflandırma Yöntemleri

3.5.1. CNN (Convolutional Neural Network)

Evrişimli Sinir Ağı (ESA) olarak tanımlanan CNN evrişim hesaplama yöntemini kullanan ve derin bir yapıyı içeren, ileriye doğru beslenen bir yapay sinir ağıdır. ESA'lar genellikle görüntü tanıma ve sınıflandırma konusunda ön plana çıkmaktadır. YSA'lar, ağırlık paylaşımı ve havuzlama katmanı CNN yapısının temel bileşenleridir. Genellikle etiketlenmiş verileri içeren YSA eğitimi için kullanılmaktadır. CNN genellikle beynin görme merkezini taklit eden bir yapı ile çalışır. Bu yapı çok katmanlı verileri alır, hesaplar ve sonuçlarını bir sonraki katmana iletir. Görüntü işleme sürecinde ağ yapısının karışıklığını azaltmak için ağırlık paylaşımı ve havuzlama yöntemleri kullanılmaktadır. CNN yapısının ilk katmanı giriş katmanıdır. Buradaki veriler işlenmemiş olarak ağa verilmektedir. Tasarlanan model için bu verilerin boyutları önem taşımaktadır. Görüntü boyutunun yüksek olması hem yüksek bellek ihtiyacı hem de eğitim süresinin artmasına neden olsa da ağın başarısını arttırabilir. Eğer görüntü boyutu düşük tutulursa bellek ihtiyacı azalır, eğitim süresi düşerken istenilen performans sağlanamayabilir (65).



Şekil 16. Çalışma için tasarlanan duygu çıkarımı modeli (Demirel'den, 66)

3.5.1.1. Konvolüsyon Katmanı

Konvolüsyonel sinir ağlarının yapıtaşını oluşturan bir katmandır. Bu katmanda girdi verisi üzerine daha önceden oluşturulmuş bir filtre aracılığı ile filtreler uygulanır. Girdi verisi bu filtreler sonucunda çok boyutlu ve daha küçük bir matrise çevrilir. Derin öğrenme algoritmalarında farklı matrisler kullanılır. AlexNet'te kullanılan matris boyutu 11x11'dir. GoogleNet, ResNet, VGGNet gibi derin öğrenme algoritmalarında ise 1x1, 2x2, 3x3, 5x5 şeklinde matrisler kullanılabilmektedir (67).

3.5.1.2. Aktivasyon Katmanı


Aktivasyon katmanı nöronların çıktılarını belirli bir değer aralığına sabitler. Her fonksiyonda farklı bir değer için kullanılmaktadır. Karmaşık doğrusal olmayan sorunları çözmek için Sigmoid, Tanh, Softplus, ReLu aktivasyon fonksiyonları kullanılırken, doygun doğrusal olmayan sorunları çözmek için Sigmoid ve Tanh yavaş yakınsama hızı nedeniyle tercih edilmektedir. Bunların arasında en çok tercih edilen ReLu fonksiyonu bu tercih edilmesindeki sebepler: Yakınsama hızı sayesinde elde edilmesi basit ve hızlıdır, böylece gradyan kaybolma problemlerini etkili bir şekilde hafifletebilir ve belirli bir seyreklik sağlayabilir. Bu tez çalışmasında yaygın olarak ReLu ve Sigmoid aktivasyon fonksiyonları kullanılmıştır (68).

3.5.1.3. Havuzlama (Pooling) Katmanı

Havuzlama katmanı verinin boyutlarını (Yükseklik X Genişlik) olarak azaltılması amaçlı yapılmaktadır. Bu işlem sonucunda verinin derinlik boyutunda değişme meydana gelmez. Bu işlem yapılmasındaki temel amaç hesaplama yükünü düşürmek ve Overfitting (aşırı öğrenme) durumunun engellenmesi için yapılmaktadır. En yaygın kullanılan havuzlama yöntemleri maksimum havuzlama ve ortalama havuzlama işlemidir. Sıklıkla maksimum havuzlama yöntemi kullanılmaktadır (69).

3.5.1.4. Softmax

Softmax çoklu sınıflandırma verileri için kullanılmaktadır. Bu çalışmada duygu sınıflamasında 7 veri sınıfı ve Anksiyete sınıflandırmada 4 veri sınıfı olduğu için Softmax yöntemi kullanıldı (70).



Şekil 17. Softmax yöntemi ile duygu çıkarımı (Zhang'dan ,71)

3.5.2. AlexNet

AlexNet, Hinton, Sutskever ve Krizhevsky (2012) tarafından geliştirilmiş DSA modelidir. Bu kadar popüler olarak kullanılmasının nedeni 2012 yılında ImageNet yarışmasını kazanmasıdır. Birbirini takip eden katmanları ve ortaklama (pool) katmanlarını içermektedir. Bu model bilgisayarların nesne tanılamadaki doğruluk oranlarını %10.8 daha arttırarak %83.6 yükselmesine yol açmıştır (72).

3.5.3. VGG-19 ve VGG-16

VGG-19 ve VGG-16, Oxford Üniversitesi “Görsel Geometri Kulübü” tarafından yayınlanmış olan “Very Deep Convolutional Networks for Large-Scale Image Recognition” adlı yayın ile 1000 sınıflandırma bölümü ve 14 milyon görüntüyü içeren sınıflandırma ImageNet veri setinde ilk beş grup içerisinde bulunarak başarı oranını %92’e kadar yükselmiştir (73).

3.5.4. ResNet

ResNet, 2015 yılında Xiangyu Z, Kaiming H, Shaoqing Ren S ve Sun J tarafından geliştirilen “Deep Residual Learning for Image Recognition” yayını ile tanıtılan bir YSA türüdür. ImageNet veri setinde 2015 yılında %3.57 hata payı ile birinci olmuştur. Bu yöntem bizim çalışmamızda da kullanılmıştır (74).

ResNet 50 mimarisi ismini ağıın içerisinde bulunan 50 ağırlık katmanından alır. VGG-19, VGG-16’dan daha derin bir ağ yapısına sahip olmasına rağmen global ortalama havuz

metoduyla çalıştığı için modelin boyutu küçüktür. Bu da zamandan ve bellekten tasarrufa yol açmaktadır. Pratik olarak artık katmanların oluşturduğu bloklar sayesinde hata oranının azaldığı gözlenmiştir. ResNet bu temelle oluşturulmuş bir modeldir (75).

3.6. Ses ve Görüntü Verilerini İşleme Sırasında Kullanılan Uygulamalar

3.6.1. Pycharm

Pycharm bir Python geliştirme ortamı sunan Entegre Geliştirme Ortamı (IDE)'dir. Çapraz platformu Windows, Mac OS X ve Linux işletim sistemleri üzerinde çalışmaktadır. Çalışmada ses verilerinin hazırlanması ve CNN için görüntülere çevrilmesi için Pycharm ile bir uygulama geliştirildi (76).

3.6.2. Jupyter Notebook

Jupyter Notebook bir web tarayıcısı ile bir not defteri şeklinde kodları derlemeyi ve çalıştırmayı sağlayan bir uygulamadır. Başlangıçta sadece Python desteği ile çıksa da birçok yazılım dili daha eklenmiştir. Jupyter Notebook bir not defteri gibi çalışır. Google Colab'tan farkı ise bilgisayarın kendi donanımlarını kullanır. Ayrıca yerel dosyalara ulaşım ve onları kullanabilme imkânı sunar. Bu çalışmada Google Colab uygulamasının yavaş kaldığı durumlarda Jupyter Notebook uygulamasından yararlanıldı (77).

3.6.3. Google Colab

Colaboratory, kısa adıyla “Colab”, Google Research tarafından kullanıma sunulan bir üründür. Kurulum gerektirmeden çevrimiçi ortamda sanal Global Photographic Union (GPU) kullanımı sunan sunulan, Python yazılım dili tabanlı bir Jupyter not defteri derleyicisidir. Google Colab özellikle makine öğrenmesi, verilerin analizi ve eğitimi için yaygın olarak kullanılmaktadır. Bu tez çalışmasında Google Colab arayüzü çeşitli yöntemler geliştirilirken aktif olarak kullanıldı (78).

3.7. Verilerin Toplanması

Bu çalışmada kullanılan veri seti Aralık 2021- Ocak 2022 tarihlerinde Ordu Eğitim Araştırma Hastanesi'nde çalışan sağlık personellerinden elde edildi. Bu çalışmaya katılma şartlarına uyan ve katılmayı kabul eden 62 sağlık personelinin çevrimiçi anket formunu doldurulması ile veri toplama aşaması tamamlandı.

Çalışmaya katılma şartları;

- Ordu Eğitim ve Araştırma Hastanesi'nde çalışıyor olmak,

3.9. Çıktıları Sınıflandırmak için Tasarlanan CNN Yapısı

Sınıflandırma Modeli, Şekil 21'deki gibi hazırlandı. Çalışmada CNN algoritmasının çalışması için TensorFlow, OpenCV ve Keras kütüphaneleri sıkça kullanıldı. Mevcut literatürdeki çalışmalar incelendi. Sistemi eğitmek için farklı modellerden yararlanıldı. Modelin başarı oranları öğrenme katsayısı, aktivasyon fonksiyonu, eğitim tur sayısı, batch boyutu gibi ölçüm metotları ölçülerek karşılaştırıldı.

3.9.1. Veri Setinin Boyutu

Çeşitli ve büyük boyutta olan veri setleri, derin öğrenme uygulamaların yapıtaşdır. Veri seti ve öğrenme oranı birbirleri ile paralel yükselmektedir. Veri seti büyüdükçe ağda eğitim miktarı artmakta ve harcanan zaman da artmaktadır. Veri sayısı yeterli bir seviyeye ulaşırsa başarı oranında önemli değişim görülmez (79).

3.9.2. Mini Batch Boyutu

Veri Setinde bulunan verilerin tek tek işlenerek ağ tarafından öğrenilmesi zaman ve bellek açısından dezavantajdır. Her yinelemede geriye yayılım (backpropagation) algoritması ile yapılan ağ modelinde gradient değeri hesaplanır ve ağırlıklar yeni modele göre tekrardan güncellenir. Veri sayısı artmasıyla hesaplanan miktar da doğru orantılı olarak artar (80).

3.9.3. Learning-rate


Geriye yayılım algoritması yapılırken bu chain rule (zincir kuralı) adı verilen geriye doğru türev alma yöntemi ile yapılan işlem, bulunan değerlerin de learning-rate ile çarpılması ile yeni değer oluşmaktadır. Yeni değer çıkan sonuçtaki ağırlık değerinden yeniden çıkarılarak, yeni ağırlık parametresini verir. Bu algoritmalar tasarlanırken learning-rate sabit ya da değişken seçilebilir (81).

3.9.4. Epoch

Oluşturulan model eğitilirken bütün veriler aynı zamanda eğitime giremez. Belli oranda eğitime dahil olur. İlk parça eğitilir başarı oranı test edilir, sonra geriye yayılım algoritması ile ağırlıkları güncellenir. Bu olay belirlenen miktarda gerçekleşir. Bu olayın her bir adımına epoch(devir) denilmektedir (82).

3.9.5. Aktivasyon Fonksiyonları

Önceki katmanlardaki tüm girdi değerlerini alan ve doğrusal olmayan bir çıktı üreten fonksiyonlardır. Yapısı itibariyle sinir hücrelerinin çalışma mantığıyla benzerdir. En çok kullanılan Aktivasyon fonksiyonlar Sigmoid, Tanh, Softplus, ReLu olarak tanımlanmaktadır (83).



Şekil 20. Bir sinir hücresi ile Aktivasyon Fonksiyonu arasındaki benzerlik (Agarwal'den, 84)

3.9.6. CNN’de Kernel Boyutu

Oluşturulan 1D CNN modeli Şekil 21’de gösterilmiştir. Oluşturulan model önce duygu tahmini için kullanılmıştır. Sonrasında 8. adımdaki çıktı katmanında duygular için 7 (kategorize edilen duygu miktarı) katman, anksiyete analizi için 4 katman kullanılmıştır. Modeli oluştururken TensorFlow ve Keras kütüphanelerinden yararlanıldı. Ses verileri etiketlendi ve dizilere dönüştürüldü. Ses verilerini büyütmek için 4 farklı yöntemden;

1. Gürültü Enjeksiyonu (Noise Injection: Ses kaydı ile alınan verilerde doğal olarak ortam gürültüsü bulunmaktadır.),
2. Zaman Esnemesi (Time Stretch),
3. Perde Kaydırma (Pitch Stretch),
4. Verilerin ham halinden yararlanıldı.

Zisad ve ark. (2020) tarafından kullanılan yöntemde gürültülerin model tarafından tanınması, perde özelliklerinin (büyütme, kayma gibi) daha iyi keşfedilmesidir. Her ses verisi üzerinde 3 veri arttırma tekniği kullanılarak veriler büyütülmüştür ve sonrasında eğitim ve test seti oluşturulmuştur (85). Eğitim ve test verisi seti, duygu analizi için 48 anksiyete, 11 kızgın, 24 korkmuş, 116 mutlu, 35 sakın, 44 üzgün ve 25 yorgun ses verisi; anksiyete analizi için ise 17 durumluk anksiyete var, 39 durumluk anksiyete yok, 18 sürekli anksiyete var, 39 sürekli anksiyete yok ses kaydı verilerini içermektedir. Arttırılmış veri


yöntemi ile eğitim ve test veri seti Tablo 1’de gösterilmiştir. Verilerin ham halini içeren veri seti Tablo 2.’de gösterilmiştir. Tablo 2’de gösterilen veri setinde eğitim verisine gürültü enjeksiyonu yapılırken test verisi ham halde bırakılmıştır.

Tablo 1. 1D CNN veri seti dağılımı

Veri Seti	Veri Yüzdesi	Veri Sayısı
Duygu Tanıma Test (7 Kategori)	%10	91
Duygu Tanıma Eğitim (7 Kategori)	%90	818
Anksiyete Analizi Test (4 Kategori)	%10	34
Anksiyete Analizi Eğitim (4 Kategori)	%90	305

Tablo 2. 1D CNN veri seti dağılımı (Ham test verisi)

Veri Seti	Veri Yüzdesi	Veri Sayısı
Duygu Tanıma Test (7 Kategori)	%10	61
Duygu Tanıma Eğitim (7 Kategori)	%90	726
Anksiyete Analizi Test (4 Kategori)	%10	23
Anksiyete Analizi Eğitim (4 Kategori)	%90	270



Şekil 21. Bir boyutlu (1D CNN) modeli

Oluşturulan 1D CNN modeli Şekil 21’de gösterilmiştir.

Şekil 21’de görülen modelin 1. katman (167 x 1) boyutuna giriş verisi verildi. 2.katman konvülasyon katmanı olup bu katmanda 3x3 boyutunda 128 kez filtreleme işlemi uygulandı ve çıktı katmanında görülen parametre aktivasyon fonksiyonun olarak ReLu kullanıldı. Sonra maxpooling (maksimum havuzlama yöntemi ile her matrisin en yüksek değeri) seçildi. Tekrardan konvülasyon işlemi yapıldı 256 kez filtreleme uygulandı. Ara katmanlarda toplamda 4 kez konvülasyon ve havuzlama işlemi uygulandı. Son konvülasyon katmanında (159 x 1024) boyutu ile flatten (düzleştirme) işlemi yapıldı bu işlem sonucu veriler tek boyuta indirildi. 10. Katman Fully-Connected Layer (Tam Bağlı Katman) bu katmanda düzleştirme katmanından alınan veriler, sinir ağlarına iletilerek öğrenme işlemini gerçekleştirir. Bu aşda backpropagation ve forward propagation gibi yöntemler gerçekleştirildi.

için ve ağdaki nöronlar bütün nöronlarla bağlantılı olduğundan en fazla parametre sayısına sahiptir. En son katman ise çıktı katmanı burada anksiyete analizi 4 katman ve duygu analizi için 7 katmandan oluşmaktadır. Optimizasyon için RMSprop seçildi ve öğrenme kat sayısı ($\text{lr}=0.0005$) olarak belirlendi.

3.9.7. ResNet, AlexNet ve VGG-16 Yapısı


Derin öğrenme alanının gelişmesinde özellikle küçük verilerde başarı oranını arttırmanın en etkili yöntemi transfer öğrenme olduğu varsayılmaktadır. Önceden eğitilmiş bir modelle eğitime başlamak, orijinal veri seti ile çalışmanın yanında daha avantajlıdır. Şekil 9'daki gibi sınıflandırdığımız veri Os, Pandas ve Numpy kütüphanelerini kullanılarak bir veri çerçevesi (Dataframe) haline getirildi. Duyguları 7 kategori, anksiyete modelini de 4 kategori olmak üzere veriler etiketlendi. Sonrasında etiketlenen verilerin resimleri 640x480 piksel olarak yeniden boyutlandırıldı. Grey Scale (Gri Ölçek) yöntemi ile resimler Red, Green, Blue (RGB) renklerine ayrıldı. Eğitim ve test verisi seti, duygu analizi için 47 anksiyete, 11 kızgın, 24 korkmuş, 115 mutlu, 33 sakin, 44 üzgün ve 25 yorgun görüntü verisi; anksiyete analizi için ise 17 durumlu anksiyete var, 38 durumlu anksiyete yok, 18 sürekli anksiyete var, 40 sürekli anksiyete yok görüntü verilerini içermektedir.

Tablo 3. Eğitim ve test modelleri


Veri Seti	Veri Yüzdesi	Veri Sayısı
Duygu Tanıma Test (7 Kategori)	%20	60
ResNet, AlexNet, VGG19		
Duygu Tanıma Eğitim (7 Kategori)	%80	239
ResNet, AlexNet, VGG19		
Anksiyete Analizi Test (4 Kategori)	%20	23
ResNet, AlexNet, VGG19		
Anksiyete Analizi Eğitim (4 Kategori)	%80	90
ResNet, AlexNet, VGG19		

İnsanların renkleri algılaması ile bilgisayarın algılaması arasında farklılıklar vardır. Bilgisayarlar renkleri birtakım sayılar olarak algırlar. Bu sebepten ötürü gri tonlamalı görüntü kullanmak bize bir avantaj sağlayabileceği düşünülse de genellikle, derin öğrenmede renkli görüntülerle çalışırken bunlar RGB biçiminde temsil edilir. Yüksek düzeyde RGB, her rengin kırmızı, yeşil ve mavi değerlerin bir kombinasyonu ile temsil edildiği bir ek renk modelidir; bunlar genellikle ayrı "kanallar" olarak saklanır, öyle ki bir RGB görüntüsü genellikle 3 kanallı bir görüntü olarak adlandırılır.


Tasarlanan CNN modelinde çalışırken de renkler Red, Green, Blue şeklinde temsil edilmiştir.




Resim 1. Matplotlib ile resimlerin etiketlerine göre gösterimi




Resim 2. Anksiyete sınıflandırma gruplarının gösterimi



Resim 3. Kategorilerine göre Melspectrogramların görselleri




Resim 4. Spectrogramlardaki kırmızı renk dağılımı




Resim 5. Spectrogramlardaki mavi renk dağılımı


Melspectogramlar içerisindeki R, G, B oranlarına göre sınıflandırıldı. Green (yeşil) oranı çok düşük olduğundan sınıflama diyagramı çıkmadı. Sırasıyla Gri Ölçekli Kenar Algılama, Beyaz Ölçekli Kenar Algılama, Histogram of Oriented Gradients (HOG algoritması) ve Scale-Invariant Feature Transform (SIFT) yöntemleri ile özellikleri çıkarılmıştır.




Resim 6. Beyaz Ölçekli Görüntü Kenar Algılama




Resim 7. Gri Ölçekli Görüntü Kenar Algılama




Resim 8. HOG algoritması ile özellik çıkarımı




Resim 9. SIFT uygulaması özellik çıkarımı




Resim 10. Gri Ölçekli SIFT uygulaması özellik çıkarımı




Resim 11. ResNet Datagen yapısı



Resim 12. VGG Datagen yapısı



Resim 13. AlexNet Datagen yapısı üzerinde rastgele verilerin görüntüleri



Şekil 22. Farklı CNN yapıları ve katmanları (Rao'dan, 87)

Görüntü temelli CNN yapısı ile oluşturulmuş katmanlar şekilde gösterilmiştir. Özellikleri belirlenmiş $(227 \times 227 \times 3)$ girdi boyutu ile melspectogramlar ağa iletilirdi. AlexNet aşamasında, ses içeren bölümleri yakalaması için 11×11 kernel penceresi kullanıldı. Ayrıca çıktının genişlik ve yüksekliğini azaltmak için de 4 stride (Kernel penceresinin ana görüntüde kaç piksel kayacağını gösterir) adımı kullanıldı. Aktivasyon katmanı için de ReLu seçildi. Her bir girdi için 96 kez 11×11 filtreleme işlemi uygulandı. Sonrasında havuzlama katmanı için 3×3 boyutunda 2 stride adımı ile çalışan katman oluşturuldu. Konvolüsyon penceresi küçülerek, padding (resimin orijinal boyutunun korunması için 0 boyutlu pikseller eklenmesi) yöntemi kullanıldı. Her bir girdi için 256 kez 5×5 kernel penceresi kullanıldı. Sonrasında yeniden havuzlama katmanı için 3×3 boyutunda 2 stride adımı ile çalışan katman oluşturuldu. 384 kez 3×3 kernel penceresi ile konvolüsyon işlemi, ardından yeniden 384 kez 3×3 konvolüsyon işlemi ve son kez 256 kez 3×3 boyutunda konvolüsyon işlemi uygulandı. Havuzlama işlemi tekrardan yapılarak 4096 düğüme aktarıldı. ReLu aktivasyon fonksiyonu ile aşırı uydurmayı engellemeye yönelik dropout yöntemi kullanıldı. Değer olarak ($p = 0.5$) seçildi. Bu işlem 2 kez tekrarlanarak çıktı

katmanına bilgiler aktarıldı. Çıktı katmanı ise anksiyete analizi için 4 düğüm, duygu analizi için 7 düğümden oluşmaktadır. Aktivasyon fonksiyonu olarak sınıflandırılma yöntemlerinde sıkça kullanılan Softmax yöntemi seçildi.

ResNet Yapısı: Özellikleri belirlenmiş (227 x 227 x 3) girdi boyutu ile melspectogramlar ağı iletilir. İlk konvolüsyon katmanı için 7 x 7 kernel penceresi kullanılır. 64 kez bu işlem uygulanır. Sonrasında 3 x 3 boyutunda 2 stride adımı ile çalışan havuzlama katmanı uygulanır. 2. konvolüsyon katmanı 3 kez tekrarlanır her bir konvolüsyon işlemi 1 x 1 konvolüsyon 64 kez, 3 x 3 konvolüsyon 64 kez, 1 x 1 konvolüsyon 256 kez kullanılır. 1 x 1 konvolüsyon 128 kez 2 stride ile çalışan, 3 x 3 konvolüsyon 128 kez, 1 x 1 konvolüsyon 512 kez yapılır. Bu işlem de 1. katmandaki kayma adımı hariç altı kez daha yapılmıştır. 1 x 1, 256 kez 2 stride adımı ile çalışan konvolüsyon, 3 x 3 konvolüsyon 256 kez, 1 x 1 konvolüsyon 1024 kez yapılır. Bu işlem de 1. adımdaki kayma hariç altı kez daha yapılmıştır. En son konvolüsyon katmanı ise yine aynı yapıya benzer olarak 512 kez, 1. sinde kayma işlemi ile üç defa tekrarlanmıştır. En son çıktı katmanından önce 2048 kez konvolüsyon işlemi yapılır. Ortalama havuzu ile 2048 çıktı katmanı 1000 düğüm içeren tam bağlantılı katmanına iletilir.

Her iki analiz için ayrı ayrı ResNet50 mimarisi oluşturulmuştur. Çıktı katmanı ise tam bağlantılı katmandan sonra gelerek, anksiyete modeli için 4 düğüm, duygu modeli için 7 çıktı düğümden oluşmaktadır. Aktivasyon fonksiyonu olarak her iki modelde sınıflandırılma yöntemlerinden sıkça kullanılan Softmax yöntemi seçildi.

VGG-19 Yapısı: ResNet50 mimarisine benzer bir yapıdadır. VGG-19 adını yapısındaki 19 adet katmandan almaktadır. 16 konvolüsyon katmanı, 5 max pooling katmanı ve 2 tam bağlantılı katman kullanılarak yapılmıştır. Her iki analiz için ayrı ayrı VGG-19 modeli oluşturulmuştur. Çıktı katmanlarında ise anksiyete analizi 4 düğüm, duygu analizi için 7 düğümden oluşmaktadır. Aktivasyon fonksiyonu olarak her iki modelde sınıflandırılma yöntemlerinden sıkça kullanılan Softmax yöntemi seçildi.

3.10. Verilerin Analizi

DSKÖ'ye yönelik verilerin analizinde IBM SPSS Statistics 24.00 programı kullanılarak analizler yapılmıştır. Verilerin normallik dağılımı için çarpıklık ve basıklık değerlerine bakılarak, ± 1.5 aralığında ise normal dağıldığı, değil ise normal dağılmadığı şeklinde değerlendirilmiştir.

Durumluk ve sürekli kaygı puanlarının cinsiyet, çalışılan bölüm, COVID-19 tanısı alan kişilerin hasta bakımına katılım durumları ve COVID-19 hastalığına yakalanma durumlarına göre karşılaştırılmasında bağımsız örneklem T testi; formu doldurma yeri ve mesleklere göre karşılaştırılmasında tek yönlü varyans analizi kullanılmıştır. Sürekli değişkenler arasındaki ilişkiyi tespit etmek için Pearson korelasyon analizi kullanılmıştır ve korelasyon katsayıları ve güç ilişkisi Tablo 4'e göre değerlendirilmiştir.

Tablo 4. Korelasyon katsayıları ve güç ilişkisi

Katsayı Düzeyi	Güç açıklaması
$\pm 0.81 - \pm 1.00$	Çok güçlü
$\pm 0.61 - \pm 0.80$	Güçlü
$\pm 0.41 - \pm 0.60$	Orta
$\pm 0.21 - \pm 0.40$	Zayıf
$\pm 0.00 - \pm 0.20$	Çok zayıf

Ses ve görüntü verilerinin analizinde ise Google Colab, Jupyter Notebook ve Pycharm derleyicileri kullanıldı. Anksiyete analizde kullanılan sınıflandırma yöntemi için kişilerin anksiyete puanlarının ortalamaları kullanıldı. Ortalama durumluk anksiyete puanının üzerindeki bireyler “durumluk anksiyete var” durumluk anksiyete puanının altındaki bireyler “durumluk anksiyete yok” şeklinde etiketlendi.

Süreklilik anksiyetesi için süreklilik anksiyete puanlarının ortalaması kullanıldı. Ortalama süreklilik anksiyete puanının üzerindeki “süreklilik anksiyete var”, altındaki bireyler “süreklilik anksiyete yok”, olarak işaretlenerek ağa kullanılmak üzere veri seti hazırlandı. Kullanılan yöntemlerin ses ve görüntü verisinden anksiyete analizi kullanılan yöntemlerin başarıları ROC (Receiver Operating Characteristic) Eğrisi yöntemi ile gösterilerek oranları yüzdelik olarak ifade edildi.

4. BULGULAR

4.1. Sağlık Çalışanlarının Anket Formuna Yönelik Bulguları

4.1.1. Sağlık Çalışanlarının Tanımlayıcı İstatistikleri

Tablo 5. Sağlık çalışanlarının demografik bilgileri

		n	%
Yaş	Ort.±S. Sapma	33.16±	
	Min.-Max.	8.66	
Cinsiyet	Erkek	27	43.5
	Kadın	35	56.5
Çalışılan Bölüm	Acil Servis	29	46.8
	Poliklinik/Danışma/Arşiv Veri Giriş Personeli	12	19.4
	Yoğun Bakım Ünitesi	8	12.9
	Radyoloji/Laboratuvar Bölümü	7	11.3
	Anjiyo Katater Laboratuvarı	2	3.2
	Evde Bakım Personeli	2	3.2
	Ortopedi Teknikeri	2	3.2
Meslek	Hemşire	20	32.3
	Sağlık Teknisyeni/Teknikeri (ATT, Paramedik dahil)	19	30.6
	Veri Giriş/Kayıt Kabul Personeli	16	25.8
	Doktor	4	6.5
	Sağlık Memuru	3	4.8
Formu Doldurma Yeri	Evde	38	61.3
	08-16 mesaisi	13	21.0
	16-08 mesaisi	6	9.7
	24(08-08) mesaisi	5	8.1
COVID-19 Tanısı Alan Hasta Bakımına Katılım Durumu	Evet	31	50.0
	Hayır	31	50.0
COVID -19 Hastalığına Yakalanma Durumu	Evet	45	72.6
	Hayır	17	27.4
Toplam		62	100.0

Araştırmaya katılan 62 kişinin yaş ortalamasının 33.16 ± 8.66 ve 19-54 yaş arası kişilerin katılım sağladıkları; %43.5' inin erkek, %56.5' inin kadın olduğu; %46.8' inin acil servis, %19.4' ünün poliklinik/danışma/arşiv veri giriş personeli, %12.9' unun yoğun bakım ünitesi, %11.3' nün radyoloji/laboratuvar bölümü, %3.2' sinin anjiyo katater laboratuvar bölümü, %3.2' sinin evde bakım personeli ve %3.2' sinin ortopedi teknikerliği bölümlerinde görev yaptıkları; %32.3' ünün hemşire, %30.6' sının sağlık teknisyeni/teknikeri, %25.8' inin veri girişi/kayıt kabul merkezi, %6.5' inin doktor ve %4.8' inin sağlık memuru olarak görev yaptıkları; %61.3' ünün evde, %21.0' inin 08-16 mesaisi, %9.7' sinin 16-08 mesaisi, %8.1' inin 24 (08-08) mesaisinde formu doldurdıkları; %50.0' sinin COVID-19 tanısı alan hasta bakımına katıldıkları ve %72.6' sının COVID-19 hastalığına yakalandıkları tespit edildi (Tablo 5).

4.1.2. Sağlık Çalışanlarının DSKÖ'ye Yönelik Tanımlayıcı İstatistikleri

Durumluk ve sürekli kaygı puanlarına ilişkin tanımlayıcı istatistik sonuçları Tablo 6'da görülmektedir.

Tablo 6. DSKÖ Puanlarına ilişkin tanımlayıcı istatistik sonuçları

N=62	Ort.	S. Sapma	Min.	Max.	Çarpıklık	Basıklık
Durumluk Kaygı	41.48	4.64	31.00	52.00	0.58	0.21
Sürekli Kaygı	45.10	5.74	35.00	58.00	0.22	-0.68

Kaynak: Fidele, S., Tabachnick, B., Mestre, V., & Fidell, L. (2013). Aircraft noise-induced awakenings are more reasonably predicted from relative than from absolute sound exposure levels. *The Journal of the Acoustical Society of America*, 134(5), 3645-3653.

Durumluk kaygı puan ortalamasının 41.48 ± 4.64 ve sürekli kaygı puan ortalamasının 45.10 ± 5.74 olduğu saptandı. Field ve diğ. (2013), çarpıklık ve basıklık değerlerinin ± 1.5 aralığında ise verilerin normal dağılım gösterdiğini ifade etmiştir. Bu durumda durumluk ve sürekli kaygı çarpıklık ve basıklık değerleri ± 1.5 aralığında olduğundan veriler normal dağılım göstermektedir.

Durumluk ile sürekli kaygı puanları arasındaki korelasyon sonuçları Tablo 7'de yer almaktadır.

Tablo 7. DSKÖ Puanları arasındaki Korelasyon sonuçları

N=62	Durumluk Kaygı	Sürekli Kaygı
Durumluk Kaygı	r 1	0.39
	p	0.00*
Sürekli Kaygı	r 0.39	1
	p 0.00*	

r: Pearson Korelasyon, *p<0.01: Düzeyinde Anlamlı

Durumluk kaygı ile sürekli kaygı puanları arasında pozitif yönde zayıf düzeyde anlamlı bir ilişki olduğu tespit edildi ($r=0.39$; $p<0.01$). Elde edilen bulgular neticesinde kişilerin durumluk kaygı düzeyleri arttıkça sürekli kaygı düzeylerinin de arttığı düşünüldü.

4.1.3. Sağlık Çalışanlarının Tanımlayıcı Özelliklerine Göre Karşılaştırmalar

Yaş ile durumluk ve sürekli kaygı puanları arasındaki korelasyon sonuçları Tablo 8’de yer almaktadır.

Tablo 8. Yaş ile DSKÖ Puanları arasındaki Korelasyon sonuçları

N=62	Yaş
Durumluk Kaygı	r -0.02
	p 0.89
Sürekli Kaygı	r 0.01
	p 0.94

r: Pearson Korelasyon, *p< 0.05: Düzeyinde Anlamlı

Yaş ile durumluk kaygı ($r=-0.02$, $p> 0.05$) ve sürekli kaygı ($r= 0.01$, $p> 0.05$) puanları arasında anlamlı bir ilişki olmadığı saptandı.

COVID-19 hastalığına yakalanma durumuna göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 9’da yer almaktadır.

Tablo 9. COVID-19 (+), tanısı alma ile DSKÖ puanlarının karşılaştırılması

N=62	COVID-19 Hastalığına Yakalanma Durumu	n	Ort.	S. Sapma	T	p
Durumluk Kaygı	Evet	45	42.02	4.99	1.500	0.14
	Hayır	17	40.06	3.29		
Sürekli Kaygı	Evet	45	45.31	5.82	0.475	0.64
	Hayır	17	44.53	5.68		

T: Bağımsız Örneklem T Testi, *p<0.05: Düzeyinde Anlamlı

COVID-19 hastalığına yakalanan kişilerin durumluk kaygı puan ortalaması 42.02, COVID-19 hastalığına yakalanmayan kişilerin durumluk kaygı puan ortalaması 40.06 olup, COVID-19 hastalığına yakalanan ve yakalanmayan kişilerin durumluk kaygı puanları arasında anlamlı bir farklılık olmadığı tespit edildi ($p > 0.05$).

COVID-19 hastalığına yakalanan kişilerin sürekli kaygı puan ortalaması 45.31, COVID-19 hastalığına yakalanmayan kişilerin sürekli kaygı puan ortalaması 44.53 olup, COVID-19 hastalığına yakalanan ve yakalanmayan kişilerin sürekli kaygı puanları arasında anlamlı bir farklılık olmadığı tespit edildi ($p > 0.05$).

Cinsiyete göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 10'da yer almaktadır.

Tablo 10. Cinsiyete göre DSKÖ puanlarının karşılaştırılması

N=62	Cinsiyet	n	Ort.	S. Sapma	T	p
Durumluk Kaygı	Erkek	27	41.74	4.98	0.380	0.71
	Kadın	35	41.29	4.43		
Sürekli Kaygı	Erkek	27	44.93	5.51	-0.204	0.84
	Kadın	35	45.23	6.00		

T: Bağımsız Örneklem T Testi, *p<0.05: Düzeyinde Anlamlı

Erkeklerin durumluk kaygı puan ortalaması 41.74, kadınların durumluk kaygı puan ortalaması 41.29 olup, erkek ve kadınların durumluk kaygı puanları arasında anlamlı bir farklılık olmadığı tespit edildi ($p > 0.05$).

Erkeklerin sürekli kaygı puan ortalaması 44.93, kadınların sürekli kaygı puan ortalaması 45.23 olup, erkek ve kadınların sürekli kaygı puanları arasında anlamlı bir farklılık olmadığı saptandı ($p > 0.05$).

Çalışılan bölüme göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 11’de yer almaktadır.

Tablo 11. Çalışılan bölüme göre DSKÖ puanlarının karşılaştırılması

N=62	Çalışılan Bölüm	n	Ort.	S. Sapma	T	p
Durumluk Kaygı	Acil Servis	29	42.76	5.67	2.081	0.04*
	Diğer	33	40.36	3.20		
Sürekli Kaygı	Acil Servis	29	44.83	5.26	-0.344	0.73
	Diğer	33	45.33	6.21		

T: Bağımsız Örneklem T Testi, * $p < 0.05$: Düzeyinde Anlamlı

Acil serviste çalışanların durumluk kaygı puan ortalaması 42.76, diğer bölümde çalışanların durumluk kaygı puan ortalaması 40.36 olup; acil serviste çalışanların, diğer bölümde çalışanlara kıyasla durumluk kaygı puanlarının daha yüksek olması istatistiksel olarak anlamlı bulundu ($p < 0.05$).

Acil serviste çalışanların sürekli kaygı puan ortalaması 44.83, diğer bölümde çalışanların sürekli kaygı puan ortalaması 45.33 olup, acil serviste ve diğer bölümde çalışanların sürekli kaygı puanları arasında anlamlı bir farklılık olmadığı tespit edildi ($p > 0.05$).

COVID-19 tanısı alan hasta bakımına katılım durumuna göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 12’de yer almaktadır.

Tablo 12. COVID-19 hastalarının bakımına katılım ile DSKÖ puanlarının karşılaştırılması

N=62	COVID-19 Tanısı Alan Hasta Bakımına Katılım Durumu	n	Ort.	S. Sapma	T	p
Durumluk Kaygı	Evet	31	42.55	5.28	1.840	0.07
	Hayır	31	40.42	3.70		
Sürekli Kaygı	Evet	31	44.45	5.28	-0.883	0.38
	Hayır	31	45.74	6.19		

T: Bağımsız Örneklem T Testi, *p<0.05: Düzeyinde Anlamlı

COVID-19 tanısı alan hasta bakımına katılan kişilerin durumluk kaygı puan ortalaması 42.55, COVID-19 tanısı alan hasta bakımına katılmayan kişilerin durumluk kaygı puan ortalaması 40.42 olup, COVID-19 tanısı alan hasta bakımına katılan ve katılmayan kişilerin durumluk kaygı puanları arasında anlamlı bir farklılık olmadığı saptandı ($p>0.05$). COVID-19 tanısı alan hasta bakımına katılan kişilerin sürekli kaygı puan ortalaması 44.45, COVID-19 tanısı alan hasta bakımına katılmayan kişilerin sürekli kaygı puan ortalaması 45.74 olup, COVID-19 tanısı alan hasta bakımına katılan ve katılmayan kişilerin sürekli kaygı puanları arasında anlamlı bir farklılık olmadığı tespit edildi ($p>0.05$).

Formu doldurma yerine göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 13'te yer almaktadır.

Tablo 13. Formu doldurma yerine göre DSKÖ puanlarının karşılaştırılması

N=62	Formu Doldurma Yeri	n	Ort.	S. Sapma	F	p	Fark
Durumluk Kaygı	a. Evde	38	41.76	4.55	.249	0.78	-
	b. 08-16 mesaisi	13	41.38	5.47			
	c. 16-08/24(08-08) mesaisi	11	40.64	4.25			
Sürekli Kaygı	a. Evde	38	46.55	5.79	3.420	0.04*	a>b
	b. 08-16 mesaisi	13	42.62	4.82			
	c. 16-08/24(08-08) mesaisi	11	43.00	5.31			

F: Tek Yönlü Varyans Analizi, *p<0.05: Düzeyinde Anlamlı

Formu evde dolduran kişilerin durumluk kaygı puan ortalaması 41.76, 08-16 mesaisinde dolduran kişilerin durumluk kaygı puan ortalaması 41.38, (16-08) /24 (08-08) mesaisinde formu dolduran kişilerin durumluk kaygı puan ortalaması 40.64 olup; durumluk kaygı puanları formu doldurma yerine göre anlamlı bir farklılık göstermediği tespit edildi ($p > 0.05$).

Formu evde dolduran kişilerin sürekli kaygı puan ortalaması 46.55, 08-16 mesaisinde dolduran kişilerin sürekli kaygı puan ortalaması 42.62, (16-08)/ 24 (08-08) mesaisinde formu dolduran kişilerin sürekli kaygı puan ortalaması 43.00 olup; sürekli kaygı puanları formu doldurma yerine göre anlamlı bir farklılık gösterdiği saptandı ($p < 0.05$). Elde edilen bulgular neticesinde evde formu dolduran kişilerin 08-16 mesaisinde formu dolduran kişilere kıyasla sürekli kaygı düzeyleri daha yüksek bulundu.

Mesleğe göre durumluk ve sürekli kaygı puanlarının karşılaştırma sonuçları Tablo 14'te yer almaktadır.

Tablo 14. Mesleğe göre DSKÖ puanlarının karşılaştırılması

N=62	Meslek	n	Ort.	S. Sapma	F	p
Durumluk Kaygı	Hemşire	20	42.90	5.64	0.992	0.40
	Sağlık Teknisyeni/Teknikeri (ATT, Paramedik dahil)	19	40.53	3.37		
	Veri Giriş/Kayıt Kabul Personeli	16	41.25	4.91		
	Doktor/Sağlık Memuru	7	40.57	3.69		
Sürekli Kaygı	Hemşire	20	45.25	4.49	0.747	0.53
	Sağlık Teknisyeni/Teknikeri (ATT, Paramedik dahil)	19	45.05	6.72		
	Veri Giriş/Kayıt Kabul Personeli	16	46.19	6.81		
	Doktor/Sağlık Memuru	7	42.29	2.69		

F: Tek Yönlü Varyans Analizi, * $p < 0.05$: Düzeyinde Anlamlı

Hemşirelerin durumluk kaygı puan ortalaması 42.90, sağlık teknisyeni/teknikerlerin durumluk kaygı puan ortalaması 40.53, veri giriş/kayıt kabul personellerin durumluk kaygı puan ortalaması 41.25 ve doktor/sağlık memurların durumluk kaygı puan ortalaması 40.57 olup; durumluk kaygı puanları mesleklere göre anlamlı bir farklılık göstermediği saptandı ($p > 0.05$).

Hemşirelerin sürekli kaygı puan ortalaması 45.25, sağlık teknisyeni/teknikerlerin sürekli kaygı puan ortalaması 45.05, veri giriş/kayıt kabul personellerin sürekli kaygı puan ortalaması 46.19 ve doktor/sağlık memurların sürekli kaygı puan ortalaması 42.29 olup; sürekli kaygı puanları mesleklere göre anlamlı bir farklılık göstermediği bulundu ($p > 0.05$).

4.2. Sağlık Çalışanlarının Ses Verilerine Yönelik Bulguları

Ses verilerine yönelik analizde ilk dört soru için 248 adet duygu ifadesi elde edildi. (Ses kayıtlarındaki dengesiz dağılım sebebiyle örneklemin en küçük duygu içeren parçası dikkate alınarak ifadeler ~2 saniyelik parçalara bölündü.). Bunun sonucunda 7 duygu kategorisinde 299 duygu ses ve görüntü verisi elde edildi. Anksiyete yönelik son iki soru için 113 adet veri elde edildi.

4.3. Sağlık Çalışanlarının Makine Öğrenmesine Yönelik Bulguları

CNN tabanlı bir sınıflandırma algoritması geliştirmek için, 2 adet veri seti kullanıldı.

1. Veri seti duyguları içeren veri seti 7 adet duyguya ait 299 adet ses kaydı bulunmaktadır.
2. Veri seti ise 4 anksiyete durumu için 113 adet veriden oluşan. Bu çalışmadaki temel amaç duygularının belirlenmesi ve oluşturulan anksiyete modelinin başarısını test etmektir. Derin öğrenme yöntemlerinde en iyi modelin bulunması için farklı hiper parametrelerden yararlanıldı. Optimizasyon algoritmaları, öğrenme oranı, epoch sayısı gibi parametreler ile ağ üzerinde eğitim yapılmış en iyi sınıflandırma modelleri seçilmiştir.

1 boyutlu CNN yapısı ile oluşturulmuş duygu tanımlama modelinin eğitim ve test doğruluğu Tablo 15'teki gibidir.

Tablo 15. Duygu modelini eğitirken farklı hiper parametreler ve doğruluk oranları


Model	Epoch Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı
Model 1	50	Adadelta	34	1.76
Model 2	50	Sgd	35	1.74
Model 3	50	Adam	53	2.38
Model 4	50	Rmsprop	63	1.59
Model 5	100	Adadelta	34	1.75
Model 6	100	Sgd	34	1.78
Model 7	100	Adam	51	3.76
Model 8	100	Rmsprop	53	3,87

Duygu modeli eğitilirken Rmsprop optimizier'ı seçildi. En iyi model 50 epoch'ta 128 batch boyutunda çalışıldı. Öğrenme oranı ise ($lr= 0.0005$)'tir. Epoch sayısı arttıkça modelin başarısı artmakta ve aynı oranda hata oranı da artmaktadır. Ağın eğitim süresi de aynı oranda arttığı gözlemlenmiştir. Düşük öğrenme oranlarında ise ağın doğruluğu azalmakta ve hata oranı artmaktadır.


Tablo 16. Anksiyete modelini eğitirken farklı hiper parametreler ve doğruluk oranları

Model	Epoch Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı
Model 1	50	Adam	38	1.22
Model 2	50	Sgd	35	1.36
Model 3	50	Adadelta	35	1.43
Model 4	50	Rmsprop	58	0.98
Model 5	100	Adadelta	35	1.35
Model 6	100	Sgd	35	1.36
Model 7	100	Adam	67	1.22
Model 8	100	Rmsprop	73	1.59
Model 9	200	Rmsprop	71	2,28
Model 10	500	Rmsprop	58	4.49


Anksiyete modeli eğitilirken Rmsprop optimizier'ı seçildi. En iyi model 100 epoch'ta 128 batch boyutunda çalışıldı. Öğrenme oranı ise ($lr= 0.0005$)'tir. Epoch sayısı arttıkça modelin başarısı artmakta, bir süre sonra azalmaya ve aynı oranda hata oranı da artmaktadır. Ağın eğitim süresi de aynı oranda arttığı gözlemlenmiştir. Düşük öğrenme oranlarında ise ağın doğruluğu azalmakta ve hata oranı artmaktadır.




Resim 14. Modelin Doğruluğu epochs=50, batch_size=128'da %63.7'dir. Hata oranı 1.59'dur.




Resim 15. 1D CNN yapısı ile oluşturulmuş duygu tanımlama modelinin karmaşıklık matrisi



Resim 16. Modelin Doğruluğu epochs=100, batch_size=128’da %73.5’dir. Hata oranı 1.59’dur.



Resim 17. 1 boyutlu CNN yapısı ile oluşturulmuş anksiyete tanımlama modelinin karmaşıklık matrisi



Resim 18. Anksiyete analizinde 100 Epoch değerinde ResNet50 modelinin doğruluk ve test grafiği

Anksiyete analizinde en başarılı model ResNet50 modeli 200 Epoch'tan oluşan batch size= 32, optimizasyon olarak Softmax seçilmiştir. Test verisinin küçüklüğünden dolayı test verisinin doğruluğu %47.8 olarak kalmıştır. AlexNet ve VGG-19 yöntemlerinin doğrulukları %50'nin altında kalmıştır. Duygu sınıflandırması için en başarılı modelde 60, anksiyete sınıflandırması için 23 örnek ile F1 skoru 0.30 (Duygu), 0.35 (Anksiyete) gibi değerlerde kaldığından tablo halinde değerlendirilmemiştir.

Tablo 17. Duygu analizinde farklı CNN Algoritmalarının doğruluk ve hata oranları

Model	Epoch Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı
AlexNet	100	Adam	13	1.89
VGG19	100	Adam	21	2.46
ResNet50	100	Adam	36	1.91

Tablo 18. Anksiyete analizde farklı CNN algoritmalarının doğruluk ve hata oranları

Model	Epoch Sayısı	Optimizasyon Yöntemi	Doğruluk Oranı	Hata Oranı
AlexNet	100	Adam	26	1.62
ResNet50	100	Adam	52	1.05
VGG	100	Adam	56	1.45

Görüntü temelli geliştirilen metotlar farklı epoch sayıları, farklı optimizasyon yöntemleri kullanarak denenmiştir. En başarılı modeller 100 ve Adam optimizasyon olarak bulunmuştur. Algoritmaları denemek için Google Colab uygulaması kullanılmıştır. Görüntü temelli modellerin ağıdaki eğitim süreleri Jupyter Notebook uygulamasında yapılan 1D CNN modeline göre uzun daha uzun sürmektedir.

Tablo 19. Duygu model çıktıları (Ham test verisi)

	Kesinlik	Duyarlılık	F1 skoru	Örnek
Endişeli	0.43	0.33	0.38	9
Korkmuş	0.50	0.50	0.50	4
Kızgın	0.50	0.50	0.50	2
Mutlu	0.50	0.62	0.55	21
Sakin	0.33	0.14	0.20	7
Yorgun	0.10	0.20	0.13	5
Üzgün	0.56	0.38	0.45	13
Doğruluk			0.43	61
Makro Ortalama	0.42	0.38	0.39	61
Ağırlıklı Ortalama	0.45	0.43	0.43	61

Tablo 20. Anksiyete model çıktıları (Ham test verisi)

	Kesinlik	Duyarlılık	F1 skoru	Örnek
Durumluk	0.10	0.50	0.17	2
Anksiyete var				
Durumluk	0.33	0.10	0.15	10
Anksiyete yok				
Sürekli	0.00	0.00	0.00	3
Anksiyete var				
Sürekli	0.38	0.38	0.38	8
Anksiyete yok				
Doğruluk			0.22	23
Makro Ortalama	0.20	0.24	0.17	23
Ağırlıklı Ortalama	0.28	0.22	0.21	23

Tablo 19 ile Tablo 20’de verilen sonuçlara göre ham test verileri dikkate alındığında modelin başarısı her iki model içinde 0.50’nin altında kalmıştır.

Tablo 21. Sınıflandırıcı model çıktıları (Duygu)

	Kesinlik	Duyarlılık	F1 skoru	Örnek
Endişeli	0.83	0.53	0.65	19
Korkmuş	0.53	1.00	0.69	9
Kızgın	1.00	0.33	0.50	3
Mutlu	0.68	0.81	0.74	32
Sakin	0.57	0.44	0.50	9
Yorgun	0.00	0.00	0.00	3
Üzgün	0.62	0.50	0.55	16
Doğruluk			0.64	91
Makro Ortalama	0.60	0.52	0.52	91
Ağırlıklı Ortalama	0.66	0.64	0.63	91

Tablo 22. Sınıflandırıcı model çıktıları (Anksiyete)

	Kesinlik	Duyarlılık	F1 skoru	Örnek
Durumluk	0.83	0.83	0.83	6
Anksiyete var				
Durumluk	0.69	0.75	0.72	12
Anksiyete yok				
Sürekli	0.80	0.67	0.73	6
Anksiyete var				
Sürekli	0.70	0.70	0.70	10
Anksiyete yok				
Doğruluk			0.74	34
Makro Ortalama	0.76	0.74	0.75	34
Ağırlıklı Ortalama	0.74	0.74	0.74	34

Tablo 23. En başarılı modellerin sınıflandırıcı model çıktıları (Duygu-Anksiyete)

	Kesinlik	Duyarlılık	F1 skoru	Hassasiyet	Özgüllük	Örnek
Anksiyete	0.79	0.74	0.76	0.73	0.91	34
Analizi						
Duygu	0.52	0.63	0.63	0.63	0.94	91
Analizi						

Toplanan verilerden oluşturulan veri setine özellikler eklenerek veriler çoğaltılmıştır. Çoğaltılan verilerden oluşturulan 1 boyutlu CNN modelinde modelin doğruluğu, kesinlik, duyarlılık ve F1 skoru tabloda incelenmiştir (Tablo 23). Sonuçlara göre anksiyete analizi için toplam ortalama hassasiyet 0.73 ve toplam ortalama özgüllük 0.91; duygu analizi için ise toplam ortalama hassasiyet 0.63 ve toplam ortalama özgüllük 0.94'tür. Anksiyete analizi için algoritmanın test verisinin 34 örneğinin 26'sını doğru tahmin ettiği, duyarlılık oranının ise 74% olduğu görülmektedir. F1 skoru 0.76 olarak ölçülmüştür. Duygu analizi için, algoritmanın 91 örneğin 47'sini doğru tahmin ettiği, duyarlılık oranının ise 63% olduğu görülmektedir. F1 skoru 0.63 olarak ölçülmüştür.

5. TARTIŞMA ve SONUÇ

Bu bölümde araştırma verilerinin istatistiksel analizi sonucunda elde edilen bulgular literatür ışığında incelenmiştir. Çalışmaya katılan 62 sağlık çalışanının yaş ortalaması 33.16 ± 8.66 (Min.-Max.:19-54); %56.5' inin kadın olduğu; %46.8' inin acil serviste görev yaptıkları; %32.3' ünün hemşire olarak görev yaptıkları; %61.3' ünün evde formu doldurdıkları; %50.0' sinin COVID-19 tanısı alan hasta bakımına katıldıkları ve %72.6' sının COVID-19 hastalığına yakalandığı şeklinde dağılım göstermektedir. Ses analizi sonucunda toplamda 299 adet duyguya, 113 adet anksiyeteye yönelik veri elde edildi. Toplanan ses verileri, duygu analizi için 7 kategoride 299 veri, anksiyete analizi için 4 kategoride 113 adettir. Bu veriler çeşitli yöntemlerle arttırılmış şekli ile 909 duygu verisinden 91'i test, 339 anksiyete verisinden 34'ü test olmak üzere rastgele ayrılmıştır.

DSKÖ analizleri sonucunda katılımcıların durumluk kaygı puan ortalamasının 41.48 ± 4.64 ve sürekli kaygı puan ortalamasının 45.10 ± 5.74 olduğu saptandı. Bu veriler sağlık çalışanlarının kaygı düzeylerinin yüksek olduğunu göstermektedir. Pandemiye bağlı kaygı düzeylerinin değerlendirildiği çalışmalarda sağlık çalışanlarının daha çok ruhsal problem yaşadığı tespit edilmiştir (86, 87, 88, 89). Que ve ark. (2020)'nın COVID-19 pandemisinin sağlık çalışanları üzerine etkisini incelediği çalışmada, sağlık çalışanlarının yüksek oranda anksiyete yaşadığı ve sağlık çalışanlarının anksiyete düzeyleri karşılaştırıldığında en üst sırada hemşirelerin olduğu tespit edilmiştir (90). Lai ve ark. (2019)'nın sağlık çalışanları üzerine yaptığı çalışmada Oue ve ark. (2020) ile benzer sonuçlara ulaşmış olup ek olarak en yüksek anksiyeteyi doğrudan hastalara temas edenlerin yaşadığını ortaya koymuştur (91). Bu sonuç bizim çalışmamızı, acil serviste çalışan sağlık çalışanlarının durumluk kaygı puan ortalaması (42.76), diğer bölümde çalışanların durumluk kaygı puan ortalamasına (40.36) kıyasla daha yüksek olması sonucunu destekler niteliktedir. Acil serviste çalışan sağlık çalışanlarının kaygı düzeylerinin yüksek olması belirsiz hasta karşılama ve belirsiz süreyle hastaya temas etme sebeplerine bağlanabilir. Anket formunu evde formu dolduran katılımcıların 08-16 mesaisinde formu dolduran kişilere kıyasla sürekli kaygı düzeyleri daha yüksek olduğu saptandı. COVID-19 pandemisi sırasında evde kronik hastalığı olan birinin varlığı, vardiya sonrasında temas edilen hasta sayısının fazla olması ve evde COVID-19 belirtilerini fark edip tedirgin olma, belirsiz vardiya düzeni, evde koruyucu ekipman olmaması gibi problemlerle karşılaşılması ile evde sorumlulukların artması ve buna bağlı olarak kaygı düzeyinin de artmasına sebep olabileceği düşünülebilir. COVID-19 (+) hastaların bakımına katılma durumuna göre bakıma katılım sağlayan ve katılım

sağlamayanlar arasında herhangi bir fark saptanmadı. COVID-19 (+) hastaya bakım verirken temas etme durumu temas etme riskini ortadan kaldırmaz. Bu sebeple tüm sağlık çalışanları doğrudan veya dolaylı yoldan risk altındadır.

Çalışmamızın sonuçları literatürdeki çalışmalara benzerlik göstermektedir. Çalışma saatinde artış, iş yükü fazlalığı, tanısı belli olmayan vakalar, pandemiye yönelik bilgi eksikliği, bilinmezlik ve damgalanma, geleceğe yönelik belirsizlik gibi durumlar sağlık çalışanlarının kaygı düzeylerinin artmasına neden olduğu düşünülmektedir. Pandemi sürecinin en büyük etkilerinden biri de teknolojiyi kullanarak etkileşim kurmanın artışıdır. Bu süreçte temastan kaçınılması sebebiyle artan kaygı düzeylerinin de teknoloji aracılığı ile tahmin edilebileceği düşünülmektedir. Dolayısıyla duygu durumu belirleyen ölçeklerin ses verisi ile yapılabilirliğini ortaya konulmaya çalışılmıştır (92).

Derin öğrenme yöntemlerinden birisi olan CNN, en çok tercih edilen sınıflandırma modeli olan 1D CNN, VGG-16, ResNet ve AlexNet gibi yöntemler çalışmamızda kullanılmıştır. Duygu ve anksiyete tahmini modellerinde en başarılı model 1D CNN modeli olmuştur. 1D CNN modelinin başarılı olmasının sebebi direk olarak ses verisi üzerinde çalışma avantajı olduğu düşünülebilir. Literatürdeki çalışmalara bakıldığında yapılan çalışmalar genellikle bir kütüphane (RAVDESS, TESS, CREMA, EMODB) verileri üzerine yapılan çalışmalar olduğu görülmektedir. Demirtaş ve Hakdağlı tarafından (2022) yapılan bir çalışmada hazır kütüphaneler ve Türkçe dizi, film ve kısa videolardan oluşturulmuş veri seti üzerinde yapılan çalışmada %85 doğruluğa ulaşılmıştır (93). Atila ve Şengür (2021) tarafından 3D CNN-LSTM modeli kullanılarak tasarlanan çalışmada en yüksek doğruluğu %98.33 sakin ses ve en düşük doğruluk %75 ile kızgın seste bulunmuştur (94). Michael ve Kandali (2022) tarafından MFCC yöntemi kullanılarak yapılan çalışmada ise mutlu, üzgün ve kızgın duygularının doğrulamasında %80 tahmin başarısına ulaştığı görülmüştür (95). Pandey ve ark. (2019) tarafından yapılan ve MFCC ile BLSTM mimarisi ile tasarlanmış CNN yöntemi kullanılan çalışmada başarı oranı %82.35'tir. IEMOCAP veri seti için sonuçlar ve EMO-DB veri seti kullanılarak yapılan çalışmada ise %92.02 doğruluk ile başarı oranına ulaşılmıştır (96). Balaha ve ark. tarafından 2020 yılında 11 veri seti ile 14.416 özellik kullanılarak yapılan çalışmada CNN ve makine öğrenmesi yöntemleri hibrit olarak kullanılarak model tasarlanmıştır. Ekstra Ağaç Sınıflandırıcı (ETC) ve Rastgele Orman Sınıflandırıcı (RFC) %100'e CNN yöntemi kullanılarak 99.17% doğruluğa ulaşılmıştır (97).

Geliştirilen CNN modelimizde, 91 duygu test verisi için %64 doğruluk, %52 kesinlik, %63 duyarlılık, %94 özgüllük değerleri; 34 anksiyete test verisi için %74 doğruluk, %79 kesinlik, %74 duyarlılık, %91 özgüllük değerleri elde edilmiştir. Toplam sonuçlar incelendiğinde anksiyete analizi için ortalama hassasiyet 0.73 ve ortalama özgüllük 0.91; duygu analizi için ise ortalama hassasiyet 0.63 ve ortalama özgüllük 0.94'tür. Oluşturduğumuz CNN modelinde ağ eğitilirken “mutlu ve korkmuş” gibi sınıflandırma yöntemlerinde en iyi başarı sağlanmasına rağmen “yorgun ve kızgın” gibi sınıflarda dengesiz veri dağılımından ötürü başarı oranı düşüktür. Anksiyete analizinde kesinliğin daha yüksek çıkma sebebi 4 değişken olmasına (duygu analizinde 7 değişken mevcut), duygu analizinde duyarlılığın daha yüksek olmasının sebebi ise 7 değişken olmasına bağlanabilir. Bu çalışma, anksiyete analizinde duygu analizine göre daha iyi performans gösteren bir algoritmanın olduğunu göstermektedir. Tüm sonuçlara bakıldığında, her iki modelin de modelinin özgüllük oranının yüksek çıkması, modellerin negatif sınıfı doğru bir şekilde tanımladığı anlamına gelir ve modellerin negatif sınıftaki örnekleri yanlış pozitif olarak etiketleme eğiliminde olmadığını göstermektedir. Hassasiyetin yüksekliği, gerçek anksiyete sınıfına ait olan örneklerin ne kadarının model tarafından doğru bir şekilde tanımlandığını gösterir. Her iki modelimiz birbiri arasında karşılaştırıldığında model anksiyete analizi için daha hassas ve duygu analizi için daha özgüldür. Anksiyete analizinde kullanılan yöntemler kısmi farklılıklar göstermekle beraber çalışmamızla yakın sonuçlara ulaşılmıştır. Ham verilerin seçildiği modelde başarı oranının düşük olmasının sebebi dengesiz veri seti ve yetersiz test verisinin olduğu düşünülmektedir. Konuşma yapısı ve dil özelliklerinin çıkarıldığı bir modelle geliştirilmiş makine öğrenmesi yöntemine göre anksiyete ve depresyon sınıflandırılması yapılmış depresyon için 0.58'den 0.63'e ve anksiyete için 0.54'ten 0.57'ye F1 skoruna ulaşılmıştır (98). Çalışma da anksiyete tahmininin depresyon tahmininden daha zorlu bir sınıflandırma olduğu sonucuna ulaşılmıştır. 2021'de Nath ve ark.'nın yaptığı çalışmada ruhsal hastalıkların teşhisi için 60-80 yaş aralığında 41 sağlıklı yaşlı yetişkinden (26 kadın ve 15 erkek) veriler toplanmış oluşturulmuş, bu veri seti ile depresyon ve anksiyete şiddetini ölçmek için ses bilimi ve dilbilimsel özellikleri içeren bir makine öğrenmesi modeli tasarlanmıştır. Elektrodermal aktivite ve fotopletismogram gibi basit bileklik sensörlerini ve bir bağlam temelli özelliği kullanarak yaşlı yetişkinlerde anksiyete tespiti ve DSKÖ ile algılanan anksiyete verilerinden elde edilen modelle daha yüksek F1 skoruna ulaşılmıştır. Bu çalışmayla makine öğrenmesi yönteminde başarı yakalanmıştır (99). Espinola ve ark. (2022) ses, akustik analiz ve makine öğrenme yöntemini kullanarak major depresif

bozukluk, bipolar bozukluk, şizofreni ve genelleştirilmiş anksiyete bozukluğunun teşhisini desteklemek için bir yöntem önermiştir. 18 yaşın üzerindeki major depresif bozukluğu olan 28; şizofrenisi olan 20; bipolar bozukluğu olan 15; genelleştirilmiş anksiyete bozukluğu olan 4 ve 12 sağlıklı (kontrol grubu) katılımcı ile toplamda 78 kişilik örneklem beş gruba ayrılarak incelenmiştir. Veriler üzerinde ses özellik çıkarım algoritması ve farklı makine öğrenimi sınıflandırma teknikleri ile denemeler yapılmıştır. 300 ağaçlı rastgele orman yöntemi ile major depresif bozukluk, şizofreni, bipolar bozukluk ve genelleştirilmiş anksiyete bozukluğunun aynı anda tespiti için en yüksek sınıflandırma performansını doğruluk için %75.27, Kappa için %69.08, hassasiyet için %75.30 ve özgüllük için %93.80 sağlamıştır (100).

Literatürde duygu çıkarımı üzerine yapılan çalışmalarda CNN sınıflandırma yöntemlerinin başarılı olduğu görülmüştür. Anksiyeteye yönelik makine öğrenmesi çalışmalarında benzer sonuçlar yakalanmıştır. Çalışmamızda yer alan kısıtlarla benzer şekilde kısıtlar yakalanmıştır. Çalışmamızda benzer şekilde CNN sınıflama yöntemi başarılı bulunmuş olsa da diğer çalışmalara kıyasla başarı oranı düşük seyretmektedir. Bunun sebebinin araştırmanın sınırlılıkları olduğu düşünülmektedir. Araştırma sürecinde katılımcı bulmanın zorluğu, katılımcıların COVID-19 pandemi sırasında aktif alanda çalışan sağlık çalışanları olması, ses kaydı esnasında zamanın yetersiz olması veya arka planda gürültü olduğunda kaydın tekrarlanması, araştırmanın zamanın kısıtlı olması ve tek merkez ile sınırlı kalması, ölçek kullanımı sebebiyle seçim yanlılığının olması, ses tonu ve konuşma şekli ile duygu durumu anlaşılmaya çalışılsa da katılımcıyı mimik, yüz ifadesi gibi katılımcının duygu durumu destekleyici davranışların ölçülememesi, katılımcının anket formunu hangi ortam bağlamında doldurduğu bilgisinin alınamaması ve bu durumun ses tonu ve sözcük seçimi üzerine etkisinin bilinmemesi, katılımcıların pandemi sürecinin yüz yüze görüşmeye izin vermemesi ve bu süreçte katılımcıların duygu durumunun değişken olması gibi durumlar araştırmanın sınırlılıkları olarak düşünülmüştür. Bu çalışmanın temelini amaç sadece ses verisi ile duygu durumu sınıflandırabilmek veya yazılı/sözlü ölçek/nitel verilere ihtiyaç duymadan ölçebilmek oluşturmaktadır. Daha doğru bir sınıflandırma yöntemi yapılması için daha büyük veri seti, gürültüden uzak ses kayıtları ve kullanıcılara sabit sorular sorulması gibi özellikler çıkarılarak bir model hazırlanması önerilmektedir. Veri seti eğitimi için seçilen katılımcıların anksiyete veya herhangi bir ruhsal hastalık tanısı almış olması modelin veri kümesini genişleterek daha kararlı bir sistemin ortaya çıkmasına yardımcı olacaktır.

Ayrıca bu çalışmada ses verisi üzerinde anksiyete duygusunun Türkçe dilinde konuşmacılardan oluşan veri seti ve CNN modeliyle sınıflandırdığı makine öğrenmesi alanında öncü çalışmalardandır. Bununla birlikte geliştirilen modelin gelecek çalışmalarda görüntü ve video kaydı gibi yöntemlerle desteklenmesi modelin başarısını arttıracığı öngörülmektedir.



6. KAYNAKLAR

1. Latinus M, Belin P (2011). Human voice perception. *Current Biology* 22 21(4): 143-145.
2. Basu S, Chakraborty J, Bag A, Aftabuddin M (2017). A review on emotion recognition using speech. In *Proceedings of the 2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*, Coimbatore, India, 10-11 March 2017, 109-114.
3. Erdem ES, Sert M (2014). Efficient Recognition of Human Emotional States from Audio Signals, 2014 IEEE International Symposium on Multimedia, Taichung, Taiwan, 12 December 2014, 139-142.
4. Schuller B, Vlasenko B, Eyben F, Rigoll G, Wendemuth A (2009). Acoustic emotion recognition: A benchmark comparison of performances. *Workshop on Automatic Speech Recognition & Understanding*, Merano, Italy, 13-17 December 2009, 552-557.
5. Chi TS, Yeh LY, Hsu CC (2012). Robust emotion recognition by spectro-temporal modulation statistic features. *Journal of Ambient Intelligence and Humanized Computing* 3(1): 47-60.
6. Kabadayı ET, Koçak AA (2013). Duygu tipolojilerinin tüketici davranışları üzerindeki etkisi ve pazarlamadaki önemi. *İşletme Araştırmaları Dergisi* 5(1): 93-114.
7. Parlak C, Diri B (2014). Farklı Veri Setleri Arasında Duygu Tanıma Çalışması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* 16(48): 21-29.
8. Cunningham S, Ridley H, Weinel J, Picking R (2020). *Proceedings of the 14th International Audio Mostly Conference: A Journey in Sound*, Nottingham, United Kingdom, 18-20 September 2019, 1-14.
9. Li TM, Chao HC, Zhang J (2019). Emotion classification based on brain wave: a survey. *Human-centric Computing and Information Sciences* 9(1): 1-17.
10. Velavan TP, Meyer CG (2020). The COVID-19 epidemic. *Tropical Medicine and International Health* 25(3): 278.
11. Sağlık çalışanları vaka ve ölüm oranları [internet]. Erişim adresi: <https://www.bbc.com/turkce/live/haberler-turkiye-55240692> [Erisim Tarihi: 20 Ocak 2021]
12. Sakaoglu HH, Orbatu D, Emiroglu M, Çakır Ö (2020). Covid-19 Salgını Sırasında Sağlık Çalışanlarında Spielberger Durumluk ve Sürekli Kaygı Düzeyi: Tepecik Hastanesi Örneği. *Tepecik Eğitim ve Arastırma Hastanesi Dergisi* 30: 1-9.

13. Bozkurt E, Erzin E, Eroglu EÇ, Erdem T (2010). INTERSPEECH 2009 duygu tanıma yarışması değerlendirmesi. IEEE 18th Signal Processing and Communications Applications Conference, Diyarbakir, 22-24 Nisan 2010, 216-219.
14. Shirani A, Nilchi ARN (2016). Speech Emotion Recognition based on SVM as Both Feature Selector and Classifier. International Journal of Image, Graphics & Signal Processing 8(4): 39-45.
15. Zhao J, Xia M, Lijiang C (2019). Speech emotion recognition using deep 1D & 2D CNN LSTM networks. Biomedical signal processing and control 47: 312-323.
16. Demircan S, Kahramanlı H (2018). Application of fuzzy C-means clustering algorithm to spectral features for emotion classification from speech. Neural Computing and Applications 29: 59-66.
17. ER, Mehmet Bilal. Önceden Eğitilmiş Derin Ağlar ile Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması. Konya Mühendislik Bilimleri Dergisi 9(1): 193-204.
18. Dilbaz N (2000). Sosyal Anksiyete Bozukluğu: Tanı, Epidemiyoloji, Etiyoloji, Klinik ve Ayırıcı Tanı. Turkish Journal of Clinical Psychiatry 3(2): 3-21.
19. Türkçapar H (2004). Anksiyete bozukluğu ve depresyonun tanısall ilişkileri. Klinik Psikiyatri 4: 12-16.
20. McGinnis EW, Anderau SP, Hruschak J, Gurchiek RD, Lopez-Duran NL, Fitzgerald K, McGinnis RS. (2019). Giving voice to vulnerable children: machine learning analysis of speech detects anxiety and depression in early childhood. IEEE journal of biomedical and health informatics 23(6): 2294-2301.
21. Tasnim M, Ehghaghi M, Diep B, Novikova J (2022). Depac: a corpus for depression and anxiety detection from speech. In Proceedings of the Eighth Workshop on Computational Linguistics and Clinical Psychology, Seattle, U.S.A, 15 July 2022, 1-16.
22. Grennan D (2019). What is a Pandemic. Jama 321(9): 910-910.
23. Ciotti M, Ciccozzi M, Terrinoni A, Jiang WC, Wang CB, Bernardini S (2020). The COVID-19 pandemic. Critical reviews in clinical laboratory sciences 57(6): 365-388.
24. Usher K, Durkin J, Bhullar N (2020). The COVID-19 pandemic and mental health impacts. International journal of mental health nursing 29(3): 315.
25. Dong L, Bouey J (2020). Public mental health crisis during COVID-19 pandemic, China. Emerging infectious diseases 26(7): 1616.

26. Kutlu M, Özsoy F (2021). Sağlık çalışanları dışı toplumsal örnekleme COVID-19 anksiyete ve sağlık anksiyetesi düzeyleri. *Kocaeli Tıp Dergisi* 10.Supp (1): 112-117.
27. Saeed H, Eslami A, Nassif NT, Simpson AM, Lal S (2022). Anxiety linked to COVID-19: a systematic review comparing anxiety rates in different populations. *International journal of environmental research and public health* 19(4): 2189.
28. Özdin S, Bayrak Özdin Ş (2020). Levels and predictors of anxiety, depression and health anxiety during COVID-19 pandemic in Turkish society: The importance of gender. *International Journal of Social Psychiatry* 66(5): 504-511.
29. Amstadter A (2008). Emotion regulation and anxiety disorders. *Journal of anxiety disorders* 22(2): 211-221.
30. Ömer A, Sezerol M, Taşcı Y, Hayran O (2020). COVID-19 pandemisinde görev yapan sağlık çalışanlarında anksiyete belirtileri ve uykusuzluk. *Turkish Journal of Public Health* 18(COVID-19 Special): 47-57.
31. Polat Ö, Coşkun F (2020). COVID-19 Salgınında sağlık çalışanlarının kişisel koruyucu ekipman kullanımları ile depresyon, anksiyete, stres düzeyleri arasındaki ilişkinin belirlenmesi. *Batı Karadeniz Tıp Dergisi* 4(2): 51-58.
32. Arpacıoğlu S, Baltalı Z, Ünübol B (2021). COVID-19 pandemisinde sağlık çalışanlarında tükenmişlik, Covid korkusu, depresyon, mesleki doyum düzeyleri ve ilişkili faktörler. *Cukurova Medical Journal* 46(1): 88-100.
33. Pappa S, Ntella V, Giannakas T, Giannakoulis VG, Papoutsis E, Katsaounou P. (2020) Prevalence of depression, anxiety, and insomnia among healthcare workers during the COVID-19 pandemic: A systematic review and meta-analysis. *Brain, behavior, and immunity* 88: 901-907.
34. Öztürk K, Şahin ME (2018). Yapay sinir ağları ve yapay zekâ 'ya genel bir bakış. *Takvim-i Vekayi* 6(2): 25-36.
35. Xu Y, Liu X, Cao X, Huang C, Liu E, Qian S, Zhan J (2021). Artificial intelligence: A powerful paradigm for scientific research. *The Innovation* 2(4): 100179.
36. Peng GC, Alber M, Buganza Tepole A, Cannon WR, De, S, Dura-Bernal S, Kuhl E (2021). Integrating machine learning and multiscale modeling—perspectives, challenges, and opportunities in the biological, biomedical, and behavioral sciences. *NPJ digital medicine* 2(1): 115.
37. Erickson BJ, Korfiatis P, Akkus Z, Kline TL (2017). Machine learning for medical imaging. *Radiographics* 37(2): 505-515.

38. Le CY, Bengio Y, Hinton G. (2015). Deep learning. *Nature* 521(7553): 436-444.
39. Jabbar H, Khan RZ (2015). Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices* 70: 163-172.
40. Hastie T, Tibshirani R, Friedman JH, Friedman JH (2009). The elements of statistical learning: data mining, inference, and prediction, Springer Newyork 2: 37-38.
41. Van der Aalst WMP, Rubin V, Verbeek HMW, van Dongen BF, Kindler E, Günther CW (2010). Process mining: a two-step approach to balance between underfitting and overfitting. *Software and Systems Modeling* 9: 87-111.
42. Sheridan RP (2013). Time-split cross-validation as a method for estimating the goodness of prospective prediction. *Journal of chemical information and modeling* 53(4): 783-790.
43. Amidi A, Amidi A (2018). Makine Öğrenmesi İpuçları ve Püf Noktaları El Kitabı [online]. Available from: <https://stanford.edu/~shervine/l/tr/teaching/cs-229/cheatsheet-machine-learning-tips-and-tricks> [Accessed 20 January 2023]
44. Mehrabi N, Morstatter F, Saxena N, Lerman K, Galstyan A (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys (CSUR)* 54(6): 1-35.
45. Bias-Variance Tradeoff Available from: <https://www.ml-science.com/bias-variance-tradeoff> [Accessed 20 January 2023]
46. Brain D, Webb G. (1999). On the effect of data set size on bias and variance in classification learning. In: *Proceedings of the Fourth Australian Knowledge Acquisition Workshop*, University of New South Wales, Sydney, Australia, 5-6 December 1999, 117-128.
47. Şeker A, Diri B, Balık HH (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi* 3(3): 47-64.
48. Goodfellow I, Bengio Y, Courville A (2016). Deep learning. Massachusetts Institute of Technology (MIT) Press, Londra; Sayfa: 136-151.
49. Türkmenoğlu C (2016). Türkçe Metinlerde Duygu Analizi. Doktora Tezi, Fen Bilimleri Enstitüsü Bilgisayar Bilimleri Anabilim Dalı, İstanbul
50. McGilloway S, Cowie R, Douglas-Cowie E, Gielen S, Westerdijk M, Stroeve S (2000). Approaching automatic recognition of emotion from voice: A rough benchmark. In *ISCA Tutorial and Research Workshop (ITRW) on Speech and Emotion*. Dublin, Ireland, 5-7 September 2000, 207-212.

51. Hu W, Huang G, Li L Zhang L Zhang Z, Liang Z (2020). Video-triggered EEG-emotion public databases and current methods: a survey. *Brain Science Advances* 6(3): 255-287.
52. Çolakoğlu E, Hızlısoy S, Arslan RS (2021). Konuşmadan Duygu Tanıma Üzerine Detaylı bir İnceleme: Özellikler ve Sınıflandırma Metotları. *Avrupa bilim ve teknoloji dergisi* (32): 471-483.
53. Öner N, Le-Compte A. (1983). Durumluk Sürekli Kaygı Envanteri El Kitabı. Boğaziçi Üniversitesi Yayınları, İstanbul, 1-26.
54. Seo M, Kim M (2020). Fusing visual attention CNN and bag of visual words for cross-corpus speech emotion recognition. *Sensors* 20(19): 5559.
55. Düz M (2018). Fourier Dönüşümünün Yardımı ile Belirsiz Katsayılar Metoduna Alternatif bir Metod. *Karaelmas Fen ve Mühendislik Dergisi* 8(1): 268-272.
56. Fourier Dönüşümü Nedir? [internet]. Erişim adresi: <https://blog.dta.com.tr/fourier-donusumu-nedir/> [Erişim Tarihi 20 Ocak 2023]
57. Kalhara PG, Jayasinghearachchi VD, Dias AHAT, Ratnayake VC, Jayawardena C, Kuruwitaarachchi N (2017). TreeSpirit: Illegal logging detection and alerting system using audio identification over an IoT network. In 2017 11th International Conference on Software, Knowledge, Information Management and Applications (SKIMA), Malabe, Sri Lanka, 06-08 December 2017, 1-7.
58. Cochran WT, Cooley JW, Favon DL, Helms HD, Kaenel RA, Lang WW, Welch PD (1967). What is the fast Fourier transform. *Proceedings of the IEEE* 55(10): 1664-1674.
59. Meng H, Yan T, Yuan F, Wei H (2019). Speech emotion recognition from 3D log-mel spectrograms with deep learning network *IEEE* 7: 125868-125881.
60. Kovitvongsa KE, Lobe PS, Phillip S (2009). Convenient fish acoustic data collection in the digital age. In: *Diving for Science 2009. Proceedings of the American Academy of Underwater Sciences 28th Symposium*, Dauphin Island, Alabama, U.S.A., 13-14 March 2009, 43-57.
61. Thakur G, Mehta J, Gandhi D, Kanani P (2021). Music Genre Classification using Transfer Learning on log-based MEL Spectrogram, 2021 5th International Conference on Computing Methodologies and Communication (ICCMC), Erode, 29-31 March 2022, 1101-1107.
62. Gupta G, Kshirsagar M, Zhong M, Gholami S, Ferres JL (2021). Comparing recurrent convolutional neural networks for large scale bird species classification. *Scientific reports* 11(1): 17085.

63. Bhalke DG, Rao CR, Borman DS (2016). Automatic musical instrument classification using fractional fourier transform based-MFCC features and counter propagation neural network. *Journal of Intelligent Information Systems* 46: 425-446.
64. Aung MSH, Alquaddoomi F, Hsieh CK, Rabbi M, Yang L, Pollak JP, Choudhury T (2016). Leveraging multi-modal sensing for mobile health: a case review in chronic pain. *IEEE journal of selected topics in signal processing* 10(5): 962-974.
65. Aghdam HH, Heravi EJ (2017). *Guide to convolutional neural networks*. New York, NY: Springer 10(978-973): 51.
66. Hajarolasvadi N, Demirel H (2019). 3D CNN-based speech emotion recognition using k-means clustering and spectrograms. *Entropy* 21(5): 479.
67. Yıldız O (2019). Derin öğrenme yöntemleriyle dermoskopi görüntülerinden melanom tespiti: Kapsamlı bir çalışma. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 34(4): 2241-2260.
68. Lin G, Shen W (2018). Research on convolutional neural network based on improved Relu piecewise activation function. *Procedia computer science* 131: 977-984.
69. İnik Ö, Ülker E (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi* 6(3): 85-104.
70. Sun Y, Wen G (2017). Ensemble softmax regression model for speech emotion recognition. *Multimedia Tools and Applications* 76: 8305-8328.
71. Zhang Z, Sun C (2021). Structural damage identification via physics-guided machine learning: a methodology integrating pattern recognition with finite element model updating. *Structural Health Monitoring* 20(4): 1675-1688.
72. Gökalp S, Aydın İ (2021). Farklı Derin Sinir Ağı Modellerinin Duygu Tanımadaki Performanslarının Karşılaştırılması. *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 2(1): 35-43.
73. Bagaskara A, Suryanegara M (2021). 4th International Conference of Computer and Informatics Engineering (IC2IE), Depok, Indonesia, 14-15 September 2021, 1-4.
74. He K, Zhang X, Ren S, Sun J (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, 27-30 June 2016, 770-778.
75. Benli SN (2021). Derin evrişimli yapay sinir ağı kullanarak meyve yaprağı hastalık tespiti. Yüksek Lisans Tezi. Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü. Bilecik

76. Yavaş G. PyCharm Nedir? [internet]. Erişim adresi: <https://medium.com/gokhanyavas/pycharm-nedir-ilk-python-uygulamamız-53a0ba0af18f> [Accessed 18 Kasım 2022]
77. Jupyter Noteook Beginner Guide Available from: https://jupyter-notebook-beginner-guide.readthedocs.io/en/latest/what_is_jupyter.html [Accessed 18 November2022]
78. Google Colaboratory [online]. Available from: <https://research.google.com/colaboratory/faq.html> [Accessed 18 November 2022]
79. Kartal E, Özen Z (2017). Dengesiz veri setlerinde sınıflandırma. Mühendislikte Yapay Zekâ ve Uygulamaları, 1. Baskı, Torkul O, Gülseçen S, Uyaroğlu Y, Çağıl G, Uçar MK, (Ed.), Sakarya Üniversitesi Kütüphanesi Yayınevi, Sakarya, Sayfa: 109-131.
80. Ioffe S (2017). Batch renormalization: Towards reducing minibatch dependence in batch-normalized models. Advances in neural information processing systems, 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, U.S.A, 4-9 December 2017, 30.
81. Xu D, Xia Y, Mandic DP (2015). Optimization in quaternion dynamic systems: Gradient, hessian, and learning algorithms. IEEE transactions on neural networks and learning systems 27:(2) 249-261.
82. Brownlee, J. (2018). What is the Difference Between a Batch and an Epoch in a Neural Network. Machine Learning Mastery, [online]. Available from: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/> [Accessed 18 November 2022]
83. Wang Y, Li Y, Song Y, Rong X (2020). The influence of the activation function in a convolution neural network model of facial expression recognition. Applied Sciences 10:(5) 1897.
84. UK Agarwal, S Makhija, V Tripathi, K Singh (2022). An Investigation into Neuromorphic ICs using Memristor-CMOS Hybrid Circuits. Yüksek Lisans Tezi, Netaji Subhas University Of Technology, Department of Electronics and Communication Engineering, Yeni Delhi.
85. Zisad SN, Hossain MS, Andersson K (2020). Speech emotion recognition in neurological disorders using convolutional neural network. In Brain Informatics: 13th International Conference, Padua, Italy, 19 September 2020, 287-296.

86. Çölgeçen Y, Çölgeçen H (2020). Covid-19 Pandemisine Bağlı Yaşanan Kaygı Düzeylerinin Değerlendirilmesi: Türkiye Örneği. *Electronic Turkish Studies* 15:(4) 261-275.
87. Lee AM, Wong JG, McAlonan GM, Cheung V, Cheung C, Sham PC, Chua SE (2007). Stress and psychological distress among SARS survivors 1 year after the outbreak. *The Canadian Journal of Psychiatry* 52(4): 233-240.
88. Nickell LA, Crighton EJ, Tracy CS, Al-Enazy H, Bolaji Y, Hanjrah S, Upshur RES, Hussain A, Makhoul S (2004). Psychosocial effects of SARS on hospital staff: Survey of a large tertiary care institution. *CMAJ* 170(5): 793-798.
89. Robertson E, Hershenfield K, Grace SL, Stewart DE (2004). The psychosocial effects of being quarantined following exposure to SARS: A qualitative study of Toronto health care workers. *Can J Psychiatry* 49(6): 403-407.
90. Que J, Shi L, Deng J, Liu J, Zhang L, Wu S, Gong Y, Huang W, Yuan K, Yan W, Sun Y, Ran M, Bao Y, Lu L (2020). Psychological impact of the COVID-19 pandemic on healthcare workers: a cross-sectional study in China. *Gen Psychiatry* 33(3): 1-12.
91. Lai J, Ma S, Wang Y, Cai Z, Hu J, Wei N, Wu J, Du H, Chen T, Li R, Tan H, Kang L, Yao L, Huang M, Wang H, Wang G, Liu Z, Hu S (2020). Factors Associated With Mental Health Outcomes Among Health Care Workers Exposed to Coronavirus Disease, *JAMA Netw Open* 3(3): 1-12.
92. Arık F, Avşar Arık I (2022). Salgın Döneminde Sosyolojik Araştırmanın İmkân ve Sınırlılıkları: COVID-19'un Psikososyal Görünümlerine Yönelik Hatay Örneğinde Bir Gömülü Teori Denemesi, *Sosyoloji Araştırmaları Dergisi*, Salgında Sosyolojik Araştırma: Sınırlılıklar ve Yeni Tahayyüller 25(1): 112-122.
93. Demirtaş SC, Hakdağlı Ö (2022). CNN Modeli ile Türkçe Konuşma Verisi Üzerinde Duygu Tanıma Emotion Recognition on Turkish Speech Data with Transformer-CNN Eleco Elektrik-Elektronik Ve Biyomedikal Mühendisliği Konferansı, Bursa, 24-26 Kasım 2022.
94. Atila O, Şengür A (2021). Attention guided 3D CNN-LSTM model for accurate speech based emotion recognition. *Applied Acoustics* 182: 108260.
95. Michael GR, Kandali AB (2022). Emotion Recognition from Manipuri Language Using MFCC and Convolution Neural Network. *International Journal for Research in Applied Science & Engineering Technology- IJRASET* 10(9): 861-865.

96. Pandey SK, Shekhawat, HS, Prasanna SM (2019). Deep learning techniques for speech emotion recognition: A review. In 2019 29th International Conference Radioelektronika, Pardubice, Czech Republic, 16-18 April 2019, 1-6.
97. Balaha HM, El-Gendy EM, Saafan MM (2020). CovH2SD: A COVID-19 detection approach based on Harris Hawks Optimization and stacked deep learning, Expert systems with applications 186: 115805.
98. Diep B, Stanojevic M, Novikova J (2022). Multi-modal deep learning system for depression and anxiety detection. [online]. Available from: arXiv:2212.14490.D <https://arxiv.org/pdf/2212.14490.pdf>. [Accessed 21 April 2023].
99. Nath RK, Thapliyal H (2021) Machine learning-based anxiety detection in older adults using wristband sensors and context feature. SN Computer Science 2(5): 359.
100. Espinola W, Gomes JC, Pereira MS, dos Santos WP (2022). Detection of major depressive disorder, bipolar disorder, schizophrenia and generalized anxiety disorder using vocal acoustic analysis and machine learning: an exploratory study. Research on Biomedical Engineering 38(3): 813-829.



EKLER

Ek-1: Veri toplama formu

Bu çalışmaya katılmayı kabul ederseniz, sizin [20 dakikanızı] alacak bir anketi cevaplamanız istenecektir. Bu çalışma ile elde edilecek tüm veriler anonim olup, tamamen gizli kalacaktır. Elde edilen veriler akademik bir yayın için kullanılacaktır. Hiçbir veri başka bir formatta başka bir amaçla yayınlanmayacaktır. Veriler güvenli bir ortamda saklanacak ve sadece araştırmacı erişime sahip olacaktır. Katılımcı hakkında herhangi bant kaydı veya yazılı metin, araştırmacı tarafından çalışma tamamlandığında yok edilecektir. Bu çalışmaya katılım gönüllüdür. Eğer katılmamaya karar verirsiniz, istediğiniz zaman ayrılma hakkına sahip olup tüm verilerinizin tahrip edilmesini talep edebilirsiniz. E-Mail adresi, herhangi bir eksik veriniz olması durumunda sizinle irtibat kurulması için istenilmektedir. İsim ve soy isim verisi de verileri sınıflandırmak için sadece araştırmacı tarafından kullanılacaktır.

İletişim ve Sorular için lütfen Mehmet Yiğit (0535 223 9342 - mehmettygt@gmail.com) ile irtibata geçiniz. Ordu Eğitim Araştırma Hastanesi Acil Servis Hemşiresi, Karadeniz Teknik Üniversitesi Biyoistatistik ve Tıp Bilişimi A.B.D

Yukarıdaki bilgileri okudum ve aydınlatıldım.

A ☐ Çalışmaya katılmayı kabul ediyorum.

✓ Sonraki

E-mail Adresiniz nedir?

E-mail adresiniz yoksa isim- soyisim yazarak geçebilirsiniz. E-Mail adresi, herhangi bir eksik veriniz olması durumunda sizinle irtibat kurulması için istenilmektedir.

Response

✓ Sonraki

İsim-Soy İsim (Eğer isminizin gizliliğini önemsiyorsanız bir rumuz kullanabilirsiniz.)

Metin Yanıtı

Response

✓ Sonraki

Yaşınız

Bir sayı girin.

Response

✓ Sonraki

Ek-1. (Devam)

Hastanede hangi bölümde çalışmaktasınız?
(Acil Servis, Cerrahi Servisi, Yoğun Bakım Ünitesi ...)

Metin Yanıtı

Response

✓ Sonraki

Cinsiyetiniz Nedir

Birini Seç

A ☐ Erkek

B ☐ Kadın

✓ Sonraki

Mesleğiniz nedir?

Birisini Seçiniz.

A ☐ Hemşire

B ☐ Doktor

C ☐ Sağlık Teknisyeni/Teknikeri (ATT, Paramedik dahil)

D ☐ Sağlık Memuru

E ☐ Veri Giriş Personeli

F ☐ Temizlik Personeli

G ☐ Diğer

✓ Sonraki

Ek-1. (Devam)

Şu an nerede bu formu dolduruyorsunuz

Birini Seç

A ☐ Evde

B ☐ Hastanede 08-16 Mesaiölünde

C ☐ Hastanede 16-08 Mesaiölünde

D ☐ Hastanede 24 Saat Nöbetinde

E ☐ Hastanede 08-24 Vardiyasında

F ☐ Diğer

✓ Sonraki

COVID-19 pandemisinde AKTİF olarak COVID-19 tanısı alan hastaların bakımına doğrudan katıldınız mı? (Mart 2020 Tarihinden itibaren sürekli olarak.)

Görevlendirme ile belirli süre COVID-19 kliniklerinde çalıştıktan sonra temiz kliniklerde çalışmaya devam edenler hayır seçeneğini işaretleyebilir.

A ☐ Evet

B ☐ Hayır

✓ Sonraki

COVID-19 hastalığına yakalandınız mı?

Birini Seç

A ☐ Evet

B ☐ Hayır

✓ Sonraki

Ek-2: Ses yanıtlı sorular

Şu an kendinizi nasıl hissediyorsunuz?

Bu soruya genel olarak bir cevap vermeniz beklenmektedir.

Zaman sınırı
01:00

Kayıt

✓ Sonraki

Bir sağlık çalışanı olarak çalışmak size nasıl hissettiriyor. Maksimum bir dakikalık ses kaydınızı yükleyebilir misiniz?

Bu soruya genel olarak bir cevap vermeniz beklenmektedir.

Zaman sınırı
01:00

Kayıt

✓ Sonraki

Pandemi sürecinde hastanede sağlık çalışanı olarak çalışmak sizi nasıl hissettiriyor?

Bu soruya bu bölümü okuduktan itibaren ne hissediyorsunuz.
Duygularınızı (Şaşırma, Üzgün, Sinirli, Mutlu, Korkmuş, İğrenmili) duyguları yansıtarak cevap vermeniz beklenmektedir.

Zaman sınırı
01:00

Kayıt

✓ Sonraki

Çalıştığınız klinikte çalışma ortamınız nasıldır? (Eğer stresli bir ortamda çalışıyorsanız. Stresle baş ederken ne gibi yöntemlere başvurursunuz?)

Mümkün olduğu süreçte ne hissediyorsanız bunu yansıtmayı rica ederim.

Zaman sınırı
01:00

Kayıt

✓ Sonraki

Ek-2. (Devam)

Aşağıda verilen metni sesli bir biçimde okuyunuz.

"Her şeyden önce maskesiz nefes alabildiğime seviniyorum. Eve gittiğimde rahatlıkla yemek yiyip, su içebildiğime seviniyorum. Bunlar çok basit şeyler gibi duruyor ama bize gelen hastalar ciddi nefes darlığıyla geliyor. Birçoğu yemek yerken bile zorlanıyor. Burada hasta kaybettikçe çok fazla üzülüyoruz. İnsanların evlerinde sevdikleriyle zaman geçirme fırsatı varken, hastaneye gelmeleri çok üzücü oluyor."

Metni kendi yorumunuzu katmadan nasıl hissediyorsanız öyle okuyunuz.

Zaman sınırı
01:00

Kayıt

Sonraki

Aşağıda verilen metni sesli bir biçimde okuyunuz.

"Daha fazlasına sahip olduğunuzda daha mutlu olacağınızı düşünüyor olabilirsiniz ama şunu bilin; dünyada bir yerlerde kendini bütün isteklerinden arındırmış biri sizden daha mutlu. "

Metni kendi yorumunuzu katmadan nasıl hissediyorsanız öyle okuyunuz.

Zaman sınırı
01:00

Kayıt

Sonraki

Ek-3: Durumluk ve Sürekli Kaygı Ölçeği (DSKÖ)

İsim:..... Cinsiyet:.....
Yaş:..... Meslek:..... Tarih:...../...../.....

YÖNERGE: Aşağıda kişilerin kendilerine ait duygularını anlatmada kullandıkları bir takım ifadeler verilmiştir. Her ifadeyi okuyun, sonra da o anda nasıl hissettiğinizi ifadelerin sağ tarafındaki parantezlerden uygun olanını işaretlemek suretiyle belirtin. Doğru ya da yanlış cevap yoktur. Herhangi bir ifadenin üzerinde fazla zaman sarfetmeksizin **anında** nasıl hissettiğinizi gösteren cevabı işaretleyin.

		HİÇ	BİRAZ	ÇOK	TAMAMİYLE
1.	Şu anda sakinim	(1)	(2)	(3)	(4)
2.	Kendimi emniyette hissediyorum	(1)	(2)	(3)	(4)
3	Su anda sinirlerim gergin	(1)	(2)	(3)	(4)
4	Pişmanlık duygusu içindeyim	(1)	(2)	(3)	(4)
5.	Şu anda huzur içindeyim	(1)	(2)	(3)	(4)
6	Şu anda hiç keyfim yok	(1)	(2)	(3)	(4)
7	Başıma geleceklerden endişe ediyorum	(1)	(2)	(3)	(4)
8.	Kendimi dinlenmiş hissediyorum	(1)	(2)	(3)	(4)
9	Şu anda kaygılıyım	(1)	(2)	(3)	(4)
10.	Kendimi rahat hissediyorum	(1)	(2)	(3)	(4)
11.	Kendime güvenim var	(1)	(2)	(3)	(4)
12	Şu anda asabım bozuk	(1)	(2)	(3)	(4)
13	Çok sinirliyim	(1)	(2)	(3)	(4)
14	Sinirlerimin çok gergin olduğunu hissediyorum	(1)	(2)	(3)	(4)
15.	Kendimi rahatlamış hissediyorum	(1)	(2)	(3)	(4)
16.	Şu anda halimden memnunum	(1)	(2)	(3)	(4)
17	Şu anda endişeliyim	(1)	(2)	(3)	(4)
18	Heyecandan kendimi şaşkına dönmüş hissediyorum	(1)	(2)	(3)	(4)
19.	Şu anda sevinçliyim	(1)	(2)	(3)	(4)
20.	Şu anda keyfim yerinde.	(1)	(2)	(3)	(4)

Ek-3. (Devam)

		Hemen hemen hiçbir zaman	Bazen	Çok zaman	Hemen her zaman
21.	Genellikle keyfim yerindedir	(1)	(2)	(3)	(4)
22.	Genellikle çabuk yorulurum	(1)	(2)	(3)	(4)
23.	Genellikle kolay ağlarım	(1)	(2)	(3)	(4)
24.	Başkaları kadar mutlu olmak isterim	(1)	(2)	(3)	(4)
25.	Çabuk karar veremediğim için fırsatları kaçıırım	(1)	(2)	(3)	(4)
26.	Kendimi dinlenmiş hissediyorum	(1)	(2)	(3)	(4)
27.	Genellikle sakin, kendine hakim ve soğukkanlıyım	(1)	(2)	(3)	(4)
28.	Güçlüklerin yenemeyeceğim kadar biriktiğini hissedirim	(1)	(2)	(3)	(4)
29.	Önemsiz şeyler hakkında endişelenirim	(1)	(2)	(3)	(4)
30.	Genellikle mutluyum	(1)	(2)	(3)	(4)
31.	Herşeyi ciddiye alır ve endişelenirim	(1)	(2)	(3)	(4)
32.	Genellikle kendime güvenim yoktur	(1)	(2)	(3)	(4)
33.	Genellikle kendimi emniyette hissedirim	(1)	(2)	(3)	(4)
34.	Sıkıntılı ve güç durumlarla karşılaşmaktan kaçınırım	(1)	(2)	(3)	(4)
35.	Genellikle kendimi hüzünlü hissedirim	(1)	(2)	(3)	(4)
36.	Genellikle hayatımdan memnunum	(1)	(2)	(3)	(4)
37.	Olur olmaz düşünceler beni rahatsız eder	(1)	(2)	(3)	(4)
38.	Hayal kırıklıklarını öylesine ciddiye alırım ki hiç unutamam	(1)	(2)	(3)	(4)
39.	Aklı başında ve kararlı bir insanım	(1)	(2)	(3)	(4)
40.	Son zamanlarda kafama takılan konular beni tedirgin ediyor	(1)	(2)	(3)	(4)