

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DUYGUSAL REAKSİYONLARIN FİZYOLOJİK DENEYİM ÖRNEKLEME
İLE ANALİZİ

YÜKSEKLİSANS TEZİ

Gülin DOĞAN

1900000822

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Dr. Öğr. Üyesi Fatma PATLAR AKBULUT

OCAK 2022

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DUYGUSAL REAKSİYONLARIN FİZYOLOJİK DENEYİM ÖRNEKLEME
İLE ANALİZİ

YÜKSEKLİSANS TEZİ

Gülin DOĞAN

1900000822

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Dr. Öğr. Üyesi Fatma PATLAR AKBULUT

Jüri Üyeleri: Dr. Öğr. Üyesi Öznur ŞENGEL

Dr. Öğr. Üyesi Faruk BULUT (Arel Üni.)

OCAK 2022

İÇİNDEKİLER

	Sayfa No
KISALTMALAR LİSTESİ.....	IV
ŞEKİLLER LİSTESİ.....	V
TABLolar LİSTESİ	VI
FORMÜLLER LİSTESİ.....	VII
ÖZET.....	VIII
ABSTRACT.....	IX
1.GİRİŞ.....	1
2.BACKGROUND.....	3
2.1. Deneyim Örneklemeye Çalışması.....	3
2.2. Anket Tabanlı Çalışmalar.....	4
2.3. Ses Sinyali Tabanlı Çalışmalar.....	5
2.4. Görüntü İşleme Tabanlı Çalışmalar	5
2.5. Fizyolojik Sinyal Tabanlı Çalışmalar.....	6
2.6. Füzyon Veri Tabanlı Çalışmaları	7
2.7. Stres Tespiti.....	8
2.7.1. Fizyolojik Sinyaller	8
2.7.1.1 Elektrodermal Aktivite	9
2.7.1.2 Kan Hacmi.....	9
2.7.1.3 Cilt Sıcaklığı.....	9
2.7.1.4 İvmeölçer.....	10
2.7.2 Davranışsal Tepkiler.....	10
2.7.2.1 Konuşma.....	10
2.8. Duygu Analizi	10

2.8.1. Ses Sinyali	10
2.8.1.1. Mel-frekans Kepstral Katsayıları	11
2.8.1.2. Mel Frekansı	11
2.8.2. Yüz İfadesi Analizi	11
2.9. Yapay Sinir Ağı	14
2.9.1 Transfer Öğrenimi	19
3. METHOD	21
3.1. Deneyim Örnekleme Metodu	21
3.2. Veri Toplama Protokolü	21
3.3. Deneyim örnekleme uygulamasının geliştirilmesi	23
3.4. Füzyon Veri Seti	26
3.5. Harici Veri Setleri	28
3.6. Veri Seti Ön İşleme	28
3.7. Önerilen Çok Kaynaklı Füzyon Veri Tabanlı Derin Öğrenme Modeli (DEEP-FUS)	29
4. BULGULAR	32
4.1. İstatistiki Bulgular	32
4.2. Yüz İfadesi Bulguları	34
4.3. Ses Bulguları	35
4.4. Fizyolojik Sinyal Bulgular	37
5. TARTIŞMA	42
6. SONUÇ	43
7. SINIRLAMALAR VE GELECEK ÇALIŞMA	45
8. TEŞEKKÜR	46
9. KAYNAKLAR	47
10. EKLER	61

10.1. EK A. Profil Anketi.....	61
10.2. EK B. Anlık Anket	61
10.3. EK C. Genel Stres Testi	62
10.4. EK D. PANAS Ölçeđi	63



KISALTMALAR

ACC	: İvmeölçer (Accelerometer)
BP	: Kan Basıncı (Blood Pressure)
BVP	: Kan Basınç Değişimi (Blood Volume Pressure)
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Network)
DNN	: Derin Sinir Ağları (Deep Neural Network)
EDA	: Elektrodermal Aktivite
EEG	: Elektroensefalografi
EKG	: Elektro Kardiyogram
ESM	: Deneyim Örnekleme Metot (ExperienceSamplingMethod)
GSR	: Galvanik Cilt Tepkisi (Galvanic Skin Response)
GRU	: Geçitli Tekrarlayan Ünite (GatedRecurrentUnit)
HRV	: Kalp Atış Hızı Değişkenliği (Heart Rate Variability)
IBI	: Vuruşlar Arası Aralık (InterbeatInterval)
LSTM	: Uzun Kısa Süreli Bellek (Longshort-termmemory)
MFCC	: Mel-frekans Kepstral Katsayıları (Mel-frequencycepstralcoefficients)
PANAS	: Pozitif ve Negatif Sendrom Ölçeği (PositiveandNegativeAffect Schedule)
PPG	: Fotopletismografi(Photoplethysmography)
RAVDESS	: Ryerson Duygusal Konuşma ve Görsel-İşitsel Veritabanı (RyersonAudio-Visual Database of Emotional Speech andSong)
SAVEE	: Surrey Görsel-İşitsel İfade Duygusu (SurreyAudio-Visual ExpressedEmotion)
SMS	: Sistemik Haritalama Çalışması (SystematicMappingStudy)
TEMP	: Cilt Sıcaklığı
TESS	: Toronto Duyusal Konuşma Seti (Toronto emotionalspeech set)

ŞEKİLLER LİSTESİ

Şekil 2.1	:	Yüz ifadesi tanıma protokolü.....	11
Şekil 2.2	:	Yapay sinir ağı hücresi.....	14
Şekil 2.3	:	Karmaşıklık matrisi.....	15
Şekil 2.4	:	CNN algoritması.....	16
Şekil 2.5	:	LSTM algoritması.....	17
Şekil 2.6	:	GRU hücresi.....	18
Şekil 3.2	:	Mobil uygulamanın genel işleyiş biçimi	22
Şekil 3.3.1	:	Deneyim örnekleme uygulamasına ait a) girişi ekranı , kayıt ekranı ve c) Şifre yenileme ekranı.....	23
Şekil 3.3.2	:	Deneyim örnekleme uygulamasına ait a) Katılımcı bilgi ekranı, b)Menü.....	24
Şekil 3.3.3	:	Deneyim örnekleme uygulamasına ait a) Profil, b) Genel Stres Testi, c) Anlık Anket, d) PANAS Ölçeği.....	25
Şekil 3.3.4	:	Deneyim örnekleme uygulamasına ait a) Görüntü, b) Ses Kaydı.....	25
Şekil 3.4	:	Deneyim örnekleme sırasında toplanan görüntü verisi örnekleri.....	26
Şekil 3.5-A	:	Fer2013 veri setinden örnek veri kesiti.....	27
Şekil 3.5-B	:	Cohn-Kanade veri setinden örnek veri kesiti.....	27
Şekil 3.8.4	:	Önerilen fizyolojik sinyal tabanlı model mimarisi.....	30
Şekil 4.1	:	Yapılan aktiviteye bağlı olumsuz duygu oranları.....	31
Şekil 4.2.1	:	Yüz ifadesi görüntüleri ve duygu tahmini.....	33
Şekil 4.2.2	:	Yüz ifadesi görüntülerinin duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi.....	33
Şekil 4.3.1	:	Korku ve üzgün durumlarda kaydedilen örnek ses veri kesiti	34
Şekil 4.3.2	:	Ses sinyallerinden güç spektrumları elde edilerek duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi.....	35
Şekil 4.3.3	:	Ses sinyallerinden mel spektrumları elde edilerek duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi.....	35
Şekil 4.4.1	:	Fizyolojik sinyallerin stres oranları.....	36
Şekil 4.4.2	:	Stresli ve stressiz duygu durumlarına ait EDA sinyalleri	37
Şekil 4.4.3	:	Stresli ve stressiz duygu durumlarına ait cilt sıcaklığı sinyalleri.....	37
Şekil 4.4.4	:	Stresli ve stressiz duygu durumlarına ait BVP sinyalleri	38
Şekil 4.4.5	:	Stressiz bir durumdaki ACC sinyali.....	38
Şekil 4.4.6	:	Stresli bir durumdaki ACC sinyali.....	38
Şekil 4.4.7	:	Optimum modelin en başarılı zaman penceresi bağlamında başarı ve kayıp grafikleri.....	41

TABLÖLAR LİSTESİ

Tablo 1	:	YSA ile biyolojik sinir hücrelerinin benzerliği.....	14
Tablo 2	:	Genel stres puanı ve PANAS ölçeği parametrelerinin korelasyon değerleri.....	32
Tablo 3	:	Yapay sinir ağı modellerinin performansları.....	39
Tablo 4	:	Fizyolojik sinyallerin üçlü kombinasyon performansları....	39
Tablo 5	:	Fizyolojik sinyallerin ikili kombinasyon performansları.....	40

FORMÜLLER LİSTESİ

Formül 1	:	Toplam Fonksiyonu.....	15
Formül 2	:	ACC.....	16



GENEL BİLGİLER

Enstitüsü	:	Lisansüstü Eğitim Enstitüsü
Dalı	:	Bilgisayar Mühendisliği Anabilim Dalı
Programı	:	Bilgisayar Mühendisliği
Tez Danışmanı	:	Dr. Öğr. Üyesi Fatma PATLAR AKBULUT
Tez Türü ve Tarihi	:	Yüksek lisans – Ocak 2022

KISA ÖZET

Duygusal reaksiyonların fizyolojik deneyim örnekleme ile analizi

Gülin DOĞAN

Stres, modern toplumumuzun ayrılmaz bir parçası haline geldi. Gelişmekte olan teknolojinin sağladığı akıllı cihazların yaygın bir şekilde kullanılması, bu cihazlarla stresi algılama ve hafifletme amacıyla kullanılması araştırma konusunu haline gelmiştir. Son zamanlarda göze çarpmayan giyilebilir cihazların ekolojik ortamlarda araştırmalara katkı sağlaması amacıyla kullanımı başlamıştır. Bu cihazların sağladıkları veriler ile duygu ve bilişin izlenmesi, deneyim ve bağlama özgü uygulama olanakları için yeni fırsatlar sağlamıştır. Bu cihazlar, günlük yaşamdaki çeşitli alanlardan çok miktarda yüksek oranda çözülmüş ve kişisel verilerin toplanmasını sağlayan deneyim örnekleme metodolojisi kullanılarak çoklu sensörler, kayıt kanalları ve uygulama tabanlı değerlendirme fırsatları ile donatılmıştır.

Çalışmanın amacı, deneyim örnekleme metodu ile toplanan görüntü, ses ve fizyolojik sinyaller ile derin öğrenmeye dayalı duygu tahmin etme sistemlerinin oluşturulmasıdır. Çalışmaya katılan 20 katılımcı tarafından 7 gün süresince 6 defa olmak üzere 15 dakikalık oturumlar olacak şekilde, 175 saatlik fizyolojik sinyal, 111 görüntü ve 68 ses kaydı toplanmıştır. Görüntü verileri kullanılarak ses verilerinin desteklenmesi sayesinde çoklu modelleme duygu analizi gerçekleştirildi. Füzyon verileri için görüntü verilerinden duygu tahmini yapılabilme %83 oranında, ses sinyallerinde duygu tahmini ise %74 oranında başarı ile tahmin edildi. Çalışma kapsamında toplanan fizyolojik sinyallerin tümünün sentezlenmesi için geliştirilen optimum performansa sahip modelin başarı oranı %94 olarak tespit edilmiştir. Toplanan fizyolojik sinyallerin çeşitli kombinasyonları transfer öğrenimi tekniğinin ardından optimum model ve optimum zaman pencereleri kullanarak stres tahmini gerçekleştirildi. İkili ve üçlü fizyolojik sinyal kombinasyonları sonucunda EDA ve BVP sinyallerinin stres tespitinde etkin rol oynadığı görülmüştür.

Anahtar Kelimeler: Deneyim Örnekleme, Stres, Makina Öğrenimi, Sinyal işleme

GENERAL INFORMATION

University	: İstanbul Kültür University
Institute	: Institute of Graduate Studies
Department	: Computer Engineering Master's Program with Thesis
Programme	: Computer Engineering Master's Program with Thesis
Supervisor	: Dr. Öğr. Üyesi Fatma PATLAR AKBULUT
Degree Awarded and Date	: Yüksek Lisans – Ocak 2022

ABSTRACT

Experience sampling application to analyze emotional reactions

Gulin DOGAN

Stress has become an integral part of our modern society. The widespread use of smart devices provided by developing technology and the use of these devices to detect and relieve stress has become a research topic. Recently, the use of inconspicuous wearable devices has begun to contribute to research in ecological environments. Tracking emotion and cognition with the data these devices provide has opened up new opportunities for experience and context-specific application possibilities. These devices are equipped with multiple sensors, recording channels, and application-based assessment opportunities using experience sampling methodology that enables the collection of large amounts of highly resolved and personal data from various areas of daily life.

The aim of the study is to create emotion prediction systems based on deep learning with photographs, audio and physiological signals collected by experience sampling method. In the study, 175 hours of physiological signals, 111 images and 68 audio recordings were collected by 20 participants in 6 times 15-minute sessions over 7 days. Multi-model sentiment analysis was performed using photographic data and supporting audio data. For fusion data, emotion estimation from photographic data was predicted with a success rate of 90%, and emotion estimation in audio signals with a 73% success rate. The success rate of the model with optimum performance, which was developed to synthesize all of the physiological signals collected within the scope of the study, was determined as 94%. Stress estimation was performed using the optimum model and optimum time windows following the transfer learning technique of various combinations of the collected physiological signals. As a result of double and triple physiological signal combinations, it has been seen that EDA and BVP signals play an active role in stress detection

Keywords: Experience Sampling, Stress, Machine Learning, Signal processing

1.GİRİŞ

Günümüzde stres faktörlerini önlemek neredeyse imkânsız bir haledir. İnsanlar hem işyerinde hem de sosyal çevrelerinde çeşitli türlerde ve değişen derecelerde strese maruz kalırlar. Literatürde stres, yaşam rutininde değişikliğe neden olan, kişinin güvenli alanı dışına çıkmasına tepki olarak meydana gelen içsel bir deneyim [1] olarak tanımlanmaktadır. Stres durumuna maruz kalınması kişinin hem duygusal, hem fiziksel sorunlar yaşamasına hatta kalıcı hastalıklara yakalanmasına neden olabilmektedir. Dünya Sağlık Örgütü [2], 2021 yılına kadar stres faktörünün işlev bozukluğu probleminin en önemli nedenlerinden biri olacağı öngörülmüyor. İşlev bozuklukları kaynaklı kronik stres, azalan refah seviyesi, artan hastalık oranları, tükenmişlik sendromu ve depresyon gibi strese bağlı bozuklukları gelişim göstermiştir.

Stres, çevresel uyaranlara karşı kişinin fizyolojik ve psikolojik bir tepkisi [3] olarak karşımıza çıkabilir. Bu uyaranlar, duygusal ve fiziksel açıdan insan sağlığını tehdit etmesi sonucunda hayat kalitesini olumsuz yönde etkiler. Stres, iş, aile ve arkadaş ortamı gibi birçok farklı alanda kişileri baskı altında hissettirebilir [4]. Colligan ve Higgins [5] işyerindeki stres faktörlerinin çalışanların refahı için zararlı olduğunu belirtmişlerdir. Kişinin iş yerinde stres düzeyinin artması, örgütsel işlev bozukluğuna neden olur. Aynı zamanda çalışanların iş performanslarını olumsuz yönde etkiler. Gevşeme ve yoga gibi stres yönetimi metotlarının, hem psikolojik stresi [6] hem de iş stresini [7] azalttığı gözlemlenmiştir. Aynı zamanda, bu metotların, stres ile başa çıkma konusunda doğrusal bir ilişkisi olduğunu tespit edilmiştir [8].

Stres, hayatın her alanlarında insanları baskı altına alarak olumsuz yönde etkilemektedir. Bu etkileri incelemek için deneyim örnekleme metodu olarak da bilinen ekolojik anlık değerlendirme [9], günlük akış içerisinde mevcut bağlam ve psikolojik durum değerlendirmesi yapan bir günlük tutma tekniği kullanılmaktadır. Bu teknik, genellikle akıllı cihaz tabanlı uygulamalar aracılığı ile çeşitli soruları rastgele veya belirli zamanlarda katılımcılara yönlendirerek anlık deneyimleri gerçek zamanlı olarak yakalama imkânı sunar. Ayrıca bu teknik, bağımlılık yapıcı davranışlar [10], [11], [12] ağrı [13], [14], [15] psikolojik hastalıklar [16], [17], yorgunluk [18], [19] ve

yakın zamanlı tıbbi deęerlendirmelerde [20], [21], [22], [23], [24] veri toplamak amacıyla da sıklıkla kullanılmaktadır.

Önerilen alıřma kapsamında duygusal reaksiyonları analiz etmek iin deneyim rnekleme metodu kullanılmıřtır. Bu baęlamda iř stresini algılama zerine deneyler yapılmıř ve fizyolojik sinyal, ses ve grnt tabanlı bir tespit metodu geliştirilmiřtir. alıřmanın literatre katkıları ařaęıda listelenmiřtir:

- ✓ oklu sensr sinyalleri, yz grnts ve ses kaydı verilerinden oluřan fzyon veri tabanı oluřturulmuř ve benzer alıřmalara destek olabilmek iin herkese aık bir platformda paylařılmıřtır.
- ✓ Yedi temel duygu olan fke, tikslenme, korku, mutluluk, znt, řařırma ve ntr duygularının tanınması iin grnt ve sinyal tabanlı bir derin ęrenme mimarisi oluřturulmuřtur.
- ✓ eřitli derin ęrenme mimarileri, oklu sensr verileri zerinden stres algılama yetenekleri kıyaslanmıřtır.

2.Genel Bilgiler

Deneyim örnekleme metodu tabanlı stres araştırmamız istatistiki çıkarımlar, görüntü verilerinin duygusal analizi ve görüntü verilerinden elde edilen duygu tahminlerinin ses sinyallerini desteklemesi, çoklu sensörlerle toplanan çeşitli fizyolojik sinyallerin incelenmesi ve yapay sinir ağları ile tahmin edilmesi ile gerçekleşen duygu analizi aşamalarından oluşmaktadır. Bu nedenle literatür taraması önemli anahtar kelimeler üzerinden araştırılmıştır.

2.1. Deneyim Örnekleme Çalışması

Deneyim örnekleme metodu (ESM), insan davranışlarını incelemekle ilgili anket tabanlı kullanıcı deneyimlerini toplayan bir yöntemdir [25]. ESM çalışmalarında, katılımcılarından günlük yaşamlarındaki etkinlikleri veya duyguları hakkında günde birçok kez öz-değerlendirme yapmaları istenir. Bu öz-değerlendirmeler, sinyal tabanlı [26], zaman tabanlı [27], olay tabanlı [28] veya birden çok öz-değerlendirmeler uygulaması [29] ile toplanabilir. Öz-değerlendirmeler, laboratuvar ortamının aksine doğal ortamda toplandığı için, katılımcıların doğal davranışları sayesinde daha gerçekçi veriler elde edilir.

ESM deneyimini geliştirmek için geçmişten günümüze kadar çeşitli cihazlar ile katılımcı deneyimleri toplanmıştır. En sık kullanılan cihazlardan bazıları, dijital yardımcılar (PDA) [30], çağrı cihazları, kâğıt kalem, kameralar [31] ve ses kayıt cihazları olarak karşımıza çıkmaktadır. Aynı zamanda katılımcıların kişisel cihazlarına indirebilecekleri uygulamalar aracılığıyla, veri toplamak da tercih edilir bir veri toplama yöntemidir [32], [33]. Bunun temel faydası, insanların kişisel cihazlarını üzerinde taşıma ve bu cihazlarla bilgi alıp göndermeye hali hazırda alışmış olmalarıdır.

Araştırmacılar, katılımcılardan veri toplama için zaman biçimini seçerken, zaman tabanlı, rastgele, olay tabanlı veya hibrit mekanizmaları tercih edebilir. Veri toplama, katılımcının bilgisi dahilinde belli zamanlarda, öngörülemeyen rastgele

zamanlarda, belirli bir olay meydana geldiğinde veya araştırmacının planladığı birden çok tetikleme biçiminin hibrit bir yapıda kullanılması sonucunda gerçekleştirilebilir.

Zaman tabanlı veri toplama, katılımcıların belirli zamanlarda veri kaydetme görevlerinin bilincinde olması sayesinde örneklemeleri zamanında gerçekleştirebilir. Ancak bu yöntem katılımcıların bilgisi dahilinde gerçekleştiği için yönteme karşı tepkisellik önemli ölçüdedir [34]. Diğer bir yöntem, rastgele zamanlarda veri toplama, katılımcıların bir sonraki sinyalin ne zaman ortaya çıkacağını öngöremedikleri için yönteme karşı tepkisellik önemli ölçüde azaltılmış olur [34]. Olay tabanlı veri toplama, azaltılmış yabancı yanıtlar ve iyileştirilmiş örnekleme doğruluğu gibi avantajlar sağlar [35]. Hibrit yöntemlerle veri toplama biçimi, sistem tasarımcısına bağlı olarak çeşitli avantaj ve dezavantajlara sahip olabilir.

2.2. Anket Tabanlı Çalışmalar

Anket tabanlı araştırmalarda motivasyon kaynağı, katılımcıların birtakım anketlere vermiş oldukları cevaplar ile istatistiki çıkarımlarda bulunmaktadır. Yapılan araştırmalar [36], stresin insanı baskı altında hissettirmesi sonucunda çalışma planının olumsuz yönde etkileyerek performansını düşüreceğini savunur. Bu alanda yapılan çalışmalardan birisi Remus Ilies ve arkadaşlarına [37] aittir, çalışma kapsamında anlık olumlu ve olumsuz olayların, çalışanların ruh halini incelemek amacıyla anketler uygulanmış ve kişinin stres altında çalışabilme yeteneği ile duygusal dayanıklılığa sahip olmasının, iş tatmini ve performansı açısından önemli olduğunu destekleyen sonuçlar bulmuşlardır. Aynı zamanda iş ortamında artan stres, çalışanları olumsuz yönde etkileyerek örgütsel işlev bozukluğuna da neden olabilmektedir [38]. Hem psikolojik stresi [39] hem de mesleki stresi [40] azaltmak için çeşitli farkındalık müdahaleleri geliştirilmiştir. Yapılan çalışmada, kurumsal ortamlar için farkındalık müdahaleler (MBI) geliştirilmiştir. Bununla birlikte, MBI ların çalışan bireyler üzerinde psikolojik sıkıntıyı azaltma konusunda gevşeme ve yoga gibi stres yönetimi müdahalelerinden daha etkili olduğunu gösteren çok az kanıt bulunmuştur [40].

2.3. Ses Sinyali Tabanlı Çalışmalar

Ses sinyaliinden stres tespiti [41], geleneksel [42] veya modern yöntemler [43] kullanılarak gerçekleştirilebilir. Geleneksel yöntemler, ses sinyaliinden özellik çıkarımı yapılmasının ardından bu özelliklerden stres tahmini yapılması amacıyla çeşitli algoritmaların kullanılması prensibine dayanır [44]. Modern yöntemler ise kendi içinde ikiye ayrılır: bunlardan ilki makine öğrenmesi algoritmaları [45] ile gerçeklerinken diğerleri derin öğrenme [46] tabanlı olup her iki yöntemde de özellik çıkarımı aşaması otomatik olarak oluşturulan model tarafından gerçekleştirilir [47].

Bu alanda geleneksel yöntemler ile yapılan çalışmalarına bakıldığında, ses sinyali ilk olarak ön-işlemden geçer, ardından ses sinyallerinden özellik çıkarımları yapılır, bu özellik çıkarımları sonucunda duygu sınıflandırması gerçekleştirilir [48]. Ses verileri toplandıktan sonraki ilk adım ön işlemdir. Ön işleme teknikleri, kayıt da bulunan gürültülerin duygu tanıma sürecini etkilememesi için ses özelliklerini normalleştirmek gibi amaçlarla kullanılır [49]. Ön-işleme aşamasından geçen ses sinyali, farklı ses özelliklerini algılayabilmek için birçok özellik çıkarma tekniğinden geçer. Bu teknik, ses teli titreşimlerindeki frekans ve genlik değişimini algılayabilmek amacıyla perde ve titreşim gibi akustik ölçümleri kullanmaktadır [50].

Modern yöntemler, ses sinyaliini ön-işleme adımından geçirdikten sonra derin öğrenme algoritmalarına göndererek duygu tahmini gerçekleştirir [51]. Ön-işleme aşamaları geleneksel yöntemler de olduğu gibi bu yöntemde de ses sinyaliini temizlemek amacıyla gerçekleştirilir. Modern yöntemler, ses sinyallerini yapay sinir ağları üzerinden eğitilmesi ve ardından test edilmesi temeline dayanır. Bu yapay sinir ağları, Evrimsel sinir ağları [52], Rekürsif sinir ağları [53] gibi popüler algoritmalar ile tahmin süreci gerçekleştirilir.

2.4. Görüntü İşleme Tabanlı Çalışmalar

Görüntü işleme çalışmaları, durağan veya devamlı görüntülerin analizleri ve söz konusu görüntülerden anlamlı bilgiler çıkarılması temeline dayanır. Fotoğraf verilerin kullanılması ile yüz ifadelerinden duygu analizi çalışmaları da karşımıza çıkmaktadır. Geleneksel yöntemlerden faydalanarak yüz ifadelerinden duygu tahmini yapabilmek için yüzdeki ipuçları kullanılır. Bu ipuçları yüz ifadelerinden özellik çıkarımları yolu

ile elde edilir. Elde edilen bu özellikler evrişimli sinir ağı modelleri üzerinden duygu tahminini gerçekleştirir. Binh Nguyen ve arkadaşlarının [54] çalışması yüz görüntülerinde özellik çıkarıp duygu tanımayla bir örnektir. Çalışmada gerçek zamanlı olarak tasarlanmış ve yaklaşık %70,65 ortalama doğruluk ile duygu algılayabilmektedir. Ayrıca, gözlerin konumu, ağız aktivitesi, baş hareketi parametrelerinden yararlanılan kamera tabanlı bir çalışmada da ise [55], K-en yakın komşular (KNN), Destek Vektör Makineleri (SVM), Naive Bayes ve AdaBoost algoritmaları kullanılmış ve %91,68 doğruluk elde etmişlerdir.

Modern yöntemlerde ise derin öğrenme metodlarına dayalı modellerin oluşturulması ile duygu tahmini yapılmaktadır. Modern yöntemlerle yürütülen bir çalışmada [ref], katılımcıların yüz ifadelerinden ve yüz hareketlerinden faydalınarak iki seviyeli stres algılama ağı (TSDNet) ile harici bir özellik çıkarma aşaması olmaksızın %85.42' lik bir doğruluk elde etmişlerdir. Yüz ifadelerinin video görüntüleri aracılığıyla stres algılamada, yüz ifadesi fotoğraflarına göre, %7 daha başarılı olduğu tespit edilmiştir [56].

Bu alanda yapılan çalışmalar, anksiyete [57] ve depresyon [58] gibi psikolojik rahatsızlıkların analiz edilebilmesinde de kullanılabilir. Psikolojik rahatsızlıkların yanı sıra meme kanseri [59] gibi hastalıklarda görsel/video verileri yolu ile karar destek sistemleri oluşturulabilir [60], [61]. Ayrıca termal görüntüleme tekniği ile video kayıtlarından solunum bozukluklarının teşhisinde de kullanılabileceği gözlemlenmiştir [62]. Bu çalışmada, termal ve derinlik kameralarının, solunum görüntülerini yakalamak için çok modlu (multimodal) tekniğinin kullanılabileceği doğrulamaktadır [62].

2.5. Fizyolojik Sinyal Tabanlı Çalışmalar

Stresli durumlar, otonom sinir sisteminde dinamik değişikliklere neden olabilir. Bu değişkenler, sempatik sistemde artan aktivite ve parasempatik sistemde azalmış aktivite olarak yansımaktadır [63]. Galvanik cilt tepkisi (GSR) [64], elektrokardiyogram (EKG) [65] ve elektroensefalogram (EEG) [66] gibi fizyolojik sinyaller stres tespiti için kullanılan başlıca sinyaller arasında yer alır. Özellikle kalp atış hızı [67] otonom sinir sistemi aktivitelerini tespit etmek için yaygın olarak

kullanılan non-invaziv bir göstergedir. Bu gösterge, birçok izleme sisteminde stres tespiti [68], [69] için birincil ölçüt olarak kullanılmıştır.

Veri madenciliği perspektifinden çeşitli fizyolojik sinyaller üzerinden stres tanımlama ve sınıflandırma problemi sıklıkla ele alınmaktadır [64]. Doğal ortamlarda giyilebilir sistemler aracılığı ile toplanan fizyolojik veriler[70] bu kapsamda yoğun olarak kullanılmaktadır. Bu bağlamda yapılan bir çalışmada [64], yalnızca kalp ritmi ve galvanik cilt iletkenliği sinyalleri ile stresin belli bir dereceye kadar saptayabilir olduğunu sonucuna varılmıştır. Çoklu fizyolojik sinyaller ile stres tahmini, bulanık mantık [64] ve makina öğrenimi [71] yöntemler kullanılarak da tespit edilebilmektedir.

2.6. Füzyon Veri Tabanı Çalışmaları

Çoklu sensörlerden elde edilen verilerle oluşturulan füzyon veri tabanı ile yapılan çalışmalarda [72, 73], birden fazla modalitenin entegrasyonunu ile sistem performansını iyileştirmek amaçlanır. Veri işleme aşamasında en büyük sorun, verilerin ayrı ayrı işlenmesi ve birbirinden bağımsız olarak değerlendirilmesidir. Oysa özellikle duygu tespiti sözkonusu ise yüz görüntülerinin yanında sesi ve/veya fizyolojik de analiz etmek modeli tahminin ötesinde bir noktaya taşıyabilmektedir. Genel füzyon mimarilerinde ve modalitelerin ortak işlenmesi [74], [75] güncel bir konudur. Çoklu kaynaklar tarafından elde edilen sinyallerin çeşitli analizlerini gerçekleştirebilmek için, bu sinyallerin birbirine bağımlı olduğu da değerlendirmeye alınmalıdır. Bu nedenle, girdi sinyalleri ortak bir özellik uzayında ve bağlama bağlı bir modele göre işlenir [76].

Yapılan çalışmada [77] farklı kanallardan gelen bilgilerle oluşturulan fusion veri seti ile duygu sınıflandırma ve tahmin etmek için çoklu modelleme (multimodel) yaklaşımı önerilmiştir. Duygu tahmini için çeşitli veri kaynakları olsa da bu kaynakların sentezlenmesiyle duygu tahmini sistemlerinin başarısının iyileştirilebileceği savunulmuştur. Çoklu çözünürlük yaklaşımı kullanılarak ölçülen fizyolojik sinyallerden duyguyu tanımak ve tahmin etmek amacı ile çeşitli fizyolojik sinyaller kullanılmıştır. Yapılan çalışmada çoklu sensörlerden elde edilen fizyolojik sinyaller, elektroensefalogram (EEG), galvanik cilt yanıtı (GSR), kan hacmi basıncı, solunum, cilt sıcaklığı, elektromiyogram (EMG) ve elektrookülogram (EOG) olarak karşımıza çıkmaktadır. Duygu tanıma kapsamında her bir sinyali ayrı ayrı

modellemenin yanında çoklu sinyal ile bir yöntem geliştirmekte hali hazırda yoğunlukla çalışılan alanlardan biridir. Çoklu sinyal kullanan bir çalışmada [77], dört farklı algoritma ile sınıflandırma yapılmıştır. Destek Vektör Makinaları (SVM), Hareketli Morfable Bileşen (MMC), Çok Katmanlı Algılayıcı (MLP) ve K-En Yakın Komşu (KNN) sınıflandırıcıları için doğruluk değerleri sıralaması %81.45, %75.94, %74.37 ve %57.74'tür. Duygu sınıflandırması ve tahmininde [78] hem galvanik cilt tepkisi (GSR) hem de konuşma verilerinin birlikte kullanılması ile bir sistem geliştirilmiştir. KNN (K en yakın komşu), GMM (Gauss Karışım Modeli), SVM (Destek vektör makinesi) ve karar ağacı algoritmaları ile stres sınıflandırmaları yapılmıştır. Her iki özellik seti ayrı ayrı ve bir arada kullanılarak stres sınıflandırması yapılmıştır. SVM sınıflandırıcısı, her stres testi için en iyi makina öğrenimi algoritması olarak tespit edilmiştir.

2.7. Stres Tespiti

Stres belirtilerinin hem ölçülmesi hem de gözlemlenmesi mümkündür. Sempatik sinir sistemi, stres reaksiyonunu tetikleyerek psikolojik, fizyolojik ve davranışsal semptomlara neden olur [78]. Stresi ölçmenin psikolojik yolu, bir psikolog ile görüşmek veya öz raporlamak metodu uygulamaktır. Stres tespitinin ikinci yolu ise, fizyolojik sinyalleri değerlendirmektir. Tez kapsamında ilgilenilen fizyolojik veriler arasında elektrodermal aktivite (EDA), kan hacmi (BVP), cilt sıcaklığı ve ivmeölçer sinyalleri bulunur. Ancak bunun dışında elektrokardiyogram [79] ve tükürük [80] verileri de stres analizinde kullanılabilir.

Stres tespitinin bir başka yolu ise davranışsal değişikliklerin analiz edilmesi yoluyla olabilir. Stres, bireyin davranışlarını etkiler. Bu davranışsal değişkenlikler, tuş vuruş şiddeti, fare kullanımı, cep telefonu kullanımı, konuşma güçlükleri, yüz ifadeleri, yürüme gibi davranışlardan oluşur. Stres tespiti için kullanılabilen son özellik tipi, bağlamsal bilgilerdir: konum ve takvim etkinlikleridir. Bu bölümde, stres tespiti için önemli fizyolojik sinyaller ele alınacaktır.

2.7.1. Fizyolojik Sinyaller

İnsan beyninde bulunan hipotalamus, bir tehdit karşısında stres hormonu salgılar [81]. Stres hormonu, acil bir durumda hızlı tepki vermek ve insan vücudunu korumak

için tasarlanmıştır [81]. İnsan fizyolojisi, stres faktörlerine karşı kasları tetikleyerek her an yanıt vermek için hazır hale getiren, kalp ritmini ve nefes alma hızını artıran hormonları salgılayarak tehdit oluşturan duruma yanıt vermek için tasarlanmıştır [82]. Bu hormonların insan vücudu üzerindeki etkilerinin ölçümlenebilmesi için çeşitli yöntemlerle sayısal değerlere dönüştürülerek sinyal formları elde edilir.

2.7.1.1 Elektrodermal Aktivite

Galvanik cilt tepkisi (GSR) olarak da bilinen elektrodermal aktivite, uyarım durumlarındaki genel değişiklikleri yansıtır [83]. Devamlılığı olmayan, anlık durum bazında çalışan ve uyarılara karşı kısa süreli tepkisel fizyolojik sinyalleri tanımlamak için kullanılır. EDA sinyali, psikolojik ve fizyolojik uyarıları küçük bir akımdan faydalanarak cilt iletkenliği yoluyla üretir [84]. Çalışma prensibi temel olarak, duygusal uyarılma anında artan terlemeyle birlikte cilt iletkenliğinin algılanmasına dayanır [85]. Diyabet, parkinson, şizofreni ve depresyon gibi hastalıkların teşhis ve tedavisinde EDA ölçümlerinden faydalanılmaktadır. Yapılan çalışmada şizofreni ve depresyon hastalarının uyarılara karşı daha az yanıt verdiği görülmüştür. Ancak deri iletkenliğinin yüksek veya düşük olması, uzmanlar tarafından devam etmekte olan bir tartışma konusudur [86].

2.7.1.2 Kan Hacmi

Kan hacmi sinyali, kalp atışında meydana gelen kan hacmindeki değişimdir. Kalp atışında damarların boyutlarında meydana gelen değişiklikleri ölçmek için fotopletismografi (PPG) yöntemi kullanılır. Bu yöntem, ışık yayan bir LED ve bir foto detektör kullanarak cilt altındaki kan hacmi değişikliğini, değişen ışık yoğunluğu ile ölçer [87].

2.7.1.3 Cilt Sıcaklığı

Cilt sıcaklığı, stres de dahil olmak üzere çeşitli etkenlere bağlı olarak değişiklik gösterebilir. Normal erişkin bir insanın cilt sıcaklığı, (-) 12.7 ve (+) 60 °C arasında dayanıklılığa sahiptir [88].

2.7.1.4 İvmeölçer

İvmeölçer, cismin hareketini ve kuvvetini ölçmek amacıyla kullanılan elektromekanik bir araçtır. Tek ve çok eksenli ivmeölçer cihazlar, ivmenin hem büyüklüğünü hem de yönünü algılayabilir [89]. İvmeölçerler, telefon ve benzeri akıllı cihazlar için navigasyon sistemlerinde kullanılmaktadır [90].

2.7.2 Davranışsal Tepkiler

Davranışsal stres, zorlama, kısıtlama ve engelleme gibi durumlar karşısında vermiş olduğumuz tepkilerin tümünü içerir.

2.7.2.1 Konuşma

Yüz ifadelerinden dudak, göz ve kaşların pozisyonlarına göre duygusal durum tahmin gerçekleştirilebilir. Ancak şaka ile karışık kızgınlık gibi durumlarda duygusal durum fark edilemez. Bu nedenle görsel tepkilerin yanı sıra ses verilerinin de analiz edilmesi gerekir. Konuşma esnasında kullanmakta olduğumuz ses, çoğu zaman duygularınızı yansıtır. Konuşma hızı ve spektral özellikleri, istemsiz olarak stresli olaylardan etkilenir. Konuşma esnasındaki ses sinyali, kontrollü ve sessiz ortamlarda kolay veri toplama imkanı sağlaması nedeni ile tercih edilmektedir [91].

2.8. Duygu Analizi

Duygu analizi, çok çeşitli yöntemlerle yapılmakta olup insanların söylediği veya söylemediği duygularının dışavurum biçimini araştırarak duygularını tespit etmeyi sağlayan bir analizdir. Duygu analizi, fizyolojik sinyal, ses sinyali veya yüz ifadesi yöntemleri ile yapılabilir. Bu yöntemlerin ortak noktası, insanların nasıl hissettiklerini keşfetmektir.

2.8.1. Ses Sinyali

Konuşmak, insanlar arasındaki en önemli iletişim aracıdır. İnsan sesi, parmak izi gibi biyometrik bir özellik olup, kişinin anlık duygu durumunu da yansıtmaktadır. Yapılan çalışmalarda [92] [93], sesin niteliğine bağlı olarak duygusal içeriklerin tespiti gerçekleştirilmiştir.

Ses sinyalinin işlenebilmesi için sayısallaştırılması gerekmektedir [94]. Düşük frekanslı ses sinyalleri, istenmeyen ortam seslerini azaltmak için düşük geçişli bir filtre kullanılarak, bu ses sinyali filtrelenir. Ayrıca ses sinyalindeki sesli ve sessiz noktaları ayırmak gerekmektedir. Bu durumda tek bir ses etkinliği algılama yöntemi kullanılmamalıdır [95]. Bu gibi durumlarda amaca uygun birtakım ayırt edici özellik çıkarımları elde edilmelidir. Özellik çıkarma yöntemi olarak, kepstral katsayıları gibi yöntemler kullanılabilir [96].

2.8.1.1. Mel-frekans Kepstral Katsayıları

Mel-frekans Kepstral Katsayıları (MFCC), insan koklamasını taklit ederek birtakım işlemler sonucunda ses sinyalini dönüştürüp kısa vadeli spektrumları biçiminde gösterilmesidir [97]. Ses sinyalinin nitelik vektörü, kepstrum katsayıları kullanılarak elde edilir. MFCC, bu nitelik vektörlerindeki değişimlerin, kısa zamanlı güç spektrumu üzerinde gösterir [94].


2.8.1.2. Mel Frekansı

İnsanların ses frekanslarını algılaması, lineer bir skalada gerçekleşmez. Bu nedenle Mel-spektrogramın logaritmik formu, duyguların daha iyi anlaşılmasına yardımcı olur. Ses sinyalleri, “mel” skalası hesaplamaları çıkarılır. Bu hesaplamalar, ses sinyalinin zamana karşı frekans temsidir. Bu frekans temsili, farklı kategorideki her duygu için farklı güç yoğunluklarını içeren Mel spektrum görüntüleri elde edilir [97].

2.8.2. Yüz İfadesi Analizi

Yüz ifadeleri, duygu analizinde en önemli ipuçlarını veren veri türü olarak kabul edilmiştir [98]. Geleneksel yöntemlerle yüz ifadesinden duygu analizi gerçekleştirilebilmesi için öncelikle birtakım işlemler uygulanmalıdır. İlk adım, yüzün belirlenmesidir [99]. Yüz görüntüleri, ölçek, aydınlatma ve poz faktörleri gibi istenmeyen birtakım durumları ortadan kaldırmak için ön işlemden geçirilerek normalize edilir [100]. Yüz tespitinden sonra yüz ifadesi özniteliklerinin çıkarılması gerekmektedir. Son adımda elde edilen öznitelikler ile yüz ifadelerini tanımlamak

amacıyla uygun algoritmaların kullanılmasıdır [101]. Yüz ifadesi analizinin genel yapısı Şekil 2.3'de gösterilmektedir.



Şekil 2.1: Yüz ifadesi tanıma protokolü

Geleneksel yöntemlerde, görüntüdeki yüzün doğru bir şekilde tespit edilmesi, sınıflandırma işlemi ile doğrudan ilişkilidir. Bu nedenle kullanılan yüz belirleme algoritmaları, ifade sınıflandırmada kullanılan yöntemler kadar önemlidir [98]. Yüz belirleme yöntemleri bilgi, öznitelik, şablon ve görünüm tabanlı olarak dört kategoride sınıflandırılmaktadır [101]. Bilgi tabanlı yüz belirleme yöntemleri; yüz bilgisini kodlamadaki birtakım kurallara dayandırmaktadır. Bu kurallar, yüz özellikleri arasındaki ilişkileri ele alarak oluşturulur. Örnek olarak, bir yüzün görüntüsü birbirine simetrik olarak iki göz, iki gözün ortasında bir burun ve ağız olarak ifade edilebilir. Gözler, burun ve ağızın konumları ve aralarındaki mesafeler, yüzün belirlenmesi için kodlama kuralları olarak kullanılabilir. Öznitelik tabanlı yüz belirleme yöntemleri; yüz görüntüsündeki bakış açısı, poz veya aydınlatma durumları değişken olsa bile değişmeyen yapısal özellikleri tespit etmeyi amaçlamaktadır. Bazı yöntemler de saç çizgisi, kaşlar, gözler, burun ve ağız gibi yüz nitelikleri kenar algılayıcılar kullanılarak belirlenir. Çıkarılan nitelikler, istatistiksel modellere uygun bir yüz olup olmadığını tespit etmek için kullanılır. Şablon eşleme ile yüz belirleme yöntemleri; önceden tanımlanmış standart bir ön cephe yüz şablonuna dayanmaktadır. Yüz şablonu, bir bütün veya ayrı ayrı olacak şekilde yüz özellikleri tanımlanabilir. Yüz tespiti için, giriş görüntüsü ile oluşturulan şablon veya şablonlar arasında korelasyon hesaplanarak, giriş görüntüsünün yüz olup olmadığı ortaya çıkarılır. Görünüm tabanlı yüz belirleme yöntemleri; yüz modellerinin, görüntü eğitim veri setlerinden öğrenilmesi ile çalışır. Eğitim veri setlerinden öğrenilen öznitelikler genellikle diskriminant fonksiyonlar veya dağılım modelleri şeklinde ifade edilir. Bu aşamada yüz algılama etkinliğini sağlamak ve model performansını artırmak için boyut azaltma algoritmaları uygulanabilmektedir

Yüz görüntüleri büyük miktarda veri barındırdığı için, öncelikle bu verileri analiz ederek özellik uzayı çıkarılmalıdır. Yüz ifadesi analizinde, tahmin performansları özellik uzayı ile doğrudan ilişkilidir. Özellik uzayının, anlamlı verilerden oluşması sistem performansı ile birlikte sistem güvenilirliğini de artırmaktadır [102]. Özellik çıkarımı için, geometrik özellikler ve görünüm tabanlı özellikler olmak üzere iki temel yaklaşım kullanılabilir [103]. Geometrik özellikler yaklaşımı, kaş, göz, burun ve ağız gibi yüz bileşenlerinin konum ve şekil bilgilerini kapsayan verilerden oluşur. Yüz bileşenlerinin konum ve şekil bilgilerini elde etmek için yüz geometrisinden faydalanılmaktadır. Bu yaklaşım, insan yüzünde ve bedeninde doğru kabul edilen belirli oranlardan yola çıkarak yüz özelliklerini elde eder. Gözlerin baş yüksekliğinin tam ortasında bulunması; iki göz arasındaki uzaklığın bir gözün uzunluğu kadar olması, yüz yüksekliği/genişliği, burun genişliği, ağız uzunluğu gibi altın oranlar yüz özelliklerinin elde edilmesinde kullanılan oranlardan bazılarıdır [102]. Buna örnek olarak, Optik Akış [105] ve Aktif Şekil Modeli [106] örnek verilebilir. Görünüm tabanlı özellikler, ağız ve göz etrafında oluşan cilt dokusunda meydana gelen izler esas alınır. Yüz dokusu üzerinde görülen bu izler, ifade sınıflandırmak için kullanılır.

İlk olarak, yüz ifadelerindeki yüzün tamamından veya belirli bölgelerinden özellikler çıkarılarak bir özellik vektörü oluşturulur [107], [108]. Gabor Filtresi [110] ya da Yerel İkili Örüntü Operatörü [111] gibi teknikler, yüz özelliklerini tespit ederek özellik vektörü oluşturmak için kullanılan yöntemlerden bazılarıdır.

Son aşamada yüz ifadelerini tanımlamak için bir önceki adımda elde edilen yüz ifadelerine ait özellik vektörleri kullanılır. Bu özellik vektörleri ile yüz ifadeleri arasında benzerlikler sayesinde bir sınıflandırma işlemi gerçekleştirilir. Sınıflandırma yöntemleri olarak Destek Vektör Makineleri (SVM) ve Saklı Markov Modeli (HMM) gibi pek çok yöntem kullanılabilir. Sınıflandırma işleminde, önce etiketli verilerden oluşan bir eğitim veri seti hazırlanmalıdır. Eğitim veri seti kullanılarak model eğitimi gerçekleştirildikten sonra eğitilen model, test veri setindeki yüz ifadelerine göre belirli sınıf etiketleri çerçevesinde yüz ifadelerini tahmin etmeye çalışır [109].

Geleneksel yöntemler yerine, günümüzde çok büyük veriler ile eğitilmiş yapay sinir ağlarına dayanan modern yöntemler yer almıştır. Yüz ifadesi analizi için en yaygın kullanılan derin öğrenme yöntemi, evrişimli sinir ağlarıdır. Derin öğrenme

yöntemlerinin avantajı, büyük miktarda veriler ile eğitilmesi sonucunda modelin öğrenebilme yeteneğidir. Derin öğrenme yöntemlerinin dezavantajı, yeterli varyasyon içeren verilerin, çok büyük veri sayısı gerektirmesidir.

2.9. Yapay Sinir Ağı

Yapay sinir ağları, insan beynindeki nöronları ve sinirleri taklit eden, öğrenme, hatırlama ve genelleştirme yapma gibi yeteneklere sahip bir bilgi işleme sistemidir. Yapay sinir ağları, öğrenme yeteneğinin yanında bilgiler arasında ilişki kurabilme ve ezberleme özelliklerine de sahiptirler. Beynin öğrenme biçimini taklit eden sinir ağları, girdi bilgisini derleme, derlenen bilgiden çıkarım yapma, öğrenmiş olduğu çıkarımları saklama ve çıkarımları bütün veriler için genelleme kabiliyetine sahip bir işlemci olarak gösterilebilir [112]. Yapay sinir ağları, sınıflandırma, örüntü tanıma ve tahmin uygulamaları başta olmak üzere birçok alanda kullanılmaktadır.

Biyolojik sinir hücreleri, insan beyninin çalışmasını sağlayan en temel birimlerini barındırır. Milyarlarca sinir hücresinin birleşmesi ile biyolojik sinir ağları oluşmaktadır. Biyolojik sinir ağları, duyu organları ile gelen bilgileri algılayabilme ve gelen bilgiyi anlama mekanizmalarını kullanarak olay ve durumlar arasındaki ilişkileri öğrenebilme yeteneklerine sahiptir.


Biyolojik sinir hücresi, üç katmandan oluşmaktadır. Katmanlar; çevreden gelen sinyalleri elektriksel sinyallere dönüştüren alıcı sinirler, beynin oluşturduğu sinyalleri uygun tepkilere dönüştüren tepki sinirleri ve tepki sinirleri arasında sürekli ileri geri besleme ile uygun sinyalleri üreten merkezi sinir sisteminden oluşmaktadır. Sinir sisteminin temel elemanları dendritler, aksonlar, hücre gövdesi ve sinapslardır.

Yapay sinir ağı, biyolojik sinir ağına benzer şekilde, insan beyninin çalışma prensibini örnek alarak bilgiyi işler. Yapay sinir ağı ile biyolojik sinir sistemi arasındaki benzerlikler Tablo 1’de verilmiştir. Yapay sinir ağları, birbiri ile doğrusal veya doğrusal olmayan bağlar ile oluşturulan birçok elemandan meydana gelir.

Tablo 1: YSA ile biyolojik sinir hücrelerinin benzeşmesi

Biyolojik Sinir Sistemi	Yapay Sinir Ağı
Dendrit	Toplama Fonksiyonu
Hücre gövdesi	Aktivasyon Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağlarının temelini oluşturan küçük birimlere, yapay sinir hücresi denir. Şekil 2.4’de görüldüğü gibi girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere beş ana bileşenden oluşmaktadır.



Şekil 2.2: Yapay sinir hücresi

Girdi verileri, çevreden gelen verileri sinir hücresine getirir. Bu veriler, kendinden önceki sinirlerden veya doğrudan dış dünyadan sinir ağına giriş yapabilmektedir. Ağırlık değerleri, yapay sinir hücresinden alınan giriş verilerine özgü olarak önem derecesi belirten katsayıdır. Toplama fonksiyonu, girdi ve ağırlık katsayı verilerinin işlenmesinden sorumludur. Toplama fonksiyonu olarak çeşitli fonksiyonlar bulunmaktadır. En sık kullanılan, Ağırlıklı Toplam fonksiyonudur. Ağırlıklı Toplam fonksiyonunda, her girdi değeri kendine özgü ağırlık değeri ile çarpılarak hesaplama yapılır. Her bir girdi verisi için hesaplanan değerlerin toplamı alınır (denklem (1)).

$$\text{Toplam Fonksiyonu} = \sum Gi \times Ai \times ni \quad (1)$$

Denklemdaki, Gi girdileri, Ai sistemin ağırlıklarını, ve ni ise hücreye gelen toplam girdi sayısını göstermektedir.

Aktivasyon fonksiyonu, toplam fonksiyonu sonucunda aktarılan veri karşısında üreteceği çıktı verisini belirleyen fonksiyondur. Aktivasyon fonksiyonunda da toplama fonksiyonundaki gibi farklı formüller kullanılmaktadır. Sigmoid aktivasyon fonksiyonu, yapay sinir ağında en çok kullanılan aktivasyon fonksiyonudur. Bu aktivasyon fonksiyonu, doğrusal ve doğrusal olmayan durumlar arasında denge sağlayan ve sürekli artan bir fonksiyondur. Hücrenin çıktı değeri, 0 ile 1 aralığında değer almaktadır.

Yapay sinir ağı modelinin sınıflandırma doğruluğunu değerlendirmek için karışıklık matrisi oluşturulur. Bu matrisin satır ve sütun sayısı, sınıf sayısına eşittir. Örnek olarak, iki sınıfı bulunan bir karmaşıklık matrisi Şekil 2.5’de gösterilmiştir. Buna göre, sınıflandırma yapan modelin tahminleri x ekseninde gösterilirken gerçek sınıf etiketleri y ekseninde gösterilir. TP, gerçek sınıfı pozitif olan ve sistemin tahmin ettiği sınıf değerinin de pozitif olması durumudur. TN, gerçek sınıf değerinin negatif olması ve sistemin tahmin ettiği sınıf değerinin de negatif olması durumudur. FN, gerçek sınıf değerinin pozitif olması, sistemin tahmin ettiği sınıf değerinin negatif olması durumudur. FP, gerçek sınıf değerinin negatif olması ve sistemin tahmin ettiği sınıf değerinin pozitif olması durumudur. Buna bağlı olarak, TP ve TN sınıf değerleri modelin doğru tahminlerini gösterirken FN ve FP sınıf değerleri modelin yanlış tahminlerini gösterir.

	Tahmin Edilen	
	Pozitif	Negatif
Gerçek		
Pozitif	TP	FN
Negatif	FP	TN


Şekil 2.3: Karmaşıklık matrisi

Karmaşıklık matrisine bağlı olarak modelin genel başarısı, doğru tahmin edilen verilerin toplamının, tahmin edilen tüm veri sayısına bölünmesi ile elde edilir (denklem (2)) .

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

Yapay sinir ağlarında, belirli problemleri çözmeye yönelik çeşitli algoritmalar geliştirilmiştir. Görüntü işleme uygulamalarında kullanılan popüler bir yöntem olan


evrişim sinir ağı (CNN), girdi verisini küçük parçalara ayırarak, bu parçaları birbirinden ayırt edebilen derin öğrenme algoritmasıdır. Evrişim sinir ağı, doğal dil işleme, görüntü işleme ve ses analizi gibi alanlarında sıkça kullanılmaktadır. Bu algoritmanın çalışma prensibi Şekil 2.4 de gösterilmiştir. Buna göre giriş katmanından gelen veri, evrişim katmanına giderek özellik çıkarımı yapılmasını sağlar. Evrişim katmanına gelen kare matris şeklindeki verilerden özellik çıkarımları öğrenilerek pikseller arasındaki ilişkiler kurulur. Birleştirilmiş katmanlar, önemli özellikleri koruyarak her görüntünün boyutunu küçültür. Düzenlenen veriler, yapay sinir ağına girdi olarak verilir. Bu veriler modellenen yapay sinir ağındaki gizli katmanlarda işlenerek çıktı verisini oluşturur [113].



Şekil 2.4: CNN algoritması


Sıralı verilerin tahmin edilebilme problemi, uzun kısa süreli bellek (LSTM) algoritmasından faydalanılarak geliştirilen yapay sinir ağları ile çözümlenebilir. Bu sinir ağları, bir zaman serisindeki olaylar arasında bilinmeyen gecikme süreleri olabileceğinden, zaman serisine dayalı olarak verileri işleme, sınıflandırma ve tahmin yapmak için uygun bir yöntemdir. LSTM mimarisi, Şekil 2.5'de gösterildiği gibi, tahmin verilerinin tekrar tekrar sinir ağına geri verilmesi temeline dayanır. LSTM mimarisi, tahmin verilerinin, beklenen tahmin veriler dışına çıkılması durumunda normal verilerin korunması için görmezden gelme katmanında verileri düzenler. LSTM sistemi, hafızasındaki önemsiz verileri unutup yeni verileri hatırlamak için unutma ve hafıza katmanlarına sahiptir. En son, hafıza ve tahminlerin verilerini ayırt edilebilmesi için işlenen veriler, veri seçimi katmanından geçirilir. Bu katmanlar, temelde yapay sinir ağı modelleri ve aktivasyon fonksiyonu işlemlerini içerir. Bu algoritmanın çalışma prensibine göre sisteme giren yeni bilgiler, eğitilmiş modelden geçerek veri tahmin olasılıklarını oluşturur. Normalin dışındaki tahminler, görmezden gelme katmanından geçerek tahmin olasılıklarından çıkarılır. Elde edilen filtrelenmiş

olasılıklar, unutma ve hafıza katmanında, bir kopyası çıkarılarak mantıksal kapılama işlemi yapılır. Mantıksal kapılama işlemi, verinin bir sonraki adıma ne ölçüde geçeceğini hesaplanması işlemidir. Toplanmış olasılıklar, hafıza ve tahmin verilerini içerdiğinden bu bilgilerin ayırt edilebilmesi için seçim katmanı kullanılarak tahmin verileri elde edilir. Bu tahmin verileri tekrar sisteme verilerek, istenen tekrar sayısı kadar döngü oluşturularak tahmin yapılabilir [113].



Şekil 2.5: LSTM algoritması

Sıralı verilerin tahmin edilebilmesi için geliştirilen ve LSTM algoritmasının çalışma prensibine benzeyen bir diğer algoritma da geçitli tekrarlayan ünite (GRU) algoritmasıdır. Geçitli tekrarlayan ünite (GRU), sıralı veriler ile ardışık modellemede uzun süreli ilişkileri etkin bir şekilde koruyabilir. GRU, hücreler arası bilgi akışını kontrol etmek ve yönetmek için geçit mekanizmalarını kullanır. Bu algoritma, bulunduğu dizinin önceki bölümlerindeki bilgileri unutmadan büyük veri dizilerinden ilişkileri uyarlamalı olarak yakalar [114]. Geçitleme kapıları, her adım da atılacak ve saklanacak bilgilerin düzenlenmesinden sorumludur. GRU hücresi Şekil 2.6'daki gibi gösterilmiştir.



Şekil 2.6: GRU hücre yapısı

GRU hücresinde iki geçit mekanizması mevcuttur. Bunlar, güncelleme geçiti ve sıfırlama geçitleridir. GRU algoritmasında bulunan kapılar, LSTM algoritmasındaki kapılar gibi gerekli bilgileri korurken, gereksiz bilgileri seçerek sistemden uzaklaştırma prensibiyle çalışır. Bu kapılar, 0 ve 1 arasında değerler içeren ve giriş verileri ile gizli durum verilerinin çarpılması ile elde edilen vektörlerdir. Kapı vektörlerinde, 0 verinin önemsiz olduğunu ve sıfırlanacağını belirtirken 1 değeri ise verilerin önemli olduğunu ve saklanacağını belirtir [114].

LSTM algoritmasında, hafıza katmanı, bir önceki hücre durumunun hangi bölümlerinin saklanacağını belirlerken, girdi kapısı eklenecek yeni bellek alanını belirler. Bu iki kapı birbirinden tamamen bağımsızdır. GRU, güncelleme geçidi, önceki bellekten hangi verilerin kullanılacağından ve eklenecek yeni belleği kontrol etmekten sorumludur. Bunun anlamı, GRU algoritmasında hafızada saklanacak verilerin ve hafızaya eklenecek yeni bilgilerin birbirinden bağımsız olmadığı anlamına gelir. GRU ve LSTM algoritmaları arasında bulunan bir diğer fark ise, LSTM algoritmasında, uzun süreli belleğin hücre durumunda ve kısa süreli belleği gizli katmanda saklarken, GRU algoritmasında, her ikisini de tek bir gizli katmanda saklanmalıdır. GRU algoritmasındaki iki kapı LSTM algoritmasında bulunan üç kapıya kıyasla, işlem yükünün daha az olması ile daha hızlı eğitilmesini sağlar [115].

2.9.1 Transfer Öğrenimi

Transfer öğrenimi, bir problem üzerinde eğitilmiş modelin, ilgili ikinci bir problem üzerinde çalışabildiği bir sürecin bu problem için kullanılmasıdır. Derin öğrenmede transfer öğrenimi yöntemi, bir problemin yapay sinir ağı modeli ile çözümünden önce, bu probleme benzer bir problem modeli üzerinden eğitildiği bir

yöntemdir. Eğitilen modeldeki bir ya da daha fazla katman, sonradan oluşturulan yeni modele entegre edilerek kullanılabilir.

Bu yöntemde istenen bilgileri öğretmek için kendi modellerimizi veya hazır modellerden yararlanılabilir. Genellikle uygulamalarda ikinci yöntem tercih edilir. Derin öğrenme ve Artık Sinir Ağına (ResNet) modeli üzerinden transfer öğrenimi tabalı, kaynak penetrasyonunun uçtan uca tahmini yapılmıştır [116]. Bu çalışmada, bir evrişimli sinir ağı (CNN) tasarlanması sonucunda, sınıflandırma başarısı %92,70 olarak elde edilir. Eğitim hızını ve sınıflandırma başarısını artırmak amacı ile ResNet ağına dayalı bir transfer öğrenimi yakasımı geliştirilmiştir. Bu yaklaşım ile sınıflandırma başarısının %96,35'e yükseldiği ve eğitim sürecinin hızlandığı görülmüştür.

3. METHOD

Çalışmanın amacı, deneyim örnekleme metodu tabanlı toplanan görüntü, ses ve fizyolojik sinyaller ile derin öğrenmeye dayalı duygu tahmin etme sistemlerinin oluşturulmasıdır. Bu kapsamda katılımcılardan toplanan anket verilerinden istatistiki çıkarımlar yapılırken, görüntü, ses ve çeşitli fizyolojik sinyal verileri ile yapay sinir ağı modellerinden duygu tahminlemesi üzerinde çalışmalar yapıldı. Ayrıca, eşzamanlı toplanan görüntü ve ses verilerinin birlikte kullanılması ile stres tahminlerini destekleyen bir sistem kuruldu.

3.1. Deneyim Örnekleme Metodu

Deneyim örnekleme metodu, günde 7 bildirim olmak üzere sabah 10.00 ve akşam 20.00 arasında yarı zaman tabanlı yarı rastgele olacak şekilde tasarlanmıştır. Gün içinde 6 defa, anlık anket doldurulması ve eşzamanlı olarak dijital saat (Empatica E4) kaydı başlatılması için katılımcıların akıllı telefonlarına bildirim gönderildi. Dijital saat kaydı, her oturumda 15 dakika boyunca katılımcıların elektrodermal aktivite, kan basıncı değişimi, cilt sıcaklığı ve 3 yönlü ivmeölçer verilerini kayıt altına alır. Aynı zamanda, günde 1 defa rastgele olarak yoğun duygular hissettikleri anlarda deneyim paylaşımı için bir kişisel görüntü çekimi ve ses kaydı yapmaları hatırlatıldı.

3.2. Veri Toplama Protokolü

Deneyim örnekleme metoduna dayanan çalışmamızda, fizyolojik sinyallerin ve anket verilerinin eşzamanlı olarak toplanması planlanmıştır. Dijital saat kaydı, katılımcıların elektrodermal aktivite, kan basıncı değişimi, cilt sıcaklığı ve 3 yönlü ivmeölçer verilerini her kayıt oturumu için 15 er dakika süreyle kaydetmektedir. Fizyolojik sinyaller ile eşzamanlı olarak anlık anket verileri mobil uygulama aracılığı ile toplanmıştır. Anlık anket soruları, duygu durumunu en doğru biçimde yakalamak için kısa ve net 6 sorulardan oluşturulmuştur. Anlık anket haricinde, 10 maddelik


Uluslararası Pozitif ve Negatif Etki Çizelgesinin Kısa Formu [117] ve 20 maddelik Sweet Briar Üniversitesi Akademik Kaynak Merkezi'nden alınıp genel stres testi [118] verilerinin de toplanması sağlanmıştır. Deneyler sırasında katılımcıların yoğun duygular hissettikleri anlarda, görüntü ve ses kaydı paylaşımlarını sunulan mobil uygulama aracılığı ile paylaşımları istenilmiştir.

Çalışma kapsamında 20 katılımcı için 7 gün süresince 6 defa 15 dakikalık oturumlar olacak şekilde 4 ayrı fizyolojik sinyalin 210 saatlik kaydın gerçekleşmesi planlandı. Bu süreçte toplanan fizyolojik sinyaller ile eşzamanlı olarak kısa anlık anketlerden de toplam 4.788 cevap elde edilmesi gerektiği hesaplanmıştır. PANAS ölçeği ve genel stres testi, birer defa cevaplanması gereken anketlerdir.

Çalışmada katılımcılardan veri toplamak için kullanılacak uygulama geliştirilmeden önce birtakım diyagramlar ile sistem modelinin ortaya çıkarılması planlandı. Bu diyagramlar, mobil uygulamanın geliştirilmesinde analiz/çözümleme ve tasarım süreçlerinin belirlenmesinde önemli rol oynar. Bu şekilde gerçek sistemin resmi çizildiğinden, sistem eksiklikleri ve özellikleri daha kolay anlaşılır.

Sistemin genel işleyişinde, uygulamaya giren katılımcının, mevcut bir hesabı yoksa hesap oluşturma ekranından yeni bir hesap oluşturduktan sonra sistem katılımcıyı giriş sayfasına tekrar yönlendirir. Katılımcının hesabı mevcut ancak şifresini hatırlamıyor ise şifre yenileme ekranından mail yoluyla şifre yenilendikten sonra giriş ekranına yönlendirilir. Uygulamaya başarılı şekilde giriş yaptığında, ilk karşılaşılabilecek ekran katılımcı bilgileri ekranıdır. Katılımcı bilgilendirme ekranından, profil, anlık anket, güçlü duygu anı, genel stres testi, PANAS ölçeği ve ayarlar ekranlarına geçiş yapılabilir. Profil bilgilerinde, katılımcılara EK A da bulunan sorular yöneltilir. Anlık anket, katılımcının anlık duygu durumunu ölçmek amacıyla tasarlanmıştır. Bu ankette, EK B deki sorular katılımcılar tarafından cevaplanması beklenir. Genel stres testinde, günlük olaylar karşısında katılımcının genel duygu durumu ölçmek için 20 soruluk bir anket kullanılır. Bu anket EK C deki sorulardan oluşur. Sistem, genel stres testi sonunda likert ölçekli soruların cevaplarına karşılık gelen puanların toplanmasının ardından katılımcılara geri bildirimde bulunur. Güçlü duygu anı, katılımcıların güçlü duygular hissettikleri anlarda görüntü ve ses kaydı görevlerini yerine getirmesi için tasarlanmıştır. Görüntü, katılımcının anlık bulunduğu

duygu durumunu yansıtan bir kişisel çekim yapması; Ses kaydı, katılımcının bulunduğu durumu sesli bir biçimde anlatması ile tamamlanır. PANAS ölçeği, katılımcının 5 pozitif ve 5 negatif duygu değerlendirmesi temeline dayanır. Bu ölçek, EK D deki duygulardan oluşur. Ayarlar ekranından, oturum kapatma ve şifre yenileme işlemleri yapılabilir. Mobil uygulamanın genel işleyiş biçimi, Şekil 3.2-A'da gösterilmektedir.




Şekil 3.2: Mobil uygulamanın genel işleyiş biçimi

3.3. Deneyim örnekleme uygulamasının geliştirilmesi

Katılımcıların anlık verilerini toplamak için geliştirilen deneyim örnekleme uygulaması, react native ile gerçekleştirilmiştir. React Native, Facebook tarafından açık kaynaklı bir mobil uygulama ortamıdır. Bu ortamda, Android, iOS ve Web için uygulamalar geliştirilebilir [119]. React bileşenleri, mevcut yerel kodu sarmalayarak katılımcı arayüz paradigması ve javascript aracılığı ile yerel API'larla etkileşime girer. Bu bağlamda, ekiplerin yerel uygulama geliştirmesine ve mevcut yerel ekiplerin daha hızlı çalışmasını sağlar [119].


Uygulamanın giriş ekranı Şekil 3.3.1-A da gösterilmiştir. Her bir katılımcının verilerini düzenli takip edebilmek için kullanıcı girişi olacak şekilde tasarım kararı alınmıştır. Katılımcının henüz bir hesabı yoksa Şekil 3.3.1-B'deki ekrana giderek hesap oluşturabilir. Katılımcı sisteme kayıtlı fakat şifresini unuttu ise Şekil 3.3.1-C'deki ekrana giderek şifre sıfırlama işlemi gerçekleştirebilir.



Şekil 3.3.1: Deneyim örnekleme uygulamasına ait a) girişi ekranı , b) kayıt ekranı ve c) Şifre yenileme ekranı

Katılımcı, başarılı bir şekilde sistemde giriş yaptığinde, katılımcı bilgi ekranına yönlendirilir. Bu bölümde katılımcı demografik bilgileri bulunmuyorsa öncelikle kişisel bilgilerini kaydeder. Bu işlemin ardından, genel stres testi ve PANAS Ölçeği görevlerinin tamamlanması istenir. Katılımcı bilgi ekranı, Şekil 3.3.2-A’da gösterilmektedir.

Katılımcı menüden profil, anlık anket, güçlü duygu anı, genel stres testi, PANAS ölçeği ve ayarlar ekranlarına geçilebilir. Profil ekranı, katılımcının demografik bilgilerini içerir. Genel stres testi, günlük olaylar karşısındaki katılımcının stresi ölçmeye yönelik 20 soruluk bir testtir. Deneyim bölümü, katılımcının anlık durum değerlendirmesi amacıyla uygulanan kısa bir ankettir. Yoğun duygu anı, katılımcının bulunduğu duruma bağlamında bir kişisel görüntü ve bir ses kaydı görevlerini yerine getirmesiyle tamamlanır. PANAS ölçeği, katılımcının pozitif ve negatif duygularını ölçmeyi amaçlayan 10 soruluk bir ölçektir. Ayarlar ekranından şifre yenileme ve oturum kapama işlemi yapılabilir. Menü Şekil 3.3.2-B’de gösterilmektedir.




Şekil 3.3.2: Deneyim örnekleme uygulamasına ait a) Katılımcı bilgi ekranı, b)Menü

Katılımcıların ilk olarak yerine getirmesi gereken görev, 11 demografik sorulardan oluşan profil bilgilerini doldurmasıdır. Katılımcı, demografik bilgilerini kaydedebilir ve güncelleyebilir. Profil, Şekil 3.3.3-A’da gösterilmektedir.

Genel stres testi ekranından, katılımcının genel anlamda stres seviyesini ölçmek amacıyla Sweet Briar Koleji Akademik Kaynak Merkezinden alınan Stres Düzeyi Testi uygulanır. Bu test de 4’lü likert ölçeği kullanılmıştır. Bu anket sonucunda, verilen cevapların sayısal değerleri toplanarak stres puanı hesaplanır. Eğer toplam stres puanı, 20-30 arasındaysa hayatınızı canlandırmaya ihtiyacınız var; 31-50 arasında ise stresle başa çıkma konusunda iyi durumdasınız; 51-60 arasında ise stres düzeyi normalin üzerinde ve aşırı gergin olmanın sınırındasınız; 61 ve üzerinde ise, kalp hastalığına yakalanma ihtimaliniz yüksek uyarılarını verir. Anket sonucu olarak elde edilen toplam stres puanına göre katılımcı bilgilendirilir. Genel stres testi, Şekil 3.3.3-B’de gösterilmektedir.


Anlık anket ekranı, katılımcının anlık durum değerlendirmesi yapması için 6 sorudan oluşan bir ankettir. Anlık anket, Şekil 3.3.3-C’de gösterilmektedir.

Katılımcılardan, bir defa kısa PANAS ölçeğini tamamlaması istenir. Bu ölçek, 10 soruluk bir pozitif ve negatif etki çizelgesidir. PANAS ölçeği, Şekil 3.3.3-D’de gösterilmektedir.



Şekil 3.3.3: Deneyim örnekleme uygulamasına ait a) Profil, b) Genel Stres Testi, c) Anlık Anket, d) PANAS Ölçeği

Katılımcılar gün içinde güçlü duygu durumu yaşadıkları esnada, kişisel görüntü ve ses kaydı görevlerini tamamlaması istenir. Bu görüntü, anlık moral durumu çerçevesine göre çekilmelidir. Bu görev Şekil 3.3.4-A’da gösterilmektedir. Görüntü görevinden sonra “Sizi etkileyen olay neydi?” sorusuna sesli cevap verilmelidir. Ses kaydı ekranı, Şekil 3.3.4-B’de gösterilmektedir.



Şekil 3.3.4: Deneyim örnekleme uygulamasına ait a) Görüntü, b) Ses Kaydı

3.4. Füzyon Veri Seti

Çalışma kapsamında çoklu kaynaktan beslenen bir veri seti oluşturulmuştur. Bu veriler anket sorularının cevaplama anlarında anlık olarak mobil cihaz ve akıllı saat (Empatica E4) yardımı ile toplanmıştır. Empatica E4, insan fizyolojisi üzerine araştırma yapan bilim insanları ve hekimler için tasarlanmış bir cihazdır. Fizyolojik

sinyallerin gerçek zamanlı takibi için masaüstü uygulamasının yanı sıra hem Android hem de iOS işletim sistemini destekleyen mobil uygulaması da bulunmaktadır [120].

Çalışma kapsamında toplanan veriler, İstanbul Kültür Üniversitesi 2020.29 numaralı etik kurul izni ile toplanmıştır. Çalışmaya katılan 20 kişiden %35'i kadın, %65'i erkek, yaş ortalamaları 38,7 ve yaş ortalamalarının standart sapması 15.05 olarak tespit edilmiştir. Katılımcıların meslekleri incelendiğinde, dört bilgisayar mühendisi, iki araştırma görevlisi, iki hakim, iki avukat, iki doktor, iki araştırma görevlisi aday, bir pazarlamacı, bir işletmeci, bir akademisyen, bir sekreter, bir mantar üreticisi ve bir öğrenci çalışmaya katılmıştır. Katılımcıların çalıştıkları ortamlar incelendiğinde %60'i özel sektöründe, %30'u kamu sektöründe çalışmaktayken %10'u ise çalışmamaktaydı. Katılımcıların alışkanlıkları incelendiğinde, %75'i sigara kullanmıyorken %25'i sigara kullanmaktadır. Sağlık durumları gözlemlendiğinde, %20 hastalık durumlarını belirtirken, %80 sağlıklı olduğunu belirtmiştir. Belirtilen hastalıklar araştırıldığında, iki kişi egzama probleminden bahsederken, bir kişi kalp problemi olduğundan ve bir kişi ise sadece hastalık durumunun mevcut olduğundan bahsetmiştir. Ayrıca çalışmaya dahil olan 1 katılımcı çalışmayı tamamlayamamıştır bu sebeple veri setinden çıkarılmıştır. Bunlar örneklem setinden çıkarılmış ve analize dahil edilmemiştir.

Çalışmadaki 20 katılımcının, 175 saatlik fizyolojik sinyal verisi toplanırken, 4.200 anlık anket sorularının cevaplandığı görülmüştür. PANAS ölçeği ve genel stres testi, tüm katılımcılar tarafından birer defa tamamlanmıştır. Fizyolojik sinyalin yanı sıra katılımcılardan 111 adet görüntü ve 68 adet ses kaydı toplanmıştır. Toplanan görüntü ve ses verileri, 7 kategoride (sinirli, tiksime, korku, mutlu, üzgün, şaşırılmış, nötr) etiketlenmiştir. Toplanan görüntü verilerinden örnek bir kesit Şekil 3.4'de gösterilmiştir.



Şekil 3.4: Deneyim örnekleme sırasında toplanan görüntü verisi örnekleri

3.5. Harici Veri Setleri

Katılımcılardan toplanan veriler haricinde birkaç popüler veri seti de çalışma kapsamına dahil edilmiştir. Ses analizinde, SAVEE veri tabanı [121], Surrey Üniversitesi'ndeki dört yüksek lisans öğrencisi tarafından, TESSS veri seti [122], Northwestern Üniversitesinde yapılan araştırma kapsamında iki katılımcı tarafından ve RAVDESS [123], 24 farklı katılımcı tarafından toplanan ses kayıtlarından faydalanılmıştır. Yüz analizinde kullanılan Fer2013 [124] veri seti, 48x48 piksel gri tonlamalı yüz ifadeleri ve Cohn-Kanade [125] veri seti, 640x480 piksel çözünürlükte gri tonlamalı yüz ifadeleri, yedi kategoride (kızgın, aşağılama, tikslenme, korku, mutlu, üzgün, sürpriz) etiketlenmiş veri setleridir. Fer2013 veri setinin örnek kesiti Şekil 3.5-'da, Cohn-Kanade veri setinin örnek veri kesiti Şekil 3.5-'de gösterilmiştir.



Şekil 3.5-A: Fer2013 veri setinden örnek veri kesiti



Şekil 3.5-B: Cohn-Kanade veri setinden örnek veri kesiti

Son olarak, sentezlenen yüz ifadelerinden oluşan veri setinde, 5.098 adet sinirli, 723 adet tikslenme, 5.200 adet korkmuş, 9.118 adet mutlu, 6.203 üzgün, 4.261 adet şaşırılmış ve 6.307 adet nötr veri olmak üzere toplamda 36.910 adet yüz ifadeleri bulunmaktadır. Sentezlenen ses kaydı veri setinde ise 655 adet sinirli, 650 adet tikslenme, 655 adet korkmuş, 655 adet mutlu, 684 üzgün, 650 adet şaşırılmış ve 618 adet nötr veri olmak üzere toplamda 4.567 adet ses kaydı bulunmaktadır.

3.6. Veri Seti Ön İşleme

Toplanan yüz görselleri, 1152×2048 piksel çözünürlükte olup RGB renklerde kodlanmıştır. RGB renkli görüntüler, veri işleme kolaylığı amacıyla gri renklendirmeye (gray scale) dönüştürülmüştür. Görüntü çözünürlükleri, çalışmaya

kapsamındaki en küçük görüntü çözünürlüğüne indirgenerek çözünürlükleri eşitlenmiştir.

Ses sinyallerinin ön işlem adımları, iki farklı yöntem kullanılarak gerçekleştirilmiştir. Birinci yöntemde sinyaller, ikili skaladaki (binary scale) güç spektrumları çıkarılırken, ikinci yöntemde ise sinyallerin mel spektrumları elde edilmiştir.

Toplanan fizyolojik sinyaller ise farklı örnekleme frekanslarında olması nedeniyle aşağı örnekleme (downsampling) metodu kullanılarak örnek sayıları eşitlenmiştir. Aşağı örnekleme metodu, yüksek frekanslı bir sinyali, düşük frekanslı sinyale indigeme işlemidir. Fizyolojik veriler, 4 Hz, 32 Hz. ve 64 Hz frekanslara sahip sinyaller. 4 Hz frekansına indirgemıştır. Örnekleme sayıları eşitlenen sinyaller, polinom özellik dönüşümü ile ikinci dereceden özellik dönüşümüne tabi tutulmuştur.

3.7. Önerilen Çok Kaynaklı Füzyon Veri Tabanlı Derin Öğrenme Modeli (DEEP-FUS)

İlk bakışta, birden çok veri kümesini veri düzeyinde birleştirmek en iyi sonucu vermesi gerektiği düşünülebilir. Fakat pratikte, altta yatan fenomenin karmaşık ve bilinmeyen doğası, çeşitli faktörler ve spesifik araştırma sorularının oluşu, veri kümelerini daha yüksek bir soyutlama düzeyinde ve belirli basitleştirme ve azaltma adımlarından sonra birleştirmeyi uygun kılar. Çok disiplinli bir yaklaşım olan bu yöntem, kaynak verilerinin performansını artırmak veya veri sınıflandırmasındaki belirsizliği azaltmak amacıyla birbiriyle ilişkili bilgilerin birden fazla modaliteden çıkarılması ve entegrasyonu için çok modlu bilgi füzyonu kullanılabilir. Biz füzyon veri tabanı oluştururken bir veya daha fazla modalitenin bir diğerini kısıtlamak için kullanıldığı, ardışık işleme modalitelerini kullanmayı tercih ettik. Bu yaklaşım ile görsel verileri, ses sinyallerinden önce işlenecek şekilde grupladık ve buna bağlı olarak ses sinyallerini işlememizde destek sağlayacak ikinci veri grubunu oluşturduk. Anket tabanlı veriler ise gerçekleştirilen işlemlerin ardından doğrulama ve kıyaslamalarda kullanılmak üzere üçüncü veri grubunu oluşturur. Böylelikle verilerin birbiri ile etkileşime girmesine imkan sağlayacak gerçek bir füzyon çalışması belirlendi.

Bu çalışma kapsamında birçok kaynaktan toplanan görüntü verileri, ön işleme aşamasında yeniden boyutlandırma, renklendirme ve temizlenme adımları

uygulanarak yapay sinir ağıları ile oluşturulan modele verilir. Görüntü verileri için eğitilen model, ses sinyalleri için yeniden eğitilerek ses verilerinin duygu analizinde kullanılmıştır.

Çeşitli sensörler aracılığı ile farklı türlerde veriler toplanmıştır. Bu verilerden, fizyolojik sinyaller çeşitli zaman pencerelerin bağlamında incelenmiştir. Birinci yapay sinir ağı, sıralı bir model olmak üzere normal dağılıma sahip kernel initializer (başlangıç ağırlıkları) parametresiyle 14 girdi verisinin relu aktivasyon fonksiyonlu ve birbirinden farklı nöron sayılarına sahip 3 gizli katmandan geçerek sigmoid aktivasyon fonksiyonu kullanarak bir çıktı verisi üretir.

İkinci yapay sinir ağı, birinci yapay sinir ağından farklı olarak sırasız (nan Sequential) bir yapıya sahiptir. Bu modelde, normal dağılıma sahip kernel initializer (başlangıç ağırlıkları) ile 14 girdi verisinin relu aktivasyon fonksiyonlu ve birbirinden farklı nöron sayılarına sahip 4 gizli katmanın birleşmesi sonucunda sigmoid aktivasyon fonksiyonu kullanarak bir çıktı verisi elde eder.


Üçüncü yapay sinir ağı, 14 girdi verisinin sıralı bir biçimde 120 nöronlu bir LSTM algoritmasında her bir tekrar sırasında 0.2 unutma oranı (recurent drop) ile geçip, düzenleme katmanının (Flatten) ardından sigmoid aktivasyon fonksiyonu kullanarak bir çıktı verisi üretmesine dayanır.

Dördüncü yapay sinir ağı, sırasız çalışan çift yönlü bir LSTM modelidir. Bu model girdi katmanının ardından iki adet çift yönlü LSTM katmanına dallanır. Bu katmanlardan biri 20 diğeri 60 nörona sahiptir. İki ayrı çift yönlü LSTM katmanından gelen veriler birleşerek sigmoid aktivasyon fonksiyonundan geçerek bir çıktı verisi üretir.

Beşinci yapay sinir ağı, üçüncü yapay sinir ağına benzer şekilde sıralı bir model olup, 14 girdi verisinin 120 nöronlu bir GRU algoritmasından geçerek düzenleme katmanının (Flatten) ardından sigmoid aktivasyon fonksiyonu kullanarak bir çıktı verisi üretmesi ile sonuçlanır.

Tüm modellerde, adam optimizasyon algoritması kullanılırken kategorik kros entropi kayıp fonksiyonu ve kategorik başarı metriği parametreleri kullanılmıştır. Fizyolojik veriler, karışık bir biçimde 150 parti boyutunda (batch_size) 45 iterasyon (epoch) sayıları stres tahmini yapmışlardır.

Bu dört yapay sinir ağı modeli üzerinden fizyolojik sinyallerin stres analizi performansları kıyaslanmıştır. Sıralı ve sırasız iki farklı çalışma prensibi ile tasarlanan modellerde, LSTM ve GRU algoritmalarından faydalanılmıştır. Bu modellerden optimum performansa sahip model mimarisi, Şekil 3.8.4 de gösterilmiştir. Bu şekle göre, fizyolojik veriler ön işlemden geçerek modelin giriş katmanına gelir. Model, 6 gizli katmandan oluşur. Bu gizli katmanlar sırasız bir şekilde birbirine bağlanır. Bu gizli katmanlardan gelen 4 girdi verisi, bir birleşim katmanından elde edilen verinin, çıktı katmanına verilerek tahmini verisini oluşturur.



Şekil 3.8.4: Önerilen fizyolojik sinyal tabanlı model mimarisi


Fizyolojik sinyallerin ikili ve üçlü kombinasyonları üzerinden 50 katmanlı ResNet [126] ağından faydalanılarak transfer öğreniminin ardından fizyolojik sinyaller için önerilen model üzerinden stres tahminleri gerçekleştirildi. Görsel ve işitsel toplanan, fizyolojik veriler doğrudan algılanabilmesine rağmen, duygu analizinde güçlü bir şekilde rol oynayıp oynamadıkları araştırılmak istenmiştir. Bu nedenle, görüntü ve ses sinyal verileri ile bir füzyon çalışması yapıldı. Önerilen model, CNN algoritması kullanılarak, kategorik çapraz entropi optimizasyonu ile kayıp (loss) değerlerinin hesaplanmasına dayanan bir yapay sinir ağı modelidir.

4. BULGULAR

Çoklu sensörlerden gelen fizyolojik sinyaller ve mobil uygulamadan elde edilen anket, görüntü ve ses verileri, duygusal tepkileri araştırmak amacı ile incelenmiştir. Görüntü ve ses verileri, yedi duygu etiketiyle incelenirken, olumlu duyguların stressiz, olumsuz duyguların da stresli durumları yansıttığı düşünülür. Fizyolojik sinyaller ile stres tahmini sırasında, katılımcıların anlık duygu ifadeleri, olumlu/olumsuz duygusal ifadeler olarak düşünülerek stressiz/stresli olarak etiketlenmiştir.

4.1. İstatistikî Bulgular

Katılımcılardan toplanan anlık anket verilerinde, olumsuz duygular (sinirli, gergin, kızgın, endişeli, mutsuz, üzgün) hissettikleri anlardaki yaptıkları aktiviteler incelenmiştir. Katılımcıların en olumsuz hissettikleri 3 aktivite incelendiğinde, %43 çalışma, %19 iş ve %19 sohbet aktiviteleri tespit edilmiştir. Şekil 4.1’de, yapılan aktiviteye bağlı olumsuz duygu oranları gösterilmiştir.



Şekil 4.1: Yapılan aktiviteye bağlı olumsuz duygu oranları

Genel stres testi cevapları, spearman korelasyonu ile incelenmiştir. Bu cevapların korelasyon değerleri, %71 ve üstünde bir değer ise değişkenler arasında

yüksek düzeyde doğrusal bir ilişki olduğunu söyleyebiliriz. Bu bağlamda katılımcıların en sık yaptıkları alışkanlık, trafik de kırmızı ışık yanmak üzere iken araba ile geçmeye çalışmak olduğu %75 korelasyon değeriyle tespit edildi. İkinci olarak katılımcıların sıklıkla yaptıkları alışkanlık, hızlı konuşma ve sohbeti hızlandırma eğilimleri, %73 korelasyon değeriyle tespit edildi. Aynı zamanda katılımcılar, %74 korelasyon değeriyle “kendini geçinilmesi zor biri” olarak tanımlamışlardır.

Vücut kitle indeksi, kilogram cinsinden ağırlığın, metre cinsinden boy uzunluğunun karesine bölünmesi ile elde edilir. Katılımcıların demografik bilgilerinden elde edilen beden kitle indeksleri ile genel stres testi puanları arasında %84 oranında yüksek bir korelasyon değeri yakalanmıştır. Katılımcıların uzun süre strese maruz kalması, strese bağlı yeme bozukluğuna neden olabileceği düşünülmektedir. Bu bağlamda uzun süreli stres durumu, beden kitle indeksinde artış ve buna bağlı obezite hastalığına yol açabileceği düşünülmektedir.

Kısa PANAS ölçeği, 5'li likert ölçek kullanılarak 5 olumlu ve 5 olumsuz duygu değerlendirmesi yapmayı amaçlar. Genel stres testi puanları, 60 puan altında ise stres düzeyi normal, üstünde ise yüksek olarak değerlendirilmiştir. Genel stres puanı ile PANAS ölçeğinde bulunan duygular arasında bir korelasyon olup olmadığı spearman korelasyonu ile hesaplanmıştır. PANAS ölçeğindeki davranışlar ve genel stres puanları arasında ilişki olup olmadığını gösteren spearman korelasyon değerleri Tablo 2’de gösterilmiştir. Bu tabloya göre sinirli olma durumu, dikkatli olma durumu, düşmanlık duygusu ve mutsuzluk duygusunun stres ile yüksek oranda ilişkili olduğu görülmüştür. Stres, kısa vade de odaklanma konusunda fayda sağlasa da, uzun vade de, sinirlilik, mutsuzluk ve düşmanlık gibi olumsuz duyguların, insanlar üzerinde psikotik rahatsızlıklara neden olabilir.


Tablo 2: Genel stres puanı ve PANAS ölçeği parametrelerinin korelasyon değerleri

Duygular	Stres ile Korelasyon (Spearman Korelasyon)
Aktiflik	%66
Kararlılık	%61
Dikkat	%79

İlham	%18
Uyanık	%55
Korku	%54
Sinir	%71
Mutsuzluk	%93
Düşmanlık	%85
Utanç	%45


4.2. Yüz İfadesi Bulguları

Yüz ifadesi görüntüleri, CNN modeli ile 7 duygu ifadesi tahmin edilmiştir. Şekil 4.2.1 de, test verileri üzerinden gerçekleştirilen duygu tahminlerinin örnek bir kesiti gösterilmektedir. Buna göre, birinci katılımcının yüz ifadesi mutlu, ikinci katılımcının yüz ifadesi nötr ve üçüncü katılımcının yüz ifadesi sinirli olarak tahmin edilmiştir.



Şekil 4.2.1: Yüz ifadesi görüntüleri ve duygu tahmini


Yüz ifadelerinin duygu tahmini, %83 başarı ile gerçekleştirilmiştir. Aynı zamanda modelin karmaşıklık matrisi Şekil 4.2.2'de gösterilmektedir. En iyi tahmin edilen veriler, mutlu etiketine sahip veriler, en kötü tahmin edilen verileri ise tiksiniş etiketlerine sahip verilerdir. Tahmin başarısı, veri setinde bulunan verilerin sayısı ile doğru orantılıdır. Bu bağlamda modele yeterli sayıda veri sağlanamaması, modelin iyi eğitilmemesi ve buna bağlı tahmin başarısının düşmesine neden olur.



Şekil 4.2.2: Yüz ifadesi görüntülerinin duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi

4.3. Ses Bulguları


Katılımcılardan toplanan ses veriler, görüntü verileriyle eşzamanlı olarak toplanmakta olup, açık kaynaklı ses verileri ile sentezlenmiştir. Oluşturulan yeni ses verileri, 7 duygu ifadesi ile etiketlenmiştir. Bu duygu ifadeleri sinirli, tıksınmış, korkmuş, mutlu, üzgün, şaşırmış ve nötr etiketlerinden oluşmaktadır. Ses sinyallerinin güç spektrumları ve mel spektrumları elde edilerek 2 farklı yöntem ile duygu tahminleri gerçekleştirilmiştir. Korku ve üzüntü etiketine sahip ses sinyalleri, Şekil 4.3.1'deki gibi güç spektrumları ve mel spektrumlarına birer örnek gösterilmiştir. Ses sinyalleri, öfke, korku ve sevinç duygularını belirtirken daha yüksek ve daha geniş bir perde aralığında, üzüntü ve yorgunluk gibi duyguları belirtirken daha yavaş ve daha düşük perdeli sinyaller üretildiği görülmüştür.



Şekil 4.3.1: Korku ve üzgün durumlarda kaydedilen örnek ses veri kesiti


Ses sinyallerinden elde edilen güç spektrum görüntülerini, görüntü verileriyle eğitilen CNN modeli üzerinden tekrar eğitilmesi sonucunda duygu tahminlerindeki

ortalama başarı %66 olarak tespit edildi. Güç spektrum görüntülerinden elde edilen duygu tahminlerinin karmaşıklık matrisi Şekil 4.3.2 de deki gibi gösterilmektedir. Bu grafiğe göre, x eksenindeki veriler modelin duygu tahminlerini gösterirken y eksenindeki verileri ise doğru duygu etiketlerini gösterir.



Şekil 4.3.2: Ses sinyallerinden güç spektrumları elde edilerek duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi

Mel spektrum görüntüleri, görüntü verilerinin eğitildiği model üzerinden tekrar eğitilmesi sonucunda ortalama %74 oranında doğru tahmin edilmiştir. Bu modelin karmaşıklık matrisi, Şekil 4.3.3 de gösterilmiştir. Bu şekle göre, x eksenindeki veriler modelin duygu tahminlerini gösterirken y eksenindeki verileri ise doğru duygu etiketlerini gösterir. En başarılı duygu tahmini, sinirli etiketine sahip ses kayıtları, en başarısız duygu tahmini ise şaşırmış etiketine sahip ses kayıtlarıdır.




Şekil 4.3.3: Ses sinyallerinden mel spektrumları elde edilerek duygu tahminleri gerçekleştirilmesi sonucunda karmaşıklık matrisi

Sonuç olarak, ses sinyalinin duygu analizi sırasında mel spektrum görüntülerinin güç spektrum görüntülerinden daha başarılı sonuçlar verdiği tespit edilmiştir.


4.4. Fizyolojik Sinyal Bulgular

Katılımcıların, strese karşı verdikleri tepkileri araştırmak için sempatik sinir sistemini etkileyen birtakım fizyolojik sinyaller incelendi. Katılımcıların fizyolojik sinyalleri, stressiz ve stresli olmak üzere iki kategoride incelenmiştir. Şekil 4.4.1’de fizyolojik sinyallerin stres dağılımları gösterilmiştir. Bu şekle göre, katılımcılardan %65,9 stressiz, %34,1 stresli fizyolojik sinyaller toplanmıştır. İncelenen fizyolojik sinyaller, elektrodermal aktivite, kan basıncı değişimi, cilt sıcaklığı ve 3 yönlü ivmeölçer sinyalleridir. Cihaz elektrotlarının, kayıt sırasında vücut üzerindeki konumu ve çevresel koşullar tarafından etkilenebileceğine dikkat edilmelidir.




Şekil 4.4.1: Fizyolojik sinyallerin stres oranları

Elektrodermal aktivite (EDA), 4 Hz sabit örnekleme oranına sahip olup bu üç ana bileşenden vardır. Bu bileşenler, cilt iletkenlik seviyesi, fazık ve tonik bileşendir. Cilt iletkenlik seviyesi, eşik zaman damgası olarak 0.05 μ S civarında ayarlıdır. Devamlılığı olan elektriksel aktiviteler tonik parametreler olarak adlandırılır. Devamlılığı olmayan ve herhangi bir uyarana karşı tepki olarak çıkan, kısa süren aktiviteler, fazık parametreler olarak adlandırılır. Bu bileşenler, uyarılma sırasındaki fizyolojik tepkileri yansıttığı düşünülmektedir. Şekil 4.4.2’de, stresli ve stressiz EDA sinyallerine birer örnek gösterilmiştir. Bu şekle göre, stresli sinyalin önemli fazık aktivite ve düşük tonik faza sahipken, stressiz sinyalin düşük fazık aktivite ve yüksek tonik faz özelliklerine sahip olduğunu söyleyebiliriz.




Şekil 4.4.2: Stresli ve stressiz duygu durumlarına ait EDA sinyalleri

Cilt sıcaklığı, 4 Hz sabit örnekleme oranına sahiptir. Bu veriler, santigrat ($^{\circ}\text{C}$) cinsinden gösterilir. Şekil 4.4.3'de stresli ve stressiz durumlardaki cilt sıcaklığı sinyallerine birer örnek gösterilmiştir. Bu şekle göre, stresli durumlar karşısında, stressiz durumlara oranla daha değişken cilt sıcaklığı verileri gözlemlendi. Bu bağlamda gözlenen veriler, stresin insan fizyolojisinde cilt sıcaklığını arttırdığı yönündedir.




Şekil 4.4.3: Stresli ve stressiz duygu durumlarına ait cilt sıcaklığı sinyalleri

BVP sinyali, 64 Hz sabit örnekleme oranına sahiptir. PPG sensöründen elde edilen kan basıncı değişimleri Şekil 4.4.4'de gösterilmektedir. Bu şekle göre, kan basıncı verileri, stresli durumlarda stressiz durumlara oranla daha yüksek frekanslı ve daha yüksek genlikte olduğu gözlemlenmiştir.




Şekil 4.4.4: Stresli ve stressiz duygu durumlarına ait BVP sinyalleri

ACC sinyali, 64 Hz sabit örnekleme oranına sahiptir. Bu sinyal, üç uzaysal boyutun her birine uygulanan sürekli yerçekimi kuvvetini ölçen 3 eksenli bir veri türüdür. Stressiz olarak tanımlanan bir durumdaki örnek bir ivmeölçer sinyali, Şekil 4.4.5’deki gibi gösterilmiştir. Stresli olarak tanımlanan bir durumdaki örnek bir ivmeölçer sinyali, Şekil 4.4.6’daki gibi gösterilmiştir.



Şekil 4.4.5: Stressiz bir durumdaki ACC sinyali



Şekil 4.4.6: Stresli bir durumdaki ACC sinyali


Son olarak, çalışmada kullanılan tüm veriler, füzyon veri tabanı [128] olarak bu alanda yapılan çalışmalara katkıda bulunmak amacıyla herkese açık bir platformdan paylaşılmıştır.

Çalışma kapsamında toplanan tüm fizyolojik sinyaller, 15 saniye, 30 saniye ve 60 saniyelik sinyaller olacak şekilde zaman pencerelerine ayrıldı. Bu zaman pencereleri bağlamında dört yapay sinir ağı modelinin stres tespiti başarımları ve kayıp değerleri Tablo 3 de kıyaslanmıştır. En iyi performans, en yüksek başarı ve en düşük kayıp oranları ile elde edilir.

Tablo 3: Yapay sinir ağı modellerinin performansları

Zaman pencereleri	15 saniyelik zaman pencereleri		30 saniyelik zaman pencereleri		60 saniyelik zaman pencereleri	
Modeller	Başarım	Kayıp	Başarım	Kayıp	Başarım	Kayıp
Sıralı DNN	%88	0.27	%92	0.19	%91	0.20
Sırasız DNN	%91	0.23	%94	0.15	%93	0.18
Sıralı LSTM	%73	0.49	%84	0.35	%87	0.28
Sırasız Çift Yönlü LSTM	%84	0.36	%88	0.28	%86	0.32
Sıralı GRU	%86	0.33	%91	0.21	%92	0.18

Tablo 3 de, çeşitli veri pencereleri bağlamında oluşturulan modeller kıyaslanmıştır. Bu tabloya göre, tüm veri pencereleri için optimum sonuçlar, Sırasız (non sequential) DNN modeli ile elde edilmiştir. Bu model, paralel çalışma prensibi sayesinde diğer modellere göre daha iyi tahminler yapmıştır. Optimum modelin zaman pencereleri bağlamında incelenmesi sonucunda, 15 saniyelik veya 60 saniyelik veri pencerelerinin yerine 30 saniyelik zaman pencerelerinin optimum süre olduğu tespit edilmiştir. En başarılı tahmin sonuçlarını elde eden sırasız DNN modelinin 30 saniyelik zaman pencereleri bağlamında, başarı ve kayıp grafikleri Şekil 4.4.7 de verildi.



Şekil 4.4.7: Optimum modelin en başarılı zaman penceresi bağlamında başarı ve kayıp grafikleri

Tablo 4: Fizyolojik sinyallerin üçlü kombinasyon performansları

Fizyolojik Sinyaller	Başarım
EDA, BVP, TEMP	%68
BVP, TEMP, İvmeölçer	%63
EDA, TEMP, İvmeölçer	%66
EDA, BVP, İvmeölçer	%67

Fizyolojik sinyallerin çeşitli kombinasyonları üzerinden stres tahmini yapmak için transfer öğrenimi tekniğinden yararlanılmıştır. Optimum model ve optimum zaman penceresi üzerinden çeşitli fizyolojik sinyal kombinasyonları oluşturularak bu teknik uygulanmıştır. Bu bağlamda, fizyolojik sinyallerin üçlü kombinasyon performansları, Tablo 4 de incelenmiştir. Buna göre, en iyi iki başarılı fizyolojik sinyal kombinasyonları incelendiğinde, EDA sinyalinin ortak olduğu tespit edildi. Ayrıca

ivmeölçer sinyali kullanılan fizyolojik sinyal kombinasyonlarında, model başarılarının düşük olduğu görüldü.

Tablo 5: Fizyolojik sinyallerin ikili kombinasyon performansları

Fizyolojik Sinyaller	Başarım
EDA, BVP	%70
BVP, TEMP	%69
EDA, TEMP	%70
TEMP, İvmeölçer	%65
EDA, İvmeölçer	%67
BVP, İvmeölçer	%70

Fizyolojik sinyallerin ikili kombinasyon performansları, Tablo 5 de incelenmiştir. Buna göre, yüksek başarılarla ulaşan fizyolojik sinyal kombinasyonları incelendiğinde, EDA sinyali göze çarpmaktadır.

5. TARTIŞMA

Geçmişte yapılan deneyim örnekleme metoduna dayanan fizyolojik sinyallerin tahmin edilmesi ile ilgili çalışmalar incelenmiştir. Anket verilerini toplamak için kâğıt-kalem, görüşme, cep telefonu gibi yöntemlerin kullanıldığı, fizyolojik sinyallerin toplanması için dijital saat, fMR cihazı, holter cihazı gibi cihazların kullanıldığı görüldü. Toplanan veri türler ise elektrodermal aktivite, kan basıncı değişimi, cilt sıcaklığı, ivmeölçer, likert veya açık uçlu soru yanıtları elde edilmiştir. Yapılan çalışmalarda, zaman tabanlı, hibrit ve rastgele olmak üzere çeşitli uygulama metotları kullanılmıştır. Bu parametrelere göre, yanıltıcı olabileceği düşünülen noktalara dikkat edilerek en güvenli çalışma modeli tasarlandı.

Geçmiş çalışmalarda kâğıt-kalem ile toplanan verilerin katılımcılar tarafından zamanında doldurulmaması, yanıltıcı verilere neden olduğu gözlemlenmiştir. Bu nedenle, veri toplama aşamasında, veri güvenliği ve kolay uygulanabilirliği açısından cep telefonları kullanıldı.

Çalışmanın zaman tabanlı uygulama biçimi, katılımcıların öngörebilecek zamanlarda toplanması, günlük olağan akışını etkileyeceği düşünülmektedir. Bu nedenle çalışma kapsamında toplanan veriler, hibrit bir yapıda olacak şekilde toplanmıştır.

Özetle çalışmanın yöntemi, elektrodermal aktivite, kan basıncı değişimi, cilt sıcaklığı ve ivmeölçer verilerinin toplanması için dijital cihaz kullanılırken görüntü, ses ve anket verilerinin toplanması için ise cep telefonu kullanılmıştır. Çalışmanın uygulama şekli, yarı zaman tabanlı yarı rastgele olarak hibrit tabanlı gerçekleştirilmiştir. Fizyolojik sinyaller zaman tabanlı, görüntü ve ses kaydı verileri ise rastgele olarak toplanmıştır. Bu çalışmada, çoklu sensör verilerinden faydalanılarak, çeşitli veri tiplerinin toplanması ile füzyon veri tabanı oluşturulmuştur.

6. SONUÇ

Bireyin fizyolojik ve psikolojik düzenini bozan her şey bir stres faktörü olabilir. Stres faktörleri, genellikle bireyler üzerinde olumsuz davranışlar ile etkisini göstermektedir. Stresin bireyler üzerinde yarattığı baskı, kontrolsüz davranışlara neden olabilmektedir. Bu bağlamda stres, bireyin sosyal ilişkilerini de etkileyebilir. Stres işyerinde, iletişim eksiklikleri nedeni ile iş aksaklıklarına neden olmaktadır. Örgütsel stres, kurumsal verimliliğin azalması, üretimin düşmesi, çalışan ve yöneticilerin iş tatminsizliği yaşamasına neden olan bir etkidir. Aynı zamanda örgütsel stresin en fazla meydana geldiği yerlerden bir diğeri ise trafiktir. Trafikte meydana gelen stres, sinirlilik hali gibi olumsuz duyguları tetikleyerek saldırgan davranışlara neden olabilir. Stres faktörlerinin, birey üzerinde baskı oluşturmaya devam etmesi, bireyin fizyolojisini de etkileyerek çeşitli rahatsızlıklara yol açabilir. Bu rahatsızlıklardan bazıları strese bağlı yeme bozukluğu ve obezite hastalığıdır.

Bu çalışmanın amacı, deneyim örnekleme metodu ile toplanan verilerden duygu analizi yapmaktır. Eşzamanlı toplanan görüntü ve ses sinyalleri ile oluşturulan füzyon sonucunda, en yüksek doğrulukla duygu tahminleri sırasıyla %83 ve %74 olarak tespit edilmiştir. Katılımcıların, strese karşı verdikleri tepkileri araştırmak için sempatik sinir sistemini etkileyen birtakım fizyolojik sinyaller incelendi. Katılımcıların fizyolojik verileri, stresli ve stressiz olmak üzere iki kategoride ayrılmıştır. Elektrodermal aktivite sinyalleri araştırılırken, stresli bir ruh halinde önemli fazık aktivite ve düşük tonik faz, stressiz bir ruh halinde iken düşük fazık aktivite ve yüksek tonik faz özelliklerine sahip sinyaller gözlemlenmiştir. Cilt sıcaklığı sinyalleri incelendiğinde, stresli bir ortam çerçevesinde stressiz bir ortama oranla daha değişken cilt sıcaklığı sinyalleri ile karşılaşıldı. Kan basıncı sinyalleri açısından, stresli durumların stressiz durumlara oranla daha yüksek frekanslı ve daha yüksek genlikte sinyaller olduğu gözlemlenmiştir.

Fizyolojik sinyaller, 15 saniye, 30 saniye ve 60 saniye olmak üzere çeşitli zaman pencerelerine bölünmüştür. Tüm zaman pencerelerine bölünen veriler için dört farklı yapay sinir ağı modeli ile stres tespit çalışması yapıldı. Optimum performansa sahip model, sırasız (non sequential) DNN modeli, 60 saniyelik fizyolojik sinyal zaman pencerelerine göre en iyi stres analizini gerçekleştirmiştir. Optimum model başarısı ve kayıp değeri sırasıyla %94 ve 0.15 olarak tespit edilmiştir. Optimum modele göre, 30 saniyelik verilerin, 15 saniyelik ve 60 saniyelik verilere oranla başarı-kayıp sonuçlarının daha başarılı olduğu tespit edilmiştir. İkili ve üçlü fizyolojik sinyal kombinasyonları, 60 saniyelik zaman pencereleri baz alınarak, görselleştirilerek ResNet transfer öğreniminin ardından optimum model üzerinden stres tahminleri değerlendirilmiştir. Bu bağlamda, üçlü kombinasyonlarda en iyi iki başarılı fizyolojik sinyal kombinasyonları incelendiğinde, EDA sinyalinin ortak olarak yer aldığı tespit edildi. İkili kombinasyonlarda ise en yüksek başarıya ulaşan fizyolojik sinyal kombinasyonlarının, EDA ve BVP sinyalleri olduğu göze çarpmaktadır. Bu kombinasyonlara göre, fizyolojik sinyallerden stres tespiti için EDA ve BVP sinyallerinin birlikte kullanımı modellemeye pozitif etkisi olmuştur.

7. SINIRLAMALAR VE GELECEK ÇALIŞMA

Mevcut çalışmanın bazı sınırlamaları bulunmaktadır. Bu sınırlamalardan birincisi, katılımcıların belli bir süre bu çalışma içinde yer almaları ve birtakım görevleri yerine getirmeleri gerektiğinden, katılımcı bulma zorluğu yaşanmıştır. Bu nedenle, çalışmaya katılmak istemeyen katılımcıları ikna etmek için çeşitli teşvik edici yöntemlere başvurulabilir. İkinci bir sınırlama ise, veri güvenliği nedeni ile biyometrik verilerin paylaşımı yapılmamıştır. Bu nedenle görüntü ve ses verilerinde yaşanan veri eksikliği, açık kaynaklı veri setleri ile desteklenmiştir. Ancak görüntü ve ses verilerinden gerçekleştirilen duygu tahminleri, deneyim örnekleme metodunu yeterince yansıtmamaktadır. Son sınırlama, Covid-19 salgını nedeni ile hastalık durumuna bağlı olarak katılımcıların çalışmaya katılma planları iptali edildi. Bu nedenle Covid-19 salgını sonrası elverişli şartlar sağlandığı bir dönemde daha çok sayıda katılımcı ile bu çalışma tekrarlanabilir.

8. TEŞEKKÜR

Bu çalışma İstanbul Kültür Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi Tarafından Desteklenmiştir. Proje numarası: İKÜ-BAP2012.

Bu çalışmada katılımcılardan veri toplamak için gerekli etik onay izni İstanbul Kültür Üniversitesi Etik Kurulu'ndan 20.05.2020 tarihli ve 2020.29 numaralı kararı ile alınmıştır.

Veri seti talep edilmesi durumunda araştırma amaçlı olarak paylaşılacaktır.

9. KAYNAKLAR

- ¹ Ö. Yasemin and A. B. KARABULUT, “Günlük yaşam ve stres yönetimi,” *Türkiye Sağlık Bilimleri ve Araştırmaları Dergisi*, vol. 1, no. 1, pp. 48–56, 2018.
- ² N. Jacobs, I. Myin-Germeys, C. Derom, P. Delespaul, J. Van Os, and N. Nicolson, “A momentary assessment study of the relationship between affective and adrenocortical stress responses in daily life,” *Biological psychology*, vol. 74, no. 1, pp. 60–66, 2007.
- ³ Özkaya, M. O. ve Yakın, V. ve Ekinçi, T. (2014). Stres düzeylerinin çalışanların iş doyumu üzerine etkisi, Celal Bayar Üniversitesi çalışanları üzerine ampirik bir araştırma. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(1), 163-179.
- ⁴ Palaz, A. (2015). Çalışma Hayatında Stres Ve Stresle Mücadele: Antalya Atatürk Devlet Hastanesi Hemşireleri Örneği (Yüksek Lisans Tezi, Beykent Üniversitesi Sosyal Bilimler Enstitüsü).
- ⁵ T. W. Colligan and E. M. Higgins, “Work place stress: Etiology and consequences,” *Journal of work place behavioral health*, vol. 21, no. 2, pp. 89–97, 2006.
- ⁶ J. D. Creswell and E. K. Lindsay, “How does mind fullness training affect health mind fullness stress buffering account,” *Current Directions in Psychological Science*, vol. 23, no. 6, pp. 401–407, 2014.
- ⁷ M. Virgili, “Mind fullness based interventions reduce psychological distress in working adults: a meta-analysis of intervention studies,” *Mind fullness*, vol. 6, no. 2, pp. 326–337, 2015.
- ⁸ N. Weinstein, K. W. Brown, and R. M. Ryan, “A multi-method examination of the effects of mindfulness on stress attribution, coping, and emotional well-being,” *Journal of research in personality*, vol. 43, no. 3, pp. 374–385, 2009.

⁹ E. J. Vella, T. W. Kamarck, and S. Shiffman, “Hostility moderates the effects of social support and intimacy on blood pressure in daily social interactions,” *Health Psychology*, vol. 27, no. 2S, p. S155, 2008.

¹⁰ R. D. J.-M. A. M. A. F. Serre, M. Fatseasand J. Swendsen, “Ecological momentary assessment in alcohol, tobacco, cannabis and opiate dependence: A comparison of feasibility and validity,” *Drug and Alcohol Dependence*, vol. 126, no. 1, p. 118–123, 2012.

¹¹ S. Shiffman, “Ecological momentary assessment (ema) in studies of substance use,” *Psychological assessment*, vol. 21, no. 4, p. 486, 2009.

¹² D. E. J. H. Minami, D. E. McCarthy and T. B. Baker, “An ecological momentary assessment analysis of relations among coping, affect and smoking during a quit attempt,” *Addiction*, vol. 106, no. 3, pp. 641–650, 2011.

¹³ Stone and J. E. Broderick, “Real-time data collection for pain: Appraisal and current status,” *Pain Medicine*, vol. 8, no. 3, pp. 85–95, 2007.

¹⁴ D. Abraham, E. J. Leung, B. A. Wong, Z. M. Rivera, L. C. Kruse, J. J. Clark, and B. B. Land, “Orally Consumed Cannabinoids Provide Long-lasting relief of allodynia in a mouse model of chronic neuropathic pain,” *Neuro psychopharmacology*, vol. 45, no. 7, pp. 1105–1114, 2020.

¹⁵ G. Glaros and M. A. Lumley, “Alexithymia and pain in temporomandibular disorder,” *Journal of Psychosomatic Research*, vol. 59, no. 2, pp. 85–88, 2005.

¹⁶ C. Conway, M. K. Forbes, K. T. Forbush, E. I. Fried, M. N. Hallquist, R. Kotov, S. N. Mullins-Sweatt, A. J. Shackman, A. E. Skodol, S. C. South, et al., “A hierarchical taxonomy of psychopathology can transform mental health research,” *Perspectives on psychological science*, vol. 14, no. 3, pp. 419–436, 2019.

¹⁷ M. Ramdin, A. R. Morrison, M. de Groen, R. van Haperen, R. De Kler, L. J. van den Broeke, J. M. Trusler, W. de Jong, and T. J. Vlugt, “High pressure electrochemical reduction of CO₂ to formic acid/formate: a comparison between bipolar membranes and cation exchange membranes,” *Industrial & engineering chemistry research*, vol. 58, no. 5, pp. 1834–1847, 2019.

¹⁸ S. Peters, A. Wilkinson, and H. Mulligan, “Views of healthcare professionalson training for and delivery of a fatigue self-management program for persons with multiple sclerosis,” *Disability and rehabilitation*, vol. 41, no. 23, pp. 2792–2798,2019.

¹⁹ R. Evans, I. A. Boggero, and S. C. Segerstrom, “Thenature of self-regulatory fatigue and “ego depletion” lessons from physical fatigue,”*Personality and Social Psychology Review*, vol. 20, no. 4, pp. 291–310, 2016.

²⁰ G. W. Alpers, “Ambulatory assessment in panic disorder and specific hobia,”*Psychological assessment*, vol. 21, no. 4, p. 476, 2009.

²¹ K. H. M. aanhet Rot and R. A. Schoevers, “Mood disorders in everyday life: Asystematic review of experience sampling and ecological momentary assessment studies,”*Clinical psychology review*, vol. 32, no. 6, pp. 510–523, 2012

²² P. F. A. J. S. Schillerand Z. C. Nelson, “Summary health statistics fortheus population: National health interview survey, 2003,”*Vital and health statistics*,vol. 10, no. 224, pp. 1–104, 2005

²³ D. Brys, E. DiStasio, B. Lenaert, M. Sanguinetti, A. Picca, R. Calvani, E. Mar-zetti, G. Gambaro, and M. Bossola, “Serum interleukin-6 and end otoxin levels and their relationship with fatigue and depressive symptoms in patients on chronic haemodialysis,” *Cytokine*, vol. 125, p. 154823, 2020.

²⁴ N. Homaira, L. K. Wiles, C. Gardner, C. J. Molloy, G. Arnolda, H. P. Ting, P. Hib-bert, C. Boyling, J. Braithwaite, A. Jaffe,et al., “Assessing appropriateness of paediatric asthma management: A population-based sample survey,” *Respirology*,vol. 25, no. 1, pp. 71–79, 2020.

²⁵ Bishay, A. (1996). Teacher motivation and job satisfaction: A study employing the experience sampling method. *Journal of undergraduate Sciences*, 3(3), 147-155.

²⁶ Csikszentmihalyi, M., & Larson, R. (2014). Validity and reliability of the experience-sampling method. In *Flow and the foundations of positive psychology* (pp. 35-54). Springer, Dordrecht.

- ²⁷ Kimhy, D., Delespaul, P., Corcoran, C., Ahn, H., Yale, S., & Malaspina, D. (2006). Computerized experience sampling method (ESMc): assessing feasibility and validity among individuals with schizophrenia. *Journal of psychiatric research*, 40(3), 221-230.
- ²⁸ Consolvo, S., & Walker, M. (2003). Using the experience sampling method to evaluate ubicomp applications. *IEEE pervasive computing*, 2(2), 24-31.
- ²⁹ Palmier-Claus, J. E., Myin-Germeys, I., Barkus, E., Bentley, L., Udachina, A., Delespaul, P. A. E. G., ... & Dunn, G. (2011). Experience sampling research in individuals with mental illness: reflections and guidance. *Acta Psychiatrica Scandinavica*, 123(1), 12-20.
- ³⁰ Burgin, C. J., Silvia, P. J., Eddington, K. M., & Kwapil, T. R. (2013). Palm or cell? Comparing personal digital assistants and cell phones for experience sampling research. *Social Science Computer Review*, 31(2), 244-251.
- ³¹ Consolvo, S., & Walker, M. (2003). Using the experience sampling method to evaluate ubicomp applications. *IEEE pervasive computing*, 2(2), 24-31.
- ³² Madjar, A. (2020). Pedagogy here on the ground: Using lived experience to research and understand our lives with children. *ACCESS: Contemporary Issues in Education*, 40(1), 72-83.
- ³³ Berkman, E. T., Giuliani, N. R., & Pruitt, A. K. (2014). Comparison of text messaging and paper-and-pencil for ecological momentary assessment of food craving and intake. *Appetite*, 81, 131-137.
- ³⁴ Myin-Germeys, I., Kasanova, Z., Vaessen, T., Vachon, H., Kirtley, O., Viechtbauer, W., & Reininghaus, U. (2018). Experience sampling methodology in mental health research: new insights and technical developments. *World Psychiatry*, 17(2), 123-132.
- ³⁵ Xie, K., Heddy, B. C., & Greene, B. A. (2019). Affordances of using mobile technology to support experience-sampling method in examining college students' engagement. *Computers & Education*, 128, 183-198.

- ³⁶ Watson, D., & Pennebaker, J. W. (1989). Health complaints, stress, and distress: exploring the central role of negative affectivity. *Psychological review*, 96(2), 234.
- ³⁷ R. Ilies, N. Dimotakis, and D. Watson, "Mood, blood pressure, and heart rate at work: An experience-sampling study.," *Journal of Occupational Health Psychology*, vol. 15, no. 2, p. 120, 2010.
- ³⁸ Colligan, T. W., & Higgins, E. M. (2006). Workplace stress: Etiology and consequences. *Journal of workplace behavioral health*, 21(2), 89-97.
- ³⁹ Creswell, J. D., & Lindsay, E. K. (2014). How does mindfulness training affect health? A mindfulness stress buffering account. *Current Directions in Psychological Science*, 23(6), 401-407.
- ⁴⁰ Virgili, M. (2015). Mindfulness-based interventions reduce psychological distress in working adults: a meta-analysis of intervention studies. *Mindfulness*, 6(2), 326-337.
- ⁴¹ Rothkrantz, L. J., Wiggers, P., Van Wees, J. W. A., & van Vark, R. J. (2004, September). Voice stress analysis. In *International conference on text, speech and dialogue* (pp. 449-456). Springer, Berlin, Heidelberg.
- ⁴² Lee, C. M., & Narayanan, S. S. (2005). Toward detecting emotions in spoken dialogs. *IEEE transactions on speech and audio processing*, 13(2), 293-303.
- ⁴³ Alu, D. A. S. C., Zoltan, E., & Stoica, I. C. (2017). Voice based emotion recognition with convolutional neural networks for companion robots. *Science and Technology*, 20(3), 222-240.
- ⁴⁴ Lee, J., Noh, B., Jang, S., Park, D., Chung, Y., & Chang, H. H. (2015). Stress detection and classification of laying hens by sound analysis. *Asian-Australasian journal of animal sciences*, 28(4), 592.
- ⁴⁵ Umapathy, K., Krishnan, S., & Rao, R. K. (2007). Audio signal feature extraction and classification using local discriminant bases. *IEEE Transactions on Audio, Speech, and Language Processing*, 15(4), 1236-1246.

- ⁴⁶ Purwins, H., Li, B., Virtanen, T., Schlüter, J., Chang, S. Y., & Sainath, T. (2019). Deep learning for audio signal processing. *IEEE Journal of Selected Topics in Signal Processing*, 13(2), 206-219.
- ⁴⁷ Han, H., Byun, K., & Kang, H. G. (2018, October). A deep learning-based stress detection algorithm with speech signal. In *proceedings of the 2018 workshop on audio-visual scene understanding for immersive multimedia* (pp. 11-15).
- ⁴⁸ Lee, C. M., & Narayanan, S. S. (2005). Toward detecting emotions in spoken dialogs. *IEEE transactions on speech and audio processing*, 13(2), 293-303.
- ⁴⁹ Akçay, M. B., & Oğuz, K. (2020). Speech emotion recognition: Emotional models, databases, features, preprocessing methods, supporting modalities, and classifiers. *Speech Communication*, 116, 56-76.
- ⁵⁰ Karan, B., Sahu, S. S., Orozco-Arroyave, J. R., & Mahto, K. (2021). Non-negative matrix factorization-based time-frequency feature extraction of voice signal for Parkinson's disease prediction. *Computer Speech & Language*, 69, 101216.
- ⁵¹ Ranganathan, H., Chakraborty, S., & Panchanathan, S. (2016, March). Multimodal emotion recognition using deep learning architectures. In *2016 IEEE Winter Conference on Applications of Computer Vision (WACV)* (pp. 1-9). IEEE.
- ⁵² Zhang, B., Quan, C., & Ren, F. (2016, June). Study on CNN in the recognition of emotion in audio and images. In *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)* (pp. 1-5). IEEE.
- ⁵³ Chinmayi, R., Sreeja, N., Nair, A. S., Jayakumar, M. K., Gowri, R., & Jaiswal, A. (2020, August). Emotion Classification Using Deep Learning. In *2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)* (pp. 1063-1068). IEEE.
- ⁵⁴ Nguyen, B. T., Trinh, M. H., Phan, T. V., & Nguyen, H. D. (2017, April). An efficient real-time emotion detection using camera and facial landmarks. In *2017 seventh international conference on information science and technology (ICIST)*(pp. 251-255). IEEE.

- ⁵⁵ Giannakakis, G., Pediaditis, M., Manousos, D., Kazantzaki, E., Chiarugi, F., Simos, P. G., ... & Tsiknakis, M. (2017). Stress and anxiety detection using facial cues from videos. *Biomedical Signal Processing and Control*, 31, 89-101.
- ⁵⁶ Bond, M. (2020). Schools and emergency remote education during the COVID-19 pandemic: A living rapid systematic review. *Asian Journal of Distance Education*, 15(2), 191-247.
- ⁵⁷ Giannakakis, G., Pediaditis, M., Manousos, D., Kazantzaki, E., Chiarugi, F., Simos, P. G., ... & Tsiknakis, M. (2017). Stress and anxiety detection using facial cues from videos. *Biomedical Signal Processing and Control*, 31, 89-101.
- ⁵⁸ Ooi, K. E. B., Low, L. S. A., Lech, M., & Allen, N. (2011, April). Prediction of clinical depression in adolescents using facial image analysis. In *WIAMIS 2011: 12th International Workshop on Image Analysis for Multimedia Interactive Services, Delft, The Netherlands, April 13-15, 2011*. TU Delft; EWI; MM; PRB.
- ⁵⁹ Bejnordi, B. E., Veta, M., Van Diest, P. J., Van Ginneken, B., Karssemeijer, N., Litjens, G., ... & CAMELYON16 Consortium. (2017). Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *Jama*, 318(22), 2199-2210.
- ⁶⁰ Wardlaw, J. M., Smith, E. E., Biessels, G. J., Cordonnier, C., Fazekas, F., Frayne, R., ... & Dichgans, M. (2013). Neuroimaging standards for research into small vessel disease and its contribution to ageing and neurodegeneration. *The Lancet Neurology*, 12(8), 822-838.
- ⁶¹ Jack Jr, C. R., Bernstein, M. A., Fox, N. C., Thompson, P., Alexander, G., Harvey, D., ... & Weiner, M. W. (2008). The Alzheimer's disease neuroimaging initiative (ADNI): MRI methods. *Journal of Magnetic Resonance Imaging: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 27(4), 685-691.
- ⁶² Procházka, A., Charvátová, H., Vyšata, O., Kopal, J., & Chambers, J. (2017). Breathing analysis using thermal and depth imaging camera video records. *Sensors*, 17(6), 1408.

- ⁶³ Kim, H. G., Cheon, E. J., Bai, D. S., Lee, Y. H., & Koo, B. H. (2018). Stress and heart rate variability: a meta-analysis and review of the literature. *Psychiatry investigation*, 15(3), 235.
- ⁶⁴ de Santos Sierra, A., Ávila, C. S., Casanova, J. G., & del Pozo, G. B. (2011). A stress-detection system based on physiological signals and fuzzy logic. *IEEE Transactions on Industrial Electronics*, 58(10), 4857-4865.
- ⁶⁵ Keshan, N., Parimi, P. V., & Bichindaritz, I. (2015, October). Machine learning for stress detection from ECG signals in automobile drivers. In *2015 IEEE International Conference on Big Data (Big Data)* (pp. 2661-2669). IEEE.
- ⁶⁶ Vanitha, V., & Krishnan, P. (2017). Real time stress detection system based on EEG signals.
- ⁶⁷ Von Borell, E., Langbein, J., Després, G., Hansen, S., Leterrier, C., Marchant-Forde, J., ... & Veissier, I. (2007). Heart rate variability as a measure of autonomic regulation of cardiac activity for assessing stress and welfare in farm animals—A review. *Physiology & behavior*, 92(3), 293-316.
- ⁶⁸ Li, W., Yao, H., Yan, K., Zheng, G., Liang, Z., Chiang, Y. M., & Cui, Y. (2015). The synergetic effect of lithium polysulfide and lithium nitrate to prevent lithium dendrite growth. *Nature communications*, 6(1), 1-8.
- ⁶⁹ Fritsche, L. G., Chen, W., Schu, M., Yaspan, B. L., Yu, Y., Thorleifsson, G., ... & Leveillard, T. (2013). Seven new loci associated with age-related macular degeneration. *Nature genetics*, 45(4), 433-9.
- ⁷⁰ Bakker, J., Pechenizkiy, M., & Sidorova, N. (2011, December). What's your current stress level? Detection of stress patterns from GSR sensor data. In *2011 IEEE 11th international conference on data mining workshops* (pp. 573-580). IEEE.
- ⁷¹ Ghaderi, A., Frounchi, J., & Farnam, A. (2015, November). Machine learning-based signal processing using physiological signals for stress detection. In *2015 22nd Iranian Conference on Biomedical Engineering (ICBME)* (pp. 93-98). IEEE.
- ⁷² Kim, P., & Zhou, X. (2019). FusionGDB: fusion gene annotation DataBase. *Nucleic acids research*, 47(D1), D994-D1004.

- ⁷³ Poh, N., & Bengio, S. (2006). Database, protocols and tools for evaluating score-level fusion algorithms in biometric authentication. *Pattern Recognition*, 39(2), 223-233.
- ⁷⁴ Huang, Y. S., & Suen, C. Y. (1995). A method of combining multiple experts for the recognition of unconstrained handwritten numerals. *IEEE transactions on pattern analysis and machine intelligence*, 17(1), 90-94.
- ⁷⁵ Bolt, R. A. (1980, July). "Put-that-there" Voice and gesture at the graphics interface. In *Proceedings of the 7th annual conference on Computer graphics and interactive techniques*(pp. 262-270).
- ⁷⁶ Demczuk, V. J. (1995). Human-Computer Interaction: An Overview.
- ⁷⁷ Kurniawan, H., A. V. Maslovand M. Pechenizkiy, "Stress detection from speech and Galvanic Skin Responsesignals", Proceedings of the 26th IEEE International Symposium on Computer-Based Medical Systems, pp. 209–214, June 2013.
- ⁷⁸ Camlikaya, E., Kholmatov, A., & Yanikoglu, B. (2008, March). Multi-biometric templates using fingerprint and voice. In *Biometric technology for human identification V* (Vol. 6944, p. 69440I). International Society for Optics and Photonics.
- ⁷⁹ Timothy J. Legg, Ph.D., "The Effects of Stress on Your Body", <https://www.healthline.com/health/stress/effects-on-body#1>, 2020
- ⁸⁰ Bigert, C., Bluhm, G., & Theorell, T. (2005). Saliva cortisol—a new approach in noise research to study stress effects. *International journal of hygiene and environmental health*, 208(3), 227-230.
- ⁸¹ Jiao, W., Wang, Q., Cheng, Y., & Zhang, Y. (2021). End-to-end prediction of weld penetration: a deep learning and transfer learning based method. *Journal of Manufacturing Processes*, 63, 191-197.
- ⁸² Kaklauskas, A., E. Zavadskas, M. Seniut, G. Dzemyda, V. Stankevic, C. Simkevičius, T. Stankevic, R. Paliskiene, A. Matuliauskaite, S. Kildiene, L. Bartkiene, S. Ivanikovasand V. Gribniak, "Web-based Biometric Computer Mouse Advisory System to Analyze a User's Emotions and Work Productivity", *Engineering Applications of ArtificialIntelligence*, Vol. 24, No. 6, pp. 928 – 945, 2011. 39. Zimmermann

- ⁸³ Greene, S., H. Thapliyal and A. Caban-Holt, "A Survey of Affective Computing for Stress Detection: Evaluating technologies in stress detection for better health", IEEE Consumer Electronics Magazine, Vol. 5, No. 4, pp. 44–56, Oct 2016.
- ⁸⁴ Poh, M.Z., Swenson, N.C. and Picard, R.W., 2009, June. Comfortable sensor wristband for ambulatory assessment of electrodermal activity. In 1st Biennial Conference of the Society for Ambulatory Assessment, Greifswald, Germany.
- ⁸⁵ Benedek, M., & Kaernbach, C. (2010). A continuous measure of phasic electrodermal activity. *Journal of Neuroscience Methods*, 190(1), 80-91. doi:10.1016/j.jneumeth.2010.04.028
- ⁸⁶ Lykken, D.T. and Venables, P.H., 1971. Direct measurement of skin conductance: A proposal for standardization. *Psychophysiology*, 8(5), pp.656-672.
- ⁸⁷ Süer, C. (1990). Elektrodermal aktiviteye Cinsiyet, Isı, Kayıt Bölgesi ve Sigaranın Etkileri. Yayınlanmış Tez: Erciyes Üniversitesi, Tıp Fakültesi, Kayseri.
- ⁸⁸ ESEN, F., 2000. Elektrodermal aktivite. *Türkiye Klinikleri Tıp Bilimleri Dergisi*, 20(1), pp.27-34.
- ⁸⁹ Shimazaki, T. and Hara, S., 2015. Design of PPG-based heart rate sensor enabling motion artifact cancellation. *Heart*, 100(60), p.20.
- ⁹⁰ Alberdi, A., A. Aztiria and A. Basarab, "Towards an automatic early stress recognition system for ocean environments based on multi modal measurements: A review", *Journal of Biomedical Informatics*, Vol. 59, pp. 49 – 75, 2016.
- ⁹¹ Govinda, K. (2018). Body fitness monitoring using iot device. In *Contemporary Applications of Mobile Computing in Healthcare Settings* (pp. 154-169). IGI Global.
- ⁹² Wang, H. G., & Williams, T. C. (2008). Strategic inertial navigation systems-high-accuracy inertially stabilized platforms for hostile environments. *IEEE Control Systems Magazine*, 28(1), 65-85.
- ⁹³ Scherer, K. R., Vocal Affect Expression - a Review and a Model for Future Research, *Psychological Bulletin*, 99, 3 (1986) 143-165. 54.

- ⁹⁴ Davitz, J. R., The Communication of Emotional Meaning, McGraw-Hill, (1964).
- ⁹⁵ Parlak, C. and Diri, B., 2013, April. Emotion recognition from the human voice. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- ⁹⁶ Venkataramanan, K., & Rajamohan, H. R. (2019). Emotion recognition from speech. *arXiv preprint arXiv:1912.10458*.
- ⁹⁷ Başaran, S., 2007. Yapay Sinir Ağları Kullanarak Konuşmacı Tanıma. Uludağ Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- ⁹⁸ Jain, N., Kumar, S., Kumar, A., Shamsolmoali, P., & Zareapoor, M. (2018). Hybrid deep neural networks for face emotion recognition. *Pattern Recognition Letters*, 115, 101-106.
- ⁹⁹ Erdem, E.S., 2014. Ses sinyallerinde duygu tanıma ve geri erişimi (Master'sthesis, Başkent Üniversitesi Fen Bilimleri Enstitüsü).
- ¹⁰⁰ Bayrakdar, S., Akgün, D. and Yücedağ, İ., 2016. Yüz ifadelerinin otomatik analizi üzerine bir literatür çalışması. *Sakarya University Journal of Science*, 20(2), pp.383-398.
- ¹⁰¹ D. Ibtesham, “A survey on facial expression recognition”, New Mexico, 2012.
- ¹⁰² M. Murtaza, M. Sharif, M. Raza ve J. H. Shah, “Analysis of face recognition under varying facial expression: a survey”, The International ArabJournal of Information Technology, cilt 10, no. 4, pp. 378-388, 2013.
- ¹⁰³ M.-H. Yang, D. J. Kriegman ve N. Ahuja, “Detecting faces in images: A survey”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, cilt 24, no. 1, pp. 34-58, 2002.
- ¹⁰⁴ N. U. Khan, “A comparative analysis of facial expression recognition techniques”, 3rd IEEE International Advance Computing Conference (IACC), Ghaziabad, 2013.

¹⁰⁵ Y. L. Tian, T. Kanade ve J. f. Cohn, “*Facial expression analysis*”, Handbook of Face Recognition, New York, Springer Science+Business Media, Inc., 2005, pp. 247-275.

¹⁰⁶ G. Özmen, “*KübilBezier Eğrileri ile yüz ifadesi tanıma*”, Edirne, Trakya Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2012.

¹⁰⁷ C. K. Hsieh, Shang-Hong and Y. C. Chen, “*An opticalflow-based approach to robust face recognition under expression variations*”, IEEE Transactions on Image Processing, cilt 19, no. 1, pp. 233-240, 2010.

¹⁰⁸ R. A. Patil, V.Sahula ve A. S. Mandal, “*Facial expression recognition images equences using active shape model and SVM*”, IEEE Fifth UK Sim European Symposium on Computer Modeling and Simulation (EMS), Madrid, 2011.

¹⁰⁹ N. Rose, “*Facial expression classification using gabor and log-gabor filters*”, IEEE 7th International Conference on Automatic Face and Gesture Recognition (FGR’06), Southampton, 2006.

¹¹⁰ R. Hablani, N. Chaudhari ve S. Tanwani, “*Recognition of facial expressions using local binary patterns of important facial parts*”, International Journal of Image Processing (IJIP), cilt 7, no. 2, pp. 163-170, 2013.

¹¹¹ K. H. M. aanhet Rot and R. A. Schoevers, “Mood disorders in everyday life: Asystematic review of experience sampling and ecological momentary assessment studies,”Clinical psychology review, vol. 32, no. 6, pp. 510–523, 2012

¹¹² Zhao, W., & Du, S. (2016). Spectral–spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4544-4554.

¹¹³ Appel, T., Fierro, R., Rohrer, B., Lumia, R. and Wood, J., 2013. “*A Learning Strategy for Source Tracking in Unstructured Environments*”. LEARNING AND APPROXIMATE DYNAMIC PROGRAMMING FOR FEEDBACK CONTROL, p.582

¹¹⁴ Fu, R., Zhang, Z., & Li, L. (2016, November). “*Using LSTM and GRU neural network methods for traffic flow prediction*”. In 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC) (pp. 324-328). IEEE.

¹¹⁵ Jiao, W., Wang, Q., Cheng, Y., & Zhang, Y. (2021). End-to-end prediction of weld penetration: a deep learning and transfer learning based method. *Journal of Manufacturing Processes*, 63, 191-197.

¹¹⁶ Session, I. Saturday October 10, 2009 Sweet Briar College.

¹¹⁷ Karim, J., Weisz, R. and Rehman, S.U., 2011. “*International positive and negative affect schedule short-form (I-PANAS-SF): Testing for factorial in variance across cultures*” *Procedia-Social and Behavioral Sciences*, 15, pp.2016-2022.

¹¹⁸ “*Out-of-TreePlatforms*”. reactnative.dev. Facebook, Inc. Retrieved 30 July 2020.

¹¹⁹ McCarthy, C., Pradhan, N., Redpath, C., & Adler, A. (2016, May). Validation of the Empatica E4 wristband. In *2016 IEEE EMBS international student conference (ISC)* (pp. 1-4). IEEE.

¹²⁰ Garrido, M. V., Lopes, D., Prada, M., Rodrigues, D., Jerónimo, R., & Mourão, R. P. (2017). The many faces of a face: Comparing stills and videos of facial expressions in eight dimensions (SAVE database). *Behavior research methods*, 49(4), 1343-1360.

¹²¹ Guizzo, E., Weyde, T., & Leveson, J. B. (2020, May). “*Multi-time-scale convolution for emotion recognition from speech audio signals.*” In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 6489-6493). IEEE.

¹²² Livingstone, S. R., & Russo, F. A. (2018). The Ryerson Audio-Visual Database of Emotional Speech and Song (RAVDESS): A dynamic, multimodal set of facial and vocal expressions in North American English. *PloS one*, 13(5), e0196391.

¹²³ Giannopoulos, P., Perikos, I., & Hatzilygeroudis, I. (2018). Deep learning approaches for facial emotion recognition: A case study on FER-2013. In *Advances in hybridization of intelligent methods* (pp. 1-16). Springer, Cham.

¹²⁴ Lucey, P., Cohn, J.F., Kanade, T., Saragih, J., Ambadar, Z. and Matthews, I., 2010, June. “*The extended cohn-kanade dataset (ck+): A complete dataset for action*

unit and emotion-specified expression” In 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition-Workshops (pp. 94-101). IEEE.

¹²⁵ Mukti, I. Z., & Biswas, D. (2019, December). “*Transfer learning based plant diseases detection using ResNet50*”. In *2019 4th International Conference on Electrical Information and Communication Technology (EICT)* (pp. 1-6). IEEE.

¹²⁶ Koch, F. S., Sepa, A., & Ludvigsson, J. (2008). Psychological stress and obesity. *The Journal of pediatrics*, 153(6), 839-844.

10. EKLER

10.1. EK A. Profil Anketi

1. Adı
2. Cinsiyet
3. Doğum Tarihi
4. Kilo
5. Boy
6. Medeni Durum
7. Meslek
8. Çalıştığı Sektör
9. Hastalık
10. Kullanılan ilaç
11. Sigara

10.2. EK B. Anlık Anket

1. Şu anda nasıl hissediyorsunuz?
2. Şu anda ne yapıyorsunuz?
3. Şu anda yanınızda kim var?
4. Şu anda sizi rahatsız eden bir durum var mı?
5. Şu anda başka bir yerde olmak ister miydin?
6. Bugün başka bir iş yapabilecek enerjiyi kendinizde hissediyor musunuz?

10.3. EK C. Genel Stres Testi

1. Birçok farklı işi kısa zamana sığdırmaya çalışıyor musunuz?
2. İş aksaklıkları veya gecikmeler durumunda sabırsızlanıyor musunuz?
3. Eğlenme amaçlı da olsa oynadığınız oyunlarda hep kazanmak zorunda hissediyor musunuz?
4. Trafikte kırmızı ışık yanmak üzereyken arabanızla hemen geçmeye çalışıyor musunuz?
5. Yaptığınız bir işte yardıma ihtiyacınız olsa da sormaktan kaçınıyor musunuz?
6. Sürekli olarak başkalarının hayranlığını kazanmak ve saygı duyulma ihtiyacı hissediyor musunuz?
7. Başkalarının işlerini yapma biçimlerini sıklıkla eleştiriyor musunuz?
8. Sıklıkla saate bakar mısınız?
9. Başarılarınızı ve pozisyonunuzu yükseltme konusunda aşırı hırs yaptığınız oluyor mu?
10. Zamanın size yetmediği düşüncesine kapılıyor musunuz?
11. Bir anda birden çok iş yapma alışkanlığınız var mıdır?
12. Sıklıkla gergin veya sinirli hissediyor musunuz?
13. Hobilerinize ve kendinize vakit ayırmakta zorlanıyor musunuz?
14. Çabuk konuşma veya sohbetleri hızlandırma eğiliminiz var mıdır?
15. Kendinizi geçinilmesi zor biri olarak kabul ediyor musunuz?
16. Arkadaş veya akrabalarınız sizinle geçinmenin zor olduğunu söylerler mi?

17. Birden fazla projede yer alma eğiliminiz var mıdır?
18. Kendinize sıklıkla işinizi bitirme tarihleri koyuyor musunuz?
19. Dinlenmeye ayırdığınız veya boş oturduğunuz vakitlerde kendinizi suçlu hissediyor musunuz?
20. Kendinize çok fazla sorumluluk yüklediğiniz oluyor mu?

10.4. EK D. PANAS Ölçeği

1. Aktiflik
2. Kararlılık
3. Dikkat
4. İlham
5. Uyanık
6. Korku
7. Sinir
8. Mutsuzluk
9. Düşmanlık
10. Utanç