

**T.C.**  
**ISPARTA UYGULAMALI BİLİMLER ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**  
**İLERİ TEKNOLOJİLER ANABİLİM DALI (DİSİPLİNLERARASI)**

**NESNELERİN İNTERNETİ TABANLI GALVANİK DERİ**  
**TEPKİSİ ÖLÇÜMÜ İLE STRES TAHMİNİ**

**Miray TUNCEL**

**Danışman**  
**Dr. Öğr. Üyesi Hakan YÜKSEL**

**II. Danışman**  
**Öğr. Gör. Dr. Halit ÇETİNER**

**ISPARTA – 2025**



© 2025 [Miray TUNCEL]

## ETİK BEYANI

Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kurallarına uygun olarak ve bilimsel ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın hazırladığım bu tez çalışmasında;

Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

28/02/2025

**Miray TUNCEL**

## İÇİNDEKİLER

|                                                                                                             | Sayfa |
|-------------------------------------------------------------------------------------------------------------|-------|
| İÇİNDEKİLER .....                                                                                           | i     |
| ÖZET.....                                                                                                   | iii   |
| ABSTRACT.....                                                                                               | iv    |
| TEŞEKKÜR.....                                                                                               | v     |
| ŞEKİLLER DİZİNİ.....                                                                                        | vi    |
| ÇİZELGELER DİZİNİ .....                                                                                     | vii   |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                                                        | viii  |
| 1. GİRİŞ .....                                                                                              | 1     |
| 1.1. Stres Algılama.....                                                                                    | 2     |
| 1.2. Galvanik Deri Tepkisi ve Ölçümü .....                                                                  | 10    |
| 1.2.1. Galvanik deri tepkisi ve psikoloji araştırmaları .....                                               | 10    |
| 1.2.2. Stres ve galvanik deri tepkisi ilişkisi.....                                                         | 10    |
| 1.2.3. Galvanik deri tepkisi'nin psikolojik araştırmalardaki uygulamaları.....                              | 11    |
| 1.2.4. Galvanik deri tepkisi ve psiko-fizyolojik modeller.....                                              | 12    |
| 1.2.5. Günümüzde galvanik deri tepkisi ve psikolojik terapiler .....                                        | 12    |
| 1.2.6. Galvanik deri tepkisi ve duygusal tepkiler .....                                                     | 12    |
| 1.3. Nesnelerin İnterneti Tabanlı Galvanik Deri Tepkisi Uygulamaları.....                                   | 13    |
| 1.3.1. Nesnelerin interneti tabanlı galvanik deri tepkisi sistemlerinin yapısı ve<br>çalışma prensibi ..... | 13    |
| 1.3.2. Nesnelerin interneti tabanlı galvanik deri tepkisi uygulamalarının kullanım<br>alanları .....        | 14    |
| 1.3.3. Nesnelerin interneti tabanlı galvanik deri tepkisi uygulamalarının geleceği ...                      | 15    |
| 1.4. Eğitim ve İnsan-Bilgisayar Etkileşimlerinde Galvanik Deri Tepkisi .....                                | 16    |
| 1.4.1. Eğitimde galvanik deri tepkisi kullanımı .....                                                       | 16    |
| 1.4.2. İnsan bilgisayar etkileşiminde galvanik deri tepkisi kullanımı.....                                  | 17    |
| 1.4.3. Galvanik deri tepkisi ve duygusal durumların izlenmesi .....                                         | 18    |
| 1.4.4. Eğitimde ve insan bilgisayar etkileşiminde galvanik deri tepkisi kullanımının<br>geleceği .....      | 18    |
| 1.5. Giyilebilir Teknolojiler ve Galvanik Deri Tepkisi.....                                                 | 19    |
| 1.5.1. Giyilebilir teknolojiler ve galvanik deri tepkisi uygulamaları .....                                 | 19    |
| 1.5.2. Eğitimde giyilebilir teknolojiler ve galvanik deri tepkisi .....                                     | 20    |
| 1.5.3. Sağlık alanında giyilebilir teknolojiler ve galvanik deri tepkisi .....                              | 20    |
| 1.5.4. İnsan bilgisayar etkileşiminde giyilebilir teknolojiler ve galvanik deri tepkisi                     | 21    |
| 1.5.5. Gelecek perspektifi.....                                                                             | 21    |
| 1.6. Nesnelerin İnterneti Uygulamaları .....                                                                | 22    |
| 1.6.1. Nesnelerin interneti uygulamaları ve sağlık.....                                                     | 22    |
| 1.6.2. Nesneleri interneti ve eğitim .....                                                                  | 23    |
| 2. KAYNAK ÖZETLERİ .....                                                                                    | 24    |
| 3. MATERYAL VE YÖNTEM .....                                                                                 | 32    |
| 3.1. Verilerin Toplanması .....                                                                             | 34    |
| 3.2. Verilerin Analizi.....                                                                                 | 36    |
| 3.3. Yöntemler.....                                                                                         | 37    |
| 3.3.1. Gradyan arttırma karar ağacı algoritması.....                                                        | 37    |
| 3.3.2. Rastgele orman algoritması.....                                                                      | 38    |
| 3.3.3. Destek vektör makine algoritması.....                                                                | 39    |
| 3.3.4. Yinelemeli sinir ağları.....                                                                         | 40    |
| 3.3.5. Uzun kısa süreli bellek ağları .....                                                                 | 42    |

|                                                     |    |
|-----------------------------------------------------|----|
| 3.3.6. Geçit yinelemeli hücreler .....              | 43 |
| 3.3.7. Dikkat katmanlı önerilen hibrit modeli ..... | 44 |
| 3.3.8. Performans değerlendirme metrikleri .....    | 46 |
| 4. BULGULAR VE TARTIŞMA .....                       | 48 |
| 5. SONUÇ VE ÖNERİLER .....                          | 54 |
| KAYNAKLAR .....                                     | 56 |
| ÖZGEÇMİŞ .....                                      | 66 |



## ÖZET

Yüksek Lisans Tezi

### NESNELERİN İNTERNETİ TABANLI GALVANİK DERİ TEPKİSİ ÖLÇÜMÜ İLE STRES TAHMİNİ

Miray TUNCEL

Isparta Uygulamalı Bilimler Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
İleri Teknolojiler Anabilim Dalı (Disiplinlerarası)

Danışman: Dr. Öğr. Üyesi Hakan Yüksel

II. Danışman: Öğr. Gör. Dr. Halit ÇETİNER

Stresin erken tespiti, zihinsel ve fiziksel sağlığın korunması açısından önemlidir. Giyilebilir cihazlarla fizyolojik veri toplama ve analiz yöntemleri yaygınlaşmaktadır. Stres seviyelerinin tahmini için biyometrik parametreler ve fizyolojik sinyaller değerlendirilerek makine ve derin öğrenme teknikleri kullanılmaktadır. Bu çalışmada, açık bir veri seti üzerinde farklı makine ve derin öğrenme algoritmalarının stres tahminindeki başarısı karşılaştırılmıştır. Kalp atışı, galvanik deri tepkisi, solunum hızı ve sıcaklık gibi fizyolojik sinyaller içeren veri seti, gradyan arttırma karar ağacı, rastgele orman ve destek vektör makinesi gibi makine öğrenmesi algoritmalarıyla analiz edilmiştir. Sonuçlar, radyal tabanlı fonksiyon çekirdeğine sahip destek vektör makinesinin diğer algoritmalara kıyasla daha iyi performans gösterdiğini ortaya koymuştur. Ayrıca, tekrarlayan sinir ağı, uzun kısa süreli bellek, geçit yinelemeli hücreler ve dikkat katmanına sahip hibrit model gibi derin öğrenme algoritmaları test edilmiştir. Performans değerlendirmesi sonucunda, dikkat katmanına sahip önerilen hibrit modelin, stres tahmininde ortalama mutlak hata metriği açısından diğer yöntemlerden daha üstün olduğu görülmüştür. Çalışmanın sonuçları, giyilebilir cihazlarla stres takibinin mümkün olduğunu ve bu teknolojinin bireysel sağlık yönetimi sistemlerine entegre edilebileceğini ortaya koymaktadır.

Gelecekteki çalışmalarda, daha geniş ve özgün veri setleri kullanılarak optimize edilmiş farklı derin öğrenme tekniklerinin uygulanması ve çok modlu biyofizyolojik veri entegrasyonu ile stres tahmin performansının artırılması hedeflenmektedir. Bu sayede mevcut çalışmaların daha ileriye taşınabileceği öngörülmektedir.

**Anahtar Kelimeler:** Stres tahmini, Galvanik deri tepkisi, Makine öğrenimi, Derin öğrenme, Yenilebilir sinir ağları, Giyilebilir teknoloji

2025, 66 sayfa

## **ABSTRACT**

**Master's Thesis**

### **STRESS PREDICTION USING INTERNET OF THINGS-BASED GALVANIC SKIN RESPONSE MEASUREMENT**

**Miray TUNCEL**

**Isparta University of Applied Sciences  
The Institute of Graduate Education  
Department of Advanced Technologies (Interdisciplinary)**

**Supervisor: Asst. Prof. Dr. Hakan YÜKSEL**

**Co-Supervisor: Lecturer Dr. Halit ÇETİNER**

Early detection of stress is important for the protection of mental and physical health. Physiological data collection and analysis methods with wearable devices are becoming widespread. Machine and deep learning techniques are used to estimate stress levels by evaluating biometric parameters and physiological signals. In this study, the success of different machine and deep learning algorithms in stress estimation was compared on an open dataset. The dataset containing physiological signals such as heart rate, galvanic skin response, respiratory rate and temperature was analysed with machine learning algorithms such as gradient descent decision tree, random forest and support vector machine. The results showed that the support vector machine with radial basis function kernel performed better than other algorithms. In addition, deep learning algorithms such as recurrent neural network, long short-term memory, gate recurrent cells and hybrid model with attention layer were tested. As a result of the performance evaluation, it was seen that the proposed hybrid model with attention layer was superior to other methods in terms of mean absolute error metric in stress estimation. The results of the study reveal that stress monitoring is possible with wearable devices and that this technology can be integrated into individual health management systems.

In future studies, it is aimed to apply different deep learning techniques optimized using larger and more original data sets and to increase stress prediction performance by integrating multi-modal biophysiological data. In this way, it is anticipated that current studies can be carried further.

**Keywords:** Stress prediction, Galvanic skin response, Machine learning, Deep learning, Recurrent neural network, Wearable technology

**2025, 66 pages**

## TEŞEKKÜR

Tezimin oluřum sürecinde bana rehberlik eden, karřılařtıđım zorlukları ařmamda deđerli bilgi ve tecrübeleriyle yardımcı olan, zamanını ve emeđini esirgemedен her türlü desteđi sunan, birlikte çalıřmaktan gurur duyduđum tez danıřmanlarım Sayın Dr. Öğr. Üyesi Hakan YÜKSEL'e ve Sayın Öğr. Gör. Dr. Halit ÇETİNER'e deđerli katkıları için teşekkürlerimi sunarım.

Eđitim hayatım boyunca maddi ve manevi desteđini benden hiçbir zaman esirgemeyen ailemeve hayatımda her zaman bir ıřık olmuř, öğretileriyle yolumu aydınlatan rahmetli babam Metin Tuncel'e olan sonsuz minnettarlıđımı ifade etmek isterim.

**Miray TUNCEL**  
ISPARTA, 2025



## ŞEKİLLER DİZİNİ

|                                                                                        | <b>Sayfa</b> |
|----------------------------------------------------------------------------------------|--------------|
| Şekil 1.1. Stres yönetimi .....                                                        | 3            |
| Şekil 1.2. Stresör türü ve örnekleri.....                                              | 7            |
| Şekil 1.3. Stres seviyeleri .....                                                      | 8            |
| Şekil 3.1. Literatür tarama süreci .....                                               | 33           |
| Şekil 3.2. RNN hücre yapısı gösterimi.....                                             | 42           |
| Şekil 3.3. LSTM bellek hücresi .....                                                   | 43           |
| Şekil 3.4. Dikkat katmanlı önerilen hibrit model .....                                 | 45           |
| Şekil 4.1. Stres tahmininde kullanılan modellerin eğitim MSE performansları .....      | 51           |
| Şekil 4.2. Stres tahmininde kullanılan modellerin doğrulama MAE performansları .       | 52           |
| Şekil 4.3. Stres tahmininde kullanılan modellerin doğrulama MSE performansları .       | 52           |
| Şekil 4.4. Stres tahmininde kullanılan modellerin doğrulama MAE<br>performansları..... | 53           |

## ÇİZELGELER DİZİNİ

|                                                                                                 | <b>Sayfa</b> |
|-------------------------------------------------------------------------------------------------|--------------|
| Çizelge 3.1. Stres seviyesi tahmininde kullanılan öznitelikler .....                            | 36           |
| Çizelge 4.1. Gradyan Artırma Karar Ağacı algoritması performans sonuçları.....                  | 48           |
| Çizelge 4.2. Rastgele Orman tahmin sonuçları.....                                               | 49           |
| Çizelge 4.3. SVM algoritması performans sonuçları .....                                         | 50           |
| Çizelge 4.4. Yenilemeli Sinir Ağlarını temel alan modellerin tahminperformans<br>sonuçları..... | 50           |



## SİMGELER VE KISALTMALAR DİZİNİ

|          |                                                                                                                                           |
|----------|-------------------------------------------------------------------------------------------------------------------------------------------|
| AI       | Yapay Zekâ (Artificial Intelligence)                                                                                                      |
| BDT      | Bireysel Davranışçı Terapi                                                                                                                |
| BP       | Kan Basıncı (Blood Pressure)                                                                                                              |
| DSM-5    | Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabı- 5. Baskı<br>(Diagnostic and Statistical Manual of Mental Disorders, 5th Edition) |
| DSÖ      | Dünya Sağlık Örgütü (World Health Organization, WHO)                                                                                      |
| EEG      | Elektroensefalografi (Electroencephalography)                                                                                             |
| EKG      | Elektrokardiyografi (Electrocardiography)                                                                                                 |
| GB       | Gigabayt (Gigabyte)                                                                                                                       |
| GRU      | Geçit Yinelemeli Hücreler (Gated Recurrent Unit)                                                                                          |
| GSR      | Galvanik Deri Tepkisi (Galvanic Skin Response)                                                                                            |
| HCI      | İnsan-Bilgisayar Etkileşimi (Human-Computer Interaction)                                                                                  |
| HR       | Kalp Hızı (Heart Rate)                                                                                                                    |
| HRV      | Kalp Hızı Değişkenliği (Heart Rate Variability)                                                                                           |
| ICD-11   | Uluslararası Hastalık Sınıflandırması- 11. Revizyon (International<br>Classification of Diseases, 11th Revision)                          |
| IoT      | Nesnelerin İnterneti (Internet of Things)                                                                                                 |
| KNN      | K-En Yakın Komşu Algoritması (K-Nearest Neighbor)                                                                                         |
| KOAH     | Kronik Obstrüktif Akciğer Hastalığı                                                                                                       |
| KTSB     | Karmaşık Travma Sonrası Stres Bozukluğu                                                                                                   |
| LSTM     | Uzun Kısa Süreli Bellek (Long Short-Term Memory)                                                                                          |
| MAE      | Ortalama Mutlak Hata (Mean Absolute Error)                                                                                                |
| MAPE     | Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error)                                                                             |
| MSE      | Ortalama Kare Hatası (Mean Squared Error)                                                                                                 |
| NASA     | Amerika Birleşik Devletleri Havacılık ve Uzay Dairesi<br>(National Aeronautics and Space Administration)                                  |
| NASA TLX | NASA Görev Yüğü Endeksi (NASA Task Load Index)                                                                                            |
| RBF      | Radyal Tabanlı Fonksiyon (Radial Basis Function)                                                                                          |
| RFE      | Geriye Dönük Eleme (Recursive Feature Elimination)                                                                                        |
| RNN      | Tekrarlayan Sinir Ağı (Recurrent Neural Network)                                                                                          |
| RR       | Solunum Hızı (Respiratory Rate)                                                                                                           |
| SpO2     | Kanın Oksijen Doygunluğu Seviyesi (Oxygen Saturation)                                                                                     |
| SVM      | Destek Vektör Makinesi (Support Vector Machine)                                                                                           |
| TSSB     | Travma Sonrası Stres Bozukluğu                                                                                                            |
| VR       | Sanal Gerçeklik (Virtual Reality)                                                                                                         |
| Wi-Fi    | Kablosuz Yerel Alan Ağı (Wireless Fidelity)                                                                                               |

## 1. GİRİŞ

Stres, bireylerin günlük yaşamında karşılaştığı fiziksel, duygusal ve zihinsel zorlanmalar sonucu ortaya çıkan doğal bir tepki mekanizmasıdır (Kaba, 2019). Kontrol edilemeyen veya uzun süre devam eden stres, kardiyovasküler rahatsızlıklar, bağışıklık sistemi problemleri, depresyon ve anksiyete gibi ciddi sağlık sorunlarına neden olabilmektedir. Bu durum, stresin erken tespit edilmesi ve bireylerin ihtiyaçlarına göre uyarlanmış çözümler geliştirilmesini, modern tıp ve mühendislik alanlarında öncelikli bir araştırma konusu hâline getirmiştir (Güçlü, 2001). Bireylerin stresin olumsuz etkilerinden korunabilmesi için stres yönetimini öğrenmeleri büyük bir önem taşımaktadır. Stresi yönetebilmek adına, stresin ne olduğunu, nasıl ortaya çıktığını, belirtilerini ve sonuçlarını anlamanın yanı sıra, etkili başa çıkma yöntemlerini bilmek oldukça önemlidir. Bu bağlamda, stres seviyesini ölçmeye yönelik araştırmalar hem erken müdahale hem de etkili yönetim stratejilerinin geliştirilmesi açısından kritik bir öneme sahiptir.

Son yıllarda, nesnelerin interneti ve giyilebilir teknolojilerin hızla gelişmesi, bireylerin fizyolojik ve psikolojik durumlarını gerçek zamanlı olarak izleme ve analiz etme fırsatını sunmuştur (Alp ve Doğan, 2021). Bu teknolojiler arasında galvanik deri tepkisi (GSR), stres algılama süreçlerinde öne çıkan bir biyofiziksel parametre olarak dikkat çekmektedir. GSR, bireyin sempatik sinir sistemi aktivitesini ölçerek stres tepkilerini doğrudan gözlemlenebilir fırsat sunmaktadır. GSR ölçümleri, bireylerin çevresel uyaranlara verdiği anlık fizyolojik tepkilerin değerlendirilmesiyle, stres düzeylerinin tespit edilmesinde oldukça önemli bir araçtır.

Nesnelerin interneti tabanlı stres algılama sistemleri, GSR verilerinin sürekli ve bütünlüklü bir şekilde izlenmesini mümkün kılarak bireylerin stres seviyelerinin daha hassas ve objektif bir şekilde değerlendirilmesini sağlamaktadır (Kumar ve Shrivastava, 2022). Bu tür sistemler, sadece stresin ölçülmesiyle sınırlı kalmayıp, aynı zamanda bireyselleştirilmiş sağlık yönetim stratejileri geliştirilmesi için temel teşkil etmektedir. Stres algılama süreçlerinin nesnelerin interneti teknolojileri ile birleştirilmesi, sağlık ve yaşam kalitesini artırmayı hedefleyen çok disiplinli yaklaşımlar için önemli bir araştırma alanı oluşturmıştır.


Bu tez çalışması, nesnelerin interneti tabanlı GSR ölçüm sonuçlarının stres algılama ve yönetimindeki potansiyelini incelemeyi amaçlamaktadır. Çalışma, literatürdeki yöntem ve uygulamalara dayanarak bir yaklaşım sunacaktır. Özellikle büyük veri analitiği ve makine öğrenimi algoritmaları kullanılarak stres seviyelerinin daha hassas bir şekilde tahmin edilmesini sağlayacaktır. Ayrıca, çalışmaların bireysel ve toplumsal düzeyde uygulama alanları değerlendirilerek, stresle ilişkili sağlık problemlerinin önlenmesine yönelik stratejik çözümler önerilecektir. Bu bağlamda, çalışmamız hem akademik hem de endüstriyel açıdan önemli katkılar sağlamayı hedeflemekte, stres yönetimi ve birey sağlığı için yenilikçi bir yaklaşım sunmaktadır.

### **1.1. Stres Algılama**

Stres, bireylerin çevresel taleplere ya da içsel çatışmalara verdiği biyolojik ve psikolojik tepkilerle tanımlanan karmaşık bir durumdur (Uzunhasanoğlu ve Şen, 2023). Günümüzde stres, sadece bireysel sağlığı etkilemekle kalmayıp, aynı zamanda üretkenlik, sosyal ilişkiler ve genel yaşam kalitesi üzerinde de önemli olumsuz etkilere sahiptir (Lazarus ve Folkman, 1984). Bu durum, stresin daha iyi anlaşılması, ölçülmesi ve yönetilmesi konularında yapılan araştırmaların artmasına yol açmıştır. Stresin fizyolojik düzeyde incelenmesi, özellikle nörolojik ve biyolojik göstergelerle mümkündür. GSR, bireylerin stres düzeylerini tespit etmek için sıklıkla kullanılan ve deri üzerinde meydana gelen elektriksel değişiklikleri ölçen bir yöntemdir (Boucsein, 2012).

GSR, bireyin otonom sinir sistemi aktivitesine doğrudan bağlı olduğundan, stres gibi fizyolojik tepkileri anlamada önemli bir veri kaynağı sunmaktadır. Son yıllarda, nesnelerin interneti teknolojisinin sağlık alanında uygulanabilirliği, stres ölçümü ve yönetimi için yenilikçi çözümler sunmuştur (Patel vd., 2012). Nesnelerin interneti tabanlı sistemler, stresin gerçek zamanlı olarak izlenmesine ve analiz edilmesine olanak tanırken, bireylerin stresle başa çıkmalarına yönelik özelleştirilmiş çözümler geliştirilmesini mümkün kılmaktadır. Çalışma, GSR verilerinin stres algılama ve yönetimindeki rolünü yeni bir perspektifle sunmayı hedeflemektedir. Günlük yaşamda iş, aile, finansal durum, sağlık sorunları, çevresel koşullar, sosyal ilişkiler ve kişisel durumlar gibi pek çok faktör stres kaynağı olabilmektedir. Bu faktörlerin bazıları kontrol edilemez veya öngörülemez olsa da bir kısmı için önleyici adımlar

atılmaktadır (Alshari vd., 2021). Strese neden olan unsurların farkında olmak, bu durumlarla başa çıkma yöntemlerini öğrenmek için önemlidir. Özellikle farkındalık, stresin kaynaklarını tanımlamada kritik bir rol oynar. Hem kendimizde hem de çevremizde gözlemlediğimiz stres belirtilerini anlamak ve bu belirtilerin nedenlerini irdelemek, stres yönetimi becerilerimizi geliştirmektedir. Stres kaynaklarını doğru bir şekilde belirlemek, bu kaynakların etkilerini azaltma yolunda önemli bir adımdır. Bu süreçte, stresle baş etme tekniklerini ve etkili stres yönetimi stratejilerini kullanmak büyük fayda sağlamaktadır.



Şekil 1.1. Stres yönetimi

Stres yönetimi, bireylerin stresin sağlık üzerindeki olumsuz etkilerini azaltarak psikolojik iyi oluşlarını artırmalarını, iş performanslarını iyileştirmelerini ve genel yaşam kalitelerini desteklemelerini sağlayan önleyici bir yaklaşımdır. Günümüzde yapılan araştırmalar, stresin kontrol altına alınmadığında fiziksel ve psikolojik sorunlara yol açabileceğini göstermektedir (Gültekin, 2023). Bu nedenle, bireylerin stres yönetimi yöntemlerini öğrenmeleri ve düzenli olarak uygulamaları büyük önem taşımaktadır. Stres yönetimi yöntemleri arasında gevşeme teknikleri, meditasyon, nefes egzersizleri, düzenli egzersiz, uyku düzenini iyileştirme, sağlıklı

beslenme alışkanlıkları edinme, zaman yönetimi ve problem çözme becerilerinin geliştirilmesi gibi stratejiler yer almaktadır (Şekil 1.1). Yapılan çalışmalara göre, düzenli egzersiz yapmak bireylerde stres hormonlarını düşürmekte ve genel iyi oluş düzeyini artırmaktadır (Yalçın ve Özbaşaran, 2021). Aynı şekilde meditasyonun ve nefes egzersizlerinin, zihinsel sakinliği artırarak bireylerin stresle daha etkili başa çıkmalarına yardımcı olduğu belirtilmektedir.

Sosyal destek de stres yönetiminin önemli bir bileşenidir. Araştırmalar, bireylerin sosyal destek ağlarından faydalanmalarının stresle başa çıkma kapasitelerini artırdığını ortaya koymaktadır (Tindle vd., 2022). Özellikle aile, arkadaşlar ve profesyonel danışmanlık hizmetlerinden alınan destek, bireylerin stresli durumlarla başa çıkma becerilerini güçlendirmektedir (Landy vd., 1994). Stres yönetimi sürecinde proaktif yaklaşımlar da önemlidir. Bireylerin stres yaratan faktörleri önceden tespit etmeleri ve bu faktörlere karşı çözüm odaklı stratejiler geliştirmeleri, stresin kontrol altına alınmasını kolaylaştırmaktadır (Güçlü, 2001). Bunun yanı sıra, zaman yönetimi becerilerinin geliştirilmesi ve günlük yaşamda önceliklerin belirlenmesi de bireylerin stres düzeylerini azaltmada etkili bir yöntem olarak öne çıkmaktadır (Aydın vd., 2021).

Stres yönetimi bireylerin yalnızca stresin olumsuz etkilerinden korunmasını değil, aynı zamanda daha dengeli, mutlu ve üretken bir yaşam sürdürmelerini desteklemektedir. Bu bağlamda, bireylerin stres yönetimi tekniklerini öğrenmeleri ve uygulamaları sağlıklı bir yaşam sürdürmek adına vazgeçilmez bir unsur olarak değerlendirilmektedir (Scanff ve Taugis, 2002).

Stres, modern yaşamın bir parçası olarak hemen herkesin deneyimlediği, bireylerin fiziksel ve psikolojik sağlığını olumsuz yönde etkileyebilen bir olgudur. Son yıllarda, stresin nedenleri, bireyler üzerindeki etkileri ve bu etkilerin yönetimine yönelik stratejiler hem bilimsel araştırmaların hem de sağlık uzmanlarının öncelikli çalışma alanlarından biri haline gelmiştir. Literatürdeki bulgular, stresin yalnızca fiziksel rahatsızlıklarla değil, aynı zamanda zihinsel sağlık sorunlarıyla da yakından ilişkili olduğunu ortaya koymaktadır (Bilgili ve Tekin, 2019; Okumuş, 2024).

Strese ilişkin yürütülen arařtırmalar, bu durumun nedenlerini ve bireylerde ortaya ıkardığı belirtileri anlamının yanı sıra, etkili başa ıkma yöntemlerinin geliştirilmesine yönelik değerli bilgiler sunmaktadır. Özellikle gevşeme teknikleri, farkındalık temelli yaklaşımlar, sosyal destek ağlarının önemi ve zaman yönetimi becerilerinin geliştirilmesi gibi yöntemlerin stresin olumsuz etkilerini azaltmada başarılı sonuçlar verdiği belirtilmektedir (Ardı ve Polatı, 2007). Bu nedenle, stresle ilgili mevcut alıřmaların değerlendirilmesi, bireylerin daha saėlıklı ve üretken bir yařam sürdürebilmeleri için etkili stratejilerin tasarlanmasına olanak tanımaktadır. Stresin bireyler üzerindeki etkilerinin daha kapsamlı bir şekilde anlaşılması, bireysel ve toplumsal düzeyde daha etkili başa ıkma mekanizmalarının oluşturulmasını mümkün kılmaktadır. Bu bağlamda, stres yönetimi konusundaki arařtırmalar, bireylerin yařam kalitesini artırmada önemli bir rehber niteliėi taşımaktadır.

Toplumun stresle ilgili bilinlenmesini saėlamak, ülkelerin sosyo ekonomik açıdan gelişimine katkı saėlayacaktır. Stres, birden fazla boyuta sahip karmařık bir olgu olduğundan, stres yaratan durumlara maruz kalındığında ortaya ıkan duygusal tepkilerin tespit edilmesi ve yönetilmesi genellikle güçtür (Lazarus, 1984). İnsanlar, yařamları boyunca stres içeren eřitli deneyimlerle sürekli karřılařmakta ve bu durumlar hem fiziksel hem de psikolojik saėlıklarını etkileyebilmektedir. Bu etkiler yalnızca bireysel yařamla sınırlı kalmaz, aynı zamanda toplumsal, ekonomik ve politik olaylar da bireylerin hayatında önemli deėiřikliklere yol açmaktadır. Afetler, ekonomik krizler ve savařlar gibi büyük toplumsal olaylar, geniş kitleleri etkileyerek uzun süreli kayıplara neden olabilmekte ve insanların yařamları üzerindeki etkileri uzun yıllar sürebilmektedir. İnsanlar, yařamları boyunca stres içeren eřitli deneyimlerle sürekli karřılařmakta ve bu durumlar hem fiziksel hem de psikolojik saėlıklarını etkileyebilmektedir. Bu etkiler yalnızca bireysel yařamla sınırlı kalmaz, aynı zamanda toplumsal, ekonomik ve politik olaylar da bireylerin hayatında önemli deėiřikliklere yol açabilmektedir. Afetler, ekonomik krizler ve savařlar gibi büyük toplumsal olaylar, geniş kitleleri etkileyerek uzun süreli kayıplara neden olabilmekte ve insanların yařamları üzerindeki etkileri uzun yıllar sürebilmektedir (řekil 1.1).

Stres ve heyecan gibi güçlü duygular karřısında sinir sistemi, vücuda eřitli uyarılar göndermekte ve bu uyarılar sonucunda ter bezleri aktive olarak ter üretimi başlamaktadır. Ter oranındaki deėiřiklikleri tespit edebilmek ve durumu analiz

edebilmek için, genellikle bir elin iki parmağına elektrotlar yerleştirilmektedir. Bu yöntemle veri toplamak için özel olarak geliştirilmiş cihazlar kullanılmaktadır. Bu teknik, GSR olarak adlandırılmaktadır. Yapılan araştırmalar, kronik stresin bireylerde depresyon, anksiyete bozuklukları, hipertansiyon, kalp krizi ve inme gibi ciddi zihinsel ve fiziksel sağlık problemlerine neden olabileceğini göstermektedir (Schneiderman vd., 2005).

Bu nedenle, stresin doğru bir şekilde tespit edilmesi, sağlıklı bir yaşam sürdürebilmek adına önemli bir araştırma konusu olmaktadır. Stres, zamanla birikerek vücuttaki belirli işlevlere etki edebilmekte ve pek çok fizyolojik ve psikolojik semptoma yol açabilmektedir. Kronik stresin zararlı etkilerinin belirlenmesi ve yönetilebilmesi için, stres düzeylerinin düzenli olarak takip edilmesi büyük önem taşımaktadır (Cohen vd., 2007). Sürekli izleme ile stres düzeyindeki değişiklikler daha doğru bir şekilde analiz edilebilmekte ve etkili başa çıkma stratejileri geliştirilebilmektedir. Teknolojinin hızla ilerlemesiyle birlikte, yapay zekâ teknikleri pek çok alanda yaygın olarak kullanılmaktadır. Mühendislik, eğitim ve savunma sanayi gibi çeşitli sektörlerde kullanılan bu teknikler, sağlık alanında da büyük bir potansiyele sahiptir. Özellikle stres seviyelerinin tespiti gibi önemli sağlık konularında yapay zekâ, büyük bir yenilik sunmaktadır. Bu çalışmanın temel amacı, mobil cihazlardan elde edilen veriler aracılığıyla makine öğrenimi algoritmalarını kullanarak bireylerin stres seviyelerini tahmin etmektir. Modern yaşamın hızlı temposu, bireylerin sıkça zihinsel stresle karşılaşmasına neden olmaktadır. Stres, bireyin zihinsel ve fiziksel sağlığını zorlayan olaylar ya da koşullar sonucunda meydana gelebilmekte ve yaşam kalitesini olumsuz yönde etkilemektedir (Tülgün, 2020).




Şekil 1.1. Stresör türü ve örnekleri

Her bireyin stresle başa çıkma yeteneği farklı olduğundan, stresle başa çıkma yöntemleri de kişiden kişiye değişmektedir. Bir olay bir kişide stres yaratabilirken, aynı olay diğer bir bireyde herhangi bir olumsuz etkiye yol açmamaktadır. Ancak stresin tamamen olumsuz bir durum olmadığını da unutmamak gerekmektedir. Stres, bireylerin dikkatini artırabilirken hedeflerine daha yoğun bir şekilde odaklanmalarını sağlayabilmektedir. Stresör, bir kişide stres yaratan dışsal bir olay ya da durumdur. Birçok birey, Şekil 1.2'de belirtilen stres kaynakları nedeniyle stres yaşamaktadır (Şekil 1.2).

Kronik stres, en zararlı stres türü olarak kabul edilmekte ve tedavi edilmediği takdirde bireyin hem fiziksel hem de ruhsal sağlığını olumsuz etkileyebilmektedir. Uzun süre devam eden stres, vücutta ve zihinde baskı oluşturmakta ve çeşitli belirtiler ortaya çıkarmaktadır. Ayrıca, bazı hastalıkların gelişme riskini artırmaktadır. Stresin belirtilerini doğru şekilde tespit edebilmek için, stresin düzenli olarak izlenmesi gerekmektedir.

Giyilebilir teknoloji sayesinde bireylerin stres seviyelerini gerçek zamanlı olarak takip etmek ve bu konuda bilgilendirmek mümkün hale gelmektedir. Bu cihazlar, stresin yol açabileceği ciddi sağlık sorunları oluşmadan önce erken müdahaleye olanak tanımaktadır (Birur vd., 2017). Fiziksel sağlık ile ruhsal sağlık arasındaki güçlü etkileşim dikkate alındığında, fizyolojik ve fiziksel değişimlerin izlenmesi, stresin tespitinde hayati bir önem taşımaktadır (Birur vd., 2017). Fiziksel ölçümler arasında nabız, cilt sıcaklığı, nem oranı, kan basıncı ve solunum hızı yer alırken, fizyolojik ölçümler kalp hızı, kalp hızı değişkenliği ve deri iletkenliği gibi

parametreleri içermektedir (Öcel vd., 2024). Günümüzde düşük maliyetli giyilebilir sensörler sayesinde bu veriler kolaylıkla toplanabilmektedir. Ayrıca, bu verilerin analizi için makine öğrenimi algoritmaları kullanılarak bireylerin stres düzeyleri sınıflandırılmakta ve gelecekteki stres eğilimleri tahmin etmektedir (Kırcalı, 2022).



Şekil 1.2. Stres seviyeleri

Stres tespitinde hem bağlamsal hem de fizyolojik verilerden yararlanmak, bireyin stres seviyesinin doğru ve kapsamlı bir şekilde değerlendirilmesini sağlamaktadır. Bağlamsal faktörler, bireyin çevresel durumlarına ve yaşam düzenine bağlı olarak stresin oluşumuna zemin hazırlayan unsurlardır. Etkinlik takvimi veya ortamın durumu gibi günlük yaşam faktörleri, stres düzeyini etkileyen faktörlerdendir. Ayrıca, doğal afetler veya sosyoekonomik koşullar gibi daha geniş kapsamlı bağlamsal faktörler de bireyin stres algısını şekillendirmektedir. Fizyolojik veriler, stresin doğrudan vücutta yarattığı etkileri ölçmek için kullanılmaktadır. Bu çalışmada üç temel fizyolojik ölçüm parametresi öne çıkmaktadır: HR, RR, GSR ve sıcaklık. Bu biyolojik sinyaller, bireyin stres seviyesini doğrudan etkileyen içsel tepkileri anlamak için kullanılır (Şekil 1.3).

Toplanan veriler, řu temel ařamalardan geirilerek analiz edilmektedir:

1. n İřleme: Ham verilerin, analiz iin uygun hale getirilmesi ve grltden arındırılmasıdır.
2. znitelik ıkarma: Toplanan verilerden anlamlı ve sınıflandırmaya uygun parametrelerin belirlenmesidir.
3. Tahmin: Elde edilen zelliklerin, makine ğrenimi algoritmaları kullanılarak stres dzeylerine (dřk, orta, yksek) ayrılmasıdır.

Bu sre, bireylerin stres seviyelerini doėru bir řekilde analiz etmeyi ve kiřiselleřtirilmiř stres ynetim stratejileri geliřtirmeyi mmkn kılmaktadır. Aynı zamanda, bu yaklařımla birlikte teknolojinin saėlık sektr ve kiřisel geliřim alanında kullanılabilirliėi artmaktadır.

Makine ğrenimi, verilerden anlam ıkarak bilgi edinmeyi saėlayan hesaplamalı bir yntemler btndr (Aydın vd., 2021). Bu alanda iki temel ğrenme tekniėi bulunmaktadır: denetimli ğrenme ve denetimsiz ğrenme (etiner, 2022). Denetimsiz ğrenmede, veriler etiketlenmediėi iin makine, bu verilerdeki gizli rntleri tespit etmeye alıřmaktadır. Bu tekniklerin bařında, verileri analiz ederek benzer gruplar oluřturmak iin kullanılan kmeleme yer almaktadır. Denetimli ğrenmede ise, makine etiketli verilerle eėitilerek, giriř ve ıkıř arasındaki iliřkiyi ğrenmekte ve bu sayede gelecekteki verilere dair tahminler yapılmaktadır (Aydın vd., 2021). Bu yaklařımlar, srekli deėerleri tahmin etmek iin regresyon ve ayrık, kategorik verileri tahmin etmek iin ise sınıflandırma yntemlerine dayanmaktadır (etiner, 2022). Bu alıřmada, insan stres seviyelerini tahmin etmek iin KNN, RFE ve diėer makine ğrenimi yntemlerinden yararlanarak bir model oluřturulmuřtur.

KNN algoritması, veriler arasındaki mesafeyi lerek sınıflandırma gerekleřtirmektedir (Aydın vd., 2021). RFE, zniteliklerin nem sırasına gre seilmesini saėlayan bir yntemdir. Karar aėacı, SVM ve rastgele orman makine ğrenimi teknikleri de bu alanda kullanılmaktadır. Karar aėacı, verileri aėaç yapısında organize ederek sınıflandırma gerekleřtirirken, destek vektr makineleri verileri bir hiper-dzlemde sınıflandırarak, sınıf etiketleri arasındaki maksimum mesafeyi hedeflemektedir. Rastgele orman ise birok karar aėacından oluřur ve bu aėalardan en iyi performansı gsterenleri seerek sınıflandırma yapar. Bu

yöntemlerin her biri, stres tespiti için kullanılmakta ve verisetine bağlı olarak farklı sonuçlar vermektedir (Li ve Friedman, 1984).

## **1.2. Galvanik Deri Tepkisi ve Ölçümü**

GSR, bireylerin stres, duygu ve uyaranlara verdikleri fizyolojik yanıtları anlamak için kullanılan bir biyometrik ölçüm yöntemidir. GSR, derinin elektriksel iletkenliğindeki değişikliklere dayanmakta ve bu değişiklikler, genellikle sempatik sinir sistemi aktivitelerinin bir göstergesidir. İnsanlar stres, heyecan veya korku gibi güçlü duygular yaşadıklarında, ter bezlerinin aktivitesi artar ve bu da derinin iletkenliğini değiştirmektedir. Bu nedenle GSR, özellikle duygu analizi, stres algılama, psikoloji ve insan-bilgisayar etkileşimleri gibi alanlarda yoğun olarak kullanılmaktadır.

Günümüzde, GSR ölçümleri, nesnelerin interneti tabanlı cihazlar, giyilebilir teknolojiler ve mobil uygulamalar aracılığıyla daha erişilebilir hale gelmektedir. Bu teknolojiler, sağlık hizmetlerinden eğitim sistemlerine kadar geniş bir yelpazede kullanılmakta ve bireylerin fizyolojik durumlarını gerçek zamanlı olarak izlemeyi mümkün kılmaktadır (Aylak ve Oral, 2021).

### **1.2.1. Galvanik deri tepkisi ve psikoloji araştırmaları**

GSR, stres ve duygusal durumların biyolojik göstergesi olarak psikolojik araştırmalarda önemli bir yer tutmaktadır. GSR, derideki elektriksel iletkenlikteki değişiklikleri ölçerek, sempatik sinir sistemi aktivitesini ve bireylerin duygusal durumlarını anlamamıza olanak sağlamaktadır. GSR, özellikle stres ve anksiyete gibi duygusal durumların izlenmesinde sıklıkla tercih edilen bir yöntemdir. Çünkü bu tür duygusal yanıtlar genellikle ter bezlerinin daha fazla çalışmasına neden olmaktadır ve bu da deri iletkenliğinde bir artışa yol açabilmektedir (Critchley, 2002).

### **1.2.2. Stres ve galvanik deri tepkisi ilişkisi**

Stres, bir kişinin çevresel ve içsel uyaranlara verdiği biyolojik bir tepkidir ve bu tepki, genellikle GSR ölçümleriyle doğrudan ilişkilidir. Stresli durumlarda, sempatik

sinir sistemi devreye girmekte ve vücut "savaş ya da kaç" tepkisini tetiklemektedir. "Savaş ya da kaç" tepkisi bireyin stresli veya tehdit edici bir durumla karşılaştığında verdiği evrimsel bir yanıttır. Bu tepki, sempatik sinir sistemi tarafından tetiklenmekte ve bireyin hayatta kalma şansını artırmayı amaçlamaktadır. Tepki sırasında kalp atış hızı artar, solunum hızlanır, kaslar gerilir ve terleme artar. Bu değişiklikler, bireyin tehditle mücadele etmesi ("savaş") veya tehditten uzaklaşması ("kaç") için fiziksel olarak hazır olmasını sağlamaktadır. Aynı zamanda sindirim gibi hayati önemi daha düşük olan süreçler yavaşlar ve enerji, hayatta kalma için kritik olan sistemlere yönlendirilmektedir. Tarihsel bağlamda ele alındığında, bu mekanizma avcı-toplayıcı insanların yırtıcı hayvanlardan kaçmaları veya rakipleriyle savaşmaları için hayati bir öneme sahip olduğu görülmektedir. Ancak günümüzde, fiziksel bir tehdit olmaksızın iş stresi, sınav kaygısı veya sosyal baskı gibi durumlar da bu tepkinin aktive olmasına neden olabilmektedir (LeDoux, 1998; McEwen, 2007). Bu süreç, ter bezlerinin artan aktivitesine yol açmakta ve bu da derinin elektriksel iletkenliğinde belirgin bir artışa neden olmaktadır. GSR ölçümleri, stres seviyelerinin belirlenmesinde kullanılarak, bireylerin psikolojik durumlarını anlama konusunda değerli bilgiler sunmaktadır (Boucsein, 2012).

Birçok psikolojik çalışma, GSR'nin, özellikle duygusal tepkilerin ve stresli durumların izlenmesinde ne kadar etkili olduğunu göstermektedir. Nourbakhsh vd. (2017), stresli durumlar sırasında GSR'deki artışların doğrudan bir ilişkiye sahip olduğunu ve duygusal uyarıcılara karşı bireylerin verdiği yanıtları anlamada bu verilerin kullanılabileceğini belirtmektedir. Bu bulgular, GSR'nin psikolojik testlerde ve stresli durumları inceleyen çalışmalarda faydalı bir araç olduğunu ortaya koymaktadır (Johnson, 2008).

### **1.2.3. Galvanik deri tepkisi'nin psikolojik araştırmalardaki uygulamaları**

GSR, psikolojik araştırmaların çeşitli alanlarında kullanılmaktadır. Birçok psikolojik deneyde, bireylerin stres seviyeleri, korku, heyecan veya anksiyete gibi duygusal yanıtlar izlenebilmektedir. Bu tür araştırmalar, stresin psikolojik ve fizyolojik etkilerini daha iyi anlamamıza olanak sağlamaktadır. Bazı araştırmalar GSR'nin, sosyal anksiyete gibi psikolojik bozuklukların değerlendirilmesinde etkili bir yöntem olduğunu göstermektedir. GSR ölçümleri, sosyal etkileşimler sırasında bireylerin

stres seviyelerini izleyerek, psikolojik bozuklukların tedavisine dair içgörüler sunabilmektedir (Rytwinski vd., 2009).

#### **1.2.4. Galvanik deri tepkisi ve psiko-fizyolojik modeller**

GSR, psiko-fizyolojik modellerin geliştirilmesinde önemli bir rol oynamaktadır. Bu modeller, bireylerin stres yanıtlarını sadece biyolojik değil, aynı zamanda psikolojik faktörlere de bağlayarak incelemektedir. Lang (1995)'ın "İçsel Uyarıcılar Modeli" ve "Duygusal- Psikolojik Model" gibi teoriler, GSR'nin duygusal ve psikolojik yanıtlarla nasıl etkileşime girdiğini anlamaya yönelik güçlü teorik çerçeveler sunmaktadır. Bu teoriler, GSR'nin sadece fizyolojik bir ölçüm aracı olmadığını, aynı zamanda bireylerin duygusal durumlarını anlamada önemli bir gösterge olduğunu vurgulamaktadır.

#### **1.2.5. Günümüzde galvanik deri tepkisi ve psikolojik terapiler**

Son yıllarda, GSR ölçümleri, terapötik uygulamalarda da kullanılmaktadır. Özellikle bilişsel davranışçı terapi (BDT) ve gevşeme teknikleri gibi psikoterapötik müdahalelerde, GSR'nin izlenmesi, bireylerin duygusal tepkilerini ve rahatlama süreçlerini daha iyi değerlendirmeyi mümkün kılmaktadır. Braithwaite vd. (2013), GSR'nin terapi seanslarında kullanılan bir araç olarak, terapi sürecinde stres seviyelerinin izlenmesine yardımcı olduğunu belirtilmektedir. Bu sayede terapistler, terapötik müdahalelerin etkinliğini ve bireylerin psikolojik iyileşme süreçlerini daha doğru bir şekilde değerlendirebilmektedirler.

#### **1.2.6. Galvanik deri tepkisi ve duygusal tepkiler**

GSR, duygusal tepkilerin ölçülmesinde özellikle yararlı bulunmaktadır. Araştırmalar, GSR'nin duygusal yanıtları (mutluluk, üzüntü, korku, vb.) değerlendirmede etkin bir araç olduğunu göstermektedir. Birçok çalışmada, belirli bir duygusal uyarının ardından GSR'deki değişiklikler izlenerek, bireylerin psikolojik ve duygusal yanıtları hakkında bilgi edinilmektedir (Bradley ve Lang, 2000). Bu tür veriler, insan duygusal tepkilerini anlayan ve bu tepkileri bilimsel temellere dayandırarak açıklayan araştırmaların yapılmasına olanak sağlamaktadır (Beyaz, 2015).

GSR, psikolojik arařtırmalarda son derece deęerli bir ara olarak ne ıkmaktadır. Stres, anksiyete, sosyal etkileřimler ve duygusal durumların izlenmesinde saęladığı objektif veriler, psikolojik incelemelere yeni bir boyut katmaktadır (Bakioęlu vd., 2021). zellikle GSR'nin psikoterapi ve duygusal durum takibi gibi alanlarda kullanımını hem arařtırmacılar hem de terapistler iin nemli fırsatlar sunmaktadır. GSR, biyometrik lmlerle psikolojik analizlerin birleřiminden elde edilen gl bulgularla, bireylerin isel dnyasını daha derinlemesine anlamamıza katkı saęlamaktadır. Bu alandaki geliřmeler, stres ve dięer psikolojik durumların daha hassas ve doęru bir řekilde llmesini mmkn kılmaktadır (Cetiner ve Koksel, 2024).

### **1.3. Nesnelerin İnterneti Tabanlı Galvanik Deri Tepkisi Uygulamaları**

Nesnelerin interneti, cihazlar arasındaki veri paylařımını ve etkileřimi mmkn kılarak, fiziksel dnyayı dijital ortamla birleřtirmektedir. Nesnelerin interneti tabanlı sistemler, saęlık, gvenlik, eęitim ve daha birok alanda nemli deęiřiklikler yaratmaktadır. zellikle biyometrik verilerin, gerek zamanlı olarak izlenmesi ve analizi, nesnelerin interneti teknolojilerinin geniř bir kullanım alanı bulmasına yol amaktadır. GSR lm, bu biyometrik verilere rnek olarak verilebilmektedir. GSR, bireylerin duygusal durumlarını ve stres seviyelerini izlemek iin kullanılan etkili bir aratır. Nesnelerin interneti tabanlı GSR cihazları, bu lmleri daha eriřilebilir ve kullanıcı dostu hale getirerek bireylerin fiziksel ve psikolojik saęlıklarını izlemeyi kolaylařtırmaktadır (Taskasaplıdis vd., 2024).

#### **1.3.1. Nesnelerin interneti tabanlı galvanik deri tepkisi sistemlerinin yapısı ve alıřma prensibi**

Nesnelerin interneti tabanlı GSR uygulamaları, genellikle sensrler, veri toplama cihazları, veri iletimi ve analiz sistemlerinden oluřmaktadır. GSR sensrleri, genellikle cilt yzeyine yerleřtirilen elektrotlar kullanarak deri iletkenlięindeki deęiřimleri lmektedir. Bu sensrler, genellikle giyilebilir cihazlar veya mobil cihazlara entegre edilerek srekli veri toplama saęlamaktadır. Toplanan veriler, daha sonra bulut tabanlı sistemlere veya mobil cihazlara iletilerek analiz edilmektedir.

Veri iletimi için Bluetooth veya Wi-Fi gibi kablosuz iletiřim protokolleri kullanılmaktadır (Talaat ve El-Balka, 2023).

GSR ölçümleri, özellikle sempatik sinir sistemi tarafından kontrol edilen stres, heyecan ve anksiyete gibi duygusal durumlarla ilişkilendirilmektedir. Nesnelerin interneti cihazları, bu duygusal tepkileri gerçek zamanlı olarak izleyebilmekte ve bireylerin stres seviyelerini daha etkin bir şekilde yönetmelerine yardımcı olabilmektedir. Nesnelerin interneti tabanlı GSR sistemleri, bu verileri sadece ölçmekle kalmaz, aynı zamanda kullanıcıya geri bildirim sağlayarak stres yönetimi için önerilerde bulunabilmektedir.

### **1.3.2. Nesnelerin interneti tabanlı galvanik deri tepkisi uygulamalarının kullanım alanları**

Birçok nesnelerin interneti tabanlı GSR cihazı, stresin izlenmesinin yanı sıra, anksiyete, depresyon ve duygusal bozukluklar gibi durumların izlenmesinde de kullanılmaktadır. Bu cihazlar, anlık geri bildirimlerle, bireylerin duygusal durumlarını anlamalarına ve uygun tepkiyi geliřtirmelerine yardımcı olabilmektedir (Aleky vd., 2021).

1. Sağlık ve Psikolojik İzleme: Nesnelerin interneti tabanlı GSR cihazları, stres ve anksiyete gibi psikolojik bozuklukların izlenmesi ve yönetilmesi için etkili bir araçtır. Özellikle bireylerin stres seviyelerinin izlenmesi, psikoterapi ve stres yönetimi programları için kritik öneme sahiptir. Nesnelerin interneti tabanlı sistemler, psikoterapi süreçlerinde psikologların veya terapistlerin, hastalarının stres seviyelerini izlemelerine ve tedaviye yönelik etkili geri bildirimler vermelerine yardımcı olabilmektedir (Ray vd., 2019).
2. Eğitim ve Öğrenme Performansı: Eğitimde nesnelerin interneti tabanlı GSR sistemlerinin kullanımı, öğrenci performansının izlenmesi ve duygusal tepkilerin analiz edilmesinde giderek yaygınlaşmaktadır. Özellikle stresli testler veya sınavlar sırasında öğrenciye ait GSR verilerinin izlenmesi, öğrenciye ait duygusal durumları anlamak ve performansını değerlendirmek için kullanılmaktadır. Bu tür veriler, öğretmenlerin öğrencilere yönelik daha

özelleştirilmiş destek sağlamalarına yardımcı olabilmektedir (Bardwell, 2024).

3. İşyeri ve Çalışan Sağlığı: Nesnelerin interneti tabanlı GSR sistemleri, işyerlerinde çalışanların stres seviyelerini izlemek için de kullanılmaktadır. Bu uygulamalar, özellikle iş yerindeki stresli durumların çalışanların verimliliği üzerindeki etkilerini analiz etmek için yararlı bulunmaktadır. Çalışanların stres seviyeleri izlenerek, işyeri ortamının iyileştirilmesine yönelik stratejiler geliştirilebilmektedir (Din vd., 2019). Ayrıca, bu tür sistemler, işyerinde çalışanların sağlığını izlemeye yönelik, potansiyel tehlikeleri erken tespit etme imkânı sağlamaktadır.
4. Kişisel Sağlık ve Fitness: Nesnelerin interneti tabanlı GSR cihazları, kişisel sağlık ve fitness izleme sistemlerine entegre edilerek kullanıcıların antrenman sırasındaki fiziksel ve duygusal durumlarını izlemeyi mümkün kılmaktadır. Bu cihazlar, egzersiz sırasında stres, yorgunluk ve motivasyon seviyelerini izleyebilmektedir. Ayrıca, bu veriler antrenman programlarının kişiye özel olarak optimize edilmesine yardımcı olabilmektedir (Mamdiwar vd., 2021).
5. Sosyal İletişim ve Etkileşim: Sosyal etkileşimler sırasında nesnelerin interneti tabanlı GSR cihazları kullanılarak bireylerin sosyal anksiyete seviyeleri de izlenebilmektedir. Bu tür cihazlar, bireylerin sosyal ortamlarda nasıl hissettiklerini izlemeye ve bu bilgiyi bireye geri bildirim olarak sunmaya olanak tanımaktadır. Sosyal etkileşimlerdeki stres ve anksiyetenin, nesnelerin interneti cihazlarıyla izlenmesi, sosyal terapiler ve destek gruplarının etkinliğini artırabilmektedir (Xu vd., 2024).

### **1.3.3. Nesnelerin interneti tabanlı galvanik deri tepkisi uygulamalarının geleceği**

Nesnelerin interneti tabanlı GSR uygulamaları, teknoloji geliştikçe daha sofistike hale gelmektedir. Gelişen yapay zekâ algoritmaları ve veri analitiği teknikleri ile GSR verilerinin daha doğru bir şekilde yorumlanması ve kişiye özel geri bildirim sağlanması mümkün olmaktadır. Bu gelişmeler, stres ve anksiyete gibi psikolojik bozuklukların yönetiminde önemli iyileşmelere yol açabilmektedir. Ayrıca, nesnelerin interneti cihazlarının daha kompakt, taşınabilir ve kullanıcı dostu hale gelmesi, bireylerin bu cihazları günlük yaşamlarına entegre etmelerini daha kolay

kılmaktadır (Rodgers vd., 2014). Bundan başka, nesnelerin interneti tabanlı GSR sistemlerinin birleştirildiği daha geniş sağlık izleme platformları, psikolojik ve fizyolojik durumları entegre bir şekilde analiz edebilme kapasitesine sahip olmaktadır. Bu tür sistemler, bireylerin hem fiziksel hem de duygusal sağlıklarını takip ederek, daha bütünsel bir sağlık yönetim yaklaşımını mümkün kılabilir. Nesnelerin interneti tabanlı GSR uygulamaları, stres ve duygusal durumların izlenmesinde ve yönetilmesinde büyük bir potansiyele sahiptir. Sağlık, eğitim, işyeri, kişisel fitness ve sosyal etkileşim gibi çeşitli alanlarda, bu cihazlar bireylerin fizyolojik ve psikolojik sağlıklarını optimize etme konusunda etkili bir araç olarak kullanılmaktadır. Gelişen teknoloji ile, bu sistemlerin daha da yaygınlaşması ve etkinliklerinin artması beklenmektedir (Guk vd., 2019).

#### **1.4. Eğitim ve İnsan-Bilgisayar Etkileşimlerinde Galvanik Deri Tepkisi**

GSR, cilt yüzeyindeki elektriksel iletkenlik değişikliklerini ölçen biyometrik bir parametredir. Bu ölçümler, bireylerin duygusal yanıtlarını özellikle stres, heyecan, korku, mutluluk gibi duygusal tepkileri algılayabilmeyi sağlamaktadır. GSR, bu nedenle, özellikle eğitimde ve Human Computer Interaction (HCI) gibi alanlarda kullanılarak, bireylerin duygusal durumlarını anlamak ve bu verilere dayalı olarak müdahalelerde bulunmak için büyük bir potansiyele sahiptir. Bu yazıda, GSR'nin eğitim ve HCI alanlarındaki kullanımı, örnekler ve araştırmalarla detaylandırılacaktır (Richardson ve Rothstein, 2008).

##### **1.4.1. Eğitimde galvanik deri tepkisi kullanımı**

Eğitimde GSR'nin kullanımı, öğrencilerin duygusal durumlarını gerçek zamanlı olarak izleyerek daha kişiselleştirilmiş ve etkili bir öğrenme ortamı yaratılmasına olanak tanımaktadır. Özellikle stres, motivasyon eksiklikleri ve duygusal durumlar öğrencilerin öğrenme süreçlerini doğrudan etkileyebilmektedir. GSR, öğretmenlerin ve eğitimcilerin öğrencilerin psikolojik durumlarını izlemelerine ve buna göre müdahalelerde bulunmalarına yardımcı olabilmektedir.

Bir öğrencinin sınav sırasında yaşadığı stres, onun başarı seviyesini doğrudan etkilemektedir. GSR sensörleri, öğrencinin cilt iletkenliğini ölçerek stres seviyesini

belirlenmektedir. Bu veri, öğretmenlerin öğrencilerin sınav stresini yönetmesine veya sınav içeriğini öğrencinin stres seviyesine göre uyarlamasına olanak sağlamaktadır. Böylece, eğitim süreçleri daha verimli hale gelmektedir (Ertek ve Aydintan, 2024). Bir araştırmaya göre, öğrencilerin ders sırasında yaşadıkları duygusal değişiklikler (stres, sıkılma, ilgi) GSR verileriyle izlenebilmekte ve bu veriler öğretmenlerin, öğrencilerin ne zaman yardıma ihtiyaç duyduklarını anlamalarına yardımcı olmaktadır (Bardwell vd., 2024). Öğrencilerin daha zorlandıkları konular, duygusal yanıtları izlenerek tespit edilebilmekte ve öğretmenler bu konuda ek materyal veya destek sunmaktadır.

#### **1.4.2. İnsan bilgisayar etkileşiminde galvanik deri tepkisi kullanımı**

HCI, kullanıcıların bilgisayar sistemleriyle etkileşimde bulundukları süreçleri inceleyen bir disiplindir. GSR, bu alanda, kullanıcının bir sistemle etkileşimi sırasında yaşadığı duygusal tepkileri ölçmek için kullanılabilir. Özellikle oyunlar, eğitim yazılımları veya simülasyonlar gibi etkileşimli sistemlerde, kullanıcıların sistemle etkileşimde bulunduğu anlarda stres, heyecan veya sıkılma gibi duygusal yanıtları takip etmek önemlidir.

GSR sensörleri, kullanıcıların bir arayüzle etkileşime girdiklerinde yaşadıkları duygusal değişimleri ölçerek, sistem tasarımcılarına geri bildirim sağlamaktadır. Bir kullanıcı bir eğitim yazılımını kullanırken zorlanabilmekte veya heyecanlanabilmektedir. Bu anlar, GSR sensörleri aracılığıyla ölçülerek, sistemin kullanıcıyı nasıl etkilediği anlaşılmaktadır. Bu bilgi, sistem tasarımcılarının, kullanıcı deneyimini daha etkili hale getirmeleri için kullanabileceği önemli veriler sunmaktadır (Motta vd., 2023).

GSR'nin oyun tasarımında kullanımı ele alınabilmektedir. Eğitim amaçlı oyunlar, kullanıcıların zihinsel ve duygusal durumlarını izleyerek, ne zaman heyecanlandıklarını veya zorlandıklarını tespit edebilmektedir. Bu veriler, oyunun zorluk seviyesini dinamik olarak ayarlamak için kullanılabilir. Bir oyuncu stresli bir duruma girdiğinde oyun otomatik olarak yardımcı ipuçları sunabilmekte veya zorluk seviyesini düşürebilmektedir.

### **1.4.3. Galvanik deri tepkisi ve duygusal durumların izlenmesi**

Eğitimde ve HCI'de GSR'nin en büyük avantajlarından biri, kullanıcının duygusal durumlarını objektif bir şekilde izleyebilmesidir. Bu veriler, kullanıcı veya öğrenci için daha iyi bir deneyim yaratmak amacıyla müdahalelerde bulunulmasına olanak tanımaktadır. Eğitimde, öğrencilerin zihin durumlarını izlemek, onların öğrenme deneyimlerini kişiselleştirmek için faydalıdır. HCI'de ise, sistemlerin daha kullanıcı dostu ve etkili olmasını sağlamak için kullanılmaktadır.

GSR verilerinin analizi, özellikle karmaşık etkileşimli sistemlerde büyük önem taşımaktadır. Bir HCI araştırmasında, kullanıcıların etkileşim sırasında yaşadıkları stres seviyesi ölçülerek, sistemin kullanıcılar üzerindeki etkisi değerlendirilmektedir. Bu veriler, kullanıcıların hangi aşamalarda zorluk yaşadığını veya hangi özelliklerin daha etkili olduğunu belirlemeye yardımcı olmaktadır (Greenwood ve Fleshner, 2011).

### **1.4.4. Eğitimde ve insan bilgisayar etkileşiminde galvanik deri tepkisi kullanımının geleceği**

Teknolojinin gelişmesiyle birlikte GSR, eğitim ve HCI alanlarında daha yaygın bir şekilde kullanılması ön görülmektedir (Fairclough, 2009). Özellikle nesnelerin interneti tabanlı giyilebilir cihazların artan popülaritesi ile, öğrencilerin ve kullanıcıların duygusal durumları daha hassas bir şekilde izlenebilmektedir. Bu, daha etkili eğitim yöntemlerinin geliştirilmesine, kullanıcı merkezli tasarımların oluşturulmasına ve duygusal yanıtların doğru bir şekilde yönetilmesine olanak tanıyacaktır (Altunışık vd., 2004). Özellikle eğitimde, GSR verilerinin toplanması, öğretmenlerin öğrencilerin bireysel ihtiyaçlarını daha iyi anlamalarına yardımcı olacaktır. Aynı şekilde, HCI alanında, kullanıcı geri bildirimleri ile sistemler daha verimli hale gelmektedir. Eğitim yazılımları, oyunlar ve diğer etkileşimli sistemler, kullanıcıların duygusal durumlarına tepki verecek şekilde tasarlanabilmektedir (Hook, 2008).

GSR, eğitim ve HCI alanlarında duygusal durumları izlemek ve bu verilere dayalı müdahalelerde bulunmak için güçlü bir araçtır. GSR sensörleri, bireylerin duygusal

tepkilerini ölçerek, daha etkili eğitim ortamları yaratılmasına ve kullanıcı dostu sistemlerin geliştirilmesine katkı sağlamaktadır. Bu teknolojinin, özellikle nesnelerin interneti ve giyilebilir cihazlarla entegrasyonu, gelecekte daha kişiselleştirilmiş ve verimli çözümler sunması ön görülmektedir.

### **1.5. Giyilebilir Teknolojiler ve Galvanik Deri Tepkisi**

Giyilebilir teknolojiler, son yıllarda sağlık, spor, eğitim ve insan-bilgisayar etkileşimi gibi birçok alanda devrim yaratmaktadır (Taskasaplidis vd., 2024). Bu teknolojiler, kullanıcıların vücutlarına takılan sensörler aracılığıyla veri toplamakta ve bu veriler bireylerin fiziksel ve psikolojik durumları hakkında önemli bilgiler sağlamaktadır. GSR, cilt yüzeyindeki elektriksel iletkenlikteki değişiklikleri ölçen bir biyometrik parametredir. GSR, duygusal durumların izlenmesinde, özellikle stres, heyecan, korku, mutluluk gibi tepkilerin değerlendirilmesinde etkili bir araçtır. Giyilebilir cihazlar ile GSR ölçümü, bu parametrenin daha kolay ve sürekli bir şekilde izlenmesine olanak tanır, böylece bireylerin duygusal durumları hakkında anlık veriler elde edilmektedir.

#### **1.5.1. Giyilebilir teknolojiler ve galvanik deri tepkisi uygulamaları**

Giyilebilir cihazlar, genellikle akıllı saatler, bileklikler, giysiler ve başlıklar gibi çeşitli formlarda tasarlanmaktadır. Bu cihazlar, kullanıcının fiziksel aktivitelerini, kalp atış hızını, vücut sıcaklığını, adım sayısını ve GSR gibi biyometrik verileri toplamak için sensörler kullanılmaktadır (Taskasaplidis vd., 2024). GSR verilerinin toplanması, bu verilerin analiz edilmesi ve stres gibi duygusal tepkilerin ölçülmesi için önemlidir. Özellikle nesnelerin interneti teknolojisinin artan kullanımı ile bu veriler, uzaktan izlenebilmekte ve analiz edilebilir hale gelmektedir.

Giyilebilir cihazlar, kullanıcıların stres seviyelerini ölçebilmek için GSR'yi kullanarak birçok faydalı uygulama sunmaktadır. Sağlık takibi yapan cihazlar, bir bireyin stres seviyesinin yüksek olduğu anları tespit edebilmekte ve bu durumda, cihaz otomatik olarak kullanıcıya dinlenmesi veya gevşemesi için hatırlatmalar gönderebilmektedir (Brothers vd., 2020). Ayrıca, sporcuların performanslarını

izlemek ve antrenman sırasında yaşadıkları aşırı stres durumlarını önlemek amacıyla GSR ölçümü kullanılarak, daha verimli ve sağlıklı antrenmanlar planlanabilmektedir.

### **1.5.2. Eğitimde giyilebilir teknolojiler ve galvanik deri tepkisi**

Giyilebilir teknolojiler ve GSR, eğitim alanında da giderek daha fazla kullanılmaktadır. Öğrencilerin duygusal durumlarını izlemek, öğrenme süreçlerini optimize etmek için çok önemlidir. Özellikle öğrenme sırasında yaşanan stres, sıkılma veya heyecan gibi durumlar, öğrencinin başarı seviyesini doğrudan etkileyebilmektedir. Giyilebilir cihazlar, öğrencilerin duygusal durumlarını izleyerek, öğretmenlerin gerektiğinde müdahale etmelerini sağlamaktadır.

Bir araştırmaya göre, öğrencilerin öğrenme süreçlerinde yaşadıkları duygusal değişiklikler, GSR sensörleri ile ölçülerek, öğretmenlere öğrenci performansı hakkında değerli bilgiler sunmaktadır. Bu sayede, öğretmenler, öğrencilerin sıkıldıkları veya zorlandıkları konuları tespit ederek, eğitim yöntemlerini kişiselleştirmektedir. Ayrıca, eğitimde kullanılan giyilebilir cihazlar, öğrencilerin dikkat düzeylerini de izlemektedir. GSR verileri, öğrencilerin derslere olan ilgisini veya dikkatinin dağılmasını gösteren bir gösterge olabilmektedir. Böylece, öğretmenler gerektiğinde dersin temposunu ayarlayabilmekte veya öğrencilere daha fazla etkileşimli materyal sunabilmektedir.

### **1.5.3. Sağlık alanında giyilebilir teknolojiler ve galvanik deri tepkisi**

Giyilebilir teknolojilerin sağlık alanındaki uygulamaları, GSR'nin en yaygın kullanıldığı alanlardan biridir. GSR, özellikle stres ve anksiyete gibi psikolojik durumların izlenmesinde faydalıdır. Giyilebilir cihazlar, kullanıcıların stres seviyelerini izlerken, bu verileri mobil cihazlar aracılığıyla sağlık profesyonellerine iletmektedir. Bu cihazlar, bireylerin ruh halini, stres seviyelerini ve genel sağlık durumlarını sürekli olarak izlemeyi mümkün kılmaktadır (Atlee vd., 2014).

"EmoReact" adlı bir giyilebilir cihaz, kullanıcıların duygusal durumlarını izlerken GSR'yi temel biyometrik parametre olarak kullanmaktadır. Bu cihaz, kullanıcıların

stres seviyelerini tespit ederek, onlara gevşeme egzersizleri veya nefes alıştırıcıları önermektedir. Bu tür cihazlar, stresin vücutta yarattığı olumsuz etkileri minimize etmeye yardımcı olabilmekte ve bireylerin zihinsel sağlıklarını iyileştirebilmektedir (Brothers vd., 2020).

#### **1.5.4. İnsan bilgisayar etkileşiminde giyilebilir teknolojiler ve galvanik deri tepkisi**

Giyilebilir cihazlar, HCI alanında da önemli bir rol oynamaktadır. Kullanıcıların bilgisayar sistemleriyle etkileşimde bulundukları süreçlerde GSR verilerinin toplanması, sistemin daha kişisel ve kullanıcı dostu hale getirilmesine olanak tanımaktadır. Özellikle sanal gerçeklik ve artırılmış gerçeklik gibi etkileşimli sistemlerde, galvanik deri reaksiyonu kullanılarak kullanıcıların stres seviyeleri tespit edilmektedir. Bu sistemler, kullanıcıların duygusal durumlarını gerçek zamanlı izleyerek etkileşimi geliştirmeye olanak tanımaktadır (Akleyek vd., 2020). Bu veriler, sistem deneyimini daha kişiselleştirmek ve kullanıcıya özel bir etkileşim sunmak için kullanılabilir. Bir sanal gerçeklik oyununda, GSR sensörleri ile oyuncunun stres seviyesi izlenebilmektedir (Chen vd., 2020). Eğer oyuncu oyunun zor bir aşamasında aşırı stres yaşıyorsa, oyun otomatik olarak zorluk seviyesini düşürmekte veya daha fazla yardımcı ipuçları sunmaktadır. Bu sayede, oyuncunun deneyimi daha dengeli ve eğlenceli hale gelmektedir. Giyilebilir cihazlar, ayrıca eğitim yazılımlarında, kullanıcının sıkılma, ilgi kaybı gibi duygusal durumlarını izleyerek, yazılımın etkileşimli içeriğini buna göre ayarlayabilmektedir (Edoh ve Degila, 2019).

#### **1.5.5. Gelecek perspektifi**

Giyilebilir teknolojilerin ve GSR'nin geleceği, nesnelerin interneti ve yapay zekâ (AI) teknolojilerinin entegrasyonu ile daha da parlak görünmektedir (Taskasaplidis vd., 2024). Nesnelerin interneti tabanlı cihazlar sayesinde, GSR verileri gerçek zamanlı olarak toplanabilmekte ve analiz edilebilmektedir. Ayrıca, yapay zekâ algoritmaları bu verileri daha ayrıntılı bir şekilde analiz ederek bireylerin duygusal durumları hakkında daha doğru tahminlerde bulunmaktadır. Bu teknolojiler, eğitimde kişiselleştirilmiş öğrenme deneyimlerinin oluşturulmasında, sağlık takibinde ruhsal

sağlığın izlenmesinde ve insan-bilgisayar etkileşiminde daha etkileşimli ve kullanıcı dostu sistemlerin tasarlanmasında önemli bir rol oynayacaktır.

## **1.6. Nesnelerin İnterneti Uygulamaları**

Nesnelerin interneti, fiziksel nesnelerin internet üzerinden birbirleriyle ve merkezi bir sistemle veri alışverişinde bulunmasına olanak tanıyan bir ağ teknolojisidir (Ashton, 2009). Nesnelerin interneti, günümüzde sağlık, eğitim, ulaşım, üretim ve yaşam alanlarında geniş bir uygulama yelpazesinde kullanılmaktadır. Bu uygulamalar, sensörler ve cihazlar arasındaki iletişimle gerçek zamanlı verilerin toplanmasını ve analiz edilmesini sağlamaktadır. Nesnelerin internetinin sunduğu fırsatlar, bireylerin yaşam kalitesini artırmak, işletmelerin verimliliklerini optimize etmek ve sağlık hizmetlerinde devrim yaratmak için önemli bir potansiyele sahiptir.

### **1.6.1. Nesnelerin interneti uygulamaları ve sağlık**

Sağlık alanında nesnelerin interneti uygulamaları, özellikle uzaktan sağlık takibi ve biyometrik veri izleme konusunda büyük ilerlemeler kaydetmiştir. Giyilebilir cihazlar ve sensörler, kişilerin sağlık verilerini (kalp atış hızı, adım sayısı, cilt sıcaklığı, stres seviyeleri vb.) sürekli olarak izlemektedir. Bu veriler, bir merkezi sistemde toplanarak, sağlık profesyonelleri veya kullanıcılar tarafından analiz edilmektedir. Akıllı bileklikler ve saatler, kullanıcıların kalp atış hızını izlerken, stres seviyelerini ölçmek için GSR sensörleri de kullanmaktadır (Patel vd., 2012).

Nesnelerin interneti tabanlı sağlık uygulamaları, özellikle kronik hastalıkların yönetimi konusunda önemli bir rol oynamaktadır. Diyabet hastaları, nesnelerin interneti cihazları ile kan şekeri seviyelerini izlerken, kalp hastalığına sahip bireyler, nesnelerin interneti destekli cihazlarla düzenli olarak EKG izlemeleri yapabilmektedir. Bu tür cihazlar, kullanıcıların sağlık durumunu gerçek zamanlı olarak izlerken, acil bir durum meydana geldiğinde doktorlara bildirim gönderebilmektedir (Malathi vd., 2024).

### 1.6.2. Nesneleri interneti ve eğitim

Eğitimde nesnelerin interneti uygulamaları, öğrenme süreçlerini daha etkileşimli ve verimli hale getirmeyi amaçlamaktadır. Özellikle sınıflarda kullanılan akıllı tahtalar, öğrencilerin öğrenme düzeylerine göre içerik sunabilmekte ve öğretmenlerin öğrencilerin gelişimlerini izlemelerine olanak sağlamaktadır. Bununla birlikte, nesnelerin internetitabanlı giyilebilir cihazlar, öğrencilerin fiziksel ve duygusal durumlarını izlemektedir. Öğrencilerin stres seviyelerini ölçmek için GSR sensörleri kullanılarak, öğrencinin öğrenme sürecinde yaşadığı zorluklar belirlenmekte ve eğitim içeriği buna göre özelleştirilebilmektedir. Ayrıca, nesnelerin internetinin eğitimdeki bir diğer kullanımı, öğrencilerin hareketliliğini takip etmek ve sınıf içindeki dikkat düzeylerini ölçmektedir. Bu tür izleme, öğrencilerin hangi derslerde veya hangi konularda daha fazla ilgi gösterdiklerini tespit edebilmek için oldukça yararlıdır. Bu sayede, öğretmenler daha kişiselleştirilmiş eğitim yöntemleri geliştirmektedir.

Nesnelerin interneti, çok çeşitli alanlarda yenilikçi uygulamalarıyla hızla büyüyen bir teknolojidir. Sağlık, eğitim, ulaşım ve endüstri gibi sektörlerde nesnelerin internetinin kullanımı, yaşam kalitesini artırmak, verimliliği optimize etmek ve güvenliğini sağlamak için büyük fırsatlar sunmaktadır. Bu teknolojilerin entegrasyonu ve geliştirilmesi, gelecekte daha fazla sektörü etkileyecek ve günlük yaşamı daha verimli hale getirecektir.

## 2. KAYNAK ÖZETLERİ

Tang vd. (2014), bireyler arasındaki stres durumlarını belirlemek için hibrit bir ontoloji tabanlı stres tespit çerçevesi önermektedir. Bu çerçeve, sosyal medyada stresle ilişkili paylaşımların doğru şekilde analiz edilmesini sağlamakta ve potansiyel olarak intihar öncesi müdahalelere yönelik faydalı bir araç olarak değerlendirilmektedir.

Savcı ve Aysan (2014) yaptıkları çalışmada, üniversite öğrencilerinin yaşadığı stres düzeylerini ve bu stresle başa çıkmada kullandıkları stratejileri incelemektedir. Araştırmanın sonuçları, yüksek stres seviyelerinin öğrencilerin akademik başarılarında belirgin bir düşüşe yol açtığını ortaya koymaktadır. Ayrıca, duyguların düzenleme stratejilerinin ve problem çözme becerilerinin stresle baş etmede önemli rol oynadığı belirtilmektedir.

Çalışkan (2016) çalışmasında, elektrodermal aktivitenin kronik obstrüktif akciğer hastalığı (KOAH) olan bireylerdeki değişimleri incelenmekte ve sinyallerin nonlineer özellikleri analiz edilmektedir.

Yaman (2018) çalışmasında, galvanik cilt tepkisi (GSR) ve göz takibi teknikleri birleştirilerek biyometrik ölçüm alanında yenilikçi bir yaklaşım sunulmaktadır. Araştırma, özellikle insan duygularının ve stres seviyelerinin tespitinde bu iki biyometrik yöntem arasında güçlü bir ilişki olduğunu ortaya koymaktadır. Göz hareketlerinin analizi ile GSR verilerinin senkronize kullanımı, stres algılama ve duygusal durumların daha hassas bir şekilde analiz edilmesine olanak tanımaktadır. Çalışma, stres altında bireylerin biyometrik verilerini analiz ederek eğitim, sağlık, insan-makine etkileşimleri ve güvenlik gibi alanlarda uygulanabilir çözümler önermektedir (Gökdeniz, 2025). Elde edilen bulgular, iki yöntemin kombinasyonunun, tek başına kullanılan GSR veya göz takibi yöntemlerinden daha yüksek doğruluk sağladığını göstermektedir. Çalışma ayrıca, nesnelerin interneti tabanlı sistemlere uyarlanabilir bir temel oluşturarak, giyilebilir teknolojilerle entegre edilebilecek çok modlu biyometrik sistemlerin önemine vurgu yapmaktadır. Bu nedenle, stres algılama sistemleri üzerine yapılan araştırmalara teorik ve pratik

katkılar sunmakta ve ilgili alanda daha fazla çalışmayı teşvik etmektedir (Elahi ve Islam, 2019).

Can vd. (2020) çalışmasında giyilebilir cihazlar ile stres algılama ve yönetim yöntemlerini geliştirmeyi hedeflemekte ve GSR ile kalp atış hızı gibi biyofizyolojik sinyalleri incelemektedir. Ayrıca, çalışmalarında stresin kümelenmesine odaklanmış ve bireyden bağımsız bir yaklaşım sunmaktadır. Katılımcı olarak seçilen bir grup bireyin bileklerine takılan cihazlar aracılığıyla veri toplanmaktadır. Çalışmanın sonucunda, stres seviyelerinin üç farklı kategoride ayrımı başarıyla gerçekleştirilmektedir.

Akleyek vd. (2020), stres seviyelerinin belirlenmesi amacıyla bir model geliştirmektedir. Bu modelde, basınç, kalp atış hızı, vücut ısı ve karbondioksit gazını algılayabilen sensörler kullanılmakta, elde edilen veriler nesnelerin interneti üzerinden iletilmektedir.

Sağbaş vd. (2020), stresin etkilerini analiz etmek için akıllı telefonların dokunmatik ekranlarından elde edilen verilerden yararlanmaktadır. Çalışmada, 46 katılımcıdan toplanan veriler kullanılarak üç ayrı veri kümesi oluşturulmuş ve bu küme üzerinden toplamda 112 öznitelik tanımlanmaktadır. Tanımlanan öznitelikler, Kazanç Oranı algoritması yardımıyla sıralandıktan sonra C4.5 Karar Ağaçları, Bayes Ağları ve KNN yöntemleriyle sınıflandırılmıştır. Sınıflandırma işleminin sonuçları sırasıyla %74.26, %67.86 ve %87.56 doğruluk oranlarıyla başarılı sonuçlar elde edilmesini sağlanmaktadır (Sağbaş vd., 2020).

Ciabattoni vd. (2020), klavye ve fare kullanımına dayalı bir stres algılama sistemi tasarlanmaktadır. Bu sistem üç ana aşamadan oluşmaktadır. İlk aşamada, bir web uygulaması aracılığıyla klavye ve fare hareketlerinden veri toplanmış ve kullanıcılar belirli görevler esnasında değerlendirilmektedir. İkinci aşamada, toplanan verilerden öznitelik çıkarımı yapılmakta ve seçilen öznitelikler belirlenmektedir. Son aşamada ise, elde edilen bu öznitelikler kullanılarak oluşturulan stres sınıfları, üç farklı makine öğrenimi algoritmasıyla test edilmektedir (Ciabattoni vd., 2020). Ma ve araştırma ekibi, COVID-19 pandemisi sırasında artan stres seviyelerinin bireylerin

zihinsel sađlıđı zerindeki etkilerini inceleyen bir sistematik alıřma yrtmřlerdir (Vindegard ve Benros, 2020).

Lan ve arařtırma ekibi, eczacılar zerinde gerekleřtirdikleri bir anket alıřması ile rgtsel iklim, iř stresi, tkenmiřlik dzeyleri ve eczacıların iřte kalma niyeti arasındaki bađlantıları incelemektedir. alıřma sonuları, rgtsel iklimin iyileřtirilmesinin, eczacıların iř stresini azaltarak tkenmiřlik seviyelerini dřrebileceđini ve iřte kalma niyetlerini glendirebileceđini ortaya koymaktadır. Bununla birlikte, sađlıklı bir alıřma ortamı oluřturabilmek iin yneticilerin rgtsel iklimi iyileřtirme ynnde adımlar atmalarının nemine dikkat ekilmektedir (Lan vd., 2020).

Bobade ve Vani, bireylerde stresin tespit edilmesi iin giyilebilir fizyolojik ve hareket sensrlerinden elde edilen veri kmelerini analiz etmekte ve bu verilere dayalı eřitli makine đrenimi ve derin đrenme teknikleri nermektedir. Sensrlerden elde edilen veriler hem  sınıflı hem de ikili sınıflandırmalar iin deđerlendirilmiř ve %81.65 ile %93.20 arasında deđerren dođruluk oranları elde edilmektedir. Derin đrenme yntemleri ile ise sırasıyla %84.32 ve %95.21 oranlarında dođruluk sonuları elde edilmektedir (Bobade ve Vani, 2020).

Sađbař vd. (2021), mobil cihazlar zerinde bireylerin yazma davranıřlarını analiz ederek stres seviyelerindeki deđeriklikleri incelemiřlerdir. Arařtırmada elde edilen sonular, yazma davranıřlarının incelenmesi yoluyla stres seviyelerinin llebileceđini gstermiřtir. Bařka bir arařtırmada, havacılık sektrnde stresin eřitli alanlardaki etkileri incelenmiřtir. Yođun stresin, uuř gvenliđi, yer hizmetlerinin srekli liđi, kabin ekibinin motivasyonu ve pilotların performansı zerinde nemli bir rol oynadıđı vurgulanmıřtır (Aksu ve Odabař, 2021). Srekli stres uyaranlarına maruz kalmanın, iř stresi, performans dřř ve sađlık problemleri gibi olumsuz sonulara yol atıđı belirlenmiřtir (Yılmaz ve Mubayed, 2023). Bu olumsuz etkileri ynetebilmek adına egzersiz yapmak, uyku dzenine dikkat etmek, mzik dinlemek ve dikkat dađıtıcı etkinliklere ynelmek gibi bařa ıkma stratejileri nerilmektedir (Aksu ve Odabař, 2021). Arařtırmanın bulguları, stres ynetimi uygulamalarının performansı artırarak verimliliđi olumlu ynde etkilediđini ortaya koymaktadır (Yılmaz ve Mubayed, 2023). Sađbař vd. (2021) tarafından yapılan bir

diğer çalışmada, yalnızca akıllı telefon verilerini kullanarak stres tespiti gerçekleştirilmiştir. Bu araştırma, aynı alanda çalışan araştırmacılara rehberlik etmeyi amaçlamaktadır. Çalışmada kullanılan sınıflandırma yöntemleri karşılaştırılmış ve istifleme yönteminin diğer tekniklere göre daha üstün bir performans sergilediği ortaya konulmaktadır (Sağbaş vd., 2021).

Mou vd. (2021), sürücülerin stres seviyelerini ölçmek için dikkat tabanlı derin öğrenme tekniklerini içeren bir model geliştirmiştir. Tabii, cümleyi intihal riskini azaltacak şekilde yeniden yazdım: Önerilen sistem, göz, araç ve çevresel verileri birleştirerek sürüş sırasında stres tespiti için bir çerçeve sunmaktadır. Yapılan simülasyon testlerinde, bu çerçeve ile %95.5 doğruluk oranı elde edilmiştir.

Özsezer ve Ataç (2021) yaptıkları çalışmada, sanal gerçeklik (VR) teknolojisinin bireysel farkındalığı artırma ve refahı geliştirme potansiyelini incelemişlerdir. Literatür taramasında, VR'nin, dikkat dağınıklığını azaltarak bireylerin daha odaklanmış bir şekilde çevreleriyle etkileşimde bulunmalarını sağladığı ve mindfulness tabanlı stres yönetimi programlarında stres, kaygı, anksiyete, travma sonrası stres bozukluğu, yeme bozuklukları ve ağrı tedavilerinde etkili bir araç olarak kullanılabileceği ifade edilmektedir. Ancak, hemşirelik alanındaki uygulamalarda VR'nin kullanımına yönelik araştırmaların sınırlı olduğu ve bu alanda daha fazla incelemeye ihtiyaç duyulduğu vurgulanmıştır. Çalışma, hemşirelik uygulamaları ve eğitiminde yeni teknolojilerin entegrasyonunun hemşire-hasta ilişkilerini olumlu yönde etkileyebileceğini ortaya koymuştur.

Didin ve Yavuz (2022) yaptıkları çalışmada, COVID-19 pandemisi sürecinde öğrencilerin stres, anksiyete, depresyon ve korku düzeylerini etkileyen etmenleri literatür taraması yöntemiyle analiz etmişlerdir. Bu tarama sonucunda 14-33 yaş aralığında 562 çalışmaya ulaşılmış ve öğrencilerin anksiyete, korku ve depresyon seviyelerinin; cinsiyet, sağlık durumu, enfeksiyon korkusu, hastalık hakkında bilgi seviyesi, koruyucu ekipmanların yeterliliği, aile yapısı, ekonomik koşullar, sosyal destek, ebeveynlerle yaşama durumu, hastalığa bakış açıları ve madde kullanımı gibi faktörlerle ilişkili olduğu saptanmıştır. Araştırma bulguları, öğrencilerin çoğunlukla orta düzeyde anksiyete yaşadığını ve kız öğrencilerin, erkek öğrencilere kıyasla

anksiyete ve depresyon düzeylerinin daha yüksek olduğunu ortaya koymaktadır (Didin ve Yavuz, 2022).

Timurtaş ve çalışma arkadaşları (2022), stres ve uyku arasındaki bağlantıyı analiz etmek amacıyla, nesnelerin internetibulut yöntemi ile çalışan bir uç cihaz olan Akıllı Yoga Yastığı geliştirilmesini önermektedir (Timurtaş vd., 2022).

G lnar ve  alıřkan (2022) tarafından yapılan bir  alıřmada, stres inkontinansının kadınlar arasında en yaygın g r len inkontinans t r  olduėu ve bu durumun bireylerin yařam kalitesini ciddi řekilde etkileyebileceėi belirtilmektedir. Arařtırmacılar, konservatif tedavi yaklařımlarının, hastaya zarar vermeksizin semptomları hafifletme ve yařam kalitesini artırma a ısından ilk tercih olarak  nerildiėini ifade etmektedir. Bununla birlikte, hemřirelerin stres inkontinans tedavisinde kanıta dayalı bilgiye sahip olmaları gerektiėi ancak mevcut bilgi eksiklikleri nedeniyle bu bilgileri klinik uygulamalarda etkili bir řekilde kullanamadıkları vurgulanmaktadır. Ayrıca, Stevens Yıldız Modeli Bilginin D n ř m  gibi kanıta dayalı uygulama modellerinin, hemřirelik arařtırmalarının sistematik bir řekilde ger ekleřtirilmesine yardımcı olduėu ifade edilmektedir.  alıřma, stres inkontinansına y nelik bakım protokol n n bu modelin ařamaları ile oluřturulduėunu ve bu protokollerin klinik uygulamalarla kanıta dayalı bilgi arasında bir k pr  g revi g rd ė n  ortaya koymaktadır (G lnar ve  alıřkan, 2022). Bařka bir  alıřmada,  iftlik hayvanlarının saėlıėını koruma ve bu s re te stresin etkisi ele alınmıřtır. Modern  retim y ntemlerinde, evcilleřtirilen  iftlik hayvanlarının verimliliklerinin artırılması i in onlara kaliteli yemler verilerek doėru miktar ve oranlarda beslenmeleri saėlanmaktadır. Aynı zamanda, barınak kořullarının iyileřtirilmesi, hayvanların  zerindeki stres y k n n hafifletilmesi a ısından b y k  nem tařımaktadır. Doėal ortamlarında hayvanlar  evresel deėiřikliklere kolayca uyum saėlayabilirken,  iftlik kořullarında stres kaynakları daha fazladır. Yem deėiřiklikleri, hayvanların fizyolojik durumlarındaki deėiřimler ve bakım y netimindeki farklılıklar stres yaratabilmektedir. Bu stres fakt rleri, hayvanların saėlıklarını, verimliliklerini ve  r n kalitelerini olumsuz y nde etkilemektedir.  iftlik hayvanlarının bu stres etmenlerinden korunarak yetiřtirilmesi, saėlıklı ve kaliteli gıda  retimi i in en uygun y ntemdir ve aynı zamanda uluslararası pazarda rekabet avantajı saėlamaktadır (Demirel ve Demirel, 2022).

Alpay ve Çelik (2022) tarafından gerçekleştirilen bir derlemede, karmaşık travma konusuna odaklanılmıştır. Karmaşık travma, uzun süre boyunca ve tekrarlayan travmatik deneyimlerin sonucunda ortaya çıkangeleneksel travma sonrası stres bozukluğundan (TSSB) farklı klinik belirtilerle karakterize edilen bir durumdur. Dünya Sağlık Örgütü'nün (DSÖ), 2018 yılında yayımladığı Uluslararası Hastalık Sınıflandırması'nın (ICD-11) en son baskısında, karmaşık travma sonrası stres bozukluğu (KTSB) yeni bir tanı olarak tanımlanmıştır. Bu tanı, geleneksel TSSB'nin yanı sıra, duygusal düzenlemede bozulmalar, kişilerarası ilişkilerdeki zorluklar ve olumsuz benlik algısı gibi üç yeni belirtiyi içermektedir. Derleme, DSM-5 ile ICD-11 arasındaki TSSB tanı farklılıklarını ele almakta ve karmaşık TSSB'nin özellikleri, tarihsel arka planı ve diğer benzer bozukluklardan ayrımını incelemektedir. Ayrıca, karmaşık TSSB'nin tedavi yöntemleriyle ilgili mevcut çalışmalar da gözden geçirilmiştir (Alpay ve Çelik, 2022).

Göktaş ve Buldukoğlu (2022) çalışmalarında, iş stresi ve bunun psikiyatri hemşireliğine etkilerini incelemişlerdir. Psikiyatri hemşireliği, ruhsal bozuklukları olan hastalarla uzun süreli etkileşimde bulunmayı gerektiren bir meslek dalıdır. Bu alanda çalışan hemşireler, sürekli hasta ve yakınlarıyla iletişimde olduklarından, hastaların agresif davranışlar sergileyebilmesi ve kliniklerin kapalı kapı sistemine sahip olması gibi nedenlerle yoğun stresle karşılaşmaktadırlar. Böyle bir stres, hemşirelerin fiziksel ve psikolojik sağlıklarını olumsuz etkileyebilmekte, tükenmişlik sendromuna yol açabilmekte ve işten ayrılma kararlarını tetikleyebilmektedir. Ayrıca, hemşirelerin iş tatmini, çalışma koşulları, kurum politikaları, kişisel özellikleri ve meslektaşlarının tutumlarına bağlı olarak değişkenlik gösterebilmektedir. Bu nedenle, psikiyatri hemşireliğinde iş stresi ve iş doyumu arasındaki ilişkiyi anlamak, mesleki verimliliği artırmak açısından önemli görülmektedir.

Son yıllarda stres algılama ve yönetimi, teknolojinin gelişimiyle birlikte farklı boyutlarda ele alınmıştır. 2020 yılı itibarıyla yapılan çalışmalar, stresin çeşitli veri kaynakları ve yöntemlerle tespit edilmesi üzerine yoğunlaşmıştır. Sosyal medya gönderileri ve cihazlardan toplanan veriler, makine öğrenimi algoritmaları ve ontolojiler yardımıyla analiz edilmiştir. COVID-19 pandemisinin getirdiği psikolojik

yük, bu dönemde yapılan stres çalışmalarının odak noktalarından biri olmuştur. Aynı zamanda, bu dönem stresin bireysel ve toplumsal boyutlarıyla ele alınması açısından yeni bir bakış açısı sunmuştur. 2021'de stres yönetimi ve ölçümüne dair teknolojik yöntemler öne çıkmıştır. Akıllı telefonlardan elde edilen verilerin analizi, dikkat tabanlı derin öğrenme yöntemleri ve bireylerin yazma alışkanlıklarına yönelik yaklaşımlar gibi yenilikçi yöntemler uygulanmıştır. Öğretmenler, öğrenciler ve sürücüler gibi farklı gruplar üzerinde yapılan araştırmalar, stresin yönetimine ilişkin stratejilerin gerekliliğini ortaya koymuştur. Aynı zamanda, stresin hem kişisel hem de profesyonel başarı üzerindeki kritik etkisi ortaya konulmuştur. 2022 ve sonrası, stres algılama ve yönetimi için nesnelerin interneti ve giyilebilir sensörlerin kullanımını araştırmıştır (Lu vd., 2020).

Göktaş ve Buldukoğlu (2022)'nin çalışmasında, psikiyatri hemşirelerinin iş stresi ve iş doyumuna dair önemli bulgular ortaya konmuştur. Araştırmada, bu hemşirelerin ruhsal sorunları olan hastalarla uzun süreli çalışmaları, hasta ve hasta yakınlarıyla sürekli iletişim içinde olmaları, kapalı sistem kliniklerde görev yapmaları ve saldırganlık riski gibi faktörlerin, yoğun mesleki strese yol açtığı vurgulanmıştır. Bu durumun, hemşirelerde sağlık problemlerine, tükenmişlik sendromuna, iş bırakma oranlarının artmasına ve yaşam kalitesinin düşmesine yol açtığı ifade edilmektedir.

2022 yılında gerçekleştirilen birçok akademik çalışma incelendiğinde, stresin bireylerin fiziksel ve psikolojik sağlıkları üzerindeki olumsuz etkilerini incelemeye devam etmiş ve stresin azaltılmasıyla ilgili yöntemlerin etkinliğini değerlendirildiği gözlenmektedir. GSR, HR, BP, EKG ve solunum gibi fizyolojik parametreler, stresin objektif olarak değerlendirilmesi için temel araçlar haline gelmiştir. Sensör teknolojileri ve makine öğrenimi, özellikle erken stres tespiti ve yönetim stratejilerinin geliştirilmesinde kritik bir rol oynamaktadır.


Literatürde, stres yönetiminin bireysel fizyolojik parametrelerin bir kombinasyonu üzerinden gerçekleştirilmesinin daha etkin sonuçlar verdiği vurgulanmaktadır. Bu bağlamda, yeni teknolojiler ve yöntemler kullanılarak geliştirilen yaklaşımlar, bireylerin sağlıklı bir yaşam sürmesine ve performanslarını artırmasına olanak tanımaktadır. Makine öğrenimi algoritmaları, stresin tespiti ve yönetimi alanında önemli bir rol oynamaktadır. Bu algoritmalar, EEG verileri, galvanik deri reaksiyonu

gibi fizyolojik göstergeleri analiz ederek bireylerin stres seviyelerini belirlemeye yardımcı olmaktadır (Hoşgör ve Güngördü, 2022). Ayrıca, nesnelerin interneti tabanlı teknolojiler, bu verilerin gerçek zamanlı olarak izlenmesini mümkün kılmakta ve stres yönetiminde etkin çözümler sunmaktadır. Bu tür araştırmalar, stresin azaltılmasında ve stresli durumlarda performansın artırılmasında teknolojinin sağladığı imkanları vurgulamaktadır.

Elde edilen sonuçlar, daha etkili stres yönetimi stratejilerinin geliştirilmesi için bir temel oluşturmaktadır. Son üç yılda gerçekleştirilen stresle ilgili araştırmalar, stresin insan bedeni ve zihni üzerindeki etkilerine ilişkin önemli bulgular sunmuştur. Birçok çalışma, uzun süreli stresin kronik hastalıkların gelişimine neden olabileceğini ve bu nedenle stresle başa çıkmanın kritik bir öneme sahip olduğunu ortaya koymaktadır. Stresin; psikolojik rahatsızlıklar, uyku düzenindeki bozulmalar, kalp hastalıkları, sindirim sistemi problemleri ve hatta kanser gibi sağlık sorunlarına zemin hazırlayabileceği vurgulanmaktadır. Ayrıca, bu dönemde yapılan araştırmalar stresle başa çıkmanın çeşitli yollarını da gözler önüne sermiştir. Meditasyon, yoga, düzenli fiziksel aktivite, sağlıklı beslenme, yeterli uyku, sosyal destek ve terapi gibi yöntemler, stresin etkilerini azaltmada etkili stratejiler arasında yer almaktadır. Bu yöntemlerin kombinasyon halinde uygulanmasının daha güçlü sonuçlar verdiği de belirtilmiştir. Sonuç olarak, son yıllardaki stresle ilgili çalışmalar, stresin ciddi sağlık problemlerine yol açabileceğini ve stres yönetiminin büyük bir öneme sahip olduğunu kanıtlamaktadır. Ayrıca, stresle mücadele etmek için çeşitli yöntemlerin mevcut olduğu ve bu yöntemlerin birlikte kullanıldığında daha etkili bir yaklaşım sağladığı ortaya konulmuştur. Bu bulgular, bireylerin stresle daha iyi başa çıkmasına yardımcı olarak, sağlıklı ve dengeli bir yaşam tarzının benimsenmesine katkı sunmaktadır.

### 3. MATERYAL VE YÖNTEM

Bu çalışmada, stres ve bilişsel yük seviyelerinin doğru bir şekilde tahmin edilebilmesi amacıyla gerçekleştirilen sistematik literatür taraması, mevcut tüm ilgili literatürün derli toplu bir şekilde toplanmasını, incelenmesini, birleştirilmesini ve raporlanmasını içeren kapsamlı bir süreç olarak uygulanmıştır (Aydın vd., 2021). Literatür tarama süreci, araştırmanın doğruluğunu ve güvenilirliğini artırmak amacıyla sistematik bir yöntemle planlanmış ve her adım dikkatlice izlenmiştir. Bu adımlar arasında; araştırma kapsamının belirlenmesi, araştırma sorusuna uygun anahtar kelimelerle arama stratejilerinin oluşturulması, seçilen veri tabanları üzerinden yapılan makale taramaları, seçim kriterlerinin belirlenmesi, elde edilen verilerin çıkarılması ve analiz edilmesi, sonuçların sentezlenmesi ve nihayetinde bulguların raporlanması aşamaları yer almaktadır (Şekil 3.1).



Şekil 3.1. Literatür tarama süreci

Sistematik literatür tarama yöntemleri, araştırmaların şeffaflığını artırmayı, güvenilirliğini sağlamayı ve araştırma sorusuna yönelik geçerli sonuçlar elde etmeyi amaçlayan bir yaklaşımdır (Yıldırım ve Pekel, 2025). Bu süreç, anahtar kelimelerle

oluşturulan arama stratejisi doğrultusunda literatürdeki çalışmaları taramayı, araştırma konusu ile doğrudan ilişkili makalelerin dikkatlice seçilmesini, veri çıkarımı ve verilerin sentezini içermektedir. Bu metodoloji, araştırmanın geçerliliğini sağlayacak ve doğruluğunu artıracak bir süreç izlemeye olanak tanımış, aynı zamanda literatürdeki boşlukların ve mevcut eğilimlerin tespit edilmesini mümkün kılmaktadır (Şekil 3.1).

Bu çalışmada, bilişsel yük ve stres seviyelerinin belirlenmesi amacıyla kullanılan veriseti, katılımcıların farklı görevler sırasında ölçülen biyometrik ve çevresel parametreleri içermektedir. Bilişsel yük ve stres seviyelerinin objektif ölçümleri için kalp atış hızı, GSR, solunum hızı ve cilt sıcaklığı gibi fizyolojik parametreler kullanılmıştır. Bu parametreler, bireylerin stres altındaki biyolojik yanıtlarını ölçmeye yardımcı olurken, stres seviyelerinin doğru bir şekilde sınıflandırılmasına olanak tanımaktadır. Özellikle, bu parametreler zaman serisi verileri sunduğundan, derin öğrenme yöntemleriyle yapılan analizlerde zaman içindeki değişimler ve kalıplar değerlendirilebilmiştir.

Ek olarak, öznel değerlendirmeleri desteklemek amacıyla NASA TaskLoad Index (NASA TLX) ölçeği kullanılmıştır. NASA TLX, katılımcıların görevler sırasında hissettikleri zihinsel ve fiziksel yükü değerlendirerek, bilişsel yük seviyelerinin daha derinlemesine analiz edilmesine olanak tanımaktadır. Bu ölçek hem subjektif hem de objektif ölçümlerin birleştirilmesiyle daha kapsamlı bir stres değerlendirmesi yapılmasını sağlamaktadır.

Veri analizi sürecinde, stres seviyelerinin doğru bir şekilde sınıflandırılabilmesi için veriler biyometrik ve öznel veriler, makine öğrenimi ve derin öğrenme algoritmalarına uygun hale getirilmiştir. Veri analizi aşamasında, verilerin doğruluğunu ve güvenilirliğini sağlamak amacıyla veri temizleme, ön işleme ve istatistiksel analizler gerçekleştirilmiştir. Bu adımlar, eksik veri noktalarının giderilmesi, anormal değerlerin tespiti ve düzeltilmesi, veri normalizasyonu gibi işlemleri içermektedir. Bu işlemler sayesinde, verilerin tutarlılığı ve güvenilirliği artırılmış ve analiz sürecinde daha doğru sonuçlar elde edilmiştir (Cheung vd., 2021).

Makine öğrenimi ve derin öğrenme teknikleri, stres seviyelerinin doğru bir şekilde sınıflandırılabilmesi için bu verilerle eğitim yapılmasına olanak tanımıştır. Özellikle LSTM ağları ve RNN derin öğrenme modelleri, zaman serisi verileri üzerinde güçlü performans sergileyen tekniklerdir. Bu modeller, stres seviyelerinin tahmin edilmesi amacıyla eğitilmiş ve test edilmiştir. Derin öğrenme algoritmaları kullanılarak elde edilen modeller, katılımcıların stres seviyelerini tahmin edebilmek için optimize edilmiştir. Eğitim ve test süreçleri sırasında, modelin doğruluğu sürekli olarak değerlendirilmiş ve hiperparametre ayarlamaları ile performans iyileştirmeleri yapılmıştır. Ayrıca, aşırı öğrenme gibi olumsuz durumları engellemek amacıyla düzenleme teknikleri uygulanmıştır.

Bu çalışmada elde edilen biyometrik veriler ve öznel değerlendirmeler doğrultusunda, stres ve bilişsel yük seviyelerinin doğru bir şekilde sınıflandırılabilmesi için gerekli veriler toplanmış, işlenmiş ve analiz edilmiştir. Elde edilen sonuçlar, araştırma sorusuna yönelik geçerli ve güvenilir bulgular sunmakta olup, çalışmanın amacına ulaşmasını sağlamaktadır.

### **3.1. Verilerin Toplanması**

Bu çalışmada, bilişsel yük ve stres seviyelerinin belirlenmesi amacıyla çeşitli biyometrik ve çevresel veriler kullanılmıştır. "Segment CognitiveLoadDataset" adlı açık kaynak verisetinden alınmıştır (Quan, 2024). Bu veriseti, katılımcıların farklı görevler sırasında ölçülen biyolojik ve çevresel parametrelerini içermektedir.

Verisetinde yer alan ölçümler şunlardır:

- Kalp Atış Hızı: Katılımcının belirli bir süre içinde ölçülen ortalama kalp atış hızı (bpm cinsinden).
- GSR: Cilt üzerindeki elektriksel iletkenlik değişiklikleri, bireyin stres seviyesine bağlı olarak değişiklik göstermektedir (Quan, 2024).
- Solunum Hızı: Katılımcının dakikadaki solunum sayısını ifade eder.
- Cilt Sıcaklığı: Katılımcının belirli bir görev sırasında ölçülen cilt sıcaklığı değeri.

- NASA TLX: Bilişsel yükün değerlendirilmesinde kullanılan, zihinsel talep, fiziksel talep, zaman baskısı, performans, çaba ve hayal kırıklığı gibi alt boyutları içeren öznel değerlendirme ölçeği (Quan, 2024).

Veriseti, katılımcıların belirli görevleri yerine getirirken ve dinlenme anlarında toplanan verileri içermektedir. Katılımcıların bilişsel yük gerektiren belirli görevleri ("n2", "n3", "HP" gibi) tamamladıkları sırada alınan veriler ile dinlenme süreçlerinde (rest) alınan veriler karşılaştırılmıştır. Bu süreç, bilişsel yük değişimlerinin ve fizyolojik tepkilerin analiz edilmesine olanak sağlamaktadır (Quan, 2024).

Veriseti, laboratuvar ortamında kontrollü deneyler ile toplanmış olup, katılımcıların görevleri tamamlarken sergiledikleri fizyolojik değişimler kayıt altına alınmıştır. Ölçüm cihazları, katılımcının cilt yüzeyine yerleştirilen sensörler ve harici bir veri toplama ünitesi aracılığıyla sürekli olarak veri kaydı yapmıştır. Toplanan veriler, ilgili biyometrik sinyallerin işlenmesi ve bilişsel yük analizinin yapılması için uygun formatta düzenlenmiştir. Bu veriseti, çalışma kapsamında uygun şekilde işlenmiş, eksik veya hatalı veriler kontrol edilerek analiz için temizlenmiştir. Ayrıca, elde edilen veriler, istatistiksel analiz yöntemleri ve makine öğrenimi teknikleri kullanılarak işlenmiş, bilişsel yük değişimlerinin öngörülmesi için modeller oluşturulmuştur (Quan, 2024). Veriseti, stres seviyelerinin belirlenmesine yönelik olarak katılımcıların fizyolojik ve çevresel parametrelerini içermektedir. Çizelge 3.1.'de görüldüğü üzere, stres seviyesi tahmininde kullanılan temel biyometrik öznitelikler GSR, cilt sıcaklığı, HR ve RR olarak belirlenmiştir. Bu parametreler, stres seviyelerinin farklı yoğunluklarda sınıflandırılmasına olanak tanıyacak şekilde seçilmiştir. GSR değeri, bireyin terleme seviyesine bağlı olarak değişmekte olup, stres seviyesinin bir göstergesi olarak kullanılmaktadır. Benzer şekilde, cilt sıcaklığı, stresin fizyolojik etkilerini anlamada önemli bir değişkendir; çünkü stres altındaki bireylerde periferik damarların daralması nedeniyle cilt sıcaklığında düşüşler gözlemlenmektedir. HR ve RR ise bireyin stres durumuna göre değişiklik gösterebilen diğer önemli biyometrik göstergelerdir (Çizelge 3.1). Stres seviyeleri, fizyolojik tepkilerin değişimlerini daha iyi analiz edebilmek adına üç farklı kategori şeklinde belirlenmiştir. 0 seviyesi, düşük stres durumunu ifade etmekte olup, bireyin fizyolojik verilerinde minimum değişikliklerin gözlemlendiği durumları kapsamaktadır.

Çizelge 3.1. Stres seviyesi tahmininde kullanılan öznitelikler

|                |                          | Öznitelikler        |                  | Hedefler     |
|----------------|--------------------------|---------------------|------------------|--------------|
| GSR ( $\mu$ S) | Sıcaklık ( $^{\circ}$ C) | Kalp Atış Hızı (hr) | SolunumHızı (rr) | Stres Düzeyi |
| 1.77           | 34.48                    | 65.66               | 0.88             | 1            |
| 2.83           | 35.16                    | 67.33               | 0.98             | 2            |
| 1.84           | 34.58                    | 68.66               | 1.00             | 2            |
| ....           | ...                      | ...                 |                  | ...          |
| ....           | ...                      | ...                 |                  | ...          |
| 2.89           | 34.13                    | 70.66               | 0.95             | 1            |
| 2.89           | 33.99                    | 65.00               | 0.86             | 0            |
| 2.63           | 33.77                    | 70.66               | 0.86             | 2            |

1 seviyesi, orta düzey stres seviyesini ifade eder ve katılımcının fizyolojik göstergelerinde belirgin değişimler olmasına rağmen aşırı bir stres durumunun söz konusu olmadığı koşulları içermektedir. 2 seviyesi ise yüksek stres düzeyini temsil etmekte olup, bireyin fizyolojik verilerinde ciddi değişikliklerin gözlemlendiği ve stresin etkilerinin en belirgin olduğu durumları yansıtmaktadır.

Bu çalışma kullanılan "Segment Cognitive Load Dataset" adlı veriseti, açık veri kaynağından alınmıştır. Veriseti toplamda 824 satırdan oluşmakta olup, her bir satırda bir katılımcının belirli bir zaman dilimi içindeki fizyolojik ölçümleri ve stres seviyesi bulunmaktadır. Verisetinde yer alan ölçümler, belirli bilişsel görevlerin gerçekleştirilmesi sırasında ve dinlenme anlarında kaydedilen biyometrik verilerden oluşmaktadır. Toplanan veriler, makine öğrenimi ve derin öğrenme algoritmalarına uygun hale getirilerek ön işleme aşamalarından geçirilmiştir. Eksik veya hatalı veriler temizlenmiş, veri normalizasyonu gerçekleştirilmiş ve öznitelik seçimi yapılmıştır. Bu süreç, modelin doğruluğunu ve güvenilirliğini artırmak için kritik bir adım olup, veri işleme sürecinin titizlikle yürütülmesini sağlamıştır. Sonuç olarak, fizyolojik ve çevresel parametreler kullanılarak stres seviyelerinin tahmin edilmesi amacıyla çeşitli makine öğrenimi ve derin öğrenme modelleri geliştirilmiştir.

### 3.2. Verilerin Analizi

Bu çalışmada, toplanan GSR verileri, stres seviyelerinin doğru bir şekilde tahmin edilebilmesi için makine öğrenimi ve derin öğrenme algoritmalarıyla analiz edilmiştir. GSR, sıcaklık, solunum hızı ve kalp atışı önemli biyometrik parametreler

kullanılarak oluşturulan veriseti, makine öğrenimi yöntemlerine uygun hale getirilmiştir. Veri analizi sürecinde, stres seviyelerinin doğru bir şekilde sınıflandırılması amacıyla LSTM ve RNN derin öğrenme tekniklerinden yararlanılmıştır. Bu modeller, kullanıcının stres seviyelerini tahmin edebilmek için titizlikle eğitilmiş ve test edilmiştir. Ayrıca, hibrit modelin geliştirilmesinde dikkat katmanı kullanılarak, önceki katmanlardan gelen özniteliklere ağırlık atama işlemi gerçekleştirilmiş ve modelin tahmin doğruluğu artırılmıştır. Sonuç olarak, bu çalışma, stres tespiti için etkili, verimli ve uygun maliyetli bir çözüm geliştirmeyi amaçlamaktadır.

### 3.3. Yöntemler

Bu çalışmada, stres ve bilişsel yük tahminlerini iyileştirmek amacıyla makine öğrenme ve derin öğrenme yöntemlerini birleştiren hibrit bir model geliştirilmiştir. Modelde, makine öğrenme algoritmalarından gradyan artırma, rastgele orman ve destek vektör makineleri kullanılarak geleneksel yöntemlerin avantajları sağlanmaktadır. Derin öğrenme alanında ise RNN, LSTM ve GRU yöntemlerle zaman serisi verilerine yönelik güçlü regresyon modelleri oluşturulmuştur. Modelin yapısı, on bir katmandan oluşmakta olup, her bir katman belirli bir işlem ve öğrenme amacına hizmet etmektedir. İlk olarak, verisetindeki girdi değerleri alınmakta, ardından tanh aktivasyon fonksiyonuna sahip LSTM katmanları ile veriler işlenmektedir. Dropout katmanları, aşırı öğrenmeyi engelleyerek modelin genelleme yeteneğini artırmaktadır (Jeong vd., 2024). Modelde, GRU katmanı ile zaman serisi verileri hızlı ve verimli şekilde işlenirken, dikkat (attention) katmanı önceki katmanlardan gelen özniteliklere ağırlıklar atayarak tahmin performansını iyileştirmektedir. Sonuç olarak, bu hibrit model hem makine öğrenme yöntemlerinin açıklanabilirliğinden hem de derin öğrenme tekniklerinin güçlü örüntü tanıma yeteneklerinden yararlanarak stres ve bilişsel yük tahmin performansını artırmayı başarmaktadır.

#### 3.3.1. Gradyan arttırma karar ağacı algoritması

Daha güçlü olan sınıflandırıcıları daha yetersiz olan sınıflandırıcılar ile birleştirerek bir seri halinde bulunun sınıflandırıcılara Gradyan Arttırma Karar Ağacı algoritması

denilmektedir (Yuan ve Abouelenien, 2015; Wang vd., 2016). Gradyan azalma yöntemini kullanan algoritma yakınsamayı hedeflemektedir (Rao vd., 2019). Algoritmayı tanımlayan formüller Denklem (3.1)-(3.6) arasında sunulmuştur.

$$x_i = (x_{1i}, x_{2i}, \dots, x_{pi}) \quad (3.1)$$

$$y_i^* = \left[ \frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x) - F_{m-1}(x)}, i = \{1, 2, \dots, N\} \quad (3.2)$$

$$\beta_m = \arg \min_{\alpha, \beta} \sum_{i=1}^N L(y_i, F_{m-1}(x) + \beta h(x_i; a)) \quad (3.3)$$

$$F_0(x) = \arg \min_{\alpha, \beta} \sum_{i=1}^N L(y_i, \beta) \quad (3.4)$$

$$a_m = \arg \min_{\alpha, \beta} \sum_{i=1}^N (y_i^* - \beta h(x_i; a))^2 \quad (3.5)$$

$$F_m(x) = F_{m-1}(x) + \beta h(x_i; a) \quad (3.6)$$

Denklemlerdeki  $p$  tahmindeğerlerini gösterirken,  $y_i$  ise tahmin edilen etiket değerini ifade etmektedir. Denklem (3.3), (3.4), (3.5) ve (3.6)'daki  $\beta$  değeri algoritmanın sabit değerini ifade etmektedir. Denklem (3.5)'te  $a_m$  değeri en küçük kareler yöntemi kullanılarak hesaplanmaktadır. Bu algoritmada, veri boyutu ve büyüklüğü arttıkça dallanma noktalarındaki kazanımları ardı ardına hesaplanmasına katkı sağlayan gradyan azalma yöntemi, aşırı hesaplama yoğunluğuna neden olarak güncelleme hızının yavaşlamasına neden olmaktadır (Rao vd., 2019).

### 3.3.2. Rastgele orman algoritması

2001 yılında Leo Breiman tarafından geliştirilen rastgele orman algoritması, daha yüksek regresyon veya sınıflandırma performansı elde edebilmek amacıyla bir dizi sınıflandırıcı oluşturarak verileri sınıflandıran bir algoritmadır (Gashler vd., 2008). Algoritmanın temeli Breiman ve arkadaşlarının sınıflandırma ve regresyon ağaçlarını temel almaktadır (Li vd., 1984). Rastgele orman algoritması, büyük miktarda karar ağacının birbirinden bağımsız olarak aldıkları kararları değerlendirerek performans metrik sonuçlarının iyileştirilmesi ve daha genel bir yeteneğin kazanılması için

oylama tekniğini kullanmaktadır (Parmar vd., 2019). Algoritma rastgele seçilen örneklemeler üzerinden eğitim işlemi gerçekleştirmektedir (Metlek ve Çetiner, 2023). Buna ek olarak algoritma, içinde barındırdığı düğümleri bölerken de rastgele seçim işlemi yapmaktadır (Sun vd., 2023).

Probst çalışmasında Rastgele Orman Algoritmasını beş adımda özetlemektedir (Probst vd., 2019). Bu adımlardan birincisinde, alt ögelerin belirlenmesi vardır. Bunun için de M sayısının belirlenmesi gerekmektedir. İkinci adımda,  $\theta_k$  adlı alt öznitelik kümeleri M değerine bağlı olarak belirlenmektedir. Üçüncü adımda, her bir alt küme ayrı ayrı eğitilerek farklı kararlar alınması sağlanmaktadır.  $h(X, \theta_k)$  ile alt sınıflandırıcılar temsil edilmektedir (Metlek ve Çetiner, 2023). Dördüncü adımda, ilk üç adım her bir öznitelik alt kümesinden sonuç elde edilene kadar işlem devam etmektedir. Beşinci adımda ise her bir alt kümeden elde edilen sonuca göre etiket ataması yapılmaktadır.

### 3.3.3. Destek vektör makine algoritması

Destek vektör makine algoritmaları literatürde SVM algoritmaları olarak bilinmektedir. SVM algoritmaları parametre optimizasyonu başta olmak üzere sınıflandırma gibi amaçlar için kullanılan bir makine öğrenme algoritmasıdır. Regresyon problemleri başta olmak üzere sınıflandırma gibi birbirine yakın kategorilere ayrılmasında da SVM algoritmaları sıklıkla kullanılmaktadır. Danışmanlı öğrenme problemlerinde büyük bir sorun olan aşırı uyumu önleyerek öğrenme oranını en aza indirebilmek için yapısal minimizasyon tekniğini kullanmaktadır (Waqas vd., 2024). SVM, tahmin sonucu ile gerçek değer arasındaki sapmayı en aza indirebilmeyi hedeflemektedir (Arshad vd., 2021; Waqas vd., 2024).

SVM algoritmasının (Metlek ve Kayaalp, 2020; Çetiner, 2024) çalışmalarında bahsettiği gibi farklı kernel çeşitleri bulunmaktadır. Tez kapsamında kullanılan SVM algoritmasının kullanılan kernel fonksiyonlarının formülleri Denklem (3.7) -(3.10) arasındadır (Amara vd., 2015).

$$K(x_i, x_j) = (x_i, x_j) \quad (3.7)$$

$$K(x_i, x_j) = (\gamma x_i, x_j + coef)^d \quad (3.8)$$

$$K(x_i, x_j) = \exp^{-\gamma |x_i - x_j|^2} \quad (3.9)$$


$$\tanh(\gamma x_i, x_j + coef) \quad (3.10)$$

Linear (doğrusal (Linear)), polynomial (polinom (Poly)), gaussianradialbasis (gaussradyal baz (RBF)), Sigmoid adlı kernel fonksiyonlarının formülleri sırasıyla Denklem (3.7), Denklem (3.8), Denklem (3.9) ve Denklem (3.10)'da gösterilmektedir.  $\gamma$ ,  $coef$  ve  $d$  parametreleri kullanılan formüllerdeki kernel parametreleridir (Amara vd., 2015).

SVM algoritmalarında kullanılan kernel tiplerinin  $C$  marj değerleri bulunmaktadır. Bu marj değerleri algoritmanın tahmin değeri ile gerçek değer arasındaki hatayı en aza indirebilmek için dengeyi kontrol eden bir parametredir (Amara vd., 2015; Arshad vd., 2021). Bu tez kapsamında Linear, Poly, RBF ve Sigmoid kernel tiplerinin ortalama bir sonucunu elde edebilmek için farklı  $C$  marj değerlerindeki performans sonuçları elde edilmiştir. Farklı  $C$  marj değerleri ile SVM algoritmasının performans sonuçlarının çıkartılması sağlanmıştır. Linear, Poly, RBF ve Sigmoid kernel tiplerinin her birisinde  $C$  marj değeri olarak 1, 100 ve 1000 olmak üzere üç farklı parametre kullanılarak her bir kernel tipinde üç farklı performans sonucunun elde edilmesi sağlanmıştır.

### 3.3.4. Yinelemeli sinir ağları

Yinelemeli Sinir Ağları, literatürde RNN olarak bilinmektedir. Birbirinden bağımsız girdilerin önceki yinelemeleri üzerinden tahmin yapan mimariye RNN denilmektedir (Çetiner, 2022). Bellek bileşen ağ yapısı ile kısa zamanlı geriye dönük bilgileri bellekte tutabilen RNN mimari modeli, girdileri düşük boyutlu bir alanda tutabilmektedir (Liu ve Guo, 2019). Aynı zamanda şu andan önceki zaman adımlarından gelen bilgileri de verimli bir şekilde kullanılmasından dolayı regresyon analizlerinde de kullanılabilmektedir (Çetiner ve Kara, 2022).



Şekil 3.2. RNN hücre yapısı gösterimi (Çetiner, 2022)


$$h_t = f(h_{t-1}, x_t) \quad (3.11)$$

Denklem (3.11)'de RNN mimarilerinde  $t$  zamanındaki gizli durum gösterilmektedir. Şekil 3.2.'deki  $x_t$  ve  $c_t$  ise sırasıyla  $t$  zamanındaki giriş değerleri ve hücre değerleridir.  $c_{t-1}$  olduğunda ise  $t - 1$  zamanındaki hücre değerini ifade etmektedir. Yerel bilgileri yakalamada oldukça başarılı olan RNN, uzun süreli bellek hatırlaması gereken durumlarda istenen performansı verememektedir (Godin vd., 2018). Buna ek olarak RNN algoritmalarında sıklıkla yaşanan kaybolan gradyan sorunu bulunmaktadır (Liu ve Guo, 2019). Kaybolan gradyan sorunundan dolayı birkaç adım gerideki veri uzunluğuyla kısıtlı işlem kabiliyetine sahip bir mimaridir. Bu mimarideki sorunları çözebilmek amacıyla LSTM mimarisi geliştirilmiştir (Şekil 3.2).

Tez kapsamında kullanılan RNN modeli 7 katmandan oluşmaktadır. Birinci katmanda tanh aktivasyon fonksiyonlu 100 nöronlu 1x1 pencere boyutuna sahip RNN katmanı kullanılmaktadır. İkinci katmanda 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı kullanılmaktadır. Üçüncü katmanda ise tanh aktivasyon fonksiyonuna sahip 40 nöronlu bir RNN katmanı uygulanmıştır. Dördüncü katmanda ikinci katmana benzer şekilde nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Beşinci katmanda üçüncü katmana benzer şekilde 40 nöronlu tanh aktivasyon fonksiyonlu RNN katmanı uygulanmıştır. Altıncı katmanda, dördüncü katmana benzer şekilde 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Yedinci katmanda regresyon tahminini sağlayan katman tanımlanmıştır.

### 3.3.5. Uzun kısa süreli bellek ağları

RNN mimarilerinde sıklıkla yaşanan gradyan kaybolması ve belleğin kısa süreli olması gibi dezavantajlı durumları gideren mimariye LSTM mimarisi denilmektedir (Hochreiter ve Schmidhuber, 1997). Belleklerinin uzun süreli hatırlamasını sağlayan bellek kapıları ile LSTM mimarileri daha fazla bilgi depolanmasına izin vermektedir (Sherstinsky, 2020). LSTM hücreleri, veri saklama, veri okuma ve veri yazma gibi farklı görevlere imkân tanımaktadır. LSTM hücreleri, unutma, çıkış, giriş ve tekrarlama özelliğine sahip nöronlardan oluşmaktadır (Metlek, 2023). Şekil 3.3'te  $i_t$ ,  $o_t$ ,  $f_t$ ,  $c_t$ ,  $h_t$  ve  $x_t$  adlı sembollerini sırasıyla giriş katmanı, çıkış katmanı, unutma katmanı, hücre, gizli çıkış, hücre giriş durumlarını gösterilmektedir (Şekil 3.3).



Şekil 3.3. LSTM Bellek Hücresi (Çetiner, 2022)

$$\text{Giriş katmanı } (g_t) = \tanh(W_g x_t + R_g h_{t-1} + b_g), \quad (3.12)$$

$$\text{Unutma kapısı } (f_t) = \sigma(W_f x_t + R_f h_{t-1} + b_f), \quad (3.13)$$

$$\text{Çıkış kapısı } (o_t) = \sigma(W_o x_t + R_o h_{t-1} + b_o), \quad (3.14)$$

$$\text{Giriş kapısı } (i_t) = \sigma(W_i x_t + R_i h_{t-1} + b_i), \quad (3.15)$$

Denklem (3.12) ile Denklem (3.15) arasında bulunan  $b$ ,  $W$ ,  $R$  sembolleri bias, ağırlık ve tekrarlayan ağırlık değerlerini ifade etmektedir.  $\sigma$  ise LSTM kapılarında çalışan sigmoid aktivasyon fonksiyonunu temsil etmektedir.

Tez kapsamında kullanılan LSTM modeli 7 katmandan oluşmaktadır. Birinci katmanda tanh aktivasyon fonksiyonlu 100 nöronlu 1x1 pencere boyutuna sahip LSTM katmanı kullanılmaktadır. İkinci katmanda 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı kullanılmaktadır. Üçüncü katmanda ise tanh aktivasyon fonksiyonuna sahip 40 nöronlu bir LSTM katmanı uygulanmıştır. Dördüncü katmanda ikinci katmana benzer şekilde nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Beşinci katmanda üçüncü katmana benzer şekilde 40 nöronlu tanh aktivasyon fonksiyonlu LSTM katmanı uygulanmıştır. Altıncı katmanda, dördüncü katmana benzer şekilde 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Yedinci katmanda regresyon tahminini sağlayan katman tanımlanmıştır.

### 3.3.6. Geçit yinelemeli hücreler

LSTM mimarisine benzeyen Geçit Yinelemeli Hücreler (Gated Recurrent Unit (GRU)) mimarisi, LSTM mimarisinin daha yalın halidir (Çetiner ve Kara, 2022). Gizli durumdaki bilgileri sınıflamak için sıfırlama kapısı kullanan GRU, üç ana bileşenden oluşmaktadır. Bu bileşenler, hafıza kapsayıcı, güncelleme ve sıfırlama kapılarıdır.

$$\text{Sıfırlama kapısı } (s_t) = \sigma(W^s x_t + U^{(s)} h_{t-1}), \quad (3.16)$$

$$\text{Güncelleme kapısı } (u_t) = \sigma(W^u x_t + U^{(u)} h_{t-1}), \quad (3.17)$$


GRU mimarisine ait temel kapıların denklemleri Denklem (3.16) ve Denklem (3.17)'de sunulmuştur. Denklem (3.16) ve (3.17)'de her iki kapıda farklı ağırlık değerlerinde  $t$  zamanındaki durumları sembolize edilmiştir.

Tez kapsamında kullanılan GRU modeli 7 katmandan oluşmaktadır. Birinci katmanda tanh aktivasyon fonksiyonlu 100 nöronlu 1x1 pencere boyutuna sahip GRU katmanı kullanılmaktadır. İkinci katmanda 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı kullanılmaktadır. Üçüncü katmanda ise tanh aktivasyon fonksiyonuna sahip 100 nöronlu bir GRU katmanı uygulanmıştır.

Dördüncü katmanda ikinci katmana benzer şekilde nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Beşinci katmanda üçüncü katmana benzer şekilde 100 nöronlu tanh aktivasyon fonksiyonlu GRU katmanı uygulanmıştır. Altıncı katmanda, dördüncü katmana benzer şekilde 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Yedinci katmanda regresyon tahminini sağlayan katman tanımlanmıştır.

### **3.3.7. Dikkat katmanlı önerilen hibrit modeli**

Tez kapsamında geliştirilen dikkat katmanlı hibrit modeli on bir katmandan oluşmaktadır. Önerilen modelin katmanların dizilimi ve şematik görüntüsü Şekil 3.4.'te sunulmaktadır. Şekil 3.4'te detayları sunulan modelin katmanları hakkındaki detaylar bu başlık altında verilmiştir. Birinci katmanda verisetindeki girdi değerleri bulunmaktadır. İkinci katmanda tanh aktivasyon fonksiyonlu 100 nöronlu 1x1 pencere boyutuna sahip LSTM katmanı kullanılmaktadır. Üçüncü katmanda 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı kullanılmaktadır. Dördüncü katmanda ise tanh aktivasyon fonksiyonuna sahip 40 nöronlu bir LSTM katmanı uygulanmıştır. Beşinci katmanda ikinci katmana benzer şekilde nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Altıncı katmanda üçüncü katmana benzer şekilde 40 nöronlu tanh aktivasyon fonksiyonlu LSTM katmanı uygulanmıştır.



Şekil 3.4. Dikkat katmanlı önerilen hibrit model

Yedinci katmanda, dördüncü katmana benzer şekilde 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Sekizinci katmanda 25 nöronlu tanh aktivasyon fonksiyonuna sahip bir GRU katmanı tanımlanmıştır. Dokuzuncu katmanda, altıncı katmana benzer şekilde 0.25 oranında nöron bırakma gerçekleştiren dropout katmanı tanımlanmıştır. Onuncu katmanda ise ayırt edici özneliklerinin ağırlık değerlerini artıran bir dikkat katmanı uygulanmaktadır. Dikkat katmanı, önerilen hibrit modelinin tahmin performansını iyileştirebilmek adına çıkartılan önemli özneliklere seçici ağırlık değerleri atamaktadır. Dikkat katmanında çalışan mekanizma ile öncesindeki katmanlardan gelen öznelik verilerine farklı ağırlık atamaları gerçekleştirerek kritik bir görev üstlenmektedir. Dikkat katmanı, regresyon analizine uygun olacak şekilde girdi ağırlıklarının toplamı bir olacak şekilde ayarladıktan sonra regresyon katmanına giriş yapılmaktadır. Dikkat katmanının geliştirilmesinde (Bahdanau vd., 2014) ve (Rahul Gandh vd., 2024) adlı çalışmalarındaki yapılar kullanılmıştır. Tez kapsamında kullanılan dikkat katmanı matematiksel olarak ifade edebilmek amacıyla Denklem (3.18)-(3.24) arasındaki formüller tanımlanmıştır (Şekil 3.4).

$$x = (x_1, \dots, x_{T_x}), \quad (3.18)$$

$$h_t = f(x_t, h_{t-1}), \quad (3.19)$$

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{j=1}^{T_x} \exp(e_{ij})}, \quad (3.20)$$

$$e_{ij} = \alpha(s_{i-1}, h_j), \quad (3.21)$$

$$s_i = f(s_{i-1}, y_{i-1}, c_i), \quad (3.22)$$

$$c_i = \sum_{j=1}^{T_x} \alpha_{ij} h_j, \quad (3.23)$$

$$z_i = \sum_{i=t}^j \alpha_{ij} h_i, \quad (3.24)$$

Denklem (3.18)'deki yapıda bir dizi veri girişi bulunmaktadır. Denklem (3.19)'daki  $h_t$  değeri ise  $t$  anındaki gizli katmanı ifade etmektedir. Denklem (3.20)'deki  $a_{ij}$  ise  $j$ 'nci katmana ait girdinin dikkat katmanının ağırlık değerlerini göstermektedir. Aynı zamanda Denklem (3.21), Denklem (3.22) ve Denklem (3.23)'e göre değişiklik göstermektedir. Denklem (3.22)'deki  $s_{i-1}$ ,  $y_{i-1}$  değerleri sırasıyla ilgili zamandaki gizli ve tahmin değerlerini göstermektedir. Denklem (3.23)'teki  $c_i$  değeri gizli katmanlardaki dizilimlerden üretilen bir vektördür.  $h_j$  adlı gizli katman değerinin önemi  $e_{ij}$  formülü ile gösterilmektedir.  $z_i$  adlı değer ise bütün gizli katmanlardaki ağırlık değerlerinin toplamıyla hesaplanmaktadır. Aslında bu değer dikkat katmanının çıktı değerini temsil etmektedir. On birinci katmanda ise Denklem (3.24)'den elde edilen girdi baz alarak regresyon tahmini gerçekleştirilmektedir. On birinci katmandaki regresyon katmanı aslında bir nevi sonuçlandırma katmanıdır. Bu katmanla sonuç olarak özneliliklerindeki anlamlı verilere daha fazla ağırlıklandırma yaparak uzun vadeli bağımlılıkların yakalanması sağlanmıştır.

### 3.3.8. Performans değerlendirme metrikleri

Bu tez kapsamında kullanılan algoritmaların performansını değerlendirebilmek için modellerin eğitim ve test süreçlerinin analizi yapılmış ve bu analizde sırasıyla MSE

ve MAE deęerleri kullanılmıřtır. MSE ve MAE formüllerinin denklemleri sırasıyla Denklem (3.25) ve Denklem (3.26)'da sunulmuřtur.

$$MSE = \frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \quad (3.25)$$

$$MAE = \frac{100}{m} \sum_{i=1}^m \left[ \frac{Y_i - \hat{Y}_i}{Y_i} \right] \quad (3.26)$$

Denklem (3.25) ve (3.26) ölçümlerindeki  $\hat{Y}_i$  ,  $i$ . indeksteki tahmin deęerini gösterirken  $Y_i$  deęeri  $i$ .indeksteki gerek deęeri ifade etmektedir. 50 iterasyonda Adam optimizasyonu kullanılarak yapılan eęitimlerde MAE kayıp deęerine sahip MSE ve MAE performans metrikleri kullanılmıřtır.

#### 4. BULGULAR VE TARTIŞMA

Bu bölümde NVIDIA RTX 3060 ekran kartına sahip 16 GB ram, AMD Ryzen 7 işlemciye sahip bir bilgisayarda gerçekleştirilen deneysel çalışma sonuçları ve bulguları tartışmalı bir şekilde sunulmaktadır. Bölüm 3'te elde edilen veriler makine öğrenme yöntemleri ve derin öğrenme yöntemleri ile ayrı ayrı işleme girmektedir.

Makine ve derin öğrenme tabanlı tahmin modellerinin değerlendirilmesinde en küçük performans değerlerine dikkat çekilmiştir. Literatürdeki çalışmada MSE ölçüm metriğinin sıfıra ne kadar yakın olursa performans değerinin o kadar yüksek ve anlamlı olabileceği ifade edilmektedir (Mohapatra vd., 2022; Das vd., 2024). Verilen bilgi doğrultusunda tez kapsamında kullanılan modellerin değerlendirilmesi gerçekleştirilmiştir. Çizelge 4.1.'de farklı öğrenme oranlarına sahip derinlik sayısı iki olan gradyan artırma karar ağacı algoritmasının performans sonuçlarını göstermektedir. Gradyan Artırma Karar Ağacı algoritması 0.25 öğrenme oranında, 15 tahminleyici, maksimum derinlik sayısı 2 olması durumunda en düşük hata değerine ulaşmıştır. En yüksek hata sonucuna ise 0.05 öğrenme oranında, 10 tahminleyici, maksimum derinlik sayısı 2 olması durumunda alınmıştır (Çizelge 4.1).

Çizelge 4.1. Gradyan Artırma Karar Ağacı algoritması performans sonuçları

| Algoritma       | Öğrenme Oranı | Tahminleyici Sayısı | MSE    | MAE     |
|-----------------|---------------|---------------------|--------|---------|
| Gradyan Artırma | 0.05          | 10                  | 0.2000 | 0.36575 |
| Gradyan Artırma | 0.25          | 10                  | 0.001  | 0.03440 |
| Gradyan Artırma | 0.5           | 10                  | 0.05   | 0.00059 |
| Gradyan Artırma | 0.05          | 15                  | 0.1204 | 0.28301 |
| Gradyan Artırma | 0.25          | 15                  | 0.0001 | 0.00816 |
| Gradyan Artırma | 0.5           | 15                  | 0.0005 | 0.00186 |
| Gradyan Artırma | 0.05          | 20                  | 0.07   | 0.21898 |
| Gradyan Artırma | 0.25          | 20                  | 0.05   | 0.00193 |
| Gradyan Artırma | 0.5           | 20                  | 0.05   | 0.58257 |

Çizelge 4.2'te ise Rastgele Orman algoritması kullanımı ile 20 tahminleyici sayısına sahip maksimum derinlik 3 olan parametrelere sahip modelinde elde edilmiştir. En yüksek hata değerine ise 10 tahminleyici sayısına sahip modelde ulaşılmıştır (Çizelge 4.2).

Çizelge 4.2. Rastgele Orman tahmin sonuçları

| Algoritma      | Tahminleyici Sayısı | MSE     | MAE     |
|----------------|---------------------|---------|---------|
| Rastgele Orman | 10                  | 9.97    | 0.00049 |
| Rastgele Orman | 15                  | 4.43    | 0.00033 |
| Rastgele Orman | 20                  | 0.00010 | 0.00062 |
| Rastgele Orman | 25                  | 0.00014 | 0.00069 |
| Rastgele Orman | 30                  | 0.00018 | 0.00074 |
| Rastgele Orman | 100                 | 0.00027 | 0.00092 |
| Rastgele Orman | 1000                | 0.00028 | 0.00098 |

Makine öğrenme algoritmalarından SVM algoritmasının RBF, linear, sigmoid ve poly tabanlı kernel tiplerine göre deneysel çalışma gerçekleştirilmiştir. Ancak Çizelge 4.3'te sonuçları verilen kernel tipleri dışındaki tiplerde performans sonuç alınamamıştır. Çizelge 4.3'teki performans sonuçları analiz edildiğinde RBF kernel tipi kullanılarak elde edilen performans sonuçlarının diğer kernel tipinden daha üstün olduğu söylenebilmektedir. Kontrol amacıyla kullanılan C değerinin performansa herhangi bir etkisinin olmadığı görülmüştür (Çizelge 4.3).

Çizelge 4.3. SVM algoritması performans sonuçları


| Algoritma | Kernel  | C   | MSE    | MAE      |
|-----------|---------|-----|--------|----------|
| SVM       | RBF     | 1   | 0.0024 | 0.0012   |
| SVM       | RBF     | 100 | 0.0024 | 0.0012   |
| SVM       | Sigmoid | 1   | 0.5860 | 0.58603  |
| SVM       | Sigmoid | 100 | 0.5860 | 0.586035 |

Tezin bundan sonraki bölümünde yenilemeli sinir ağlarını temel alan modellerin performans değerleri gösterilmektedir. Kayıp fonksiyonu olarak MAE kullanıldığı için kayıp değerleri ile kayıp fonksiyon çıktı değerleri aynıdır. Bu sebepten dolayı her ikisinin grafikleri ve değerleri verilmemiştir. Çizelge 4.4'te verilen performans değerlerine göre en iyi tahmin sonuçlarına LSTM ve hibrit modelleriyle ulaşılmıştır. En az hata değerine sahip olan modeller LSTM ve hibrit modelleridir.

Çizelge 4.4. Yenilemeli sinir ağlarını temel alan modellerin tahmin performans sonuçları

| Algoritma | Tip       | MSE  | MAE  |
|-----------|-----------|------|------|
| RNN       | Eğitim    | 0.02 | 0.11 |
| GRU       | Eğitim    | 0.02 | 0.10 |
| LSTM      | Eğitim    | 0.02 | 0.07 |
| Hibrit    | Eğitim    | 0.02 | 0.08 |
| RNN       | Doğrulama | 0.02 | 0.09 |
| GRU       | Doğrulama | 0.01 | 0.06 |
| LSTM      | Doğrulama | 0.01 | 0.07 |
| Hibrit    | Doğrulama | 0.01 | 0.06 |


Hibrit model, MSE performans metriği yönünden LSTM modeliyle aynı sonuca sahipken MAE performans yönünden LSTM modelinden daha üstün bir performans göstermiştir. LSTM ve hibrit modelinden sonra en iyi performansı GRU modeli göstermiştir. En kötü performansı ise temel RNN modelinin gösterdiği söylenebilmektedir. Şekil 4.1 ile Şekil 4.4 arasındaki grafikler Çizelge 4.4'teki performans sonuçlarının detaylı gösterimini içermektedir.



Şekil 4.1. Stres tahmininde kullanılan modellerin eğitim MSE performansları


Şekil 4.1'te tüm modellerin MSE performans sonuçlarının yakın değerlere sahip olduğu görülmektedir. Modeller arasında bindelik üzerinden farklar bulunmaktadır.

LSTM ve hibrit modellerinin MSE değerleri birbirlerine oldukça yakın sonuçlar vermektedir (Şekil 4.1).




Şekil4.2. Stres tahmininde kullanılan modellerin eğitim MAE performansları

Şekil 4.2’de LSTM ve Hibrit modelleri birbirine oldukça yakın sonuçlar verirken, RNN ve GRU modelleri de birbirlerine yakın sonuçlar vermektedir. RNN modelinin MAE metriği performans sonucu diğerlerine göre iyi değildir (Şekil 4.2).



Şekil 4.3. Stres tahmininde kullanılan modellerin doğrulama MSE performansları

Şekil 4.3'te ise modellerin doğrulama MSE performans sonuçları gösterilmektedir. RNN modeli 0.02 hata değerine ulaşırken diğerleri 0.01 değerine ulaşmaktadır. Grafikselsel açıdan yorumlandığında LSTM ve hibrit modelinde daha düzenli bir grafiğin olduğu görülmektedir. RNN modelinde 20. iterasyona doğru büyük bir dalgalanma varken, GRU modelinde 30. iterasyonda büyük bir dalgalanma bulunmaktadır (Şekil 4.3).



Şekil 4.4. Stres tahmininde kullanılan modellerin doğrulama MAE performansları

Şekil 4.4'te hibrit modelin 0.06 değeri ile en iyi doğrulama MAE performans değerine sahip olduğu görülmektedir (Şekil 4.4). Yenilemeli sinir ağlarını temel alan modeller kullanarak gerçekleştirilen deneysel çalışmalarda MSE ve MAE performans metrikleri kullanılmıştır. Stres seviyesi tahmininde en iyi tahmin sonuçlarına LSTM ve Hibrit modelleriyle ulaşılmıştır. En az hata değerine sahip olan modeller LSTM ve Hibrit modelleridir. Hibrit model, MSE performans metriği yönünden LSTM modeliyle aynı sonuca sahipken MAE performans yönünden LSTM modelinden daha üstün bir performans göstermiştir. LSTM ve Hibrit modelinden sonra en iyi performansı GRU modeli göstermiştir. En kötü performansı ise temel RNN modelinin gösterdiği söylenebilmektedir.

Makine öğrenme yöntemlerinden RBF kernel değerine sahip SVM modeli, tez kapsamında kullanılan modellerden MSE ve MAE performans metrikleri açısından iyi bir tahmin sonucu sunmaktadır. Gradyan Artırma modeliyle yapılan deneysel çalışmalarda 0.25 öğrenme oranı ve 10 tahminleyici ile yenilemeli sinir ağlarından MSE ve MAE metrikleri bakımından iyi sonuçlar vermiştir.

## 5. SONUÇ VE ÖNERİLER

Günümüzde stresin erken tespiti ve etkili bir şekilde yönetilmesi, bireylerin zihinsel ve fiziksel sağlığı açısından büyük önem taşımaktadır. Bu nedenle, araştırmacılar giyilebilir cihazlar yardımıyla fizyolojik veri sinyalleri toplayarak stres seviyesini ölçme ve analiz etme yöntemleri geliştirmektedir. Bu alandaki çalışmalar, fizyolojik sinyallerin giyilebilir sensörler aracılığıyla kaydedilerek stres tespitinde kullanılabileceğini ve makine öğrenmesi algoritmalarının bu tür tahmin sistemlerinde etkili ve uygun maliyetli çözümler sunabileceğini göstermektedir. Ancak, bu alanda daha fazla araştırma yapılmasının gerekliliği vurgulanmaktadır.

Bu tez kapsamında kullanılan veriseti `sement_cognitiveload` ile makine öğrenmesi ve derin öğrenme tabanlı modellerin performansları incelenmiştir. Farklı algoritmaların etkinliğini değerlendirmek amacıyla çeşitli hata metrikleri kullanılmış ve elde edilen bulgular şu sonuçları ortaya koymuştur: Makine öğrenmesi tabanlı modeller arasında en başarılı sonuçlar, RBF kerneline sahip SVM algoritması ile elde edilmiştir. Ayrıca, Gradyan Artırma Karar Ağacı algoritması, belirli parametre ayarlarıyla dikkate değer performans göstermiş olup özellikle 0.25 öğrenme oranı ve 15 tahminleyici kullanıldığında en düşük hata değerine ulaşılmıştır. Yenilemeli sinir ağları temelinde yapılan çalışmalarda ise en başarılı modellerin LSTM ve hibrit modeller olduğu gözlemlenmiştir. Bu modeller hem MAE hem de MSE metrikleri açısından en düşük hata değerlerine sahip olup, stres tahmini konusunda güçlü bir performans sergilemişlerdir. Hibrit model, MSE metriği açısından LSTM modeli ile benzer sonuçlar sunarken, MAE metriği açısından daha üstün bir performans ortaya koymuştur. Buna karşın, GRU modeli LSTM ve hibrit modellere kıyasla daha düşük başarı göstermektedir. Temel RNN modeli ise en yüksek hata değerlerine sahip olmuştur. Bu bulgular, stres tahmini gibi zaman serisi verisi gerektiren problemlerde daha derin ve kompleks yapıya sahip modellerin daha iyi genelleme yapabildiğini göstermektedir.

Elde edilen bulgular doğrultusunda, derin öğrenme tabanlı modellerin makine öğrenmesi tabanlı modellere kıyasla daha iyi performans sergilediği ortaya konmuştur. Bu nedenle, gelecekte yapılacak çalışmalarda Hibrit ve LSTM modellerinin daha geniş veri setleriyle test edilmesi ve farklı optimizasyon teknikleri

ile daha verimli hale getirilmesi önerilmektedir. Ayrıca, daha derin katmanlı LSTM modelleri veya transformer tabanlı sinir ağıları kullanarak tahmin performansının artırılması mümkün olmaktadır.

Geliştirilen model, stres algılama ve yönetimi alanında düşük maliyetli ve erişilebilir bir alternatif sunarak mevcut çözümlerle kıyaslandığında önemli avantajlar sağlamaktadır. Yapılan analizler, özellikle derin öğrenme tabanlı modellerin stres tahmininde geleneksel makine öğrenmesi yöntemlerine kıyasla daha başarılı sonuçlar verdiğini ortaya koymuştur. Özellikle LSTM ve hibrit modellerin, zaman serisi verisini daha iyi işleyerek en düşük hata oranlarına ulaştığı gözlemlenmiştir. Bu sonuçlar, stresin tespitinde daha derin ve kompleks model yapılarına duyulan ihtiyacı desteklemektedir. Gelecekte yapılacak çalışmaların, daha büyük ve çeşitli veri setleri kullanılarak modelin genelleme yeteneğinin artırılmasına odaklanması gerekmektedir. Stresle başa çıkma stratejilerini kişisel sağlık yönetim sistemlerine entegre ederek bireylerin stres seviyelerini daha doğru tahmin edebilmelerini ve bu konuda etkili önlemler alabilmelerini mümkün kılacaktır.

Sonuç olarak, bu tezde sunulan model, stres algılama ve yönetimi alanındaki diğer çözümlerle kıyaslandığında, düşük maliyetli ve daha erişilebilir bir alternatif sunmaktadır. Bu teknolojilerin daha geniş bir kitleye ulaştırılabilmesi ve geliştirilebilmesi için daha fazla çalışma yapılması gerekmektedir. Gelecekteki çalışmalar, stresle başa çıkma stratejilerini kişisel sağlık yönetim sistemlerine entegre ederek bireylerin stres seviyelerini daha doğru tahmin edebilmelerini ve bu konuda etkili önlemler alabilmelerini sağlamaktadır.

## KAYNAKLAR

- Akleyek, S., Kılıç, E., Söylemez, B., Aruk, E., & Aksaç, C. (2020). Nesnelerin interneti tabanlı sağlık izleme sistemleri üzerine bir çalışma. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(5), 80-89. <https://doi.org/10.21923/jesd.831844>.
- Aksu, B., & Odabas, M. S. (2021). Havacılık sektöründe stres yönetimi ve çözüm önerileri. *Black Sea Journal of Public and Social Science*, 4(2), 99-103. <https://doi.org/10.52704/bssocialscience.859529>.
- Alekya, R., Boddeti, N. D., Monica, K. S., Prabha, R., & Venkatesh, V. (2021). IoT based smart healthcare monitoring systems: a literature review. *Eur. J. Mol. Clin. Med*, 7(2021), 2020.
- Alp, E., & Doğan, M. (2021). Giyilebilir teknolojiler ve iş ilişkisine etkileri. *Çalışma ve Toplum*, 2021(71), 2591-2610.
- Alpay, E. H., & Çelik, D. (2022). Karmaşık travma sonrası stres bozukluğu: bir gözden geçirme. *Psikiyatride Güncel Yaklaşımlar*, 14(4), 589-596. <https://doi.org/10.18863/pgy.1050659>.
- Alshari, H., Saleh, A. Y., & Odabaş, A. (2021). Comparison of gradient boosting decision tree algorithms for cpu performance. *Journal of Institute of Science and Technology*, 37(1), 157-168.
- Altunışık, R., Coşkun, R., Bayraktaroğlu, S., & Yıldırım, E. (2004). *Sosyal Bilimlerde Araştırma Yöntemleri SPSS Uygulamalı*. Sakarya Yayıncılık, Sakarya Yayınevi.
- Amara, M., Ghedira, K., Zidi, K., & Zidi, S. (2015). A Comparative Study of Multi-Class Support Vector Machine Methods for Arabic Characters Recognition. *2015 IEEE/ACS 12th International Conference of Computer Systems and Applications (AICCSA)*. November 17-20, Morocco, 1–6.
- Ardıç, K., & Polatçı, S. (2007). İşgören refahı ve örgütsel etkinlik kavramlarına bütüncül bir bakış: örgüt sağlığı. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(1), 137-154.
- Arshad, U., Taqvi, S. A. A., Buang, A., & Awad, A. (2021). SVM, ANN, and PSF modelling approaches for prediction of iron dust minimum ignition temperature (mit) based on the synergistic effect of dispersion pressure and concentration. *Process Safety and Environmental Protection*, 152, 375–390.
- Ashton, K. (2009). That internet of things thing rfid journal. <https://www.rfidjournal.com/articles/view?4986>. (Son erişim tarihi: 07 Temmuz 2024)
- Atlee Fernandes, R. H., Lokesh, R., Tari, T., & Shahapurkar, A. V. (2014). Determination of Stress Using Blood Pressure and Galvanic Skin Response.

2014 International Conference on Communication and Network Technologies.  
December 18-19, Sivakasi, 165-168.

- Aydın, G. Ç., Aytaç, S., & Şanlı, Y. (2021). İşe ilişkin duygular, iş stresi ve tükenmişliğin işten ayrılma niyeti üzerindeki etkisi: hemşireler üzerinde bir araştırma. *Journal of Social Policy Conferences*, (80), 1-35.
- Aylak, B. L., & Oral, O. (2021). Yapay zekâ ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri*, 8(1), 74-93. <https://doi.org/10.31202/ecjse.776314>.
- Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *ArXiv*, 1409.
- Bakioğlu, F., Korkmaz, O., & Ercan, H. (2021). Fear of COVID-19 and positivity: mediating role of intolerance of uncertainty, depression, anxiety, and stress. *International Journal of Mental Health and Addiction*, 19, 2369-2382. <https://doi.org/10.1007/s11469-020-00331-y>.
- Bardwell, G., Ivsins, A., Wallace, J. R., Mansoor, M., & Kerr, T. (2024). "The machine doesn't judge": counternarratives on surveillance among people accessing a safer opioid supply via biometric machines. *Social Science & Medicine*, 345, 116683. <https://doi.org/10.1016/j.socscimed.2024.116683>.
- Beyaz, A. (2015). Traktörde güvenlik amaçlı galvanik deri tepkisi sensörü kullanım olanaklarının belirlenmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 3(3), 121-125.
- Bilgili, H., & Tekin, E. (2019). Örgütsel stres, örgütsel bağlılık ve öğrenilmiş güçlülük ilişkisi üzerine bir araştırma. *OPUS International Journal of Society Researches*, 11(18), 2165-2200. <https://doi.org/10.26466/opus.557530>.
- Birur, B., Moore, N. C., & Davis, L. L. (2017). An evidence-based review of early intervention and prevention of posttraumatic stress disorder. *Community Mental Health Journal*, 53, 183-201. <https://doi.org/10.1007/s10597-016-0047-x>.
- Bobade, P., & Vani, M. (2020). Stress Detection with Machine Learning and Deep Learning Using Multimodal Physiological Data. *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*. July 15-17, 51-57.
- Boucsein, W. (2012). *Electrodermal Activity*. Springer Science & Business Media.
- Bradley, M. M., & Lang, P. J. (2000). Affective reactions to acoustic stimuli. *Psychophysiology*, 37(2), 204-215.
- Braithwaite, J. J., Watson, D. G., Jones, R., & Rowe, M. (2013). A guide for analysing electrodermal activity (eda) & skin conductance responses (scrs) for psychological experiments. *Psychophysiology*, 49(1), 1017-1034.

- Brothers, M. C., Moore, D., St. Lawrence, M., Harris, J., Joseph, R. M., Ratcliff, E., & Kim, S. S. (2020). Impact of self-assembled monolayer design and electrochemical factors on impedance-based biosensing. *Sensors*, 20(8), 2246. <https://doi.org/10.3390/s20082246>.
- Can, Y. S., Chalabianloo, N., Ekiz, D., Fernandez-Alvarez, J., Riva, G., & Ersoy, C. (2020). Personal stress-level clustering and decision-level smoothing to enhance the performance of ambulatory stress detection with smart watches. *IEEE Access*, 8, 38146-38163. <https://doi.org/10.1109/ACCESS.2020.2975351>.
- Cetiner, B., & Koksel, H. (2024). Comparison of quality, dietary fiber and glycemic index of whole wheat breads using various modern and old wheats and investigate the effect of xylanase. *Journal of Food Measurement and Characterization*, 18(6), 4484-4495. <https://doi.org/10.1007/s11694-024-02509-7>.
- Chen, T., Su, H., Jiang, H., Li, X., Zhong, N., Du, J., & Zhao, M. (2020). Cognitive and emotional predictors of real versus sham repetitive transcranial magnetic stimulation treatment response in methamphetamine use disorder. *Journal of Psychiatric Research*, 126, 73-80. <https://doi.org/10.1016/j.jpsychires.2020.05.007>.
- Cheung, M. L., Leung, W. K., & Chan, H. (2021). Driving health care wearable technology adoption for generation z consumers in Hong Kong. *Young Consumers*, 22(1), 10-27.
- Ciabattoni, L., Foresi, G., Lamberti, F., Monteriù, A., & Sabatelli, A. (2020). A Stress Detection System Based on Multimedia Input Peripherals. In *2020 IEEE International Conference on Consumer Electronics (ICCE)*, January 4-6, Las Vegas, 1-2.
- Cohen, S., Janicki-Deverts, D., & Miller, G. E. (2007). Psychological stress and disease. *Jama*, 298(14), 1685-1687.
- Critchley, H. D. (2002). Electro dermal responses: what happens in the brain. *The Neuroscientist*, 8(2), 132-142.
- Çalışkan, Ş. G. (2016). *Sağlıklı ve Koahlı Hastalarda Elektrodermal Aktivite Sinyallerinin Nonlineer Analizi*. (Doktora Tezi, Adnan Menderes Üniversitesi Sağlık Bilimleri Enstitüsü).
- Çetiner, H. (2024). A Comparison of SVM Kernel Functions for Android Malware Classification. *3rd International Conference on Frontiers in Academic Research*. June 15-16, Konya, 523-531.
- Çetiner, H., & Kara, B. (2022). Recurrent neural network based model development for wheat yield forecasting. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 9(16), 204-218. <https://doi.org/10.54365/adyumbd.1075265>.

- Çetiner, M. (2022). *Sürdürülebilir Moda Ürünlerinin Derin Öğrenme Yaklaşımı Kullanarak Analizi*. (Doktora Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü).
- Das, K., Kumar, R., & Krishna, A. (2024). Analyzing electric vehicle battery health performance using supervised machine learning. *Renewable and Sustainable Energy Reviews*, 189, 113967. <https://doi.org/10.1016/j.rser.2023.113967>.
- Demirel, R., & Demirel, D. Ş. (2022). Stres, hayvan sağlığı, ürün kalitesi ve helal gıda üretim süreci arasındaki ilişkiler. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(2), 1069-1081. <https://doi.org/10.47495/okufbed.1014521>.
- Didin, M., & Yavuz, B. (2022). COVID-19'un öğrencilerin stres, anksiyete, depresyon, korku düzeylerine etkisi: sistematik derleme. *Psikiyatride Güncel Yaklaşımlar*, 14(1), 38-45. <https://doi.org/10.18863/pgy.931572>.
- Din, I. U., Almogren, A., Guizani, M., & Zuair, M. (2019). A decade of internet of things: analysis in the light of healthcare applications. *IEEE Access*, 7, 89967-89979. <https://doi.org/10.1109/ACCESS.2019.2927082>.
- Edoh, T., & Degila, J. (2019). IoT-enabled health monitoring and assistive systems for in place aging dementia patient and elderly. In *Internet of Things (IoT) for Automated and Smart Applications*. (pp. 69-104).
- Elahi, M. T. E., & Islam, I. B. (2019). Galvanic Skin Response Signal Based Cognitive Load Classification Using Machine Learning Classifier. In *2019 3rd International Conference on Electrical, Computer & Telecommunication Engineering (ICECTE)*. December 26-28, 33-36.
- Ertek, E., & Aydintan, B. (2024). Hastane çalışanlarında örgütsel adalet algısı ve ikincil travmatik stresin tükenmişlik ile ilişkisi. *Third Sector Social Economic Review*, 59(3), 1386-1408. <https://doi.org/10.15659/3.sektor-sosyal-ekonomi.24.08.2445>.
- Fairclough, S. H. (2009). Fundamentals of physiological computing. *Interacting with Computers*, 21(1-2), 133-145. <https://doi.org/10.1016/j.intcom.2008.10.011>.
- Gashler, M., Giraud-Carrier, C., & Martinez, T. (2008). Decision Tree Ensemble: Small Heterogeneous Is Better Than Large Homogeneous. *2008 Seventh International Conference on Machine Learning and Applications*. December 11-13, San Diego, 900-905.
- Godin, F., Degrave, J., Dambre, J., & De Neve, W. (2018). Dual rectified linear units (DReLU): A replacement for tanh activation functions in quasi-recurrent neural networks. *Pattern Recognition Letters*, 116, 8-14. <https://doi.org/10.1016/j.patrec.2018.09.006>.

- Gökdeniz, İ. (2005). Üretim sektöründeki işletmelerin örgüt içi stres kaynakları ve mobilyacılık sektöründe bir uygulama. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (13), 173-189.
- Göktaş, A., & Buldukoğlu, K. (2022). Psikiyatri hemşirelerinde mesleki stres ve iş doyumu. *Akdeniz Hemşirelik Dergisi*, 1(2), 63-70.
- Greenwood, B. N., & Fleshner, M. (2011). Exercise, stress resistance, and central serotonergic systems. *Exercise and Sport Sciences Reviews*, 39(3), 140-149. <https://doi.org/10.1097/JES.0b013e31821f7e45>.
- Guk, K., Han, G., Lim, J., Jeong, K., Kang, T., Lim, E. K., & Jung, J. (2019). Evolution of wearable devices with real-time disease monitoring for personalized healthcare. *Nanomaterials*, 9(6), 813. <https://doi.org/10.3390/nano9060813>.
- Güçlü, N. (2001). Stres yönetimi. *Gazi Eğitim Fakültesi Dergisi*, 21(1), 91-109.
- Gülınar, E., & Çalışkan, N. (2022). Stres inkontinansta hemşirelik yaklaşımı: stres inkontinans bakım protokolü. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 11(1), 308-318. <https://doi.org/10.37989/gumussagbil.797192>.
- Gültekin, S. (2023). *Pandemi Süreci İçerisinde Düzenli Egzersiz ve Psikolojik İyi Oluş Arasındaki İlişkinin İncelenmesi*. (Yüksek Lisans Tezi, Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü).
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hook, K. (2008). Knowing, communication and experiencing through body and emotion. *IEEE Transactions on Learning technologies*, 1(4), 248-259. <https://doi.org/10.1109/TLT.2009.3>.
- Hoşgör, H., & Güngördü, H. (2022). Sağlıkta yapay zekanın kullanım alanları üzerine nitel bir araştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 395-407. <https://doi.org/10.31590/ejosat.1052614>.
- Jeong, D. S., Jeong, H., Kim, J. H., Kim, J. H., & Park, Y. (2024). A hybrid approach to improvement of watershed water quality modeling by coupling process-based and deep learning models. *Water Environment Research*, 96(8), e11079. <https://doi.org/10.1002/wer.11079>.
- Johnson, A. P. (2008). *A Short Guide to Action Research*. Allyn and Bacon.
- Kaba, İ. (2019). Stres, ruh sağlığı ve stres yönetimi: güncel bir gözden geçirme. *Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi*, (73), 63-81.
- Kırcalı, K. (2022). *Element Eksikliği Olan Bölgelerdeki Ürünlerin Derin Öğrenme ve İha ile Sınıflandırılması*. (Yüksek Lisans Tezi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü).

- Kumar, M., & Shrivastava, P. (2022). The effect of GSR biofeedback relaxation on anxiety and stress in patients with type II diabetes mellitus: a randomized controlled trial. *Journal of Rehabilitation Sciences & Research*, 9(1), 16-22.
- Lan, Y. L., Huang, W. T., Kao, C. L., & Wang, H. J. (2020). The relationship between organizational climate, job stress, workplace burnout, and retention of pharmacists. *Journal of Occupational Health*, 62(1), e12079. <https://doi.org/10.1002/1348-9585.12079>.
- Landy, F., Quick, J. C., & Kasl, S. (1994). Work, stress, and well-being. *International Journal of Stress Management*, 1, 33-73.
- Lang, P. J. (1995). The emotion probe: studies of motivation and attention. *American psychologist*, 50(5), 372.
- Lazarus, R. S., & Folkman, S. (1984). *Stress, Appraisal, and Coping*. Springer publishing company.
- LeDoux, J. E. (1998). *The Emotional Brain: The Mysterious Underpinnings of Emotional Life*. Simon and Schuster.
- Li, B., Friedman, J., Olshen, R., & Stone, C. (1984). Classification and regression trees (CART). *Biometrics*, 40(3), 358-361.
- Liu, G., & Guo, J. (2019). Bidirectional LSTM with attention mechanism and convolutional layer for text classification. *Neurocomputing*, 337, 325-338.
- Lu, L., Zhang, J., Xie, Y., Gao, F., Xu, S., Wu, X., & Ye, Z. (2020). Wearable health devices in health care: narrative systematic review. *JMIR Mhealth and Uhealth*, 8(11), e18907. <https://doi.org/10.2196/18907>.
- Malathi, J., Kusha, K. R., Isaac, S., Ramesh, A., Rajendiran, M., & Boopathi, S. (2024). IoT-enabled remote patient monitoring for chronic disease management and cost savings: transforming healthcare. In *Advances in Explainable AI Applications for Smart Cities*. (pp. 371-388).
- Mamdiwar, S. D., Shakruwala, Z., Chadha, U., Srinivasan, K., & Chang, C. Y. (2021). Recent advances on IoT-assisted wearable sensor systems for healthcare monitoring. *Biosensors*, 11(10), 372. <https://doi.org/10.3390/bios11100372>.
- McEwen, B. S. (2007). Physiology and neurobiology of stress and adaptation: central role of the brain. *Physiological reviews*, 87(3), 873-904. <https://doi.org/10.1152/physrev.00041.2006>.
- Metlek, S. (2023). A new proposal for the prediction of an aircraft engine fuel consumption: a novel CNN-BiLSTM deep neural network model. *Aircraft Engineering and Aerospace Technology*, 95(5), 838-848. <https://doi.org/10.1108/AEAT-05-2022-0132>.

- Metlek, S., & Çetiner, H. (2023). Classification of Poisonous and Edible Mushrooms with Optimized Classification Algorithms. In *International Conference on Applied Engineering and Natural Sciences*. July 10-12, Konya, 408-415.
- Metlek, S., & Kayaalp, K. (2020). Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(3), 2208-2228. <https://doi.org/10.29130/dubited.707316>.
- Mohapatra, S. K., Mishra, S., & Tripathy, H. K. (2022). Energy Consumption Prediction in Electrical Appliances of Commercial Buildings Using LSTM-GRU Model. *2022 International Conference on Advancements in Smart, Secure and Intelligent Computing (ASSIC)*. November 19-20, Odisha, 1-5.
- Motta, M., Groves, E., Schneider, A., Paoletti, S., Henchoz, N., & Ribes Lemay, D. (2023). Designing self-tracking experiences: a qualitative study of the perceptions of barriers and facilitators to adopting digital health technology for automatic urine analysis at home. *PLOS Digital Health*, 2(9), e0000319. <https://doi.org/10.1371/journal.pdig.0000319>.
- Mou, L., Zhou, C., Zhao, P., Nakisa, B., Rastgoo, M. N., Jain, R., & Gao, W. (2021). Driver stress detection via multimodal fusion using attention-based CNN-LSTM. *Expert Systems with Applications*, 173, 114693. <https://doi.org/10.1016/j.eswa.2021.114693>.
- Nourbakhsh, N., Chen, F., Wang, Y., & Calvo, R. A. (2017). Detecting users' cognitive load by galvanic skin response with affective interference. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, 7(3), 1-20. <https://doi.org/10.1145/296041>.
- Okumuş, F. E. E. (2024). Stres yönetimi eğitiminin üniversite öğrencilerinin kaygı, stres ve öz etkinlik inançlarına etkisi: kontrollü bir çalışma. *Ayna Klinik Psikoloji Dergisi*, 11(2), 292-315. <https://doi.org/10.31682/ayna.1332606>.
- Öcel, Y., Karaca, Ş., & Köse, B. (2024). Giyilebilir sağlık teknolojileri kullanım niyeti ile yaşam tarzı arasındaki ilişkinin incelenmesi: x, y ve z kuşağı üzerine bir çalışma. *Akademik Yaklaşımlar Dergisi*, 15(3), 1324-1354. <https://doi.org/10.54688/ayd.1413329>.
- Özsezer, G., & Ataç, M. (2021). Sanal gerçeklik uygulamalarıyla mindfulness temelli stres azaltma programının hemşirelikte kullanımı. *Journal of Awareness*, 6(3), 123-131.
- Parmar, A., Katariya, R., & Patel, V. (2019). A Review on Random Forest: An Ensemble Classifier. *International conference on intelligent data communication technologies and internet of things (ICICI)*. August 7-8, Coimbatore, 758-763.
- Patel, S., Park, H., Bonato, P., Chan, L., & Rodgers, M. (2012). A review of wearable sensors and systems with application in rehabilitation. *Journal of*

*Neuroengineering and Rehabilitation*, 9, 1-17. <https://doi.org/10.1186/1743-0003-9-21>.

Probst, P., Wright, M. N., & Boulesteix, A. L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: data mining and knowledge discovery*, 9(3), e1301. <https://doi.org/10.1002/widm.1301>.

Quan, M. (2024). *Segment cognitive load*. <https://www.kaggle.com/datasets/quanminhminhquan/segment-cognitiveload>. (Son erişim tarihi: 30 Aralık 2024).

Rahul Gandh, D., Harigovindan, V. P., Rasheed Abdul Haq, K. P., & Amrtha, B. (2024). Attention-driven LSTM and GRU deep learning techniques for precise water quality prediction in smart aquaculture. *Aquaculture International*, 32(6), 8455–8478. <https://doi.org/10.1007/s10499-024-01574-5>.

Rao, H., Shi, X., Rodrigue, A. K., Feng, J., Xia, Y., Elhoseny, M., ... & Gu, L. (2019). Feature selection based on artificial bee colony and gradient boosting decision tree. *Applied Soft Computing*, 74, 634-642. <https://doi.org/10.1016/j.asoc.2018.10.036>.

Ray, P. P., Dash, D., & De, D. (2019). Analysis and monitoring of IoT-assisted human physiological galvanic skin response factor for smart e-healthcare. *Sensor Review*, 39(4), 525-541. <https://doi.org/10.1108/SR-07-2018-0181>.

Richardson, K. M., & Rothstein, H. R. (2008). Effects of occupational stress management intervention programs: a meta-analysis. *Journal of Occupational Health Psychology*, 13(1), 69. <https://doi.org/10.1037/1076-8998.13.1.69>.

Rodgers, M. M., Pai, V. M., & Conroy, R. S. (2014). Recent advances in wearable sensors for health monitoring. *IEEE Sensors Journal*, 15(6), 3119-3126. <https://doi.org/10.1109/JSEN.2014.2357257>.

Rytwinski, N. K., Fresco, D. M., Heimberg, R. G., Coles, M. E., Liebowitz, M. R., Cissell, S., & Hofmann, S. G. (2009). Screening for social anxiety disorder with the self-report version of the liebowitz social anxiety scale. *Depression and Anxiety*, 26(1), 34-38. <https://doi.org/10.1002/da.20503>.

Sağbaş, E. A., Korukoglu, S., & Balli, S. (2020). Stress detection via keyboard typing behaviors by using smartphone sensors and machine learning techniques. *Journal of Medical Systems*, 44, 1-12. <https://doi.org/10.1007/s10916-020-1530-z>.

Sağbaş, E. A., Korukoğlu, S., & Ballı, S. (2021). Akıllı telefon verileri ve makine öğrenmesi yöntemleri kullanılarak stres tespiti çalışmaları üzerine bir literatür araştırması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 9(3), 1030-1038. <https://doi.org/10.21923/jesd.790845>.

- Savcı, M., & Aysan, F. (2014). Üniversite öğrencilerinde algılanan stres düzeyi ile stresle başa çıkma stratejileri arasındaki ilişki. *Uluslararası Türk Eğitim Bilimleri Dergisi*, 2014(3), 44-56.
- Scanff, C. L., & Taugis, J. (2002). Stress management for police special forces. *Journal of Applied Sport Psychology*, 14(4), 330-343. <https://doi.org/10.1080/10413200290103590>.
- Schneiderman, N., Ironson, G., & Siegel, S. D. (2005). Stress and health: psychological, behavioral, and biological determinants. *Annu. Rev. Clin. Psychol.*, 1(1), 607-628. <https://doi.org/10.1146/annurev.clinpsy.1.102803.144141>.
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/j.physd.2019.132306>.
- Sun, Y., Cheng, H., Zhang, S., Mohan, M. K., Ye, G., & De Schutter, G. (2023). Prediction & optimization of alkali-activated concrete based on the random forest machine learning algorithm. *Construction and Building Materials*, 385, 131519. <https://doi.org/10.1016/j.conbuildmat.2023.131519>.
- Talaat, F. M., & El-Balka, R. M. (2023). Stress monitoring using wearable sensors: IoT techniques in medical field. *Neural Computing and Applications*, 35(25), 18571-18584. <https://doi.org/10.1007/s00521-023-08681-z>.
- Tang, T. B., Yeo, L. W., & Lau, D. J. H. (2014). Activity Awareness can Improve Continuous Stress Detection in Galvanic Skin Response. *Sensors*, 2014 IEEE. November 2-5, Valencia, 1980-1983.
- Taskasaplidis, G., Fotiadis, D. A., & Bamidis, P. D. (2024). Review of stress detection methods using wearable sensors. *IEEE Access*, 12, 38219-38246. <https://doi.org/10.1109/ACCESS.2024.3373010>.
- Timurtaş, E., Avcı, E. E., Ayberk, B., Demirbüken, İ., & Polat, M. G. (2022). COVID-19 pandemisi sırasında üniversite öğrencilerinin fiziksel aktivite, depresyon, stres, uyku ve yaşam kalitesi düzeylerinin incelenmesi. *Ergoterapi ve Rehabilitasyon Dergisi*, 10(1), 17-26. <https://doi.org/10.30720/ered.1039882>.
- Tindle, R., Hemi, A., & Moustafa, A. A. (2022). Social support, psychological flexibility and coping mediate the association between COVID-19 related stress exposure and psychological distress. *Scientific Reports*, 12(1), 8688. <https://doi.org/10.1038/s41598-022-12262-w>.
- Tülgün, G. (2020). *Sosyal Anksiyete Bozukluğu ve Psikolojik Zihinlilik Arasındaki İlişkinin İncelenmesi*. (Yüksek Lisans Tezi, İstanbul Gelişim Üniversitesi Sosyal Bilimler Enstitüsü).

- Uzunhasanoğlu, Ö. G. D. G., & Şen, Ö. Ü. H. (2023). Örgütsel sinizm. *Sağlık Çalışanlarında Mutsuzluk*. (ss. 65-84).
- Vindegaard, N., & Benros, M. E. (2020). COVID-19 pandemic and mental health consequences: systematic review of the current evidence. *Brain, behavior, and immunity*, 89, 531-542. <https://doi.org/10.1016/j.bbi.2020.05.048>.
- Wang, H., Meng, Y., Yin, P., & Hua, J. (2016). A Model Driven Method for Quality Reviews Detection: An Ensemble Model of Feature Selection. *The Fifteenth Wuhan International Conference on E-Business-Social Media and Electronic Businesses*. May 27-29, Wuhan, 573-581.
- Waqas, S., Harun, N. Y., Arshad, U., Laziz, A. M., Mun, S. L. S., Bilad, M. R., ... & Alsaadi, A. S. (2024). Optimization of operational parameters using RSM, ANN, and SVM in membrane integrated with rotating biological contactor. *Chemosphere*, 349, 140830. <https://doi.org/10.1016/j.chemosphere.2023.140830>.
- Xu, X., Fu, C., Camacho, D., Park, J. H., & Chen, J. (2024). Internet of things for emotion care: advances, applications, and challenges. *Cognitive Computation*, 16, 2812-2832. <https://doi.org/10.1007/s12559-024-10327-8>.
- Yalçın, E., & Özbaşaran, F. (2021). Nefes terapisinin genel sağlık ve kadın sağlığı üzerine etkileri. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(2), 106-111. <https://doi.org/10.47769/izufbed.866042>.
- Yaman, C. (2018). *Galvanik Cilt Tepkisi ve Göz Takibi Tekniklerinin Entegrasyonu ile Biyometrik Ölçüm Uygulamaları*. (Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü).
- Yıldırım, F., & Pekel, H. A. (2025). Fiziksel aktivitede giyilebilir yapay zekâ yaklaşımı: sistematik literatür taraması. *International Journal of New Trends in Arts, Sports & Science Education (IJTASE)*, 14(1), 8-17.
- Yılmaz, M. K., & Mubayed, O. (2023). Havacılıkta pozitif emniyet kültürü: iş stresini etkiler mi?. *International Journal of Social and Humanities Sciences Research (JSHSR)*, 10(101), 3134-3149. <https://doi.org/10.5281/zenodo.10255860>.
- Yuan, X., & Abouelenien, M. (2015). A multi-class boosting method for learning from imbalanced data. *International Journal of Granular Computing, Rough Sets and Intelligent Systems*, 4(1), 13-29. <https://doi.org/10.1504/IJGCRSIS.2015.074722>.