

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**TRİGONOMETRİK DÖNÜŞÜM ESASLI ÖZNİTELİKLER İLE EEG İŞARETLERİNDEN STRES
KAYNAĞININ TESPİT EDİLMESİ**

YÜKSEK LİSANS TEZİ

Müslüm Serhat ÜNVER

**NİSAN 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**TRİGONOMETRİK DÖNÜŞÜM ESASLI ÖZNİTELİKLER İLE EEG İŞARETLERİNDEN
STRES KAYNAĞININ TESPİT EDİLMESİ**

Müslüm Serhat ÜNVER

ORCID : - - -

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
" ELEKTRONİK YÜKSEK MÜHENDİSİ "
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 23 / 03 / 2023

Tezin Savunma Tarihi : 07 / 04 / 2023

Tez Danışmanı : Doç. Dr. Önder AYDEMİR
ORCID : - - -

Trabzon 2023

ÖNSÖZ

Uzun yıllardır insanların birçok çeşitli faktörle tetiklenerek stresli durumlara maruz kaldığı ve erken tedavi sürecinin başlatılamadığı durumlarda ciddi sağlık problemleriyle yüzleştiği bilinmektedir. Bu tez çalışması kapsamında farklı stres kaynakları sırasında kaydedilen elektroensefalografi (EEG) işaretleri kullanılarak stresli durumların gevşeme durumları ile karşılaştırılmasından daha zor bir problem olarak görülen farklı stres kaynaklarının karşılaştırılarak tespiti üzerine çalışılmıştır. Ayrıca literatürde özniteliklerin belirlenmesi aşamasında yaygın olarak kullanılan yöntemlere ek olarak trigonometrik öznitelik vektörlerinin sınıflandırma performansına olan etkileri incelenerek en yüksek sınıflandırma doğruluğunun elde edilmesi amaçlanmıştır.

Bu tez çalışmasının her aşamasında kıymetli bilgi birikimini ve tecrübesini benimle paylaşarak yanımda olan, kendisini ve çalışmalarını örnek aldığım değerli danışman hocam Sayın Doç. Dr. Önder AYDEMİR'e, bu süreçte yoğun çalışma tempomuza rağmen yardımlarını ve desteklerini hiçbir zaman esirgemeyen KTÜ Teknoloji Transferi Uygulama ve Araştırma Merkezi yönetimi ve mesai arkadaşlarıma, Elektrik-Elektronik Mühendisliği bölümü arkadaşım Miraç ÖZTÜRK'e ve bugünlere gelmemde büyük emekleri olan kıymetli aileme sonsuz teşekkürlerimi sunarım.

Müslüm Serhat ÜNVER

Trabzon 2023

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Trigonometrik Dönüşüm Esaslı Öznitelikler ile EEG İşaretlerinden Stres Kaynağının Tespit Edilmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Önder AYDEMİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 07/04/2023

Müslüm Serhat ÜNVER

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY.....	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Stresin Tanımı ve Belirtileri.....	2
1.3. Stresi Belirleme Yöntemleri.....	6
1.3.1. Stresin Belirlenmesi Aşamasında Anket Kullanımı ve Davranış Gözlemi.....	7
1.3.2. Stresin Belirlenmesi Aşamasında Hormonal Testlerin Kullanımı	8
1.3.2.1. Kortizol Hormonu Seviyesi Ölçülerek Stresin Tespiti	8
1.3.2.2. Tiroid Hormonu Seviyesi Ölçülerek Stresin Tespiti.....	8
1.3.2.3. Katekolamin Hormonu Seviyesi Ölçülerek Stresin Tespiti	9
1.3.2.4. Vazopressin Hormonu Seviyesi Ölçülerek Stresin Tespiti	9
1.3.2.5. İnsülin Hormonu Seviyesi Ölçülerek Stresin Tespiti.....	10
1.3.2.6. Büyüme Hormonu Seviyesi Ölçülerek Stresin Tespiti	10
1.3.2.7. Gonadotropin Hormonu Seviyesi Ölçülerek Stresin Tespiti.....	10
1.3.2.8. Prolaktin Hormonu Seviyesi Ölçülerek Stresin Tespiti	11
1.3.3. Stresin Belirlenmesi Aşamasında Fizyolojik Sinyallerin Kullanımı	11
1.3.3.1. Elektrokardiyografi Sinyalleri Kullanılarak Stresin Tespiti	12

1.3.3.2.	Elektrodermal Aktivite Sinyalleri Kullanılarak Stresin Tespiti.....	13
1.3.3.3.	Kan Hacmi Basıncı Sinyalleri Kullanılarak Stresin Tespiti.....	15
1.3.3.4.	Elektromiyografi Sinyalleri Kullanılarak Stresin Tespiti	15
1.3.3.5.	Cilt Sıcaklığı Sinyalleri Kullanılarak Stresin Tespiti.....	17
1.3.3.6.	Solunum Sinyalleri Kullanılarak Stresin Tespiti	18
1.3.3.7.	Göz Bebeği Çapı Sinyalleri Kullanılarak Stresin Tespiti	20
1.3.3.8.	Kalp Atış Hızı Değişkenliği Sinyalleri Kullanılarak Stresin Tespiti	22
1.3.3.9.	Elektroensefalogram Sinyalleri Kullanılarak Stresin Tespiti.....	23
1.4.	Literatür Araştırması	26
2.	MATERYAL VE YÖNTEM	30
2.1.	Veri Seti Tanıtımı.....	30
2.1.1.	Stroop Renk Kelime Testi.....	30
2.1.2.	Aritmetik Problem Çözme Testi	31
2.1.3.	Yansıyan Ayna Görüntüleri Testi	32
2.1.4.	Deney Prosedürü	33
2.2.	Sinyal Ön İşleme.....	38
2.2.1.	Bant Geçiren Filtre.....	39
2.2.2.	Maksimum ve Minimum Noktaların Belirlenmesi	40
2.3.	Öznitelik Çıkarımı.....	41
2.3.1.	Min-Max Normalizasyon Yöntemi	41
2.3.2.	Trigonometrik Dönüşüm Fonksiyonları.....	42
2.3.3.	Dalgacık Dönüşümü.....	45
2.4.	Sınıflandırma.....	46
2.4.1.	K En Yakın Komşuluk Sınıflandırma Algoritması.....	47
2.4.2.	Destek Vektör Makineleri Sınıflandırma Algoritması	48
2.4.3.	Bayes Sınıflandırma Algoritması.....	49

2.4.4.	Karar Ağacı Sınıflandırma Algoritması	50
2.5.	Önerilen Yöntem.....	51
3.	BULGULAR.....	56
3.1.	Trigonometrik Öznitelikler Kullanılarak Farklı Stres Kaynaklarının Sınıflandırılması.....	57
3.1.1.	Yaygın Trigonometrik Dönüşüm Fonksiyonları Kullanılarak Elde Edilen Sınıflandırma Sonuçları	57
3.1.2.	Yaygın Trigonometrik Dönüşüm Fonksiyonlarına İlaveten Önerilen Trigonometrik Dönüşüm Fonksiyonları da Kullanılarak Elde Edilen Sınıflandırma Sonuçları	61
3.2.	Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Sınıflandırılması.....	65
3.2.1.	Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının k-EYK Sınıflandırma Algoritması Sonuçları.....	66
3.2.2.	Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Bayes Sınıflandırma Algoritması Sonuçları.....	67
3.2.3.	Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Karar Ağacı Sınıflandırma Algoritması Sonuçları.....	68
3.2.4.	Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Destek Vektör Makineleri Sınıflandırma Algoritması Sonuçları	69
3.3.	Önerilen Yöntemin Literatürdeki Diğer Çalışmalarla Kıyaslanması.....	70
4.	SONUÇLAR VE TARTIŞMA	72
5.	ÖNERİLER.....	75
6.	KAYNAKLAR	77

ÖZGEÇMİŞ

Yüksek Lisans Tezi

ÖZET

Trigonometrik Dönüşüm Esaslı Öznitelikler ile EEG İşaretlerinden Stres Kaynağının Tespit Edilmesi

Müslüm Serhat ÜNVER

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Önder AYDEMİR
2023, 85 Sayfa

Stres uzun yıllardır insanların günlük yaşantısı, ofis ortamı ve aile hayatı gibi birçok farklı durumda tetiklenerek maruz kaldıkları ve bunun sonucunda insan vücudunun zihinsel, fiziksel ve psikolojik tepkiler gösterdiği bir durumdur. Stresin erken tespiti yapılarak tedavi sürecine başlanılamadığı durumlarda kalp krizi, inme ve depresyon gibi birçok farklı hastalığın görülme riski oldukça fazladır. Bu sebeple birçok araştırmacı anketler, hormonal testler ve fizyolojik sinyaller kullanarak stresin erken tespiti üzerine çalışmalar gerçekleştirmektedir. Yapılan çalışmaların büyük bir çoğunluğunda görüldüğü üzere stres yaklaşımları gevşeme durumu ile kıyaslanmaktadır. Bu tez çalışmasında stres yaklaşımının gevşeme durumuna göre kıyaslanmasından daha zor bir problem olarak kabul edilen farklı stres kaynaklarının birbirleri ile sınıflandırılması üzerine çalışılmıştır. 40 katılımcının 3 farklı stres kaynağı süresince kaydedilen EEG verilerinin öznitelikleri yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonları kullanılarak oluşturulmuştur. 3 farklı stres kaynağı ikili alt sınıflandırma problemlerine ayrılarak 4 farklı sınıflandırma algoritması ile sınıflandırılmış ve birbirleriyle kıyaslanmıştır.

Anahtar Kelimeler: EEG, Stres, Trigonometrik Dönüşüm Fonksiyonları, Makine Öğrenmesi, Sınıflandırma

Master Thesis

SUMMARY

Identification of Stress Source from EEG Signals with Trigonometric Transformation Based Features

Müslüm Serhat ÜNVER

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronics Engineering Graduate Program
Supervisor: Assoc. Prof. Dr. Önder AYDEMİR
2023, 85 Pages

Stress is a condition that people have been exposed to for many years, triggered in many different situations such as daily life, office environment, and family life, and as a result, the human body shows mental, physical, and psychological reactions. In cases where stress cannot be detected early and the treatment process cannot be started, the risk of many different diseases such as heart attack, stroke, and depression is quite high. For this reason, many researchers are conducting studies on early detection of stress using questionnaires, hormonal tests, and physiological signals. As seen in most of the studies, stress approaches are compared with relaxation state. In this thesis, the classification of different stress sources, which is considered to be a more difficult problem than the comparison of the stress approach according to the relaxation state, was studied. The features of 40 participants' EEG data recorded during 3 different stress sources were generated using common trigonometric transformation functions and the proposed trigonometric transformation functions. The 3 different stressors were divided into binary subclassification problems and classified by 4 different classification algorithms and compared with each other.

Key Words: EEG, Stress, Trigonometric Transformation Functions, Machine Learning, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. EKG Grafiği	12
Şekil 2 EDA Elektrotlarının Kullanımı [41].....	14
Şekil 3 Yüzey elektrotlar ve iğne elektrotların kullanım yerleri [46].....	16
Şekil 4. İnsan derisinin genel gösterimi [55].....	17
Şekil 5. Solunum sisteminin genel gösterimi [60].....	19
Şekil 6. Gözbebeği çapında gerçekleşen değişikliklerin fiziksel gösterimi [68].....	21
Şekil 7. Nörolojik bilgi içeren EEG sinyal işareti örneği	23
Şekil 8. EEG sinyal işaretlerinde oluşan dalga biçimleri [79].....	24
Şekil 9. 10-20 elektrot sistemine göre konumlandırılan elektrotlar [81].....	25
Şekil 10. Stroop renk kelime testinde uygulanan uyumlu ve uyumsuz durum örneği	31
Şekil 11. Aritmetik problem çözme testi örneği.....	32
Şekil 12. Simetrik ve simetrik olmayan ayna görüntüleri örneği	33
Şekil 13. Verileri kaydedilen katılımcıların elektrot yerleşimi şeması [98].....	34
Şekil 14. Deney prosedürü.....	35
Şekil 15. Aritmetik problem çözme testi sinyal işaretleri	36
Şekil 16. Stroop renk kelime testi sinyal işaretleri	36
Şekil 17. Yansıyan ayna görüntüleri testi sinyal işaretleri	36
Şekil 18. Alt kesim ve üst kesim frekanslarının gösterimi	39
Şekil 19. Küresel ve yerel maksimum, minimum noktaları gösterimi	40
Şekil 20. k-EYK sınıflandırma algoritmasının genel gösterimi	48
Şekil 21. DVM sınıflandırma algoritmasının genel gösterimi	49
Şekil 22. Bayes sınıflandırma algoritmasının genel gösterimi	50
Şekil 23. KA sınıflandırma algoritmasının genel gösterimi	51

Şekil 24. Önerilen yöntemin genel akış diyagramı	52
Şekil 25. Trigonometrik öznitelik kombinasyonlarının genel akış diyagramı	53



TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Katılımcıların test sürecinde belirttikleri stres derecesi ölçeği	37
Tablo 2. Veri Seti Oluşturma Prosedürü	54
Tablo 3. SD 1 ve SD 2 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları	58
Tablo 4. SD 1 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları	59
Tablo 5. SD 2 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları	60
Tablo 6. SD 1 ve SD 2 kombinasyonunda yaygın trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları.....	62
Tablo 7. SD 1 ve SD 3 kombinasyonunda trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları.....	63
Tablo 8. SD 2 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları.....	64
Tablo 9. Standart öznelik belirleme yöntemi kombinasyonlarında k-EYK sınıflandırma sonuçları.....	66
Tablo 10. Standart öznelik belirleme yöntemi kombinasyonlarında k-EYK sınıflandırma sonuçları.....	67
Tablo 11. Standart öznelik belirleme yöntemi kombinasyonlarında KA sınıflandırma sonuçları.....	68
Tablo 12. Standart öznelik belirleme yöntemi kombinasyonlarında DVM sınıflandırma sonuçları	69
Tablo 13. Literatürdeki diğer çalışmalarla önerilen yöntemin karşılaştırılması	71
Tablo 14. Yaygın trigonometrik dönüşüm fonksiyonları kullanılarak elde edilen en yüksek sınıflandırma doğrulukları	73
Tablo 15. Yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonları ile elde edilen en yüksek sınıflandırma doğrulukları	73

SEMBOLLER DİZİNİ

BVP	Kan hacmi basıncı
DVM	Destek vektör makineleri
EDA	Elektrodermal aktivite
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
EMG	Elektromiyogram
FBW	Kısmi bant genişliği
GSR	Cilt iletkenliği
HHA	Hipotalamik hipofiz adrenal
HRV	Kalp atış hızı değişkenliği
HZ	Hertz
K	Komşuluk sayısı
k-EYK	K en yakın komşuluk
KA	Karar ağacı
MIST	Montreal görüntüleme stres görevi
MÜAP	Motor ünite aksiyon potansiyelleri
ÖTD1	Önerilen trigonometrik dönüşüm 1
ÖTD2	Önerilen trigonometrik dönüşüm 2
ÖTD3	Önerilen trigonometrik dönüşüm 3
ÖTD4	Önerilen trigonometrik dönüşüm 4
ÖTD5	Önerilen trigonometrik dönüşüm 5
ÖTD6	Önerilen trigonometrik dönüşüm 6
ÖTD7	Önerilen trigonometrik dönüşüm 7
PD	Göz bebeği çapı
RSP	Solunum sinyali
SD1	Stres durumu 1
SD2	Stres durumu 2
SD3	Stres durumu 3
SKT	Cilt sıcaklığı
SÖY1	Standart öznitelik belirleme yöntemi 1

SÖY2	Standart öznitelik belirleme yöntemi 2
SÖY3	Standart öznitelik belirleme yöntemi 3
SÖY4	Standart öznitelik belirleme yöntemi 4
SÖY5	Standart öznitelik belirleme yöntemi 5
SÖY6	Standart öznitelik belirleme yöntemi 6
SÖY7	Standart öznitelik belirleme yöntemi 7
SÖY8	Standart öznitelik belirleme yöntemi 8
SÖY9	Standart öznitelik belirleme yöntemi 9
SÖY10	Standart öznitelik belirleme yöntemi 10
SÖY11	Standart öznitelik belirleme yöntemi 11
TD1	Trigonometrik dönüşüm 1
TD2	Trigonometrik dönüşüm 2
TD3	Trigonometrik dönüşüm 3
TD4	Trigonometrik dönüşüm 4
TD5	Trigonometrik dönüşüm 5
TSST	Trier sosyal stres testi
T4	Tiroksin
T3	Triiyodotironin

1. GENEL BİLGİLER

1.1. Giriş

17. yüzyılın başlarında incelenmeye başlanan stres kavramı; uyku düzeninde olan değişimler, iş hayatında karşılaşılan zorluklar, günlük yaşamda karşılaşılan sağlık problemleri, düzensiz beslenme, tütün ürünleri ve alkol gibi maddeye olan bağımlılıklar gibi birçok olumsuz durum ile tetiklenerek insanlığın çok büyük bir bölümünü etkileyen ciddi bir sağlık sorunu olarak kabul edilmektedir. Bireyler stresli durumlara maruz kaldıklarında baş ağrısı, göğüs ağrısı, soğuk eller vb. fiziksel ve kaygı, motivasyon eksikliği, agresiflik vb. psikolojik tepkiler göstermektedir. Stres kalp krizi, inme, depresyon vb. ciddi sağlık problemlerine sebep olabileceği gibi bireylerin aile hayatını, çalışma hayatını ve günlük yaşantısındaki konforunu da oluşturacağı sorunlar ile ciddi oranda etkilemektedir. Bu nedenle strese sebebiyet veren durumların belirlenmesi ve stresin neden olacağı fiziksel, psikolojik etkilerin hızlı bir şekilde düzeltilebilmesi için erken tedaviye başlanması çok önemli bir faktör olarak görülmektedir. Stresin belirlenmesi aşamasında uzman araştırmacılar bireyler ile ikili görüşmeler, anketler/testler, davranış gözlemi gibi birçok birbirinden farklı muayene yöntemini sıklıkla tercih etmektedir. Uygulanan muayene yöntemleri stresin insan vücudunda oluşturduğu fiziksel ve psikolojik belirtilerin belirlenmesini mümkün kılmaktadır. Ancak yapılan çalışmalar sonucunda bazı bireylerin stresli bir durumda fark edilmesi zor veya hiçbir belirti göstermedikleri görülmektedir [1]. Stresin erken teşhisinin yapılamaması ve tedaviye başlanılamadığı durumlarda bireylerde kalp krizi, depresyon, konsantrasyon bozukluğu gibi birçok ciddi sağlık sorunu ortaya çıkmaktadır. Bu açıdan objektif bir şekilde stresin belirlenmesi ve erken tedaviye başlanması uzman araştırmacılar tarafından çok önemli bir faktör olarak görülmektedir.

Günümüzde tıbbi görüntüleme teknikleri, elektromiyogram (EMG), elektrokardiyogram (EKG), kalp atış hızında olan değişiklik, hormonal testler, EEG gibi birçok fizyolojik sinyalin kullanımı ile stresin erken belirlenmesi üzerine çalışmalar mevcuttur [2-6]. İlgili çalışmalar ile stresli durumlarda sinyallerde oluşan fizyolojik durumun belirlenerek stresin erken tespitinin yapılması amaçlanmaktadır. EEG sinyalleri yüksek doğruluk oranları, düşük maliyetli olması ve kayıt aşamasında kapsamlı bir donanım ihtiyacı duymamaları nedeniyle stres seviyesinin belirlenmesi aşamasında

araştırmacılar tarafından sıklıkla tercih edilmektedir. EEG sinyalleri kullanılarak bireyde meydana gelen stres olgusunun tespit edilmesi üzerine yapılan çalışmalar incelendiğinde; çalışmaların büyük bir çoğunluğunda katılımcıların stresli durumlarda oluşturduğu sinyal işaretleri ve gevşeme durumunda oluşturduğu sinyal işaretlerinin kıyaslanarak stres çalışması yapıldığı görülmektedir.

Bu tez çalışması kapsamında; 40 sağlıklı katılımcının stroop renk kelime testi, yansıyan ayna görüntüleri testi ve aritmetik problem çözme testi süreçlerinde kaydedilen EEG verileri kullanılmıştır. Çalışmada; stresli durumların gevşeme durumlarına göre kıyaslanmasından daha zor bir problem olarak kabul edilen farklı stres durumlarının birbirleriyle kıyaslanarak en yüksek sınıflandırma doğruluğunun elde edilmesi amaçlanmıştır.

Veri kümesi; stroop renk kelime testi, yansıyan ayna görüntüleri ve aritmetik problem çözme testi durumlarında kaydedilen içeriklerine göre kıyaslanarak toplamda 3 farklı stres durumu kombinasyonunun karşılaştırılması yapılmıştır. Sınıflandırma aşamasında en uygun öznitelik vektörlerinin belirlenebilmesi için nöral aktivasyon fonksiyonlarına ek olarak 7 farklı trigonometrik dönüşüm fonksiyonu önerilmiştir. Çalışma kapsamında nöral aktivasyon fonksiyonlarının sınıflandırma sonuçlarına etkileri, nöral aktivasyon fonksiyonlarına ek olarak önerilen trigonometrik dönüşümlerin fonksiyonlarının sınıflandırma sonuçlarına etkileri ve trigonometrik dönüşüm fonksiyonları kullanılmadan standart öznitelik belirleme yöntemlerinin sınıflandırma sonuçlarına etkileri gözlemlenmiştir. Elde edilen öznitelik vektörleri k-En yakın komşuluk (k-EYK), Bayes, karar ağacı (KA) ve destek vektör makineleri (DVM) sınıflandırma algoritmaları kullanılarak sınıflandırılmıştır.

1.2. Stresin Tanımı ve Belirtileri

Stres günümüzde şehir yaşıntısı, iş hayatı, aile hayatı, okul hayatı, ekonomik koşullar vb. birçok alanda tetiklenmekte ve hemen hemen herkesin deneyimlediği bir durum olarak karşımıza çıkmaktadır. Bu sebeple stres kavramı yaşıntımızda karşılaşılabileceğimiz ve herkes tarafından bilinen kaçınılmaz gerçeklerden birisi haline gelmiştir. İnsan vücudu stresli durumlara maruz kaldığı zaman bu durumla başa çıkabilmek için fiziksel, psikolojik

ve zihinsel tepkiler göstermektedir. Uzun süreli ve tedavi edilmeyen stresli durumlarda ise ciddi fiziksel hastalıklara ve psikolojik sorunlara sebebiyet verdiği yapılan pek çok çalışmada incelenmiştir.

Stres kelimesi Latince kökenli olan “estricia” kelimesine dayanmaktadır. Stres psikolojik bir terim olarak tanımlanmadan önce fiziksel terimleri ifade etmek için de kullanılmıştır. Yüzyıllardır kullanılan stres kelimesi 17. yüzyılda felaket, dert ve bela anlamında kullanılırken, 18. ve 19. yüzyılda baskı ve zor anlamında kişilere, organa veya ruhsal yapıya yönelik kullanılmaktaydı. 1842 yılında Thomas Curling yapmış olduğu çalışmalarda stres terimini ilk defa günümüzdeki anlamına benzer olarak kullanmıştır. Stres terimi yıllar boyunca bilinmesine rağmen bilimsel olarak fizyolojide ve psikolojideki ilk tanımı ise 1878 yılında Walter Cannon tarafından yapılmıştır. Cannon yapmış olduğu çalışmalarda stresi organizmaların dengesini bozan bir uyaran olarak tanımlamıştır.

McGrath organizmanın çevreden aldığı talepler ile mücadele mekanizmaları arasında dengesizlik olması durumunda stresin ortaya çıktığını ifade ederek günümüzde en çok kullanılan stres tanımlarından birini ifade etmiştir. Hans Selye yapmış olduğu çalışmada stresin olumlu ve olumsuz uyaranlar ile sürdürüldüğünü savunarak stresi kötü stres ve iyi stres olarak kategorilendirerek bireylerde iyi stresin seviyesinin yüksek, kötü stresin seviyesinin ise düşük tutulması gerektiğini savunmuştur [7]. Selye, Genel Uyum Sendromu adı verilen stres modelini geliştirerek insan vücudunun stresli durumlar ile karşılaştığında alarm aşaması, direnç aşaması ve tükenme aşamalarını belirleyerek stresin tedavisinin yapılmadığı durumlarda sağlık sorunlarına sebebiyet verebileceğini ifade etmiştir [8]. Genel Uyum Sendromunda belirtilen aşamalar ve tanımları şu şekildedir;

- I. Alarm Aşaması; insan vücudu stresörler ile tetiklendiğinde sinir sistemi bu durumla karşılaşma veya bu durumu göz ardı etme tepkisi göstermektedir. Stresli durum bu aşamada yok edilmez ise organizma direnme aşamasına geçmektedir.
- II. Direnme Aşaması; insan vücudu stresörlerin oluşturduğu zarar ile savaşılmaya başlanarak organizmanın dengesini sağlamaya çalışmaktadır. Eğer bu aşamada stresörlerin sebebiyet verdiği zararların onarımı sağlanırsa fizyolojik sorunlar ortadan kalkarak vücut eski haline dönmeye başlar.
- III. Tükenme Aşaması; insan vücudu direnme aşamasında dengeyi sağlayamayıp stres yok edemediğinde bu evreye girmektedir. Vücudun alarm seviyesinde olan reaksiyonlara benzer tepkiler gösterdiği bu aşamada farklı stres kaynaklarının

sebebiyet vereceği yıkıcı etkilere de açık hale gelmektedir. Bu durumda organizma tükenme seviyesine ulaşarak sağlık problemlerinin görüldüğü evreye geçmektedir.

İnsanlar içerisinde bulunduğu toplumsal baskı, arzular, çalışma hayatı, eğitim hayatı, özel hayat ve toplumsal beklentiler gibi pek çok çevresel faktör ile tetiklenerek stresli durumlar ile karşılaşmaktadır. İnsan vücudu dolaşım sistemi, sinir sistemi, kas ve iskelet sistemi, solunum sistemi, boşaltım sistemi, üreme sistemi ve sindirim sistemini içerisinde barındıran karmaşık bir organizma olarak tanımlanmaktadır. Sistemler kendi içlerinde ve birbirleriyle uyum içinde çalışırken sistem içerisinde oluşan bir aksaklık dolaylı olarak birbirini etkileyebilmektedir. Stres kaynakları insanlar üzerinde aynı seviyede stres oluşturmayacağı gibi stres kaynaklarını algılama düzeylerine göre birbirinden farklı seviyede tepkiler vermesine de sebep olabilmektedir. İnsan vücudu stresli durumlarla karşılaştığında bununla başa çıkabilmek için fiziksel, psikolojik ve zihinsel tepkiler göstermektedir. Stres belirtileri temel olarak üç farklı kategori altında incelenmektedir [9].

a) Stresin Fiziksel Belirtileri

Stres genel olarak psikolojik bir temele dayandırılmasına rağmen çeşitli sebepler ile strese maruz kalındığında fiziksel stres bireylerde gözle görülebilir etkilere sahiptir [10]. İnsan vücudu bu sorunla başa çıkmak için aşağıda sıraladığımız gibi fiziksel belirtiler gösterebilmektedir.

- Yorgunluk,
- Baş ağrısı,
- Sindirim ve boşaltım sisteminde düzensizlik,
- Hipertansiyon,
- Terleme,
- Oksijen yetersizliği,
- Hormonal ve biyokimyasal dengesizlikler,
- Yeme içme düzeninde dengesizlik,
- Kilo kaybı, kas ağrısı ve kaslarda kasılma,

- Uyku problemleri,
- Ağız kuruluđu,
- Solunum sayısında deęişim,
- Kulak çınlaması,
- Göz bebeklerinde büyüme,
- Cilt kuruluđu-kurdeşen.

b) Stresin Psikolojik Belirtileri

Psikolojik stres bireylerin kişisel durumlar veya çevresel tetikleyicilerine göre deęişiklik göstererek insan vücudunun psikososyal açıdan stres ile yüklenmesi olarak ifade edilmektedir. Fiziksel stresin belirtileri ile karşılaştırıldığında psikolojik stres belirtileri dışardan bakıldığında fark edilmesi zor tepkiler göstermektedir. Psikolojik stres ile yüklendiğinde insan vücudu aşağıda sıraladığımız gibi belirtiler gösterebilmektedir.

- Öfke,
- Anksiyete,
- Hayal kırıklığı,
- Telaş,
- Kendini bulunduğu yere ait hissetmeme,
- Hassasiyet,
- Gerginlik,
- Asabiyet,
- Korku,
- Üzüntü,
- Kaygı,
- Güven duygusunun azalması,
- Duyguların aşırı yaşanması,

- Bıkkınlık.

c) Stresin Zihinsel Belirtileri

Zihinsel stres bireylerin stresli durumlar ile karşılaşması sonucunda düş dünyasında yaşadıkları stresli durumlar olarak ifade edilmektedir. Stresörler tarafından tetiklenen bireylerde aşağıda sıraladığımız gibi belirtiler görülebilmektedir.

- Unutkanlık,
- Gereğinden fazla hayal kurma,
- Karar verme sürecinde güçlük çekme,
- Konsantrasyon bozukluğu,
- Yapılan işte verim düşmesi,
- Motivasyon kaybı,
- Mizah anlayışının azalması,
- Durumlara karşı takıntılı olma.

1.3. Stresi Belirleme Yöntemleri

Stresin yapıcı ve yıkıcı etkileri uzun yıllardır bilinmektedir. Minimal düzeyde tutulabilen stresin bireylerde motivasyon, hırs, rekabet seviyesinin artması vb. konularda olumlu sonuçlar doğurabildiği görülürken, istenmeyen seviyelere ulaşan stres bireylerde fizyolojik, psikolojik ve zihinsel etkiler bırakarak tedavi edilmediği sürece kalıcı hasarlara ve ciddi hastalıklara sebebiyet verebildiği görülmektedir. Bireyler yaşam biçimi, hayata bakış açıları, ekonomik koşulları, beklentileri gibi konularda birbirlerinden ayrıldığı gibi aynı stresörlerden etkilenen bireylerde benzer etkiler görülmeyebilir ve tedavi yöntemleri de kişiden kişiye farklılık gösterebilmektedir.

Uzman hekimler/psikologlar ve araştırmacılar tarafından uzun yıllardır anketler, ikili görüşmeler, davranış gözlemi, hormonal testler ve fizyolojik sinyaller kullanarak stresin

erken tespitini ve en doğru tedavi/müdahale yöntemlerini belirlemesi üzerine birçok çalışma yapılarak stresin yıkıcı etkileri azaltılmaya çalışılmaktadır.

1.3.1. Stresin Belirlenmesi Aşamasında Anket Kullanımı ve Davranış Gözlemi

İnsan vücudunda stresin ortaya çıkması kendi kendine oluşan bir durum değildir. Stresin ortaya çıkabilmesi için bireylerin iş hayatı, aile hayatı, özel yaşantısı vb. bulunduğu ortamlarda gerçekleşen değişimler ile tetiklenmesi gerekmektedir. İnsan vücudunu tetikleyen stresörler her bireyde aynı derecede etki yaratmayabileceği için uzman hekimler/psikologlar tarafından stres oluşturan faktörlerin belirlenmesi ve bu duruma uygun olarak stresin bireyde oluşturduğu etki düzeyinin belirlenmesi için ikili görüşme, davranış gözlemi ve anket kullanımı yapılmaktadır.

Lazarus değerlendirme teorisi bireyin stres düzeyini belirleme sürecini birincil ve ikincil değerlendirme olarak ayırmaktadır. Stresörlerle ilk etkileşimin gerçekleştiği birincil değerlendirme organizmanın tehdit, zarar ve pozitif mücadeleye davet aşamalarını içermektedir. Tehdit ve zarar aşamasında birey fiziksel ve psikolojik tepkiler gösterirken, pozitif mücadeleye davet aşamasında birey motivasyon, hırs gibi pozitif duygular yaşamaktadır. İkincil değerlendirme aşamasında insan vücudunda hem fiziksel hem de psikolojik stres meydana gelmektedir [11].

Stres düzeyinin belirlenmesindeki ilk çalışmalar Holmes ve Rahe oluşturdukları çizelgede stresli durum olarak kabul ettikleri 43 farklı stresör ile stres düzeylerini karşılaştırmışlardır. Ancak bu çalışmada stresörlerin bireylere uygun olup olmadığı kavramı göz ardı edilmiştir [12]. Sarason ve arkadaşlarının stresörlerin bireylerden bağımsız olmadığını savundukları düşünceleri doğrultusunda; bir durumun stresör olarak kabul edilip stres düzeyini belirleme aşamasında kullanılabilmesi için birey ile çevresel faktörleri algılama biçimine uygun olan olayları değerlendirme envanterini geliştirmişlerdir [13]. Vagg ve arkadaşları yapmış oldukları çalışmada stres düzeyinin belirlenmesi aşamasında stresörlerin sürekliliği ve sonucunda oluşturduğu rahatsızlık durumunun birbiri ile olan ilişkisinin göz ardı edilmesiyle nadirde olsa bazı stresli durumların gözden kaçtığını savunmuşlardır [14].

Literatürde yapılan çalışmalar incelendiğinde insan vücudunda oluşan stresin belirlenmesi için geliştirilen anketler/stres değerlendirme ölçekleri belirli gruplar ve belirli koşullar altında incelenmiş olup kapsamlı anket/stres değerlendirme ölçeğine ihtiyaç duyulduğunu göstermektedir.

1.3.2. Stresin Belirlenmesi Aşamasında Hormonal Testlerin Kullanımı

İnsan vücudu içerisinde barındırdığı sistemler ile birlikte muhteşem bir uyumla çalışan karmaşık bir yapıya sahiptir. Dışarıdan gelen uyaran ile tetiklenen insan vücudu sistemler arasındaki uyumu kaybetmemek ve sağlıklı bir şekilde fonksiyonlarını yerine getirebilmek için kendi içerisinde önlemler almaktadır. Stresörler tarafından uyarılan organizma stres ile mücadele etmek için çeşitli hormonların seviyesini değiştirerek mücadele etmeye başlar. Stres durumunda uzman hekimler tarafından seviyeleri incelenen hormonlar aşağıdaki gibidir:

1.3.2.1. Kortizol Hormonu Seviyesi Ölçülerek Stresin Tespiti

Kortizol hormonu hipotalamik hipofiz adrenal (HHA) eksenini aktivasyonu sayesinde kısa vadeli akut stres faktörlerini belirlemek için kullanılan bir biyobelirteçtir. Hargaves yapmış olduğu çalışmada HHA ekseninin uyarılması kortikotropin salma faktörünü tetikleyerek hipofizi adrenokortikotropin, lipotropin ve endorfin salgılaması için uyararak stresli durumlarda insan vücudunda kortizol seviyesinin iki ile beş kat daha arttığını ifade etmiştir [15]. Rodrigues ve arkadaşları yapmış oldukları çalışmada insan vücudunun stresli durumla karşılaştığı yirmi ile kırk dakika boyunca tükürük, idrar ve serumdaki kortizol seviyelerinin en yüksek seviyede gözlemlendiği ifade etmişlerdir [16].

1.3.2.2. Tiroid Hormonu Seviyesi Ölçülerek Stresin Tespiti

Tiroid hormonu, metabolizmanın düzenlenmesi için tiroid bezi tarafından salgılanan iyot kaynaklı kalsitonin, triiyodotironin (T3) ve tiroksin (T4) hormonlarına verilen genel

isimdir. Helmreich ve diğerleri stresin merkezi sinir sistemine etki ederek tiroid hormonunun salgılanmasını engellediğini bu sebeple T3 ve T4 seviyelerinin stres ile birlikte azaldığını ifade etmişlerdir [17]. Nadolnik yapmış olduğu çalışmada kronik ve akut stresin tiroid bezi üzerindeki etkilerini incelemiştir. Akut stres döneminde hipofiz tiroid eksenini aktivasyonunun gerçekleştiği ve uzun süreli kronik stres evresinde baskılandığı görülmüştür [18]. Diğer bir çalışmada Koyuncu ve arkadaşları stres anında ve stresten önce uygulanan T3 ve T4 hormonlarının stres ülserlerinin uzunluğunu ve derinliğini azalttığını bulmuşlardır [19].

1.3.2.3. Katekolamin Hormonu Seviyesi Ölçülerek Stresin Tespiti

Katekolamin hormonu, stresli koşullar altında artarak beyin ve sempatetik nöronlarda tirozin aminoasidinden sentezlenen dopamin, adrenalın ve norepinefrindir. Johnson ve arkadaşları yoğun stres altında katekolamin hormonlarında yoğun artış görüldüğünü ifade etmişlerdir [20]. Elenkov ve diğerleri fiziksel ve psikolojik stresörlerin organizmanın HHA eksenini aktive ederek katekolamin hormonlarının artarak dolaşım sistemine salınmasına neden olduğunu ifade etmişlerdir [21].

1.3.2.4. Vazopressin Hormonu Seviyesi Ölçülerek Stresin Tespiti

Vazopressin hormonu, insan vücudunda kan basıncının düzenlenmesinde, ozmotik dengenin sağlanmasında ve böbrek fonksiyonlarının kontrol edilmesinde önemli rol oynayan nonapeptittir [22]. Jezova ve diğerleri stres koşullarında oksitonin hormonu ve vazopressin hormonu arasında yapmış oldukları karşılaştırma akut stres durumunda vazopressin hormonlarında tutarlı bir artış görüldüğünü ifade etmişlerdir [23]. Diğer bir çalışmada Gal ve arkadaşları vazopressin hormonunun stresli durumlarda HHA ekseninin aktivasyonuna katılarak organizmanın strese karşı tepkisinde nöro-adaptif bir rol oynadığını ifade etmişlerdir [24].

1.3.2.5. İnsülin Hormonu Seviyesi Ölçülerek Stresin Tespiti

İnsülin hormonu, pankreas içerisinde üretilerek kanda bulunan yüksek şeker seviyesini azaltmak için kandaki şekeri hücre içerisine aktaran bir hormon olarak tanımlanmaktadır. Rains ve Jain oksidatif stres, insülin ve diyabet üzerine yapmış oldukları çalışmada stresli durumların insülin sinyallerinde değişiklikler yaparak diyabetin başlangıcında önemli bir risk faktörü olduğunu ifade etmişlerdir [25]. Benzer içerikli farklı bir çalışmada Henriksen ve arkadaşları oksidatif stres altında organizmada gerçekleşen insülin dengesizliğinin sonucu olan glikozun kan dolaşımından uzaklaştırılmasının azalmasına sebep olan insülin direnci üzerine etkilerini incelenmişlerdir [26].

1.3.2.6. Büyüme Hormonu Seviyesi Ölçülerek Stresin Tespiti

Temel görevi kas, kemik ve organların dokusunu artırarak onları güçlendirmek olan büyüme hormonu beyinde bulunan hipofiz bezinde üretilmektedir. Pickering ve diğerleri gökkuşağı alabalıklarının üzerinde yapmış oldukları çalışmada kronik stresin organizmada salgılanan büyüme hormonu konsantrasyonunda önemli derecede artışa sebep olduğunu ifade etmişlerdir [27]. Donahue ve arkadaşlarının yaptığı çalışmada akut stres altındaki kadın ve erkeklerde büyüme hormonu üretiminin arttığı görülmüştür [28].

1.3.2.7. Gonadotropin Hormonu Seviyesi Ölçülerek Stresin Tespiti

Ovülasyon, spermatogenez ve cinsiyet hormonlarının sentezi için gerekli olan gonadotropin hormonu, erkeklerde testis fonksiyonları kadınlarda ise overlerin düzenlenmesini sağlayan hormondur [29]. Kirby ve arkadaşları yapmış oldukları çalışmada kemirgenler ve insanların dahil olduğu birçok tür üzerinde stres deneyiminin HHA eksenine ve hormonal üreme sistemi üzerinde dengesizliklere yol açarak üreme sistemlerinde işlevsel bozukluklara sebebiyet verdiğini açıklamışlardır [30]. Iwasa ve diğerleri yapmış oldukları derleme çalışmasında strese bağlı olarak gonadotropin hormonunun artış göstermesi üreme

sisteminde işlevsel bozukluğa sebep olarak gebelik oranı ve yavru boyutlarında olumsuz etkiler oluşturduğunu ifade etmişlerdir [31].

1.3.2.8. Prolaktin Hormonu Seviyesi Ölçülerek Stresin Tespiti


Prolaktin hormonu, hipofiz bezinde bulunan laktarof hücreleri tarafından bazal hipotalamik nöronlarda sentezlenen ve median eminensten hipofizyal portal vaskülatüre salgılanan hormondur. Stres esnasında organizmaya bağlı olarak prolaktin seviyesinin azaldığı veya artabildiği görülmektedir. Angelier ve Chastel yapmış oldukları çalışmada stresörler tarafından tetiklenen organizmada prolaktin hormonu seviyesinin düşmesinin ebeveynin hayatta kalmasını sağlayan bir taktik olduğunu ifade etmişlerdir [32]. Lennartson ve diğerlerinin 15 kadın ve 30 erkek denek üzerinde psikobiyolojik stres tepkilerini ölçtükleri çalışmada prolaktin hormonu seviyesinde önemli ölçüde artış olduğunu ifade etmişlerdir [33].

1.3.3. Stresin Belirlenmesi Aşamasında Fizyolojik Sinyallerin Kullanımı

Organizmanın fizyolojik stres tepkisi çevresel faktörler ile etkilenecek ortaya çıkan bedensel değişiklikler olarak tanımlanmaktadır. Stres değerlendirme aşamasında yapılan çalışmalar; kullanılan yöntemler ve tanıma bağlı kalma, geniş kapsamlı inceleme yapılmaması gibi kişiye bağlı olup bir takım sistematik ölçüm hatalarından kolaylıkla etkilenebilmektedir. Aynı zamanda stres sonucu oluşması muhtemel vücut hareketi, yüz ifadesi gibi davranışsal kalıplarda bilinçli bir şekilde yapılabilen hareketler olduğu için stresli durumların tespiti ve seviyelerinin ölçülmesi aşamasında bir takım kişiye bağlı sistematik ölçüm hataları barındırabilmektedir. Bu durum bireysel olarak kontrolü mümkün olmayan (istemsiz) ve değerleri manipüle edilemeyecek fizyolojik sinyallerin kullanımına olan ihtiyacı gözler önüne sermektedir. Stres algılama yaklaşımlarında EKG, EEG, kan hacmi basıncı (BVP), EMG, elektrodermal aktivite (EDA), solunum (RSP), cilt sıcaklığı (SKT), göz bebeği çapı (PD), cilt iletkenliği (GSR), kalp atış hızı değişkenliği (HRV) sıklıkla tercih edilen fizyolojik sinyallerdir [34, 35].

1.3.3.1. Elektrokardiyografi Sinyalleri Kullanılarak Stresin Tespiti

EKG; kalp atışlarının ritmi, hızı, düzensizlikleri ve güç değerleri hakkında bilgi veren elektriksel aktivitelerin kaydedilerek grafik olarak görüntülenebilmesi için kullanılan bir yöntemdir. EKG cihazları ile kalbin tam olarak elektrokardiyografik sinyallerinin ölçülebilmesi için 12 deri elektrotu kullanılarak EKG'si çekilmektedir. EKG kalbin farklı bölgelerinde bulunan depolarizasyon ve repolarizasyon kas liflerinde oluşan elektriksel sinyalleri kaynak noktası olarak belirlemektedir. EKG döngüsü kalp aktivitelerine farklı açılardan bakan 5 farklı (P, Q, R, S, T) dalgadan oluşmaktadır [36]. Şekil 1'de EKG grafiği verilmiştir.



Şekil 1. EKG Grafiği

Kalp üst odacıklarındaki depolarizasyon P dalgası olarak kaydedilmektedir. Atriyal anormalliklerin tespit edilmesi için P dalgasının süresi, amplitüdü ve frekansı gözlemlenmektedir. Q, R, S dalgaları bir araya gelerek QRS kompleksini oluşturmaktadır. QRS dalgası ventriküllerin depolarizasyonunu ve atriyumların repolarizasyonu yansıtmaktadır. T dalgası ise ventriküler repolarizasyonu yansıtmaktadır [36].

Yaygın olarak hastanelerde ve kliniklerde kalpte meydana gelen işlevsel bozuklukları belirlemek için kullanılan EKG; kardiyovasküler hastalıkların tespiti ve tedavisi açısından

çok önemli parametreler sunmaktadır. EKG kalp rahatsızlığının belirlenmesi aşamasında kullanılmasının yanı sıra birçok araştırmacı tarafından stres seviyesinin belirlenmesi ve duygu tanıma gibi farklı alanlarda da kullanılmaktadır.

Pereira ve diğerleri yaşları 20 ile 26 arasında değişen 14 farklı katılımcı üzerinde dinlenme verileri, iş görüşmesi protokolü hazırlama/sunma ve aritmetik test görevlerinden oluşan 12 dakikalık stres oluşturma protokolü olan Trier Sosyal Stres Testini (TSTT) uygulayarak EKG verilerinin stresli durum ile stressiz durum arasında farkı belirlemek için güvenilir parametreler olduğunu göstermişlerdir [37]. Bir diğer çalışmada Pinge ve arkadaşları yaşları 25 ile 35 arasında değişen 5 farklı katılımcının topluluk önünde konuşması, mental aritmetik test görevlerini çözmesi, ellerini buz kovalarına sokması ve dinlenmelerini isteyerek 45 dakika boyunca stresli ve stressiz verilerini kaydederek EKG monitöründen okudukları kalp atış hızı ve stres algılamadaki performanslarını karşılaştırarak %80.00'in üzerinde doğruluk oranı elde etmişlerdir [38].

1.3.3.2. Elektrodermal Aktivite Sinyalleri Kullanılarak Stresin Tespiti

EDA, vücutta cildin altında bulunan sinir sisteminin yaymış olduğu epidermal ve dermal dokularda ortaya çıkan aktif ve pasif elektriksel sinyalleri ölçebilen ve elektriksel sinyallerde oluşan değişimlerin grafik olarak görüntülenebilmesini sağlayan bir yöntem olarak tanımlanmaktadır. Termal uyaranlara görece psikolojik uyaranlara daha duyarlı olan ter; içerisinde mineraller, üre ve laktik asit barındırmasında rağmen büyük bir çoğunluğu sudan oluşmaktadır. Vücutta terlemenin artması deride elektriksel iletkenliği artırmaktadır. EDA vücudun ter salgısına yanıtı olarak oluşan elektriksel değişim olarak kabul edilmektedir [39].

EDA; sinir sistemi ve beyin arasındaki aktivite ile ilişki olarak insanlarda meydana gelen bedensel reaksiyonlar, düşünceler ve duygusal durum değişikliklerini yansıtabilmektedir. Tarihte üzerine birçok çalışma yapılan EDA; galvanik cilt tepkisi (GSR), deri iletkenlik yanıtı ve sempatik deri yanıtı olarak da bilinmektedir ya da bu terimlerle oldukça yakından ilişkilidir [40]. Literatürde yapılan çalışmaların çoğunda EDA eller ve parmakların üzerine yerleştirilen çift elektrot ile ölçülmektedir. Şekil 2'de EDA elektrotlarının kullanımı verilmiştir.



Şekil 2 EDA Elektrotlarının Kullanımı [41].

Kalp atışı, tansiyon ve diğer vücut fonksiyonlarının gözlemlenmesi gibi tıbbi parametrelerde veya kişisel gelişim süreçlerinde duygu durumunun izlenmesi, görsel-işitsel tasarım araştırmalarında duygusal tepkinin ölçülmesi gibi psikolojik tespitler için sıklıkla tercih edilen EDA aynı zamanda stres seviyesinin belirlenmesi aşamasında da kullanılmaktadır.

Liu ve Du yaptıkları çalışmada 11 farklı araç sürücüsünün dinlenme, otoyol ve şehir içi olmak üzere sürüş deneyimlerini EDA sinyallerini kullanarak kaydederek üç farklı sürüş durumunu az stresli, orta stresli ve yüksek stresli olarak tanımlamışlardır. Stres seviyesi belirlerken %81.82'lik performans elde etmeyi başarmışlardır [42]. Diğer çalışmada Lee ve arkadaşları 36 deneğin akademik sınav süresince deneyimledikleri stresli durumlar ile rahat durumların el cihazı ile kaydedilen EDA verilerini kullanarak %87.50 oranında tespit etmeyi başarmışlardır [43]. Benzer içerikli bir diğer çalışmada Acevedo ve diğerleri akademik sınav döneminde öğrencilerde oluşan stresin tespiti için GSR ve E-burun kullanılarak geliştirdikleri bir metodoloji üzerine çalışmışlardır. Pandemi döneminde 25 farklı öğrencinin mart ve haziran aylarında girdikleri akademik sınavlarda stresli verileri, sınav sonrasında gevşeme verileri GSR sinyalleri ile toplanarak stres başarıyla tespiti %100.00 olarak sınıflandırmayı başarmışlardır [44].


1.3.3.3. Kan Hacmi Basıncı Sinyalleri Kullanılarak Stresin Tespiti

Kan hacmi, vücudun enerji ihtiyacını karşılamak için gerekli olan oksijen ve besin maddelerini taşıyan bir maddedir. BVP; vücutta kan hacmini, vücuttaki kan hacminin değişimine paralel olarak meydana gelen basınç değişimlerini ölçen ve bu değişimleri grafik olarak gösterebilen bir yöntemdir. BVP ölçümleri, kalp atım hızı, kan hacmi, kalp hacmi ve vasküler direnç gibi kardiyovasküler sistemdeki değişiklikleri ölçmek için kullanılır. Ölçümler, arterlerde yerleştirilen transdüserler aracılığıyla yapılmaktadır. Kan hacminin aşırı yükselmesi hipertansiyon olarak adlandırılmaktadır. BVP’de gerçekleşen orantısız değişimler ciddi sağlık sorunlarına hatta ani ölümlere sebebiyet verebilmektedir bu sebeple hekimler tarafından özellikle kardiyovasküler hastalıkların tespitinde kullanılan önemli parametrelerden birisidir. Stresli durumlarda vücut noradrenalin, adrenalin gibi hormonlar salgılayarak BVP oranlarında değişimlere sebebiyet verebilir. Bu durum hem stresli durumun keşfedilmesi hem de değişen hormon seviyelerinin nasıl bir etki gösterdiği hakkında fikir verebilir.

1.3.3.4. Elektromiyografi Sinyalleri Kullanılarak Stresin Tespiti

EMG, hayvan ve insanlarda elektriksel uyarıların (kas kasılmasını sağlayan) incelendiği bir medikal ölçüm tekniğidir. Bu uyarılar, beyinden gönderilen sinyallerle gerçekleşen Motor Ünite Aksiyon Potansiyelleri (MÜAP) tarafından yaratılır. Kas kontraksiyonunun şiddeti, MÜAP sayısı ve frekansı ile ilişkilidir. EMG, normal veya anormal elektriksel uyarıların varlığını, kas sorunlarını analiz etmek için kullanılan faktörler arasındadır.

EMG sinyalleri aktif ve pasif yüzey elektrotlar kullanılarak deri üzerinde bulunan kas bölgesine yerleştirilen (non invaziv) ya da iğne elektrotlar kullanılarak kas içine elektrotların yerleştirilmesi (invaziv) ile elde edilebilmektedir [45]. Yüzey elektrotlar ve iğne elektrotlar Şekil 3’te verilmiştir.




Şekil 3 Yüzey elektrotlar ve iğne elektrotların kullanım yerleri [46]

EMG, kasların kontrakte veya rahat olduğu durumlarının elektriksel yanıtlarını ölçerek, kasların sağlıklı çalışması veya hastalık durumları hakkında bilgi verir. EMG, doktorlar ve fizyoterapistler tarafından sadece kas aktivitesinin değil aynı zamanda sinir uçlarının ve sinir-kas bağlantısının da teşhis ve tedavisinde kullanılan önemli bir araçtır [47]. Stresörler tarafından tetiklenen kişilerde kas gücünün azalması gibi belirgin bir kas aktiveleri görülebildiği için EMG sinyalleri fizyolojik stresin tespiti için güvenilir ölçüm yöntemlerinden biri olarak kabul edilmektedir [48]. Bu sebeple EMG sinyallerinin stresin tespiti aşamasında kullanılması sıklıkla tercih edilen fizyolojik sinyallerden birisi olarak ön plana çıkmaktadır [49]. Duran-Acevedo ve diğerleri pandemi döneminde yaptıkları çalışmalarında 25 gönüllü öğrencinin çevrimiçi düzenlenen akademik bir test esnasında oluşan stresli durumlarını ve gevşeme durumunda oluşan EMG sinyallerini kullanarak %88.00 oranında başarı elde etmişlerdir [50]. Diğer bir çalışmada Karthikeyan ve arkadaşları stres seviyelerinde oluşan değişim ile kas gerilimleri arasındaki ilişkiyi incelemişlerdir. Çalışmada 10 kadın denek üzerinde hazırladıkları Stroop renk-kelime test protokülü ile oluşan stresli durumu ve gevşeme anının EMG sinyallerini kaydederek stres seviyelerinin değerlendirmesinde kullanarak %90.70 doğruluk oranı elde etmişlerdir [51].

1.3.3.5. Cilt Sıcaklığı Sinyalleri Kullanılarak Stresin Tespiti

İnsan cildi; yaralanmalara ve bakterilere karşı koruma, terleme ve izolasyon ile sıcaklığın düzenlenmesi, su içeriğinin düzenlenmesi gibi hayati görevlere sahip olan ve yüzeyinin hemen altında kan damarları, sinirler, hormonal bezler ve kılları barındıran en büyük yüzeye sahip organdır [52]. Şekil 4'te insan cildinin şematik görseli verilmiştir. İnsan vücudu yapısı gereği 3 µm ile 10 µm arasında değişen dalga boyu aralığında yayılan termal emisyonu sahiptir. SKT ölçümü ciltten yayılan kızılötesi dalgaların kızılötesi görüntüleme tekniği kullanılarak belirlenmektedir [53]. İnsan vücudunun ortalama sıcaklığının hesaplanabilmesi için vücut üzerinde çok sayıda bölge belirlenmesi ve her birinden ölçüm alınarak hesaplanması gerekmektedir. Ancak bu durum hem çok fazla zaman kaybına sebep olması hem de hata yapma olasılığının yüksek olması sebebiyle tercih edilmemektedir. Bunun yerine ölçülmek istenen sıcaklık parametreleri belirlenen bölgede deri sıcaklığını en iyi temsil edilebileceği bilinen yüzeylerden yapılmaktadır [54].



Şekil 4. İnsan derisinin genel gösterimi [55]

Vücut sıcaklığının yükseldiği durumlarda doğru orantılı bir şekilde cilt sıcaklığını da etkilediği bilinmektedir. Uzman hekimler cilt yüzeyinde yaptıkları sıcaklık ölçümleri ile vücut sıcaklığının artmasına sebep olan enfeksiyon, febril hastalıklar, komplikasyonlar gibi birçok hastalığının tespitini yapmaktadır. Stresli durumlarda organizma istenmeyen durumla

başa çıkabilmek ve dengesini sağlayabilmek için çeşitli hormonlar salgılayabilmekte ve bu durumda vücut sıcaklığının değişmesinde rol oynamaktadır. SKT stresin belirlenmesi aşamasında uzman hekimler ve araştırmacılar tarafından kullanılmaktadır. Yamakoshi ve diğerleri 25 deneği sabit hızda simüle edilmiş monoton bir seyahat testine sokarak sürüş anında sürücünün farkındalığının azalarak güvenli sürüş modunu sürdürebilmek için oluşan stres seviyeleri üzerine çalışmalar yapmışlardır. Sürüş anında deneklerin cilt sıcaklıkları, toplam periferik dirençleri, kardiyak debileri ve kan basıncında gerçekleşen değişimleri gözlemlenerek farklı stres ölçümlerinde cilt sıcaklığının stres seviyesini belirleyen önemli belirteçlerden biri olduğunu açıklamışlardır [56]. Farklı bir çalışmada Pisanski ve arkadaşları 80 sağlıklı denek üzerinde oluşan akut stres tepkisini ortaya çıkarmak için eleştiri ve sunum odaklı TSST kullanmışlardır. Her bir testin 2 saat sürdüğü çalışmada stresli ve gevşeme durumlarında deneklerden tükürük hormonu, ses ve yalan makinesi verileri toplanarak stresli durumlarda elde edilen fizyolojik ölçümlerde kadınlarda ve erkeklerde cilt sıcaklığında azalmalar olduğu görülmüştür [57].

1.3.3.6. Solunum Sinyalleri Kullanılarak Stresin Tespiti

Solunum sistemi; göğüs duvarının sürekli kas hareketi sonucunda akciğerler vasıtasıyla çevre ile gaz alışverişini sağlayarak organizmanın ihtiyaç duyduğu oksijeni hücreler seviyesine ulaştıran hayati öneme sahip sistemdir [58]. Solunum sisteminin ana görevi organizmanın ihtiyaç duyduğu oksijenin içeriye alınması ve biriken karbondioksitin dışarıya atılmasını sağlamaktır. Diğer görevi ise solunum yolu ile nemlendirilmiş havanın giriş ve çıkışını sağlayarak organizmanın sıcaklık kontrolünü sağlamaktır. Bir diğer görevi de kanda bulunan karbondioksit düzeyini kontrol altına alarak kanın pH seviyesinin düzenlenmesini sağlamaktır.

Solunuma bağlı hastalıkların tedavisinde solunum hızının ve hacminin ölçülmesi hastanın erken tedavi edilmesi için kritiktir. Solunum sisteminin genel şeması Şekil 5'te verilmiştir. Literatürde yaygın olarak kullanılan birçok solunum ölçme yöntemi ana hatlarıyla fiziksel temas gerektiren (solunum empedansı, hasta izleme monitörü, spirometri vb.) ve fiziksel temas gerektirmeyen (kamera yöntemleri, mobil cihazlar vb.) olarak sınıflandırılmaktadır [59].

vücut ağırlığı çömelmesi ve psikolojik stres testi esnasında Stroop Renk Kelime testini yapmaları istenmiştir. Test aşamalarında solunum sinyalleri kaydedilen katılımcıların stres seviyelerinin doğruluk oranları %90.00 seviyelerine ulaşmıştır [63]. Diğer çalışmada Han ve diğerleri iş ortamında oluşan aşırı stresin tespiti için 39 deneğin verilerini EKG ve Solunum sinyallerini aynı anda ölçebilecek giyilebilir sensör kullanarak kaydetmişlerdir. Katılımcılar zihinsel aritmetik test ve sosyal değerlendirme soruları içeren ortalama stres testi, yüksek stres testi ve gevşeme durumu, iyileşme periyodundan oluşan toplamda 18 dakikalık 4 farklı süreçten geçirilmişlerdir. Elde edilen EKG ve solunum sinyalleri ile stres yok, orta düzey stres ve yüksek stres algılamasında %84.00 oranında doğruluk elde etmeyi başarmışlardır [64].

1.3.3.7. Göz Bebeği Çapı Sinyalleri Kullanılarak Stresin Tespiti

Göz bebeği; antagonistik kas yapılarından oluşan pigmentli yapıya sahip iris açıklığı olarak tanımlanmaktadır. Temel görevi ışığın göze girerek görme işleminin başlatılmasıdır. Sempatik sinir sistemi ve parasempatik sinir sisteminden oluşan Otonom sinir sistemi tarafından kontrol edilen göz bebeği çapı 1,5 mm ile 8-9 mm arasında hareket alanına sahiptir [65, 66]. Şekil 6'da göz bebeği çapındaki değişimler verilmiştir. Göz bebeği çapının ölçülmesi için göz algılama, göz bebeği algılama ve göz bebeği çapı ölçülmesi olarak 3 temel adım bulunmaktadır. Literatürde algılama yöntemleri ve görüntü işleme algoritmaları ile ölçüm alınması üzerine birçok farklı yöntem mevcuttur [67].



Şekil 6. Gözbebeği çapında gerçekleşen değişikliklerin fiziksel gösterimi [68]

Beyin veya göz patolojisi bulunan hastalarda göz bebeği çapı ölçümleri bilinç açıklığının kontrolü, diyabet hastalarının teşhisi, nörolojik hastalıklar, beyin tümörü, çocukluk dönemi kataraktı, hipotoni, glaukom gibi farklı hastalıkların teşhis aşamasında kullanabilmektedir. Stres üzerine yapılan çalışmalarda da göz bebeği çapı duygusal ve bilişsel durumların incelenmesinde önemli değişkenlerden biri olarak görülmektedir. Stres ve yoğun duygu anında göz bebeği çapı genişleme eğilimi gösterirken, gevşeme durumlarında göz bebeği standart formuna dönme eğilimi göstermektedir [69]. Pedrotti ve arkadaşları araştırmalarına katılım sağlayan 32 öğrencinin gevşeme durumu, trafiksiz ve üç şeritli bir yolda simüle edilen şerit değiştirme stresi testi, sesle uyarılma ve deneyçiler tarafından uyarılması aşamalarından oluşan dört farklı süreç içerisinde göz bebeği çapı sinyallerinde oluşan değişiklikleri gözlemlemiştir. Çalışmanın sonucunda öğrencilerden elde edilen göz bebeği çapı sinyallerinin stresi belirleme oranını %79.20 olarak tahmin edebilmişlerdir [70]. Farklı bir çalışmada ise Ren ve diğerleri oluşturdukları çevrimiçi ve çevrimdışı algoritmaları kullanarak stres ve gevşeme durumunda göz bebeği çapı sinyallerinde oluşan değişiklikleri incelemiştir. 19 farklı denegin kullanıldığı çalışmada stroop renk-kelime testi ile her bir denek için 30 dakika süren stres testi uygulanarak çevrimiçi algoritmada %72.30, çevrimdışı algoritmada %86.43 doğruluk oranı elde edilmiştir [71].

1.3.3.8. Kalp Atış Hızı Değişkenliği Sinyalleri Kullanılarak Stresin Tespiti


HRV birbiri ardına gelen iki kalp atışı arasındaki zaman aralıklarının değişmesi olarak tanımlanmaktadır. HRV, EKG ölçümlerinde oluşan QRS kompleksi içerisindeki R – R dalgaları aralıklarında meydana gelen zaman değişimi olarak bilinmektedir. HRV'nin grafiksel gösterimi Şekil 1'de verilmiştir. HRV analizi için frekans ve zaman alanı ölçümleri kullanılmalıdır direkt EKG verilerinden hesaplanamamaktadır. Frekans alanı ölçümü için dört farklı frekans bandı kullanılır. Bunlar ultra düşük frekans (< 0.003 Hz), çok düşük frekans ($0.03 - 0.004$ Hz), düşük frekans ($0.04 - 0.15$ Hz) ve yüksek frekans ($0.15 - 0.4$ Hz)'dir. Zaman alanı ölçümü için normalde normale aralıklarının standart sapması ve RR aralıklarının kök ortalama karesi yaygın olarak kullanılmaktadır [72].

Klinik ve deneysel çalışmaların çoğunda kardiyovasküler hastalıkların tanımlanmasında önemli bir rol oynayan HRV sinyalleri birçok farklı hastalığında öngörüsünü yansıtmaktadır. Aynı zamanda HRV sinyallerinde gerçekleşen orantısız değişimler insan sağlığı için büyük bir tehlike oluşturmaktadır [73]. Bilişsel yük, duygu değişikliği ve stresli durumlarda otonom sinir sistemi tarafından üretilen fizyolojik tepkilerden birisi de HRV oranlarında değişikliğe neden olmasıdır [74]. Bu durum stres tespiti aşamasında HRV sinyallerinin birçok farklı çalışmada stresi belirlemek için kullanılan dikkate değer parametrelerden birisi haline getirmiştir.

Melillo ve diğerleri çalışmalarında üniversite sınavında öğrencilerde oluşan stresi kullanarak gerçek hayatta karşılaşılan stres kaynağını ele almışlardır. 42 öğrencinin katılım sağladığı çalışmada 5 dakikalık HRV kayıtları hem üniversite sınavı esnasında hem gevşeme durumlarında kaydedilerek stresin gevşeme durumundan ayırt edilebilmesi için kullanılmış ve %90.00 doğruluk oranı elde edilmiştir [75]. Purnamasari ve arkadaşları 10 deneğin katılım sağladığı çalışmalarında stroop renk-kelime testi, anagram testi ve aritmetik testlerden oluşan 3 farklı stres aşaması ve gevşeme aşamasından oluşan Android uygulama geliştirmişlerdir. Stres ve gevşeme aşamasında HRV sinyalleri kaydedilen deneklerin stres tespitinde %79.17 doğruluk elde etmişlerdir [76]. Bir diğer çalışmada Szakonyi ve diğerleri yaşları 50'nin üzerinde olan 7 katılımcıyı topluluk önünde konuşma ve stroop renk-kelime testinden oluşan 2 farklı stresör ile tetikleyerek hem stresli durumlardaki hem de gevşeme durumlarındaki HRV sinyallerini kaydederek stresi %96.31 oranında tespit edebilmişlerdir [77].

1.3.3.9. Elektroensefalogram Sinyalleri Kullanılarak Stresin Tespiti

Vücudun en karmaşık yapıya sahip organı olan insan beyninin bilgi işleme, tepki verme, bilgileri saklama süreçlerini milyarlarca sinir ile yürüten merkezi sinir sisteminin en önemli organı olduğu bilinmektedir. EEG sinyalleri; beyinde gerçekleşen fonksiyonel aktivitelerin gözlemlenebilmesi için kafa derisinde konumlandırılan elektrotlar yardımıyla beyinde gerçekleşen elektriksel değişimleri izlemek için kullanılmaktadır. Beyinde meydana gelen elektriksel aktiviteler nöronlar arasında bilgi iletimi görevini üstlenen sinapslar aracılığıyla gerçekleşmektedir. Şekil 7’de içerisinde birçok nörolojik bilgiyi barındıran EEG sinyal işaretinin örneği gösterilmiştir.



Şekil 7. Nörolojik bilgi içeren EEG sinyal işareti örneği


EEG sinyal işaretleri tepeden tepeye 1-400 μV genliğe, 0.5-100 Hz frekans bandına sahip olmakla birlikte çalışmalar çoğunlukla Alfa (α), Beta (β), Teta (θ) ve Delta (δ) olmak üzere farklı aktiviteleri ifade edebilen dört farklı frekans bandı üzerinde yoğunlaşmıştır [78]. Şekil 8’de EEG sinyallerinin dört farklı frekans dalgasının görülebildiği grafik verilmiştir. Bu frekans bantlarının genel özellikleri aşağıda verildiği gibidir;

Delta (δ) Dalgası: Frekans aralığı 0.5-4 Hz arasında değişmektedir. Genlik değerleri 20-400 μ V arasında değişmektedir. Delta dalgası derin uyku, beyinsel fonksiyonların neredeyse devre dışı kaldığı veya çok az aktivite gösterebildiği durumlarda ölçülebilmektedir.

Teta (θ) Dalgası: Frekans aralığı 4- 8 Hz arasında değişmektedir. Genlik değerleri 5-100 μ V arasında değişmektedir. Teta dalgası genellikle çocuklar ve genç yaştaki yetişkinlerde görülen beynin dikkat fonksiyonlarının yoğun olduğu uyanık ve gevşemiş durumlarda ölçülebilmektedir.


Alfa (α) Dalgası: Frekans aralığı 8- 13 Hz arasında değişmektedir. Genlik değerleri 2-10 μ V arasında değişmektedir. Alfa dalgası zihinsel ve fiziksel olarak dış etkenlerin olmadığı rahatlama, gevşeme durumlarında gözü kapalı olan kişilerden kaydedilerek ölçülebilmektedir.

Beta (β) Dalgası: Frekans aralığı 14- 26 Hz arasında değişmektedir. Genlik değerleri 1-5 μ V arasında değişmektedir. Beta dalgası zihinsel olarak dikkatli ve uyanık durumlarda beyin aktivitelerinin düşünceli, stresli veya dikkatli olması gibi durumlarda ölçülebilmektedir.



Şekil 8. EEG sinyal işaretlerinde oluşan dalga biçimleri [79]

EEG sinyal işaretleri kafa derisine konumlandırılan elektrotlar yardımıyla ölçülebilmektedir. Uluslararası Elektroensefalografi ve Klinik Nörofizyoloji federasyonu kafa derisine yerleştirilen elektrotların konumlarını standardize etmek amacıyla 10-20 elektrot yerleştirme sistemini benimsemişlerdir [80]. Bunun sebebi kafa derisi üzerine yerleştirilen elektrotların orantılı olarak beynin her bölgesini kapsayacak şekilde konumlandırılabilmesidir. Bu standartta elektrotlar parietal, oksipital, frontal, temporal ve central olmak üzere 5 farklı bölgede etiketlenilmektedir. Şekil 9'da 10-20 elektrot sistemi ile konumlandırılan elektrotlar gösterilmiştir.



Şekil 9. 10-20 elektrot sistemine göre konumlandırılan elektrotlar [81]

EEG sinyalleri epileptik nöbetler, depresyon, baş ağrısı, uyku evreleri gibi beyin fonksiyonlarının izlenmesi durumunda tespit edilmesi muhtemel birçok hastalığın tanısı ve izleme süreçlerinde hastaneler ve kliniklerde kullanılmaktadır. Aynı zamanda bireylerin stresli durumlarında merkezi sinir sisteminde oluşan tepkileri ve beyin fonksiyonlarını ifade edebilme potansiyelinin yüksek olması sebebiyle stresin tanı aşamasında da kullanılmaktadır. Tsai ve diğerleri 25 denegın katıldığı çalışmalarında stresli ve stressiz durumlar için aritmetik test, Stroop renk-kelime testi ve gevşeme anında kaydedilen EEG sinyallerini kullanmışlardır. 25 denek üzerinde stresli durum ile gevşeme anının

kıyaslanmasında %94, sadece ilk 5 deneğin verilerinin kullanıldığı her iki stresli durum ve gevşeme anının kıyaslanmasında ise %86,49 doğruluk oranına ulaşmışlardır [81]. Benzer içerikli diğer çalışmada Perez-Valero ve arkadaşları 23 deneğin katılım sağladığı çalışmalarında aritmetik test, sosyal baskı içeren Montreal görüntüleme stres görevi (MIST) testi ve sanal gerçeklik gözlüğü ile stresli ve stressiz durumlar oluşturmuşlardır. Deney esnasında EEG sinyalleri kaydedilen deneklerin stresli ve stressiz durumlarının sınıflandırılmasında %90 üzerinde doğruluk oranı elde etmeyi başarmışlardır [82].

1.4. Literatür Araştırması

Stresin belirlenmesi sürecinde dış uyaranlar ile tetiklenen EEG sinyallerinin kullanımı birçok çalışmada yer almaktadır. EEG sinyallerinin yaygın bir şekilde kullanılmasının sebeplerini nörofizyolojik aktivitelerde beyin fonksiyonlarını iyi derecede yansıtabilmeleri, ölçüm maliyetlerinin düşük olması, kapsamlı donanım gerektirmemeleri ve yüksek sınıflandırma doğruluğu verebilmeleri olarak sıralandırabiliriz. Çalışmaların bir kısmında bireylerde oluşan stresli ve stressiz durumun kıyaslanması yapılarak stresin olup olmadığına karar vermek üzere 2 sınıflı karar verme mekanizması kullanılmaktadır.

Kaminska ve arkadaşları çalışmalarında 28 deneğin 32 kanallı EEG sinyallerini sanal gerçeklik gözlüğü (stroop renk-kelime testi, gevşeme) ile oluşturdukları süreçte kaydederek SVM ve çok katmanlı algılayıcı sınıflandırıcılarında %96.42 doğruluk oranı elde etmişlerdir [83]. Benzer bir çalışmada Al-Shargie ve diğerleri birbiri ardına devam eden yıllarda MIST (mental aritmetik test) ve gevşeme durumlarında 5, 22 ve 25 katılımcının 7 kanallı EEG sinyallerini ve fonksiyonel yakın kızıl ötesi spektroskopilerini kaydederek 3 farklı çalışma yürütmüşlerdir. SVM sınıflandırma algoritması ile en yüksek doğruluk oranı elde edilen çalışmalarda 5 deneğin verilerinde %95.00, 22 deneğin verilerinde %91.70 ve 25 deneğin verilerinde %89.90 sınıflandırma doğruluğuna ulaşmayı başarmışlardır [84–86]. Bir diğer benzer içerikli çalışmada ise Chen ve arkadaşları katılımcıların kaygı derecelerini puanladıkları ölçek ile stresli durumlarını ve gevşeme durumları belirtmelerini isteyerek bu süreçte 34 deneğin 6 kanallı EEG sinyalleri ile kaydetmişlerdir. SVM sınıflandırma algoritması ile stresli durumun belirlenmesinde %88.60, stressiz durumun belirlenmesinde ise %92.48 doğruluk oranı elde etmeyi başarmışlardır [87]. Farklı bir çalışmada ise Ahn ve

diğerleri 14 farklı katılımcının stresli durumlar (stroop renk-kelime test, mental aritmetik test) ve stressiz durumlar (gevşeme) esnasında 2 kanallı EEG ve 1 kanallı EKG verilerini kaydetmişlerdir. SVM sınıflandırma algoritması kullanılarak stresli durum ile gevşeme anının 2 sınıflı sonuçlarını EEG verilerinde %77.90, EKG verilerinde %75.00 ve EEG ile EKG verilerinin birlikte kullanımında %87.50 olarak belirlemişlerdir [88]. Benzer çalışmada Xu ve arkadaşları oluşturdukları deney prosedüründe 39 deneğin stresli (hafıza, dikkat ve hesaplama) ve gevşeme anında oluşturdukları fizyolojik sinyallerini 2 kanallı EEG, 2 kanallı EKG, 3 kanallı EMG ve 2 kanallı GSR ile kaydetmişlerdir. Stresli ve stressiz durumun karşılaştırıldığı 2 sınıflı çalışmada k-means algoritması ile sınıflandırma doğruluğu %85.00 olarak hesaplanmıştır [89]. Farklı fizyolojik sinyallerin kombinasyonlarını kullanan benzer içerikli bir diğer çalışmada ise Masood ve Alghamdi 24 deneğin 2 kanallı EEG verilerini, HRV ve EDA verileri ile aynı süreçte kaydetmiştir. Stresli (Stroop renk-kelime testi) ve stressiz (gevşeme) verileri evrişimli sinir ağı modeliyle doğrularak EEG sinyallerinde %87.50, EEG sinyalleri ve diğer fizyolojik sinyallerin kombinasyonunda ise %90.00 sınıflandırma doğruluğuna ulaşmışlardır [90].

EEG sinyalleri üzerine yapılan çalışmaların büyük bir çoğunluğunda ise stresli durumlar ve stressiz durumun 3 sınıflı veya 4 sınıflı karar verme mekanizması ile çoklu stres faktörlerinin aynı anda belirlenmesi hedeflenerek stresin erken tespiti üzerine yoğunlaşmaktadır. Jun ve arkadaşları çalışmalarında 10 katılımcının stresli (stroop renk-kelime, mental aritmetik) ve stressiz (gevşeme) durumlar için oluşturdukları test sürecinde 14 kanallı EEG verilerini kaydetmişlerdir. SVM sınıflandırma algoritması ile en iyi performansa ulaşarak 2'li sınıflandırmada stroop renk-kelime için %88.00 ve mental aritmetik için %96.00, 3'lü sınıflandırmada ise %75.00 doğruluk oranı elde etmişlerdir [91]. Farklı fizyolojik sinyallerinde kullanıldığı benzer içerikli bir diğer çalışmada ise Zanetti ve diğerleri aritmetik test, video oyunu ve gevşeme süreçlerinde 14 kanallı EEG sinyallerine ek olarak EKG, BVP ve solunum sinyallerini de 17 katılımcı için kaydetmişlerdir. Tüm fizyolojik sinyallerin kullanıldığı 3 sınıflı çalışmada lojistik regresyon ve KA algoritmalarında %84.60 doğruluk performansı elde edilirken EEG sinyalleri çıkarılarak yapılan 3 sınıflı çalışmada doğruluk oranının %76.50'e düştüğü görülmüştür [92]. Bir diğer benzer çalışmada Minguillon ve arkadaşları 10 deneğin MIST (mental aritmetik test), gevşeme durumlarında 8 kanallı EEG, 1 kanallı EKG, 2 kanallı EMG ve 2 kanallı GSR verilerini kaydetmişlerdir. Stresli, nötr ve gevşeme durumlarının tespit edildiği 3 sınıflı

çalışmada lineer diskriminant analiz sınıflandırma algoritması ile en yüksek sınıflandırma doğruluğu %86.00 olmuştur [93]. Farklı bir çalışmada ise Plechawska-Wójcik ve arkadaşları aritmetik test kullanarak 12 farklı katılımcının gevşeme, düşük ve yüksek seviye bilişsel yük durumlarını oluşturmuşlar ve bu esnada 19 kanallı EEG verilerini kaydetmişlerdir. 3 farklı durum için oluşturulan verilerin doğruluk oranını k-EYK sınıflandırma algoritması ile %91.50 olarak tespit etmeyi başarmışlardır [94]. Benzer içerikli bir diğer çalışmada Zhang ve diğerleri deney prosedürlerinde 3 farklı düzeyde stres süreci MIST (aritmetik test) ve gevşeme süreçleri oluşturarak 25 deneğin 4 kanallı EEG verilerini kaydetmişlerdir. Lineer diskriminant analiz algoritması kullanarak eğittikleri veri kümelerinde en yüksek sınıflandırma doğruluğu 2 sınıflı (stres-gevşeme) için %85.60, 3 sınıflı (2 stres-gevşeme) için %71.20 ve 4 sınıflı (3 stres-gevşeme) için %58.40 olarak hesaplanmıştır [95].

Literatürde stresin sınıflandırılması üzerine gerçekleştirilen çalışmalar incelendiğinde çoğunlukla stresli durumlar ile stressiz durumların 2 sınıflı, 3 sınıflı ve 4 sınıflı kıyaslamaları yapılarak stresli durumlar sınıflandırılmaktadır. Ancak stresli durum ile stressiz durumun karşılaştırılmasından daha zor bir problem olarak görülen farklı stres faktörlerinin birbirleriyle kıyaslanarak stresin tespit edilmesi veya bilişsel iş yükünün belirlenmesi üzerine yapılan çalışmaların kısıtlı olduğu görülmektedir.

So ve arkadaşları çalışmalarında 20 sağlıklı katılımcıdan oluşturdukları deney sürecinde zihinsel rotasyon, sözcüksel karar verme, aritmetik işlem ve parmak dokunma görevlerini tamamlamalarını istemişlerdir. Deney sürecinde aktif olarak 1 kanallı EEG sinyalleri ölçülen katılımcılarda oluşan bilişsel iş yükü değişiklikleri gözlemlenmiştir. SVM sınıflandırma algoritması kullanılarak bilişsel iş yüklerinin birbirleri ile kıyaslanmış ve %65.00-75.00 arasında sınıflandırma doğruluğuna ulaşılabilirdiği görülmüştür [96]. Bir diğer benzer çalışmada Jebelli ve diğerleri 7 sağlıklı inşaat işçisinin 3 tanesinin fabrika içerisinde yapılan günlük işlerle (yerde, merdiven üstünde, kapalı alanda çalışmak) uğraşmasını isteyerek bu durumu yüksek seviyeli stres olarak, 4 tanesinin ise fabrika dışında yaptıkları günlük işlerle (normalde yaptıkları saatten farklı saatlerde çalışmak) uğraşmasını isteyerek bu durumu düşük seviyeli stres olarak tanımlamışlardır. Belirlenen deney prosedüründe 14 kanallı EEG sinyalleri kaydedilen inşaat işçilerinin verilerini SVM kullanılarak sınıflandırılması sonucunda %80.32 doğruluk sonucu elde etmeyi başarmışlardır. Bu durumun farklı stres yaklaşımlarının değerlendirilmesi kapsamında gelecek için ümit vaat edici olduğunu göstermişlerdir [97].

Yapılan çalışmalar incelendiğinde insan vücudunda oluşan stresin varlığının tespit edilmesi birçok uzman tarafından incelenmekte ve erken tedavi sürecinin başlatılabilmesi için hekimlerin işini kolaylaştırmaktadır. Ancak farklı stres yaklaşımlarının birbiriyle kıyaslanarak sınıflandırılması üzerine gerçekleştirilen çalışmaların gevşeme durumuna göre stresin belirlenebilmesi çalışmalarına göre daha kısıtlı olduğu görülmektedir. Bu tez çalışmasında; 40 sağlıklı denek üzerinde stroop renk-kelime testi, yansıyan ayna görüntüleri ve aritmetik işlemler sırasında oluşturulan farklı stres kaynaklarının birbiri ile sınıflandırılmalarının yapılarak stresin tespit edilmesi amaçlanmaktadır.

Sınıflandırma çalışmaları incelendiğinde birçok farklı öznitelik çıkarımı yöntemi kullanılmaktadır. İlgili çalışmaların bir kısmında ise öznitelik çıkarılma aşamasında trigonometrik dönüşüm fonksiyonları ve nöral aktivasyon fonksiyonlarının trigonometrik dönüşümlerinden yararlanılmaktadır [98]. Bu kapsamda; 40 sağlıklı katılımcının 3 farklı stres yaklaşımında 32 kanallı EEG sinyallerinin öznitelikleri belirlenerek sınıflandırılmıştır. Bu doğrultuda çalışma 3 aşamadan oluşmaktadır. 1.aşamada nöral aktivasyon fonksiyonları kullanılarak trigonometrik dönüşümleri alınan sinyallerin DD yöntemiyle öznitelikleri belirlenmiştir. 2. aşamada nöral aktivasyon fonksiyonlarına ek olarak önerilen trigonometrik dönüşümlerinde kombinasyonları kullanılarak trigonometrik dönüşümleri alınan sinyal işaretlerinin DD yöntemiyle öznitelikleri belirlenmiştir. 3. aşamada ise trigonometrik dönüşüm fonksiyonları kullanılmadan standart öznitelik belirleme yöntemleriyle öznitelikleri belirlenmiştir. Sonrasında belirlenen öznitelikler k-EYK, Bayes, KA ve DVM sınıflandırma algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma işlemleri sonunda elde edilen sonuçların birbirleriyle kıyaslamaları yapılmıştır.

2. MATERYAL VE YÖNTEM

Bu tez çalışmasında kullanılan veri seti, ön işleme aşaması, özniteliklerin belirlenmesi, sınıflandırma algoritmaları ve önerilen yöntemin detayları bu kısımda ayrıntılı bir şekilde açıklanmaktadır.

2.1. Veri Seti Tanıtımı

Bu tez çalışmasında; Ghosh ve arkadaşlarının stroop renk-kelime testi, yansıyan ayna görüntüleri, aritmetik işlemler ve gevşeme sürecinde katılımcılarda oluşan kısa süreli stres durumlarındaki EEG verilerini kaydederek açık kullanıma sunduğu veri seti kullanılmaktadır [99]. Veri seti yaşları ortalaması 21.50 olan 26'sı erkek, 14'ü kadın toplamda 40 katılımcının EEG verilerinden oluşmaktadır. Katılımcıların EEG verileri 32 kanallı Emotiv Epoc Flex jel kiti kullanılarak kaydedilmiştir. Deney sürecinde katılımcılardan kısa süreli stres görevlerini 25 saniye içerisinde tamamlamaları istenilerek her bir katılımcı için bu süreç 3 kere tekrar edilmiştir. Tez çalışmasında kullanılan veri setindeki EEG verilerin kaydedilmesi sürecinde kullanılan materyal ve deney prosedürü detaylı bir şekilde aşağıda verilmiştir.

2.1.1. Stroop Renk Kelime Testi

Stroop renk-kelime testi; klinik ve deneysel çalışmalarda hem çocuklar hem de yetişkinlerde sıklıkla kullanılan nöropsikolojik bir test olarak tanımlanmaktadır [100]. Testin amacı deneklerin çeşitli uyaranlar tarafından tetiklenmesi durumunda sıra dışı durumu değiştirebilme davranışını gerçekleştirebilme potansiyelinin ölçülebilmesidir.

Testin birçok farklı kombinasyonu çalışmalarda kullanılmakla birlikte temel prensibi sözcük, renk ve renk-sözcük görevlerinin tamamlanması şeklinde gerçekleştirilmektedir. Testin uygulanma prensibi uyumsuz sözcük renk eşleşmesi ve uyumlu sözcük renk eşleştirmeleri oluşturularak belirlenen süre içerisinde deneklerin istenilen testi

tamamlamasını beklemektir. Süre kısıtı içerisinde uyumsuz ve uyumlu durumların belirlenmesi teste katılım sağlayan denekler üzerinde strese sebebiyet vermektedir. Bu sebeple stroop renk kelime testi birçok çalışmada bireylerde oluşan stresli durumun tespit edilmesi aşamasında sıklıkla tercih edilmektedir. Şekil 10'da stroop renk kelime testi sırasında kullanılan uyumsuz ve uyumlu durumun gösterildiği test soruları örneği verilmiştir.




Şekil 10. Stroop renk kelime testinde uygulanan uyumlu ve uyumsuz durum örneği

2.1.2. Aritmetik Problem Çözme Testi

Aritmetik problem çözme testi; bireylerde bilişsel iş yükü yoğunluğu oluşturarak gerçekleşen nörolojik tepkilerin gözlemlenmesi için kullanılan bir test olarak tanımlanmaktadır. Uygulanan test sırasında farklı matematiksel kombinasyonlar kullanılarak zorluk dereceleri artırılıp azaltılabilirken temel matematiksel işlemler toplama, çıkarma, çarpma ve bölme işlemlerinden oluşmaktadır.

Belirlenen süre kısıtı içerisinde aritmetik problemi çözmeleri istenen katılımcılardan cevapları kâğıda yazmaları, ekrana dokunarak belirlemeleri, el hareketiyle göstermeleri, sesli olarak belirtmeleri gibi farklı yanıt verme seçenekleri sunarak katılımcılar üzerinde kısa süreli stres oluşturulabilmektedir. Bu sebeple stresin tespiti üzerine gerçekleştirilen birçok

farklı çalışmada aritmetik problem çözme testi yaygın bir şekilde tercih edilmektedir. Şekil 11’de aritmetik problem çözme testinde kullanılan bir problem örnek olarak verilmiştir.




Şekil 11. Aritmetik problem çözme testi örneği

2.1.3. Yansıyan Ayna Görüntüleri Testi

Yansıyan ayna görüntüleri testi katılımcıların duygusal ve bilişsel süreçlerini gözlemlemek için psikiyatri ve psikoloji alanındaki uzmanlar tarafından yaygın olarak kullanılan projektif bir test olarak tanımlanmaktadır. Yansıyan ayna görüntüleri için çalışmalarda farklı görüntü bileşenleri kullanılarak testin bireylerde oluşturduğu zorluk dereceleri belirlenebilmektedir. Testin uygulanma sürecinde uyulması gereken temel prensip katılımcıların görsellerin aynadaki yansımaları yorumlamaları veya görselin doğru yansımasını bulmalarını istemektir.

Yansıyan ayna görüntüleri testi kullanılan farklı görsellere göre katılımcılarda oluşan çeşitli duyguları ortaya çıkarmak için çalışmalarda tercih edilmektedir. Ayrıca katılımcılardan belirli süre kısıtı içerisinde simetrik ve asimetrik yansımaların bulunması istenilerek bireylerde kısa süreli stres faktörü oluşturulabilmektedir. Bu sebeple stres tespiti


çalışmalarında yansıyan ayna görüntüleri testi kullanılmaktadır. Şekil 12'de yansıyan ayna görüntüleri testi için kullanılan simetrik ve asimetrik görsellerin bir örneği verilmiştir.



Şekil 12. Simetrik ve simetrik olmayan ayna görüntüleri örneği

2.1.4. Deney Prosedürü

Tez çalışmasında yaş aralıkları 18 ile 25 arasında değişen 26'sı erkek 14'ü kız olmak üzere toplamda 40 farklı kişinin EEG sinyal ölçümlerini içeren veri seti kullanılmıştır. Deneklerin EEG sinyalleri stres testi ve gevşeme aşamalarında belirlenen süre kısıtları içerisinde 32 kanallı Emotiv Epoc Flex jel kiti ile elde edilmiştir. Örnekleme frekansı 128 Hz'dir. Şekil 13'te veri seti oluşturulurken dikkate alınan kanalların konumları gösterilmiştir.




Şekil 13. Verileri kaydedilen katılımcıların elektrot yerleşimi şeması [99]

Veri setinin elde edilmesi için oluşturulan deney prosedüründe takip edilen aşamalar aşağıda verilmiştir.

1. Aşama: Deney ortamı araştırmacılar tarafından ayarlanır ve EEG cihazı deneğe yerleştirilir.
2. Aşama: Deney prosedürü hakkında detaylı bilgi deneğe aktarılır ardından deneğin rahatlaması için dinlendirici etkisi olan müzik çalmaya başlar.
3. Aşama: Müzik etkisiyle rahatlayan deneğin EEG verileri 25 saniye boyunca kaydedilir.
4. Aşama: Stroop renk kelime testi süresince yapılması istenen talimatlar 10 saniye boyunca deneğe gösterilir.
5. Aşama: Deneğin stroop renk kelime testini tamamlaması istenir. 25 saniye boyunca EEG verileri kaydedilir.
6. Aşama: Deneğin 5 saniye boyunca rahatlaması istenir ve 10 saniye boyunca yansıyan ayna görüntüleri testi talimatları deneğe gösterilir.


7. Aşama: Deneğin yansıyan ayna görüntüleri testini tamamlaması istenir. Deney sırasında verilen soruların baş parmak yukarı ve aşağı olarak cevaplanması beklenir. 25 saniye boyunca EEG verileri kaydedilir.
8. Aşama: Deneğin 5 saniye boyunca rahatlaması istenir ve 10 saniye boyunca aritmetik problem çözme testi talimatları deneğe gösterilir.
9. Aşama: Deneğin aritmetik problem çözme testini tamamlaması istenir. Deney sırasında verilen soruların baş parmak yukarı ve aşağı olarak cevaplanması beklenir. 25 saniye boyunca EEG verileri kaydedilir.
10. Aşama: Stres testlerini tamamlayan deneklerden 1 ile 10 arasında oluşturulan ölçekte stres seviyelerini belirtmeleri istenir. (1- Minimum stres, 10- maksimum stres)

Oluşturulan deney prosedürü her bir denek için 3 defa tekrarlanır. Her bir denemede stroop renk kelime testi, yansıyan ayna görüntüleri testi ve aritmetik problem çözme testi soruları farklı soru setleri oluşturularak uygulanmaktadır. Şekil 14’te deney prosedürü verilmiştir.




Şekil 14. Deney prosedürü


Şekil 15, Şekil 16 ve Şekil 17’de 40 deneğin 3 farklı deneme için stroop renk kelime testi, yansıyan ayna görüntüleri testi ve aritmetik problem çözme testi sırasında kaydedilen EEG sinyal örnekleri verilmiştir.



Şekil 15. Aritmetik problem çözme testi sinyal işaretleri



Şekil 16. Stroop renk kelime testi sinyal işaretleri



Şekil 17. Yansıyan ayna görüntüleri testi sinyal işaretleri

Deney prosedürü boyunca her bir deneğin 3 farklı stres testi için hissettikleri stres seviyelerini 1 ile 10 derecelendirme ölçeğini kullanarak belirttikleri sonuçlar Tablo 1’de verilmiştir.

Tablo 1. Katılımcıların test sürecinde belirttikleri stres derecesi ölçeği

Denek	1. Deneme			2. Deneme			3. Deneme		
	Aritmetik Problem	Yansıyan Ayna Görüntüsü	Stroop Renk Kelime	Aritmetik Problem	Yansıyan Ayna Görüntüsü	Stroop Renk Kelime	Aritmetik Problem	Yansıyan Ayna Görüntüsü	Stroop Renk Kelime
1	6	3	3	7	5	2	4	7	4
2	3	4	5	3	4	4	7	5	3
3	5	3	4	3	5	5	8	7	5
4	5	3	4	3	5	2	7	5	5
5	6	6	6	5	3	2	5	7	3
6	5	4	2	4	3	3	8	6	5
7	5	5	4	3	3	3	6	3	6
8	3	5	4	6	6	3	5	6	3
9	3	6	4	4	4	4	7	4	6
10	3	4	4	4	5	3	6	4	5
11	7	3	4	6	5	5	5	6	5
12	5	7	2	5	4	5	8	6	3
13	3	5	3	3	4	2	3	5	1
14	3	4	3	6	4	2	6	3	4
15	9	6	5	7	5	3	6	5	5
16	4	4	1	5	6	1	8	5	6
17	8	9	8	6	8	4	7	7	6
18	6	5	6	5	6	5	9	6	7
19	4	6	6	2	4	3	4	1	3
20	10	9	7	10	9	5	10	8	6
21	7	8	9	8	8	9	7	8	9
22	9	8	5	8	8	6	7	6	5
23	3	2	1	4	2	1	8	4	5
24	4	2	1	2	1	1	5	7	4
25	2	1	2	2	1	2	5	7	5
26	6	7	8	6	8	7	4	5	6
27	5	5	3	3	4	2	5	3	3
28	7	8	7	7	7	5	6	5	4
29	6	7	6	8	7	6	6	6	5
30	7	6	5	8	6	5	7	5	4
31	10	8	4	9	7	3	6	3	7
32	5	5	1	1	2	1	7	6	3
33	5	4	3	3	2	2	8	3	6
34	2	3	1	3	1	1	2	2	3
35	6	5	1	5	2	1	4	6	5
36	4	4	6	5	4	3	5	5	5
37	6	5	4	5	3	2	8	4	6
38	6	4	5	5	6	3	4	5	3
39	6	4	3	5	5	3	6	3	5
40	3	5	5	4	6	5	4	4	3

2.2. Sinyal Ön İşleme

EEG sinyallerinin kaydedilmesi aşamasında hem işaret iletim hattı hem de sinyallerin kendi özelliklerine bağlı olarak sinyal işaretlerinde gürültüler meydana gelmektedir. Sinyal işaretlerinde ortaya çıkan gürültülü durum artefakt olarak adlandırılmaktadır. Artefakt oluşumu içerisinde pek çok nörolojik bilgiyi barındıran sinyal işaretlerinin doğru bir şekilde analiz edilmesine engel teşkil etmektedir. Genel olarak artefaktlara sebep olan durumlar fizyolojik sebepler ile ortaya çıkan ve fizyolojik olmayan sebeplerle ortaya çıkan artefaktlar olarak 2'ye ayrılmaktadır. Bu etkenlerden bazılarını şu şekilde sıralandırabiliriz; çevrede meydana gelen sesler, EEG ölçüm cihazında ortaya çıkan arıza durumu, elektrot yerleşimi, ölçüm sırasında deneğin hareketi, göz kırpması, terleme, kalp atışı. Uzmanlar ilk aşamada artefakt oluşumuna sebep olan durumları ortadan kaldırmaya çalışarak deney prosedürlerini belirledikleri en uygun parametrelere göre oluşturmaktadır. Ancak fizyolojik sebepler nedeniyle meydana gelen artefakt oluşumlarını engellemek, fizyolojik olmayan çevresel etkilerin sebebi ile ortaya çıkan artefakt oluşumuna göre çok daha güçtür [101]. Özellikle sağlıklı bireylerden elde edilen sinyaller ile pediatrik, klinik ve yaşlı bireyler üzerinde yapılan ölçümlerden elde edilen artefaktlar karşılaştırıldığında sağlıklı bireylere göre oldukça yüksek miktarda artefakt oluşumu olduğu gözlemlenmektedir.


EEG sinyallerinin içerisinde barındırdığı nörolojik bilgilerin sağlıklı bir şekilde elde edilmesi ve analizinin yapılabilmesi için sinyal işaretlerindeki artefaktları kaldırarak ön işleme aşamasından geçirmek çok önemlidir. Çünkü sinyal ön işleme aşaması doğrudan öznelik belirleme ve sınıflandırma aşamalarını etkilemektedir. Sinyal işaretlerindeki artefaktları ortadan kaldırmak için birçok standart haline gelmiş yöntem kullanılmaktadır. Ancak ön işleme aşamasından geçirilmiş EEG sinyaller işaretlerinin kalite seviyesini belirlemek için kullanılan bir yöntem henüz yoktur. Tez çalışmasında ön işleme aşaması için bant geçiren filtre ve maksimum minimum noktalar uygulamaları tercih edilmiştir.

2.2.1. Bant Geçiren Filtre

Bant geçiren filtre; belirlenen frekans aralığındaki sinyalleri geçiren ve belirlenen frekans aralığının dışarısında kalan sinyalleri zayıflatarak yok sayan elektronik filtre olarak tanımlanmaktadır [102]. Kısmi Bant genişliği (FBW); f_L =Alt kesim, f_0 =Merkez ve f_H = Üst kesim frekansları arasında iletilen sinyal işaretlerini tanımlamak için kullanılmaktadır. Şekil 18’de alt kesim ve üst kesimleri haricindeki sinyalleri zayıflatarak filtreleyen bant geçiren filtrenin tepkisi gösterilmiştir. Merkez frekansı belirlemek için kullanılan matematiksel ifade Denklem 1’de verilmiştir. Kısmi bant genişliğini tanımlamak için kullanılan matematiksel ifade Denklem 2’de verilmiştir.

$$f_0 = \sqrt{f_H f_L} \quad (1)$$

$$FBW = \frac{f_H - f_L}{f_0} \quad (2)$$




Şekil 18. Alt kesim ve üst kesim frekanslarının gösterimi

2.2.2. Maksimum ve Minimum Noktaların Belirlenmesi

Makine öğrenim algoritmalarında kullanılan sinyal işaretlerinde oluşması muhtemel kayıpları en aza indirmek ve barındırdığı bilgi içeriğini korumak için optimizasyon işlemi yapılması oldukça önemlidir. Sinyal işaretlerinin istatistiksel analizinde fonksiyonun frekans ve genlik değerleri maksimum ve minimum noktalardan oluşmaktadır. Fonksiyonun en düşük değerini aldığı nokta küresel minimum, en yüksek değerini aldığı nokta ise küresel maksimum noktası olarak ifade edilmektedir. Aynı zamanda minimum ve maksimum noktalar görülen ancak en yüksek ve en düşük değerleri ifade etmeyen noktalar ise yerel minimum ve yerel maksimum noktalar olarak ifade edilmektedir [103]. Şekil 19’da küresel ve yerel maksimum, minimum noktaları gösteren grafik verilmiştir. Denklem 3 ve Denklem 4’te küresel maksimum ve küresel minimum noktaları belirlemek için kullanılan matematiksel ifade verilmiştir. $F(x)$ sinyal işaretlerini tanımlamak için kullanılmıştır.

$$\frac{d F'(x)}{dx} < 0 \quad (3)$$

$$\frac{d F'(x)}{dx} > 0 \quad (4)$$



Şekil 19. Küresel ve yerel maksimum, minimum noktaları gösterimi

2.3. Öznitelik Çıkarımı

Öznitelik çıkarımı farklı durumlar altında kayıt altına alınan EEG sinyal işaretlerini en iyi şekilde temsil edebilecek özelliklerinin belirlenerek öznitelik vektörünün elde edilmesi olarak tanımlanmaktadır. Özellikle büyük sayılabilecek veri kümelerinin daha küçük veri kümelerine indirgenip iyi bir şekilde temsil edilebilmesi hem işlem hızını artırmakta hem de verilerin sınıflandırma aşamasını kolaylaştırarak doğruluk performansının artmasına imkân sağlamaktadır.

Özniteliklerin çıkarımı EEG sinyal işaretlerini en iyi şekilde temsil edecek özelliklerin çıkarılması olarak tanımlanmasına rağmen bu durum olabilecek en yüksek doğruluk performansı vereceği anlamına gelmez. Bu sebeple öznitelik vektörünün belirlenmesi en iyi sınıflandırma doğruluğunu elde edebilmek için önemli parametrelerden biri olarak kabul edilmektedir. Uzun yıllardır yapılan çalışmalarda EEG sinyal işaretlerini en iyi şekilde sınıflandırabilmek için birçok öznitelik çıkarımı yöntemi kullanılarak en iyi öznitelik vektörü elde edilmeye çalışılmaktadır.

Tez çalışması kapsamında öznitelik belirleme yöntemi olarak min-max normalizasyon yöntemi, nöral aktivasyon fonksiyonları, tez kapsamında önerilen trigonometrik dönüşüm fonksiyonları ve dalgacık dönüşümü kullanılmaktadır. Tez çalışmasında kullanılan öznitelik çıkarımı yöntemleri detaylı bir şekilde aşağıda verilmiştir.

2.3.1. Min-Max Normalizasyon Yöntemi

Min-Max normalizasyon yöntemi kullanılan verilerdeki içeriği tam anlamıyla koruyarak 0 – 1 aralığına indirgenmek için kullanılmaktadır. Maksimum en yüksek değeri minimum ise en düşük değeri ifade etmek için kullanılmaktadır [104]. Verileri 0 - 1 aralığına indirmek için kullanılan yöntemin matematiksel ifadesi Denklem 5'te verilmiştir. Denklemi en iyi şekilde açıklayan ifadeler aşağıda verildiği gibidir;

X' = Normalize edilen sinyal

X_i = Sinyalin giriş değeri

$X_{\max}$ = Sinyalin giriş deęerindeki en büyük deęer

$X_{\min}$ =Sinyalin giriş deęerindeki en küçük deęer

$$X' = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

2.3.2. Trigonometrik Dönüşüm Fonksiyonları

Nöral aktivasyon fonksiyonları derin öğrenme çalışmalarından özellikle yapay sinir ağlarında doğruluk performansını yükseltmek için sıklıkla kullanılan fonksiyonlardır. Nöral aktivasyon fonksiyonları derin öğrenme çalışmalarında sıklıkla tercih edilmesinin sebebi her bir nöronun diğerine aktivasyon fonksiyonları sayesinde bilgi geçişleri sağlanmasından gelmektedir [105]. Aktivasyon fonksiyonları; doğruluk performansı artırmak için işaretlerin öznitelik çıkarımı süreçlerinde kullanılmaktadır [106-109]. Aktivasyon fonksiyonları yapıları gereęi doğrusal ve doğrusal olmayan fonksiyonlar olarak 2'ye ayrılmaktadır. Yapıları gereęi bir aktivasyon fonksiyonunun derin öğrenme algoritmalarında başarılı olabilmeleri için sahip olması gereken özellikler aşağıda sıralandığı gibidir;

- Merkeze göre yakınsayan
- Monoton
- Aralıklı yapıya sahip
- Türevlenebilen
- Doğrusal olmayan

Doğrusal olmayan ve monoton nöral aktivasyon fonksiyonları sigmoid fonksiyonu, tanjant hiperbolik fonksiyonu, logish fonksiyonu, softsing fonksiyonu ve softplus fonksiyonudur. Bu fonksiyonlar derin öğrenme algoritmalarında yüksek derecede doğruluk performansı sağlaması sebebiyle tercih edilmektedirler. Doğrusal olmayan nöral aktivasyon fonksiyonlarının detayları aşağıda verilmiştir.

a) Sigmoid Fonksiyonu

Sigmoid fonksiyonu ve türevli sigmoid fonksiyonunun matematiksel ifadesi Denklem 6 ve Denklem 7’de verilmiştir. Denklem içerisinde kullanılan x sinyal işaretini ifade etmek içindir. Sigmoid fonksiyonu yapısı gereği doğrusal değildir, monotondur ve türevlenebilirdir. Sigmoid fonksiyonun çıktısı 0 ile 1 aralığındadır. Eğer çıktı 0.5’den büyükse sonuç 1 eğer çıktı 0.5’den küçükse sonuç 0’dır. Bu durum sigmoid fonksiyonun özellikle ikili sınıflandırma algoritmalarında sıklıkla tercih edilmesini sağlamaktadır [106].

$$F(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

$$F'(x) = \text{sigmoid}'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} \quad (7)$$

b) Tanjant Hiperbolik Fonksiyonu

Tanjant hiperbolik fonksiyonunun ve türevli tanjant hiperbolik fonksiyonunun matematiksel ifadesi Denklem 8 ve Denklem 9’da verilmiştir. Denklem içerisinde kullanılan x sinyal işaretini ifade etmek içindir. Tanjant hiperbolik fonksiyonu yapısı gereği doğrusal değildir, monotondur, türevlenebilirdir ve sıfır merkezlidir. Tanjant hiperbolik fonksiyonunun çıktısı -1 ile 1 aralığındadır. Bu durum çıktıların 0’a yakınsamasına sebep olarak verileri daha merkezci bir yapıya getirmesine olanak sağlamaktadır [106].

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

$$\tanh'(x) = \frac{4e^{-2x}}{(1 + e^{-2x})^2} \quad (9)$$

c) Logish Fonksiyonu

Logish fonksiyonu ve türevli logish fonksiyonunun matematiksel ifadesi Denklem 10 ve Denklem 11’de verilmiştir. Denklem içerisinde kullanılan x sinyal işaretini ifade etmek içindir. Logish fonksiyonu yapısı gereği doğrusal olmayan, monoton olmayana ve yakın doğrusal dönüşüm karakteristiğine sahip bir fonksiyondur. Logish fonksiyonu mish ve swish fonksiyonlarının eğrilerine benzer şekilde pürüzsüz bir yapıya sahiptir. Bu durum iyi derecede doğruluk performansı sağlamasına olanak vermektedir [107].

$$F(x) = x \cdot \ln[1 + \text{sigmoid}(x)] \quad (10)$$

$$F'(x) = \ln\left(1 + \frac{1}{1 + e^{-x}}\right) + \frac{x \cdot e^{-x}}{(1 + e^{-x}) \cdot (2 + e^{-x})} \quad (11)$$

d) Softsing Fonksiyonu

Softsing fonksiyonu ve türevli softsing fonksiyonunun matematiksel ifadesi Denklem 12 ve Denklem 13’te verilmiştir. Denklem içerisinde kullanılan x sinyal işaretini ifade etmek içindir. Softsing fonksiyonu yapısı gereği tanjant hiperbolik fonksiyonuna çok benzer bir yapıya sahiptir. Doğrusal değildir, monotondur, türevlenebilirdir ve sıfır merkezlidir. Softsing fonksiyonları dil ve video işleme süreçlerinde aktif olarak kullanılan aktivasyon fonksiyonlarıdır [108].

$$F(x) = \frac{x}{1 + |x|} \quad (12)$$

$$F'(x) = \frac{1}{(1 + |x|)^2} \quad (13)$$

e) Softplus Fonksiyonu

Softplus fonksiyonu ve türevli softplus fonksiyonunun matematiksel ifadesi Denklem 14 ve Denklem 15’te verilmiştir. Denklem içerisinde kullanılan x sinyal işaretini ifade etmek

içindir. Softplus fonksiyonu yapısı gereği doğrusal ve türevlenebilirdir. Diğer aktivasyon fonksiyonlarıyla karşılaştırıldığında softplus fonksiyonu görüntü tabanlı sınıflandırma süreçlerinde daha yüksek performans göstermektedir [109].

$$F(x) = \ln(1 + e^x) \quad (14)$$

$$F'(x) = \frac{1}{1 + e^{-x}} \quad (15)$$

2.3.3. Dalgacık Dönüşümü

DD; matematiksel temeli Fourier dönüşümüne dayanan ve Fourier dönüşümünün durağan olmayan sinyallerdeki analiz eksiklerini gidermek için geliştirilen bir yöntem olarak tanımlanmaktadır [110]. DD durağan olmayan sinyal işaretlerinde zaman fonksiyonunu kullanarak kaydırma ve ölçeklendirme işlemlerini gerçekleştirme yeteneğine sahiptir. Ölçeklendirme işlemi sayesinde dalgacık sıkıştırılırken kaydırma işlemi ile zaman fonksiyonunda değişken pencereler kaydırılmaktadır. Bu özellikleri sayesinde frekans aralığında esnek zaman-frekans çözünürlüğü elde edilerek alçak ve yüksek frekanslı sinyal işaretlerinin hesaplanmasını mümkün kılmaktadır. Yüksek frekansa sahip işaretler için dar pencereler kullanılırken, alçak frekansa sahip işaretler için ise geniş pencereler kullanılmaktadır.

DD'nin temel fonksiyonları dalgacık olarak isimlendirilmektedir. Bir $\psi(t)$ fonksiyonunun dalgacık olarak isimlendirilebilmesi için Denklem 16 ve Denklem 17'de verilen eşitlikleri sağlaması beklenmektedir. Denklemi en iyi şekilde açıklamak için kullanılan ifadeler aşağıda verildiği gibidir;

τ =öteleme

s=ölçek

t=zaman

$$\psi_{\tau,s} = \psi\left(\frac{t-\tau}{s}\right) \quad (16)$$

$$DD_x^\psi = \frac{1}{\sqrt{s}} \int x(t) \cdot \psi\left(\frac{t-\psi}{s}\right) \cdot dt \quad (17)$$

DD ailesi 16 ana dalgacıktan oluşmaktadır. Bunlar haar, daubechies, symlets, coiflets, biorsplines, reversebior, fejer-korovkin, complex morlet, frequency b-spline, Shannon, complex gaussian, morlet, mexican hat, gaussian, dmeyer, meyerdir. Öznitelik belirleme aşamasında hangi dalgacığın kullanılacağı doğruluk performansını etkileyen önemli parametrelerden birisidir. DD ani değişimlerin meydana geldiği sinyal işaretlerinde kullanılmaktadır. Özellikle biyomedikal uygulama alanlarındaki öznitelik belirleme aşamasında sıklıkla tercih edilir. Başlıca kullanılma sebebi sinyal işaretinin sıkıştırılması ve işaretin gürültüden arındırılmasıdır.

2.4. Sınıflandırma

Sınıflandırma işlemi belirlenen öznitelik vektörlerinin birbirleriyle kıyaslanarak sınıflarına ayrıldığı aşama olarak tanımlanmaktadır. Temel olarak iki farklı süreçten oluşmaktadır. İlk aşama verilerin eğitilmesi sürecidir. Sınıflandırma algoritmaları bu aşamada verileri en iyi şekilde temsil eden özniteliklerin özelliklerine göre sınıflandırmayı öğrenen bir model geliştirmektedir. Makine öğrenmesi üzerine yapılan çalışmalar incelendiğinde genellikle verilerin %70.00'inin eğitim sürecinde kullanıldığı görülmektedir. İkinci aşama verilerin test edilme sürecidir. Eğitim aşamasında kullanılan sinyal işaretlerinden oluşturulan eğitim modeli analiz edilerek sınıflarına ayrılmaktadır. Makine öğrenmesi üzerine yapılan çalışmalar incelendiğinde genellikle verilerin %30.00'nun test sürecinde kullanıldığı görülmektedir.

Bu tez çalışmasında sınıflandırma işlemi için k-EYK, DVM, Bayes ve KA sınıflandırma algoritmaları kullanılmıştır. Tez çalışmasında kullanılan sınıflandırma yöntemleri detaylı bir şekilde aşağıda verilmiştir.

2.4.1. K En Yakın Komşuluk Sınıflandırma Algoritması


k-EYK, sınıflandırma problemlerini çözmek için kullanılan denetimli bir öğrenme algoritması olarak tanımlanmaktadır. Sınıflandırma problemleri ve regresyon problemlerinde kullanılan algoritma akademik çalışmaların yanında endüstriyel işlemlerde de tercih edilmektedir. Yüksek doğruluk performansı sağlaması ve basit uygulama prosedürüne sahip olması da diğer sınıflandırma algoritmaları ile birlikte sıklıkla tercih edilmesini sağlamaktadır. k-EYK sınıflandırma algoritması temel çalışma prensibini veriler arasındaki benzerlikler ve verilerin birbirlerine olan uzaklıkları dikkate alarak oluşturmaktadır [111]. Çalışma prensibinin genel parametreleri komşu sayısı(k), verilerin birbirine olan uzaklığı ve ağırlıklandırma. Verilerin birbirlerine olan uzaklıklarının hesaplanabilmesi bir takım geometrik hesaplamalar gerektirmektedir. Veriler arası uzaklıkların hesaplanmasında en çok tercih edilenler Öklid, Manhattan, Minkowski, Chebyshev ve Dilca yöntemleridir. Öklid yöntemini en iyi şekilde temsil edebilecek matematiksel ifade Denklem 18’de verilmiştir. Denklemden ifade edilen x_i sınıflandırılma işlemine sokulan test örneğini y_i ise komşu eğitim örneğini ifade etmektedir.

$$D(x_i, y_i) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (18)$$

k-EYK sınıflandırma algoritması temel işlem adımları aşağıda verildiği gibidir;

- 1.Aşama= Veri boyutu ve yapısında göre k parametresinin belirlenmesi
- 2.Aşama= Test kümesinden bir örnek seçilmesi
- 3.Aşama= Seçilen örneğin çevresinde bulunan eğitim kümesi verilerinden hangilerinin (k sayısı kadar) en yakın uzaklıkta olduğunun belirlenmesi
- 4.Aşama= En yakın uzaklıktaki verilerin çoğunluğuna göre sınıflandırma sonucunun belirlenmesi.

Şekil 20’de $k=5$ ve $k=7$ parametreleri için iki farklı sınıftan oluşan verilerin k-EYK sınıflandırma algoritması kullanılarak belirlenmesi gösterilmiştir.




Şekil 20. k-EYK sınıflandırma algoritmasının genel gösterimi

2.4.2. Destek Vektör Makineleri Sınıflandırma Algoritması

DVM, regresyon, örüntü tanıma ve sınıflandırma problemlerinde yaygın bir şekilde kullanılan denetimli öğrenme algoritması olarak tanımlanmaktadır. DVM’nin temel çalışma prensibi veriler arasındaki en yüksek uzaklığa göre yüksek özellik sayına sahip uzay alanında doğrusal hiperbolik düzlem oluşturarak verileri farklı sınıflara bölmektir [112]. Bu durum verilerin birbirilerinden ayrılarak sınıflandırma algoritmasında sınıflandırılabilmesine olanak sağlamaktadır. Sınıflandırma algoritmasında kullanılan temel parametreler destek makineleri, destek vektör çekirdekleri ve çekirdek sayısıdır. DVM sınıflandırma algoritmasında kullanılan destek vektör çekirdekleri gaus çekirdek, gaus RBF çekirdek, sigmoid çekirdek, polinomal çekirdek ve doğrusal çekirdektir. DVM yüksek

boyutlu verilerle çalışabilmesi, uygulanma işleminin basit olması ve yüksek doğruluk performansı elde edebilme potansiyeline sahip olduğu için çalışmalarda sıklıkla tercih edilmektedir [113]. Hiperbolik düzlem ve iki sınıflı veriden oluşan DVM sınıflandırma algoritması örneği Şekil 21’de verilmiştir.




Şekil 21. DVM sınıflandırma algoritmasının genel gösterimi

2.4.3. Bayes Sınıflandırma Algoritması

Bayes algoritması hastalık teşhisi, ürün yönetim süreci gibi birçok farklı alanda kullanılan istatistiksel sınıflandırma algoritması olarak tanımlanmaktadır. Bayes uygun maliyette olması, yüksek boyutlu veri analizi yapabilmesi, birçok farklı alana uygulanabilmesi, basit uygulama prosedürüne sahip olması ve yüksek doğruluk performansı sağlayabilmesi sebebiyle araştırmacıların sınıflandırma problemlerinde sıklıkla tercih ettiği algoritmalardan biridir [114].

Bayes algoritması sınıflandırma etiketlerini kullanarak eğitim seti verileri üzerinden olasılıksal modellemeler ile sınıflandırma tahmini gerçekleştirmektedir [115]. Denklem 19'da Bayes algoritmasını en iyi şekilde temsil edebilecek matematiksel ifade verilmiştir. Denklem içerisinde bahsedilen $P(y)$ ve $P(x_i | y)$ veri seti olasılık tahminleridir. Şekil 22'de iki farklı sınıftan oluşan verilerin Bayes sınıflandırma algoritması kullanılarak belirlenmesi gösterilmiştir.

$$\operatorname{argmax}_y (P'(y) \sum_{i=1}^n P'(x_i | y)) \quad (19)$$




Şekil 22. Bayes sınıflandırma algoritmasının genel gösterimi

2.4.4. Karar Ağacı Sınıflandırma Algoritması

KA sınıflandırma algoritması örüntü tanıma işlemleri, veri madenciliği ve makine öğrenmesi alanlarında kullanılan istatistiksel sınıflandırma ve tahmin algoritmasıdır. KA algoritması ismini işlem yapısından almaktadır. Sınıflandırma ve tahmin aşamalarında kullandığı temel adımlar karar düğümü, dallar ve yapraklardan oluşmaktadır. Karar verme

mekanizmasında n sayıda kullanılan eğitim seti verileri sınıflandırma tahmini sonucunda etiketleme işlemi için kullanılmaktadır [116]. Etiketleme sürecinde herhangi bir ağaç yapısında alınan yanlış kararın diğer ağaç yapıları tarafından absorbe edilebilmesi KA algoritmasında yüksek doğruluk performansı sağlamaktadır [117]. Ayrıca birçok multidisipliner çalışmaya kolay bir şekilde uyarlanabilmesi, uygun maliyetleri ve büyük veriler ile kolaylıkla çalışabilmesi birçok çalışmada sıklıkla tercih edilen sınıflandırma algoritmalarından birisi olmasını sağlamaktadır. Şekil 23'te KA sınıflandırma algoritmasının çalışma adımlarını gösteren model verilmiştir.



Şekil 23. KA sınıflandırma algoritmasının genel gösterimi

2.5. Önerilen Yöntem

Tez çalışmasında uygulanan ve genel yapısı veri setinin içeriği, sinyal işaretleri ön işleme aşaması, öznitelik belirleme yöntemleri ve sınıflandırma yöntemlerinden oluşan

algoritmanın akış diyagramı Şekil 24'te verilmiştir. Öznitelik kombinasyonlarının belirlenmesi için kullanılan algoritmanın akış diyagramı Şekil 25'te verilmiştir.



Şekil 24. Önerilen yöntemin genel akış diyagramı



Şekil 25. Trigonometrik öznitelik kombinasyonlarının genel akış diyagramı

Veri Seti İçeriği: Veri Seti İçeriği 14'ü kadın 26'sı erkek olmak üzere toplamda 40 sağlıklı katılımcının EEG verilerinden oluşmaktadır. EEG verileri; 32 kanallı Emotiv Epoc Flex jel kiti kullanılarak üç farklı stres durumunda elde edilmiştir. Farklı stres durumlarının detayları aşağıda verildiği gibidir;

Stres durumu 1 (SD1): Stroop renk kelime testi

Stres durumu 2 (SD2): Yansıyan ayna görüntüleri

Stres durumu 3 (SD3): Aritmetik problem

Stresli durumların oluşturulması için izlenen prosedürün detayları tablo 2'de verilmiştir.

Tablo 2. Veri Seti Oluşturma Prosedürü

	Soru Sayısı	Deneme Sayısı	Veri Kayıt Süresi
SD 1	11	3	25sn
SD 2	8	3	25sn
SD 3	6	3	25sn

Sinyal İşaretleri Ön İşleme Aşaması: Sinyal işaretlerinin ön işleme aşamasında bant geçiren filtre kullanılarak alt kesim frekans değeri 2 Hz, üst kesim frekans değeri ise 10 Hz olmak üzere filtrelenmiştir. Filtrelenmiş sinyal işaretleri maksimum ve minimum noktaların belirlenmesi yöntemiyle maksimum frekans noktaları kullanılarak filtrelenmiştir.

Öznitelik Belirleme Yöntemleri: Ön işleme aşaması tamamlanan veriler min-max normalizasyon yöntemi ile 0-1 aralığına indirgenerek normalize edilmiştir. 0-1 aralığına indirgenen veri değerlerinin derece olarak 0^0 - 360^0 aralığındaki karşılıklarını elde edebilmek için veriler matlab içerisinde $0-2\pi$ ($0-6.28$) çarpılarak normalize edilmiştir. Veri değerlerinin derece olarak karşılıkları kullanılarak trigonometrik dönüşümler ile öznitelik vektörü oluşturulmuştur. Öznitelik vektörü içerisinde kullanılan trigonometrik dönüşümler nöral aktivasyon formülleri ve tez çalışmasında önerilen trigonometrik fonksiyonlardır. Kullanılan trigonometrik dönüşüm denklemleri aşağıda verildiği gibidir;

Trigonometrik Dönüşüm 1 (TD1): $\frac{1}{1+e^{-x}}$

Trigonometrik Dönüşüm 2 (TD2): $\frac{e^x - e^{-x}}{e^x + e^{-x}}$

Trigonometrik Dönüşüm 3 (TD3): $x \cdot \ln \left[1 + \frac{1}{1+e^{-x}} \right]$

Trigonometrik Dönüşüm 4 (TD4): $\frac{x}{1+|x|}$

Trigonometrik Dönüşüm 5 (TD5): $\ln (1 + e^x)$

Önerilen Trigonometrik Dönüşüm 1 (ÖTD1): $\frac{\cos(x)^4 + \sin(x)^4}{\sin(x)^4 + 4}$

Önerilen Trigonometrik Dönüşüm 2 (ÖTD2): $\frac{-\cos(x)^4 - 1}{4 \cdot \sin(2x)^2} - \sin(x)^2 + 1$

Önerilen Trigonometrik Dönüşüm 3 (ÖTD3): $1 + \cos(x) + \left(\sin(x)^2 - \frac{1}{4 \cdot \sin(2x)^2} \right)$

Önerilen Trigonometrik Dönüşüm 4 (ÖTD4): $1 + \sin(x) + \left(\cos(x)^3 - \frac{1}{12 \cdot \sin(x)^5} \right)$

Önerilen Trigonometrik Dönüşüm 5 (ÖTD5): $\cos(x)$

Önerilen Trigonometrik Dönüşüm 6 (ÖTD6): $\sin(x)$

Önerilen Trigonometrik Dönüşüm 7 (ÖTD7): $\frac{\sin(x)^{12} + \sin^3 6}{\cos(x)^5 + 4}$

Trigonometrik dönüşüm fonksiyonları kullanılarak oluşturulan öznitelik vektörü dalgacık dönüşümü yöntemine sokularak yeniden dalgacık dönüşümü tabanlı öznitelik vektörü oluşturulmuştur. Öznitelik vektörü Morlet dalgacığında 100:110 ölçeğinde hesaplanmıştır.

Sınıflandırma Yöntemleri: Veri seti her bir stres durumu için 3 ayrı oturumda 40 farklı katılımcıdan 120 farklı EEG verisi içermektedir. Bu verilerin %50.00'si eğitim verisi %50.00'si test verisi olarak eşit 2 parçaya ayrılmıştır. Belirlenen öznitelik vektörü 4 farklı sınıflandırma algoritması (k-EYK, Bayes, KA ve DVM) ile sınıflandırılmıştır.

3. BULGULAR

Bu tez çalışmasında 40 deneğin farklı stres durumlarında kaydedilen EEG verilerinden oluşan veri seti kullanılmıştır [98]. Veri setinin oluşturulması için izlenen deney prosedürü ve süreç esnasında kullanılan materyaller detaylı bir şekilde yöntem kısmında verilmiştir. Veri seti bünyesinde oluşturulan SD 1, SD 2 ve SD 3 Şekil 25'te verilen öznitelik belirleme prosedürü uygulanarak Şekil 24'te verilen algoritmanın uygulama aşamaları takip edilerek sonuçlandırılmıştır. Algoritma içerisinde kullanılan parametreler ve yöntemlerin detayları yöntem kısmında verilmiştir.

Tez çalışması kapsamında yaygın trigonometrik dönüşüm fonksiyonları kullanılarak farklı stres durumlarının birbirleri ile kıyaslaması yapılmıştır. Ayrıca yaygın trigonometrik dönüşüm fonksiyonlarına ek olarak çalışma kapsamında önerilen trigonometrik dönüşümler fonksiyonları ile sınıflandırma doğruluğu sonuçlarının artırılması hedeflenmiştir. Veri seti; SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılarak toplamda yaygın trigonometrik dönüşüm fonksiyonları ve bu tez kapsamında önerilen trigonometrik dönüşüm fonksiyonlarından oluşan öznitelik vektörlerinin sınıflandırma sonuçlarının karşılaştırmaları yapılmıştır.

Çalışmada; önerilen trigonometrik dönüşüm fonksiyonları kullanılarak farklı stres kaynaklarının sınıflandırılması problemini doğrulamak açısından farklı stres kaynakları SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılarak trigonometrik dönüşüm fonksiyonları kullanılmadan sınıflandırma sonuçları elde edilmiştir. Ayrıca önerilen çalışmanın literatürdeki benzer çalışmalara göre farklılıkları (öznitelik belirleme yöntemi, farklı stres kaynaklarının sınıflandırılması problemi) gösterilmiştir. Tez çalışmasında elde edilen bulgular bu kısımda detaylı bir şekilde açıklanmıştır.

3.1. Trigonometrik Öznitelikler Kullanılarak Farklı Stres Kaynaklarının Sınıflandırılması

İlgili başlık altında SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılan veri setinin sadece yaygın trigonometrik dönüşüm fonksiyonları kullanılarak elde edilen sınıflandırma sonuçlarına ait bulgular ve yaygın trigonometrik dönüşüm fonksiyonlarına ek olarak önerilen trigonometrik dönüşüm fonksiyonları da kullanılarak elde edilen sınıflandırma sonuçları detaylı bir şekilde verilmiştir.

3.1.1. Yaygın Trigonometrik Dönüşüm Fonksiyonları Kullanılarak Elde Edilen Sınıflandırma Sonuçları

Farklı stres durumlarında 25 saniye boyunca 128 Hz örnekleme frekansı ile 3 defa kaydedilen EEG verileri; bant geçiren filtre ve maksimum minimum noktalar kullanılarak ön işleme aşamasından geçirilmiştir. Ön işleme aşaması tamamlanan EEG verileri; min-max normalizasyon yöntemi kullanılarak 0-1 aralığına indirgenmiş ve elde edilen veriler $0-2\pi$ aralığında çarpılarak 0^0-360^0 karşılıkları elde edilmiştir. TD1, TD2, TD3, TD4 ve TD5 fonksiyonları ile Şekil 25'te verilen öznitelik belirleme algoritması kullanılmıştır. 5 farklı trigonometrik dönüşüm fonksiyonunun birbirleriyle oluşturabilecekleri 31 (2^5-1) farklı öznitelik vektörü belirlenerek ayrı ayrı dalgacık dönüşümüne sokulmuştur. Devamında elde edilen 31 farklı öznitelik vektörü k-EYK, Bayes, KA ve DVM sınıflandırma algoritmalarına sokularak en yüksek sınıflandırma doğrulukları hesaplanmıştır. Her işlem adımı on defa tekrarlanmıştır. 40 farklı denekten ölçülen 32 farklı kanalın hepsi hesaplama sürecinde işleme alınmıştır. Eğitim seti ve test seti verileri rastgele dağıtılarak iki eşit parçaya bölünmüştür. 3 farklı stres kaynağından oluşan veri seti SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılarak her bir stres durumunun kombinasyonu için işlemler tekrarlanmıştır.

SD 1 ve SD 2 kaynaklarından oluşan ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (TD2, TD3, TD4 ve TD5) kombinasyonunda k-EYK sınıflandırma algoritması için %69.17, (TD5) kombinasyonunda Bayes sınıflandırma

algoritması için %66.67, (TD1, TD2 ve TD5) kombinasyonunda KA sınıflandırma algoritması için %69.17 ve (TD2, TD3 ve TD5) kombinasyonunda DVM sınıflandırma algoritması için %70.00 olarak hesaplanmıştır. Tablo 3'te SD 1 ve SD 2 sınıflarının yaygın trigonometrik dönüşüm fonksiyonlarının tüm kombinasyonlarında elde edilen sonuçları verilmiştir.

Tablo 3. SD 1 ve SD 2 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	KA	DVM
TD1	61.67	63.33	61.67	64.17
TD2	63.33	61.67	62.50	65.00
TD3	60.83	64.17	64.17	69.17
TD4	63.33	63.33	62.50	66.67
TD5	64.17	66.67	65.83	66.67
TD1+TD2	62.50	62.50	66.67	65.83
TD1+TD3	60.00	61.67	60.83	68.33
TD1+TD4	61.67	62.50	60.00	65.83
TD1+TD5	60.83	60.00	61.67	65.00
TD2+TD3	60.83	63.33	62.50	65.83
TD2+TD4	63.33	63.33	60.83	65.83
TD2+TD5	58.33	61.67	63.33	65.00
TD3+TD4	67.50	62.50	66.67	69.17
TD3+TD5	60.83	60.83	64.17	67.50
TD4+TD5	60.83	64.17	65.00	67.50
TD1+TD2+TD3	64.17	62.50	59.17	66.67
TD1+TD2+TD4	65.00	60.00	61.67	64.17
TD1+TD2+TD5	60.83	62.50	69.17	67.50
TD1+TD3+TD4	63.33	62.50	64.17	67.50
TD1+TD3+TD5	62.50	62.50	64.17	66.67
TD1+TD4+TD5	64.17	62.50	65.00	67.50
TD2+TD3+TD4	66.67	62.50	62.50	67.50
TD2+TD3+TD5	62.50	62.50	64.17	70.00
TD2+TD4+TD5	60.83	65.83	63.33	68.33
TD3+TD4+TD5	63.33	59.17	60.83	67.50
TD1+TD2+TD3+TD4	62.50	65.83	62.50	63.33
TD1+TD2+TD3+TD5	62.50	64.17	61.67	64.17
TD1+TD2+TD4+TD5	62.50	65.00	63.33	67.50
TD1+TD3+TD4+TD5	64.17	64.17	68.33	66.67
TD2+TD3+TD4+TD5	69.17	65.83	62.50	67.50
TD1+TD2+TD3+TD4+TD5	64.17	63.33	63.33	65.83

SD 1 ve SD 3 kaynaklarından oluşan ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (TD1, TD4 ve TD5) kombinasyonunda k-EYK sınıflandırma algoritması için %66.67, (TD3) kombinasyonunda Bayes sınıflandırma algoritması için %65.00, (TD1 ve TD4) kombinasyonunda KA sınıflandırma algoritması için %68.33 ve (TD5 / TD2, TD4 / TD4, TD5) kombinasyonlarında DVM sınıflandırma algoritması için %69.17 olarak hesaplanmıştır. Tablo 3'te SD 1 ve SD 3 sınıflarının yaygın trigonometrik dönüşüm fonksiyonlarının tüm kombinasyonlarında elde edilen sonuçları verilmiştir.

Tablo 4. SD 1 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	KA	DVM
TD1	61.67	61.67	60.00	65.00
TD2	61.67	63.33	60.83	66.67
TD3	60.83	65.00	62.50	64.17
TD4	65.83	62.50	67.50	66.67
TD5	62.50	60.00	59.17	69.17
TD1+TD2	60.00	62.50	61.67	66.67
TD1+TD3	63.33	64.17	66.67	66.67
TD1+TD4	65.83	61.67	68.33	65.83
TD1+TD5	64.17	60.83	59.17	65.83
TD2+TD3	62.50	64.17	64.17	67.50
TD2+TD4	62.50	61.67	64.17	69.17
TD2+TD5	68.33	60.83	65.00	68.33
TD3+TD4	64.17	63.33	65.83	65.83
TD3+TD5	65.83	60.83	62.50	66.67
TD4+TD5	64.17	63.33	64.17	69.17
TD1+TD2+TD3	60.83	62.50	59.17	65.00
TD1+TD2+TD4	58.33	64.17	60.83	63.33
TD1+TD2+TD5	59.17	60.00	63.33	67.50
TD1+TD3+TD4	63.33	61.67	60.83	66.67
TD1+TD3+TD5	65.00	64.17	65.00	66.67
TD1+TD4+TD5	66.67	60.83	60.00	67.50
TD2+TD3+TD4	57.50	60.83	59.17	67.50
TD2+TD3+TD5	63.33	62.50	63.33	65.00
TD2+TD4+TD5	62.50	61.67	63.33	65.83
TD3+TD4+TD5	64.17	62.50	60.00	67.50
TD1+TD2+TD3+TD4	60.83	60.83	60.83	67.50
TD1+TD2+TD3+TD5	61.67	61.67	59.17	65.83
TD1+TD2+TD4+TD5	61.67	61.67	60.83	65.00
TD1+TD3+TD4+TD5	65.00	60.83	63.33	67.50
TD2+TD3+TD4+TD5	63.33	60.83	61.67	66.67
TD1+TD2+TD3+TD4+TD5	58.33	63.33	58.33	66.67

SD 2 ve SD 3 kaynaklarının ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (TD1, TD2, TD3, TD4 ve TD5) kombinasyonunda k-EYK sınıflandırma algoritması için %69.17, (TD2, TD3 ve TD4) kombinasyonunda Bayes sınıflandırma algoritması için %68.33, (TD1, TD2 ve TD3) kombinasyonunda KA sınıflandırma algoritması için %67.50 ve (TD1, TD4 ve TD5/ TD2, TD3 ve TD5/ TD2, TD4 ve TD5) kombinasyonlarında DVM sınıflandırma algoritması için %68.33 olarak hesaplanmıştır. Tablo 3'te tüm kombinasyonların sınıflandırma sonuçları verilmiştir.

Tablo 5. SD 2 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	DVM	KA
TD1	60.00	60.83	59.17	65.00
TD2	65.00	59.17	60.00	63.33
TD3	59.17	61.67	59.17	63.33
TD4	57.50	64.17	57.50	65.83
TD5	58.33	62.50	55.83	64.17
TD1+TD2	59.17	63.33	60.00	65.83
TD1+TD3	60.83	60.83	61.67	63.33
TD1+TD4	60.83	60.00	60.83	62.50
TD1+TD5	59.17	60.00	58.33	67.50
TD2+TD3	62.50	57.50	60.83	65.83
TD2+TD4	60.00	61.67	59.17	63.33
TD2+TD5	59.17	62.50	62.50	63.33
TD3+TD4	62.50	59.17	58.33	63.33
TD3+TD5	64.17	59.17	63.33	67.50
TD4+TD5	60.00	61.67	58.33	65.00
TD1+TD2+TD3	65.83	61.67	67.50	65.00
TD1+TD2+TD4	64.17	62.50	60.83	65.00
TD1+TD2+TD5	64.17	60.83	63.33	65.00
TD1+TD3+TD4	64.17	64.17	60.00	67.50
TD1+TD3+TD5	60.83	62.50	61.67	67.50
TD1+TD4+TD5	64.17	63.33	63.33	68.33
TD2+TD3+TD4	60.00	68.33	61.67	65.00
TD2+TD3+TD5	60.83	63.33	59.17	68.33
TD2+TD4+TD5	63.33	65.00	60.00	68.33
TD3+TD4+TD5	63.33	60.00	60.00	67.50
TD1+TD2+TD3+TD4	63.33	61.67	63.33	64.17
TD1+TD2+TD3+TD5	60.00	60.00	61.67	67.50
TD1+TD2+TD4+TD5	60.00	63.33	59.17	66.67
TD1+TD3+TD4+TD5	61.67	63.33	65.00	66.67
TD2+TD3+TD4+TD5	63.33	60.00	59.17	65.83
TD1+TD2+TD3+TD4+TD5	69.17	65.00	65.83	67.50

3.1.2. Yaygın Trigonometrik Dönüşüm Fonksiyonlarına İlaveten Önerilen Trigonometrik Dönüşüm Fonksiyonları da Kullanılarak Elde Edilen Sınıflandırma Sonuçları

Yaygın Trigonometrik dönüşüm fonksiyonları kullanılarak gerçekleştirilen sınıflandırma çalışmalarının başarı oranını artırmak amacıyla 7 farklı trigonometrik dönüşüm fonksiyonu önerilerek çalışmaya dahil edilmiştir. Önerilen trigonometrik dönüşüm fonksiyonları oluşturulurken aktivasyon fonksiyonlarının derin öğrenme fonksiyonlarında başarılı olarak kabul edildiği merkeze göre yansıyan, monoton olma durumu, aralıklı yapıya sahip olma durumu, türevlenebilme özelliğine sahip ve doğrusal olmayan yapıya sahip olma özellikleri dikkate alınmıştır. Bu kapsamda yöntem kısmında matematiksel denklemleri verilen ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6 ve ÖTD7 fonksiyonları oluşturulmuştur. Önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma performanslarındaki başarı potansiyelini değerlendirmek için TD1, TD2, TD3, TD4, TD5, ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6 ve ÖTD7 fonksiyonlarının kombinasyonları oluşturularak Şekil 25'te verilen öznitelik belirleme algoritmasında işleme alınmıştır.

5 farklı trigonometrik dönüşüm ve 7 farklı önerilen trigonometrik dönüşüm fonksiyonunun birbiri ile oluşturabilecekleri 4095 (2^5-1) farklı öznitelik vektörü belirlenerek ayrı ayrı dalgacık dönüşümüne sokulmuştur. Devamında elde edilen 4095 farklı öznitelik vektörü k-EYK, Bayes, KA ve DVM sınıflandırma algoritmalarına sokularak en yüksek sınıflandırma doğrulukları hesaplanmıştır. Her işlem adımı on defa tekrarlanmıştır. 40 farklı denekten ölçülen 32 farklı kanalın hepsi hesaplama sürecinde işleme alınmıştır. Eğitim seti ve test seti verileri rastgele dağıtılarak iki eşit parçaya bölünmüştür. 3 farklı stres kaynağından oluşan veri seti SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılarak her bir stres durumu kombinasyonu için işlemler tekrarlanmıştır.

SD 1 ve SD 2 kaynaklarının ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, ÖTD7, TD2 ve TD3) kombinasyonunda k-EYK sınıflandırma algoritması için %81.67, (ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, TD2, TD3 ve TD4) kombinasyonunda Bayes sınıflandırma algoritması için %74.17, (ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, ÖTD7, TD2 ve TD3)

kombinasyonunda KA sınıflandırma algoritması için %80.84 ve (ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, ÖTD7, TD2, TD3 ve TD4) kombinasyonunda DVM sınıflandırma algoritması için %84.17 olarak hesaplanmıştır. Tablo 6'da yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonlarından elde edilen en iyi 5 kombinasyonun sonuçları verilmiştir.

Tablo 6. SD1 ve SD2 kombinasyonunda yaygın trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	KA	DVM
ÖTD1+ÖTD2+ÖTD3+ ÖTD4+ÖTD5+ÖTD6 ÖTD7+TD2+TD3+TD4	80.00	72.50	80.00	84.17
ÖTD1+ÖTD2+ÖTD3+ ÖTD4+ÖTD5+ÖTD6 ÖTD7+TD2+TD3	81.67	73.33	80.84	76.67
ÖTD1+ÖTD2+ÖTD3+ ÖTD4+ÖTD5+ÖTD6 TD2+TD3+TD4	80.00	74.17	76.67	80.00
ÖTD1+ÖTD2+ÖTD4 +ÖTD5+ÖTD6+ÖTD7 TD2+TD3+TD4	77.50	72.50	79.17	78.33
ÖTD2+ÖTD3+ÖTD4 ÖTD5+ÖTD6+ÖTD7 TD2+TD3+TD4	79.17	69.17	75.83	79.17

Yaygın trigonometrik dönüşüm fonksiyonlarına ilaveten önerilen trigonometrik dönüşüm fonksiyonları ile sınıflandırma doğrulukları k-EYK sınıflandırma algoritmasında %69.17'den %81.67'ye, Bayes sınıflandırma algoritmasında %66.67'den %74.17'ye, KA sınıflandırma algoritmasında %69.17'den %80.84'e ve DVM sınıflandırma algoritmasında %70'den %84.17'ye yükselmiştir.

SD 1 ve SD 3 kaynaklarının ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (ÖTD2, ÖTD5, ÖTD7, TD3 ve TD4) kombinasyonunda k-EYK sınıflandırma algoritması için %74.17, (ÖTD3, ÖTD4, ÖTD6, ÖTD7 ve TD2) kombinasyonunda Bayes sınıflandırma algoritması için %70.83, (ÖTD2, ÖTD4, ÖTD6,

ÖTD7,TD3 / ÖTD2, ÖTD4, ÖTD6, ÖTD7, TD10 / ÖTD4, ÖTD6, ÖTD7, TD3, TD4 / ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, TD2, TD4) kombinasyonunda KA sınıflandırma algoritması için %74.17 ve (ÖTD1, ÖTD2, ÖTD3, ÖTD4, ÖTD5, ÖTD6, ÖTD7 ve TD4) kombinasyonunda DVM sınıflandırma algoritması için %75.83 olarak hesaplanmıştır. Tablo 7’de yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonlarından elde edilen en iyi 5 kombinasyonun sonuçları verilmiştir.

Tablo 7. SD1 ve SD3 kombinasyonunda trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	KA	DVM
ÖTD1+ÖTD2+ÖTD3+ ÖTD4+ÖTD5+ÖTD6 ÖTD7+TD4	72.50	68.33	69.17	75.83
ÖTD1+ÖTD2+ÖTD3+ ÖTD4+ÖTD5+ÖTD6 TD2+TD4	71.67	64.17	74.17	70.83
ÖTD4+ÖTD6+ÖTD7 TD3+TD4	70.00	66.67	74.17	71.67
ÖTD2+ÖTD5+ÖTD7 TD3+TD4	74.17	64.17	72.50	69.50
ÖTD3+ÖTD4+ÖTD6 ÖTD7+TD2	72.50	70.83	71.67	71.67

Yaygın trigonometrik dönüşüm fonksiyonlarına ilaveten önerilen trigonometrik dönüşüm fonksiyonları ile sınıflandırma doğrulukları k-EYK sınıflandırma algoritmasında %66.67’den %74.17’ye, Bayes sınıflandırma algoritmasında %65.00’den %70.83’e, KA sınıflandırma algoritmasında %68.33’den %74.17’ye ve DVM sınıflandırma algoritmasında %69.17’den %75.83’e yükselmiştir.

SD 2 ve SD 3 kaynaklarının ikili alt sınıflandırma problemi çalışması sonucunda en yüksek doğruluk oranları; (ÖTD3, ÖTD4, ÖTD5, ÖTD6, TD2, TD3 / ÖTD2, ÖTD4, ÖTD5, ÖTD6, TD2, TD3 / ÖTD2, ÖTD5, ÖTD6, ÖTD7, TD2, TD3) kombinasyonunda k-EYK sınıflandırma algoritması için %77.83, (ÖTD1, ÖTD3, ÖTD4, TD2, TD4 / ÖTD2, ÖTD3,

ÖTD5, ÖTD6, ÖTD7, TD4) kombinasyonunda Bayes sınıflandırma algoritması için %73.67, (ÖTD2, ÖTD4, ÖTD5, ÖTD6, ÖTD7, TD2 / ÖTD4, ÖTD6, ÖTD7, TD2, TD3, TD4) kombinasyonunda KA sınıflandırma algoritması için %78.67 ve (ÖTD2, ÖTD6, ÖTD7, TD2, TD3 ve TD4) kombinasyonunda DVM sınıflandırma algoritması için %79.50 olarak hesaplanmıştır. Tablo 8’de yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonlarından elde edilen en iyi 5 kombinasyonun sonuçları verilmiştir.

Tablo 8. SD 2 ve SD 3 kombinasyonunda yaygın trigonometrik dönüşümler ile önerilen trigonometrik dönüşüm fonksiyonlarının sınıflandırma sonuçları

	k-EYK	Bayes	KA	DVM
ÖTD2+ÖTD4+ÖTD5+ ÖTD6+TD2+TD3	77.83	65.83	74.17	76.17
ÖTD2+ÖTD3+ÖTD5+ ÖTD6+ÖTD7+TD4	72.50	73.67	74.17	75.50
ÖTD4+ÖTD6+ÖTD7 TD2+TD3+TD4	73.33	70.00	78.67	72.50
ÖTD2+ÖTD6+ÖTD7 TD2+TD3+TD4	70.83	70.00	73.33	79.50
ÖTD1+ÖTD2+ÖTD6 ÖTD7+TD2+TD4	75.33	71.83	74.17	79.50

Yaygın trigonometrik dönüşüm fonksiyonlarına ilaveten önerilen trigonometrik dönüşüm fonksiyonları ile sınıflandırma doğrulukları k-EYK sınıflandırma algoritmasında %69.17’den %77.83’e, Bayes sınıflandırma algoritmasında %68.33’den %73.67’ye, KA sınıflandırma algoritmasında %67.50’den %78.67’ye ve DVM sınıflandırma algoritmasında %68.33’den %79.50’ye yükselmiştir.

3.2. Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Sınıflandırılması

Çalışmada önerilen trigonometrik dönüşümler kullanılarak farklı stres kaynaklarının birbirleri ile sınıflandırma probleminin başarısını doğrulamak için; standart öznitelik belirleme yöntemlerinden oluşan kombinasyonlar veri setine uygulanmıştır. Veri seti kendi içinde SD 1 ve SD 2, SD 1 ve SD 3, SD 2 ve SD 3 olmak üzere ikili alt sınıflandırma problemlerine ayrılarak sınıflandırma algoritmasına sokulmuştur. Her işlem adımı on defa tekrarlanmıştır. 40 farklı denekten ölçülen 32 farklı kanalın hepsi hesaplama sürecinde işleme alınmıştır. Eğitim seti ve test seti verileri rastgele dağıtılarak iki eşit parçaya bölünmüştür. Çalışmada kullanılan sınıflandırma algoritmaları k-EYK, Bayes, KA ve DVM'dir. Çalışma kapsamında kullanılan standart öznitelik belirleme yöntemleri aşağıda verildiği gibidir;

Standart Öznitelik Belirleme Yöntemi 1 (SÖY1) = Min max normalizasyon;

Standart Öznitelik Belirleme Yöntemi 2 (SÖY2) = Hilbert Dönüşümü,

Standart Öznitelik Belirleme Yöntemi 3 (SÖY3) = Ortalama,

Standart Öznitelik Belirleme Yöntemi 4 (SÖY4) = Basıklık,

Standart Öznitelik Belirleme Yöntemi 5 (SÖY5) = Çarpıklık,

Standart Öznitelik Belirleme Yöntemi 6 (SÖY6) = Türev,

Standart Öznitelik Belirleme Yöntemi 7 (SÖY7) = Türev Toplamı,

Standart Öznitelik Belirleme Yöntemi 8 (SÖY8) = Standart Sapma,

Standart Öznitelik Belirleme Yöntemi 9 (SÖY9) = Kurtosis,

Standart Öznitelik Belirleme Yöntemi 10 (SÖY10) = Varyasyon,

Standart Öznitelik Belirleme Yöntemi 11 (SÖY11) = Dalgacık Dönüşümü,

3.2.1. Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının k-EYK Sınıflandırma Algoritması Sonuçları

Veri seti; ikili alt sınıflandırma problemlerine bölünerek standart öznitelik belirleme yöntemlerinden oluşan kombinasyonlar ile en yüksek sınıflandırma sonuçları elde edilmiştir. k-EYK sınıflandırma algoritmasında trigonometrik öznitelik belirleme yöntemleri kullanılmadan elde edilen sınıflandırma sonuçları; SD 1 ve SD 2 sınıfları için %72.50, SD 1 ve SD 3 sınıfları için %73.33, SD 2 ve SD 3 sınıfları için %63.33 olarak hesaplanmıştır. Tablo 9’da standart öznitelik belirleme yöntemleri kullanılarak k-EYK sınıflandırma algoritmasında elde edilen sonuçları verilmiştir.

Tablo 9. Standart öznitelik belirleme yöntemi kombinasyonlarında k-EYK sınıflandırma sonuçları

	SD 1/SD 2	SD 1/SD 3	SD 2/SD 3
SÖY3/SÖY4/SÖY5/SÖY6/SÖY7/ SÖY8/SÖY9/SÖY10/SÖY11	71.67	73.33	62.50
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10	63.33	65.00	62.50
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/	62.50	65.00	59.17
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/ SÖY11	65.83	63.33	63.33
SÖY1/ SÖY2/SÖY11	62.50	59.17	60.83
SÖY1/ SÖY2	63.33	61.67	61.67
SÖY1/SÖY2/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	62.50	59.17	63.33
SÖY1/SÖY11/SÖY2/SÖY3/SÖY4/ SÖY5/SÖY6/SÖY7/SÖY8/SÖY9/ SÖY10	61.67	60.83	61.67
SÖY2/SÖY11/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	72.50	71.67	56.67
SÖY2/SÖY11	71.67	70.00	58.33

3.2.2. Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Bayes Sınıflandırma Algoritması Sonuçları

Veri seti; ikili alt sınıflandırma problemlerine bölünerek standart öznitelik belirleme yöntemlerinden oluşan kombinasyonlar ile en yüksek sınıflandırma sonuçları elde edilmiştir. Bayes sınıflandırma algoritmasında trigonometrik öznitelik belirleme yöntemleri kullanılmadan elde edilen sınıflandırma sonuçları; SD 1 ve SD 2 sınıfları için %68.33, SD 1 ve SD 3 sınıfları için %67.50, SD 2 ve SD 3 sınıfları için %62.50 olarak hesaplanmıştır. Tablo 10'da standart öznitelik belirleme yöntemleri kullanılarak Bayes sınıflandırma algoritmasında elde edilen sonuçları verilmiştir.

Tablo 10. Standart öznitelik belirleme yöntemi kombinasyonlarında k-EYK sınıflandırma sonuçları

	SD 1/SD 2	SD 1/SD 3	SD 2/SD 3
SÖY3/SÖY4/SÖY5/SÖY6/SÖY7/ SÖY8/SÖY9/SÖY10/SÖY11	65.83	64.17	58.33
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10	67.50	67.50	61.67
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/	64.17	64.17	60.83
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/ SÖY11	61.67	61.67	62.50
SÖY1/ SÖY2/SÖY11	62.50	64.17	62.50
SÖY1/ SÖY2	62.50	61.67	60.83
SÖY1/SÖY2/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	61.67	63.33	60.83
SÖY1/SÖY2/SÖY11/SÖY3/SÖY4/ SÖY5/SÖY6/SÖY7/SÖY8/SÖY9/ SÖY10	65.83	63.33	63.33
SÖY2/SÖY11/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	68.33	65.83	60.83
SÖY2/SÖY11	66.67	64.17	61.67

3.2.3. Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Karar Ağacı Sınıflandırma Algoritması Sonuçları

Veri seti; ikili alt sınıflandırma problemlerine bölünerek standart öznitelik belirleme yöntemlerinden oluşan kombinasyonlar ile en yüksek sınıflandırma sonuçları elde edilmiştir. KA sınıflandırma algoritmasında trigonometrik öznitelik belirleme yöntemleri kullanılmadan elde edilen sınıflandırma sonuçları; SD 1 ve SD 2 sınıfları için %69.17, SD 1 ve SD 3 sınıfları için %66.67, SD 2 ve SD 3 sınıfları için %63.33 olarak hesaplanmıştır. Tablo 11’de standart öznitelik belirleme yöntemleri kullanılarak KA sınıflandırma algoritmasında elde edilen sonuçları verilmiştir.

Tablo 11. Standart öznitelik belirleme yöntemi kombinasyonlarında KA sınıflandırma sonuçları

	SD 1/SD 2	SD 1/SD 3	SD 2/SD 3
SÖY3/SÖY4/SÖY5/SÖY6/SÖY7/ SÖY8/SÖY9/SÖY10/SÖY11	62.50	63.33	57.50
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10	69.17	65.00	60.83
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/	65.83	64.17	63.33
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/ SÖY11	62.50	62.50	60.83
SÖY1/ SÖY2/SÖY11	63.33	63.33	62.50
SÖY1/ SÖY2	68.50	66.67	59.17
SÖY1/SÖY2/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	63.33	65.83	60.00
SÖY1/SÖY2/SÖY11/SÖY3/SÖY4/ SÖY5/SÖY6/SÖY7/SÖY8/SÖY9/ SÖY10	65.83	64.17	61.67
SÖY2/SÖY11/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	69.17	65.83	61.67
SÖY2/SÖY11	62.50	65.00	59.17

3.2.4. Standart Öznitelik Belirleme Yöntemleri Kullanılarak Farklı Stres Kaynaklarının Destek Vektör Makineleri Sınıflandırma Algoritması Sonuçları

Veri seti; ikili alt sınıflandırma problemlerine bölünerek standart öznitelik belirleme yöntemlerinden oluşan kombinasyonlar ile en yüksek sınıflandırma sonuçları elde edilmiştir. DVM sınıflandırma algoritmasında trigonometrik öznitelik belirleme yöntemleri kullanılmadan elde edilen sınıflandırma sonuçları; SD 1 ve SD 2 sınıfları için %70.00, SD 1 ve SD 3 sınıfları için %68.33, SD 2 ve SD 3 sınıfları için %67.50 olarak hesaplanmıştır. Tablo 12’de standart öznitelik belirleme yöntemleri kullanılarak DVM sınıflandırma algoritmasında elde edilen sonuçları verilmiştir.

Tablo 12. Standart öznitelik belirleme yöntemi kombinasyonlarında DVM sınıflandırma sonuçları

	SD 1/SD 2	SD 1/SD 3	SD 2/SD 3
SÖY3/SÖY4/SÖY5/SÖY6/SÖY7/ SÖY8/SÖY9/SÖY10/SÖY11	68.33	66.50	64.17
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10	69.17	65.00	66.50
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/	67.50	64.17	63.33
SÖY1/SÖY3/SÖY4/SÖY5/SÖY6/ SÖY7/SÖY8/SÖY9/SÖY10/SÖY2/ SÖY11	69.17	68.33	67.50
SÖY1/ SÖY2/SÖY11	66.67	68.33	65.00
SÖY1/ SÖY2	66.67	65.00	64.17
SÖY1/SÖY2/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	67.50	65.3	63.33
SÖY1/SÖY2/SÖY11/SÖY3/SÖY4/ SÖY5/SÖY6/SÖY7/SÖY8/SÖY9/ SÖY10	69.17	68.33	62.50
SÖY2/SÖY11/SÖY3/SÖY4/SÖY5/ SÖY6/SÖY7/SÖY8/SÖY9/SÖY10	70.00	68.33	61.67
SÖY2/SÖY11	70.00	67.50	62.50

3.3. Önerilen Yöntemin Literatürdeki Diğer Çalışmalarla Kıyaslanması

Bu tez çalışması kapsamında önerilen yöntem literatürdeki benzer içerikli diğer çalışmalar ile kıyaslanmıştır. Önerilen yöntemin ve benzer içerikli diğer çalışmaların ayrıntılarını içeren bilgiler tablo 13'te verilmiştir. Fizyolojik sinyallerin kullanımı ile stresin belirlenmesi üzerine birçok çalışma mevcuttur. Çalışmalar stres olgusuna yaklaşımlarına göre farklı kategorilere ayrılmaktadır. Çalışmaların çoğunda oluşturulan deney prosedüründe farklı stres kaynakları ve katılımcılara ait gevşeme durumlarına ait EEG verileri kaydedilerek stresli durum ile gevşeme durumunun birbirlerine göre kıyaslanmasına yönelik stres tespitine odaklanılmaktadır. Stres ve gevşeme durumuna ait sınıflandırma sonuçları 2 sınıflı, 3 sınıflı ve 4 sınıflı çalışmalara konu olabilmektedir. Yapılan kısıtlı çalışmalarda ise stresli durum ve gevşeme durumunun birbirleriyle kıyaslanmasından daha zor bir problem olarak kabul edilen farklı stres kaynaklarının birbirleriyle kıyaslanarak tespit çalışmasının yapıldığı çalışmalara rastlanılmaktadır.

Tez çalışması diğer çalışmalar ile kıyaslandığında iki farklı yaklaşım ile diğer çalışmalara göre farklılık göstermektedir. Birinci yaklaşım stroop renk kelime testi, yansıyan ayna görüntüleri ve aritmetik problem testinden oluşan farklı stres kaynaklarının birbirleriyle kıyaslanması üzerine çalışmalar yapılmıştır. Çalışma literatürdeki benzer çalışmalara göre farklı stres kaynaklarının kombinasyonlarından oluşmakta ve %84.17'lik sınıflandırma performansı ile benzer içeriğe sahip diğer çalışmaların önüne geçmektedir. İkinci yaklaşım ise öznitelik belirleme yöntemidir. Bu tez çalışmasında nöral aktivasyon fonksiyonlarına ek olarak trigonometrik dönüşüm fonksiyonları önerilerek en iyi kombinasyonlarına ait sonuçları EEG sinyallerinin özniteliklerinin belirlenmesi aşamasında kullanılmıştır.

Tablo 13. Literatürdeki diğer çalışmalarla önerilen yöntemin karşılaştırılması

	Fizyolojik Sinyal	Stres Görevi	Öznitelik Belirleme Yöntemi	Kişi Sayısı	Kanal Sayısı	Sınıf Sayısı	Doğruluk
Kaminska vd. [83]	EEG	Stroop renk kelime, Gevşeme durumu	Bağımsız Bileşen Analizi	28	32	2 (stres, gevşeme)	%96.42
Ahn vd [88].	EEG	Stroop renk kelime, Aritmetik problem, Gevşeme durumu	Fourier dönüşümü, İstatistiksel Yöntemler	14	2	2 (stres, gevşeme)	%77.90
Masood ve Alghamdi [90]	EEG	Stroop renk kelime, Gevşeme durumu	Fourier dönüşümü	24	2	2 (stres, gevşeme)	%87.50
Al Shargie vd. [84]	EEG	MIST, Gevşeme durumu	Kanonik Korelasyon Analizi	25	7	2 (stres, gevşeme)	%89.90
Xu vd. [89]	EEG	Bilişsel görev, Gevşeme durumu	Ortalama spektral güç, dalgacık dönüşümü	39	2	2 (stres, gevşeme)	%85.00
Zannetti vd. [92]	EEG	Aritmetik problem, Video oyunu, Gevşeme durumu	Bilgi teorik ölçütleri	17	14	3 (2 stres, gevşeme)	%84.60
Zhang vd. [95]	EEG	MIST, Gevşeme durumu	Frontal asimetri alfa, Beta Band gücü, Göreceli gama gücü	25	4	3 (2 stres, gevşeme)	%71.20
Minguillon vd. [93]	EEG	MIST, Gevşeme durumu	Ortalama bağıl gama, Pearson korelasyon katsayısı	10	8	3 (stres,nötr gevşeme)	%86.00
Jun vd. [91]	EEG	Stroop renk kelime, Aritmetik problem, Gevşeme durumu	Hızlı Fourier dönüşümü, Güç Spektral yoğunluğu	10	14	3 (2 stres, gevşeme)	%75.00
Jebelli vd. [97]	EEG	Fabrika içi işler, Fabrika dışı işler	İstatistiksel yöntemler, Ortalama güç	11	14	2 (stres,stres)	%80.32
So vd. [96]	EEG	Aritmetik problem, parmak vurma, Zihinsel rotasyon, sözcüksel karar	Min max normalizasyon, Zaman frekans analizi, İstatistik analiz	20	1	4 (stres,stres)	%65.00- %75.00
Önerilen Yöntem	EEG	Stroop renk kelime, Yansıyan ayna, Aritmetik problem	Trigonometrik Dönüşüm, Dalgacık Dönüşümü	40	32	2 (stres,stres)	%84.17

4. SONUÇLAR VE TARTIŞMA

Stres olgusu uzun yıllardır insanlığın yüzleştiği ve günümüzde kişilerin yaşam biçimlerine göre birçok değişken faktör ile tetiklenerek ortaya çıkmaya devam eden bir durumdur. Stresin tespit edilmesi ve tedavi sürecinin oluşturulması aşamasında uzman hekim ve uzman psikologlar yoğun bir şekilde çalışmalarına devam etmektedir. Ancak klinik ve rehabilitasyon süreçleri ile yapılan çalışmaların çoğunda tespit süreci birtakım bireysel deneyimlere ve hasta ile iyi ilişkiler kurulmasına bağlı olarak hata yapma olasılığının artmasına sebep olmaktadır. Teknolojinin gelişmesi stres kaynaklarında artışa sebep olmasına rağmen kişilerin tedavi sürecinde olumlu geri dönüşler verebilecek algoritmaların, ölçüm aletlerinin, hızlı sonuca ulaşılması ve hata olasılığının azaltılması gibi faydalı parametrelerinde ortaya çıkmasını sağlamıştır. Özellikle stres faktörleri tarafından tetiklenen bireyler istemsiz şekilde fizyolojik tepkiler göstermektedir. Bu durum stresin tespiti sürecinde fizyolojik sinyallerin kullanılmasına olanak sağlayarak daha hızlı daha doğru teşhis süreçleri oluşturabilmektedir.

Bu tez çalışmasında farklı stres kaynakları ile tetiklenen bireylerde oluşan stresli durumların tespiti üzerine çalışılmıştır. Bu kapsamda 40 sağlıklı katılımcının farklı stres testleri boyunca kaydedilen EEG sinyalleri kullanılmıştır. Stroop renk kelime testi, yansıyan ayna görüntüleri testi ve aritmetik problem çözme testi süreçlerinde 25 saniye boyunca 128 Hz örnekleme frekansında 32 kanallı EEG sinyalleri sınıflandırılmıştır. Sınıflar SD1, SD2 ve SD3 olmak üzere isimlendirilmiş ve farklı stres testlerinden oluşan veriler ikili alt sınıflandırma problemlerine bölünerek sınıflandırılmıştır. Öznitelik belirleme sürecinde nöral aktivasyon fonksiyonlarının trigonometrik dönüşümleri kullanılmış ve trigonometrik dönüşüm fonksiyonlarına ek olarak yeni trigonometrik dönüşüm fonksiyonları önerilerek sınıflandırma doğruluğunun artırılması hedeflenmiştir. Öznitelik vektörlerinin sınıflandırma süreçleri k-EYK, Bayes, KA ve DVM sınıflandırma algoritmaları kullanılarak gerçekleştirilmiştir. Tablo 14'te yaygın trigonometrik dönüşüm fonksiyonları kullanılarak oluşturulan öznitelik vektörlerinin 4 farklı sınıflandırma algoritmasında elde edilen en yüksek sınıflandırma doğrulukları gösterilmiştir. Tablo 15'te ise yaygın trigonometrik dönüşüm fonksiyonları ile önerilen trigonometrik dönüşüm fonksiyonlarından oluşan öznitelik vektörlerinin 4 farklı sınıflandırma algoritmasında elde edilen en yüksek sınıflandırma doğrulukları gösterilmiştir.

Tablo 14. Yaygın trigonometrik dönüşüm fonksiyonları kullanılarak elde edilen en yüksek sınıflandırma doğrulukları

	k-EYK	Bayes	KA	DVM
SD1/SD2	69.17	66.67	69.17	70.00
SD1/SD3	66.67	65.00	68.33	69.17
SD2/SD3	69.17	68.33	67.50	67.50

Tablo 15. Yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonları ile elde edilen en yüksek sınıflandırma doğrulukları

	k-EYK	Bayes	KA	DVM
SD1/SD2	81.67	74.17	80.84	84.17
SD1/SD3	74.17	70.83	74.17	75.83
SD2/SD3	77.83	73.67	78.67	79.50

Yaygın trigonometrik dönüşüm fonksiyonları ve önerilen trigonometrik dönüşüm fonksiyonlarının kıyaslanması sonucunda elde edilen sınıflandırma doğruluklarının karşılaştırılması sırasıyla aşağıda belirtilmiştir.

SD1/SD2 ikili alt sınıflandırma probleminde; k-EYK sınıflandırma algoritmasında doğruluk oranı %69.17'den %81.67'ye çıkarak %18.07 artış, Bayes sınıflandırma algoritmasında doğruluk oranı %66.67'den %74.17'ye çıkarak %11.25 artış, KA sınıflandırma algoritmasında doğruluk oranı %69.17'den %80.84'e çıkarak %16.87 artış ve DVM sınıflandırma algoritmasında doğruluk oranı %70.00'den %84.17'ye çıkarak %20.24 artış göstermiştir.

SD1/SD3 ikili alt sınıflandırma probleminde; k-EYK sınıflandırma algoritmasında doğruluk oranı %66.67'den %74.17'ye çıkarak %11.25 artış, Bayes sınıflandırma algoritmasında doğruluk oranı %65.00'den %70.83'e çıkarak %8.97 artış, KA sınıflandırma algoritmasında doğruluk oranı %68.33'den %74.17'ye çıkarak %8.55 artış ve DVM sınıflandırma algoritmasında doğruluk oranı %69.17'den %75.83'e çıkarak %9.63 artış göstermiştir.

SD2/SD3 ikili alt sınıflandırma probleminde; k-EYK sınıflandırma algoritmasında doğruluk oranı %69.17'den %77.83'e çıkarak %12.52 artış, Bayes sınıflandırma algoritmasında doğruluk oranı %68.33'den %73.67'ye çıkarak %7.82 artış, KA sınıflandırma algoritmasında doğruluk oranı %67.50'den %78.67'ye çıkarak %16.55 artış ve DVM sınıflandırma algoritmasında doğruluk oranı %68.33'den %79.50'ye çıkarak %16.35 artış göstermiştir.

Önerilen öznitelik belirleme yöntemi ile farklı stres kaynaklarının sınıflandırılmasında %84.17'ye varan sınıflandırma doğruluğu performansı elde edilmektedir. Ayrıca yaygın trigonometrik dönüşüm fonksiyonlarının tüm kombinasyonları ile önerilen trigonometrik dönüşüm fonksiyonlarının tüm kombinasyonlarının karşılaştırılması yapıldığında önerilen trigonometrik dönüşüm fonksiyonları kombinasyonlarında k-EYK sınıflandırma algoritmasında %18.07'ye varan, Bayes sınıflandırma algoritmasında %11.25'e varan, KA sınıflandırma algoritmasında %16.87'ye varan ve DVM sınıflandırma algoritmasında ise %20.24'e varan performans artışı gözlemlenmiştir.

5. ÖNERİLER

Bu tez çalışmasında laboratuvar ortamında 3 farklı stres kaynağı tarafından tetiklenen sağlıklı bireylerin EEG sinyal işaretlerinden oluşan veri seti kullanılmıştır. Farklı stres kaynaklarının birbirleriyle olan kombinasyonlarının sınıflandırılması işlemi sürecinde trigonometrik dönüşüm fonksiyonlarından oluşan öznitelik belirleme yönteminin kullanılması ise çalışmanın özgün yönünü ortaya çıkarmaktadır. Sınıflandırma sonucunda elde edilen en yüksek sınıflandırma performansı ise %84.17 olarak hesaplanmıştır. Farklı stres kaynaklarının birbirleriyle sınıflandırması aşamasında yüksek sınıflandırma doğruluğu elde etmeyi hedefleyen çalışmanın başarı oranını artırabilecek farklı yaklaşımlar için getirilen öneriler aşağıda sıralandığı gibidir;

Tez çalışmasında katılımcılardan laboratuvar ortamında suni testler ile oluşturulan stres kaynakları ile elde edilen EEG veri seti kullanılmıştır. Bunun yerine, ofis ortamı, şantiye ortamı, okul ortamı gibi günlük hayatta karşılaşılan stresli durumlarda katılımcıların kayıtları mobil EEG cihazı kullanılarak kaydedilebilir. Bu kapsamda oluşturulan veri seti içeriğinin suni ortamda oluşturulan stres kaynaklarına göre daha gerçekçi sonuçları içerisinde barındıracağı düşünülmektedir. Laboratuvar ortamında kaydedilen EEG verileri ile günlük işlerde kaydedilen EEG verilerinin doğruluk oranları arasında kıyaslama yapılabilmesine olanak sağlayabilir.

EEG verilerine ek olarak EKG, EMG, Solunum sinyaller gibi farklı fizyolojik sinyallerinde çalışmaya dahil edildiği multi modeller geliştirilebilir. Geliştirilen multi model sistemler laboratuvar ortamında kullanılabileceği gibi günlük hayatta karşılaşılan durumlarda mobil ölçüm cihazları ile de kayıt altına alınabilir. Bu durum stres sırasında oluşan farklı vücut tepkilerinin ölçülmesine olanak sağlayarak sınıflandırma performansının artmasına pozitif katkı sunabilir. Ayrıca stres sınıflandırılma çalışmalarında; fizyolojik sinyal tepkilerinin karşılaştırılabilmesi adına önemli katkılar sunabilir.

Bireylerin stresli durumlardan etkilenme oranları birbirlerine göre farklılık gösterebilmektedir. Kişiye göre öznitelik belirleme algoritmaları kullanılması sınıflandırma doğruluğuna pozitif katkı sunmasına rağmen işlem süresini artıracaktır. Ayrıca bireylerin stresli duruma gösterecekleri tepkiler günden güne farklılık gösterebileceği için farklı

günlerde kaydedilen veri seti ile daha kapsamlı bir içerik oluşturularak tespit çalışması gerçekleştirilebilir.

Bu çalışmada EEG verileri 32 kanallı Emotiv Epoc Flex jel kiti kullanılarak kaydedilmiş ve sınıflandırma sürecinde tüm kanallar kullanılmıştır. Ancak stresli durumlarda beyin aktivitesinin yoğun olduğu bölgeleri belirleyerek uygun elektrot seçimini gerçekleştiren bir algoritma hazırlanması sınıflandırma performansına pozitif katkı sunabilir.

EEG sinyal işaretlerinin ön işleme aşamasında bant geçiren filtre ve maksimum minimum noktalar yöntemi kullanılmıştır. Bunun yerine literatürde kullanılan diğer sinyal ön işleme yöntemlerinin de kullanılmasının sınıflandırma performansına etkileri üzerine araştırma yapılabilir.

Tez çalışmasında kullanılan 25 sn'lik veri seti 10 saniye, 5 saniye, 2 saniye ve 1 saniye gibi alt epoklara ayrılabilir. Alt bileşenlerine ayrılan veri seti içerisinde en etkin epoklar belirlenerek veri artırımı yapılabilir. Bu durum işlem süresini kısaltılabilir ve sınıflandırma performansının artmasına pozitif katkı sunabilir.

Sınıflandırma çalışmasında literatürde sıklıkla kullanılan k-EYK, Bayes, KA ve DVM sınıflandırma algoritmaları tercih edilmiştir. Gelecekteki çalışmalarda yapay sinir ağları, derin sinir ağları gibi farklı sınıflandırma algoritmaları da uygulanarak sınıflandırma performansları karşılaştırılabilir.

6. KAYNAKLAR

- [1] Fernández, J.R.M. ve Anishchenko, L., Mental Stress Detection Using Bioradar Respiratory Signals, Biomed Signal Process Control 43 (2018) 244.
- [2] De La Cruz, J., Shimizu, D. ve George, K., EEG and FNIRS Analysis Using Machine Learning to Determine Stress Levels, 2022 IEEE World AI IoT Congress (AIIoT), IEEE (2022) 318–322.
- [3] Shim, M., Im, C.H., Lee, S.H. ve Hwang, H.J., Enhanced Performance by Interpretable Low-Frequency Electroencephalogram Oscillations in the Machine Learning-Based Diagnosis of Post-Traumatic Stress Disorder, Front Neuroinform 16 (2022).
- [4] Pourmohammadi, S. ve Maleki, A., Stress Detection Using ECG and EMG Signals: A Comprehensive Study, Comput Methods Programs Biomed 193 (2020) 105482.
- [5] Reinertsen, E., Nemati, S., Vest, A. N., Vaccarino, V., Lampert, R., Shah, A. J. ve Clifford, G. D. Heart rate-based window segmentation improves accuracy of classifying posttraumatic stress disorder using heart rate variability measures. *Physiological measurement*, 38, 6 (2017) 1061.
- [6] Giannakakis, G., Grigoriadis, D., Giannakaki, K., Simantiraki, O., Roniotis, A. ve Tsiknakis, M. Review on psychological stress detection using biosignals. *IEEE Transactions on Affective Computing*, 13,1(2019) 440-460.
- [7] Bardavit, M., Kişilik Yapılarının-Stresi Değerlendirme, Stresle Başa Çıkma Yaklaşımları, Algılanan Stres ve İş Doyumu Üzerinde Olan Etkisinin Karşılaştırmalı Olarak İncelenmesi, Yayınlanmamış Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Psikoloji Anabilim Dalı, İstanbul (2007).
- [8] Elzeiny, S. ve Qaraqe, M., Blueprint to Workplace Stress Detection Approaches, 2018 International Conference on Computer and Applications, ICCA 2018, (2018) 407.
- [9] İlker, K., Stres, Ruh Sağlığı ve Stres Yönetimi: Güncel Bir Gözden Geçirme, Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi, 73 (2019) 63.
- [10] Shan, Y., Chen, T., Yao, L., Wu, Z., Wen, W., ve Liu, G., Remote Detection and Classification of Human Stress Using a Depth Sensing Technique, 2018 1st Asian Conference on Affective Computing and Intelligent Interaction, ACII Asia 2018 (2018).
- [11] Lazarus, R.S. ve Folkman, S., Stress, Appraisal, and Coping, Springer publishing company 1984.
- [12] Yerlikaya, E.E., Üniversite Öğrencilerinin Mizah Tarzları ile Algılanan Stres, Kaygı ve Depresyon Düzeyleri Arasındaki İlişkinin İncelenmesi, 2009.

- [13] Sarason, I.G., Johnson, J.H. ve Siegel, J.M., Assessing the Impact of Life Changes: Development of the Life Experiences Survey., J Consult Clin Psychol 46, 5 (1978) 932.
- [14] Vagg, P.R. ve Spielberger, C.D., Occupational Stress: Measuring Job Pressure and Organizational Support in the Workplace., J Occup Health Psychol 3, 4 (1998) 294.
- [15] Hargreaves, K.M. ve Branch, A., Neuroendocrine Markers of Stress., Anesth Prog 37, 2–3 (1990) 99.
- [16] Rodrigues, S.M., LeDoux, J.E. ve Sapolsky, R.M., The Influence of Stress Hormones on Fear Circuitry, Annu Rev Neurosci 32 (2009) 289.
- [17] Helmreich, D.L., Parfitt, D.B., Lu, X.-Y., Akil, H. ve Watson, S.J., Relation between the Hypothalamic-Pituitary-Thyroid (HPT) Axis and the Hypothalamic-Pituitary-Adrenal (HPA) Axis during Repeated Stress, Neuroendocrinology 81, 3 (2005) 183.
- [18] Nadolnik, L.I., Stress and the Thyroid Gland, Biochem Mosc Suppl B Biomed Chem 5 (2011) 103.
- [19] Koyuncu, A., Aydintuğ, S., Koçak, S., Aydın, C., Demirer, S., Topçu, Ö. ve Kuterdem, E., Effect of Thyroid Hormones on Stress Ulcer Formation, ANZ J Surg 72, 9 (2002) 672.
- [20] Johnson, J.D., Campisi, J., Sharkey, C. M., Kennedy, S. L., Nickerson, M., Greenwood, B. N. ve Fleshner, M., Catecholamines Mediate Stress-Induced Increases in Peripheral and Central Inflammatory Cytokines, Neuroscience 135, 4 (2005) 1295.
- [21] Elenkov, I.J. ve Chrousos, G.P., Stress System–Organization, Physiology and Immunoregulation, Neuroimmunomodulation 13, 5–6 (2006) 257.
- [22] Cuzzo, B., Padala, S.A. ve Lappin, S.L., “Physiology, vasopressin”, StatPearls [Internet], StatPearls Publishing (2021).
- [23] Jezova, D., Skultetyova, I., Tokarev, D.I., Bakos, P. ve Vigas, M., Vasopressin and Oxytocin in Stress., Ann N Y Acad Sci 771 (1995) 192.
- [24] Gal, C.S., Wagnon, J., Tonnerre, B., Roux, R., Garcia, G., Griebel, G. ve Aulombard, A., An Overview of SSR149415, a Selective Nonpeptide Vasopressin V1b Receptor Antagonist for the Treatment of Stress-Related Disorders, CNS Drug Rev, 11, 1 (2005) 53.
- [25] Rains, J.L. ve Jain, S.K., Oxidative Stress, Insulin Signaling, and Diabetes, Free Radic Biol Med 50, 5 (2011) 567.
- [26] Henriksen, E.J., Diamond-Stanic, M.K. ve Marchionne, E.M., Oxidative Stress and the Etiology of Insulin Resistance and Type 2 Diabetes, Free Radic Biol Med 51, 5 (2011) 993.
- [27] Pickering, A.D., Pottinger, T.G., Sumpter, J.P., Carragher, J.F. ve Le Bail, P.-Y., Effects of Acute and Chronic Stress on the Levels of Circulating Growth Hormone in the Rainbow Trout, *Oncorhynchus Mykiss*, Gen Comp Endocrinol 83, 1 (1991) 86.

- [28] Donahue, C.P., Kosik, K.S. ve Shors, T.J., Growth Hormone Is Produced within the Hippocampus Where It Responds to Age, Sex, and Stress, Proceedings of the National Academy of Sciences 103, 15 (2006) 6031.
- [29] Sarıbay, M. K., Köse, A. M. ve Yılmaz, M. A. Repeat breeder ineklerin tedavisinde GnRH ve gonadotropinlerin (LH, hCG, PMSG) kullanımı. Lalahan Hayvancılık Araştırma Enstitüsü Dergisi, 58, 1 (2018) 34-41.
- [30] Kirby, E.D., Geraghty, A.C., Ubuka, T., Bentley, G.E. ve Kaufer, D., Stress Increases Putative Gonadotropin Inhibitory Hormone and Decreases Luteinizing Hormone in Male Rats, Proceedings of the National Academy of Sciences 106, 27 (2009) 11324.
- [31] Iwasa, T., Matsuzaki, T., Yano, K. ve Irahara, M., Gonadotropin-Inhibitory Hormone Plays Roles in Stress-Induced Reproductive Dysfunction, Front Endocrinol (Lausanne) 8 (2017) 62.
- [32] Angelier, F. ve Chastel, O., Stress, Prolactin and Parental Investment in Birds: A Review, Gen Comp Endocrinol 163, 1–2 (2009) 142.
- [33] Lennartsson, A.-K. ve Jonsdottir, I.H., Prolactin in Response to Acute Psychosocial Stress in Healthy Men and Women, Psychoneuroendocrinology 36, 10 (2011) 1530.
- [34] Ancillon, L., Elgendi, M. ve Menon, C., Machine Learning for Anxiety Detection Using Biosignals: A Review, Diagnostics 12, 8 (2022) 1794.
- [35] Gedam, S. ve Paul, S., A Review on Mental Stress Detection Using Wearable Sensors and Machine Learning Techniques, IEEE Access 9 (2021) 84045.
- [36] Hammad, M., Maher, A., Wang, K., Jiang, F. ve Amrani, M., Detection of Abnormal Heart Conditions Based on Characteristics of ECG Signals, Measurement 125 (2018) 634.
- [37] Pereira, T., Almeida, P.R., Cunha, J.P.S. ve Aguiar, A., Heart Rate Variability Metrics for Fine-Grained Stress Level Assessment, Comput Methods Programs Biomed 148 (2017) 71.
- [38] Pingge, A., Bandyopadhyay, S., Ghosh, S. ve Sen, S., A Comparative Study between ECG-Based and PPG-Based Heart Rate Monitors for Stress Detection, 2022 14th International Conference on COMmunication Systems & NETworkS (COMSNETS), IEEE (2022) 84–89.
- [39] Posada-Quintero, H.F. ve Chon, K.H., Innovations in Electrodermal Activity Data Collection and Signal Processing: A Systematic Review, Sensors 20, 2 (2020) 479.
- [40] Tarvainen, M.P., Karjalainen, P.A., Koistinen, A.S. ve Valkonen-Korhonen, M. V, Principal Component Analysis of Galvanic Skin Responses, Proceedings of the 22nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (Cat. No. 00CH37143), Vol. 4, IEEE (2000) 3011–3014.
- [41] Zangróniz, R., Martínez-Rodrigo, A., Pastor, J.M., López, M.T. ve Fernández-Caballero, A., Electrodermal Activity Sensor for Classification of Calm/Distress Condition, Sensors 17, 10 (2017) 2324.
- [42] Liu, Y. ve Du, S., Psychological Stress Level Detection Based on Electrodermal Activity, Behavioural brain research 341 (2018) 50.

- [43] Lee, T., Natarajan, B. ve Warren, S., Pen-Type Electrodermal Activity Sensing System for Stress Detection Based on Likelihood Ratios, IEEE Trans Biomed Circuits Syst 15, 6 (2021) 1467.
- [44] Acevedo, C.M.D., Gómez, J.K.C. ve Rojas, C.A.A., Academic Stress Detection on University Students during COVID-19 Outbreak by Using an Electronic Nose and the Galvanic Skin Response, Biomed Signal Process Control 68 (2021) 102756.
- [45] Aboodı, S. A. K, Emg işaretleri ile kontrol edilen robot kol tasarımı, Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, 2022.
- [46] <https://www.tipacilar.com/elektromiyografi/>. 27 Şubat 2023.
- [47] Stålberg, E., van Dijk, H., Falck, B., Kimura, J., Neuwirth, C., Pitt, M. ve Zwarts, M., Standards for Quantification of EMG and Neurography, Clinical Neurophysiology 130, 9 (2019) 1688.
- [48] Pourmohammadi, S. ve Maleki, A., Stress Detection Using ECG and EMG Signals: A Comprehensive Study, Comput Methods Programs Biomed 193 (2020) 105482.
- [49] Chatterjee, D., Dutta, S., Shaikh, R. ve Saha, S.K., A Lightweight Deep Neural Network for Detection of Mental States from Physiological Signals, Innov Syst Softw Eng (2022) 1.
- [50] Durán-Acevedo, C.M., Carrillo-Gómez, J.K. ve Albarracín-Rojas, C.A., Electronic Devices for Stress Detection in Academic Contexts during Confinement Because of the Covid-19 Pandemic, Electronics (Switzerland) 10, 3 (2021) 1.
- [51] Karthikeyan, P., Murugappan, M. ve Yaacob, S., EMG Signal Based Human Stress Level Classification Using Wavelet Packet Transform, Trends in Intelligent Robotics, Automation, and Manufacturing: First International Conference, IRAM 2012, Kuala Lumpur, Malaysia, November 28-30, 2012. Proceedings, Springer (2012) 236–243.
- [52] Nielsen, M. M., Aryal, E., Safari, E., Mojsoska, B., Jenssen, H. ve Prabhala, B. K., Current State of Slc and Abc Transporters in the Skin and Their Relation to Sweat Metabolites and Skin Diseases, Proteomes, 9, (2021).
- [53] Kolosovas-Machuca, E.S. ve González, F.J., Distribution of Skin Temperature in Mexican Children, Skin Research and Technology 17, 3 (2011) 326.
- [54] Choi, J.K., Miki, K., Sagawa, S. ve Shiraki, K., Evaluation of Mean Skin Temperature Formulas by Infrared Thermography, Int J Biometeorol 41 (1997) 68.
- [55] <https://www.nkfu.com/derinin-dermis-katmaninda-neler-bulunur-ozellikleri-ve-gorevleri/> Derinin Dermis Katmanında Neler Bulunur? Özellikleri ve Görevleri 1 Mart 2023.
- [56] Yamakoshi, T., Yamakoshi, K. I., Tanaka, S., Nogawa, M., Park, S. B., Shibata, M. ve Hirose, Y., Feasibility Study on Driver's Stress Detection from Differential Skin Temperature Measurement, 2008 30th Annual International Conference of the Ieee Engineering in Medicine and Biology Society, IEEE (2008) 1076–1079.
- [57] Pisanski, K., Kobylarek, A., Jakubowska, L., Nowak, J., Walter, A., Błaszczynski, K. ve Sorokowski, P., Multimodal Stress Detection: Testing for Covariation in Vocal,

- Hormonal and Physiological Responses to Trier Social Stress Test, Horm Behav 106 (2018) 52.
- [58] Parreira, V. F., Bueno, C. J., França, D. C., Vieira, D. S., Pereira, D. R. ve Britto, R. R., Breathing Pattern and Thoracoabdominal Motion in Healthy Individuals: Influence of Age and Sex, Braz J Phys Ther 14 (2010) 411.
- [59] Helfenbein, E., Firoozabadi, R., Chien, S., Carlson, E. ve Babaeizadeh, S., Development of Three Methods for Extracting Respiration from the Surface ECG: A Review, J Electrocardiol 47, 6 (2014) 819.
- [60] <https://www.nkfu.com/solunum-sistemi-modeli-nasil-yapilir-solunum-sistemi-semalari/> Solunum Sistemi Modeli Nasıl Yapılır? Solunum Sistemi Şemaları. 1 Mart 2023
- [61] Pramudita, A.A. ve Suratman, F.Y., Low-Power Radar System for Noncontact Human Respiration Sensor, IEEE Trans Instrum Meas 70 (2021) 1.
- [62] Hameed, R.A., Sabir, M.K., Fadhel, M.A., Al-Shamma, O. ve Alzubaidi, L., Human Emotion Classification Based on Respiration Signal, Proceedings of the International Conference on Information and Communication Technology, (2019) 239–245.
- [63] Shan, Y., Li, S. ve Chen, T., Respiratory Signal and Human Stress: Non-Contact Detection of Stress with a Low-Cost Depth Sensing Camera, International Journal of Machine Learning and Cybernetics 11, 8 (2020) 1825.
- [64] Han, L., Zhang, Q., Chen, X., Zhan, Q., Yang, T. ve Zhao, Z., Detecting Work-Related Stress with a Wearable Device, Comput Ind 90 (2017) 42.
- [65] Ren, P., Barreto, A., Huang, J., Gao, Y., Ortega, F. R. ve Adjouadi, M., Off-Line and on-Line Stress Detection through Processing of the Pupil Diameter Signal, Ann Biomed Eng 42 (2014) 162.
- [66] Steinhauer, S.R., Siegle, G.J., Condray, R. ve Pless, M., Sympathetic and Parasympathetic Innervation of Pupillary Dilation during Sustained Processing, International journal of psychophysiology 52, 1 (2004) 77.
- [67] Sari, J.N., Hanung, A.N., Lukito, E.N., Santosa, P.I. ve Ferdiana, R., A Study on Algorithms of Pupil Diameter Measurement, 2016 2nd International Conference on Science and Technology-Computer (ICST), IEEE (2016) 188–193.
- [68] https://www.healio.com/news/optometry/20160623/j722_2002_7_news_print_2. Pupillary responses can signal potentially serious problems. 7 Mart 2023.
- [69] Vö, M. L. H., Jacobs, A. M., Kuchinke, L., Hofmann, M., Conrad, M., Schacht, A. ve Hutzler, F., The Coupling of Emotion and Cognition in the Eye: Introducing the Pupil Old/New Effect, Psychophysiology 45, 1 (2008) 130.
- [70] Pedrotti, M., et al., Automatic Stress Classification with Pupil Diameter Analysis, Int J Hum Comput Interact 30, 3 (2014) 220.
- [71] Pedrotti, M., Mirzaei, M. A., Tedesco, A., Chardonnet, J. R., Mérienne, F., Benedetto, S. ve Baccino, T., Off-Line and on-Line Stress Detection through Processing of the Pupil Diameter Signal, Ann Biomed Eng 42 (2014) 162.

- [72] Brockmann, L., Wang, H. ve Hunt, K.J., Time Dependence of Heart Rate Variability during Treadmill Running, Systems Science & Control Engineering 10, 1 (2022) 436.
- [73] Sacha, J., Interaction between Heart Rate and Heart Rate Variability, Annals of Noninvasive Electrocardiology 19, 3 (2014) 207.
- [74] Purnamasari, P.D., Martmis, R. ve Wijaya, R.R., Stress Detection Application Based on Heart Rate Variability (HRV) and k-Nearest Neighbor (KNN), 2019 International Conference on Electrical Engineering and Computer Science (ICECOS), IEEE (2019) 271–276.
- [75] Melillo, P., Bracale, M. ve Pecchia, L., Nonlinear Heart Rate Variability Features for Real-Life Stress Detection. Case Study: Students under Stress Due to University Examination, Biomed Eng Online 10 (2011) 1.
- [76] Purnamasari, P.D., Martmis, R. ve Wijaya, R.R., Stress Detection Application Based on Heart Rate Variability (HRV) and k-Nearest Neighbor (KNN), 2019 International Conference on Electrical Engineering and Computer Science (ICECOS), IEEE (2019) 271–276.
- [77] Szakonyi, B., Vassányi, I., Schumacher, E. ve Kósa, I., Efficient Methods for Acute Stress Detection Using Heart Rate Variability Data from Ambient Assisted Living Sensors, Biomed Eng Online 20, 1 (2021) 1.
- [78] Aydemir, Ö. ve Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim 9 (2009) 11.
- [79] Kayıkçıoğlu, T., Malek, M. ve Ketenci, S., Beyin-Bilgisayar Arayüzü, TMMOB Elektrik Mühendisleri Odası, Biyomedikal Mühendisliği ve Uygulamaları (2018).
- [80] Jasper, H.H., Ten-Twenty Electrode System of the International Federation, Electroencephalogr. Clin. Neurophysiol. 10 (1958) 371.
- [81] Tsai, Y.-H., Wu, S.-K., Yu, S.-S. ve Tsai, M.-H., Analyzing Brain Waves of Table Tennis Players with Machine Learning for Stress Classification, Applied Sciences 12, 16 (2022) 8052.
- [82] Perez-Valero, E., Vaquero-Blasco, M.A., Lopez-Gordo, M.A. ve Morillas, C., Quantitative Assessment of Stress through EEG during a Virtual Reality Stress-Relax Session, Front Comput Neurosci 15 (2021) 684423.
- [83] Kamińska, D., Smółka, K. ve Zwoliński, G., Detection of Mental Stress through EEG Signal in Virtual Reality Environment, Electronics (Basel) 10, 22 (2021) 2840.
- [84] Al-Shargie, F., Tang, T.B., Badruddin, N. ve Kiguchi, M., Simultaneous Measurement of EEG-FNIRS in Classifying and Localizing Brain Activation to Mental Stress, 2015 IEEE International Conference on Signal and Image Processing Applications (ICSIPA), IEEE (2015) 282–286.
- [85] Al-Shargie, F., Kiguchi, M., Badruddin, N., Dass, S. C., Hani, A. F. M. ve Tang, T. B., Mental Stress Assessment Using Simultaneous Measurement of EEG and FNIRS, Biomed Opt Express 7, 10 (2016) 3882.

- [86] Al-Shargie, F., Tang, T.B. ve Kiguchi, M., Assessment of Mental Stress Effects on Prefrontal Cortical Activities Using Canonical Correlation Analysis: An FNIRS-EEG Study, Biomed Opt Express 8, 5 (2017) 2583.
- [87] Chen, C., Yu, X., Belkacem, A. N., Lu, L., Li, P., Zhang, Z. ve Ming, D., EEG-Based Anxious States Classification Using Affective BCI-Based Closed Neurofeedback System, J Med Biol Eng 41 (2021) 155.
- [88] Ahn, J.W., Ku, Y. ve Kim, H.C., A Novel Wearable EEG and ECG Recording System for Stress Assessment, Sensors 19, 9 (2019) 1991.
- [89] Xu, Q., Nwe, T.L. ve Guan, C., Cluster-Based Analysis for Personalized Stress Evaluation Using Physiological Signals, IEEE J Biomed Health Inform 19, 1 (2014) 275.
- [90] Masood, K. ve Alghamdi, M.A., Modeling Mental Stress Using a Deep Learning Framework, IEEE Access 7 (2019) 68446.
- [91] Jun, G. ve Smitha, K.G., EEG Based Stress Level Identification, 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), IEEE (2016) 3270–3274.
- [92] Zanetti, M., Mizumoto, T., Faes, L., Fornaser, A., De Cecco, M., Maule, L. ve Nollo, G., Multilevel Assessment of Mental Stress via Network Physiology Paradigm Using Consumer Wearable Devices, J Ambient Intell Humaniz Comput 12 (2021) 4409.
- [93] Minguillon, J., Perez, E., Lopez-Gordo, M.A., Pelayo, F. Ve Sanchez-Carrion, M.J., Portable System for Real-Time Detection of Stress Level, Sensors 18, 8 (2018) 2504.
- [94] Plechawska-Wójcik, M., Tokovarov, M., Kaczorowska, M. ve Zapała, D., A Three-Class Classification of Cognitive Workload Based on EEG Spectral Data, Applied Sciences 9, 24 (2019) 5340.
- [95] Zhang, Y., Wang, Q., Chin, Z.Y. ve Ang, K.K., Investigating Different Stress-Relief Methods Using Electroencephalogram (EEG), 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE (2020) 2999–3002.
- [96] So, W.K.Y., Wong, S.W.H., Mak, J.N. ve Chan, R.H.M., An Evaluation of Mental Workload with Frontal EEG, PLoS One 12, 4 (2017) e0174949.
- [97] Jebelli, H., Hwang, S. ve Lee, S., EEG-Based Workers' Stress Recognition at Construction Sites, Autom Constr 93 (2018) 315.
- [98] Karimoi, R. Y., &-ve Karimoi, A. Y. Classification of EEG signals using hyperbolic tangent-tangent plot. International Journal of Intelligent Systems and Applications, 8 (2014) 39-45.
- [99] Ghosh, R., Deb, N., Sengupta, K., Phukan, A., Choudhury, N., Kashyap, S. ve Dutta, P., SAM 40: Dataset of 40 Subject EEG Recordings to Monitor the Induced-Stress While Performing Stroop Color-Word Test, Arithmetic Task, and Mirror Image Recognition Task, Data Brief 40 (2022) 107772.
- [100] Golden, C.J. ve Freshwater, S.M., Stroop Color and Word Test, (1978).

- [101] Somers, B., Francart, T. ve Bertrand, A., A Generic EEG Artifact Removal Algorithm Based on the Multi-Channel Wiener Filter, J Neural Eng 15, 3 (2018) 036007.
- [102] Nwajana, A., Analysis and Design of a Substrate Integrated Waveguide Multi-Coupled Resonator Diplexer, (2017).
- [103] https://en.wikipedia.org/wiki/Maximum_and_minimum#cite_note-5. Maximum and minimum – Wikipedia. 9 Mart 2023.
- [104] Tunç, A. ve Ülger, İ., Veri Madenciliği Uygulamalarında Özellik Seçimi İçin Finansal Değerlere Binning ve Five Number Summary Metotları Ile Normalizasyon İşleminin Uygulanması, XVIII. Akademik BiliGim Konferansı, Adnan Menderes Üniversitesi 30 (2016) 3.
- [105] Wang, X., Ren, H. ve Wang, A., Smish: A Novel Activation Function for Deep Learning Methods, Electronics (Basel) 11, 4 (2022) 540.
- [106] Feng, J. ve Lu, S., Performance Analysis of Various Activation Functions in Artificial Neural Networks, Journal of Physics: Conference Series, Vol. 1237, IOP Publishing (2019) 022030.
- [107] Zhu, H., Zeng, H., Liu, J. ve Zhang, X., Logish: A New Nonlinear Nonmonotonic Activation Function for Convolutional Neural Network, Neurocomputing 458 (2021) 490.
- [108] Lyu, F., Xia, Y., Mao, Z., Wang, Y., Wang, Y. ve Luo, Y. , ML-PLAC: Multiplierless Piecewise Linear Approximation for Nonlinear Function Evaluation, IEEE Transactions on Circuits and Systems I: Regular Papers 69, 4 (2021) 1546.
- [109] Zhao, H., Liu, F., Li, L. ve Luo, C., A Novel Softplus Linear Unit for Deep Convolutional Neural Networks, Applied Intelligence 48 (2018) 1707.
- [110] Polikar, R. The wavelet tutorial part i. Fundamental Concepts and an Overview of the Wavelet Theory, (1996).
- [111] Dilki, G. ve Başar, Ö.D., İşletmelerin İflas Tahmininde K-En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi 19-38 (2020) 224.
- [112] Zhang, L., Zhou, W. ve Jiao, L., Wavelet Support Vector Machine, IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics) 34, 1 (2004) 34.
- [113] Zhang, L., Ye, N., Zhou, W. ve Jiao, L., Support Vectors Pre-Extracting for Support Vector Machine Based on K Nearest Neighbour Method, 2008 International Conference on Information and Automation, IEEE (2008) 1353–1358.
- [114] Wickramasinghe, I. ve Kalutarage, H., Naive Bayes: Applications, Variations and Vulnerabilities: A Review of Literature with Code Snippets for Implementation, Soft comput 25, 3 (2021) 2277.
- [115] Mizianty, M.J., Kurgan, L.A. ve Ogiela, M.R., Discretization as the Enabling Technique for the Naive Bayes and Semi-Naive Bayes-Based Classification, Knowl Eng Rev 25, 4 (2010) 421.

- [116] Murthy, S.K., Automatic Construction of Decision Trees from Data: A Multi-Disciplinary Survey, Data Min Knowl Discov 2 (1998) 345.
- [117] Talekar, B. ve Agrawal, S., A Detailed Review on Decision Tree and Random Forest, Biosci. Biotechnol. Res. Commun 13 (2020) 245.



ÖZGEÇMİŞ

Lise öğrenimini Tevfik Serdar Anadolu Lisesi'nde tamamladı. Lisans öğrenimini Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. 2020 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliğinde yüksek lisans öğrenimine başladı. Yaklaşık 4 yıldır Karadeniz Teknik Üniversitesi Teknoloji Transferi Uygulama ve Araştırma Merkezi'nde proje uzmanı olarak görev yapmaktadır.

