

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FOTOPLETİSMOGRAFİ SINYALI İLE BRUKSİZM TEŞHİSİ İÇİN
MAKİNE ÖĞRENMESİ TABANLI BİR YÖNTEM
GELİŞTİRİLMESİ

DOKTORA TEZİ

Ömer ERİŞ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

HAZİRAN 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FOTOPLETİSMOGRAFİ SINYALI İLE BRUKSİZM TEŞHİSİ İÇİN
MAKİNE ÖĞRENMESİ TABANLI BİR YÖNTEM
GELİŞTİRİLMESİ

DOKTORA TEZİ

Ömer ERİŞ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof. Dr. Mehmet Recep BOZKURT

HAZİRAN 2025

Ömer Eriş tarafından hazırlanan “Fotopletismografi sinyali ile bruksizm teşhisi için makine öğrenmesi tabanlı bir yöntem geliştirilmesi” adlı tez çalışması 23.06.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektronik Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Mehmet Recep BOZKURT Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Gökçen ÇETİNEL Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Özhan ÖZKAN Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Mustafa Zahid YILDIZ Sakarya Uygulamalı Bilimler Üniversitesi	
Jüri Üyesi :	Doç. Dr. Ali Furkan KAMANLI Sakarya Uygulamalı Bilimler Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “FOTOPLETİSMOGRAFİ SİNYALİ İLE BRUKSİZM TEŞHİSİ İÇİN MAKİNE ÖĞRENMESİ TABANLI BİR YÖNTEM GELİŞTİRİLMESİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, etik kurul onay belgesi aldığımı, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(23/06/2025).

Ömer Eriş





Eşime ve oğluma



TEŞEKKÜR

Doktora tez çalışmam süresince bilgi, tecrübe ve desteğini her zaman yanımda hissettiren; yol göstericiliğiyle çalışmamı şekillendiren değerli danışmanım Sayın Prof. Dr. Mehmet Recep BOZKURT'a en içten teşekkürlerimi sunarım.

Veri seçimi ve çalışmanın önemli aşamalarında kıymetli katkılarını esirgemeyen Sayın Prof. Dr. Cahit BİLGİN'e; tez savunma jürimde ve izleme komitemde yer alan düzenli aralıklarla görüş ve yönlendirmeleriyle çalışmama katkıda bulunan Sayın Doç. Dr. Gökçen ÇETİNEL ve Sayın Doç. Dr. Mustafa Zahid YILDIZ'a teşekkür ederim.

Tez savunma jürimde yer alan Doç. Dr. Ali Furkan KAMANLI ve Dr. Öğr. Üyesi Özhan ÖZKAN'a kıymetli katkıları için teşekkür ederim. Ayrıca bilgi ve birikiminden yararlandığım Doç. Dr. Muhammed Kürşad UÇAR'a da gönülden teşekkür ederim.

Doktora eğitimim süresince en büyük desteğim olan, her adımda yanımda duran, birlikte emek verdiğimiz, birlikte ürettiğimiz, hem hayat hem akademi yol arkadaşım olan sevgili eşim Seval'e gönülden teşekkür ederim. Aynı zamanda tüm bu yoğunlukta sabrıyla, sevgisiyle bizi anlayışla karşılayan canım oğlum Deniz Burak'a da ayrıca teşekkür ederim.

Her zaman dualarıyla ve desteğiyle yanımda olan aileme, varlıklarıyla güç verdikleri için çok teşekkür ederim.

Ömer Eriş

İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	v
TEŞEKKÜR.....	ix
İÇİNDEKİLER.....	xi
KISALTMALAR	xiii
SİMGELER.....	xv
TABLO LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
SUMMARY.....	xxiii
1. GİRİŞ	1
2. BRUKSİZM	11
2.1. Tanımı.....	11
2.2. Etiyolojisi.....	12
2.3. Epidemiyolojisi	13
2.4. Teşhisi.....	13
2.5. Tedavisi.....	14
3. PPG VE HRV	17
3.1. PPG.....	17
3.2. PPG'nin Filtrelenmesi	18
3.3. PPG'den HRV'nin Elde Edilmesi	20
4. KULLANILAN VERİ SETİ	21
4.1. Çalışmanın Konusu ve Verilerin Toplanması.....	21
4.2. Verisetinin Elde Edilmesi	22
4.2.1. Uyku evreleme	22
4.2.2. Veri etiketlemeleri	25
4.2.1.1. Bruksizm etiketlemeleri	25
4.2.1.2. Kontrol etiketlemeleri	26
4.2.2. Veri setlerinin oluşturulması	27
5. ÖZELLİK ÇIKARMA VE SEÇME.....	29
5.1. Özellik Çıkarma	29
5.2. Özellik Seçme	33
5.2.1. PCA	33
5.2.2. Fisher özellik seçme algoritması	34
6. SINIFLANDIRMA VE PERFORMANS PARAMETRELERİ	35
6.1. Sınıflandırma Organizasyonu	35
6.2. Sınıflandırma Algoritmaları.....	36
6.2.1. SVM.....	37
6.2.2. kNN	38
6.2.3. Ensemble.....	39
6.2.4. NN	40
6.3. Performans Parametreleri	41

6.3.1. LOO yöntemi	41
6.3.2. k-kat çapraz doğrulama	41
6.3.1.1. Sistematiik örnekleme	42
6.3.3. Doğruluk, duyarlılık, özgüllük, kesinlik, F-ölçümü, Kappa ve AUC	43
7. SONUÇLAR	45
7.1. Tüm, SA ve Non-SA Veri Setleri ile Oluşturulan Modellerin Sonuçları.....	46
7.2. PCA ile Elde Edilen Modellerin Sonuçları	47
7.3. Fisher Özellik Seçme Algoritması ile Oluşturulan Modellerin Sonuçları	48
7.4. LOO Yöntemi Sonuçları	51
7.5. Bruksizmin Kontrol Grubundaki Her Bir Etiketle Ayrılma Performansları ..	52
8. TARTIŞMA VE ÖNERİLER	55
KAYNAKLAR.....	61
ÖZGEÇMİŞ.....	75



KISALTMALAR

AASM	: Amerikan uyku tıbbı akademisi
AI	: Yapay zeka
AUC	: Eğri altındaki alan
DK	: Değişim katsayısı
DT	: Karar ağaçları
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
EOG	: Elektrookulogram
fdatool	: Filtre tasarım ve analiz aracı
FFT	: Hızlı Fourier dönüşümü
FN	: Yanlış negatif
FP	: Yanlış pozitif
HRV	: Kalp atış hızı değişkenliği
IQR	: Çeyrekler arası genişlik
kNN	: k-En yakın komşu
LOO	: Birini dışarıda bırak
MAD	: Ortalama ya da medyan mutlak sapma
NN	: Sinir ağları
Non-SA	: Uyku apnesi olmayan
PCA	: Temel bileşen analizi
PLM	: Periyodik bacak hareketleri
PPG	: Fotopletismogram
PSG	: Polisomnografi
RERA	: Solunum çabası ile ilişkili uyarılma
RMMA	: Ritmik çiğneme kası aktivitesi
ROC	: Alıcı işlem karakteristiği
SA	: Uyku apnesi
SB	: Uyku bruksizmi
sEMG	: Yüzey elektromiyogram

SVD	: Tekil deęer ayrışımı
SVM	: Destek vektör makinesi
TME	: Temporomandibular eklem
TN	: Gerçek negatif
TP	: Gerçek pozitif



SİMGELER

A	: Hjort parametresi – Aktivite
A(i)	: i. HRV noktası
C	: Hjort parametresi – Karmaşıklık
CL	: Ortalama eğri uzunluğu
E	: Ortalama enerji
fs	: PPG örnekleme frekansı (Hertz)
G	: Geometrik ortalama
H	: Harmonik ortalama
M	: Hjort parametresi – Hareketlilik
N	: Popülasyon büyüklüğü
n	: örneklem büyüklüğü
N(i)	: i. PPG tepe noktası
p_o	: Gözlenen doğruluk değeri
p_e	: Rastgele beklenen doğruluk değeri
R	: Aralık
S	: Standart sapma
S²	: Varyans
S₁²	: 1. türevin varyansı
S₂²	: 2. türevin varyansı
SF	: Şekil faktörü
S_x	: Standart hata
T25	: %25 kırılmış ortalama
T50	: %50 kırılmış ortalama
TE	: Ortalama Teager enerjisi
$\bar{x}$	: Ortalama
$\tilde{x}$	: Medyan
x_i	: PPG/HRV'nin i. örneği (volt)
x_{kur}	: Basıklık
x_{maks}	: Maksimum değer
x_{min}	: Minimum değer

x_{rms} : Ortalama karekök değeri

x_{ske} : Çarpıklık



TABLO LİSTESİ

Sayfa

Tablo 4.1. Çalışmadaki bireylerin demografik bilgileri.	21
Tablo 4.2. Çalışmadaki bireylere ait uyku evre sayıları.	25
Tablo 4.3. Bruksizm ve kontrol etiketlemelerinin bireylere göre dağılımı.	27
Tablo 4.4. Veri setlerine ait bruksizm-kontrol veri sayıları.	28
Tablo 5.1. PPG'den çıkarılan karakteristik özelliklerin açıklamaları.	29
Tablo 5.2. İstatistiksel özelliklerin açıklamaları.	31
Tablo 5.3. Fisher puanlarına göre oluşturulan veri setleri.	34
Tablo 6.1. LOO yönteminde eğitim ve test için bireylerin dağılımı.	41
Tablo 6.2. 5-kat çapraz doğrulama ile eğitim veri setinin eğitilmesi.	42
Tablo 6.3. Karışıklık matrisi.	43
Tablo 7.1. Tüm, SA ve Non-SA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.	47
Tablo 7.2. Tüm ve PCA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.	48
Tablo 7.3. Tüm ve PCA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.	49
Tablo 7.4. LOO yöntemi ile sırasıyla her bir bireye ait verilerin test verisi olarak kullanıldığı modeller arasında en yüksek performansı veren modellerin performans değerleri.	52
Tablo 7.5. Bruksizm - mikro uyarılma, bruksizm - RERA ve bruksizm - PLM uyarılma veri setleri kullanılarak oluşturulan modeller arasında en yüksek performans gösteren modellerin performans değerleri.	53



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. PPG ölçümü a) İletim modu b) Yansıma modu (Park vd., 2022).....	17
Şekil 3.2. PPG dalga formu.....	18
Şekil 3.3. PPG a) Filtrelenmemiş b) Chebyshev tip II alçak geçiren filtre çıkışı c) Hareketli ortalama filtre çıkışı.	19
Şekil 3.4. PPG'den HRV'nin elde edilmesi a) PPG'de sistolik tepe noktalarının tespiti b) PPG sistolik tepe noktalarından HRV elde edilmesi.	20
Şekil 4.1. Verisetinin elde edilmesi.	22
Şekil 4.2. Uyku evrelemede elektrotların yerleşimi a) EEG b) EOG ve c) Çene EMG (Shriram vd., 2013).....	23
Şekil 4.3. Uyku evrelerine göre EEG, EOG ve EMG (Fröhlich, 2016).	24
Şekil 4.4. Örnek bruksizm ve kontrol etiketleri a) Mikro uyarılma b) RERA c) PLM uyarılma d) Fazık bruksizm e) Tonik bruksizm.	25
Şekil 4.5. Bruksizm tipleri (Huynh vd., 2011).	26
Şekil 5.1. PPG'den çıkarılan karakteristik özellikler.....	29
Şekil 5.2. Özellik çıkarma ile veri setinin elde ediliş süreci.	33
Şekil 5.3. PCA öz-vektör grafiği.	33
Şekil 6.1. Sınıflandırma süreci.	35
Şekil 6.2. SVM'de iki sınıf arasındaki düzlem (Melekoglu vd., 2022).....	37
Şekil 6.3. kNN çalışma yapısı (Melekoglu vd., 2022).....	38
Şekil 6.4. Torbalama ve yükseltme yöntemlerinin çalışma yapıları.....	39
Şekil 6.5. Sinir ağları yapısı.	40
Şekil 7.1. Tüm, SA ve Non-SA veri setleri en yüksek performanslı modellerin ROC eğrileri.	46
Şekil 7.2. Tüm ve PCA veri setleri en yüksek performanslı modellerin ROC eğrileri.	48
Şekil 7.3. Fisher özellik seçme algoritması sonucunda oluşturulan 1, 10, 15 ve 33 özellikli modellerin ROC eğrileri.	51
Şekil 7.4. Bruksizm - mikro uyarılma, bruksizm - RERA ve bruksizm - PLM uyarılma veri setleri ile en yüksek performans gösteren sınıflandırma modellerinin ROC eğrileri.	53



FOTOPLETİSMOGRAFİ SİNYALİ İLE BRUKSİZM TEŞHİSİ İÇİN MAKİNE ÖĞRENMESİ TABANLI BİR YÖNTEM GELİŞTİRİLMESİ

ÖZET

Uyku Bruksizmi (SB), bireyin farkında olmadan dişlerini sıkması veya gıcırdatması sonucu çene kaslarında anormal aktivitelere yol açan; hem dental hem de genel sağlık üzerinde olumsuz etkileri olabilen bir durumdur. Diş aşınması, çene eklemi bozuklukları, baş ağrısı ve uyku kalitesinde bozulma gibi çeşitli şikâyetlere neden olabilirken; tedavi edilmediği takdirde daha ciddi nöromüsküler ve psikolojik komplikasyonlara yol açabilmektedir.

Bruksizmin erken teşhisi, neden olduğu olumsuz etkiler başlamadan önce önlem alınmasına olanak tanır. Ancak, bruksizmin kesin teşhisi için kullanılan polisomnografi (PSG), yüksek maliyeti, sınırlı erişilebilirliği ve uygulama zorlukları nedeniyle yaygın olarak kullanılamamaktadır. Bu durum, bruksizmin genellikle klinik muayene veya anket gibi subjektif değerlendirme yöntemleriyle “olası” ya da “muhtemel” olarak teşhis edilmesine yol açmaktadır. Oysa erken ve kesin teşhis, hem bireyin yaşam kalitesinin korunması hem de sağlık sistemine olan yükün azaltılması açısından büyük önem taşımaktadır.

Bu tez çalışmasında, SB’nin noninvaziv, pratik ve yüksek doğrulukla teşhisini mümkün kılan; fotopletismogram (PPG) ve PPG’den elde edilen kalp atış hızı değişkenliği (HRV) verileri kullanılarak geliştirilen yapay zeka (AI) tabanlı bir teşhis modeli sunulmuştur. Bu kapsamda, 2013 yılına ait Sakarya Hendek Devlet Hastanesi Göğüs Hastalıkları Uyku Laboratuvarına ait kayıtlar retrospektif olarak incelenmiş; 12 uyku apnesi (SA) ve 5 uyku apnesi olmayan (Non-SA) olmak üzere toplam 17 bireye ait uyku kayıtları çalışmaya dahil edilmiştir.

PSG kayıtları, Amerikan Uyku Tıbbı Akademisi (AASM) uyku evreleme kriterlerine göre uzman hekim tarafından etiketlenmiş; sadece “uyku” olarak belirlenen epoklar değerlendirmeye alınmıştır. Bu epoklardaki çene elektromiyogram (EMG) kayıtları, yine AASM kriterlerine göre uzman hekim tarafından “bruksizm” (fazık, tonik ve karma) ve “kontrol” (mikro uyarılma, solunum çabası ile ilişkili uyarılma - RERA ve periyodik bacak hareketleri - PLM) olarak etiketlenmiştir. Etiketlenen bu epokların senkronize PPG kayıtları alınarak 623 bruksizm ve 875 kontrol olmak üzere toplam 1498 veri elde edilmiştir. Veriler uygun filtre kullanılarak temizlenmiş; zaman domeninde karakteristik ve istatistiksel olmak üzere toplam 96 özellik çıkarılmıştır.

Temel Bileşen Analizi (PCA) ile özellik sayısı 96’dan 47’ye düşürülmüştür. Ardından, Fisher özellik seçme yöntemi ile özelliklerin Fisher skorları hesaplanarak, en etkili biyobelirteçlerin belirlenmesi amacıyla farklı veri setleri oluşturulmuştur.

Dört farklı makine öğrenmesi algoritması (destek vektör makinesi - SVM, k en yakın komşu - kNN, Ensemble ve Sinir Ağları - NN) kullanılarak, 5-kat çapraz doğrulama ve hiperparametre optimizasyonu uygulanmış; bruksizm - kontrol ikili sınıflandırma modelleri geliştirilmiştir. Modellerin performansı, daha önce görülmemiş test verileri

üzerinde doğruluk, duyarlılık, özgüllük, F-ölçümü, Kappa ve alıcı işletim karakteristiği (ROC) eğrisi altındaki alan (AUC) ölçütleri ile değerlendirilmiştir.

Veri seti hem SA ve hem de Non-SA bireyleri içerdiğinden, sınıflandırma başarısının bu duruma bağlı olup olmadığı analiz edilmiştir. Tüm verilerde %92,8 doğruluk ve 0,9727 AUC, sadece SA'lı bireylerde %92,3 doğruluk ve 0,9722 AUC, sadece Non-SA'lı bireylerde ise %92,9 doğruluk ve 0,9705 AUC elde edilmiştir. Bu sonuçlar, modelin SA durumunda bağımsız olarak yüksek performans gösterdiğini ortaya koymuştur.

PCA sonrası 47 özellikli veri seti ile oluşturulan Ensemble modelinde %92,4 doğruluk ve 0,9676 AUC elde edilmiştir. Bu performans, 96 özellikli tüm veri setiyle elde edilen sonuçlara çok yakındır ve PCA veri setinin tüm veriyi %100 temsil ettiğini göstermektedir. PCA sonrasında özelliklerin Fisher skorları hesaplatılmış ve en yüksek Fisher skor değerine sahip özellikten başlayarak özellik sayısını her defasında bir artırarak 47 farklı veri seti elde edilmiştir. Bu veri setlerinde yapılan sınıflandırmalar sonucunda, 33 özelliğin kullanıldığı modelde %92,7 doğruluk ve 0,9685 AUC ile en yüksek başarı elde edilmiştir. Bununla birlikte, sadece 15 özelliğin kullanıldığı modelde %92 doğruluk ve 0,9691 AUC ile oldukça yakın bir başarı sağlanmıştır. Özellik sayısının 10'a düşürüldüğü durumda %91,1 doğruluk ve 0,96 AUC; yalnızca bir özelliğin (86 numaralı) kullanıldığı durumda ise %89,1 doğruluk ve 0,9374 AUC elde edilmiştir.

Modellerin bireyden bağımsız performansını test etmek amacıyla Birini Dışarıda Bırak (LOO) yöntemi kullanılmıştır. Her birey sırasıyla testte, diğer bireyler eğitimde kullanılarak oluşturulan modellerin performansları; sınıflandırma başarısının bireylere özgü olmadığını ve genellenebilir olduğunu doğrulamıştır. Ayrıca, kontrol grubunun içerdiği üç farklı uyarılma türü (mikro uyarılma, RERA ve PLM uyarılma) ayrı ayrı analiz edilmiş; 47 özellikli modelde bruksizm, mikro uyarılmadan %93, RERA'dan %89,3 ve PLM uyarılmadan %87 doğruluk ile ayırt edilebilmiştir.

Sonuçlar, PPG ve HRV kullanılarak geliştirilen AI destekli modellerin; yüksek doğrulukla, erken, güvenilir ve kullanıcı dostu bir şekilde bruksizmi teşhis etmede etkili olabileceğini göstermektedir. Bu yaklaşım, mevcut teşhis sistemlerine önemli bir alternatif sunmakta ve sağlıkta fırsat eşitliğini destekleme potansiyeline sahiptir. Ayrıca, bu çalışma PPG tabanlı bruksizm teşhisine yönelik literatürdeki ilk çalışma olması bakımından da önemli bir katkı sunmakta; gelecekte yapılacak çalışmalara ışık tutması beklenmektedir.

DEVELOPMENT OF A MACHINE LEARNING BASED METHOD FOR THE DIAGNOSIS OF BRUXISM WITH PHOTOPLETHYSMOGRAPHY SIGNAL

SUMMARY

Bruxism is a jaw muscle activity that can occur during sleep or wakefulness and is characterized by the habit of grinding or clenching the teeth and/or a thrusting movement that displaces the jaw forward or sideways. It is of significant clinical importance due to its potential to cause or exacerbate dental damage, temporomandibular joint disorders, muscle fatigue, orofacial pain, headaches, and sleep disruption. Left untreated, this can lead to more serious complications such as irreversible tooth wear, musculoskeletal strain, chronic pain, and psychological distress. Given its multifactorial nature and complex etiology, early and accurate diagnosis of sleep bruxism is essential for effective intervention and prevention of long-term health consequences.

Polysomnography (PSG), which enables the definitive diagnosis of bruxism, is the gold standard in the diagnosis of many sleep disorders other than bruxism, too. In diagnosis with PSG, the individual must sleep throughout the night under expert control with a large number of electrodes connected to the body. Because the individual is not in a home environment and many electrodes are connected to the body, the sleep disorder may show different characteristics and cause errors in diagnosis.

PSG is available in sleep laboratories. The number of sleep laboratories is limited, and bed capacities are low. Therefore, appointments are scheduled for later dates. In addition, since sleep laboratories are generally used to diagnose life-threatening conditions such as sleep apnea (SA), individuals with sleep bruxism cannot be referred to sleep laboratories for definitive diagnosis. Thus, individuals with bruxism receive a possible or probable diagnosis through clinical examination and patient history. Although bruxism is not a life-threatening sleep disorder such as SA, it can affect the quality of life and general health of the person. When left untreated, it can lead to increased physical damage in the long term and trigger other life-threatening disorders. Therefore, diagnosing bruxism early and starting treatment as soon as possible is important.

Developing practical systems that enable the diagnosis of bruxism with high accuracy will make it possible to diagnose bruxism before dental or general health problems caused by bruxism occur, improve the quality of life of individuals, and make equal opportunity in health possible. Sleep disorders can affect each other. Bruxism that can be diagnosed early will prevent the emergence of other disorders, too.

Considering all these, this thesis aims to develop an artificial intelligence (AI)-based model to diagnose bruxism accurately. For this purpose, photoplethysmogram (PPG), which can be easily obtained from the body without causing discomfort to the individual, was used. Considering that using more than one signal would increase

classification success, the heart rate variability (HRV) signal obtained from PPG, which is practical to obtain, was preferred as the second signal. Thus, developing two-signal diagnostic models with a single signal obtained from the body was possible.

The data in the study were obtained from the PSG records of individuals admitted to the sleep laboratory with suspected SA. In this context, the data of 17 individuals, 12 with SA and five without sleep apnea (Non-SA), were retrospectively analyzed. PSG recordings containing 33 channels of data are in 30-second epochs. An expert physician analyzed electromyogram (EMG), electrooculogram (EOG), and electroencephalogram (EEG) data in the recordings according to the American Academy of Sleep Medicine (AASM) criteria, and each epoch was labeled as “sleep” or “awake.” After discarding waking episodes, only sleep episodes were evaluated. An expert doctor labeled the jaw EMG recordings in these episodes according to the AASM bruxism criteria, and bruxism data were obtained. Similarly, EEG arousals were labeled according to AASM criteria, and control data were obtained. The control data consists of micro-arousals, respiratory effort- related arousals (RERA), and periodic leg movement (PLM) arousals. PPG data at the time intervals of the labeled data were obtained; a PPG data set consisting of bruxism and controls was obtained. The data set consists of 623 bruxism and 875 control labeled PPG data. Signal processing steps were then performed on these data. First, artifacts were cleaned from the data using an appropriate filter. Then, HRV was obtained from the filtered PPG signal. We extracted 38 characteristics and 29 statistical features from PPG and 29 statistical features from HRV. The aim was to better characterize the signals by keeping the number of features high. With the Principal Component Analysis (PCA) method, the database with 96 features could be represented 100% with 47 features. Thus, dimension reduction was possible. Fisher scores, which express the association level of 47 features with the result label, were calculated using the Fisher feature selection algorithm. According to Fisher's scores, the features were ranked from highest to lowest. Starting with the feature with the highest Fisher score and increasing the number of features one by one, 47 different data sets were obtained. Classification models were created using four machine learning methods: Support vector machine (SVM), k-nearest neighbor (kNN), Ensemble, and Neural Network (NN). It was aimed to identify the model that offers high performance with the minimum number of features. While creating the models, 5-fold cross-validation and hyperparameter optimization were performed. Classification performances of the models were evaluated using accuracy, sensitivity, selectivity, precision, F-score, Kappa, and area under the ROC curve (AUC) performance criteria. The Leaving-One-Out (LOO) method was used to observe whether the performances obtained in the models were independent of the individuals in the data set used. Bruxism-Micro-arousal, bruxism-RERA, and bruxism-PLM arousal classifications were also designed to see how well the micro-arousal, RERA, and PLM arousal labels in the control data could be distinguished from the bruxism labels. Of the 17 individuals in the study, 12 had SA, and five were Non-SA. We performed bruxism-control classification separately for individuals with and Non-SA and observed whether the performance obtained was generalizable. All labeling in the study was performed by a specialist physician who had previously worked in a sleep laboratory and experienced sleep staging (sleep-awake) and bruxism-arousal labeling. Evaluation of the labelings by more than one expert may increase the reliability of the study. In addition, the performance of machine learning models can improve as the sample size increases. Larger datasets can increase the generalizability of the model. We tried to minimize the adverse effects of sample size by performing LOO and 5-fold cross-validation.

According to the performance results obtained:

The bruxism data were successfully discriminated from the control data both in the whole dataset (92,8% accuracy, 0,9727 AUC) and when the data of SA (92,3% accuracy, 0,9722 AUC) and Non-SA (92,9% accuracy, 0,9708 AUC) individuals were considered separately. The performance values obtained with SA and Non-SA datasets confirmed the performance of the classification obtained using the whole dataset.

An accuracy of 92,8% and an AUC of 0,9727 before PCA (96 features) and an accuracy of 92,4% and an AUC of 0,9676 after PCA (47 features) were achieved. These results confirmed that the dataset obtained with PCA is 100% representative.

When only one feature (number 86) was used, the SVM method achieved 89,1% accuracy and 0,9374 AUC. Among 47 features, the Ensemble method achieved the highest performance using 33 features with 92,7% accuracy and 0,9685 AUC value. Close to the highest performance, the Ensemble model with only 15 features achieved 92% accuracy and 0,9691 AUC value. In addition, the Ensemble model with fewer features (10 features) could perform high-performance classification with 91,1% accuracy and 0,96 AUC.

Between the LOO method and the models where each individual is used as test data, the accuracy rates vary between 78,8% and 97,1%, and the AUC value varies between 0,88 and 1. The performance results confirm that the classification success is independent of the individuals.

Bruxism could be classified as having 93% accuracy with micro-arousal, 89,3% accuracy with RERA, and 87% accuracy with PLM arousal. These findings show that bruxism can be successfully classified regardless of the different labels of the control data and that the bruxism-control classification is generalizable for each label.

The results showed that AI-assisted models developed using PPG and HRV can be effective in early, reliable, and user-friendly diagnosis of bruxism with high classification performance. This approach will provide an important alternative to existing diagnostic systems and support equal opportunities in health. This study is also important as it is the first study in the literature to propose using PPG in diagnosing bruxism and is expected to shed light on future studies.



1. GİRİŞ

Uyku, insan sađlıđının korunmasında temel bir rol oynamakta olup, fiziksel, zihinsel ve duygusal iyilik halinin sürdürölmesi için vazgeçilmez bir süreçtir. Uyku sırasında vücutta doku onarımı gerçekleşmekte, bağışıklık sistemi güçlenmekte ve öğrenme ile hafıza gibi bilişsel işlevler desteklenmektedir (Walker, 2017). Bu nedenle, uyku süresinin ve kalitesinin bozulması, yalnızca bireyin gün içindeki performansını deđil, uzun vadede genel sađlık durumunu da olumsuz etkileyebilir. Uyku sađlığını etkileyen faktörler arasında, bireyin farkında olmadan gerçekleştirdiđi bazı davranışlar da yer almakta ve bu durum çeşitli sađlık problemlerine zemin hazırlayabilmektedir. Bu kapsamda, uyku sırasında ortaya çıkan davranışsal anomalilerden biri olan bruksizm, hem bireyin uyku kalitesini hem de genel sađlığını tehdit eden önemli bir durum olarak karşımıza çıkmaktadır.

Bruksizm, uykuda veya uyanıkken ortaya çıkabilen, dişleri gıcırdatma veya sıkma alışkanlığı ve/veya çeneyi ileri veya yanlara dođru yer deđiştiren itme hareketi ile karakterize bir çene kası aktivitesidir (Beddis vd., 2018; Castelo vd., 2010; Manfredini vd., 2017; Neu vd., 2018).

Multifaktöriyel (stres, anksiyete, sigara, alkol, uyuşturucu kullanımı (yetişkinlerde) gibi) kökeni konusunda fikir birliği bulunan bruksizm, hem diş sađlığını hem de yaşam kalitesini olumsuz etkilemektedir (Beddis vd., 2018; Castelo vd., 2010; Gouw vd., 2019; Lobbezoo vd., 2018).

Bruksizm, dişlerde hassasiyete, aşınmaya ve kırılmaya, diş destekleyen ve çevreleyen dokuları etkileyen hastalıklara sebep olabilmektedir. Temporomandibular eklem (TME) bozuklukları ile de ilişkilendirilen bruksizm tedavi edilmediğinde ilerleyen dönemlerde çene hareketlerinde kısıtlılık ve fonksiyonel bozukluklara neden olabilmektedir. Baş ağrısı, solunum güçlüđu ve yorgunluk/kas atrofisi gibi genel sađlık sorunlarına da neden olabilmektedir. Kötü uyku kalitesi ve beraberinde dikkat eksikliği bireylerin yaşam kalitesini olumsuz etkileyebilmektedir (Bezerra vd., 2021).

Bruksizm kaynaklı fiziksel bozukluklar bireylerin kendilerini sosyal ortamlarda kötü hissetmesine sebep olup, bu durum psikolojik rahatsızlıkları da tetikleyebilmektedir.

Ayrıca uykuda görülebilen diğer rahatsızlıklara da yol açabileceği bilinmektedir (Manfredini vd., 2013). Bruksizmin erken teşhisi bireylerin ilerleyen dönemlerde ciddi dental ve nöromusküler komplikasyonlar yaşamamasının önüne geçebilmek adına büyük önem taşımaktadır.

Hem diş hekimliği hem de uyku tıbbı açısından kritik öneme sahip bruksizm, klinik muayene, hasta anketleri ve polisomnografi (PSG) yöntemleri ile teşhis edilebilmektedir. Klinik muayene ve hasta anketleri, olası ve muhtemel teşhiste kullanılan subjektif yöntemlerdir ve hataya açıktır. PSG bruksizmin kesin teşhisinde kullanılır. Ancak maliyetli ve erişimi zordur (Raphael vd., 2016). Bu nedenle son yıllarda biyomedikal sinyal işleme tabanlı yaklaşımlar üzerine yapılan çalışmalar artmıştır. Makine öğrenmesi yöntemleri biyomedikal sinyal işleme ile entegre edilerek bruksizm tespiti için güvenilir ve pratik çözümler sunmaktadır. Bu tür yaklaşımlar uyku laboratuvarlarında yapılan pahalı ve zaman alıcı uygulamaya alternatif olarak daha erişilebilir ve kullanıcı dostu teşhis sistemleri geliştirilmesine olanak sağlayabilir.

Bu çalışmada, fotopletizmogram (PPG) ve PPG'den elde edilen kalp atış hızı değişkenliği (HRV) kullanılarak yapay zeka (AI) tabanlı bir bruksizm tespit sistemi geliştirildi. Çalışmadaki veriler, uyku apnesi (SA) şüphesi ile uyku laboratuvarına yatan bireylerin PSG kayıtlarından elde edildi. 33 kanal veri içeren PSG kayıtları 30 saniyelik epoklar halindedir. Kayıtlardaki elektromiyogram (EMG), elektrookülogram (EOG) ve elektroensefalogram (EEG) verileri Amerikan Uyku Tıbbı Akademisi (AASM) kriterlerine göre uzman hekim tarafından analiz edilerek her epok “uyku” veya “uyanık” olarak etiketlendi. Uyanık epoklar atılarak, uyku etiketli epoklar değerlendirmeye alındı. Bu epoklardaki çene EMG verileri yine uzman hekim tarafından AASM bruksizm kriterlerine göre etiketlendi. Ayrıca EEG uyarılmaları da uzman hekim tarafından AASM kriterlerine göre mikro uyarılma, solunum çabası ile ilişkili uyarılma (RERA) ve periyodik bacak hareketleri (PLM) ile ilişkili uyarılma olarak etiketlendi. Uyarılma olarak etiketlenen kısımlar kontrol verilerini oluşturmaktadır. Etiketlemelerin başlangıç ve bitiş süreleri dikkate alınarak PPG verileri alındı. Böylelikle PPG verilerinden oluşan bruksizm ve kontrol verileri elde edildi. Ardından sinyal işleme aşamaları gerçekleştirildi. İlk olarak uygun filtre kullanarak verilerdeki artefaktlar temizlendi. Daha sonra filtreli PPG'den HRV elde edildi. PPG'den 38 karakteristik, 29 istatistiksel ve HRV'den de 29 istatistiksel özellik çıkarıldı. Özellik sayısı yüksek tutularak sinyallerin daha iyi tanımlanması amaçlandı.

Temel Bileşen Analizi (PCA) yöntemi ile 96 özellikli veri tabanı 47 özelliğe %100 temsil edilebildi. Böylece boyut küçültme yapılabildi. Fisher özellik seçme algoritması kullanarak 47 özelliğin sonuç etiketi ile ilişki düzeyini ifade eden Fisher skorları hesaplatıldı. Fisher skorlarına göre özellikler en yüksekten düşüğe doğru sıralandı. En yüksek Fisher skoruna sahip özellikten başlanarak ve özellik sayısı birer artırılarak 47 farklı veri seti elde edildi. Veri setlerinde, destek vektör makinesi (SVM), k en yakın komşu (kNN), Ensemble ve Sinir Ağları (NN) olmak üzere 4 farklı makine öğrenmesi yöntemi ile sınıflandırma modelleri oluşturuldu. Minimum özellik sayısı ile yüksek performans sunan modelin tespit edilmesi amaçlandı. Modeller oluşturulurken 5-kat çapraz doğrulama ve hiperparametre optimizasyonu yapıldı. Modellerin sınıflandırma performansları doğruluk, duyarlılık, özgüllük, kesinlik, F-ölçümü, Kappa ve alıcı işletim karakteristiği (ROC) eğrisi altındaki alan (AUC) performans kriterleri ile değerlendirildi. Modellerde elde edilen performansların, kullanılan veri setindeki bireylerden bağımsız olup olmadığını gözlemlemek için Birini Dışarıda Bırak (LOO) yöntemi kullanıldı. Kontrol verileri içerisinde bulunan mikro uyarılma, RERA ve PLM uyarılma etiketlerinin bruksizm etiketlerinden ne kadar ayırt edilebildiğini görmek için ayrıca bruksizm - mikro uyarılma, bruksizm - RERA ve bruksizm - PLM uyarılma sınıflandırmaları da tasarlandı. Çalışmaya dahil edilen 17 bireyin; 12'si SA'lı ve 5'i Non-SA bireylerdi. SA ve Non-SA bireyler için ayrı ayrı bruksizm - kontrol sınıflandırması yaparak elde edilen performansın her ikisi için genellenebilir olup olmadığı gözlemlendi. Çalışmada tüm etiketlemeler, daha önce uyku laboratuvarında çalışmış, uyku evreleme (uyku - uyanık) ve bruksizm - uyarılma etiketlemeleri konusunda tecrübeli bir uzman hekim tarafından gerçekleştirildi. Etiketlemelerin birden fazla uzman tarafından değerlendirilmesi çalışmanın güvenilirliğini arttırabilir. Ayrıca makine öğrenimi modellerinin performansı, örneklem büyüklüğü arttıkça iyileşebilir. Daha büyük veri setleri modelin genelleme kabiliyetini artırabilir. LOO ve 5 kat çapraz doğrulama yaparak örneklem büyüklüğünün olumsuz etkileri en aza indirilmeye çalışıldı.

Bruksizmin kesin teşhisini mümkün kılan PSG, bruksizm dışında birçok uyku rahatsızlığı teşhisinde de altın standarttır. PSG ile teşhiste, bireyin vücuduna çok sayıda elektrot bağlı olarak uzman kontrolünde gece boyunca uyuması gerekir. Bireyin ev ortamında olmaması ve vücuduna çok sayıda elektrot bağlı olması nedeniyle uyku rahatsızlığı farklı karakter göstererek teşhiste hatalara sebep olabilir.

PSG uyku laboratuvarlarında bulunmaktadır. Uyku laboratuvar sayıları sınırlı ve laboratuvarlardaki yatak kapasiteleri düşüktür. Bu nedenle randevular ileri tarihlere verilmektedir. Ayrıca uyku laboratuvarları genellikle SA gibi hayati risk bulunduran rahatsızlıkların teşhisi için kullanıldığından, uyku bruksizm (SB)'li bireyler uyku laboratuvarlarına kesin teşhis için yönlendirilememektedir. Böylece bruksizimli bireyler, klinik muayene ve hasta öyküleri ile olası veya muhtemel teşhis almaktadırlar. Bruksizm, SA gibi hayati risk taşıyan bir uyku rahatsızlığı olmasa da, kişinin yaşam kalitesini ve sağlığını etkileyip, tedavi edilmediğinde uzun vadede fiziksel hasarların artmasına ve diğer hayati rahatsızlıkların tetiklenmesine sebep olabilir. Bu nedenle bruksizmin erken teşhis edilip bir an önce tedaviye başlanması önemlidir. Bruksizmin yüksek doğrulukla teşhisini mümkün kılan pratik sistemler geliştirmek, bruksizmin sebep olduğu dental veya genel sağlık sorunları ortaya çıkmadan teşhisini mümkün kılacak, bireylerin yaşam kalitesini artıracak ve sağlıkta fırsat eşitliğini mümkün hale getirecektir. Uyku rahatsızlıkları birbirlerini etkileyebilmektedir. Erken teşhis edilebilen bruksizm başka rahatsızlıkların da ortaya çıkmasını engelleyebilecektir. Tüm bunlar göz önüne alınarak bu tez çalışmasında, bruksizmi yüksek doğrulukla kesin teşhis etmeyi amaçlayan AI tabanlı bir model geliştirilmesi amaçlanmıştır. Bunun için bireye rahatsızlık vermeden vücuttan kolay elde edilebilen PPG kullanılmıştır. Birden fazla sinyal kullanımının sınıflandırma başarısını arttıracığı düşünülerek, elde edilmesi pratik olan PPG'den elde edilen HRV sinyali tercih edilmiştir. Böylece vücuttan alınan tek sinyal ile iki sinyalli teşhis modelleri geliştirilmesi mümkün olmuştur.

Literatürde bruksizm ile ilgili yapılan ilk çalışmalarda, bruksizm ve TME disfonksiyonu olan bireylerdeki diş temas sayıları incelenmiştir (Trenouth, 1979). Bunun için kesici dişlere paslanmaz çelik bantlar yerleştirilmiştir. Bu bantlar iletkenler ile osilatöre bağlanarak diş teması sırasında pals üretilmesi sağlanmıştır. Üretilen palsin sayısı ve süresi bilgisayarda hesaplatılarak diş temas sayısı ve süresi tespit edilmiştir. TME disfonksiyonu ve bruksizm olmayan bireyler kontrol grubunda değerlendirilmiştir. Hem TME disfonksiyonu hem de bruksizm bulunan bireylerde diş temas sayısında kontrol grubuna kıyasla anlamlı farklılık varken TME disfonksiyonu olup bruksizm olmayan bireylerde kontrol grubuna göre anlamlı farklılık görülmemiştir.

Bruksizmin stomatognatik sistem (baş, dişler, çeneler, TME, çiğneme ve yüz kasları, dil, dudak ve yanak, damar ve sinirlerin oluşturduğu bir bütün) üzerindeki etkisinin incelendiği bir çalışmada, PSG ile entegre edilmiş bir PIN fotodiyot sensör ve LED sırasıyla metal bağlantı ile üst ve alt kesici dişlere sabitlenmiştir (Amemori vd., 2001). Mandibular hareket, sıkma, gıcırdatma ve her ikisini içerecek şekilde kategorize edilmiştir. Bruksizimli deneklerde sıkma hareketi diğer hareketlere kıyasla daha sık gözlenirken, sıkma sırasındaki EMG aktivitelerinin gıcırdatmadan daha güçlü olduğu görülmüştür.

Kostka ve Tkacz (2015), masseter kasından elde ettikleri EMG, elektrokardiyogram (EKG)'dan elde ettikleri HRV ve EOG'yi kullanarak bruksizmin ev ortamında tespitine yönelik pilot bir çalışma yürütmüşlerdir. HRV için istatistiksel analiz yapmışlardır. EMG ve EOG'de de bruksizm atakları sırasında meydana gelen değişiklikleri incelemişlerdir. Bruksizm esnasında, 10 - 20 saniye boyunca EMG ve EOG genliğinde %40 veya daha fazla artış görülmüştür. Eşzamanlı olarak HRV'nin Düşük Frekans/Yüksek Frekans oranının son 10 dakikadaki ortalama değerinin %20-40'ı arasında monoton olarak arttığını ifade etmişlerdir (Kostka & Tkacz, 2015).

Maeda ve ark. (2020), SB'nin büyük bir bölümünü oluşturan ritmik çiğneme kası aktivitesi (RMMA)'nde çene kapatan ve çene açan kas aktivitelerinin genliklerini ve modellerini açıklığa kavuşturmak istemişlerdir. Bunun için bireylerin sakız çiğneme sırasında ki EMG aktivitelerini ve uyku sırasındaki RMMA aktivitelerini karşılaştırmışlardır. RMMA sırasındaki çene kapama kas aktivitesi sakız çiğneme sırasındaki aktiviteye yakınsa, çene açma kas aktivitesinin sakız çiğneme sırasındaki aktiviteden küçük olduğunu tespit etmişlerdir. Elde ettikleri sonuç, çene açma ve kapama kas aktivitelerinin eş kasılmalar olduğunu düşündükleri hipotezlerinin aksi olduğunu düşündürmüştür (Maeda vd., 2020).

AI'nın gelişmesiyle bruksizm teşhisinde de AI tabanlı çalışmalar yapılmaya başlanmıştır. Castroflorio ve ark. (2013), EMG ve EKG'yi kullanarak çok katmanlı NN modeli ile SB teşhis modeli geliştirmişlerdir. Yalnızca EMG kullanılarak oluşturulan AI tabanlı modelde sınıflandırma performansı düşükken; EMG ve EKG birlikte kullanılarak sınıflandırma performansı artırılmış ve %64 doğrulukla bruksizimli bireyler bruksizm olmayanlardan ayırt edilebilmiştir (Castroflorio vd., 2013). Lai ve ark. (2019) da EMG ve EKG'yi kullanarak karar ağaçları (DT) makine öğrenmesi modeli ile %97,21 doğrulukla SB tespit modeli geliştirmişlerdir. SB'li

bireylerde EMG ve EKG'nin güç spektral yoğunluklarının ortalama değerlerinin bruksizm olmayan bireylere kıyasla daha yüksek olduğunu gözlemlemişlerdir (Lai vd., 2019). Heyat ve ark. (2019) ise DT makine öğrenmesi modelinde EEG'yi kullanarak %81,7 doğrulukla SB tespit modeli geliştirmişlerdir (Heyat vd., 2019). Heyat ve ark. (2020), sonraki çalışmalarında EEG'ye EKG ve EMG'yi de ilave ederek hibrit makine öğrenmesi modeli ile SB teşhis doğruluğunu %94'e çıkarmışlardır (Bin Heyat vd., 2020). Martinot ve ark. (2020), yüzey EMG (sEMG)'yi kullanarak Evrimsel Sinir Ağları (CNN) ile SB'nin bir türü olan fazik bruksizmi mikro uyarılmalardan %94 ile ayırmışlardır (J. Martinot vd., 2020). Çalışmalarını ilerleterek Aşırı Gradyan Artırma Algoritması (XGB) ile fazik bruksizmi, mikro uyarılma ve RERA'dan %86 doğrulukla ayırt etmişlerdir (J.-B. Martinot vd., 2021). Sönmezocak ve Kurt (2021), masseter kas üzerine yerleştirilen sEMG elektrodu ile bireylere bruksizm durumlarını tanımlayan 4 çene hareketi (gevşek çene kası, sıkma, yorgunluk/ağrı ve gıcırdatma) yaptırmışlar ve EMG verilerini kaydetmişlerdir. EMG'den zaman ve frekans domeninde 13 özellik çıkarmışlardır. Bu özellikleri farklı sayılarda kullanarak çene hareketlerini 5 makine öğrenmesi yöntemi kullanarak sınıflandırmışlardır. En etkili sınıflandırma performansına (%98,8 doğruluk) yapay sinir ağları (ANN) algoritması ve beş özellik ile ulaşmışlardır (Sonmezocak & Kurt, 2021). Peruzzi ve ark. (2022), bruksizmle ilgili sesleri ayırt etmek için ses sinyallerini sınıflandıran bir Makine Öğrenmesi (ML) modeli tasarlamışlardır. CNN modeli ile bruksizmle ilişkili sesler %80, ilişkili olmayan sesler de %91,99 doğrulukla sınıflandırılmıştır (Peruzzi vd., 2022). Tiwari ve ark. (2024), PLM ve bruksizmin tanımlanması için EEG'den çıkarılan özelliklerle makine öğrenmesi yöntemleri (kNN, SVM, ANN) kullanarak sınıflandırma modeli tasarlamışlardır. SVM algoritması ile bruksizmi %94,74 doğrulukla sınıflandırmışlardır (Tiwari vd., 2024). Orhan ve ark. (2024), masseter kası üzerinde USG görüntüleme yaparak SVM algoritmasıyla bruksizmi normal deneklerden 0,848 AUC değerinde ayırt etmişlerdir (Orhan vd., 2024). Tripathi ve ark. (2024), bruksizmi biyolojik sinyallerden teşhis etmek için hibrit makine öğrenimi sınıflandırıcısı kullanmışlardır. EEG ile %95, EKG ile %96 doğrulukla, EMG, EKG ve EEG'yi birlikte kullanarak ise %99 doğrulukla sınıflandırma başarısı elde etmişlerdir (Tripathi vd., 2024).

Taşınabilir sensörler ve ağız içi aparatların bruksizm teşhisi için kullanıldığı çalışmalar da mevcuttur. McAuliffe ve ark. (2015), ev ortamında bruksizm olaylarını kaydetmek

için kullanılabilecek bir cihazı klinik olarak test etmek istemişlerdir. Oklüzal splint yüzeyinin altında kullanılacak basınç sensörleri geliştirmişler ve sensörden gelen bilgileri kablosuz iletmek ve bilgisayara kaydetmek için devre tasarlamışlardır. Bruksizm ve bruksizm olmayan örüntüleri simüle etmek için bireylere kontrollü alt çene hareketleri yaptırmışlardır. Örüntüler iki uzmana grafiksel sunulmuş, uzmanlar bruksizmi %80 ile %100 arasında duyarlılık ve %75 ile %100 arasında özgüllükle ayırt etmişlerdir. Bu sonuçlara göre oklüzal splintteki sensörleri kullanarak, SB’de görülen tipik diş temas desenlerini tanımanın mümkün olduğunu belirtmişlerdir (McAuliffe vd., 2015). Ağız içi sensörler AI tabanlı sistemlerle birlikte kullanılarak bruksizmin teşhis edildiği çalışmalar da mevcuttur. Gao ve ark. (2019), bruksizmin tanısı ve tedavisi için AI algoritmalarına dayalı geri besleme algılama cihazını araştırmışlardır. Basınç sensörünü, oklüzyon stabilizasyon atelinin içine entegre etmişlerdir. Sensörden alınan verileri işlemek ve yapılandırmak için makine öğrenimi algoritması kullanmışlardır. Sensörün ve tasarımın, bireyin diş sıkma veya gıcırdatma değişikliklerini izlemeye umut verici bir cihaz olacağını belirtmişlerdir (Gao vd., 2019). O’Hare ve ark. (2022), üst azı dişlerine basınç sensörü yerleştirerek, sensörden alınan basınç verilerini bruksizm veya bruksizm olmayan olarak sınıflandırmak için doğrusal ayırıcı analizi (LDA) yapmışlardır. Bruksizmi %82,2 doğrulukla sınıflandırmışlardır (O’Hare vd., 2022).

Bruksizm teşhisine yönelik yapılan çalışmalar incelendiğinde çeşitli fizyolojik sinyallerin veya ağız içi sensörlerin kullanıldığı görülmektedir. Bunların bazıları makine öğrenmesi algoritmalarıyla desteklenerek güvenilirliği artırılmıştır. Bu tez çalışması ile ilk defa bruksizm teşhisinde PPG kullanılmıştır. PPG’nin elde edilme avantajı ve AI ile desteklenen bu çalışma, bruksizmin pratik ve güvenilir teşhisi için uygun bir model önermektedir. Literatürdeki çalışmaların büyük bölümünde bruksizmin bruksizm olmayan verilerden yüksek performans ile ayırt edilebildiği ifade edilmektedir. Ancak bruksizm olmayan verilerin hangi verileri içerdiğine dair net bilgiler yoktur. Bruksizmin hangi verilerden ayırt edildiği önemlidir. Kontrol verisine eklenecek farklı özellikteki veriler performans sonuçlarını değiştirebilir. Ayrıca kontrol verileri içerisindeki farklı özelliklerdeki verilerin her birinin bruksizmden ne kadar iyi ayırt edildiği önemlidir. Kontrol verisi içerisinde yer alan belli özellikteki bir veri bruksizmden çok iyi performansla ayırt edilebilirken, başka özellikli bir veri iyi olmayan bir performans ile ayırt edilebilir. Kontrol verilerini net bir şekilde

belirlemez ya da kontrol verileri içerisinde yer alan farklı özelliklerdeki veriler için sınıflandırma performansını incelemek, genel performansı olduğundan farklı gösterebilir. Bu çalışmada kullanılan kontrol verileri içerisinde üç farklı özellikli veri mevcuttur. Bruksizm kontrol verilerinden başarılı olarak ayırt edilebilmiştir. Bruksizm kontrol etiketindeki üç farklı uyarılma ile ayrı ayrı sınıflandırılarak elde edilen performansın üç etiket için de genellenebilir olduğu görülmüştür.

Literatürde yapılan çalışmalar, bruksizm sırasında EKG ve HRV'nin değiştiğini göstermektedir (Kostka & Tkacz, 2015; Lai vd., 2019; Lu vd., 2021; Macaluso vd., 1998). PPG, kılcal damarlardaki hacimsel değişikliklerin ölçülmesiyle elde edilir. Bu değişiklikler kalbin çalışmasına bağlı olduğundan, PPG'nin karakteristik yapısı aynı zamanda kardiyak aktiviteyi de yansıtır (Liang vd., 2018a). Bu nedenle, bruksizm sırasında kalbin elektriksel aktivitesinden kaynaklanan EKG ve HRV'deki değişiklikler PPG'de de gözlemlenebilir.

Bruksizm sırasında EMG'de de değişiklikler olduğu (Amemori vd., 2001; Kostka & Tkacz, 2015; Lai vd., 2019) ve PPG'nin karakteristik yapısının EMG'ye bağlı olarak değiştiği (Okamoto & Murao, 2023) bilinmektedir. Bu nedenle, bruksizm sırasında EMG'deki değişiklikler PPG'de de gözlemlenebilir.

EKG, EMG, EEG ve EOG bireylerin baş, bacak, göğüs, karın gibi bölgelerine elektrotlar yerleştirilerek elde edilir. Bruksizmin kesin teşhisinde kullanılan PSG cihazı da birçok fizyolojik sinyali eş zamanlı olarak elektrotlar aracılığıyla toplar ve kaydeder. PPG vücuttan kolaylıkla ve noninvaziv olarak elde edilebilir. Bu özelliği ile diğer fizyolojik sinyallerin elde edilmesinde kullanılan elektrotların; bağlantılarının uzman gerektirmesi, kablo karmaşıklığının olması ve bireye rahatsızlık vermesi gibi dezavantajlarının üstesinden gelebilir.

PSG ile teşhiste birey uzman kontrolünde uyur. Bireyden toplanan fizyolojik veriler yine uzman hekim tarafından değerlendirilerek teşhis konur. Maliyetlidir ve zaman alır. Yoğun iş temposunda çalışan hekimlerden aynı zamanda bu verileri kısa sürede değerlendirmesi beklenmektedir. Bu nedenle PSG kayıtlarının değerlendirilmesinde insan kaynaklı hatalar olabilir. AI ile desteklenen modeller hızlı ve güvenilir teşhisi mümkün kılar.

Birden fazla sinyal kullanımı sınıflandırma başarı oranlarını artırabilmektedir (Bin Heyat vd., 2020; Castroflorio vd., 2013; Lai vd., 2019). Bu çalışmada, PPG ve

PPG'den elde edilen HRV kullanılmıřtır. HRV, PPG'den elde edildiđi iin ekstra bir elektrot bađlantısı gerektirmez. Hem sınıflandırma başarısını artırmak hem de elde edilme ve kullanım kolaylıđı avantajları nedeniyle ikinci sinyal olarak PPG'den elde edilen HRV kullanılmıřtır.

Bruksizm sırasında fizyolojik sinyallerde meydana gelen deđiřikliklerin PPG'de de görülebileceđini destekleyen alıřmalar, PPG'nin ve PPG'den elde edilen HRV'nin sahip olduđu avantajlar, AI sistemlerinin güvenilirliđi ve gömülü sistemlere entegrasyonunun kolaylıđı nedenleriyle bu alıřmada PPG ve HRV'den AI destekli bruksizm teřhis modeli geliřtirilebileceđi düşünölmüřtür.





2. BRUKSİZM

2.1. Tanımı

Bruksizm, dişlerin sıkılması veya gıcırdatılması ve/veya alt çenenin gerilmesi veya ileri itilmesiyle karakterize tekrarlayan çene kası aktivitesi olarak tanımlanmıştır (Lobbezoo vd., 2013). Uluslararası Uyku Bozuklukları Sınıflandırması'nın (ICSD) üçüncü baskısında hareket bozukluğu grubunda yer almaktadır (Sateia, 2014). Bruksizm uyku esnasında ya da uyanırken gerçekleşebilir. Uyku esnasında olan bruksizm birey tarafından bilinmezken, uyanık bruksizm bilinçsiz ya da bilinçli ortaya çıkabilir (Beddis vd., 2018).

Bruksizm tanımındaki destekleme ve itme terimlerini açıklığa kavuşturmak, uyku ve uyanık bruksizm kavramlarının farklı olması nedeniyle ayrı ayrı tanımlamak ve bruksizmin bir bozukluk olup olmadığını belirlemek için Mart 2017'de uluslararası bruksizm uzman grubu bir araya geldi. Diş sıkma ve gıcırdatma, diş araştırmacıları ve klinisyenler tarafından bilinen olgular olsa da alt çenenin desteklenmesi ve itilmesi daha fazla açıklamaya ihtiyaç duyuyordu. Destekleme belirli bir alt çene pozisyonunu kuvvetlice korumak, itme ise alt çeneyi ileri veya yanal yönde kuvvetlice hareket ettirmek olduğundan; her iki aktivite de diş teması olmadan gerçekleşir. Klasik aktivitelere (diş sıkma ve gıcırdatma) ek olarak bruksizmin diş temasından daha fazlasını içerebileceği yönünde fikir birliğine varıldı. Uyku ve uyanık bruksizm ayrı ayrı tanımlandı. Buna göre; SB, “uyku sırasında görülen, sağlıklı bireylerde hareket veya uyku bozukluğu olmayan, ritmik (fazik) veya ritmik olmayan (tonik) çiğneme kası aktivitesi” ve uyanık bruksizm, “uyanırken görülen, sağlıklı bireylerde hareket bozukluğu olmayan, ritmik veya ritmik olmayan diş teması ve/veya alt çenenin öne veya arkaya doğru itilmesi ile karakterize çiğneme kası aktivitesi” olarak tanımlanmıştır (Lobbezoo vd., 2018).

2.2. Etiyolojisi

Bruksizm etiyojisi ok fakt6rl6d6r. Genel olarak psikososyal (stres, anksiyete vb.), fizyolojik (genetik) ve dıřsal (ila, sigara, alkol kullanımı vb.) fakt6rler olarak 3 grupta toplanabilir (Melo vd., 2019).

Stres kas gerginliđine sebep olduđundan, uzun s6reli stres, masseter ve temporalis gibi iđneme kaslarının da gerginliđini artırabilir. Tıp ve diř hekimliđi 6đrencilerinde stres ile bruksizm iliřkisini inceleyen bir alıřmada, stresin bruksizm geliřtirme riskini 6nemli 6l6de artırdıđı g6r6lm6řt6r (Babayiđit vd., 2024). Bruksizmle iliřkili n6rolojik ve psikiyatrik bozukluklar arasında; anksiyete, Alzheimer hastalıđı, Huntington hastalıđı, oklu sistem atrofisi, travmatik beyin hasarı, Down sendromu, Rett sendromu, serebral palsy ve dikkat eksikliđi yer almaktadır (Lal vd., 2025). Ergenlerde ortodontik tedavi gereksinimi, anksiyete ve SB arasındaki iliřkinin incelendiđi bir alıřmada, 12 yařına kadar olan ve orta veya řiddetli ortodontik tedaviye ihtiya duyan kız ergenlerin kaygı d6zeylerinin daha y6ksek olduđu ve buna bađlı SB g6r6lme olasılıđının y6kseldiđi bildirilmiřtir (Martins vd., 2024).

Bruksizm etiyojisi 6zerinde genetik fakt6rlerin etkili olduđu ve yetiřkinlerde genetik fakt6rlerin bruksizm geliřimine %38,9 ile %53,2 arasında katkı sađladıđı bildirilmiřtir (Hublin vd., 1998; Rintakoski vd., 2012; Takaoka vd., 2017). Tek ve ift yumurta ikizleri ile SB arasındaki iliřkinin sistematik olarak incelendiđi alıřmada, tek yumurta ikizlerinde SB g6r6lme olasılıđının ift yumurta ikizlerine kıyasla daha y6ksek olduđu ifade edilmiřtir (Pereira vd., 2024). Bu da SB'nin ortaya ıkmasında genetik fakt6r6n etkili olduđunu g6stermektedir.

Sigara ve alkol kullanımı, kafein t6ketimi, ila kullanımı gibi dıřsal fakt6rlerin de bruksizm ile iliřkili risk fakt6rleri olduđu bilinmektedir. 17-60 yař aralıđındaki 400 yetiřkin bireyle yapılan alıřmada, bruksizimli bireylerde antidepresan kullanımı ve sigara t6ketimi kontrol grubuna g6re anlamlı d6zeyde y6ksek bulunmuřtur (EniNan, 2023). 1930-1957 yılları arasında dođan 12502 ikiz bireyle yapılan bařka bir alıřmada ise alkol kullanımı ve kahve t6ketiminin bruksizm ile bađımsız bir iliřkisi olduđunu destekleyen sonular elde edilmiřtir (Rintakoski & Kaprio, 2013).

2.3. Epidemiyolojisi

Bruksizmin belirli nüfus düzeylerinde yaygınlık tespitini yapmak zordur. Çalışmalar genellikle öz bildirime veya klinik değerlendirmelere dayanmaktadır. Kesin teşhisi mümkün kılan PSG kayıtları ile yapılan çalışmalar sınırlıdır (Khoury vd., 2016). Tek gecelik araştırmalar da bruksizm'in zamanla değişen durumu hakkında bilgi vermemektedir (Manfredini vd., 2019). Bu nedenle epidemiyolojisi hakkında kesin bir şey söylemek zordur.

Bruksizmin küresel yaygınlığı hakkında yakın zamanda yapılan sistematik inceleme ve meta-analizde, SB yaygınlığı %21, uyanık bruksizmin yaygınlığı %23 ve bruksizmin (uyku ve uyanık) genel yaygınlığı %22,22 olarak bildirilmiştir (Zieliński vd., 2024).

Bruksizm her yaştan bireyde görülebilmektedir. Ancak bruksizm yaş arttıkça azaldığı belirtilmiştir (Khoury vd., 2016; Lavigne & Montplaisir, 1994; Maluly vd., 2013). Kadınlarda bruksizm görülme olasılığının erkeklere göre daha yaygın olduğu bildirilmektedir (Kato vd., 2003; Wetselaar vd., 2019).

2.4. Teşhisi

Uluslararası bruksizm uzman grubunun oluşturduğu konsensusda bruksizm olası, muhtemel ve kesin olarak derecelendirilmiştir (Lobbezoo vd., 2013). Olası bruksizm teşhisi, anamnez ya da anket yoluyla bireyden elde edilen bildirimlerle konulur. Muhtemel bruksizm teşhisi, olası bruksizm teşhisine ek olarak klinik muayene bulguları da gerektirir. Kesin bruksizm teşhisi ise, muhtemel bruksizm teşhisi sonrasında PSG adı verilen cihazlar kullanılarak yapılır. PSG cihazının aynı zamanda ses ve görüntü kaydı içermesi tercih edilmektedir (Lobbezoo vd., 2013, 2018).

Anketler, bruksizmin olası nedenleri ve sonuçları hakkında bilgi toplamak açısından önemlidir (Lobbezoo vd., 2012). Bruksizm teşhisinde kullanılan anketler, bruksizmin türü, etiyojisi, risk faktörleri, semptomları, tedavi ve teşhis yöntemleri gibi bruksizm hakkında genel sorular içerir (Bahammam, 2022; Şahin, 2024; Uma vd., 2024). Anketler, hekimlerin muayene öncesinde fikir edinmesini sağlarken hastaların da bruksizm farkındalıklarının artmasını sağlar (Lobbezoo vd., 2012). Büyük popülasyonlara kolaylıkla uygulanabilmesine rağmen anketlere verilen cevaplar

subjektifdir. Bruksizm sadece diş gıcırdatma olmadığından bruksizm farkındalığı düşük olan bireylere uygulanan anketler doğru sonuçlar vermeyebilir.

Bruksizimli bireylerde, çene kaslarında ağrı, temporomandibular ağrı ve bozukluklar, baş, omuz ve boyun ağrıları görülür (Baad-Hansen vd., 2019; Da Silva vd., 2017). Ayrıca diş aşınması, diş kırılması, kas hipertrofisi, açık deviasyon, dil ısırığı gibi ağız içi klinik bulgular da görülmektedir (Baad-Hansen vd., 2019; Melo vd., 2019). Çocuklarla yapılan bir çalışmada, çiğneme sisteminin klinik belirti ve semptomlarının SB ile ilişkisi incelenmiştir. En sık görülen klinik belirti ve semptomların, birincil köpek dişi aşınması, diş aşınması ve baş ağrısı olduğu bildirilmiştir (Soares vd., 2021).

Bruksizmin kesin teşhisini mümkün kılan PSG'ler uyku laboratuvarlarında bulunmaktadır. Kaslar, gözler, beyin ve kalp gibi birçok noktadan sinyalleri elektrotlar aracılığıyla toplayan PSG, gece boyunca bu verileri kaydeder. Aynı zamanda ses ve görüntü kaydı da almaktadır (Yanez-Regonesi vd., 2023). Böylece orofasiyel hareketler (konuşma, öksürme, yutkunma vb.) ile bruksizm hareketlerinin ayırt edilmesine yardımcı olur. Uzman kontrolünde kaydedilen veriler daha sonra yine uzman tarafından AASM kriterlerine göre değerlendirilir (Berry vd., 2017). PSG kullanımının maliyetli olması sebebiyle, PSG genellikle SA gibi hayati risk taşıyan uyku rahatsızlıklarının teşhisinde kullanılmaktadır (Miettinen vd., 2018). Bruksizimli bireyler PSG'ye yönlendirilememekte ve bruksizm teşhisi genellikle olası veya muhtemel olarak konulmaktadır. Bu nedenle PSG'ye alternatif, pratik ve güvenilir bruksizm teşhis sistemlerinin geliştirilmesi önemlidir.

2.5. Tedavisi

Bruksizmin etiyolojisi çok faktörlü olduğundan tedavi yaklaşımları değişkenlik göstermektedir. Farmakoterapi, fizyoterapi, botoks ve oklüzal splinti gibi farklı tedavi yöntemlerinden bir veya daha fazlası tercih edilebilir (Beddis vd., 2018; Guaita & Högl, 2016; Manfredini vd., 2020).

Genellikle gece koruyucuları olan oklüzal splintler, koruyucu bariyerler olarak işlev gören diş aletleridir. Uyku esnasında dişlerin birbirine temasını engelleyerek diş hasarı, temporomandibular bozukluklar gibi bruksizmin zararlı etkilerini en aza indirir (Ainoosah vd., 2024).

Bruksizm risk faktörleri arasında yer alan stres ve anksiyeteyi düşürmek için kas gevşetici, antidepresan gibi ilaçlar (Beddis vd., 2018) ve botoks (Kün-Darbois vd., 2015) kullanılmaktadır. Ancak sitalopram, paroksetin, fluoksetin ve venlafaksin gibi antidepresanların bruksizme sebebiyet verdiği bildirilmiştir (Bulanda vd., 2021).

Fizyoterapi ile bruksizm tedavisine yönelik çalışmalar incelendiğinde; kinezyolojik bantlama, kuru iğneleme, düşük seviyeli lazer tedavisi, masaj terapisi, elektriksel uyarm, egzersizler ve gevşeme tekniklerinin bruksizm ağrısını ve bruksizm kaynaklı kas aktivitelerini azalttığı bildirilmiştir (Savla vd., 2021).






3. PPG VE HRV

3.1. PPG

PPG, insan vücut kompozisyonunun yansıma ve iletim özellikleri gibi optik özelliklere dayalı olarak kan hacmi değişimlerini ölçmek için kullanılan invaziv olmayan bir yöntemdir (Park vd., 2022). PPG ölçümünde bir ışık kaynağı ve bir fotodedektör kullanılır. Işık kaynağı ve fotodedektör yanyana ya da ölçülecek bölge arada kalacak şekilde karşılıklı yerleştirilir. Karşılıklı yerleştirmede ışığın vücuttan iletimi, yanyana yerleşimde ışığın vücuttan yansıma özelliği kullanılır. Şekil 3.1, PPG ölçümü için iletim ve yansıma modunu göstermektedir. Işığın dalga boyu arttıkça, penetrasyon derinliği de artar (Ruggiero vd., 2016). 660 nm veya daha yüksek dalga boylarının deri altı dokuların arterlerine ulaşabileceği bilinmektedir (Liu vd., 2019). PPG ölçümü için genellikle 640-660 nm kırmızı dalga boyuna ve 880-940 nm kızılötesi dalga boyuna sahip ışık kullanılır (Jones, 1987).




Şekil 3.1. PPG ölçümü a) İletim modu b) Yansıma modu (Park vd., 2022).

PPG dalga formu Şekil 3.2’de görülmektedir. PPG, pulsatil ve pulsatil olmayan iki bileşene sahiptir (Lee vd., 2011). Alternatif akım (AC) bileşeni olarak bilinen pulsatil bileşen, atardamardaki kan hacmindeki değişikliklerle ilgilidir ve kalp döngüsü ile senkronizedir. Doğru akım (DC) bileşeni olarak bilinen nabızsız bileşen, deri, kas ve kemik gibi sabit yansıtıcı maddelerden ve venöz kandan kaynaklanan bileşenleri ifade eder. PPG, kardiyak kasılmaya bağlı kılcıl kan hacmindeki artışa göre artan bir eğriye (sistolik faz), kardiyak genişlemeye bağlı kılcıl kan hacmindeki azalmaya göre ise azalan bir eğriye (diyastolik faz) sahiptir. Kardiyak aktiviteye göre tekrarlanır (Park vd., 2022). Sistolik fazda kan hacmi, arter çapı ve hemoglobin konsantrasyonu arttığından ışığın emilimi artarken, fotodedektörün algıladığı ışık yoğunluğu azalır.

Diyastolik fazda ise ışığın Emilimi azalırken fotodedektörün algıladığı ışık yoğunluğu artar. Fotodedektör ile toplanan ışık sinyalleri elektrik sinyaline dönüştürülür. Böylece kan hacmindeki değişikliklere bağlı PPG elde edilir (Ding vd., 2017).

Kan hacminin en düşük olduğu nabızın başladığı nokta PPG başlangıcı, kan hacminin en yüksek olduğu nokta da sistolik tepe olarak tanımlanır. Diyastol sırasında PPG dalga formunun geçici yükselmesi ve alçalması, kılcal damarlardaki kan hacminin geçici olarak tekrar artmasıyla meydana gelir. Bu sırada, girintili nokta dikrotik çentik olarak tanımlanır ve sistolik tepeden sonra dalga formunun birinci türevinin sıfıra en yakın olduğu nokta diyastolik tepe olarak tanımlanır (Millasseau vd., 2002; Park vd., 2022).



Şekil 3.2. PPG dalga formu.

PPG ölçümleri alın, ayak parmakları ve bilek gibi farklı vücut bölgelerinden alınabilmekle birlikte, sıklıkla kulak memesi ve parmak uçları gibi uç noktalardan yapılır. Bu bölgeler, damar yatağının sık ve geniş alana yayılması nedeniyle kan hacmindeki değişimleri ölçmek için elverişlidir (Millasseau vd., 2006).


3.2. PPG'nin Filtrelenmesi

PPG kaydı sırasında, elektrik şebekesi frekansı, kullanılan elektronik cihazlar ve hareket gibi faktörlerden kaynaklanan gürültüler sinyale karışmaktadır. Fizyolojik parametrelerin ve teşhis sistemlerinin doğru bir şekilde değerlendirilmesi için bu bilgilerin sinyalden arındırılması gerekir (Elgendi, 2016).

PPG, sabit bir DC bileşen ile zamana bağlı değişim gösteren bir AC bileşen içerir. Kardiyak aktiviteye özgü bilgi AC bileşende yer aldığından, analizlerde yalnızca bu

bileşen kullanıldı. Bu doğrultuda, sinyalin ortalama değeri hesaplandı ve bu değer sinyalden çıkarılarak yalnızca AC bileşene sahip PPG elde edildi.

PPG'nin hızlı Fourier dönüşümü (FFT) alınıp, periyodogram grafiği analiz edildiğinde, 20 Hz'e kadar bilgi taşıdığı görülür (Melekoglu vd., 2022). Bu çalışmada PPG'yi filtrelemek için 20 Hz kesim frekansına sahip çeşitli alçak geçiren sayısal filtreler tasarlandı. Filtre tasarımı MATLAB'de "fdatool" aracı kullanılarak gerçekleştirildi. Her filtre için performans analizleri yapıldı ve sonuçları karşılaştırıldı. Performans sonuçlarına göre Chebyshev tip II alçak geçiren filtre kullanılmasına karar verildi (Eriş vd., 2021). Chebyshev tip II filtresi, geçiş bandında dik bir iniş ile frekans geçişlerine hızlı yanıt verip, düz bir geçiş bandı ile istenen bilgiler için daha iyi koruma sağlar. Bu özellikleri nedeniyle PPG kullanılarak yapılan çalışmalarda da sıklıkla tercih edilmektedir (M. R. Bozkurt vd., 2019; Kavas vd., 2022; Melekoglu vd., 2022). PPG için en uygun filtrenin araştırıldığı başka bir çalışmada da dokuz tip sayısal filtre kullanılmış ve Chebyshev tip II filtresinin, PPG kalitesini diğer filtre tiplerine göre daha etkili bir şekilde iyileştirdiği gözlemlenmiştir (Liang vd., 2018b). Sinyaldeki küçük genlik dalgalanmaları tepe noktalarının yanlış algılanmasına neden olabilir (D. Han vd., 2022). Bu nedenle Chebyshev tip II alçak geçiren filtre çıkışındaki sinyal hareketli ortalama filtresinden geçirilmiştir. Şekil 3.3'te, filtrelenmemiş ve kullanılan filtrelerin çıkışlarındaki PPG'ler görülmektedir.




Şekil 3.3. PPG a) Filtrelenmemiş b) Chebyshev tip II alçak geçiren filtre çıkışı c) Hareketli ortalama filtre çıkışı.

3.3. PPG'den HRV'nin Elde Edilmesi

HRV, kalp atışları arasındaki zamanın değişimini gösteren bir parametredir. İç ve dış tetikleyicilere (stres, dinlenme, rahatlama, uyku vb.) bağlı olarak otonom sinir sistemi tarafından değiştirilir (Lundell & Ojanen, 2023). Çeşitli bozukluklar hakkında bilgi sağlar. EKG veya PPG'den elde edilebilir (Jeyhani vd., 2015; Kavas vd., 2022).

PPG'den elde edilen HRV, Şekil 3.4'te görülmektedir. İlk olarak PPG'nin tepe noktaları belirlenmiştir. HRV'yi oluşturan noktaların hesaplanmasını sağlayan eşitlik ve ilk HRV noktasının hesaplanması Denklem 3.1'de gösterilmiştir. A(i) HRV'yi oluşturan noktalar, N(i) PPG'nin zirveye ulaştığı örnek sayısını gösterir. A(i) noktalarını hesaplamak için iki tepe noktası arasındaki örnek sayısı PPG'nin örnekleme frekansına (128 Hz) bölünür. HRV noktalarının sayısı PPG tepe noktalarının sayısından bir eksiktir.

$$A(i) = \frac{N_{i+1} - N_i}{f_s} \rightarrow A(1) = \frac{N_2 - N_1}{f_s} = \frac{182 - 62}{128} = 0,9375 \text{ saniye} \quad (3.1)$$



Şekil 3.4. PPG'den HRV'nin elde edilmesi a) PPG'de sistolik tepe noktalarının tespiti b) PPG sistolik tepe noktalarından HRV elde edilmesi.

4. KULLANILAN VERİ SETİ

4.1. Çalışmanın Konusu ve Verilerin Toplanması

Bruksizmi kesin olarak teşhis etmek için PSG kullanılmalıdır. PSG, maliyetli tanı süreci nedeniyle genellikle SA gibi yaşamı tehdit eden uyku bozukluklarının teşhisinde kullanılır. Bu nedenle bireyler bruksizmin kesin tanısı için uyku laboratuvarlarına sevk edilememektedir (Miettinen vd., 2018; Yap & Chua, 2016). Dolayısıyla, bruksizm olası ya da muhtemel olarak teşhis edilmektedir. Ayrıca bruksizmin, uyku bozukluğu olan bireylerde olmayanlara göre daha yaygın olduğu bilinmektedir (Da Costa Lopes vd., 2020; Maluly vd., 2020; Tan vd., 2019). Bu nedenle bu çalışmada kullanılan veriler, SA şüphesi ile uyku laboratuvarına yatan bireylerin PSG kayıtlarının incelenmesi ile elde edildi. Çalışmaya PSG sonucunda SA teşhisi almış 12 birey ve SA olmayan (non-SA) 5 birey olmak üzere toplam 17 birey dahil edildi.

Veriler Sakarya Hendek Devlet Hastanesi Göğüs Hastalıkları Uyku Laboratuvarı kayıtlarından elde edildi. Veri tabanındaki kayıtlar retrospektif olarak analiz edildi ve değerlendirildi. Çalışmanın yürütülmesi için Türkiye Cumhuriyeti Sakarya Üniversitesi Rektörlüğü Fen ve Mühendislik Bilimleri Etik Kurulu'ndan E-61923333-050.99-162384 sayılı etik kurul raporu ve Türkiye Cumhuriyeti Sakarya Valiliği İl Sağlık Müdürlüğü'nden E-18343338-604.01.99 sayılı veri kullanım izni alındı.

Çalışmada 2013 yılına ait veriler kullanıldı. Veri tabanındaki bireylerin demografik bilgileri Tablo 4.1'de görülmektedir.


Tablo 4.1. Çalışmadaki bireylerin demografik bilgileri.

Özellikler	Kadın n ₁ =2	Erkek n ₂ =15	Tümü n=n ₁ +n ₂ =17
Yaş (yıl)	63±4,9	55,5±22,5	55,9±20,1
Kilo (kg)	94±15,56	100,4±31,4	99,6±30,4
Boy (cm)	160±0	173,5±6,5	171,9±11,9
Vücut Kitle İndeksi (BMI) (kg/m ²)	36,7±6,08	33,3±9,7	33,7±10,1

Veriler SOMNOscreen Plus PSG cihazı ile elde edildi. Bu cihaz 33 kanal veriyi kaydetmektedir. Çalışma PPG ile bruksizm tespiti olduğundan, PSG cihazından sadece etiketlenen verilere ait PPG kayıtları alındı. PPG kayıtları, parmak ucundan ve 128 Hz örnekleme frekansı ile elde edildi. Veriler, Domino versiyon 3.0.0.3 yazılımı kullanılarak analiz edildi.

4.2. Verisetinin Elde Edilmesi

Verisetinin elde edilmesi, uyku evreleme ve veri etiketleme olmak üzere iki aşamadan oluşmaktadır. Tüm uyku evrelemeleri ve etiketlemeleri, uyku bozuklukları konusunda deneyimli, daha önce uyku laboratuvarında çalışmış ve uyku kayıtlarının incelendiği Domino versiyon 3.0.0.3 yazılımını kullanmış olan uzman hekim tarafından yapıldı. Veri setinin elde edilmesine ait akış şeması Şekil 4.1’de görülmektedir.




Şekil 4.1. Verisetinin elde edilmesi.

4.2.1. Uyku evreleme

Uyku esnasında gerçekleşen bruksizm aktivitesinin belirlenebilmesi için öncelikle uyku evreleme yapıldı. Çalışmada kullanılan Domino versiyon 3.0.0.3 yazılımı, PSG kayıtlarını 30 saniyelik epok adı verilen bölümlere ayırmaktadır. AASM kriterlerine


göre, uyku evreleme ve uyarılmalar için üç tip elektrofizyolojik sinyal kullanılmalıdır (Berry vd., 2017; Iber vd., 2007). Bunun için en az üç kafa derisi EEG elektrodu, gözlerin her iki tarafına yerleştirilmiş iki elektrookülografi elektrodu ve çenenin üstüne ve altına yerleştirilmiş iki çene elektromiyografi elektrodu ile çenenin altına yerleştirilmiş üçüncü bir elektrot gerekir. 10-20 uluslararası sistemine göre, EEG elektrotları, santral (C3 ve/veya C4), frontal (F3 ve/veya F4), ve oksipital (O1 ve/veya O2) bölgelere yerleştirilir. Referans için mastoid bölgeler (M1-M2 ya da A1-A2) kullanılır. EOG elektrotları için de aynı mastoid bölgeler referans olarak kullanılır. Çene EMG, iki çene EMG elektrodu arasında bipolar bir kanal olup referans gerektirmez (Lambert & Peter-Derex, 2023). Şekil 4.2, uyku evreleme için EEG, EOG ve çene EMG elektrotlarının yerleşimini göstermektedir.



Şekil 4.2. Uyku evrelemede elektrotların yerleşimi a) EEG b) EOG ve c) Çene EMG (Shriram vd., 2013).

Her epok, EMG, EOG ve EEG'nin özellikleri dikkate alınarak uyanık (W), Evre 1 (N1), Evre 2 (N2), Evre 3 (N3) veya hızlı göz hareketi (REM) olarak etiketlenir. N1, N2 ve N3 uyku evreleri REM olmayan uyku evresi olarak da adlandırılır. Şekil 4.3, uyku evrelerine göre EEG, EOG ve EMG'yi göstermektedir.

EEG'de uyanık durumda alfa (8-13 Hz) ve beta (>13 Hz) dalgaları, N1 uyku evresinde teta (4-7 Hz) dalgası, N2 ve REM uyku evresinde ise teta ve alfa dalgaları, N3 uyku evresinde delta (<4 Hz) dalgaları görülür. N2 uyku evresinde uyku içcikleri (0,5 saniyeden daha fazla süren 12-14 Hz'lik aktiviteler) ve K kompleksi (0,5 saniyeden daha fazla süren EEG'de önce yukarı sonra aşağı bifazik dalgalar) EEG paternleri gözlemlenir (Lambert & Peter-Derex, 2023; Uçar, 2017). EEG'nin frekansı genel olarak, uyanık evrede uyku evrelerine göre daha yüksektir. Sadece N2 evrede, görülebilen uyku içcikleri nedeniyle diğer REM olmayan uyku evrelerine kıyasla daha yüksek frekanslı EEG dalgaları görülebilir.



Şekil 4.3. Uyku evrelerine göre EEG, EOG ve EMG (Fröhlich, 2016).

EOG’de uyanık evrede 0,5-2 Hz civarı düşük göz hareketleri gözlemlenir. N1 evrede yavaş göz hareketleri gözlenir. N2 evrede bazen yavaş göz hareketleri görülürken bazen hiç göz hareketi görülmez. N3 evrede genellikle göz hareketleri görülmez. REM uykuda ise hızlı göz hareketleri görülür (Uçar, 2017).

EOG’de N2 ve N3 evrede dalgalanmanın az olduğu görülürken en yüksek dalgalanmanın REM evrede olduğu görülmektedir. EMG’de ise en yüksek tonusa uyanıkken sahip olup, uyku durumunda ise N1’den REM evreye doğru giderek düşen tonus dikkat çekmektedir (Şekil 4.3).

Bir epok içerisinde birden fazla uyku evresine ait elektrofizyolojik özellikler görülebilir. Bu durumda epoğun %50'sinden fazlası (15 saniye) hangi evreye ait özellik gösteriyorsa, epok o evre olarak etiketlenir (Lambert & Peter-Derex, 2023; Uçar, 2017).


Çalışmadaki bireylere ait uyku evre sayıları Tablo 4.2’de görülmektedir. SB çalışıldığından uyku evreleme sonucunda uyanık evreler atıldı. Tüm uyku evreleri “uyku” etiketi altında birleştirildi. Bruksizm ve kontrol verileri, uyku evrelerinden seçildi.

Tablo 4.2. Çalışmadaki bireylere ait uyku evre sayıları.

Evreler (epok)		Kadın n ₁ =2	Erkek n ₂ =15	Tümü n=n ₁ +n ₂ =17
Uyanık		280	1504	1784
	REM	210	3378	3588
	N1	129	527	656
	N2	572	3493	4065
	N3	394	2840	3234
Toplam		1585	11742	13327

4.2.2. Veri etiketlemeleri

Çalışmada bruksizm ve kontrol etiketlemeleri yapılmıştır. Bruksizm etiketleri fazik, tonik ve karma bruksizmden oluşmaktadır. Kontrol etiketleri ise mikro uyarılma, RERA ve PLM ile ilişkili uyarılmalardan oluşmaktadır. Yapılan etiketlemelere ait örnekler Şekil 4.4'te görülmektedir. Etiketlemeler yapıldıktan sonra etiketlemenin yapıldığı sürelerdeki PPG'ler alınmıştır. Böylece bruksizm ve kontrol etiketli PPG verileri elde edildi (Şekil 4.1).



Şekil 4.4. Örnek bruksizm ve kontrol etiketleri a) Mikro uyarılma b) RERA c) PLM uyarılma d) Fazik bruksizm e) Tonik bruksizm.

4.2.1.1. Bruksizm etiketlemeleri

AASM kriterlerine göre bruksizm fazik, tonik ve karma formlarda gözlemlenebilir (Iber vd., 2007). Bruksizm tipleri Şekil 4.5'te görülmektedir. Fazik form, 0,25-2 saniye arasında süren üç veya daha fazla EMG patlamasından oluşur. Tonik form, 2 saniyeden uzun süren EMG patlamalarından oluşur. Karışık form, fazik ve tonik özellikler birlikte gözlemlendiğinde ortaya çıkar (D. Li vd., 2022). EMG patlamalarının bruksizm olarak kabul edilmesi için EMG genliği, mevcudun en az iki katı olması

gerekmektedir. Ayrıca EMG patlamalarının aynı bruksizm etiketi içinde değerlendirilebilmesi için aralarındaki sürenin 3 saniyeden daha az olması gereklidir (Winck vd., 2017). Çalışmada tüm SB tipleri “bruksizm” etiketi altında birleştirildi.



Şekil 4.5. Bruksizm tipleri (Huynh vd., 2011).

Konuşma ve öksürme gibi orofasiyal aktiviteler çene EMG'sinde değişikliklere neden olabilir. Bu aktiviteler tipik bir frekansa sahip değildir ve keskin genlik artışlarıyla karakterize edilir (J.-B. Martinot vd., 2021; Sonmezocak & Kurt, 2021). Bruksizm sırasındaki EMG tipik olarak 1 Hz frekansa sahiptir ve orofasiyal aktivitenin neden olduğu EMG değişikliklerinden ayırt edilebilir (J.-B. Martinot vd., 2021). Video/ses kayıtları ile desteklenen PSG kayıtlarının incelenmesi ile bu tür durumlardan kaynaklanan yanlış etiketlemelerin önüne geçilmesi amaçlandı.

4.2.1.2. Kontrol etiketlemeleri

Kontrol etiketleri olarak, bruksizm aktivitesinin görülmediği zaman aralıklarındaki mikro, RERA ve PLM ile ilişkili uyarılmalar seçildi. Bruksizm ve kontrol etiketlemelerinin bireylere göre dağılımı Tablo 4.3'te görülmektedir.

Uyarılma, derin uykudan yüzeysel uykuya veya uyanıklığa kısa ve ani bir geçiştir (Halász vd., 2004). Uyarılma, kalp atış hızında ve kan basıncında artışa neden olabilir (H. Han vd., 2024).

Genellikle 3 ila 15 saniye süren ve EEG'yi bozan ancak uyanık olarak etiketlenemeyecek kadar kısa olan uyku sırasındaki uyarılma, mikro uyarılma olarak adlandırılır. Mikro uyarılmalar, genellikle EMG genliğinde küçük artışlara neden olur. Mikro uyarılmalar, doğal uyku/uyanıklık durumlarının veya harici uyaranların (gürültü ve SA gibi) bir parçası olarak ortaya çıkabilir (Brink-Kjaer vd., 2020).

RERA, apne veya hipopne kriterlerini karşılamayan, en az 10 saniye boyunca azalmış burun solunumu ile artan solunum çabasıyla ilişkili uyarılmalardır. Uyananlar genellikle bu uyanmaları hatırlamazlar. Aşırı gündüz uykululuğuna neden olur.

Solunumdaki azalma, apne ve hipopneye göre daha hafiftir ve RERA kandaki oksijen seviyesini düşürmez (Halász vd., 2004).

PLM, uyku sırasında ekstremitelerin istemsiz hareketleridir. Bacak hareketi (LM), 0,5-10 saniye boyunca dinlenme halindeki EMG genliğinden en az 8 mikrovoltluk bir artışla belirlenir. Periyodik olarak kabul edilebilmesi için 5-90 saniye aralıklarla en az dört ardışık LM meydana gelmelidir. PLM uyarılmaları, PLM ile senkronize, PLM ile ortak bir zamana sahip veya PLM'den en fazla 0,5 saniye önce veya sonra meydana gelir (Hirshkowitz, 2012).

Tablo 4.3. Bruksizm ve kontrol etiketlemelerinin bireylere göre dağılımı.

Kişi	Bruksizm	Kontrol			Toplam
		Mikro Uyarılma	RERA	PLM Uyarılma	
1	98	60	8	4	170
2	49	75	3	28	155
3	30	42	17	5	94
4	45	49	39	1	134
5	37	40	5	1	83
6	46	38	17	5	106
7	11	15	8	5	39
8	41	39	8	14	102
9	28	8	35	20	91
10	48	20	1	1	70
11	45	37	19	3	104
12	61	42	8	13	124
13	21	20	6	5	52
14	14	22	5	9	50
15	7	17	9	-	33
16	11	13	-	6	30
17	31	26	1	3	51
		563	189	123	
Toplam	623		875		1498

4.2.2. Veri setlerinin oluşturulması

Çalışmada bruksizmi kontrol etiketlerinden ayıran ikili sınıflandırmalar yapıldı. Bunun için 4 farklı veri seti oluşturuldu. Bunlar sırasıyla; bruksizmi mikro uyarılmalardan ayırmak için kullanılan veri seti, bruksizmi RERA'dan ayırmak için kullanılan veri seti, bruksizmi PLM uyarılmalarından ayırmak için kullanılan veri seti ve bruksizmi tüm kontrol etiketlerinden ayırmak için kullanılan veri setidir.

Her bir uyarılmadaki veri miktarı bruksizm veri miktarından farklıdır. Bruksizm etiketli veri sayısı 623 iken, kontrol veri setinde bulunan mikro uyarılma etiketli veri sayısı 563, RERA etiketli veri sayısı 189 ve PLM uyarılma etiketli veri sayısı 123'tür (Tablo 4.3). Veri setindeki sınıf etiketlerinin miktarları birbirinden çok farklı olması veri setini dengesiz hale getirir. Dengesiz veri setleri, yanıltıcı sonuçlara ve dolayısıyla yanlış performans değerlendirmelerine sebep olabilir (Haibo He & Garcia, 2009; Yıldırım vd., 2021). Bu nedenle kontrol verilerinin sayılarına uygun miktarda bruksizm verisi, sistematik örnekleme yöntemi kullanılarak seçildi. Böylece hem dengeli veri seti oluşturuldu hem de veri setlerinde her bir kişiye ait veriler kullanıldı. Sistematik örnekleme sonucunda veri setlerindeki dağılımlar Tablo 4.4'te görülmektedir.

Tablo 4.4. Veri setlerine ait bruksizm-kontrol veri sayıları.


VERİ SETLERİ	Veri Miktarı		
	Bruksizm	Kontrol	Toplam
Bruksizm – Mikro Uyarılma	560	563	1123
Bruksizm – RERA	186	189	375
Bruksizm – PLM Uyarılma	124	123	247
Bruksizm – Tüm Uyarılmalar	623	875	1498

5. ÖZELLİK ÇIKARMA VE SEÇME

5.1. Özellik Çıkarma

Bu çalışmada bruksizm teşhisi için zaman domeninde PPG'den 38 karakteristik ve 29 istatistiksel, HRV'den de 29 istatistiksel olmak üzere toplam 96 özellik çıkarıldı.

Etiketlenen sinyallerin süreleri farklı olabilir. Karakteristik özellikler çıkarılırken, etiketli sinyaldeki her periyot için karakteristik özelliğin değeri ayrı ayrı hesaplatıldı ve periyot sayısına bağlı olarak ortalaması alındı. Böylece ilgili etikete ait karakteristik özellik değeri elde edildi. PPG'den çıkarılan karakteristik özellikler Şekil 5.1'de ve bu özelliklerin açıklamaları Tablo 5.1'de görülmektedir.



Şekil 5.1. PPG'den çıkarılan karakteristik özellikler.

Tablo 5.1. PPG'den çıkarılan karakteristik özelliklerin açıklamaları.

Özellik Numarası	Açıklama
1**	PPG'nin sistolik tepe değeri
2**	PPG'nin periyodu
3	PPG'nin başlangıcından minimum noktaya kadar geçen süre
4**	Minimum noktadan PPG'nin sonuna kadar geçen süre
5	Sistolik tepe ile PPG'nin minimum değeri arasındaki tepeden tepeye değer

Tablo 5.1. (Devamı) PPG'den çıkarılan karakteristik özelliklerin açıklamaları.

Özellik Numarası	Açıklama
6	Üçüncü özelliğin %75'ine karşılık gelen genlik değeri
7**	Üçüncü özelliğin %50'sine karşılık gelen genlik değeri
8	Üçüncü özelliğin %25'ine karşılık gelen genlik değeri
9	Altıncı özelliğin beşinci özelliğe oranı
10**	Yedinci özelliğin beşinci özelliğe oranı
11**	Sekizinci özelliğin beşinci özelliğe oranı
12**	Üçüncü özelliğin %75'ine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
13	Üçüncü özelliğin %50'sine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
14	Üçüncü özelliğin %25'ine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
15**	Onikinci özelliğin beşinci özelliğe oranı
16	Onüçüncü özelliğin beşinci özelliğe oranı
17**	Ondördüncü özelliğin beşinci özelliğe oranı
18	PPG'nin son değeri ile minimum değeri arasındaki genlik değeri
19**	Dördüncü özelliğin %75'ine karşılık gelen genlik değeri
20**	Dördüncü özelliğin %50'sine karşılık gelen genlik değeri
21	Dördüncü özelliğin %25'ine karşılık gelen genlik değeri
22**	Ondokuzuncu özelliğin onsekizinci özelliğe oranı
23	Yirminci özelliğin onsekizinci özelliğe oranı
24	Yirmibirinci özelliğin onsekizinci özelliğe oranı
25	Dördüncü özelliğin %75'ine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
26	Dördüncü özelliğin %50'sine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
27**	Dördüncü özelliğin %25'ine karşılık gelen genlik değeri ile PPG'nin minimum değeri arasındaki fark
28**	Yirmibeşinci özelliğin onsekizinci özelliğe oranı
29	Yirmialtıncı özelliğin onsekizinci özelliğe oranı
30**	Yirmiyedinci özelliğin onsekizinci özelliğe oranı
31**	Onikinci özelliğin yirmiyedinci özelliğe oranı
32**	Onüçüncü özelliğin yirmialtıncı özelliğe oranı
33**	Ondördüncü özelliğin yirmibeşinci özelliğe oranı
34**	Beşinci özelliğin onsekizinci özelliğe oranı
35**	Üçüncü özelliğin dördüncü özelliğe oranı
36	Sistolik tepe ile minimum genlik değeri arasındaki sinyalin altındaki alan
37**	Minimum genlik değeri ile sinyalin son noktası arasındaki sinyalin altındaki alan
38	Otuzaltıncı özelliğin otuzyedinci özelliğe oranı

** PCA sonucunda seçilen özellikler.

PPG ve HRV'den çıkarılan istatistiksel özellikler ve bu özelliklerin denklemleri Tablo 5.2'de görülmektedir. Bu özellikler, literatürde kullanılmış ve etkili sonuçlar verdiği için tercih edilmiştir (F. Bozkurt vd., 2020, 2021; Melekoglu vd., 2022; Özen

Kavas vd., 2023). İstatistiksel özellikler, veriler arasındaki ilişkiyi ölçer ve karmaşık veri dağılımlarını anlamaya yardımcı olur (Gras & Kuntz, 2008). Ayrıca sinyallerin daha ayrıntılı tanımlanmasını sağlar.

Tablo 5.2. İstatistiksel özelliklerin açıklamaları.

PPG Özellik Numarası	HRV Özellik Numarası	Özellik	Eşitlik
39**	68	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n (x_1 + \dots + x_n)$
40	69	Hjort parametresi - Aktivite	$A = S^2$
41	70	Standart sapma	$S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
42	71	Ortalama eğri uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $
43	72	Ortalama enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
44	73**	Ortalama Teager enerjisi	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$
45**	74**	Hjort parametresi - Hareketlilik	$M = S_1^2 / S^2$
46**	75**	Hjort parametresi - Karmaşıklık	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
47**	76**	Çarpıklık (Skewness)	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
48**	77	Basıklık (Kurtosis)	$x_{kur} = \frac{\sum_{i=1}^n (x(i) - \bar{x})^4}{(n-1)S^4}$
49	78	Ortalama karakök değeri	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
50	79	Şekil faktörü	$SF = X_{rms} / (\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i })$

Tablo 5.2. (Devamı) İstatistiksel özelliklerin açıklamaları.

PPG Özellik Numarası	HRV Özellik Numarası	Özellik	Eşitlik
51	80	Geometrik ortalama	$G = \sqrt[n]{x_1 x \dots x x_n}$
52**	81	Harmonik ortalama	$H = n / (\frac{1}{x_1} + \dots + \frac{1}{x_n})$
53	82	Medyan	$\tilde{x} = \begin{cases} x_{\frac{n+1}{2}} & : x \text{ tek} \\ \frac{1}{2} (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & : x \text{ çift} \end{cases}$
54	83**	Minimum*	$x_{min} = \min (x_i)$
55	84**	Maksimum*	$x_{maks} = \max (x_i)$
56	85	Aralık	$R = x_n - x_1$
57**	86**	Tekil değer ayrışımı*	$SVD = svd (x)$
58	87	%25 kırılmış ortalama*	$T25 = trimmean (x, 25)$
59	88	%50 kırılmış ortalama*	$T50 = trimmean (x, 50)$
60	89	Çeyrekler genişlik* arası	$IQR = iqr(x)$
61	90	Ortalama ya da meydan mutlak sapma*	$MAD = mad(x)$
62**	91	Değişim katsayısı	$DK = (S/\bar{x})100$
63	92	Normallik testi h*	$[h,p] = kstest(x)$
64	93	Normallik testi p*	
65**	94	İşaret testi p*	$[p,h] = signtest(x)$
66**	95	İşaret testi h*	
67**	96	Standart hata	$S_{\bar{x}} = S/\sqrt{n}$


* işaretli özellikler, MATLAB'in hazır komutları kullanılarak hesaplanmıştır.

** işaretli özellikler, PCA ile seçilen özellikleri göstermektedir.

Denklemlerde; x örnekleri, n örnek sayısını, S^2 x sinyalinin varyansını, S_1^2 x sinyalinin 1. türevinin varyansını, S_2^2 x sinyalinin 2. türevinin varyansını göstermektedir.

Tablo 5.1 ve Tablo 5.2'de yer alan toplam 96 özellik MATLAB'de yazılan kodlar ile hesaplatıldı. Tablo 5.2'deki * işaretli özellikler, MATLAB'in hazır komutları kullanılarak hesaplatıldı. Tablo 5.1 ve Tablo 5.2'deki ** işaretli özellikler ise PCA sonucunda kalan özellikleri göstermektedir. Bununla ilgili ayrıntılı bilgi 6. bölüm (Özellik Seçme) altında yer alan PCA başlığı altında yer almaktadır.

Çıkarılan 96 özellik ve 1498 veri etiketi (623 bruksizm ve 875 kontrol) ile 96×1498 boyutlu veri seti elde edildi. Şekil 5.2, bu veri setinin elde ediliş sürecini göstermektedir.



Şekil 5.2. Özellik çıkarma ile veri setinin elde ediliş süreci.


5.2. Özellik Seçme

5.2.1. PCA

PCA, özelliklerin hedef etiketle olan ilişkisine değil, diğer özelliklerle olan ilişkisine bakan denetimsiz bir özellik seçme yöntemidir (Shafizadeh-Moghadam, 2021). Çok değişkenli verilerin ana özelliklerini daha az değişkenle temsil etmek için gerçekleştirilir.

PCA, SPSS programında “Analyze” menüsünün “Dimension Reduction” modülünde yer alan “Factor” seçeneği kullanılarak gerçekleştirildi. Analiz sonucunda 96 özellikten oluşan veri seti, 13 temel bileşenle %77,853 oranında temsil edildi. Ayrıca veri seti, 47 temel bileşenle %100 temsil edildi.

Şekil 5.3, PCA öz-vektör grafiğini göstermektedir.



Şekil 5.3. PCA öz-vektör grafiği.

Temel bileşen sayısı arttıkça “Eigen” değeri düşmekte ve 47 temel bileşende sıfıra düşerek %100 temsili sağlamaktadır. Temel bileşen sayısı adım adım arttığında

“Eigen” değeri 13 bileşene kadar daha hızlı düşüş gösterip, 13 bileşenden sonra düşüş hızı azalmaktadır. Buradan da 13 temel bileşene ayrılma ve veri setinin %100 temsili için 47 temel bileşen kullanımı doğrulanmaktadır.

PCA sonucunda seçilen özellikler Tablo 4 ve 5'te ** ile listelenmiştir. Seçilen özelliklerle veri setinin boyutu 47×1498 'ye düşürülmüştür.

5.2.2. Fisher özellik seçme algoritması

Fisher özellik seçim algoritması, özelliklerin sınıf etiketiyle olan ilişki düzeyini belirler. Bir özellik diğer özelliklerle ilişkili veya ilişkisiz olabilir ancak sınıf etiketiyle ilişkili olmalıdır (Solorio-Fernández vd., 2022). Sınıf etiketiyle ilişkisiz bir özellik atılabilir. Özellik sayısı azaltılarak hesaplama karmaşıklığı ortadan kaldırılır. Fisher özellik seçme algoritması yüksek performansı nedeniyle çalışmalarda sıklıkla tercih edilmektedir (F. Bozkurt vd., 2021; C. Li & Xu, 2019; Melekoglu vd., 2022; Sun vd., 2019; Uçar vd., 2020; Wang vd., 2011).

Özelliklerin Fisher skorları dikkate alınarak farklı veri setleri oluşturulabilir. Bu çalışmada bruksizmi kontrol etiketlerinden ayırmada en etkili özellikleri belirlemek için Fisher özellik seçme algoritması kullanıldı. Bunun için her özelliğin Fisher puanı hesaplatıldı ve özellikler Fisher puanlarına göre yüksekten düşüğe sıralandı. En yüksek Fisher puanına sahip özellikten başlayarak özellik sayısı tek tek artırılarak 47 farklı veri seti oluşturuldu. Tablo 5.3, özelliklerin Fisher puanlarına göre oluşturulan veri setlerini göstermektedir.


Tablo 5.3. Fisher puanlarına göre oluşturulan veri setleri.

Veri Setleri	Özellikler
Veri Seti 1	86
Veri Seti 2	86, 95
Veri Seti 3	86, 95, 94
Veri Seti 4	86, 95, 94, 67
Veri Seti 5	86, 95, 94, 67, 3
Veri Seti 6	86, 95, 94, 67, 3, 57
-	-
-	-
-	-
-	-
Veri Seti 47	86, 95, 94, 67, 3, 57, 82, 30, 15, 66, 17, 92, 96, 77, 65, 76, 74, 75, 27, 29, 35, 48, 83, 84, 47, 31, 34, 12, 36, 11, 59, 20, 73, 54, 42, 6, 52, 64, 33, 62, 24, 39, 32, 4, 45, 46, 7

6. SINIFLANDIRMA VE PERFORMANS PARAMETRELERİ

6.1. Sınıflandırma Organizasyonu

Sınıflandırma, verilerin belirli kategorilere ayrılması sürecidir ve genellikle bu süreç, istatistiksel yöntemler veya makine öğrenmesi algoritmaları kullanılarak gerçekleştirilir. Bu çalışmada, bruksizm etiketlerini kontrol etiketlerinden ayırmak için ikili sınıflandırma modelleri oluşturuldu. Şekil 6.1'de sınıflandırma süreci görülmektedir.



Şekil 6.1. Sınıflandırma süreci.

İlk olarak, çıkarılan tüm özellikler (96 özellik) kullanılarak sınıflandırma gerçekleştirildi. Daha sonra PCA ile veri seti boyutu küçültüldü ve yeniden sınıflandırma yapıldı. Sınıflandırma performansının veri setindeki kişilere bağlı olup

olmadığını belirlemek için LOO yöntemi kullanıldı. LOO yöntemi sekizinci bölümde ayrıntılı olarak anlatılmaktadır. Kontrol etiketleri üç farklı uyarılmadan oluşmaktadır. Elde edilen performansın, kontrol etiketlerindeki üç uyarılmaya genellenebilir olup olmadığını belirlemek için, bruksizm grubu ile kontrol grubundaki her uyarılma arasında üç ayrı sınıflandırma daha yapıldı.

PCA sonrasında veri seti 47 temel bileşen ile %100 temsil edilmişti. Bruksizmi kontrol etiketlerinden başarıyla ayıran en ayırt edici özellikleri belirlemek için PCA'dan sonra elde edilen veri setine Fisher özellik seçme algoritması uygulandı. Özellikler Fisher puanlarına göre yüksekten düşüğe sıralandı. En yüksek Fisher puanından başlanarak özellik sayısı birer birer artırıldı ve 47 veri seti elde edildi. Her bir veri seti kullanılarak, bruksizm etiketlerini kontrol etiketlerinden ayıran sınıflandırmalar yapıldı.

6.2. Sınıflandırma Algoritmaları


Sınıflandırma modelleri oluşturulurken SVM, kNN, Ensemble ve NN makine öğrenmesi algoritmaları kullanıldı. Bu algoritmalar bu bölümde ayrıntılı olarak anlatılmıştır. Bu algoritmalar, hızlı çalışmaları, gömülü sistemlere uygulanabilir olmaları, yüksek işlem kapasitesine sahip bilgisayarlar gerektirmemeleri ve yüksek performanslı sınıflandırma yapmaları nedeniyle tercih edildi (Branco vd., 2019; Karmakar vd., 2014; Maluly vd., 2020; Orhan vd., 2024; Roscher vd., 2020; Sonmezocak & Kurt, 2021; Tiwari vd., 2024; Younes vd., 2021).

Kullanılan AI algoritmaları için hiperparametre optimizasyonu yapıldı. Hiperparametre aralıkları:

- SVM için; 0,001-1000 box constraint seviyesi, 0,001-1000 kernel ölçeği, Gaussian - Linear- Quadratic- Cubic Kernel fonksiyonları
- kNN için; 1-432 komşu sayısı, City block, Chebyshev, Correlation, Cosine, Euclidean, Hamming, Jaccard, Mahalanobis, Minkowski (Cubic), Spearman mesafe metrikleri, Equal, Inverse, Squared Inverse mesafe ağırlıkları
- Ensemble için; Bag, GentleBoost, LogitBoost, AdaBoost, RUSBoost Ensemble yöntemleri, 10-500 öğrenici sayısı, 0,001-1 öğrenme oranı, 1-862 maksimum bölünme sayısı
- NN için; 1-3 tam bağlı katman sayısı, ReLU, Tanh, Sigmoid, None aktivasyon fonksiyonları, 1-300 birinci katman, ikinci katman ve üçüncü katman boyutları.

6.2.1. SVM

SVM, sınıflandırma ve regresyon problemlerinde kullanılan denetimli bir makine öğrenme algoritmasıdır. Sınıflandırma için en iyi hiper düzlemi (hyperplane) bulmayı amaçlar. Bu düzlem sınıflar arasındaki ayrımı (marjin) maksimize eden doğrusal ayırıcıdır (Cortes & Vapnik, 1995; Melekoglu vd., 2022). Şekil 6.2, SVM'nin iki sınıf arasındaki ayrım için çizilen düzlemi göstermektedir.



Şekil 6.2. SVM'de iki sınıf arasındaki düzlem (Melekoglu vd., 2022).


SVM'nin iki temel prensibi vardır. Bunlardan ilki sınıflar arası ayrımın en geniş olduğu hiper düzlemi bulmaktır. Bu ayrımı tanımlayan veri noktalarına destek vektörleri denir (Schölkopf & Smola, 2001). İkinci prensip, doğrusal ve doğrusal olmayan ayırmadır. Doğrusal ayırma, doğrusal olarak ayrılabilen verilerde doğrusal hiper düzlem ile yapılır. Eğer veriler doğrusal olarak ayrılamıyorsa çekirdek (kernel) fonksiyonları kullanarak veri uzayı daha yüksek boyutlu uzaya dönüştürülür. Lineer, Radyal Temel Fonksiyon (RBF) ve Polinomal en çok kullanılan çekirdek fonksiyonlarıdır (Bishop, 2006).

SVM, görüntü sınıflandırma, doğal dil işleme, tıbbi teşhis ve spam filtreleme gibi uygulamalarda sıklıkla kullanılır (Bishop, 2006). Yüksek boyutlu verilerde etkili performans gösteren SVM, az veriyle de etkili sonuçlar verebilir (Cortes & Vapnik, 1995; Hastie vd., 2009). Çekirdek fonksiyonlarıyla farklı SVM modelleri oluşturulmasına imkan sağlar (Schölkopf & Smola, 2001). Yüksek boyutlu verilerde eğitim süresi uzayabilen SVM'lerde uygun çekirdek fonksiyonu seçimi önemlidir (Hastie vd., 2009; Schölkopf & Smola, 2001).

6.2.2. kNN

kNN, basit ve etkili bir denetimli makine öğrenme algoritmasıdır. Hem sınıflandırma hem de regresyonda kullanılan bu yöntem, veri sınıfını ya da değerini özellik uzayında ona en yakın olan k komşusunun özelliklerine göre tahmin eder (Altman, 1992).

Şekil 6.3, kNN algoritmasının çalışma yapısını göstermektedir.



Şekil 6.3. kNN çalışma yapısı (Melekoglu vd., 2022).

kNN algoritması veriler arasındaki benzerliği ölçmek için Öklidyen, Chebyshev, Manhattan gibi mesafe metriklerini kullanır (Cover & Hart, 1967). “ k ” değeri hesaplama için dikkate alınacak komşu sayısını belirler. Bu değerin büyük olması modelin yanlılığını artırabilir. Küçük olması ise modelin varyansını artırır. En uygun “ k ” değeri çapraz doğrulama ile tespit edilir (Bishop, 2006).


kNN sınıflandırma için kullanıldığında veriler çoğunlukla en yakın “ k ” komşusunun sınıfına atanır. Regresyonda ise öngörülen veri değeri, “ k ” komşusunun ortalaması ya da medyanı hesaplanarak bulunur (Hastie vd., 2009).

kNN, görüntü tanıma, öneri sistemleri, metin sınıflandırma, anomali tespiti ve tıbbi teşhis gibi uygulamalarda tercih edilmektedir. kNN algoritma yapısının anlaşılabilirliği kolaydır (Cover & Hart, 1967). Hem kategorik hem de sürekli verilerle çalışabilir (Bishop, 2006). Büyük veri setlerinde noktalar arasındaki mesafeler anlamsızlaşabilir, bu da performansı düşürür (Beyer vd., 1999). Ayrıca dengesiz veri setlerinde azınlık sınıflarda doğru tahmin zorlaşır (Cover & Hart, 1967).

6.2.3. Ensemble

Farklı DT'lerin tahminlerini birleştirerek tahmin yapan böylece daha güçlü ve geliştirilebilir modeller oluşturmayı hedefleyen bir makine öğrenmesi algoritmasıdır (Dietterich, 2000). DT, verilerin özelliklerini ağaç dalları gibi dallandırarak sınıflandırma veya regresyon yapar. Tek bir DT yanlı sonuç verebileceği için birden fazla DT bir araya getirilir (Breiman, 2001).

Ensemble öğrenme algoritmaları, torbalama (bagging) ve yükseltme (boosting) olarak adlandırılan iki ana kategoriye ayrılır. Şekil 6.4'te bu yöntemlerin çalışma yapısını göstermektedir.



Şekil 6.4. Torbalama ve yükseltme yöntemlerinin çalışma yapıları.

Yüksek varyanslı modeller için etkili olan torbalama yönteminde veri setinden birbirinden bağımsız alt veri kümeleri oluşturulur. Her alt veri kümesi ile DT modeli oluşturulur. Modeller paralel ve birbirinden bağımsız çalışır. Bu durum ağaçlar arasındaki korelasyonu azaltarak performansı artırır. Modellerden gelen sonuçlar birleştirilerek nihai sonuç belirlenir (Breiman, 2001). Rastgele Orman (Random Forest) algoritması torbalama yönteminin bir örneğidir.


Yükseltme yönteminde, veri setinden bir alt veri kümesi alınır. Bu alt veri kümesinden DT modeli oluşturulur. Bu model tahmin yapar. Tahmin eden modeldeki hataları düzeltmek için yeni bir model oluşturulur. Bu işlem tekrarlanarak her model kendinden önceki modelin hatalarını düzeltmek üzere eğitilir. Böylece daha güçlü tahmin modelleri oluşturulur. Nihai karar verici model, tüm modellerin ağırlıklı ortalamasıdır. AdaBoost, Gradient Boosting Machines (GBM), Extreme Gradient Boosting Machines (XGBM) algoritmaları yükseltme yönteminin örnekleridir (Freund & Schapire, 1997).

6.2.4. NN

İnsan beyninin çalışmasına benzeyen NN bir makine öğrenmesi yöntemidir. Karmaşık veri yapılarını modellemek ve nöronlar arasındaki doğrusal olmayan ilişkileri öğrenmek için kullanılır. Bu yöntem çok katmanlı yapılarıyla verilerden öğrenir ve tahmin yapar.

NN'nin genel yapısı Şekil 6.5'te görülmektedir. NN sırasıyla giriş katmanı, bir veya birden fazla gizli katman ve çıkış katmanından oluşur. Her katman nöronlardan oluşur ve bir sonraki katmandaki nöronlarla bağlantılıdır (Goodfellow vd., 2016). Giriş katmanında her nöron veri setindeki bir özelliğe karşılık gelir. Gizli katmanlar giriş verisinden alınan veriyi işler ve sonraki katmana iletir. Çıkış katmanı ise ağın nihai tahminini üretir.

Her nöron bir aktivasyon fonksiyonu kullanarak girişleri işler. Bu fonksiyonlar doğrusal olmayan ilişkileri modellemek için gereklidir. En yaygın kullanılan aktivasyon fonksiyonları Sigmoid, Hyperbolic Tangent (Tanh) ve Rectified Linear Unit (ReLU)'dur (Goodfellow vd., 2016).



Şekil 6.5. Sinir ağı yapısı.

NN'de ileri yayılım (forward propagation) ve geri yayılım (back propagation) gibi öğrenme süreçleri vardır. İleri yayılım algoritmasında giriş verileri ağ boyunca ileriye taşınır. Her bir nöronun ağırlık katsayısı ve aktivasyon fonksiyonu kullanılarak çıkış hesaplanır (Goodfellow vd., 2016). Geri yayılım algoritmasında ise hata düzeltmesi için geriye doğru yayılarak ağırlık katsayıları güncellenir (Rumelhart vd., 1986).

Gizli katman sayısının az olması daha hızlı hesaplamayı ve böylece modelin daha hızlı çalışmasını sağlar. Ayrıca modelin karmaşıklığını ve aşırı öğrenmeyi azaltır.

Gizli katmandaki nöronlar kendinden önceki katmandaki tüm nöronlarla bağlantısı mevcut ise bu katmana tam bağlı katmanlar (fully connected layers) denir. Bu da yoğun bir bağlantı ağı (dense layer) oluşturur. Bu durum aşırı öğrenme riskini arttırabilir. Bu riski azaltmak için düzenleme teknikleri (Dropout ve L2 düzenleme gibi) kullanılır (Goodfellow vd., 2016; Srivastava vd., 2014).

6.3. Performans Parametreleri

6.3.1. LOO yöntemi

LOO yöntemi, modelin genelleme yeteneğini değerlendirmek için kullanılan çapraz doğrulama tekniklerinden biridir.

Çalışmada sınıflandırma sonuçlarının öznel özellikler yerine veri örüntüleri üzerinden genellenip genellenemeyeceğini belirlemek için LOO yöntemi kullanıldı. Her bireyin bruksizm ve kontrol verileri test verisi olarak, kalan veriler de eğitim verisi olarak seçildi. Bu süreç 17 birey için tekrarlandı. Tablo 6.1, LOO yöntemi kullanılarak eğitim ve test süreçleri sırasında bireylerin dağılımını göstermektedir.

Tablo 6.1. LOO yönteminde eğitim ve test için bireylerin dağılımı.

Eğitim																	Test
Birey No																	Birey No
2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17		1
1		3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	2
1	2		4	5	6	7	8	9	10	11	12	13	14	15	16	17	3
1	2	3		5	6	7	8	9	10	11	12	13	14	15	16	17	4
1	2	3	4		6	7	8	9	10	11	12	13	14	15	16	17	5
1	2	3	4	5		7	8	9	10	11	12	13	14	15	16	17	6
1	2	3	4	5	6		8	9	10	11	12	13	14	15	16	17	7
1	2	3	4	5	6	7		9	10	11	12	13	14	15	16	17	8
1	2	3	4	5	6	7	8		10	11	12	13	14	15	16	17	9
1	2	3	4	5	6	7	8	9		11	12	13	14	15	16	17	10
1	2	3	4	5	6	7	8	9	10		12	13	14	15	16	17	11
1	2	3	4	5	6	7	8	9	10	11		13	14	15	16	17	12
1	2	3	4	5	6	7	8	9	10	11	12		14	15	16	17	13
1	2	3	4	5	6	7	8	9	10	11	12	13		15	16	17	14
1	2	3	4	5	6	7	8	9	10	11	12	13	14		16	17	15
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15		17	16
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16		17

6.3.2. k-kat çapraz doğrulama

Modelin genelleme yeteneğini değerlendirmek için kullanılan yaygın bir çapraz doğrulama yöntemidir. Bu yöntemde veri k eşit parçaya bölünür. k-1 parça modelin

eğitilmesi için kullanılırken kalan parça modelin test edilmesi için kullanılır. Bu işlem her parça test sürecinde kullanılacak şekilde k kez tekrar edilir. Bu yöntem modelin genelleme yeteneğini artırır ve daha güvenilir bir performans değerlendirmesi sağlar (Hastie vd., 2009; Stone, 1974).

Büyük veri setlerinde her bir katmanda modelin tekrar tekrar eğitilmesi hesaplama maliyetini yükseltir (Arlot & Celisse, 2010). Bu nedenle k değerinin optimal seçimi önemlidir. K değeri genellikle 5 veya 10 olarak seçilir. Bu değerler modelin performansını değerlendirmek için yeterli bilgi sağlarken hesaplama maliyetini makul seviyede tutar (Bengio & Grandvalet, 2004).

Çalışmada veri seti, sistematik örnekleme ile %50 eğitim - %50 test olacak şekilde ayrıldı. Sistematik örnekleme bu bölümün alt başlığında anlatılmıştır. Eğitim için ayrılan veriler, 5 kat çapraz doğrulama yapılarak eğitildi. 5 kat çapraz doğrulamanın genel yapısı Tablo 6.2’de görülmektedir. Eğitilen modeller test veri seti kullanılarak test edildi.

Tablo 6.2. 5-kat çapraz doğrulama ile eğitim veri setinin eğitilmesi.

Eğitim Veri Seti					Performans
		Eğitim	Test		
Veri 2	Veri 3	Veri 4	Veri 5	Veri 1	Performans 1
Veri 1	Veri 3	Veri 4	Veri 5	Veri 2	Performans 2
Veri 1	Veri 2	Veri 4	Veri 5	Veri 3	Performans 3
Veri 1	Veri 2	Veri 3	Veri 5	Veri 4	Performans 4
Veri 1	Veri 2	Veri 3	Veri 4	Veri 5	Performans 5
Eğitimin performansı	Ortalama (Performans 1; Performans 2; Performans 3; Performans 4; Performans 5)				

6.3.1.1. Sistematik örnekleme

Veri %50 eğitim ve %50 test verisi olacak şekilde ayrılırken, ilk %50’nin eğitim, kalan %50’nin test şeklinde ayrılması, ilk bireylerin tüm verilerinin eğitim veri seti içerisinde, son bireylerin tüm verilerinin de test veri seti içerisinde olmasına neden olur. Hem eğitim hem de test verisinde her kişiye ait örneklerin yer alması için sistematik örnekleme yöntemi kullanıldı.

Sistematik örnekleme, düzenli sıralanmış popülasyonda veri ayırma işlemi için kullanılan uygulanması kolay bir yöntemdir (Levy & Lemeshow, 2008). Bu yöntem,

veri setindeki tüm bireylerden düzenli aralıklarla örnek alınmasını ve popülasyonun temsilini sağlamaktadır. 1498 adet veri, popülasyon büyüklüğü N’i vermektedir. N’in %50’si olan 749’da örneklem büyüklüğü olan n’i vermektedir. Örneklem aralığı k, N/n’den 2 olarak bulunur. Böylece ilk örnek birinci veri olarak seçildiğinde, sonraki seçilecek örnekler sırasıyla 1+k, 1+2k, 1+3k, ... şeklinde olacaktır.

6.3.3. Doğruluk, duyarlılık, özgüllük, kesinlik, F-ölçümü, Kappa ve AUC

Doğruluk, duyarlılık, özgüllük, kesinlik, F-ölçümü, Kappa ve AUC değerlerinin her biri makine öğrenmesi modellerinin belirli bir yönünü değerlendirmek için kullanılan performans parametreleridir. Bu değerlerin hesaplanabilmesi için karışıklık matrisi oluşturulur. Karışıklık matrisi, Tablo 6.3’te görülmektedir.

Tablo 6.3. Karışıklık matrisi.

	Gerçek	
	Bruksizm (1)	Kontrol (0)
Tahmin	Bruksizm (1) Kontrol (0)	TP FN FP TN
TP, doğru pozitif; TN, doğru negatif; FP, yanlış pozitif; FN, yanlış negatif.		

Doğruluk, yaygın olarak kullanılan performans parametresidir. Modelin doğru tahmin ettiği örneklerin toplam tahmine oranını gösterir ve yüzde olarak ifade edilir (Powers, 2020). Denklem 6.1, doğruluk hesaplamasını göstermektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.2)$$

Duyarlılık, gerçek pozitif oranı olarak da ifade edilir. Pozitif sınıfları doğru tahmin etme yeteneğini gösterir (Sokolova & Lapalme, 2009). Veri setindeki bruksizm sınıfının ne kadarının doğru tahmin edildiğinin göstergesidir. Denklem 6.2, duyarlılık hesaplamasını göstermektedir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6.2)$$

Özgüllük, gerçek negatif oranı olarak da ifade edilir. Negatif sınıfları doğru tahmin etme yeteneğini gösterir (Fawcett, 2006). Veri setindeki kontrol sınıfının ne kadarının doğru tahmin edildiğinin göstergesidir. Denklem 6.3, özgüllük hesaplamasını göstermektedir.

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (6.3)$$

Kesinlik, modelin pozitif tahminlerinin ne kadarının doğru olduğunu gösterir (Powers, 2020). Bruksizm olarak tahmin edilenlerin gerçekte ne kadarının bruksizm olduğunun bir göstergesidir. Denklem 6.4, kesinlik hesaplamasını göstermektedir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (6.4)$$

F-ölçümü, özellikle dengesiz veri setlerinde yararlı olan bir parametredir. Duyarlılık ve kesinliğin harmonik ortalamasını verir (Sokolova & Lapalme, 2009). Denklem 6.5, F-ölçümü hesaplamasını göstermektedir.

$$F - \text{ölçümü} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (6.5)$$

Duyarlılık, özgüllük, kesinlik ve F-ölçümü parametreleri, 0 ile 1 arasında değişir ve 1'e ne kadar yakınsa o kadar iyidir.

Kappa, özellikle iki değerlendirici arasındaki uyumu ölçen bir metriktir. -1 ile 1 arasında değer alır. 1, mükemmel uyumu, 0, şansa bağlı uyumu ve <0 ise uyumsuzluğu gösterir. 0,81'in üzerinde olması çok iyi uyum anlamına gelmektedir (Cohen, 1960). Denklem 6.6, 6.6a ve 6.6b kullanılarak kappa değeri hesaplanır. p_o , gözlenen doğruluk değerini ve p_e , rastgele (şansa dayalı) beklenen doğruluk değerini gösterir.

$$\text{Kappa} = \frac{p_o - p_e}{1 - p_e} \quad (6.6)$$

$$p_o = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.6a)$$

$$p_e = \frac{(TP + FP) \times (TP + FN)}{(TP + TN + FP + FN)^2} + \frac{(TN + FN) \times (TN + FP)}{(TP + TN + FP + FN)^2} \quad (6.6b)$$

AUC, ROC eğrisi altındaki alanı verir. ROC, '1 - özgüllük' ve duyarlılık arasındaki ilişkiyi gösteren bir grafikdir. 1'e ne kadar yakınsa modelin sınıflandırma yeteneği o kadar iyidir (Fawcett, 2006).

7. SONUÇLAR

Bu çalışmada bruksizmi kontrol etiketlerinden ayıran ikili sınıflandırma modelleri, dört farklı makine öğrenmesi algoritması kullanılarak oluşturuldu. Modellerde kullanılan veri setleri, sistematik örnekleme yöntemi ile %50 eğitim ve %50 test olacak şekilde bölündü. Modeller oluşturulurken hiperparametre optimizasyonu ve 5-kat çapraz doğrulama yapıldı. Modellerin performansları, görülmemiş veriler kullanılarak test edildi.

Veri seti, SA olan ve olmayan bireylerden oluşmaktadır. Sınıflandırma performansının, SA olan ve olmayan bireylerde farklılık gösterip göstermediğini belirlemek için veri seti iki gruba (SA ve Non-SA) ayrıldı. Daha sonra, her iki veri seti ile ayrı ayrı sınıflandırmalar gerçekleştirildi. Son olarak, tüm veri seti ile elde edilen performans ile SA olan ve olmayan veri setleri ile elde edilen performanslar karşılaştırıldı.

PPG ve HRV'den toplam 96 özellik çıkarıldı. PCA uygulanarak özellik sayısı 47'ye düşürüldü ve böylece veri setinin boyutu "47x1498" olacak şekilde küçültüldü. PCA sonrası elde edilen veri seti ile tekrar sınıflandırma işlemi gerçekleştirildi. PCA ile elde edilen veri setinin %100 temsil gücüne sahip olduğu görüldü ve bundan sonraki sınıflandırmalarda bu veri seti kullanıldı.

Çalışmada bruksizmi kontrol etiketlerinden ayıran optimum modelin belirlenmesi amaçlandı. Bu amaçla Fisher özellik seçme algoritması kullanılarak veri setindeki özelliklerin sınıf etiketini belirlemedeki etkisi (Fisher skoru) hesaplatıldı. Elde edilen Fisher skorlarına göre 47 özellik büyükten küçüğe sıralandı. En yüksek Fisher skora sahip özellikten başlayarak, özellik sayısı birer birer artırılarak 47 farklı veri seti oluşturuldu. Her veri seti üzerinde dört farklı makine öğrenmesi algoritması kullanılarak modeller geliştirildi. Böylece, hem optimum modeli belirlemek hem de özellik seçme algoritmasının sınıflandırma performansına etkisini incelemek hedeflendi.

Bruksizmi kontrol etiketlerinden ayıran sınıflandırmalarda, kontrol etiketleri üç farklı gruba ayrılmaktadır: mikro uyarılma, RERA ve PLM uyarılma. Elde ettiğimiz sınıflandırma performanslarının bu üç etiket için de genellenebilir olup olmadığını değerlendirmek amacıyla üç ek sınıflandırma daha gerçekleştirildi. Bu sınıflandırmalar sırasıyla:


1. Bruksizmi mikro uyarılmalardan ayıran,

2. Bruksizmi RERA'dan ayıran,
3. Bruksizmi PLM uyarılmalardan ayıran sınıflandırmalardır.

Çalışmada 17 bireyden elde edilen bruksizm ve kontrol verileri kullanıldı. Sonuçların bireylere bağlı olarak değişiklik gösterip göstermediğini belirlemek için LOO yöntemi uygulandı. Böylece her bireyin verileri sırasıyla test için ayrılırken, geri kalan bireylere ait veriler eğitimde kullanıldı. Bu süreçte toplamda 17 farklı sınıflandırma gerçekleştirildi.

7.1. Tüm, SA ve Non-SA Veri Setleri ile Oluşturulan Modellerin Sonuçları

Tablo 7.1, tüm, SA ve Non-SA veri setleri kullanılarak oluşturulan modellerin performanslarını göstermektedir. Üç veri setinde de en yüksek performans değerlerine sahip modellerin ROC eğrileri Şekil 7.1'de gösterilmektedir. Makine öğrenmesi modelleri karşılaştırıldığında, her üç veri setinde de en yüksek performansa Ensemble model ulaşmıştır. Bruksizm hem tüm veri setinde hem de SA ve SA olmayan bireylerin verileri ayrı ayrı ele alındığında kontrol verilerinden başarılı bir şekilde ayırt edildi. SA ve Non-SA veri setleri ile elde edilen performans değerleri, tüm veri seti kullanılarak elde edilen sınıflandırmanın performansını doğrulamaktadır.



Şekil 7.1. Tüm, SA ve Non-SA veri setleri en yüksek performanslı modellerin ROC eğrileri.

Tablo 7.1. Tüm, SA ve Non-SA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.


Veri Setleri	Performans	Metot			
		SVM	kNN	Ensemble	NN
Tüm (96 x 1498)	Doğruluk (%)	89,9	87,7	92,8	91,1
	Duyarlılık	0,8494	0,8109	0,8974	0,8558
	Özgüllük	0,9336	0,9245	0,9497	0,9497
	Kesinlik	0,9014	0,8846	0,9272	0,9239
	F-ölçümü	0,8746	0,8462	0,9121	0,8885
	Kappa	0,8923	0,8697	0,9234	0,9051
	AUC	0,9463	0,9237	0,9727	0,9597
SA (96 x 1272)	Doğruluk (%)	91,7	89,3	92,3	90,9
	Duyarlılık	0,8704	0,8185	0,8963	0,8889
	Özgüllük	0,9508	0,9481	0,9426	0,9235
	Kesinlik	0,9289	0,9208	0,9202	0,8955
	F-ölçümü	0,8987	0,8667	0,9081	0,8922
	Kappa	0,9115	0,8866	0,9181	0,9030
	AUC	0,9629	0,9494	0,9722	0,9652
Non-SA (96 x 226)	Doğruluk (%)	37,2	85,0	92,9	91,2
	Duyarlılık	1,0000	0,8095	0,9286	0,8571
	Özgüllük	0,0000	0,8732	0,9296	0,9437
	Kesinlik	0,3717	0,7907	0,8864	0,9000
	F-ölçümü	0,5419	0,8000	0,9070	0,8780
	Kappa	0,3717	0,8408	0,9250	0,9065
	AUC	0,5238	0,8414	0,9708	0,9252

7.2. PCA ile Elde Edilen Modellerin Sonuçları

PCA yöntemi ile veri seti 47 özellik ile %100 temsil edildi. Böylece özellik sayısı 96'dan 47'ye düşürülerek veri seti boyutu küçültüldü. PCA sonrası, aynı makine öğrenmesi yöntemleri kullanılarak sınıflandırmalar gerçekleştirildi. Elde edilen performans sonuçları, PCA öncesi (tüm) veri seti ile elde edilmiş sonuçlarla karşılaştırıldı. PCA öncesi ve sonrası oluşturulan modellerin performansları Tablo 7.2'de gösterilmektedir. En yüksek performansa sahip modellerin ROC eğrileri Şekil 7.2'de sunulmaktadır. PCA öncesinde ve sonrasında en yüksek performansa Ensemble yöntemi ile ulaşıldı. PCA öncesinde %92,8 doğruluk ve 0,9727 AUC ve PCA sonrasında %92,4 doğruluk ve 0,9676 AUC değerlerine erişildi. Bu sonuçlar, PCA ile elde edilen veri setinin %100 temsil yeteneğine sahip olduğunu doğrulamaktadır.

Tablo 7.2. Tüm ve PCA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.

Veri Setleri	Performans	Metot			
		SVM	kNN	Ensemble	NN
Tüm (96 x 1498)	Doğruluk (%)	89,9	87,7	92,8	91,1
	Duyarlılık	0,8494	0,8109	0,8974	0,8558
	Özgüllük	0,9336	0,9245	0,9497	0,9497
	Kesinlik	0,9014	0,8846	0,9272	0,9239
	F-ölçümü	0,8746	0,8462	0,9121	0,8885
	Kappa	0,8923	0,8697	0,9234	0,9051
	AUC	0,9463	0,9237	0,9727	0,9597
PCA (47 x 1498)	Doğruluk (%)	89,7	89,6	92,4	90,8
	Duyarlılık	0,8622	0,8494	0,8942	0,8814
	Özgüllük	0,9222	0,9291	0,9451	0,9268
	Kesinlik	0,8878	0,8953	0,9208	0,8958
	F-ölçümü	0,8748	0,8717	0,9073	0,8885
	Kappa	0,8908	0,8894	0,9192	0,9021
	AUC	0,9437	0,9292	0,9676	0,9561



Şekil 7.2. Tüm ve PCA veri setleri en yüksek performanslı modellerin ROC eğrileri.

7.3. Fisher Özellik Seçme Algoritması ile Oluşturulan Modellerin Sonuçları

PCA sonrası elde edilen 47 özelliğin her biri için Fisher skorları hesaplatıldı ve özellikler, en yüksek skordan en düşüğe doğru sıralandı. Daha sonra ilk özellikten başlayarak ve özellik sayısı birer birer artırılarak 47 farklı veri seti oluşturuldu (Tablo 5.3). Her veri setinde 4 farklı makine öğrenmesi modeli ile sınıflandırma yapıldı. En az özellikle yüksek performansa ulaşılan durumlar analiz edildi.


Yalnızca bir özellik (86 numaralı) kullanıldığında SVM yöntemi ile %89,1 doğruluk ve 0,9374 AUC değerine ulaşıldı. 47 özellik içerisinde en yüksek performansa %92,7 doğruluk ve 0,9685 AUC değeri ile 33 özelliğin kullanıldığı Ensemble yöntemi ile ulaşıldı. Bu özellikler sırasıyla 86, 95, 94, 67, 3, 57, 82, 30, 15, 66, 17, 92, 96, 77, 65, 76, 74, 75, 27, 29, 35, 48, 83, 84, 47, 31, 34, 12, 36, 11, 59, 20 ve 73 numaralı özelliklerdir. Bunların on üç adedi PPG karakteristik (3, 30, 15, 17, 27, 29, 35, 31, 34, 12, 36, 11 ve 20 numaralı), yedi adedi PPG istatistiksel (67, 57, 66, 65, 48, 47 ve 59 numaralı) ve on üç adedi HRV istatistiksel (86, 95, 94, 82, 92, 96, 77, 76, 74, 75, 83, 84 ve 73 numaralı) özelliklerdir. Özelliklerin açıklamaları, Tablo 5.1 ve Tablo 5.2’de görülmektedir. En yüksek performansa yakın sadece 15 özelliğin kullanıldığı Ensemble modelde %92 doğruluk ve 0,9691 AUC değeri elde edildi. Ayrıca özellik sayısının daha az olduğu 10 özelliğin kullanıldığı Ensemble model ile de %91,1 doğruluk ve 0.96 AUC ile yüksek performanslı sınıflandırma yapılabilirdi. Tablo 7.3, her veri setinde en yüksek performansın elde edildiği modele ait sınıflandırma performans değerlerini göstermektedir. Şekil 7.3 ise bu veri setleri arasından en yüksek performansın elde edildiği 33 özellikli ve daha az özellikle (1, 10 ve 15) en yüksek performansa yakın sınıflandırma performanslarının elde edildiği modellerin ROC eğrilerini göstermektedir.

Tablo 7.3. Tüm ve PCA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları.

Özellik Sayısı	Metot	Doğ. (%)	Duy.	Özg.	Kes.	F-ölç.	Kappa	AUC
1	SVM	89,1	0,8333	0,9314	0,8966	0,8638	0,8838	0,9374
2	Ensemble	88,8	0,8333	0,9268	0,8904	0,8609	0,8810	0,9078
3	NN	89,1	0,8333	0,9314	0,8966	0,8638	0,8838	0,9376
4	Ensemble	88,9	0,8333	0,9291	0,8935	0,8624	0,824	0,9196
5	SVM	89,5	0,8109	0,9542	0,9267	0,8650	0,8882	0,9491
6	NN	89,5	0,8333	0,9382	0,9059	0,8681	0,8881	0,9521
7	Ensemble	90,1	0,8782	0,9176	0,8839	0,8810	0,8950	0,9557
8	Ensemble	90,4	0,8814	0,9199	0,8871	0,8842	0,8978	0,9643
9	kNN	90,5	0,8686	0,9314	0,9003	0,8842	0,8993	0,9619
10	Ensemble	91,1	0,8910	0,9245	0,8939	0,8925	0,9049	0,96
11	Ensemble	90	0,8750	0,9176	0,8835	0,8792	0,8936	0,9612
12	SVM	89,9	0,8397	0,9405	0,9097	0,8733	0,8923	0,9483
13	Ensemble	91,3	0,8910	0,9291	0,8997	0,8953	0,9078	0,9673
14	Ensemble	90,9	0,8718	0,9359	0,9067	0,8889	0,9036	0,9639
15	Ensemble	92	0,8942	0,9382	0,9118	0,9029	0,9149	0,9691

Tablo 7.3. (Devamı) Tüm ve PCA veri setleri ile oluşturulan makine öğrenmesi modellerinin performansları..

Özellik Sayısı	Metot	Doğ. (%)	Duy.	Özg.	Kes.	F-ölç.	Kappa	AUC
16	Ensemble	90,9	0,8814	0,9291	0,8987	0,8900	0,9035	0,9583
17	Ensemble	90,3	0,8397	0,9474	0,9193	0,8777	0,8966	0,9564
18	Ensemble	91,6	0,8782	0,9428	0,9164	0,8969	0,9107	0,9663
19	Ensemble	90,7	0,8622	0,9382	0,9088	0,8849	0,9008	0,968
20	Ensemble	91,1	0,8686	0,9405	0,9125	0,8900	0,9050	0,9677
21	Ensemble	90,4	0,8878	0,9153	0,8822	0,8850	0,8978	0,9641
22	Ensemble	90,9	0,8622	0,9428	0,9150	0,8878	0,9036	0,9642
23	Ensemble	91,7	0,8846	0,9405	0,9139	0,8990	0,9121	0,9707
24	Ensemble	92,1	0,8782	0,9519	0,9288	0,9028	0,9164	0,9733
25	Ensemble	91,1	0,8718	0,9382	0,9097	0,8903	0,9050	0,9581
26	Ensemble	91,5	0,8654	0,9497	0,9247	0,8940	0,9093	0,9651
27	Ensemble	91,6	0,8814	0,9405	0,9136	0,8972	0,9107	0,9694
28	Ensemble	92,1	0,8942	0,9405	0,9148	0,9044	0,9163	0,9669
29	Ensemble	92,3	0,8974	0,9405	0,9150	0,9061	0,9177	0,9697
30	Ensemble	92,3	0,8942	0,9428	0,9178	0,9058	0,9177	0,9694
31	Ensemble	92,1	0,8878	0,9451	0,9203	0,9038	0,9163	0,9701
32	NN	90,7	0,8878	0,9199	0,8878	0,8878	0,9007	0,9538
33	Ensemble	92,7	0,8910	0,9519	0,9298	0,9100	0,9220	0,9685
34	Ensemble	92	0,8942	0,9382	0,9118	0,9029	0,9149	0,9687
35	Ensemble	92,1	0,8814	0,9497	0,9259	0,9031	0,9164	0,9699
36	Ensemble	92	0,8846	0,9451	0,9200	0,9020	0,9149	0,9738
37	Ensemble	91,1	0,8622	0,9451	0,9181	0,8893	0,9051	0,964
38	Ensemble	91,3	0,8942	0,9268	0,8971	0,8957	0,9078	0,9644
39	Ensemble	91,9	0,8846	0,9428	0,9169	0,9005	0,9135	0,9678
40	Ensemble	92	0,8590	0,9634	0,9437	0,8993	0,9150	0,9715
41	Ensemble	91,6	0,8814	0,9405	0,9136	0,8972	0,9107	0,9663
42	Ensemble	92	0,8750	0,9519	0,9286	0,9010	0,9150	0,9692
43	Ensemble	91,5	0,8622	0,9519	0,9276	0,8937	0,9093	0,9652
44	Ensemble	92,7	0,8942	0,9497	0,9269	0,9103	0,9220	0,9708
45	Ensemble	91,7	0,8878	0,9382	0,9112	0,8994	0,9121	0,9659
46	NN	90,7	0,8878	0,9199	0,8878	0,8878	0,9007	0,9578
47	Ensemble	92,4	0,8942	0,9451	0,9208	0,9073	0,9192	0,9676



Şekil 7.3. Fisher özellik seçme algoritması sonucunda oluşturulan 1, 10, 15 ve 33 özellikli modellerin ROC eğrileri.

7.4. LOO Yöntemi Sonuçları

Sınıflandırma performansının bireylerden bağımsız olup olmadığını değerlendirmek için LOO yöntemi kullanıldı. Bu yöntemde, her bireyin verisi sırayla test sürecine alınırken, diğer bireylere ait veriler eğitim için kullanılarak sınıflandırma modelleri oluşturuldu. Bu işlem veri tabanındaki 17 bireyin tamamı için tekrar edildi.

Tablo 7.4, LOO yöntemi ile her bireyin test verisi olarak kullanıldığı modeller arasında en yüksek performansa sahip modellerin sonuçlarını göstermektedir. Buna göre doğruluk oranları %78,8 ile %97,1 arasında, AUC değeri 0,88 ile 1 arasında değişmektedir. Elde edilen performans sonuçları, sınıflandırma başarısının bireylerden bağımsız olarak doğrulandığını göstermektedir.

Tablo 7.4. LOO yöntemi ile sırasıyla her bir bireye ait verilerin test verisi olarak kullanıldığı modeller arasında en yüksek performansı veren modellerin performans değerleri.

Test								
Birey No	Metot	Doğ. (%)	Duy.	Özg.	Kes.	F-ölç.	Kappa	AUC
1	Ensemble	83,5	0,77	0,93	0,94	0,84	0,82	0,94
2	SVM	89	0,78	0,94	0,86	0,82	0,88	0,97
3	Ensemble	96,8	0,97	0,97	0,94	0,95	0,97	0,99
4	Ensemble	95,5	0,87	1,00	1,00	0,93	0,95	0,97
5	kNN	94	0,95	0,93	0,92	0,93	0,94	0,97
6	Ensemble	92,5	0,98	0,89	0,87	0,92	0,92	0,97
7	Ensemble	79,5	0,91	0,75	0,59	0,71	0,78	0,88
8	SVM	86,3	0,71	0,97	0,94	0,81	0,86	0,94
9	SVM	81,3	0,89	0,78	0,64	0,75	0,80	0,93
10	NN	82,9	0,81	0,86	0,93	0,87	0,82	0,89
11	Ensemble	97,1	0,96	0,98	0,98	0,97	0,97	0,98
12	Ensemble	96	0,92	1,00	1,00	0,96	0,96	0,99
13	Ensemble	96,2	0,90	1,00	1,00	0,95	0,96	1,00
14	kNN	96	0,86	1,00	1,00	0,92	0,96	0,96
15	Ensemble	78,8	0,86	0,77	0,50	0,63	0,78	0,92
16	Ensemble	96,7	0,91	1,00	1,00	0,95	0,96	1,00
17	SVM	88,5	0,84	0,93	0,93	0,88	0,88	0,94
Ortalama		90,04	0,87	0,92	0,88	0,87	0,89	0,96

7.5. Bruksizmin Kontrol Grubundaki Her Bir Etiketten Ayrılma Performansları

Bruksizm verilerinin kontrol grubundaki farklı etiketlerden (mikro uyarılma, RERA ve PLM uyarılma) ne kadar iyi ayrılabilmesini değerlendirmek için üç ek sınıflandırma daha yapıldı. Bu sınıflandırmalarda, veri miktarının bruksizm ve kontrol grubu arasında dengeli olmasını sağlamak için sistematik örnekleme yöntemi kullanıldı. Böylece her bireyden veri seçilebildi.

Bu kapsamda:

- 563 mikro uyarılma verisi için 560 bruksizm verisi,
- 189 RERA verisi için 186 bruksizm verisi,
- 123 PLM uyarılma verisi için 124 bruksizm verisi seçildi.

Üç sınıflandırma için de dört makine öğrenme yöntemini kullanarak modeller oluşturuldu. En yüksek performansa sahip modellerin sınıflandırma performans değerleri Tablo 7.5'te ve ROC eğrileri Şekil 7.4'te görülmektedir.

Elde edilen sonuçlara göre Ensemble yönteminde:


- Bruksizm mikro uyarılmadan %93 doğruluk ile,

- Bruksizm RERA'dan %89,3 doğruluk ile,
- Bruksizm PLM uyarılma %87 doğruluk ile ayrılabilir.

Bu bulgular, kontrol verilerinin farklı etiketlerinden bağımsız olarak, bruksizmin başarılı bir şekilde de ayrılabilirliğini ve bruksizm - kontrol sınıflandırmasının her bir etiket için genellenebilir olduğunu göstermektedir.

Tablo 7.5. Bruksizm - mikro uyarılma, bruksizm - RERA ve bruksizm - PLM uyarılma veri setleri kullanılarak oluşturulan modeller arasında en yüksek performans gösteren modellerin performans değerleri.

	Veri Setleri		
	Bruksizm - Mikro Uyarılma	Bruksizm - RERA	Bruksizm - PLM Uyarılma
Veri Miktarı	560 - 563	186 - 189	124 - 123
Özellik Sayısı	47	47	47
Metot	Ensemble	Ensemble	Ensemble
Doğruluk (%)	93	89,3	87
Duyarlılık	0,9179	0,8387	0,8065
Özgüllük	0,9431	0,9468	0,9344
Kesinlik	0,9414	0,9398	0,9259
F-ölçümü	0,9295	0,8864	0,8621
Kappa	0,9259	0,8860	0,8614
AUC	0,9789	0,9516	0,9392



Şekil 7.4. Bruksizm - mikro uyarılma, bruksizm - RERA ve bruksizm - PLM uyarılma veri setleri ile en yüksek performans gösteren sınıflandırma modellerinin ROC eğrileri.



8. TARTIřMA VE ÖNERİLER

Bruksizm bireyin günlük yaşamını olumsuz etkiler. Bruksizmi olan bireylerde uykusuzluk, baş ağrısı, diş dokusunda bozulma ve çene ağrısı sıkça görülmektedir. Ayrıca, diş ve çene yapısındaki estetik farklılıklar, bireylerin kendileri hakkında olumsuz düşünceler geliřtirmesine neden olabilmektedir. Uyku bozukluęu olan bireylerde bruksizm görölme olasılıęı daha yüksek olsa da, birbirlerini nasıl etkiledikleri konusunda hala kesin bir bilgi yoktur (Da Costa Lopes vd., 2020; Maluly vd., 2020; Tan vd., 2019).

Bruksizmin erken teřhisi ve uygun tedavinin bařlatılması, bireyin yaşam kalitesini artırarak uyku bozukluklarının etkilerini hafifletebilir. Bu nedenle, hızlı, pratik ve güvenilir bir teřhis sistemi geliřtirilmesi büyük önem taşımaktadır.

PSG, bruksizmin kesin tanısını saęlayabilen bir yöntemdir. PSG ile bruksizm tanısı AASM kriterlerine göre konulur. Kamera ve ses kayıtlarıyla desteklenen bu yöntem güvenilirdir. Ancak PSG'nin, yüksek maliyetli ve zaman alıcı olması, bruksizmin erken teřhisi için daha erişilebilir bir yöntemin geliřtirilmesini zorunlu kılmaktadır. Bu bağlamda AI tabanlı sistemlerin kullanımı giderek daha önemli hale gelmektedir.

Bu çalışmanın temel amacı bruksizmi kontrol etiketlerinden ayırt etmektir. Bu doğrultuda, farklı bruksizm türleri (fazik, tonik ve karışık) ayrı ayrı incelenmek yerine, “bruksizm” etiketi altında birleřtirildi. Literatürde, bruksizmin genel tanısının yeterli olduęu, alt türlere ayrılmadan deęerlendirilebileceęi belirtilmiřtir (Lavigne vd., 2008; Manfredini vd., 2013). Alt tiplendirme, çene kaslarına odaklanan çalışmalar için deęerlidir (Lavigne vd., 2008). Bruksizm tedavi yaklařımları genellikle tüm bruksizimli bireyler için benzer olduęundan (Carra vd., 2012; Manfredini vd., 2013), alt türlerin ayrı ayrı deęerlendirilmesi istatistiksel sorunlara yol açabilir (Guyon & Elisseff, 2003). Etiketlerin birleřtirilmesi, daha büyük bir veri setiyle çalışmayı mümkün kılarak AI tabanlı bir teřhis modelinin genelleme kapasitesini ve performansını artırabilir (Cai vd., 2018).

Bruksizm teřhisi, öznel yorumlara açık bir süreçtir. Birden fazla uzmanın deęerlendirme yapması, teřhis kararlarının tutarlılıęını artırırken hata olasılıęını

azaltabilir (J.-B. Martinot vd., 2021). Bu noktada, AI tabanlı karar destek sistemleri, insan hatalarını minimize ederek objektif teşhis yapılmasına yardımcı olabilir. AI tabanlı teşhis sistemlerinin önemi giderek artmaktadır (Bin Heyat vd., 2020; Heyat vd., 2019; Melekoglu vd., 2022; Suhaib Kidwai & Zunnun Khan, 2021; Uçar vd., 2020). Bu sistemler, klasik makine öğrenmesi ve derin öğrenme yöntemlerini kullanmaktadır. Derin öğrenme yöntemleri genellikle daha yüksek sınıflandırma başarısı elde etse de, bu yöntemde gizli katman sayısının fazla olması, hesaplama yükünü artırmakta ve çalışma sürelerini uzatmaktadır. Karmaşık hesaplamalar için yüksek işlem kapasitesine sahip bilgisayarlara ihtiyaç duyulması, derin öğrenmenin günlük hayatta uygulanabilirliğini sınırlayabilmektedir (Melekoglu vd., 2022). Öte yandan, klasik makine öğrenmesi algoritmaları, hem hızlı çalıştıkları hem de düşük işlem kapasitesine sahip bilgisayarlarda kullanılabildikleri için günlük hayatta daha uygulanabilir. Bu çalışmada, klasik makine öğrenmesi algoritması kullanılarak yüksek doğrulukta performans sunan bir model önerilmektedir.

Bruksizmi teşhis etmek için ilk kez PPG ve PPG'den elde edilen HRV kullanılarak, AI tabanlı model geliştirildi. PPG'den 38 karakteristik ve 29 istatistiksel ve HRV'den 29 istatistiksel özellik çıkarılarak bir veritabanı oluşturuldu. PCA yöntemi ile, özellik sayısı 96'dan 47'ye düşürülerek, veritabanı %100 temsil edildi. En az özellik ile en yüksek performans elde etmek için Fisher özellik seçme yöntemi kullanılarak modeller oluşturuldu. Modellerin güvenilirliğini artırmak için hiperparametre optimizasyonu ve 5 kat çapraz doğrulama uygulandı. Modeller görülmeyen veriler kullanarak test edildi. Modellerin performans değerlendirmesi yapılırken doğruluk, duyarlılık, özgüllük, kesinlik, F-ölçümü, kappa ve AUC parametreleri kullanıldı.

Bruksizm-kontrol sınıflandırması, SA ve SA olmayan bireyler üzerinden de test edildi ve genel model performansının bu durumdan bağımsız olduğu görüldü. LOO yöntemi kullanılarak yapılan testlerde, her birey bağımsız olarak sınıflandırıldı ve böylece genel model performansının bireylere bağlı olmadığı görüldü. Bruksizm, kontrol verilerindeki üç uyarılma ile ayrı ayrı sınıflandırıldı ve böylece genel model performansının kontrol verilerindeki her uyarılma için geçerli olduğu doğrulandı.

PPG ve HRV'den çıkarılan özellikleri kullanarak bruksizm başarıyla tespit edildi. Fisher özellik seçme yöntemi ile belirlenen en uygun özellikler, PPG ve HRV'nin özelliklerinin, biyobelirteç olarak bruksizm teşhisinde etkin rol oynadığını ortaya koymuştur. Bu özellikler sırasıyla 86, 95, 94, 67, 3, 57, 82, 30, 15, 66, 17, 92, 96, 77,

65, 76, 74, 75, 27, 29, 35, 48, 83, 84, 47, 31, 34, 12, 36, 11, 59, 20 ve 73 numaralı özelliklerdir. Sonuçlar, PPG ve HRV'den çıkarılan özelliklerin birlikte kullanılmasının teşhis performansını artırdığını göstermektedir.

HRV, EKG ya da PPG'den elde edilebilmektedir. Bu çalışmada kullanılan HRV verileri, PPG'den elde edilmiştir. Kontrollü solunum sırasında, EKG ve PPG'den elde edilen HRV indeksleri arasında önemli farklılıklar olduğu bilinmektedir (Jan vd., 2019). Ancak, uyku sırasında bireylerin solunum düzenleri kontrol edilemediği için, bu çalışmada elde edilen fizyolojik veriler spontane solunum koşullarında kaydedilmiştir. Bu sayede, çalışmanın gerçekçi sonuçlar üretmesine olanak sağlamıştır.

Uyku sırasında solunum hareketleri, otonom sinir sistemi tarafından doğal olarak düzenlenir. SA gibi durumlarda solunum düzensizlikleri görülse de, bu düzensizlikler spontane solunumun doğal bir sonucu olarak kabul edilir. Bu nedenle, uyku sırasında kaydedilen PPG veya HRV verileri, doğal ve kesintisiz solunum düzenine dayanır (Berry vd., 2017; Goldberger vd., 2008).

AI tabanlı brüksizm teşhis sistemlerinde PSG'ye alternatif olarak EMG, EEG ve EKG kullanılmaktadır (Bin Heyat vd., 2020; Castroflorio vd., 2013; Heyat vd., 2019; Lai vd., 2019; J. Martinot vd., 2020; J.-B. Martinot vd., 2021; Sonmezocak & Kurt, 2021; Tiwari vd., 2024). Ancak, bu yöntemler elektrot bağlantıları gerektirdiği için pratik kullanım sınırlıdır. Taşınabilir sensör ve ağız içi aparatlar, brüksizm teşhisinde kullanılan alternatifler arasındadır. Piezoelektrik sensörler ve çene hareket dedektörleri içeren özelleşmiş plaklar, diş sıkma hareketlerini kaydeder. Ancak, bu cihazlar günlük kullanımda konfor açısından sınırlamalar getirmektedir.

Öte yandan, PPG, parmak ucu veya vücuttaki diğer kılcal damar bölgelerinden elektrot bağlantısı olmadan kolayca elde edilebilir. Bu çalışmada, HRV doğrudan PPG'den elde edilerek ek bir elektrot veya kablo bağlantısı gereksinimini ortadan kaldırıldı. PPG tabanlı HRV ölçümü, kişinin konforunu artırırken, brüksizm teşhisi için gerçek zamanlı sistemlere entegrasyonu kolaylaştırmaktadır.

PPG'den çıkarılan özellikler, çeşitli hastalıkların teşhisinde yaygın olarak kullanılmaktadır. Özen Kavas ve ark. (2023) PPG'den 37, Melekoğlu ve ark. (2022) 25, Ferizoli ve ark. (2024) 5, Gupta ve ark. (2022) ise 16 özellik çıkarmıştır (Ferizoli vd., 2024; Gupta vd., 2022; Melekoğlu vd., 2022; Özen Kavas vd., 2023). Yeni ve

etkili biyobelirteçler keşfetmek için sinyallerden mümkün olduğunca fazla özellik çıkarmak önemlidir. Bu çalışmada, bruksizmi teşhis etmek için PPG'den 67 ve HRV'den 29 özellik çıkarıldı.

En yüksek sınıflandırma performansı, 33 özellik kullanılarak elde edildi. Ancak, özellik sayısı 15'e ve 10'a düşürüldüğünde, performans önemli ölçüde azalmadı, dolayısıyla daha az özellik ile de etkili sınıflandırmalar yapılabildiği görüldü. En önemli özellikler sırasıyla 86, 95, 94, 67, 3, 57, 82, 30, 15 ve 66 numaralı özelliklerdir.

Birinci (86. özellik) ve altıncı (57. özellik) özellikler, HRV ve PPG'nin istatistiksel özellikleri olan Tekil Değer Ayrışımı (SVD)'dir. Sadece HRV'nin SVD özelliği kullanıldığında, %89,1 doğruluk ve 0,9374 AUC ile yüksek performanslı sınıflandırma gerçekleştirildi. Bu sonuçlar, SVD değerinin bruksizmi kontrol verilerinden ayırt etmede önemli bir biyobelirteç olduğunu göstermektedir.

3, 30 ve 15 numaralı özellikler, PPG'nin karakteristik özellikleridir. Literatürde, bruksizm sırasında kalp atış hızında değişiklikler olduğu bildirilmektedir (Lu vd., 2021; Macaluso vd., 1998). 3 numaralı özellik, PPG'nin düşen kenar süresini, 4 numaralı özellik (özellik 30'u elde etmek için kullanılan) ise yükselen kenar süresini temsil etmektedir. 3 ve 4 numaralı özelliklerin toplamı, PPG'nin periyodunu vermektedir. PPG periyodu, kalp atış hızı ile ilişkili olduğundan literatürdeki bilgiyi desteklemektedir ve bruksizm teşhisi için önemli biyobelirteçtir.

30 ve 15 numaralı özellikler, diğer özelliklerin oranlanmasıyla elde edildi. Oranlanan özelliklerin ortak yönleri incelendiğinde, PPG'nin düşen ve yükselen kenar sürelerinin %25 ve %75'indeki genlik değerleri ile ilişkili oldukları görülmektedir. Bu nedenle, düşen kenar ve yükselen kenar süreleri ve bu sürelerin %25 ve %75'indeki genlik değerleri de bruksizm teşhisi için önemli diğer biyobelirteçlerdir.

Hiperparametre optimizasyonu ve çapraz doğrulama kullanılarak en iyi performans kriterlerine göre değerlendirilen modeller, gelecekteki çalışmalarda ve bruksizmin klinik teşhisinde kullanılabilir. Bu durum, literatüre hem uygulama hem de yöntem açısından yenilik getirecek olup, bruksizmin pratik ve güvenilir şekilde teşhis edilmesine olanak sağlayacaktır.

Bu çalışmada, veri etiketleme süreci, uyku bozuklukları konusunda deneyimli, daha önce uyku laboratuvarında çalışmış ve uyku kayıtlarının incelendiği yazılımı kullanmış bir uzman hekim tarafından gerçekleştirildi. Ancak, etiketleme sürecinde

tek bir uzman yer aldığı için öznel hatalar oluşma riski bulunmaktadır. İnsan hatasını azaltmak amacıyla, etiketleme süreci birden fazla uzman tarafından doğrulanmalıdır.

Makine öğrenimi modellerinin performansı, artan örneklem büyüklüğü ile iyileşebilir. Daha büyük veri setleri ile modellerin genelleme yeteneği artırılabilir. Bu çalışmada 1498 adet etiketli veri kullanıldı. LOO ve 5 kat çapraz doğrulama yöntemleri kullanılarak, örneklem büyüklüğünün olası etkileri minimize edilmeye çalışıldı. Daha büyük veri setleri ile modellerin güvenilirliği ve genelleme kabiliyeti artırılabilir.

Önerilen model, PSG'nin sınırlamalarını ve dezavantajlarını aşarak yüksek performanslı bir sınıflandırma sunmaktadır. Çalışmada kullanılan metodoloji ve PPG ile HRV'nin kolayca elde edilebilmesi, önerilen modelin gömülü sistemlere entegrasyonunu mümkün kılmaktadır. Ayrıca, önerilen modelin klinik değerlendirme süreçlerinde kullanılması önemli avantajlar sunmaktadır.

Bu çalışma, literatüre yenilikçi bir bakış açısı kazandırmakta olup, gelecek araştırmalar için önemli bir referans niteliğindedir.



KAYNAKLAR

- Ainoosah, S., Farghal, A. E., Alzemei, M. S., Saini, R. S., Gurumurthy, V., Quadri, S. A., Okshah, A., Mosaddad, S. A., & Heboyan, A. (2024). Comparative analysis of different types of occlusal splints for the management of sleep bruxism: A systematic review. *BMC Oral Health*, 24(1), 29. <https://doi.org/10.1186/s12903-023-03782-6>
- Altman, N. S. (1992). An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression. *The American Statistician*, 46(3), 175-185. <https://doi.org/10.1080/00031305.1992.10475879>
- Amemori, Y., Yamashita, S., Ai, M., Shinoda, H., Sato, M., & Takahashi, J. (2001). Influence of nocturnal bruxism on the stomatognathic system. Part I: A new device for measuring mandibular movements during sleep. *Journal of Oral Rehabilitation*, 28(10), 943-949. <https://doi.org/10.1111/j.1365-2842.2001.00757.x>
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4(none). <https://doi.org/10.1214/09-SS054>
- Baad-Hansen, L., Thymi, M., Lobbezoo, F., & Svensson, P. (2019). To what extent is bruxism associated with musculoskeletal signs and symptoms? A systematic review. *Journal of Oral Rehabilitation*, 46(9), 845-861. <https://doi.org/10.1111/joor.12821>
- Babayigit, O., Büyükkalaycı, F. N., & Altun, S. (2024). The interplay of academic procrastination, self-generated stress, and self-reported bruxism among medical and dental students: A cross-sectional study. *BMC Psychology*, 12(1), 586. <https://doi.org/10.1186/s40359-024-02105-w>
- Bahammam, H. A. (2022). Validation of Sleep Bruxism Questionnaire Toward the Experience of Jaw Pain and Limitation of Jaw Movement in Saudi Arabian Adolescents. *Cureus*. <https://doi.org/10.7759/cureus.26120>
- Beddis, H., Pemberton, M., & Davies, S. (2018). Sleep bruxism: An overview for clinicians. *British Dental Journal*, 225(6), 497-501. <https://doi.org/10.1038/sj.bdj.2018.757>
- Bengio, Y., & Grandvalet, Y. (2004). No Unbiased Estimator of the Variance of K-Fold Cross-Validation. *Journal of Machine Learning Research*, 5(Sep), 1089-1105.
- Berry, R. B., Brooks, R., Gamaldo, C., Harding, S. M., Lloyd, R. M., Quan, S. F., Troester, M. T., & Vaughn, B. V. (2017). AASM Scoring Manual Updates for 2017 (Version 2.4). *Journal of Clinical Sleep Medicine*, 13(05), 665-666. <https://doi.org/10.5664/jcsm.6576>

- Beyer, K., Goldstein, J., Ramakrishnan, R., & Shaft, U. (1999). When Is “Nearest Neighbor” Meaningful? İçinde C. Beeri & P. Buneman (Ed.), *Database Theory—ICDT’99* (C. 1540, ss. 217-235). Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-49257-7_15
- Bezerra, I. M., Brito, A. C. M., Martins, M. L., De Sousa, S. A., De Medeiros Serpa, E. B., Santiago, B. M., De Fátima Dantas De Almeida, L., & Cavalcanti, Y. W. (2021). Does bruxism impact the quality of life of children and adolescents? A systematic review and meta-analysis. *Journal of Public Health*, 29(3), 571-578. <https://doi.org/10.1007/s10389-019-01151-8>
- Bin Heyat, M. B., Akhtar, F., Khan, A., Noor, A., Benjdira, B., Qamar, Y., Abbas, S. J., & Lai, D. (2020). A Novel Hybrid Machine Learning Classification for the Detection of Bruxism Patients Using Physiological Signals. *Applied Sciences*, 10(21), 7410. <https://doi.org/10.3390/app10217410>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bozkurt, F., Uçar, M. K., Bilgin, C., & Zengin, A. (2021). Sleep–wake stage detection with single channel ECG and hybrid machine learning model in patients with obstructive sleep apnea. *Physical and Engineering Sciences in Medicine*, 44(1), 63-77. <https://doi.org/10.1007/s13246-020-00953-5>
- Bozkurt, F., Uçar, M. K., Bozkurt, M. R., & Bilgin, C. (2020). Detection of Abnormal Respiratory Events with Single Channel ECG and Hybrid Machine Learning Model in Patients with Obstructive Sleep Apnea. *IRBM*, 41(5), 241-251. <https://doi.org/10.1016/j.irbm.2020.05.006>
- Bozkurt, M. R., Uçar, M. K., Bozkurt, F., & Bilgin, C. (2019). In obstructive sleep apnea patients, automatic determination of respiratory arrests by photoplethysmography signal and heart rate variability. *Australasian Physical & Engineering Sciences in Medicine*, 42(4), 959-979. <https://doi.org/10.1007/s13246-019-00796-9>
- Branco, S., Ferreira, A. G., & Cabral, J. (2019). Machine Learning in Resource-Scarce Embedded Systems, FPGAs, and End-Devices: A Survey. *Electronics*, 8(11), 1289. <https://doi.org/10.3390/electronics8111289>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Brink-Kjaer, A., Olesen, A. N., Peppard, P. E., Stone, K. L., Jennum, P., Mignot, E., & Sorensen, H. B. D. (2020). Automatic detection of cortical arousals in sleep and their contribution to daytime sleepiness. *Clinical Neurophysiology*, 131(6), 1187-1203. <https://doi.org/10.1016/j.clinph.2020.02.027>
- Bulanda, S., Ilczuk-Rypuła, D., Nitecka-Buchta, A., Nowak, Z., Baron, S., & Postek-Stefańska, L. (2021). Sleep Bruxism in Children: Etiology, Diagnosis, and Treatment—A Literature Review. *International Journal of Environmental Research and Public Health*, 18(18), 9544. <https://doi.org/10.3390/ijerph18189544>
- Cai, J., Luo, J., Wang, S., & Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70-79. <https://doi.org/10.1016/j.neucom.2017.11.077>

- Carra, M. C., Huynh, N., & Lavigne, G. (2012). Sleep Bruxism: A Comprehensive Overview for the Dental Clinician Interested in Sleep Medicine. *Dental Clinics of North America*, 56(2), 387-413. <https://doi.org/10.1016/j.cden.2012.01.003>
- Castelo, P. M., Barbosa, T. S., & Gavião, M. B. D. (2010). Quality of life evaluation of children with sleep bruxism. *BMC Oral Health*, 10(1), 16. <https://doi.org/10.1186/1472-6831-10-16>
- Castroflorio, T., Mesin, L., Tartaglia, G. M., Sforza, C., & Farina, D. (2013). Use of Electromyographic and Electrocardiographic Signals to Detect Sleep Bruxism Episodes in a Natural Environment. *IEEE Journal of Biomedical and Health Informatics*, 17(6), 994-1001. <https://doi.org/10.1109/JBHI.2013.2274532>
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27. <https://doi.org/10.1109/TIT.1967.1053964>
- Da Costa Lopes, A. J., Cunha, T. C. A., Monteiro, M. C. M., Serra-Negra, J. M., Cabral, L. C., & Júnior, P. C. S. (2020). Is there an association between sleep bruxism and obstructive sleep apnea syndrome? A systematic review. *Sleep and Breathing*, 24(3), 913-921. <https://doi.org/10.1007/s11325-019-01919-y>
- Da Silva, M. D. F., Vedovello, S. A. S., Vedovello Filho, M., Venezian, G. C., Valdrighi, H. C., & Degan, V. V. (2017). Temporomandibular disorders and quality of life among 12-year-old schoolchildren. *CRANIO®*, 35(6), 392-396. <https://doi.org/10.1080/08869634.2016.1248590>
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. İçinde G. Goos, J. Hartmanis, & J. Van Leeuwen (Eds.), *Multiple Classifier Systems* (C. 1857, ss. 1-15). Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-45014-9_1
- Ding, X., Yan, B. P., Zhang, Y.-T., Liu, J., Zhao, N., & Tsang, H. K. (2017). Pulse Transit Time Based Continuous Cuffless Blood Pressure Estimation: A New Extension and A Comprehensive Evaluation. *Scientific Reports*, 7(1), 11554. <https://doi.org/10.1038/s41598-017-11507-3>
- Elgendi, M. (2016). Eventogram: A Visual Representation of Main Events in Biomedical Signals. *Bioengineering*, 3(4), 22. <https://doi.org/10.3390/bioengineering3040022>
- EniNanç, İ. (2023). Evaluation of Risk Factors Associated with Bruxism in Adult Turkish Population. *Cumhuriyet Dental Journal*, 26(2), 188-193. <https://doi.org/10.7126/cumudj.1304333>
- Eriş, Ö., Bulut Eriş, S., Bilgin, C., & Bozkurt, M. R. (2021). IIR Based Digital Filter Design for Denoising the Photoplethysmography Signal. *2021 29th Signal Processing and Communications Applications Conference (SIU)*, 1-4. <https://doi.org/10.1109/SIU53274.2021.9477993>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>

- Ferizoli, R., Karimpour, P., May, J. M., & Kyriacou, P. A. (2024). Arterial stiffness assessment using PPG feature extraction and significance testing in an in vitro cardiovascular system. *Scientific Reports*, 14(1), 2024. <https://doi.org/10.1038/s41598-024-51395-y>
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 119-139. <https://doi.org/10.1006/jcss.1997.1504>
- Fröhlich, F. (2016). Low-Frequency Oscillations. İçinde *Network Neuroscience* (ss. 231-242). Elsevier. <https://doi.org/10.1016/B978-0-12-801560-5.00017-3>
- Gao, J., Liu, L., Gao, P., Zheng, Y., Hou, W., & Wang, J. (2019). Intelligent Occlusion Stabilization Splint with Stress-Sensor System for Bruxism Diagnosis and Treatment. *Sensors*, 20(1), 89. <https://doi.org/10.3390/s20010089>
- Goldberger, J. J., Cain, M. E., Hohnloser, S. H., Kadish, A. H., Knight, B. P., Lauer, M. S., Maron, B. J., Page, R. L., Passman, R. S., Siscovick, D., Stevenson, W. G., & Zipes, D. P. (2008). American Heart Association/American College of Cardiology Foundation/Heart Rhythm Society Scientific Statement on Noninvasive Risk Stratification Techniques for Identifying Patients at Risk for Sudden Cardiac Death: A Scientific Statement From the American Heart Association Council on Clinical Cardiology Committee on Electrocardiography and Arrhythmias and Council on Epidemiology and Prevention. *Circulation*, 118(14), 1497-1518. <https://doi.org/10.1161/CIRCULATIONAHA.107.189375>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT press.
- Gouw, S., De Wijer, A., Bronkhorst, E. M., Kalaykova, S. I., & Creugers, N. H. J. (2019). Association between self-reported bruxism and anger and frustration. *Journal of Oral Rehabilitation*, 46(2), 101-108. <https://doi.org/10.1111/joor.12727>
- Gras, R., & Kuntz, P. (2008). An overview of the Statistical Implicative Analysis (SIA) development. İçinde R. Gras, E. Suzuki, F. Guillet, & F. Spagnolo (Ed.), *Statistical Implicative Analysis* (C. 127, ss. 11-40). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-78983-3_1
- Guaïta, M., & Högl, B. (2016). Current Treatments of Bruxism. *Current Treatment Options in Neurology*, 18(2), 10. <https://doi.org/10.1007/s11940-016-0396-3>
- Gupta, S., Singh, A., Sharma, A., & Tripathy, R. K. (2022). dSVRI: A PPG-Based Novel Feature for Early Diagnosis of Type-II Diabetes Mellitus. *IEEE Sensors Letters*, 6(9), 1-4. <https://doi.org/10.1109/LSSENS.2022.3203609>
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, 3(Mar), 1157-1182.
- Haibo He, & Garcia, E. A. (2009). Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263-1284. <https://doi.org/10.1109/TKDE.2008.239>
- Halász, P., Terzano, M., Parrino, L., & Bódizs, R. (2004). The nature of arousal in sleep. *Journal of Sleep Research*, 13(1), 1-23. <https://doi.org/10.1111/j.1365-2869.2004.00388.x>

- Han, D., Bashar, S. K., Lázaro, J., Mohagheghian, F., Peitzsch, A., Nishita, N., Ding, E., Dickson, E. L., DiMezza, D., Scott, J., Whitcomb, C., Fitzgibbons, T. P., McManus, D. D., & Chon, K. H. (2022). A Real-Time PPG Peak Detection Method for Accurate Determination of Heart Rate during Sinus Rhythm and Cardiac Arrhythmia. *Biosensors*, 12(2), 82. <https://doi.org/10.3390/bios12020082>
- Han, H., Seong, M. J., Hyeon, J., Joo, E., & Oh, J. (2024). Classification and automatic scoring of arousal intensity during sleep stages using machine learning. *Scientific Reports*, 14(1), 5983. <https://doi.org/10.1038/s41598-023-50653-9>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>
- Heyat, M. B. B., Lai, D., Khan, F. I., & Zhang, Y. (2019). Sleep Bruxism Detection Using Decision Tree Method by the Combination of C4-P4 and C4-A1 Channels of Scalp EEG. *IEEE Access*, 7, 102542-102553. <https://doi.org/10.1109/ACCESS.2019.2928020>
- Hirshkowitz, M. (2012). Introduction to Sleep Medicine Diagnostics in Adults. İçinde *Therapy in Sleep Medicine* (ss. 28-40). Elsevier. <https://doi.org/10.1016/B978-1-4377-1703-7.10003-9>
- Hublin, C., Kaprio, J., Partinen, M., & Koskenvuo, M. (1998). Sleep bruxism based on self-report in a nationwide twin cohort. *Journal of Sleep Research*, 7(1), 61-67. <https://doi.org/10.1046/j.1365-2869.1998.00091.x>
- Huynh, N., Lavigne, G. J., Okura, K., Yao, D., & Adachi, K. (2011). Chapter 55—Sleep bruxism. İçinde P. Montagna & S. Chokroverty (Ed.), *Sleep Disorders Part II* (C. 99, ss. 901-911). Elsevier. <https://doi.org/10.1016/B978-0-444-52007-4.00014-X>
- Iber, Sonia, A.-I., Chesson, A.L., & Quan, Stuart F. (2007). *The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications* | Request PDF. ResearchGate. https://www.researchgate.net/publication/285881487_The_AASM_Manual_for_the_Scoring_of_Sleep_and_Associated_Events_Rules_Terminology_and_Technical_Specifications
- Jan, H.-Y., Chen, M.-F., Fu, T.-C., Lin, W.-C., Tsai, C.-L., & Lin, K.-P. (2019). Evaluation of Coherence Between ECG and PPG Derived Parameters on Heart Rate Variability and Respiration in Healthy Volunteers With/Without Controlled Breathing. *Journal of Medical and Biological Engineering*, 39(5), 783-795. <https://doi.org/10.1007/s40846-019-00468-9>
- Jeyhani, V., Mahdiani, S., Peltokangas, M., & Vehkaoja, A. (2015). Comparison of HRV parameters derived from photoplethysmography and electrocardiography signals. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 5952-5955. <https://doi.org/10.1109/EMBC.2015.7319747>
- Jones, D. P. (1987). Medical electro-optics: Measurements in the human microcirculation. *Physics in Technology*, 18(2), 79-85. <https://doi.org/10.1088/0305-4624/18/2/305>

- Karmakar, C., Khandoker, A., Penzel, T., Schobel, C., & Palaniswami, M. (2014). Detection of Respiratory Arousals Using Photoplethysmography (PPG) Signal in Sleep Apnea Patients. *IEEE Journal of Biomedical and Health Informatics*, 18(3), 1065-1073. <https://doi.org/10.1109/JBHI.2013.2282338>
- Kato, T., Dal-Fabbro, C., & Lavigne, G. J. (2003). Current knowledge on awake and sleep bruxism: Overview. *The Alpha Omegan*, 96(2), 24-32.
- Kavas, P. O., Bozkurt, M. R., Kocayigit, I., & Bilgin, C. (2022). A New Medical Decision Support System for Diagnosing HFrEF and HFpEF Using ECG and Machine Learning Techniques. *IEEE Access*, 10, 107283-107292. <https://doi.org/10.1109/ACCESS.2022.3213065>
- Khoury, S., Carra, M. C., Huynh, N., Montplaisir, J., & Lavigne, G. J. (2016). Sleep Bruxism-Tooth Grinding Prevalence, Characteristics and Familial Aggregation: A Large Cross-Sectional Survey and Polysomnographic Validation. *Sleep*, 39(11), 2049-2056. <https://doi.org/10.5665/sleep.6242>
- Kostka, P. S., & Tkacz, E. J. (2015). Multi-sources data analysis with sympatho-vagal balance estimation toward early bruxism episodes detection. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 6010-6013. <https://doi.org/10.1109/EMBC.2015.7319761>
- Kün-Darbois, J.-D., Libouban, H., & Chappard, D. (2015). Botulinum toxin in masticatory muscles of the adult rat induces bone loss at the condyle and alveolar regions of the mandible associated with a bone proliferation at a muscle enthesis. *Bone*, 77, 75-82. <https://doi.org/10.1016/j.bone.2015.03.023>
- Lai, D., Heyat, M. B. B., Khan, F. I., & Zhang, Y. (2019). Prognosis of Sleep Bruxism Using Power Spectral Density Approach Applied on EEG Signal of Both EMG1-EMG2 and ECG1-ECG2 Channels. *IEEE Access*, 7, 82553-82562. <https://doi.org/10.1109/ACCESS.2019.2924181>
- Lal, S. J., Sankari, A., & Weber, D. D. S. (2025). Bruxism Management. İçinde *StatPearls*. StatPearls Publishing. <http://www.ncbi.nlm.nih.gov/books/NBK482466/>
- Lambert, I., & Peter-Derex, L. (2023). Spotlight on Sleep Stage Classification Based on EEG. *Nature and Science of Sleep, Volume 15*, 479-490. <https://doi.org/10.2147/NSS.S401270>
- Lavigne, G. J., Khoury, S., Abe, S., Yamaguchi, T., & Raphael, K. (2008). Bruxism physiology and pathology: An overview for clinicians*. *Journal of Oral Rehabilitation*, 35(7), 476-494. <https://doi.org/10.1111/j.1365-2842.2008.01881.x>
- Lavigne, G. J., & Montplaisir, J. Y. (1994). Restless legs syndrome and sleep bruxism: Prevalence and association among Canadians. *Sleep*, 17(8), 739-743.
- Lee, C., Sik Shin, H., & Lee, M. (2011). Relations between ac-dc components and optical path length in photoplethysmography. *Journal of Biomedical Optics*, 16(7), 077012. <https://doi.org/10.1117/1.3600769>
- Levy, P. S., & Lemeshow, S. (2008). *Sampling of Populations: Methods and Applications* (1. bs). Wiley. <https://doi.org/10.1002/9780470374597>

- Li, C., & Xu, J. (2019). Feature selection with the Fisher score followed by the Maximal Clique Centrality algorithm can accurately identify the hub genes of hepatocellular carcinoma. *Scientific Reports*, 9(1), 17283. <https://doi.org/10.1038/s41598-019-53471-0>
- Li, D., Aarab, G., Lobbezoo, F., Arcache, P., Lavigne, G. J., & Huynh, N. (2022). Accuracy of sleep bruxism scoring based on electromyography traces of different jaw muscles in individuals with obstructive sleep apnea. *Journal of Clinical Sleep Medicine*, 18(6), 1609-1615. <https://doi.org/10.5664/jcsm.9940>
- Liang, Y., Chen, Z., Ward, R., & Elgendi, M. (2018a). Hypertension Assessment Using Photoplethysmography: A Risk Stratification Approach. *Journal of Clinical Medicine*, 8(1), 12. <https://doi.org/10.3390/jcm8010012>
- Liang, Y., Elgendi, M., Chen, Z., & Ward, R. (2018b). An optimal filter for short photoplethysmogram signals. *Scientific Data*, 5(1), 180076. <https://doi.org/10.1038/sdata.2018.76>
- Liu, J., Yan, B. P., Zhang, Y.-T., Ding, X.-R., Su, P., & Zhao, N. (2019). Multi-Wavelength Photoplethysmography Enabling Continuous Blood Pressure Measurement With Compact Wearable Electronics. *IEEE Transactions on Biomedical Engineering*, 66(6), 1514-1525. <https://doi.org/10.1109/TBME.2018.2874957>
- Lobbezoo, F., Ahlberg, J., Glaros, A. G., Kato, T., Koyano, K., Lavigne, G. J., De Leeuw, R., Manfredini, D., Svensson, P., & Winocur, E. (2013). Bruxism defined and graded: An international consensus. *Journal of Oral Rehabilitation*, 40(1), 2-4. <https://doi.org/10.1111/joor.12011>
- Lobbezoo, F., Ahlberg, J., Manfredini, D., & Winocur, E. (2012). Are bruxism and the bite causally related? *Journal of Oral Rehabilitation*, 39(7), 489-501. <https://doi.org/10.1111/j.1365-2842.2012.02298.x>
- Lobbezoo, F., Ahlberg, J., Raphael, K. G., Wetselaar, P., Glaros, A. G., Kato, T., Santiago, V., Winocur, E., De Laat, A., De Leeuw, R., Koyano, K., Lavigne, G. J., Svensson, P., & Manfredini, D. (2018). International consensus on the assessment of bruxism: Report of a work in progress. *Journal of Oral Rehabilitation*, 45(11), 837-844. <https://doi.org/10.1111/joor.12663>
- Lu, J., Zhang, Y., Han, K., Wang, C., Zhong, Z., Xu, M., Zou, X., Yu, B., & Yao, D. (2021). Heart rate changes associated with rhythmic masticatory muscle activities and limb movements in sleep bruxers: Preliminary findings. *CRANIO®*, 39(1), 47-57. <https://doi.org/10.1080/08869634.2019.1578032>
- Lundell, R. V., & Ojanen, T. (2023). A systematic review of HRV during diving in very cold water. *International Journal of Circumpolar Health*, 82(1), 2203369. <https://doi.org/10.1080/22423982.2023.2203369>
- Macaluso, G. M., Guerra, P., Di Giovanni, G., Boselli, M., Parrino, L., & Terzano, M. G. (1998). Sleep Bruxism is a Disorder Related to Periodic Arousals During Sleep. *Journal of Dental Research*, 77(4), 565-573. <https://doi.org/10.1177/00220345980770040901>

- Maeda, M., Yamaguchi, T., Mikami, S., Yachida, W., Saito, T., Sakuma, T., Nakamura, H., Saito, M., Mizuno, M., Yamada, K., & Satoh, K. (2020). Quantitative analyses of jaw-opening muscle activity during the active phase of jaw-closing muscles in sleep bruxism. *Journal of Sleep Research*, 29(6), e12922. <https://doi.org/10.1111/jsr.12922>
- Maluly, M., Andersen, M. L., Dal-Fabbro, C., Garbuio, S., Bittencourt, L., De Siqueira, J. T. T., & Tufik, S. (2013). Polysomnographic Study of the Prevalence of Sleep Bruxism in a Population Sample. *Journal of Dental Research*, 92(7_suppl), S97-S103. <https://doi.org/10.1177/0022034513484328>
- Maluly, M., Dal Fabbro, C., Andersen, M. L., Herrero Babiloni, A., Lavigne, G. J., & Tufik, S. (2020). Sleep bruxism and its associations with insomnia and OSA in the general population of Sao Paulo. *Sleep Medicine*, 75, 141-148. <https://doi.org/10.1016/j.sleep.2020.06.016>
- Manfredini, D., Ahlberg, J., Aarab, G., Bracci, A., Durham, J., Ettlin, D., Gallo, L. M., Koutris, M., Wetselaar, P., Svensson, P., & Lobbezoo, F. (2020). Towards a Standardized Tool for the Assessment of Bruxism (STAB)—Overview and general remarks of a multidimensional bruxism evaluation system. *Journal of Oral Rehabilitation*, 47(5), 549-556. <https://doi.org/10.1111/joor.12938>
- Manfredini, D., Ahlberg, J., Wetselaar, P., Svensson, P., & Lobbezoo, F. (2019). The bruxism construct: From cut-off points to a continuum spectrum. *Journal of Oral Rehabilitation*, 46(11), 991-997. <https://doi.org/10.1111/joor.12833>
- Manfredini, D., Serra-Negra, J., Carboncini, F., & Lobbezoo, F. (2017). Current Concepts of Bruxism. *The International Journal of Prosthodontics*, 30(5), 437-438. <https://doi.org/10.11607/ijp.5210>
- Manfredini, D., Winocur, E., Guarda-Nardini, L., Paesani, D., & Lobbezoo, F. (2013). Epidemiology of Bruxism in Adults: A Systematic Review of the Literature. *Journal of Orofacial Pain*, 27(2), 99-110. <https://doi.org/10.11607/jop.921>
- Martinot, J., Le-Dong, N., Cuthbert, V., Denison, S., Gozal, D., & Pepin, J. (2020). 0792 Mandibular Movement Monitoring with Artificial Intelligence Analysis for the Diagnosis of Sleep Bruxism. *Sleep*, 43(Supplement_1), A301-A302. <https://doi.org/10.1093/sleep/zsaa056.788>
- Martinot, J.-B., Le-Dong, N.-N., Cuthbert, V., Denison, S., Gozal, D., Lavigne, G., & Pépin, J.-L. (2021). Artificial Intelligence Analysis of Mandibular Movements Enables Accurate Detection of Phasic Sleep Bruxism in OSA Patients: A Pilot Study. *Nature and Science of Sleep*, Volume 13, 1449-1459. <https://doi.org/10.2147/NSS.S320664>
- Martins, M. F. L., Piovezane, F. J., Carneiro, D. P. A., Menezes, C. C. D., Venezian, G. C., & Vedovello, S. A. S. (2024). The Behavior of Probable Sleep Bruxism, Anxiety and Need for Orthodontic Treatment in Adolescents. *Pesquisa Brasileira em Odontopediatria e Clínica Integrada*, 24, e230086. <https://doi.org/10.1590/pboci.2024.066>
- McAuliffe, P., Kim, J. H., Diamond, D., Lau, K. T., & O'Connell, B. C. (2015). A sleep bruxism detection system based on sensors in a splint – pilot clinical data. *Journal of Oral Rehabilitation*, 42(1), 34-39. <https://doi.org/10.1111/joor.12223>

- Melekoglu, E., Kocabicak, U., Uçar, M. K., Bilgin, C., Bozkurt, M. R., & Cunkas, M. (2022). A new diagnostic method for chronic obstructive pulmonary disease using the photoplethysmography signal and hybrid artificial intelligence. *PeerJ Computer Science*, 8, e1188. <https://doi.org/10.7717/peerj-cs.1188>
- Melo, G., Duarte, J., Pauletto, P., Porporatti, A. L., Stuginski-Barbosa, J., Winocur, E., Flores-Mir, C., & De Luca Canto, G. (2019). Bruxism: An umbrella review of systematic reviews. *Journal of Oral Rehabilitation*, 46(7), 666-690. <https://doi.org/10.1111/joor.12801>
- Miettinen, T., Myllymaa, K., Hukkanen, T., Töyräs, J., Sipilä, K., & Myllymaa, S. (2018). Home Polysomnography Reveals a First-Night Effect in Patients With Low Sleep Bruxism Activity. *Journal of Clinical Sleep Medicine*, 14(08), 1377-1386. <https://doi.org/10.5664/jcsm.7278>
- Millasseau, S. C., Kelly, R. P., Ritter, J. M., & Chowienczyk, P. J. (2002). Determination of age-related increases in large artery stiffness by digital pulse contour analysis. *Clinical Science*, 103(4), 371-377. <https://doi.org/10.1042/cs1030371>
- Millasseau, S. C., Ritter, J. M., Takazawa, K., & Chowienczyk, P. J. (2006). Contour analysis of the photoplethysmographic pulse measured at the finger. *Journal of Hypertension*, 24(8), 1449-1456. <https://doi.org/10.1097/01.hjh.0000239277.05068.87>
- Neu, D., Baniasadi, N., Newell, J., Styczen, D., Glineur, R., & Mairesse, O. (2018). Effect of sleep bruxism duration on perceived sleep quality in middle-aged subjects. *European Journal of Oral Sciences*, 126(5), 411-416. <https://doi.org/10.1111/eos.12564>
- O'Hare, E., Cogan, J. A., Dillon, F., Lowery, M., & O'Cearbhaill, E. D. (2022). An Intraoral Non-Occlusal MEMS Sensor for Bruxism Detection. *IEEE Sensors Journal*, 22(1), 153-161. <https://doi.org/10.1109/JSEN.2021.3128246>
- Okamoto, M., & Murao, K. (2023). PPG2EMG: Estimating Upper-Arm Muscle Activities and EMG from Wrist PPG Values. *Sensors*, 23(4), 1782. <https://doi.org/10.3390/s23041782>
- Orhan, K., Yazici, G., Önder, M., Evli, C., Volkan-Yazici, M., Kolsuz, M. E., Bağış, N., Kafa, N., & Gönüldaş, F. (2024). Development and Validation of an Ultrasonography-Based Machine Learning Model for Predicting Outcomes of Bruxism Treatments. *Diagnostics*, 14(11), 1158. <https://doi.org/10.3390/diagnostics14111158>
- Özen Kavas, P., Recep Bozkurt, M., Kocayigit, İ., & Bilgin, C. (2023). Machine learning-based medical decision support system for diagnosing HFpEF and HFrEF using PPG. *Biomedical Signal Processing and Control*, 79, 104164. <https://doi.org/10.1016/j.bspc.2022.104164>
- Park, J., Seok, H. S., Kim, S.-S., & Shin, H. (2022). Photoplethysmogram Analysis and Applications: An Integrative Review. *Frontiers in Physiology*, 12, 808451. <https://doi.org/10.3389/fphys.2021.808451>

- Pereira, L. F., Muniz, F. W. M. G., De Lima, M. D. D. M., Rösing, C. K., De Deus Moura, L. D. F. A., De Moura, M. S., & Lima, C. C. B. (2024). Genetics and sleep bruxism: A systematic review and meta-analysis of studies with twins. *Sleep and Breathing*, 28(5), 2269-2281. <https://doi.org/10.1007/s11325-024-03090-5>
- Peruzzi, G., Galli, A., & Pozzebon, A. (2022). A Novel Methodology to Remotely and Early Diagnose Sleep Bruxism by Leveraging on Audio Signals and Embedded Machine Learning. *2022 IEEE International Symposium on Measurements & Networking (M&N)*, 1-6. <https://doi.org/10.1109/MN55117.2022.9887782>
- Powers, D. M. W. (2020, Ekim 11). *Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation*. arXiv.Org. <https://arxiv.org/abs/2010.16061v1>
- Raphael, K. G., Santiago, V., & Lobbezoo, F. (2016). Is bruxism a disorder or a behaviour? Rethinking the international consensus on defining and grading of bruxism. *Journal of Oral Rehabilitation*, 43(10), 791-798. <https://doi.org/10.1111/joor.12413>
- Rintakoski, K., Hublin, C., Lobbezoo, F., Rose, R. J., & Kaprio, J. (2012). Genetic Factors Account for Half of the Phenotypic Variance in Liability to Sleep-Related Bruxism in Young Adults: A Nationwide Finnish Twin Cohort Study. *Twin Research and Human Genetics*, 15(6), 714-719. <https://doi.org/10.1017/thg.2012.54>
- Rintakoski, K., & Kaprio, J. (2013). Legal Psychoactive Substances as Risk Factors for Sleep-Related Bruxism: A Nationwide Finnish Twin Cohort Study. *Alcohol and Alcoholism*, 48(4), 487-494. <https://doi.org/10.1093/alcalc/agt016>
- Roscher, R., Bohn, B., Duarte, M. F., & Garcke, J. (2020). Explainable Machine Learning for Scientific Insights and Discoveries. *IEEE Access*, 8, 42200-42216. <https://doi.org/10.1109/ACCESS.2020.2976199>
- Ruggiero, E., Alonso-de Castro, S., Habtemariam, A., & Salassa, L. (2016). Upconverting nanoparticles for the near infrared photoactivation of transition metal complexes: New opportunities and challenges in medicinal inorganic photochemistry. *Dalton Transactions*, 45(33), 13012-13020. <https://doi.org/10.1039/C6DT01428C>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Sateia, M. J. (2014). International classification of sleep disorders-third edition highlights and modifications. *Chest*, 146(5). <https://doi.org/10.1378/chest.14-0970>
- Savla, K., Vardhan, V., & Aage, D. (2021). Physiotherapy in Bruxism: A Scoping Review. *International Journal of Health Sciences and Research*, 11(6), 115-125. <https://doi.org/10.52403/ijhsr.20210616>
- Schölkopf, B., & Smola, A. J. (2001). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. The MIT Press. <https://doi.org/10.7551/mitpress/4175.001.0001>

- Shafizadeh-Moghadam, H. (2021). Fully component selection: An efficient combination of feature selection and principal component analysis to increase model performance. *Expert Systems with Applications*, 186, 115678. <https://doi.org/10.1016/j.eswa.2021.115678>
- Shriram, R., Sundhararajan, D. M., & Daimiwal, N. (2013). *EEG Based Cognitive Workload Assessment for Maximum Efficiency*. <https://api.semanticscholar.org/CorpusID:10897702>
- Soares, J. P., Moro, J., Massignan, C., Cardoso, M., Serra-Negra, J. M., Maia, L. C., & Bolan, M. (2021). Prevalence of clinical signs and symptoms of the masticatory system and their associations in children with sleep bruxism: A systematic review and meta-analysis. *Sleep Medicine Reviews*, 57, 101468. <https://doi.org/10.1016/j.smr.2021.101468>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Solorio-Fernández, S., Carrasco-Ochoa, J. A., & Martínez-Trinidad, J. F. (2022). A survey on feature selection methods for mixed data. *Artificial Intelligence Review*, 55(4), 2821-2846. <https://doi.org/10.1007/s10462-021-10072-6>
- Sonmezocak, T., & Kurt, S. (2021). Machine learning and regression analysis for diagnosis of bruxism by using EMG signals of jaw muscles. *Biomedical Signal Processing and Control*, 69, 102905. <https://doi.org/10.1016/j.bspc.2021.102905>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(56), 1929-1958.
- Stone, M. (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 36(2), 111-133. <https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>
- Suhaib Kidwai, M., & Zunnun Khan, M. (2021). A new perspective of detecting and classifying neurological disorders through recurrence and machine learning classifiers. *2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 200-206. <https://doi.org/10.1109/ICACITE51222.2021.9404645>
- Sun, L., Zhang, X.-Y., Qian, Y.-H., Xu, J.-C., Zhang, S.-G., & Tian, Y. (2019). Joint neighborhood entropy-based gene selection method with fisher score for tumor classification. *Applied Intelligence*, 49(4), 1245-1259. <https://doi.org/10.1007/s10489-018-1320-1>
- Şahin, T. (2024). Bruxism awareness and self-assessment in dental clinical students: A questionnaire-based study. *BMC Oral Health*, 24(1), 1223. <https://doi.org/10.1186/s12903-024-04997-x>
- Takaoka, R., Ishigaki, S., Yatani, H., Ogata, S., & Hayakawa, K. (2017). Evaluation of genetic factors involved in nocturnal electromyographic activity of masticatory muscles in twins. *Clinical Oral Investigations*, 21(1), 319-325. <https://doi.org/10.1007/s00784-016-1794-3>

- Tan, M., Yap, A., Chua, A., Wong, J., Parot, M., & Tan, K. (2019). Prevalence of Sleep Bruxism and Its Association with Obstructive Sleep Apnea in Adult Patients: A Retrospective Polysomnographic Investigation. *Journal of Oral & Facial Pain and Headache*, 33(3), 269-277. <https://doi.org/10.11607/ofph.2068>
- Tiwari, S., Arora, D., & Nagar, V. (2024). Advanced EEG-Based Classification of Periodic Leg Movements and Bruxism Using Complexity and Entropy Features. *Procedia Computer Science*, 235, 1034-1043. <https://doi.org/10.1016/j.procs.2024.04.098>
- Trenouth, M. J. (1979). The relationship between bruxism and temporomandibular joint dysfunction as shown by computer analysis of nocturnal tooth contact patterns. *Journal of Oral Rehabilitation*, 6(1), 81-87. <https://doi.org/10.1111/j.1365-2842.1979.tb00408.x>
- Tripathi, P., Ansari, M. A., Gandhi, T. K., Albalwy, F., Mehrotra, R., & Mishra, D. (2024). Computational ensemble expert system classification for the recognition of bruxism using physiological signals. *Heliyon*, 10(4), e25958. <https://doi.org/10.1016/j.heliyon.2024.e25958>
- Uçar, M. K. (2017). *Obstrüktif Uyku Apne Teşhisi İçin Makine Öğrenmesi Tabanlı Yeni Bir Yöntem Geliştirilmesi*. Sakarya Üniversitesi.
- Uçar, M. K., Nour, M., Sindi, H., & Polat, K. (2020). The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets. *Mathematical Problems in Engineering*, 2020, 1-17. <https://doi.org/10.1155/2020/2836236>
- Uma, U., Fongpisuttikul, P., Padungpipatbawon, P., & Luyapan, P. (2024). Prevalence, awareness, and management of bruxism in Thai dental students: A cross-sectional study. *CRANIO®*, 42(5), 532-538. <https://doi.org/10.1080/08869634.2021.2015557>
- Walker, M. (2017). *Why We Sleep: Unlocking the Power of Sleep and Dreams* (Illustrated edition). Scribner.
- Wang, S., Li, D., Song, X., Wei, Y., & Li, H. (2011). A feature selection method based on improved fisher's discriminant ratio for text sentiment classification. *Expert Systems with Applications*, 38(7), 8696-8702. <https://doi.org/10.1016/j.eswa.2011.01.077>
- Wetselaar, P., Vermaire, E. (J. H.), Lobbezoo, F., & Schuller, A. A. (2019). The prevalence of awake bruxism and sleep bruxism in the Dutch adult population. *Journal of Oral Rehabilitation*, 46(7), 617-623. <https://doi.org/10.1111/joor.12787>
- Winck, M., Drummond, M., Viana, P., Pinho, J. C., & Winck, J. C. (2017). Sleep bruxism associated with obstructive sleep apnoea syndrome – A pilot study using a new portable device. *Revista Portuguesa de Pneumologia (English Edition)*, 23(1), 22-26. <https://doi.org/10.1016/j.rppnen.2016.07.001>
- Yanez-Regonesi, F., Eisa, E., Judge, S., Carlson, C., Okeson, J., & Moreno-Hay, I. (2023). Diagnostic accuracy of a portable device (Bruxoff®) to measure sleep bruxism. *Journal of Oral Rehabilitation*, 50(4), 258-266. <https://doi.org/10.1111/joor.13416>

- Yap, Adrian U. J., & Chua, A. (2016). Sleep bruxism: Current knowledge and contemporary management. *Journal of Conservative Dentistry*, 19(5), 383. <https://doi.org/10.4103/0972-0707.190007>
- Yıldırım, K., Uçar, M. K., Bozkurt, F., & Bozkurt, M. R. (2021). Diagnosis of Parkinson's Disease with Acoustic Sounds by Rule Based Model. İçinde J. Hemanth, T. Yigit, B. Patrut, & A. Angelopoulou (Ed.), *Trends in Data Engineering Methods for Intelligent Systems* (C. 76, ss. 59-75). Springer International Publishing. https://doi.org/10.1007/978-3-030-79357-9_7
- Younes, H., Ibrahim, A., Rizk, M., & Valle, M. (2021). An Efficient Selection-Based kNN Architecture for Smart Embedded Hardware Accelerators. *IEEE Open Journal of Circuits and Systems*, 2, 534-545. <https://doi.org/10.1109/OJCAS.2021.3108835>
- Zieliński, G., Pająk, A., & Wójcicki, M. (2024). Global Prevalence of Sleep Bruxism and Awake Bruxism in Pediatric and Adult Populations: A Systematic Review and Meta-Analysis. *Journal of Clinical Medicine*, 13(14), 4259. <https://doi.org/10.3390/jcm13144259>



ÖZGEÇMİŞ

Ad-Soyad : Ömer ERİŞ

ÖĞRENİM DURUMU:

- **Lisans** : 2007, Marmara Üniversitesi, Teknik Eğitim Fakültesi, Elektronik ve Haberleşme Öğretmenliği
- **Lisans** : 2017, Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2010, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik-Haberleşme Eğitimi

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2007-2009 Servis Mühendisi, Gelecek Yönetim Merkezi.
- 2009-Devam Öğretim Görevlisi, Bursa Uludağ Üniversitesi, İnegöl Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Elektrik Programı.
- 2015-Devam Bölüm Başkanı, Bursa Uludağ Üniversitesi, İnegöl Meslek Yüksekokulu, Elektrik ve Enerji Bölümü.
- 2010-Devam Program Başkanı, Bursa Uludağ Üniversitesi, İnegöl Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Elektrik Programı.

TEZDEN TÜRETİLEN ESERLER:

- Ö. Eriş, S. Bulut Eriş, C. Bilgin and M. R. Bozkurt, "IIR Based Digital Filter Design for Denoising the Photoplethysmography Signal," 2021 29th Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkey, 2021, pp. 1-4, doi: 10.1109/SIU53274.2021.9477993.
- O. Eris, M. Recep Bozkurt, S. Bulut Eris and C. Bilgin, "An Artificial Intelligence-Based Approach With Photoplethysmogram and Heart Rate Variability for Sleep Bruxism Diagnosis," in IEEE Access, vol. 13, pp. 40413-40428, 2025, doi: 10.1109/ACCESS.2025.3546720.
- Eriş Ö., Bilgin C., Bulut Eriş S. ve Bozkurt M. R., (2025, 21-23, Şubat). Bruksizm Tanısında Yapay Zeka: Fotopletismografi ve Kalp Hızı Değişkenliği Kullanılarak

Non-Invazif Bir Yaklaşım. Uluslararası 4.Dental Oral Enfeksiyonlar (4.Doinf) Ve 3.Ağız Mikrobiyotası Kongresi. Journal of Biotechnology and Strategic Health Research 2025. E-ISSN:2587-1641, Sakarya, Türkiye.

DİĞER ESERLER:

- Ö. Eriş, S. Bulut Eriş, and M. R. Bozkurt, “Mamografik Kitle Sınıfının Makine Öğrenmesi Teknikleri ile Tespiti”, Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, vol. 11, no. 1, pp. 164–175, 2022, doi: 10.17798/bitlisfen.1003938.
- S. Bulut Eris, M. Recep Bozkurt, O. Eris and C. Bilgin, "A Huge Innovation in Diagnosis of Obstructive Sleep Apnea Syndrome: With an Artificial Intelligence-Based Algorithm, Obstructive Sleep Apnea Syndrome Can Now Be Diagnosed With Pulmonary Function Test," in IEEE Access, vol. 13, pp. 15376-15389, 2025, doi: 10.1109/ACCESS.2025.3531501.
- Bulut Eriş, S., Bilgin, C., Eriş, Ö., & Bozkurt, M. R., (2023). A review of the relationship between flow-volume curve and obstructive sleep apnea. INTERNATIONAL JOURNAL OF MEDICAL ENGINEERING AND INFORMATICS , vol.1, no.1, 1-11.